

SIRADÜZENSEL BÖLÜTLEME İLE TÜRDEŞ OLMAYAN YAPILARIN SEZİMİ DETECTION OF HETEROGENEOUS STRUCTURES USING HIERARCHICAL SEGMENTATION

H. Gökhan Akçay, Selim Aksoy

Bilgisayar Mühendisliği Bölümü, Bilkent Üniversitesi, Bilkent, 06800, Ankara

{akçay, saksoy}@cs.bilkent.edu.tr

ÖZETÇE

Basit türdeş yapıdaki temel nesnelerden oluşan karmaşık heterojen görüntü yapılarının bulunması için sıradüzensel bir bölütleme algoritması önermekteyiz. İlk adımda, türdeş spektral içeriğe sahip temel nesnelere karşılık gelen bölgeler oluşturulmaktadır. Daha sonra, birbirine komşu bölgeler arasındaki eş oluşumlar modellenmektedir ve öbeklenmektedir. Bu eş oluşum uzayında yoğun ve büyük öbeklerin önemli olduğu varsayılmaktadır. Son olarak, önemli öbeklere ait komşu bölgeler, sıradüzensel bir sonraki ölçeği elde etmek amacıyla birleştirilmektedir. Deneyler, bölge gruplarını yinelemeli olarak birleştiren algoritmanın, heterojen yapıları sıradüzensel bir şekilde bölütleyebildiğini göstermektedir.

ABSTRACT

We present an unsupervised hierarchical segmentation algorithm for detecting complex heterogeneous image structures that are comprised of simpler homogeneous primitive objects. The first step segments primitive objects with uniform spectral content. Then, the co-occurrence information between neighboring regions is modeled and clustered. We assume that dense clusters of this co-occurrence space can be considered significant. Finally, the neighboring regions within these clusters are merged to obtain the next level in the segmentation hierarchy. The experiments show that the algorithm that iteratively clusters and merges region groups is able to segment heterogeneous structures in a hierarchical manner.

1. GİRİŞ

Bölütleme, bilgisayarla görmede ve görüntü tanımda klasik bir problemdir. Popüler yöntemler spektral ve/veya doksal türdeşliğe sahip piksel gruplarını bulmayı amaçlamakta ve genellikle az sayıda nesne içeren görüntülere uygulanmaktadır. Halbuki, karmaşık bir sahnedeki birçok nesne için güzel çalışan iyi bir parametre kümesi bulmak neredeyse imkansızdır. Öte yandan, farklı nesneler farklı ölçeklerde ortaya çıktığı için sıradüzensel bölütleme büyük ilgi görmüştür. Verilen bir sıradüzensel bölütlemeye, anlamlı ve ilginç nesneler seçip çıkartılabilir [1, 2]. Burada önemli bir problem, sıradüzenin nasıl oluşturulacağını belirlemesidir. [1, 2]'teki genel yaklaşım, spektral türdeşliğe dayanarak bölme ve/veya birleştirme yapmaktır. Fakat bu yaklaşım, özü itibarıyla heterojen olan ve farklı spektral karakteristiklerde elemanlara

sahip karmaşık yapılar için iyi çalışmamaktadır. Bunun gibi kısıtlamalardan dolayı, ilgi duyulan birçok yapı sıradüzensel ortaya çıkmamaktadır. Bir alternatif olarak, Scarpa ve diğerleri [3], beraber sık görülen birbirine komşu bölgelerin güçlü bir şekilde ilişkili olduğunu varsayarak sıradüzensel doku bölütlemesi gerçekleştirmişlerdir. Güçlü şekilde ilişkili bölgeleri bulmak amacıyla, nicemlenmiş bölge çiftlerinin frekanslarını hesaplamak için görüntü piksellerini öbeklemişlerdir. Ancak, bu frekanslar deneme yanılma yoluyla belirlenen öbek sayısına çok duyarlıdır.

Bu bildiri, karmaşık heterojen yapıları içeren bir sıradüzen oluşturmak amacıyla, bölge tiplerini belirlemek için önceden öbekleme gerektirmeyen bir algoritma üzerine odaklanmaktadır. Algoritma, birleştirme için yalnızca renk bilgisine bağlı değildir. Birleşecek ilginç komşu bölge çiftlerini bulmak için, görüntü bölütlemesini bölgeler arası eş oluşum (co-occurrence) uzayı olarak kodlamaktadır. Birinci adım, türdeş spektral içeriğe sahip temel nesnelere karşılık gelen bölgeler oluşturan ilk bölütlemedir (2. bölüm). Sonraki adım, birbirine komşu bölgeler arasındaki eş oluşum bilgisini modelleme ve birlikte görülme frekanslarını hesaplamadır (3. bölüm). Son olarak, birleşmesi gereken bölgeleri belirlemek için önemli eş oluşumlar otomatik olarak seçilmektedir (4. bölüm). [1]'de sunulan daha önceki çalışmamız ile bu makalede önerilen yaklaşım arasındaki temel fark, öncekinde bir bölütleme sıradüzeninden türdeş bölgeleri otomatik olarak seçmek amaçlanırken, burada heterojen bölgelerden oluşan bir sıradüzen oluşturmaya odaklanılmaktadır. Birden çok banta sahip bir uydu görüntüsü, bir renkli doku mozaik görüntüsü, ve doğal görüntüler kullanılarak yapılan deneyler, karmaşık yapıların sıradüzensel bölütlemesi için önerilen bölgeler arası eş oluşum modellemesinin etkinliğini göstermektedir (5. bölüm).

2. İLK BÖLÜTLEME VE ÖZNİTELİK ÇIKARMA

İlk adım, türdeş renk içeriğine sahip bölgeler temel nesnelere karşılık gelecek şekilde görüntünün bir bölütlemesini elde etmektir. Bu ilk bölütleme aşaması için, çok sayıda banta sahip görüntünün genelleştirilmiş gradyanı [4] üzerine biçimbilimsel havza (watershed) dönüşümü uygulanmaktadır.

Bölütlemekten elde edilen bölgeler, spektral ve büyüklük bilgisi ile temsil edilmektedir. Her bir bölge için spektral bilgi,



Şekil 1: 3, 4, ve 6. ölçeklerdeki en önemli eş oluşumlara karşılık gelen öbekler. Seçilmiş olan eş oluşumlar mavi ile işaretlenmekte, ve ilgili bölgeler daha net gösterilmektedir.

her bir spektral bant için bölge içerisindeki piksellerin ortalama değerlerinden oluşmaktadır. Büyüklük bilgisi, her bir bölgedeki piksel sayısına karşılık gelmektedir. Bütün öznitelikler, doğrusal ölçekleme kullanılarak $[0, 1]$ aralığına düzgelendirilmiştir. k spektral bantla birlikte bölütlemesi verilen bir görüntü için, her bir R_i bölgesi $\mathbf{y}_i = (b_{i1}, \dots, b_{in}, s_i)$ öznitelik vektörü kullanılarak temsil edilmektedir. Burada, b_{ik} , $k = 1, \dots, n$, k inci spektral bant için ortalama değere karşılık gelirken, s_i bölgenin büyüklüğüdür.

3. KOMŞU BÖLGELERİN MODELLENMESİ

Karmaşık heterojen yapıların bölütlenmesi için, farklı karakteristiklerdeki birbirine komşu bölgelerin birleşmesi gerekmektedir. Bu çalışmada, birleşmesi gereken bölgelerin otomatik olarak seçilmesi için öğreticisiz bir algoritma sunulmaktadır. Algoritmanın girdisi, bölge öznitelikleriyle beraber bir bölütlemedir. Amacımız bu bölütlemeye önemli komşulukları bulmaktır. Bu makalede, önemli komşulukları, birbirine komşu bölgeler arasındaki eş oluşum frekansları ile bulmaktayız. Burada, karmaşık yapıların beraber sıkça görülen nesnelerden oluştuğu varsayımını kullanmaktayız. Örneğin, bir uydu görüntüsündeki yerleşim alanları, heterojen yapılar olarak ifade edilebilmekte ve çok sayıda bina-bitki ve bina-yol komşuluğundan meydana gelmektedir.

3.1. Bölgeler arası eş oluşumların modellenmesi

Bu motivasyon ile, birleşmesi gereken bölgeleri bulmak için, birbirine komşu bölgeler arasındaki eş oluşumları modellemekteyiz. Sınırlarının keşişiminin uzunluğunun büyük bölgenin çevre uzunluğuna oranı, bir uzunluk eşiğinden yüksek olan iki bölge birbirine komşu olarak ifade edilmektedir. R_i ve R_j birbirine komşu iki bölge olsun. Bu iki bölge arasındaki komşuluk, eş oluşum uzayında, $\mathbf{y}_i$ ve $\mathbf{y}_j$ öznitelik vektörlerinin $\mathbf{y}_{ij} = (\mathbf{y}_i, \mathbf{y}_j)$ ve $\mathbf{y}_{ji} = (\mathbf{y}_j, \mathbf{y}_i)$ şeklinde art arda bağlanmasıyla elde edilen iki öznitelik ile temsil edilmektedir. Bu uzay, bölge özniteliklerini görüntüdeki eş oluşum frekansları ile beraber kodlamaktadır.

3.2. Eş oluşum uzayının öbeklenmesi

Burada kullanılan varsayımda, benzer iki bölge çifti (örneğin, bina-bitki çiftleri) eş oluşum uzayında birbirine yakın yer almaktadır. Benzer eş oluşumlar yoğun öbekler oluşturmak üzere bir araya toplanırken, az görülen eş oluşumlar seyrek olarak yerleşmişlerdir. Amaç, önemli komşuluklara karşılık gelen eş oluşumlara ait tutarlı öbekler bulmaktır. Sonuç olarak elde edilen öbekler görüntüde farklı tiplerde komşuluklara karşılık gelmektedir.

Bu çalışmada, öbekleme problemini çözmek için, Gauss Karışım Modeli (GKM) [5] kullanılmaktadır. Burada, GKM'deki bileşenler farklı eş oluşumlara ait öbeklere karşılık gelmektedir. Öbeklerin biçimleri, benzer komşuların eş oluşum uzayında doruk noktaları etrafında toplanacağı beklentisinden dolayı, sezgisel olarak Gauss varsayılmaktadır. GKM, beklenti-embüyütme algoritması ve minimum tanımlama uzunluğu (MTU) sıra kestirimi ölçütü kullanılarak öğrenilmektedir. Burada, öbek sayısının doğrudan veriden kestirilmesi önemli bir noktadır. Çünkü, belirli bir bölütlemeye benzer komşuların sayısını tahmin etmek çoğu kez imkansızdır. MTU ile öbek sayısı seçildikten ve öbekler oluşturulduktan sonra, her bir eş oluşum en yüksek olasılıklı öbeğe atanmaktadır. Önemli bir gözlem olarak, ortaya çıkan öbeklerin çoğu, karmaşık görüntü içeriğinden dolayı uzayda seyrek olarak bulunabilen önemli eş oluşumları temsil etmekte yeterli (yeteri kadar yoğun) değildir.

4. SIRADÜZENSEL BÖLÜTLEME

Eş oluşumları öbekledikten sonra, sonraki büyük problem önemli eş oluşumlara karşılık gelen öbekleri bulmaktır. Yeteri kadar yoğun ve büyük öbeklerin önemli eş oluşumlara karşılık geldiğini varsaymaktayız. Bu öbekler, her bir öbekteki öğelerin ortalama log-olabilirlik (log-likelihood) değerleri karşılaştırılarak bulunabilir. Sonuç olarak, ortalama log-olabilirlik değerleri, bütün öbeklerin log-olabilirliklerinin ortalamasından yüksek olan öbekleri seçmekteyiz. Şekil 1, sıradüzenin farklı ölçeklerinde seçilen bazı örnek öbekleri göstermektedir. Daha sonra, en yüksek ortalama log-olabilirlik değerine sahip öbekten başlayarak, seçilen her



Şekil 2: Örnek bir sıradüzzen.


bir öbek içerisinde bulunan eş oluşumlara ait bölgeleri ayrı ayrı birleştirmekteyiz. Bir bölge, seçilen farklı öbeklerde yer alan birden fazla eş oluşumda yer alırsa, bölge için, sadece, en önce seçilen ilgili öbeğe göre birleştirme işlemi gerçekleştirilmektedir.

Önemli eş oluşumlar birleştirildikten sonra sıradüzende bir sonraki ölçeği elde etmekteyiz. Sonuç olarak, ortaya çıkan bölgeler görüntüdeki karmaşık heterojen yapıları temsil etmektedir. Sıradüzendeki her bir ölçeği elde etmek için, öznitelik çıkarma, komşu bölgelerin modellenmesi, öbek seçilmesi, ve bölgelerin birleştirilmesi adımları tekrarlanmaktadır. Şekil 2, beş ölçekte ortaya çıkan bölgelerle kurulan örnek bir sıradüzene bir bölümünü göstermektedir.

Öznitelik çıkarılması adımında, spektral ortalama, karmaşık yapıları daha yüksek sıradüzzen ölçeklerinde ayırt etmekte yetersiz kalabilmektedir. Alternatif bir öznitelik gösterimi, her bir bölgedeki nesne türü dağılımıdır. Bu çalışmada, nesne türü dağılımı, nesne-koşullu olasılık dağılımlarını öğrenerek nesne modelleri oluşturan Olasılıksal Gizli Değişken Analizi (OGDA) algoritması [6] kullanılarak hesaplanmaktadır. Önce, spektral tanım kümesinde k -ortalama algoritması uygulanarak görüntüdeki tüm pikseller nicemlenmektedir. x_j nicemlemiş bir öznitelik değeri, ve s_i bir bölge olsun. Ek olarak, her bir gözlemle bağdaştırılan bir gizli nesne türü, t_k , bulunmaktadır. Burada gözlem, bir öznitelige belirli bir bölgede rastlanmasıdır. $P(x_j|t_k)$, x_j öznitelik değerinin t_k nesne türünde nesne-koşullu rastlanma olasılığı, ve $P(t_k|s_i)$, t_k nesne türünün s_i bölgesinde gözlemlenme olasılığını ifade etsin. $P(x_j|s_i)$ koşullu olasılığı şu şekilde hesaplanabilir:

$$P(x_j|s_i) = \sum_{k=1}^K P(x_j|t_k)P(t_k|s_i). \quad (1)$$

OGDA'da amaç, $P(x_j|t_k)$ ve $P(t_k|s_i)$ olasılıklarını bulmaktır. Bu olasılıklar, beklenti-embüytme algoritması [6] kullanılarak öğrenilmektedir. Daha sonra, bölgeye özel nesne türü dağılımı, $P(t_k|s_i)$, her bir bölgeyi temsil etmek için kullanılabilir. Yer sınırlamasından dolayı, her bir bölge için nesne türü dağılımının nasıl bulunduğuyla ilgili ayrıntılar [1]'e bırakılmıştır. Bu adımda öznitelik gösterimi olarak başka modeller de kullanılabilir.



Şekil 4: Yakınlaştırılmış sıradüzzen ölçek örnekleri.

5. DENEYLER


Önerilen sıradüzensel bölütleme algoritmasını üç farklı türden görüntüye uyguladık. Birinci görüntü, mavi, yeşil, kırmızı, ve yakın-kızılberisi bantlarını içeren Quickbird uydu görüntüsüdür. Algoritmayı çalıştırarak ilk bölütleme dahil 7 sıradüzzen ölçeği elde ettik. Şekil 3, farklı ölçeklerde örnek bölütleme sonuçlarını göstermektedir. Doğruluk verisi mevcut olmadığı için sadece nitel değerlendirme yapılmıştır. Bölgelerin hemen hemen türdeş kaldığı ilk 6 bölütleme ölçeği için, spektral ortalamalar ve bölge büyüklükleri kullanılmıştır. Altıncı sıradüzzen ölçeğinde, farklı spektral içeriğe sahip bölgeler karmaşık yapıları oluşturmak üzere birleşmiştir ve türdeşlik kaybolmuştur. Bu nedenle, en son ölçeği elde etmek için, bölge öznitelikleri olarak, nesne türü dağılımlarını kullandık. Şekil 4, farklı ölçeklerde bölgelerin birleşmesini yakınlaştırılmış bir alan üzerinde göstermektedir.

Sıradüzzen ölçekleri tek tek detaylı olarak incelendiğinde, ikinci sıradüzzen ölçeğinde birbirine komşu yeşil-gölge bölgelerinin ağaç bölgelerini oluşturmak üzere birleştiklerini görebilmekteyiz. Bir sonraki ölçekte, birbirine komşu çim-ağaç bölgeleri bitki bölgelerini oluşturmak üzere birleşmişlerdir. Bu durum beklenmektedir, çünkü, birçok yeşil-gölge ve daha sonra çim-ağaç öbekleri ortaya çıkaran bitkisel alanlar görüntüde çokça yer almaktadır. Dördüncü sıradüzzen ölçeğinde, parlak (güneş gören) ve koyu bina çatıları arasındaki komşuluk en önemli komşuluk olarak seçilerek bina bölgeleri ortaya çıkmıştır. Daha sonra, en önemli eş oluşumlar, birleştğinde yollarla ayrılan karmaşık yerleşim bölgeleri meydana getiren bitki-bina öbeklerine karşılık gelmiştir. En son sıradüzzen ölçeğinde, en önemli komşuluklar, daha büyük yerleşim alanlarını karmaşık yapılar olarak ortaya çıkaran yerleşim ve yol bölgeleri arasında meydana gelmiştir. (Burada sadece ilgili ölçeklerdeki en önemli eş oluşumlar tartışılmıştır. Sıradüzende başka komşuluklar da önemli olarak seçilmiş olabilir.)

Dokular da benzer türden eş oluşumlar içerdiği için heterojen yapılar olarak düşünülebilir. Bu eş oluşumlar, bölgelere ait farklı karakteristikler (örneğin, renk, şekil, yönelim) açısından meydana gelebilmektedir. Bundan dolayı, önerilen algoritmanın başarımını, sıradüzensel doku bölütleme için, bir mozaik görüntüsü [3] üzerinde de değerlendirdik. Şekil 5, elde edilen 15 bölütleme ölçeği arasında 4 tanesini göstermekte-



Şekil 3: Uydu görüntüsü için örnek sıradüzen ölççekleri: 1, 5, 7.



Şekil 5: Doku mozaik görüntüsü için örnek sıradüzen ölççekleri: 1, 6, 10, 16.

dir. Sonuçlar, bölütleme algoritmamızın görüntüdeki küçük ve büyük dokuları bölütleyebildiğini göstermektedir.

Önerilen algoritmayı doğal görüntüler üzerinde de uyguladık. Şekil 6’de, sıradüzenden elle seçilen örnek ölççekler gösterilmektedir. Sonuçlar, önerdiğimiz algoritmanın, sadece renk tabanlı türdeşliğe bakan geleneksel sıradüzensel yöntemlerle ayıramayacak karmaşık yapıları (örneğin, ayçiçekleri, zebra, ve şekerlemeler) düzgün ayırabildiğini göstermektedir.

6. SONUÇLAR

Sadece spektral veya dokusal türdeşliği gözönüne alan geleneksel sıradüzensel bölütleme yaklaşımlarından farklı olarak, basit nesnelerin oluşturduğu karmaşık gruplar olarak ortaya çıkan heterojen görüntü yapılarının sıradüzensel bölütlenmesi için öğreticisiz bir yöntem sunduk. Sıradüzende bir sonraki ölççeği elde etmek için birleşmesi gereken bölgeleri bulmak amacıyla



Şekil 6: Doğal görüntüler için örnek sıradüzen ölççekleri.

birbirine komşu bölgeler arasındaki eş oluşumları modelledik. Deneyler, önerilen algoritmanın, karmaşık görüntü yapılarını sıradüzensel bir şekilde bulabildiğini göstermiştir. İleriki çalışmalar, karmaşık yapıları sıradüzenden farklı ölççeklerinden farklı uygulamalar için otomatik olarak seçmeyi kapsayacaktır.

7. TEŞEKKÜR

Bu çalışma TÜBİTAK 104E074 ve 109E193 numaralı projeler tarafından desteklenmiştir.

8. KAYNAKÇA

- [1] H. Akcay and S. Aksoy, “Automatic detection of geospatial objects using multiple hierarchical segmentations,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 46, no. 7, pp. 2097–2111, July 2008.
- [2] N. Ahuja and S. Todorovic, “Connected segmentation tree — A joint representation of region layout and hierarchy,” in *CVPR*, 2008.
- [3] G. Scarpa, R. Gaetano, M. Haindl, and J. Zerubia, “Hierarchical multiple markov chain model for unsupervised texture segmentation,” *IEEE Transactions on Image Processing*, vol. 18, no. 8, pp. 1830–1843, August 2009.
- [4] S. Di Zenzo, “A note on the gradient of a multi-image,” *Computer Vision, Graphics, and Image Processing*, vol. 33, no. 1, pp. 116–125, 1986.
- [5] C. A. Bouman, “Cluster: An unsupervised algorithm for modeling Gaussian mixtures,” April 1997, available from <http://www.ece.purdue.edu/~bouman>.
- [6] T. Hofmann, “Unsupervised learning by probabilistic latent semantic analysis,” *Machine Learning*, vol. 42, no. 1-2, pp. 177–196, 2001.