

MEAN-SHIFT SEGMENTASYON ALGORİTMASI DESTEKLİ “EN BÜYÜK OLASILIK” SINIFLANDIRMA YÖNTEMİ KULLANILARAK TARIM ALANLARININ SINIFLANDIRILMASI

A. Özdarıcı¹, A. Ö. Ok²

¹Ortadoğu Teknik Üniversitesi, Jeodezi ve Coğrafi Bilgi Teknolojileri EABD, Ankara, ozdarici@metu.edu.tr

²Ortadoğu Teknik Üniversitesi, Jeodezi ve Coğrafi Bilgi Teknolojileri EABD, Ankara, oozgun@metu.edu.tr

ÖZET

Bu çalışmada, tarım alanları için Mean Shift segmentasyon algoritması destekli “En Büyük Olasılık” sınıflandırma yaklaşımı geliştirilmiştir. Amaç, tarımsal ürün sınıflandırması için etkili bir yöntem ortaya koymaktır. Test alanı olarak Bursa ilinde yer alan Karacabey Ovası seçilmiş ve alanın 10m çözünürlüğe sahip renkli SPOT 5 görüntüsü kullanılmıştır. Geliştirilen metodolojide, ilk olarak, SPOT 5 görüntüsüne Mean Shift segmentasyon algoritması uygulanarak görüntüyü oluşturan hücreler yansıma değerlerine bağlı olarak segmentlere ayrılmıştır. Devamında, segment edilen görüntü, eğitilmiş bir sınıflandırma yöntemi olan “En Büyük Olasılık” sınıflandırma yöntemi kullanılarak sınıflandırılmıştır. Elde edilen tematik haritanın güvenilirliği, doğruluk analizleri yardımıyla test edilmiş ve %78,73 doğruluk sağladığı görülmüştür. Bu yaklaşımla üretilen sonuç, parsel tabanlı sınıflandırma yöntemi sonucu ile de karşılaştırılmış ve yöntemin tematik harita üretimindeki başarısı belirlenmiştir. Sonuçta, öne sürülen yöntemin, tarım alanlarının sınıflandırılması için en etkili yöntem olarak bilinen parsel tabanlı sınıflandırma yöntemi sonucuna yakın olduğu görülmüştür.

Anahtar Sözcükler: Uzaktan Algılama, Görüntü İşleme, Tarım, Mean-Shift, SPOT 5.

ABSTRACT

“MAXIMUM LIKELIHOOD” CLASSIFICATION METHOD SUPPORTED WITH MEAN-SHIFT SEGMENTATION ALGORITHM TO CLASSIFY AGRICULTURAL LANDS

In this study, “Maximum Likelihood” classification approach supported with Mean-Shift segmentation algorithm was developed to classify agricultural lands. The focus of this study was to provide an effective approach for the classification of agricultural crops. The selected test site was located in Karacabey Plain of Bursa and a multispectral SPOT 5 image having 10m spatial resolution was used. In the first stage of the developed methodology, the SPOT 5 image was segmented using the Mean-Shift segmentation algorithm based on the spectral characteristics of the pixels that form the image. Next, a traditional pixel-based classification of “Maximum Likelihood” algorithm was applied on the segmented image and a thematic map was produced. The reliability of the produced thematic map was then assessed with accuracy analysis and the results revealed that the developed approach provided an overall accuracy of 78,73%. The results produced based on this approach was compared with the results of parcel-based classification to assess the performance of the developed methodology. Finally, it was concluded that the proposed approach provided similar results to the parcel-based classification which is known to be the most efficient method to classify agricultural lands.

Keywords: Remote Sensing, Image Processing, Agriculture, Mean-Shift, SPOT 5.

1. GİRİŞ

Nüfusun artmasıyla birlikte tarımsal üretime olan önem artmış ve tarım alanlarındaki ürünlerin etkili bir şekilde nasıl haritalanabileceği sorusu gündeme gelmiştir. Ürün tahmini ve gelişim aşamalarının belirlenmesi, ekonomiye olan katkının saptanabilmesi açısından önemlidir. Günümüzde bu amaç için var olan en etkili yöntem otomatik görüntü sınıflandırmasıdır. Bu yöntem ile uydu görüntülerini oluşturan hücrelerin bilgisayar ortamında sınıflandırılması yoluyla tarım alanlarından tematik harita üretimi sağlanabilmektedir. Tarım alanları için bilinen en temel sınıflandırma yöntemleri; (a) hücre tabanlı ve (b) parsel tabanlı sınıflandırmalardır. Son yıllarda kullanılmaya başlanan bir diğer yöntem ise segmentasyon algoritmaları destekli sınıflandırmalardır (Lee, et. al., 2006; Meyer et. al., 1996; Gaugeon, 1995). Geleneksel hücre tabanlı sınıflandırmalarda hücreler, önceden belirlenen sınıflara atanır. Fakat bu tür sınıflandırmaların, topraktaki nemlilik ve/veya ürünlerdeki hastalıklı bölgelerden kaynaklanan çeşitlilik vb. gibi etkiler sonucunda hücrelerin yanlış sınıflandırılmasına neden olabilecek kısıtlamaları vardır. Bir diğer sorun ise parseller arası geçişlerin yanlış hücre yansımalarına sebep olmasıdır (De Wit and Clevers, 2004). Bu gibi faktörler hücrelerin yansıma değerlerinde karışıklığa neden olmakta ve sınıflandırma sonucunu olumsuz yönde etkilemektedir. Tarım alanlarının hücre tabanlı sınıflandırılması esnasında ortaya çıkabilen bu gibi kısıtlamalar, bu alanlarının parsel tabanlı bir yöntem kullanılarak sınıflandırılmasına yönelimde etkili olmuştur. Parsel tabanlı sınıflandırma mantığının temeli, varolan tarım parsellerinin sınır bilgisinden yararlanılarak görüntünün homojen

“Mean Shift” Segmentasyon Algoritması Destekli “En Büyük Olasılık” Sınıflandırma Yöntemi Kullanılarak Tarım Alanlarının Sınıflandırılması

parsel bölgelerine ayrılmasıdır. Bu yöntemde, ilk olarak, hücre tabanlı sınıflandırmada olduğu gibi hücreler, yansıma değerlerine bağlı olarak sınıflandırılır. Sınıflandırılmış görüntü ile parsel sınırlarından oluşan veri üst üste çakıştırılarak her parselin içine düşen hücreler saydırılır ve her parsel için çoğunlukta olan hücre bilgisi ilgili parsel etiket bilgisi olarak atanır. Bu özelliğinden dolayı, parsel tabanlı sınıflandırma yöntemi ile parsel içindeki çeşitlilik ve parsel sınırlarına düşen karışık hücre etkileri giderilmiş olur (De Wit and Clevers, 2004). Giderek yaygınlaşmaya başlayan bir diğer yöntem segmentasyon destekli algoritmalar. Bu tür algoritmaların kullanımındaki amaç, görüntü üzerindeki (nesnelerin) parsellerin yardımcı bir veri olmadan (vektör vb.) istatistiksel özelliklerine göre homojen bölgelere ayrılmasıdır. Temel istatistiksel örnekleme teorisi, grupların kendilerini oluşturan elemanlardan daha ayırt edilebilir olduğunu ileri sürer. Birbirine komşu olan hücrelerin birlikte sınıflandırılmasının hücrelerin ayrı ayrı sınıflandırılmasından daha iyi sonuçlar sağladığı birçok çalışma tarafından kanıtlanmıştır (Lu et. al., 2007; Li and Gong, 2005; Luo and Guo, 2003). Bu çalışmalarda kullanılan algoritmalar Luo ve Guo (2003) tarafından genel olarak 4 grup altında toplanmıştır: (i) nesne tabanlı, (ii) kenar tabanlı, (iii) alan tabanlı segmentasyonlar ve (iv) hibrid görüntü segmentasyonu. Bu çalışmada hibrid bir segmentasyon yöntemi olan Mean-Shift segmentasyon algoritması kullanılmıştır.

Bu çalışmanın amacı, SPOT 5 renkli görüntüsüne hücre tabanlı sınıflandırma öncesinde Mean-Shift segmentasyon algoritması uygulamak, devamında eğitilmiş bir sınıflandırma yöntemi olan “En Büyük Olasılık” sınıflandırma yöntemi yoluyla sınıflandırarak sonuçta elde edilecek olan tematik haritanın sınıflandırma doğruluğunu arttırmak ve sonucu parsel tabanlı sınıflandırma yöntemi sonucu ile karşılaştırmaktır. Bu amaçla, ilk olarak, Mean-Shift algoritmasının temel parametresi olan kernel boyutu için optimum bir değer seçilerek SPOT 5 uydu görüntüsü segmentlere ayrılmıştır. Ardından, segment edilen görüntü üzerinden örnek alanlar toplanarak görüntü hücre tabanlı olarak sınıflandırılmıştır. Yöntemin doğruluğunu test etmek amacıyla referans verisi kullanılarak doğruluk analizi yapılmış ve sonuç, tarım alanları için etkili bir yöntem olarak bilinen parsel tabanlı sınıflandırma sonucu ile karşılaştırılmıştır. Karşılaştırma sonucunda, Mean-Shift segmentasyon algoritması destekli sınıflandırma doğruluğunun parsel tabanlı sınıflandırma doğruluğuna yakın olduğu görülmüştür.

2. ÇALIŞMA ALANI VE VERİ SETİ

Çalışma alanı, Bursa ilinin Karacabey ilçesinde yer alan Karacabey Ovasında yer almaktadır (Şekil 1). Yaklaşık 95 km² lik bir alanı kapsayan tarım alanı, 28°10'18" - 28°18'06" enlemleri and 40°13'43" - 40°08'37" boylamları arasındadır. Karacabey Ovası zengin toprak yapısı ve ikliminin üretime elverişli olması nedeniyle Türkiye'nin en verimli ovaları arasında yerini almaktadır. Bu özelliklerinden dolayı alanda; domates, biber, buğday, şeker pancarı ve pirinç başta olmak üzere çok sayıda ürün yetiştirilmektedir.



Şekil 1: Çalışma Alanı

Geliştirilen yöntemi uygulamak için 23 Temmuz 2004 tarihli, 10 m çözünürlüğe sahip renkli SPOT 5 uydu görüntüsü kullanılmıştır (Şekil 2). Görüntü, 1120 kolon ve 929 sıradan oluşmaktadır. Görüntü çekim tarihinin, ovadaki ürünlerin gelişmiş olduğu dönem olan yaz aylarında olmasına ve mümkün olduğunca bulutsuz bir günde çekilmesine dikkat edilmiştir. Kullanılan uydu görüntüsü, yer gözlem istasyonundan işlem seviyesi 2A olarak ve “Universal Transverse Mercator” (UTM) koordinat sisteminde alınmıştır. SPOT 5 görüntüsü, daha önce yapılan bir çalışmada 20 yer kontrol noktası kullanılarak vektör veriye göre geometrik olarak düzeltilmiştir. Geometrik düzeltme işlemi için ikinci derece polinom model ve düzeltme sonrasında hücrelere atanacak yeni radiometrik değerler için en yakın uzaklık yöntemi kullanılmıştır. Yapılan geometrik düzeltme sonucunda ortaya çıkan hata miktarı ±0,41 piksel olarak hesaplanmıştır. (Özdarıcı, 2005).

Yöntem sonuçlarının karşılaştırılacağı parsel tabanlı görüntü sınıflandırması için kullanılan vektör veri, 2003 yılında yapılan bir çalışmada üretilmiştir (Arıkan, 2003). Aynı vektör veri, daha sonra Özdarıcı (2005) tarafından güncellenerek bu çalışmada kullanılan halini almıştır. Güncellenen veride irili ufaklı toplam 4134 tarım parseli bulunmaktadır.



Şekil 2: SPOT 5 uydu görüntüsü ve vektör veri

3. YÖNTEM

Bu çalışmada kullanılan yöntem iki ana aşamadan oluşmaktadır: (a) Mean-Shift segmentasyon algoritması kullanılarak segmentlere ayrılmış görüntü elde edilmesi ve (b) “En Büyük Olasılık” yöntemi kullanılarak segmentlere ayrılmış görüntünün sınıflandırılması. Mean-Shift prosedürü ve segmentasyon algoritması detaylı olarak (Comaniciu ve Meer, 2002)’de açıklanmıştır. Bu nedenle, bu çalışmada Mean-Shift algoritmasından kısaca bahsedilecek, segmentasyon algoritması verilecek ve segmentasyonun başarısını etkileyen faktörler anlatılacaktır. Devamında, bu çalışmada kullanılan yöntem verilecektir.

3.1 Mean Shift Prosedürü

“d” boyutlu R^d uzayında bulunan n nokta için x_i vektörü ($i = 1 \dots n$) verilsin. Herhangi bir K kerneli kullanılarak çok değişkenli Mean-Shift vektörü - $m_K(x)$ aşağıdaki formülle hesaplanır (Comaniciu ve Meer, 2002):

$$m_K(x) \equiv \frac{\sum_{i=1}^n x_i K\left(\frac{x - x_i}{h}\right)}{\sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)} - x \quad (1)$$

Yukarıdaki denklemde x kullanılan K kernelinin merkez noktası, h ise kullanılan kernelin boyutunu tanımlamaktadır. Eğer 1 nolu formülde K çok değişkenli simetrik gauss dağılımlı bir kernel olarak tanımlanırsa 2 nolu formüldeki halini alır:

$$K(x) = (2\pi)^{-d/2} \exp\left(-\frac{1}{2}\|x\|^2\right) \quad (2)$$

Yukarıdaki denklemde $\|x\|$ x parametresinin normunu göstermektedir. Patern tanımlama yöntemlerinden biri olan kernel dağılım tahmini (Parzen window) metodu en popüler dağılım tahmini metodlarından biridir. Bu metod ilk olarak herhangi bir öznitelik uzayında varolan bir $f(x)$ fonksiyonunun dağılımının modlarını bulmayı amaçlar. Modlar ise fonksiyonların gradyanlarının sıfır olduğu noktalarda bulunmaktadır ($\nabla f(x) = 0$). Mean-Shift prosedürü ise öznitelik uzayında varolan bu modları fonksiyonun dağılım tahminini yapmadan bulmaktadır. x noktasındaki Mean-Shift vektörü, K kerneli ile hesaplanan normalize dağılım gradyant tahmini ile orantılır (2 nolu denklemdeki kernel için):

$$m_K(x) = h^2 \frac{\hat{\nabla} f_K(x)}{\hat{f}_K(x)} \quad (3)$$

3 nolu formülden de anlaşılacağı üzere Mean-Shift vektörü her zaman öznitelik uzayında varolan dağılımın en çok artan yönünü göstermektedir. Yine aynı formülden anlaşılacağı üzere, kernelin merkezi, yine kernelin içine düşen noktaların yoğun olduğu bölgeye doğru kaydırılmaktadır. Mean-Shift vektörü yerel gradyant tahmini ile uyuştugu sürece, öznitelik uzayında varolan dağılımın durağan noktalarına (stationary points) kadar bir yol izleyebilir. Öznitelik uzayının modları ise bu durağan noktalardır. Dolayısıyla Mean-Shift prosedürü iki basamaklı bir iterasyon olarak yazılabilir:

- $m_K(x)$ Mean-Shift vektörünün hesaplanması
- $K(x)$ kernelinin $m_K(x)$ kadar ötelenmesi

Bu iterasyonun tahmini yapılan dağılımın gradyanının sıfır olduğu herhangi bir noktada duracağı ispatlanmıştır (Comaniciu ve Meer, 2002). Fakat tahmini yapılan bir dağılımın gradyanının sıfır olduğu noktaların bulunması o fonksiyon için birinci-dereceden gerekli koşul olarak tanımlanır ve tek başına o fonksiyonun yerel minimum, yerel maksimum veya eyer noktalarını (saddle point) tanımlayabilmek için yeterli değildir (Nash and Sofer, 1996). Mean-Shift prosedürü her zaman öznitelik uzayında varolan dağılımın en çok artan yönünü göstermekte olduğundan bulunan noktalar yalnızca maksimum veya eyer noktası olabilmektedir. Bu noktaları tanımlayabilmek için kullanılabilecek temel yol, Hessian matrisi olarak tanımlanan fonksiyonun ikinci dereceden türevinin incelenmesi ve Hessian matrisi için ikinci-dereceden yeterlilik koşulunun sağlanmasıdır. Bir başka ve daha kolay bir yöntem ise gradyanti sıfır olarak bulunan noktaların kararlılığını test etmektir (Comaniciu et. al., 2002). Bunun için küçük bir norma sahip rasgele bir vektör dağılımın Mean-Shift prosedürü uygulanarak bulunan durağan noktalara eklenir. Eğer bulunan durağan nokta tekrar aynı noktada (belirli bir tolerans içerisinde kalarak) sabitleniyorsa, bu nokta tahmini yapılan dağılımın yerel maksimum noktası veya modu olarak tanımlanır. Dolayısıyla, tahmini yapılan dağılımın yerel maksimum değerlerinin bulunması için algoritma şu şekilde geliştirilebilir:

- Öznitelik uzayının durağan noktalarının bulunması için Mean-Shift prosedürünün çalıştırılması
- Bulunan durağan noktaların kararlılığının test edilmesi sonucunda tahmini yapılan dağılımın modlarının bulunması

3.2 Mean-Shift tabanlı görüntü segmentasyonu

Gri veya renkli görüntülerdeki birbirine yakın olan hücre değerlerinin homojenleştirilerek bir araya getirildiği işleme görüntü segmentasyonu adı verilmektedir. Mean-Shift tabanlı görüntü segmentasyonunu açıklamak için öncelikle kullanılan renk uzayının tanımlanması gerekmektedir. Sağlıklı bir görüntü segmentasyonu gerçekleştirebilmek için görüntüde algılanan renk farklılıklarını tanımlayan renk uzayının öklit metriğine uygun olması gerekmektedir. Fakat görüntülerin doğasında bulunan kırmızı-yeşil-mavi (KYM) renk uzayı öklit metriğini garanti etmemektedir. Bu nedenle uniform renk uzayı teorisine en çok yaklaşan uzay olan L^*u^*v uzayı tercih edilmiştir (Comaniciu et. al., 2002). Dolayısıyla, segmentlere ayrılacak olan görüntü öncelikle KYM renk uzayından L^*u^*v uzayına dönüştürülmektedir.

Segmentlere ayrılacak olan bir görüntü p -boyutlu olabilen iki boyutlu matrislerden (gri tonlara sahip bir görüntü için $p=1$, KYM uzayındaki bir görüntü için $p=3$, çok-banltı görüntüler için ise $p>3$ olmaktadır) oluşmaktadır.

Dolayısıyla, segmentlere ayrılacak olan görüntü aslında iki kısımdan oluşmaktadır. Bunlardan birincisi iki boyutlu matrisin oluşturduğu uzaysal kısımdır. İkincisi ise o matrisleri dolduran spektral değerlerin oluşturduğu spektral mesafe uzayıdır. Her iki kısmın öklit metriği geometrisine uygun olduğu kabul edilmiştir. Dolayısıyla, görüntü segmentasyonu işlemi sırasında bu iki kısmın beraber ele alınması ve karakteristiklerine uygun bir şekilde normalizasyona tabi tutulmaları gerekmektedir. Bu nedenle, görüntü segmentasyonu için kullanılacak olan K kerneli adı geçen iki kısmı simgeleyen iki simetrik kernelin çarpımı şeklinde oluşturulacak ve iki kısım için farklı kernel boyutları tanımlanacaktır (Comaniciu et. al., 2002):

$$K_{h_s, h_r}(x) = \frac{C}{h_s^2, h_r^p} K\left(\left\|\frac{x^s}{h_s}\right\|^2\right) K\left(\left\|\frac{x^r}{h_r}\right\|^2\right) \quad (4)$$

4 nolu formülde x^s uzaysal kısmı, x^r spektral kısmı, h_s ve h_r uzaysal ve spektral kısımlar için uygulanan kernel boyutlarını ve C ise tanımlanacak olan normalizasyon katsayısını belirtmektedir. Genellikle 2 nolu formülde verilen gauss dağılımlı kernel iyi sonuçlar verdiğinden 4 nolu formülde tanımlanması gereken sadece iki parametre (h_s ve h_r) kalmaktadır. Bu iki parametre segmentlere ayrılacak olan görüntüdeki modların belirlenmesi için uzaysal ve spektral kısımlar için gerekli kernel boyutunu tanımlar.

Mean-Shift tabanlı görüntü segmentasyonu aslında $L*u*v$ uzayında dağılımın yerel maksimum değerlerinin bulunması işleminin gerçekleştirildiği sırada başlamaktadır. Dağılımın modları yani yerel maksimum değerleri bulunduktan sonra her modun bulunması sırasında üzerinden geçilen noktalar o modun “çekim bölgelerini” oluşturmaktadır (Comaniciu et. al., 2002). Bu çekim bölgesi ise sonuçta otomatik olarak görüntünün segmentlere ayrılmasında kullanılmaktadır. Mean-Shift tabanlı görüntü segmentasyonu algoritmasının ilk adımı yine Mean-Shift tabanlı olan ve görüntüdeki süreksizliklerin korunduğu filtreleme prosedürüdür (Comaniciu et. al., 2002). Bu prosedür sonucunda hem görüntü filtrelenmekte hem de $L*u*v$ uzayında görüntünün modları bulunmaktadır. Devamında modların bulunmasında kullanılan “çekim bölgeleri” bilgisi kullanılarak görüntü segmentlere ayrılmaktadır. Son olarak, isteğe bağlı olarak segmentlere ayrılmış görüntü üzerinde belirli bir M hücre sayısı değerinden küçük değere sahip olan segmentler temizlenebilmektedir.


Mean-Shift tabanlı görüntü segmentasyon algoritması uygulanırken yöntemin performansını optimize etmek için aşağıda belirtilen üç parametrenin iyi incelenmesi gerekmektedir:

- (1) *Kernel Tipi*: Çeşitli kernel tipleri (Düz, Gaussian ve Epanechnikov vb.) ve yeni kerneller oluşturabilmek için geliştirilen operatörler Cheng (1995) tarafından incelenmiştir. Uygulamada genellikle Gaussian veya Epanechnikov kernel tipleri her zaman iyi sonuçlar vermektedir (Comaniciu et. al., 2002).
- (2) *Kernel Boyutu*: Segmentasyonun başarısını belirleyen en önemli parametredir. Görüntü segmentasyonu için $h = (h_s, h_r)$ şeklinde tanımlanmalıdır. Tahmini yapılan herhangi bir dağılımın modlarının bulunması dolayısıyla segmentasyonun çözünürlüğünün belirlendiği parametredir.
- (3) *Minimum Bölge (M)*: Segmentasyon sonucunda elde edilen her bir segmentin sahip olabileceği en küçük hücre sayısını tanımlamaktadır. Minimum bölge, segmentasyon uygulanacak çalışmaya özgü bir nitelikler ve çalışmanın özelliklerine bağlı olarak değerinin belirlenmesi gerekmektedir.

3.3 Uygulanan Yöntem

Bu çalışmada uygulanan yöntemde izlenen aşamalar Şekil 3’te verilmiştir. SPOT 5 renkli görüntüsüne ait üç band (yeşil, kırmızı ve kızıl ötesi) Mean-Shift segmentasyon algoritması yardımıyla segmentlere ayrılmıştır. Bir önceki bölümde bahsedilen Mean-Shift tabanlı olan ve görüntüdeki süreksizliklerin korunduğu filtreleme prosedürü ve segmentasyon algoritması EDISON (Edge Detection and Image SegmentatiON) adlı ve C++ programlama dilinde yazılmış olan bir program kullanılarak uygulanmıştır. Mean-Shift tabanlı görüntü segmentasyon algoritması uygulanırken yöntemin performansını optimize etmek için belirtilen üç parametreden ilki olan Kernel Tipi olarak bu çalışmada Gaussian seçilmiştir. Minimum Bölge (M) parametresi için çalışma alanında varolan en küçük parsel alanı dikkate alınmış ve bu alanın içine düşen piksel sayısı saydırılmıştır. Sonuçta, M değeri bu çalışma alanı için 10 hücre olarak belirlenmiştir. Segmentasyonun başarısını belirleyen en önemli parametre olan Kernel Boyutu için

“Mean Shift” Segmentasyon Algoritması Destekli “En Büyük Olasılık” Sınıflandırma Yöntemi Kullanılarak Tarım Alanlarının Sınıflandırılması



Şekil 3. Uygulanan yöntem

değişik $\mathbf{h} = (h_s, h_r)$ kombinasyonları denenerek elde edilen her segmentasyon sonucu görsel olarak incelenmiştir. İncelemeler sonucunda Kernel Boyutu bu çalışma için $\mathbf{h} = (3, 3)$ olarak belirlenmiştir. Bir sonraki aşamada, segment edilen görüntü üzerinden 5 sınıfa ait örnek alanlar toplanmıştır. Görüntünün segmentlere ayrılması homojen bölgelerin artmasını sağlamış ve örnek toplama işini oldukça kolaylaştırmıştır. Çünkü var olan hücre tabanlı sınıflandırmalarda toprak ve hastalık gibi etkenlerden doğan hücre değerlerinin çeşitliliği ve sınır birleşmeleri sonucu ortaya çıkan karışıklıklar, görüntü üzerinden örnek alan toplama işini oldukça zorlaştırmaktadır. Bu nedenle, öne sürülen metodolojide kullanılan Mean-Shift segmentasyon yöntemi, örnek alan toplama kolaylığı getirmesi bakımından çalışmanın devamında uygulanacak olan eğitimi sınıflandırmaya önemli kolaylık ve katkı sağlamaktadır. Sınıflandırma işlemine dahil edilecek ürün türleri; domates, biber, mısır, pirinç, şeker pancarı ve buğday olarak seçilmiştir. Domates ve biber sınıflarının yansıma değerleri birbirine çok yakın olduğu için bu iki sınıf birlikte değerlendirilmiştir. Toplanan örnek alanların güvenilirliği 'Bhattacharyya Distance' ve 'Transformed Divergence' ayrılabilirlik matrislerine bakılarak değerlendirilmiştir. Adı geçen ürünlerden toplanan örnek alanların sınıflandırma için uygun olduğuna karar verildikten sonra "En Büyük Olasılık" sınıflandırma yöntemi kullanılarak görüntü hücre tabanlı olarak sınıflandırılmıştır. Sınıflandırma sonucunda, segment edilen görüntü üzerindeki hücrelerin olabilecek en yakın sınıflara atanması sağlanmıştır. Öne sürülen yaklaşımın doğruluğunu test etmek

amacıyla sınıflandırılmış veri üzerine rastgele 583 adet nokta atılmış ve bu noktaların altındaki değerler referans verideki gerçek değerlerle karşılaştırılmıştır. Rasgele atılan noktaların sınıflandırma öncesinde toplanan örnek alanlar üzerine düşmesini önlemek amacıyla bu alanlar doğruluk analizine dahil edilmemiştir. Rasgele atılan örnek sayısı, literatürde bu sayıyı belirlemek için kullanılan aşağıdaki formül yardımıyla hesaplanmıştır (Jensen, 2005; Congalton and Green, 1999; Tortora, 1978):

$$N = \frac{B \Pi_i (1 - \Pi_i)}{b_i^2} \quad (5)$$

5 nolu formülde, Π_i , alanda bulunan k sınıf içinde toplam alanın %50'sini kapsamaya en yakın olan i sınıfının tüm alana oranını, b_i bu i sınıfı için hedeflenen hassasiyet düzeyini, B ise 1 serbestlik derecesinde ve $(\alpha / k) \times 100$ formülüyle hesaplanan Ki kare (χ^2) tablosundaki değeri ve k ise alanda bulunan toplam sınıf sayısını göstermektedir.

Yöntem sonucu, Özdarıcı (2005) tarafından yapılan bir çalışmada kullanılan aynı tarihli SPOT 5 görüntüsünün parsel tabanlı sınıflandırma sonucuyla karşılaştırılmıştır. Mean-Shift segmentasyon algoritması destekli “En Büyük Olasılık” sınıflandırma yöntemi sonuçlarının parsel tabanlı sınıflandırma sonuçları ile karşılaştırılmasının nedeni, parsel tabanlı sınıflandırma sonucunun tarım alanları için en etkili sınıflandırma yöntemi olarak kabul edilmesidir (Türker ve Arıkan, 2005; Dewit ve Clevers, 2004; Lloyd vd, 2004; Dean ve Smith, 2003; Smith ve Fuller 2001; Janssen ve Van Amsterdam, 1991). Parsel tabanlı sınıflandırma yönteminde, öncelikle, görüntü hücre tabanlı olarak sınıflandırılır. Sınıflandırılmış görüntü, parsellere ait kenar bilgilerinin tutulduğu vektör veri ile çakıştırılarak her bir parselin içine düşen hücre değerleri saydırılır ve çoğunlukta olan hücre bilgisi her bir parsel için etiket olarak atanır. Bu çalışmada kullanılan SPOT 5 görüntüsüne ait Mean-Shift segmentasyon algoritması destekli “En Büyük Olasılık” sınıflandırma sonucu ve parsel tabanlı sınıflandırma sonucunun karşılaştırılabilmesi için her iki yöntem için oluşturulan hata matrislerinden yararlanılmıştır.

4. TARTIŞMA

Geliştirilen yöntem sonucunda üretilen tematik harita, doğruluk analizleri yöntemleriyle incelenmiş ve yöntemin başarısı bilinen en etkili sınıflandırma yöntemi olan parsel tabanlı sınıflandırma yöntemi ile karşılaştırılarak öne sürülen yaklaşımın başarısı değerlendirilmiştir. Her iki sınıflandırma için toplam doğruluk, toplam kappa, kappa, üretici doğruluğu ve kullanıcı doğruluk değerleri hesaplanmıştır. Karşılaştırma sonucunda %78,73 doğruluk payına sahip olan yöntem sonucunun, doğruluk oranı %80,61 olan parsel tabanlı sınıflandırma sonucuna yakın olduğu görülmüştür. Her iki yönteme ait sonuçlar, Tablo 2a ve 2b’de verilmiştir.

Mean-Shift segmentasyon algoritması destekli “En Büyük Olasılık” sınıflandırma sonuçlarına göre toplam doğruluk %78,73 ve toplam kappa %73,20 olarak hesaplanmıştır. Ürün sınıflarının doğruluk oranları incelendiğinde en yüksek doğrulukların %96,12 üretici ve %94,65 kullanıcı doğruluk değerleri ile buğday bitkisinden sağlandığı görülmüştür. Buğdayı, %80,85 üretici ve %85,39 kullanıcı doğrulukları ile pirinç izlemiştir. Mısır ve domatesin üretici doğrulukları yaklaşık %75 hesaplanırken kullanıcı doğrulukları sırasıyla %78,63 ve %60,60 olarak bulunmuştur. Çalışmada en düşük üretici doğruluğunu %65,68 ile şeker pancarı sağlamıştır. Bunun nedeni, şeker pancarı bulunan parsellere rastgele atılan 102 hücreden sadece 67 tanesinin şeker pancarı olarak sınıflandırılmasıdır. Diğer taraftan, bu sınıfın kullanıcı doğruluğu %82,71 olarak hesaplanmıştır. Ürün sınıflarına ait kappa değerleri incelendiğinde en yüksek değeri %93,14 ile buğday sağlarken bunu %82,59 ile pirinç ürünü takip etmiştir. Şeker pancarı ve mısır ürünlerinin kappa değerleri yaklaşık %75 olarak hesaplanmıştır. En düşük kappa değeri ise %48,62 ile domates bitkisine aittir (Tablo 1a).

Mean-Shift segmentasyon algoritması destekli sınıflandırma sonuçları, Tablo 1b de verilen parsel tabanlı sınıflandırma sonuçları ile karşılaştırılmıştır. Karşılaştırma sonucunda parsel tabanlı sınıflandırma yönteminin toplam doğruluğu %80,61 olarak bulunmuş ve önerilen yöntem sonucuna göre yaklaşık %3 oranında artış gösterdiği saptanmıştır. Parsel tabanlı sınıflandırma yöntemiyle hesaplanan kappa değerleri de, Mean-Shift segmentasyon algoritması destekli sınıflandırma sonucundan yaklaşık %2 oranında bir artış ortaya koymuş ve %75,60 olarak hesaplanmıştır. Önerilen yönteme ait kappa değerinin (%73,20) parsel tabanlı sınıflandırma yöntemi sonucuna yakın olması kullanılan yöntemin başarısı olarak değerlendirilmiştir. Sınıf doğrulukları tek tek incelendiğinde buğdayın üretici doğruluğu, önerilen yöntem sonucuna göre yaklaşık %12 oranında azalarak %84,49 olarak hesaplanmıştır. Aynı ürünün kullanıcı doğruluğu ise yaklaşık %4 oranında artarak %98,19 olarak bulunmuştur. Mean-Shift segmentasyon algoritması kullanılarak yapılan sınıflandırmada sırasıyla %80,85 ve %85,39 üretici ve kullanıcı doğruluğu ortaya koyan pirinç bitkisinin parsel tabanlı sınıflandırma sonucunda elde edilen üretici ve kullanıcı doğrulukları sırasıyla %78,72 ve %82,22 olarak hesaplanmıştır. Görüntünün parsel tabanlı sınıflandırılması sonucu

Tablo 1: (a) “Mean Shift” segmentasyon algoritması destekli “En Büyük Olasılık” sınıflandırma sonuçları, (b) Parsel tabanlı sınıflandırma sonuçları

“Mean Shift” Segmentasyon Algoritması Destekli “En Büyük Olasılık” Sınıflandırma Yöntemi Kullanılarak Tarım Alanlarının Sınıflandırılması

	Mısır	Domates	Pirinç	Buğday	Ş.Pancarı	S.Toplamı
Mısır	92	14	8	0	3	117
Domates	22	100	10	5	28	165
Pirinç	3	6	76	0	4	89
Buğday	5	2	0	124	0	131
Ş. Pancarı	0	14	0	0	67	81
K. Toplamı	122	136	94	129	102	583
ÜD (%)	75,41	73,52	80,85	96,12	65,68	
KD (%)	78,63	60,60	85,39	94,65	82,71	
Kappa (%)	72,98	48,62	82,59	93,14	79,05	
Toplam Doğruluk (%) = 78,73 Toplam Kappa (%) = 73,20						

(a)

	Mısır	Domates	Pirinç	Buğday	Ş.Pancarı	S.Toplam
Mısır	80	3	5	2	0	90
Domates	33	123	7	18	0	190
Pirinç	7	0	74	0	9	90
Buğday	2	0	0	109	0	111
Ş. Pancarı	0	10	8	0	84	102
K. Toplam	122	136	94	129	102	583
ÜD (%)	65,57	90,44	78,72	84,49	82,35	
KD (%)	88,88	64,73	82,22	98,19	82,35	
Kappa (%)	85,95	54,01	78,80	97,69	78,61	
Toplam Doğruluk (%) = 80,61 Toplam Kappa (%) = 75,60						

(b)

Ş. Pancarı: Şeker pancarı, K. Toplam: Kolon toplamı, S. Toplam: Sıra toplamı, ÜD: Üretici doğruluğu, KD: Kullanıcı doğruluğu

şeker pancarı %82,35 üretici doğruluğuna ulaşmıştır. Bu değer, şeker pancarının “Mean Shift” segmentasyon yöntemi kullanımı sonucu ortaya çıkan üretici doğruluğunu yaklaşık %17 oranında arttırdığı gözlenmiştir. Diğer taraftan aynı ürünün parsel tabanlı sınıflandırma sonucunda %82,35 olarak hesaplanan kullanıcı doğruluğu, Mean-Shift segmentasyon algoritması destekli sınıflandırma sonucuyla benzer değeri sağlamıştır. Sınıflandırmaya dahil edilen ürünler içinde en yüksek üretici doğruluğu %90,44 ile domatesten elde edilmesine rağmen aynı ürün %64,73 ile en düşük kullanıcı doğruluğunu sağlamıştır. Bunun nedeni, toplam 136 hücreden oluşan domates bitkisinin 10 tanesinin şeker pancarı ve 3 tanesinin mısır olarak sınıflandırılmasıdır. Bu oranların tam tersi bir durum mısır bitkisinde gözlenmiştir. Bu ürün %65,57 ile en düşük üretici doğruluğunu sağlarken kullanıcı doğruluğu %88,88 olarak hesaplanmıştır. “Mean Shift” segmentasyon algoritması destekli sınıflandırma sonucunda mısırın kappa değeri %73 civarlarında iken bu oran parsel tabanlı sınıflandırma sonucunda yaklaşık %13 artış göstermiştir. Parsel tabanlı sınıflandırma sonucunda kappa değerinde artış gözlenen diğer ürünler ise domates ve buğday olarak belirlenmiştir. Bu artış domates bitkisi için yaklaşık %6, buğday için %4 civarlarındadır. Mean-Shift segmentasyon algoritması destekli sınıflandırma sonucu kappa değerlerinde artış gözlenen bitkiler pirinç ve şeker pancarı olarak belirlenmiştir. Pirinç bitkisi için yaklaşık %4 oranında bir artış gözlenirken, bu artış şeker pancarı için yaklaşık %1 düzeyinde kalmıştır.

5. SONUÇ

Bu çalışmada Mean-Shift segmentasyon algoritması destekli “En Büyük Olasılık” sınıflandırma yöntemi kullanılarak bir tarım alanı sınıflandırılmış ve bu yaklaşım parsel tabanlı sınıflandırma yöntemi sonuçları ile karşılaştırılarak öne sürülen yöntemin güvenilirliği değerlendirilmiştir. Analizler sonucunda %78,73 olan Mean-Shift segmentasyon algoritması destekli sınıflandırma sonucunun %80,61 doğruluğa sahip olan parsel tabanlı sınıflandırma yöntemi sonucuna yakın olduğu görülmüştür. Mean-Shift segmentasyon algoritması destekli “En

Büyük Olasılık” sınıflandırma yönteminin parsel tabanlı sınıflandırma yöntemine olan üstünlüğü, sınıflandırma esnasında vektör veriye ihtiyaç duymaması ve segmentasyon sonucunda üretilen homojen alanlar sayesinde eğitilmiş bir sınıflandırma olan “En Büyük Olasılık” yönteminde örnek alan toplama kolaylığı getirmesidir. Çünkü tarım alanları için vektör verinin hazırlanması ve güncellenmesi zor ve bir o kadar da masraflı bir iştir. Diğer taraftan, örnek alanların homojen bölgelerden toplanması, seçme kolaylığı getirecek ve ön yargıyı azaltacaktır. Önerilen yöntemin parsel tabanlı sınıflandırma yöntemine olan bir diğer üstünlüğü de elde edilen harita çıktısının vektör veriye ihtiyaç duyulmadan parsel tabanlı olarak alınmasıdır. Bu özelliklerinden dolayı Mean-Shift segmentasyon algoritması destekli “En Büyük Olasılık” sınıflandırma yaklaşımı, tarım alanlarının sınıflandırılabilmesi için kullanılan etkili yöntemler arasında gösterilebilir. Bu yöntemin daha yüksek çözünürlüğe sahip uydu görüntülerinde uygun parametreler kullanarak daha yüksek sonuçlar vereceği düşünülmektedir. Bu nedenle, önerilen yaklaşımın performansı, çalışmanın bir sonraki aşamasında daha yüksek çözünürlüğe sahip uydu görüntüleri üzerinde denenecektir.

KAYNAKLAR

Arikan, M., 2003, “*A Multi-Temporal Masking Classification Method For Field Based Agricultural Crop Mapping*”, Yüksek Lisans Tezi, ODTÜ Fen Bilimleri Enstitüsü, Jeodezi ve Coğrafi Bilgi Teknolojileri, Ankara.

Cheng Y., 1995, “*Mean shift, mode seeking, and clustering*” IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 17, p. 790–799.

Comaniciu D., Ramesh V., Bue, A. D., 2002, *Multivariate Saddle Point Detection for Statistical Clustering* Proceedings of the 7th European Conference on Computer Vision-Part III.

Comaniciu D., ve Meer P., 2002, “*Mean Shift: A robust approach toward feature space analysis*” IEEE transactions on pattern analysis and machine intelligence, International Journal of Remote Sensing Vol. 24, p. 603–619.

Concalton, R. G. and Green, K., 1999, “*Assesing The Accuracy Of Remotely Sensed Data: Principles and Practices*”, Boca Raton, FL: Lewis publishers, p. 137.

Dean A. M., Smith G. M., 2003, “*An evaluation of per-parcel land cover mapping using maximum likelihood class probabilities*” International Journal of Remote Sensing Vol. 24, p.2905- 2921.

De wit A. J. W. and Clevers J. G. P. W., 2004, “*Efficiency and accuracy of per-field classification for operational crop Mapping*” International Journal of Remote Sensing Vol. 25 p. 4091–4112.

Friedman L, Netanyahu N, ve Shoshany M., 2003, *Mean-Shift Based Clustering of Remotely Sensed Data*, IEEE Transactions on Geoscience and Remote Sensing..

Gougeon, F.A., 1995, “*Comparison of possible multispectral classification schemes for tree crowns individually delineated on high spatial resolution MEIS images*”, Canadian Journal of Remote Sensing, Vol. 21, p. 1–9.

Janssen L. L. F., and Van Amsterdam J. D., 1991, “*An object based approach to the classification of remotely sensed images*”, IEEE Transactions on Geoscience and Remote Sensing, p. 2191–2195.

Jensen, J., 2005, “*Introductory Digital Image Processing: A Remote Sensing Perspective*”, University of South Carolina, p. 501.

Lee, Y. J., and Warner, T.A., 2006, “*Segment based image classification*”, International Journal of Remote Sensing Vol. 27, p. 3403–3412.

Li, Y. and Gong, P., 2005, “*An efficient texture image segmentation algorithm based on the GMRF model for classification of remotely sensed imagery*”, Vol.26, p. 5149–5159.

Lloyd C. D., Berberoglu S., Curran P. J. and Atkinson P. M., 2004 “*A comparison of texture measures for the per-field classification of Mediterranean land cover*”, International Journal of Remote Sensing Vol. 25 p.3943–3965.

“Mean Shift” Segmentasyon Algoritması Destekli “En Büyük Olasılık” Sınıflandırma Yöntemi Kullanılarak Tarım Alanlarının Sınıflandırılması

Lu, S., Oki, K., Shimizu, Y., Omasa, K., 2007, “*Comparison Between Several Feature Extraction/Classification Methods For Mapping Complicated Agricultural Land Use Patches Using Airborne Hyperspectral Data*” , International Journal Of Remote Sensing, Vol. 28, p. 963–984.

Meyer, P., Staenz, K. and Itten, K.I., 1996, “*Semi-automated procedures for tree species identification in high spatial resolution data from digitized colour infrared-aerial photography*”, ISPRS Journal of Photogrammetry and Remote Sensing, Vol.51, p. 5-16.

Nash S. G., Sofer A., 1996, “*Linear and Nonlinear Programming*”, p. 297.

Özdarıcı, A., 2005, “*Comparison Of Different Resolution Images For Polygon-Based Crop Mapping*”, Yüksek Lisans Tezi, ODTÜ Fen Bilimleri Enstitüsü, Jeodezi ve Coğrafî Bilgi Teknolojileri, Ankara.

Smith G. M. *, Fuller R. M., 2001, “An integrated approach to land cover classification: an example in the Island of Jersey” Vol. 22 p3123–3142.

Tortora, R., 1978, “*A note on sample size estimation for multinomial populations*”, The American Statistician, Vol. 32, p. 100–102.

Türker M. ve Arıkan M., 2005, “*Sequential masking classification of multi-temporal Landsat7 ETM+ images for field-based crop mapping in Karacabey, Turkey*”, International Journal of Remote Sensing Vol. 26, p. 3813–3830.