

Hiperspektral Görüntülerin Eğitimsiz Sınıflandırma Sonuçlarının Karşılaştırılması

(Comparison of Hyperspectral Images Unsupervised Classification Results)

Mustafa CANIBERK

Harita Genel Komutanlığı, Fotogrametri Dairesi, Ankara
mustafa.caniberk@hgk.msb.gov.tr

ÖZET

Yeryüzü üzerindeki objelerin uzaktan algılama teknolojileri ile ayırt edilebilmelerinin en önemli nedeni, söz konusu objelerin farklı spektral özelliklere sahip olmasıdır. Uzaktan algılama sistemleri, seçilen dalga boyu bantlarında yer yüzeyindeki cisimlerden yansıyan ve yayılan enerji miktarlarını kayıt etmektedir. Hiperspektral görüntüleme birçok dar dalga boyu bandına ait imge verilerini elde etmekte ve dalga boyuna göre bir ayrışım sağlamaktadır. Hiperspektral görüntülerde her piksel için dalga boyuna bağlı bir spektrum bilgisi elde edilmesi ile piksellerin değişimi, benzerlikleri ve farklılıklarının algılanabilmesi sonucu, bölgelerin sınıflandırılması standart görüntü algılayıcılarına oranla çok daha yüksek bir başarımla sağlanabilmektedir.

Bu çalışmada hiperspektral görüntülerin eğitimsiz sınıflandırma yöntemlerinin sonuçları incelenmiştir. K-Means ve ISODATA algoritmaları kontrolsüz sınıflandırma yöntemlerinde sıklıkla kullanıldıkları için bu algoritmalar ile sınıflandırma yapılmış ve elde edilen sonuçlar incelenmiştir.

Anahtar Kelimeler: Hiperspektral Görüntüleme, Uzaktan Algılama, Eğitimsiz Sınıflandırma

ABSTRACT

The most important reason of being able to distinguish objects on the Earth with remote sensing technology is to have different spectral properties of these objects. Remote sensing systems, record the selected wavelengths bands reflected from objects located on the surface and the amount of energy emitted. Hyperspectral imaging systems provide many images corresponding to narrow spectral bands and therefore they provide decomposition with respect to wavelength. The corresponding spectrum information is obtained for every pixel within the image. It is possible to determine changes, similarities and differences using the spectral information for each pixel within the hyperspectral image.


In this study, the results of the hyperspectral images unsupervised classification methods were investigated. Because of the K-Means and ISODATA algorithms frequently used for supervised classification methods this algorithm also used for classification and the results examined.

Keywords: Hyperspectral Imaging, Remote Sensing, Unsupervised Classification

1. GİRİŞ

Hiperspektral görüntüleme, diğer spektral görüntülemelerde olduğu gibi bilgiyi toplar ve elektromanyetik tayfta işleminden geçirir. Ancak insan gözünün 3 bantta algılayabildiği görünür ışıktan başka, spektral görüntüleme, tayfı birçok banda ayırır. Görüntüyü birçok banda ayıran bu teknik sayesinde, resimlerde çıplak gözle görünenden çok öte şeyleri de kavrayabilme fırsatına sahip oluruz. Hiperspektral resimler 1970'li yılların başından itibaren kullanılmaya başlanmış olmasına rağmen, yaygın kullanımı geçtiğimiz son on yıla dayanmaktadır. Görüntü spektrometrisi olarak da bilinen hiperspektral görüntülerin uzaktan algılanması ve işlenmesi, üzerinde birçok araştırma yapılan önemli bir konudur.

Hiperspektral görüntüler kullanılarak bilgi edinme yöntemlerinden birisi sınıflandırmadır. Sayısal görüntü sınıflandırma, bir görüntüdeki tüm piksellerin sınırlı sayıdaki sınıflar içerisinde gruplandırılması işlemidir.



Şekil 1. Çalışma bölgesinin ortofoto görüntüsü

Bu çalışmada seçilen bir bölgenin eğitimsiz sınıflandırılması üzerinde durulmuştur. Çalışma alanı olarak Amerika Birleşik Devletleri California Eyaleti San Francisco kentinde bulunan San Jose bölgesi seçilmiştir. Çalışma bölgesinde vahşi yaşamı koruma alanları, kentsel alanlar ve su alanları gibi çok farklı arazi kullanımı


mevcuttur. Çalışma bölgesinin Word Imagery servisinden sağlanan ortofoto görüntüsü Şekil 1'de sunulmuştur.

2. HİPERSPEKTRAL GÖRÜNTÜLEME

Hiperspektral görüntüler diğer sayısal görüntülerin aksine ışığın dalga boyunun insan gözü ile görülemeyen kısımları hakkında da bilgi içeren özel bir görüntü şeklidir. Özel sensörlerle alınan bu görüntülerle genellikle ultraviyole ışınları ile kızılötesi ışınları arasında kalan dalga boyu aralığı kaydedilebilmektedir. İnsan gözünün algılayabileceği ışığın dalga boyu aralığı kabaca 400 nm ile 700 nm arasındayken, hiperspektral sensörler 350 nm ile 2500 nm arasını tespit edebilmektedir. Böylece elde edilen görüntülerde klasik görüntülere göre daha fazla karakteristik özellik bulunmaktadır. Alıcıları hiperspektral yapan özellik bant sayısından çok, bantların ne kadar dar ve birbirine ne kadar bitişik olduğudur (Shippert, 2003).

a. Hiperspektral Veri Özellikleri

Pankromatik görüntü algılayıcıları ışığın sadece görülebilen dalga boyunu algılar ve o aralığı tek bir değer olarak kaydederler. Bu sebeple resimler sayısal ortamda tek bir matris ile ifade edilmektedir. Tek matris bir piksele ait tek değer dolayısıyla tek özellik anlamına gelmektedir. Hiperspektral görüntülerde ise, kullanılan sensörün hassasiyetine göre seçilen bir dalga boyu aralığı çok sayıda parçaya ayrılabilir. Böylece görüntüyü temsil edecek çok sayıda matris oluşacaktır. Bu da her bir piksel için elde edilen matris sayısı kadar özellik anlamına gelmektedir.



Şekil 2. Farklı türdeki maddeler için spektral imzalar

Hiperspektral görüntülerde maddenin cinsine göre farklı spektral band değerleri oluşacağından, görüntü üzerindeki piksel vektörleri, yine maddenin cinsine göre birbirlerine benzerlik ya da farklılık göstereceklerdir. Şekil 2'de görüldüğü gibi resim üzerindeki farklı türdeki alanlara ait piksellerin vektörleri yakın değerlere sahip olacaklardır.

Görüldüğü gibi bu vektörleri kullanarak görüntü üzerindeki bu alanları birbirlerinden ayırt etmek ve sınıflandırmak mümkündür. Bahsi geçen özellikten dolayı bu vektörlere "spektral imza" denilmektedir (Binol, 2012).

b. Hiperspektral Görüntü Uygulamaları


Hiperspektral algılayıcılar ile dar bantlı ve sürekli aralıklandırılmış yüzlerce spektral bantta veri toplanabilmektedir. Farklı nesneler farklı dalga boylarında, farklı yansıma özellikleri gösterir. Bu özellik sayesinde cisimler birbirlerinden ayırt edilebilmektedir. Hiperspektral sınıflandırma ve tanıma yöntemlerinin, askeri ve savunma (Shippert, 2002), medikal (Chaudhari, 2005), tarım (Haboudane, 2004), hayvancılık (Smith, 2005), tekstil (Choi ve Stenger, 2004), çevre (Salem, 2005), madencilik (Bachmann, 2002), hedef tespiti (Binol, 2012) alanlarında uygulamaları bulunmaktadır.

3. HİPERSPEKTRAL GÖRÜNTÜLERDE SINIFLANDIRMA

Sınıflandırma yöntemlerinin amacı; veri kümesini, sahip olduğu özelliklere göre sınıf ya da kategorilere ayırmaktır. Hiperspektral görüntülerde sınıflandırma yöntemleri spektral sınıfları çeşitli istatistiksel yöntemler ile belli kategorilere ayırmaktadır. Sınıflandırma yöntemleri eğitilmiş (supervised) ve eğitimsiz (unsupervised) sınıflandırma olarak farklı iki kategoride incelenebilmektedir (Duda, 2000). Görüntü sınıflandırma kurallarının ana hedefi; alanı kapsayan sınıflar ve konulara göre bütün pikselleri ayırtmaktır.

a. Eğitilmiş Sınıflandırma

Eğitilmiş sınıflama, sınıflandırılacak bölge hakkında kullanıcıların yeterli bilgiye sahip olmaları durumunda kullanılacak bir yöntemdir. Analizci tarafından tanınan veya çeşitli kaynaklarından elde edilen bilgilerle arazi örtüsünü temsil eden pikseller seçilir. Belirli birkaç özelliğin sınıflandırılmasında tercih edilen bir yöntemdir (Şekil 3).



Şekil 3. Eğitilmiş sınıflandırma döngüsü

b. Eğitimsiz Sınıflandırma

Eğitimsiz sınıflandırma; piksellerin, kullanıcı müdahalesi olmadan algoritmalar yardımı ile otomatik olarak kümelendirilmesi temeline dayanmaktadır. Eğitimsiz sınıflandırma yöntemlerinde, sınıflandırılacak bölgenin tüm pikselleri kullanılarak gruplar (kümeler) elde edilmektedir (Long ve Srihann, 2004). Eğitimsiz sınıflandırma yöntemi, eğitilmiş sınıflandırma yöntemlerine geçişte ilk aşama olup sayısal görüntü işlemede çok önemli bir yer tutar.

Piksellerin bir araya gelip kümelenecekleri için, önce bir benzerlik veya yakınlık ölçütü tanımlamak gerekmektedir. Benzerlik ölçütü olarak Öklid (Euclidean) ve Mahalanobis gibi çeşitli uzaklıklar kullanılır.

$$D = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

Öklid uzunluğu (1) ile verilmiştir. Burada n bant sayısını, x_i i . banttaki x pikselinin parlaklığını, y_i i . banttaki y pikselinin parlaklığını ifade etmektedir. (Spath, 1980; Richards, 1986).

$$D = \sqrt{(x_i - a)^T S^{-1} (x_i - a)} \quad (2)$$

$$a = \frac{1}{k} \sum_{i=1}^k x_i \quad (3)$$

$$S = \frac{1}{n} \sum_{i=1}^n (x_i - a_i) (y_j - a_j) \quad (4)$$

Mahalanobis uzunluğu ise (2) ile verilmiştir. Burada (3) ve (4)'deki a ortalama, S kovaryans matrisidir. Kovaryans matrisindeki n bant sayısını, a_i birinci bant ortalamasını, a_j ikinci bant ortalamasını, x_i birinci banttaki piksel parlaklığını, y_j ikinci banttaki piksel parlaklığını ifade etmektedir (Spath, 1980).

Eğitimsiz sınıflandırma, görüntüdeki veri tanımlanamadığında başvurulan yöntemdir. Başlangıçta arazi örtüsünün bilinmesi gerekmemektedir. Yapılacak ilk iş sınıf sayısının belirlenmesidir. Şekil 4'de eğitimsiz sınıflandırma döngüsü görülmektedir.




Şekil 4. Eğitimsiz sınıflandırma döngüsü

Eğitimsiz sınıflandırma yöntemleri içerisinde en yaygın olarak kullanılan yöntem K-ortalama (K-Means) yöntemidir (Goswami, 2004). Bu sınıflandırma yönteminde, her bir kümenin ortalaması hesaplanmaktadır. Piksel değerlerinin her bir küme ortalamasına uzaklığı bulunmakta ve piksel değerleri en yakın kümeye yerleştirilmektedir. Hiperspektral görüntülerin eğitimsiz sınıflandırılmasında kullanılan K-ortalama algoritması (Meyer, 2003) tarafından yapılan çalışmada önerilmiştir.

ISODATA (Iterative Self Organizing Data Analyses Technique) yöntemi (Chun, 1999), tekrarlı olarak sınıflandırmayı gerçekleştirme ve uygulanan her iterasyon sonrasında yeniden istatistik hesaplamasını temel almaktadır. Bu yöntem karar kuralı olarak, minimum uzaklığı kullanmaktadır. Pikseller, görüntünün sol üst köşesinden başlanarak soldan sağa ve satır satır analiz edilmektedir. Aday piksel ile her bir küme ortalaması arasında spektral uzaklık hesaplanmakta ve aday piksel en yakın kümeye atanmaktadır.

4. MATERYAL ve YÖNTEM

Araştırmanın temel materyalini 1992 yılında San Francisco körfezinin güneyindeki Moffett bölgesine ait hiperspektral veri küpü oluşturmaktadır. Bu veri AVIRIS (Airborne Visible Infrared Imaging Spectrometer) tarafından yaklaşık 20.000 m yükseklikten NASA-ER-2 uçağındaki hiperspektral kamera ile elde edilmiştir. 400-2500 nm dalga boyu aralığında 224 banttan oluşan bir veri küpüdür (Şekil 5).



Şekil 5. Çalışma bölgesinin hiperspektral veri küpü

Hiperspektral verinin işlenmesi ve analizi için ENVI 4.1 (The Environment for Visualizing Images) yazılımı kullanılmıştır. Bu yazılım; pankromatik ve çok bantlı uzaktan algılama verilerinin yanı sıra hiperspektral verilerin de işlenmesine ve analizine olanak sağlayan bir görüntü işleme yazılımdır.

Çalışma bölgesine ait ortofotolar World Imaginery tarafından sunulan servisten, vektör veriler ise Open Street Map (OSM) servisinden elde edilmiştir.

5. UYGULAMA

Çalışma bölgesinin gerçek renkli ve renkli kızılötesi görüntüsü Şekil 6'da sunulmuştur. Sınıflandırma işlemine geçmeden önce veri içerisinde atmosferik etki ve gürültü içeren bantlar

temizlenmiştir. Bu işlem için ENVI 4.1 yazılımının araçları kullanılmıştır. Verideki toplam bant sayısı 224 iken, temizleme işleminin ardından 145 banta düşmüştür.

Sınıflandırma çalışmasının ilk örneği ISODATA algoritması kullanılarak gerçekleştirilmiştir. Burada 5 sınıf oluşturulacak şekilde ve bir sınıfta en az 1000 piksel olacak şekilde seçim yapılmıştır. 1000 pikselden az olarak oluşturulan sınıflar en yakın sınıfa atanmaktadır. Sınıflandırma çalışmasının ikinci örneği K-Means (K-ortalama) algoritması kullanılarak gerçekleştirilmiştir. Bir önceki uygulamada olduğu gibi 5 sınıf oluşturacak şekilde seçim yapılmıştır. İki uygulama da bir iterasyon ile sonlandırılmıştır. Yapılan iki farklı eğitimsiz sınıflandırma sonucunda elde edilen sınıflar incelendiğinde % 0.5-2.2 oranında farklılıklar gözlenmiştir.

Hem ISODATA hem de K-Means algoritmalarıyla yapılan sınıflandırmada beş farklı sınıf oluşturulmuştur. Oluşturulan sınıflara benzer özellikteki pikseller atanarak sınıflandırma işlemi sonuçlandırılmıştır. Burada oluşan sınıflar spektral benzerliği ifade eden piksel kümeleridir.

Hiperspektral görüntülerde; aynı özellikteki maddeler farklı spektral band değerleri oluşturacağından görüntüdeki pikseller maddenin cinsine göre birbirlerine benzerlik ya da farklılık göstereceklerdir. Çalışmanın sonuçlarının daha net anlaşılması için oluşturulan beş sınıf farklı veriler ile (ortofoto görüntü, OSM verisi ve renkli kızılötesi görüntü) irdelenmiş ve bu sınıfların temsil ettiği detaylar saptanmaya çalışılmıştır.



(a)

(b)

Şekil.6 (a) Çalışma bölgesinin gerçek renkli görüntüsü. (b) Çalışma bölgesinin renkli kızılötesi görüntüsü

Çalışma bölgesinin ortofo to görüntüsü, OSM verisi ve renkli kızılötesi görüntüsü incelenmiş ve piksel kümelenmelerinin oluşturduğu sınıfların “Su Alanları”, “Bataklık Alanlar”, “Bitki Örtüsü”, “Kentsel Alanlar” ve “Kullanım Dışı Alanlar (Toprak Örtüsü)” olacak şekilde beş farklı grupta değerlendirilebileceği görülmüştür.


Genel olarak bakıldığında tüm sınıfların piksel değerlerinin iki uygulamada da yakın sonuçlar verdiği söylenebilir (Tablo 1). Özellikle su alanı olarak tanımlanan alanlardaki piksel değerleri her iki sınıflandırma tekniğinde de birbirine çok yakın

sonuçlar vermiştir. Su alanları genel olarak görünür bölgede (400-700 nm) yansıma vermektedir. Özellikle yakın kızılötesi bölgede hemen hemen hiç yansıma vermez. Su alanlarının bu özelliği piksellerin sınıflandırılmasında başarılı sonuçların alınmasının nedeni olarak açıklanabilir.


Ayrıca tüm veri için toplam sınıflandırma farkı % 6,968 oranında gerçekleşmiştir. İki uygulamada da piksel kümelenmeleri tüm detay sınıflarında birbirlerine çok yakın olarak gözlenmiştir (Şekil 7).

Tablo.1 Sınıflandırma sonuçları

Detay Sınıfları	K-Means		ISODATA		Sınıflar Arası Piksel Farkı	
	Piksel	Oran	Piksel	Oran	Piksel	Oran
Bataklık Alanlar	42.415	13,492%	46.458	14,778%	4043	1,286%
Su Alanları	105.368	33,517%	103.963	33,070%	1405	0,447%
Kentsel Alanlar	44.490	14,152%	40.699	12,946%	3791	1,206%
Kullanım Dışı Alanlar	60.706	19,310%	54.949	17,479%	5757	1,831%
Bitki Örtüsü	61.389	19,528%	68.299	21,726%	6910	2,198%
TOPLAM	314.368		314.368		21.906	6,968%



Şekil 7. ISODATA ve K-Means algoritmaları kullanılarak elde edilen sınıflandırma sonuçları



Şekil 8. Bitki örtüsü sınıflandırma sonucunun renkli kızılötesi görüntü ile karşılaştırılması

Confusion Matrix: D:\Akademik\Yayınlar\HSI\Result\ISOData_class_5

Overall Accuracy = (280357/314368) %89.181

Kappa Coefficient = 0.86

Ground Truth (Pixel)						
Class		Bataklık Alanlar	Su Alanlar	Kentsel Alanlar	Kullanım Disi Alanlar	Bitki Örtüsü
Bataklık Alanlar	39377	3038	0	0	0	0
Su Alanlar	7081	96074	2213	0	0	0
Kentsel Alanlar	0	4851	35246	4393	0	0
Kullanım Disi Alanlar	0	0	3240	49413	8053	0
Bitki Örtüsü	0	0	0	1143	60246	0
Total	46458	103963	40699	54949	68299	0
User Accuracy	% 84.758	% 92.412	% 86.602	% 89.925	% 88.209	
Ground Truth (Pixel)						
Class	Total	Producer Accuracy				
Bataklık Alanlar	42415	% 92.837				
Su Alanlar	105368	% 91.179				
Kentsel Alanlar	44490	% 79.222				
Kullanım Disi Alanlar	60706	% 81.397				
Bitki Örtüsü	61389	% 98.138				
Total	314368					

Şekil 9. Sınıflandırma doğruluk matrisi ve kappa değeri

Renkli kızılötesi görüntülerde kırmızı tonlarda görünen alanlar doğal bitki örtüsüne karşılık gelen alanlardır. Şekil 8 incelendiğinde iki sınıflandırmada da bitki örtüsü olarak kümelenen bölgeler açık mavi tonda işaretlenmiştir. Aynı zamanda bu bölgelerin Renkli kızılötesi görüntüdeki kırmızı tonlarla görünen alanlara karşılık geldiği görülmektedir.

Sınıflandırma çalışmasının kalitesinin belirlenmesi için genel doğruluk ve kappa katsayısı belirlenmiştir. Kappa katsayısı iki veri kümesi arasındaki karşılaştırmalı uyumun güvenilirliğini ölçen istatistik yöntemidir. Bu kapsamda karşılaştırma matrisi oluşturulmuştur. K-Means sınıflandırma sonucu girdi verisi olarak, ISODATA sınıflandırma sonucu ise "Ground Truth" olarak kabul edilmiştir. Sınıflandırma doğruluğu Şekil 9'da görülmektedir. Elde edilen sonuçlar ışığında sınıflandırmanın genel doğruluğu %89.181, kappa katsayısı ise 0.86 olarak belirlenmiştir.

6. SONUÇLAR ve ÖNERİLER

Eğitimsiz sınıflandırma uzaktan algılama çalışmalarında sıklıkla kullanılan bir sınıflandırma yöntemidir. Aynı zamanda eğitilmiş sınıflandırmaya geçilmeden önce yapılması faydalı sonuçlar vermektedir. Gerçekleştirilen bu çalışmada; iki farklı eğitimsiz sınıflandırma algoritmasının sonuçları incelenmiş ve sınıfların hem piksel değerlerinin hem de kümelenmelerinin çok yakın olduğu gözlenmiştir.

Özellikle arazi kullanımının bilinmediği veya sınıflandırma kontrolünün yapılamayacağı durumlarda hiperspektral verilerin eğitimsiz sınıflandırılması tercih edilebilir. Bu tercihin en önemli nedeni; hiperspektral verilerde her pikselin çok sayıda spektral bilgi içermesinden dolayı eğitim seti olmaksızın başarılı sonuçlar vermesidir. Ayrıca eğitim seti oluşturmanın zaman alacağı acil öncelikli uygulamalarda

sonuca hızlı biçimde gitmemize olanak sağlamaktadır.

Eğitimsiz sınıflandırma işlemleri genellikle eğitilmiş sınıflandırma işlemlerinin girdisi olarak düşünülmektedir. Ancak özellikle hiperspektral veri küpünün çok sayıda spektrum içermesinden, gerçek renkli ve renkli kızılötesi görüntüler ile sınıfların kolayca ayırt edilebilmesinden ötürü eğitimsiz sınıflandırma tercih edilebilir.

Eğitimsiz sınıflandırmada sıklıkla kullanılan ISODATA ve K-Means algoritmalarının sonuçları piksel değerleri ve piksel kümelenmesi açısından birbirlerine çok yakın çıkmaktadır. İki algoritmanın işlem hızında da önemli bir farklılık gözlenmediği için hangi algoritmanın kullanılacağı tamamen analizcinin kararına bırakılabilir.

KAYNAKLAR

- Bachmann C.M., Donato T.F., Lamela G.M., Rhea W.J., Bettenhausen M.H., Fusina R.A., Bois K.R.D., Porter J.H., Truitt B.R., (2002), **Automatic Classification of Land Cover on Smith Island, VA, Using HyMAP Imagery**, IEEE Trans. on Geoscience and Remote Sensing 40, 2313–2330
- Binol H., (2012), **Termal ve Hiperspektral Görüntülerden Hareketli Hedef Tespiti**, Yüksek Lisans Tezi, İstanbul
- Chang L., (2004) **Multispectral Image Compression Using Eigenregion-based, Segmentation**, Pattern Recognition, 36, 1233-1243,
- Chaudhari A.J., Darvas F., Bading J.R., Moats R.A., Conti P.S., Smith D.J., Cherry S.R., Leahy R.M., (2005), **Hyperspectral and Multispectral Bioluminescence Opticaltomography for Small Animal Imaging**, Phys. Med. Biol.50, 5421-5441
- Choi, Y., Stenger, H.G., (2004), **Kinetics, Simulation And Insights for CO Selective Oxidation**, Journal of Power Sources, 129, 246-254
- Chun B.T., Bae Y., Kim T.Y., (1999), **Caption Segmentation Method in Videos Using Isodata Clustering of Topographical Features**, TENCON 99, Proceedings of the IEEE Region Conference, 2, 915 - 918
- Duda R.O., Hart P.E., Stork D.G., (2000), **Pattern Classification** (2nd Edition), Wiley-Interscience, Hoboken, NJ
- Goswami A., Ruoming J., Agrawal G., (2004), **Fast And Exact Out-Of-Core K-Means Clustering**, Fourth IEEE International Conference on Data Mining, 83-90, Brighton, UK
- Haboudane D., Miller J.R., Tremblayc N., Pattey E., (2004), **Estimation of Leaf Area Index Using Ground Spectral Measurements Over Agriculture Crops: Prediction Capability Assessment of Optical Indices**, Xxth ISPRS Congress, 12-23, Istanbul
- Long W., Srihann S., (2004), **Land Cover Classification of SSC Image: Unsupervised And Supervised Classification Using ERDAS Imagine**, IEEE International Geoscience and Remote Sensing Symposium, 4, 2707 – 2712
- Meyer A., Paglieroni D., Astanek C., (2003), **K-Means Re-Clustering: Algorithmic Options With Quantifiable Performance Comparisons**, SPIE Proceeding: Optical Engineering at the Lawrence Livermore National Laboratory, 5001, 84-92
- Richards I.A., (1986), **Remote Sensing Digital Image Analysis**, Springer-Verlag Berlin Heidelberg New York
- Salem F., Kafatos M., El-Ghazawi T., Gomez R., Yang R., (2005), **Hyperspectral Image Assessment of Oil-Contaminated Wetland**, International Journal of Remote Sensing 26, 811-821
- Shippert P., (2003), **Introduction to Hyperspectral Image Analysis**, Online Journal of Space Communication, Ohio University, Athens
- Shippert, P., (2002), **Spotlight on Hyperspectral**, Geospatial Solutions, www.geospatialonline.com
- Smith D.P., Lawrence K.C., Park B., (2005), **Detection of Fertility And Early Development of Hatching Eggs With Hyperspectral Imaging**, Proceedings 17th European Symposium on Quality of Poultry Meat. 139-144
- Spath H., (1980), **Cluster Analysis Algorithms for Data Reduction and Classification of Objects**, John Wiley and Sons, New York.