

하이퍼스펙트럴 영상의 분류 기법 비교

A Comparison of Classification Techniques in Hyperspectral Image

가칠오¹⁾ · 김대성²⁾ · 변영기³⁾ · 김용일⁴⁾

Ga, Chill O · Kim, Dae Sung · Byun, Young Ki · Kim, Yong Il

¹⁾ 서울대학교 대학원 지구환경시스템공학부 석사과정(E-mail: crowise@empal.com)

²⁾ 서울대학교 대학원 지구환경시스템공학부 박사과정(E-mail: mutul94@empal.com)

³⁾ 서울대학교 대학원 지구환경시스템공학부 박사과정(E-mail: 071-kkokko@hotmail.com)

⁴⁾ 서울대학교 공과대학 지구환경시스템공학부 부교수(E-mail: yik@plaza.snu.ac.kr)

Abstract

The image classification is one of the most important studies in the remote sensing. In general, the MLC(Maximum Likelihood Classification) classification that in consideration of distribution of training information is the most effective way but it produces a bad result when we apply it to actual hyperspectral image with the same classification technique. The purpose of this research is to reveal that which one is the most effective and suitable way of the classification algorithms in the hyperspectral image classification. To confirm this matter, we apply the MLC classification algorithm which has distribution information and SAM(Spectral Angle Mapper), SFF(Spectral Feature Fitting) algorithm which use average information of the training class to both multispectral image and hyperspectral image. I conclude this result through quantitative and visual analysis using confusion matrix could confirm that SAM and SFF algorithm using of spectral pattern in vector domain is more effective way in the hyperspectral image classification than MLC which considered distribution.

Key Words : Hyperspectral Image, Spectral Feature Fitting, Spectral Angle Mapper, Maximum Noise Fraction

1. 서 론

트레이닝 데이터의 분광 분포를 이용하여 분류를 수행하는 MLC(Maximum Likelihood Classification) 기법은 다중분광 영상의 분류에 있어 가장 일반적으로 사용되는 효과적인 알고리즘이다. 하지만, 실제 이러한 기법을 하이퍼스펙트럴 영상에 적용하였을 경우에는 신뢰할 만한 정확도를 보이지 않는다. 그 이유 중 하나는 트레이닝 정보의 신뢰성이 떨어지는 경우를 들 수 있는데, 분류를 수행하기 위해 사용되는 트레이닝 개수는 보통 $10N \sim 100N$ (여기서, N 은 밴드 수) 정도가 필요하게 되지만(Swain and Davis, 1978), 밴드 수가 많은 하이퍼스펙트럴 영상의 경우 안정적인 트레이닝 개수를 확보하지 못하게 되는 문제점이 발생한다. 이러한 단점을 해결하기 위해 유효 밴드의 선택(Band Selection) 또는 밴드 추출(Band Extraction)을 수행하여 분류 정확도를 높이기 위한 노력들이 많이 이루어지고 있다(C. Lee, 1997; X. Jia, 1999). 또한, 지표면의 분광 특성을 가장 잘 반영하는 하이퍼스펙트럴 영상의 장점을 최대한 활용하기 위하여 영상 화소의 파장대별 밝기 값으로 이루어진 연속된 분광 곡선(Z-Profile)을 이용한 영상분류 기법도 많이 연구되어 왔다(Youngsinn Sohn, 2002; Clark, R. N, 1990).

본 연구는 하이퍼스펙트럴 영상에 가장 적합한 분류 기법을 알아보기 위하여 가장 일반적인 다중분광 영상 분류 기법인 MLC와 분광 곡선과 최소분광각거리를 이용한 SAM(Spectral Angle Mapper)과 SFF(Spectral Feature Fitting) 기법을 Landsat ETM+과 Hyperion 영상에 대하여 분류를 수행하고 비교 평가해 보았다.

2. 분류 알고리즘

2.1 SAM(Spectral Angle Mapper)

SAM은 분광차원에서 최소분광각거리(minimum spectral angle distance)의 원리에 기본을 두고 있다(Sohn *et al*, 2002). 트레이닝 클래스의 각 밴드별 평균을 계산하여 기준 스펙트럼(reference spectrum)의 중심 값을 계산하고(식 1), 기준 스펙트럼과 분류하고자 하는 미지의 화소 스펙트럼(test spectrum)간의 각은 벡터의 내적으로 계산한다.(식 2). 이 중심 값은 분광차원 상에서 평균 벡터의 의미를 가지며 미지의 화소는 각각의 레퍼런스 스펙트럼 중심과의 각이 가장 작은 클래스로 배정된다.

$$\mu_{r,k} = \frac{1}{N_r} \sum_{i=0}^{N_r} x_{i,k,r} \quad (1)$$

$$\theta_{i,r} = \cos^{-1} \left[\frac{\sum_{k=1}^m x_{i,k} \mu_{r,k}}{\sqrt{\sum_{k=1}^m x_{i,k}^2 \sum_{k=1}^m \mu_{r,k}^2}} \right] \quad (2)$$

여기서, $\theta_{i,r}$ 는 레퍼런스 스펙트럼 중심과 미지의 화소 사이의 각의 크기를 말하며, m 은 밴드 수, $x_{i,k}$ 는 임의의 k 밴드에서의 미지의 화소값, $\mu_{r,k}$ 는 k 밴드에서의 레퍼런스 스펙트럼 중심 화소값, N_r 은 클래스의 개수이다.

2.2 SFF(Spectral Feature Fitting)

SFF는 분광차원에서 데이터 간 상관계수를 의미하는 fitting 값을 판단 근거로 화소별(pixel by pixel) 영상 분석을 수행하는 알고리즘을 말한다. 트레이닝 과정을 통해 취득한 기준 스펙트럼과 미지의 화소 스펙트럼의 정규화를 수행하기 위해 우선적으로 Continuum Removal을 수행하고, 두 데이터의 관계를 최소제곱(Least Square)을 이용하여 식 (3)에서의 계수인 a, b 값을 추정 후 간단한 선형모형에서의 fitting 값을 구하게 된다(식 6). 모든 영상의 화소는 계산을 통해 도출된 fitting 값이 가장 큰 클래스로 분류되어진다. 여기서, O_c 와 L_c 는 각각 영상 화소와 트레이닝 데이터의 밴드별 스펙트럼을 나타내고, n 은 밴드 수를 의미한다.

$$L'_c = a + bL_c \quad (3)$$

$$a = (\sum O_c - b \sum L_c) / n \quad (4)$$

$$b = \frac{S_{xy}}{S_{xx}} = \frac{\sum O_c L_c - (\sum O_c \sum L_c) / n}{\sum L_c^2 - (\sum L_c)^2 / n}, \quad b' = \frac{S_{xy}}{S_{yy}} = \frac{\sum O_c L_c - (\sum O_c \sum L_c) / n}{\sum O_c^2 - (\sum O_c)^2 / n} \quad (5)$$

$$F = (bb')^{1/2} = \frac{S_{xy}}{\sqrt{S_{xx} S_{yy}}} \quad (6)$$

3. 사용 데이터 및 알고리즘 실험

3.1 사용 데이터

본 연구에서는 다중분광 영상과 하이퍼스펙트럴 영상 간의 비교 평가를 위하여 Hyperion과 Landsat ETM+ 영상을 사용하였다. 대상 지역은 각각 2002년 9월과 2001년 9월에 촬영된 경기도 안양 주변 지역이

다. Hyperion은 EO-1 위성을 구성하고 있는 센서 중의 하나로 Pushbroom 방식으로 지상의 자료를 취득하고, 약 7.6km의 비교적 좁은 관측 폭과 30m의 공간해상도를 갖는다. ETM+는 Hyperion과 동일한 공간해상도를 가지며, 촬영 폭은 185km 이다. 그림 1과 표 1에 사용 영상과 데이터의 제원을 나타내었다.




그림 1. 사용 영상(좌: Hyperion, 우: ETM+)

표 1. 사용 데이터 제원

위성	EO-1	Landsat-7
센서	Hyperion	ETM ⁺
공간해상도	30m	30m
영상크기	250×500pixels	250×500pixels
밴드 수	242	8
촬영지역	서울, 경기	서울, 경기
데이터 취득일	2002년 9월	2001년 9월

3.2 알고리즘 실험

Hyperion 센서로 취득한 영상은 242의 밴드를 가지고 있지만, 실제 데이터는 잡음이 심한 밴드를 포함하고 있어 이를 우선적으로 제거하였으며, MNF(Maximum/Minimum Noise Fraction) 변환(Green *et al*, 1988)을 통하여 필터링을 수행하고 다시 역 MNF 변환을 함으로써 최종적으로 153개의 밴드를 사용하였고 ETM+ 영상은 열적의 밴드와 전정색(panchromatic) 영상을 제외한 6개 밴드를 사용하였다.

두 영상에 대해 각각 MLC와 SAM, SFF를 수행하였으며, 나대지, 수계, 산림, 초지 그리고 도심지로 5개의 클래스를 선정하고 각 알고리즘에 적용하였다. 여기서, MLC는 트레이닝 클래스의 분포 정보를 이용하게 되며, SAM과 SFF는 평균 벡터 정보를 사용하게 된다. 분류 결과 영상은 동일 지역 1:25,000 축척의 지형도를 이용하여 기하보정을 실시하였고, 총 456개의 격자점을 선택하여 분류 정확도를 정량적으로 분석하였다. 그림 1은 본 연구에 사용된 Hyperion과 ETM+ 영상이며, 그림 2는 연구의 흐름도를 간단히 나타낸 것이다.

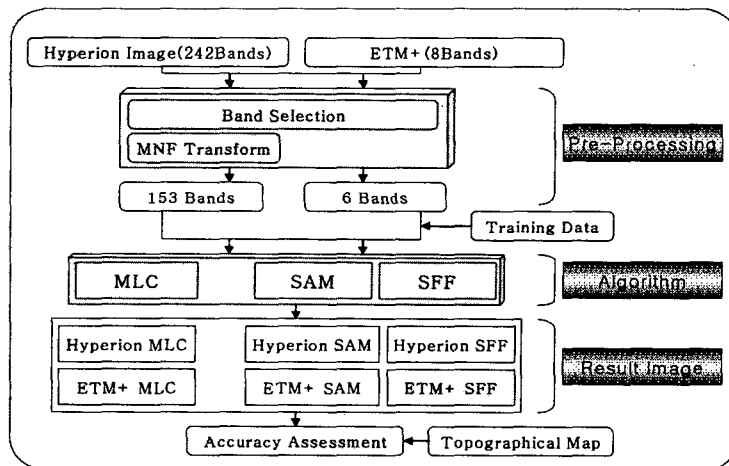


그림 2. 연구 흐름도

4. 정확도 평가 및 분석

분류 결과를 시각적으로 평가하기 위해 우선 위색(pseudo color) 영상을 생성하였고, 동일 데이터에 대한 알고리즘 별 분석과 각 알고리즘에 대한 Hyperion 영상과 ETM+ 영상의 데이터간 분석을 수행하

였다. 우선 Hyperion 영상의 경우, SAM 기법은 산림에서 어두운 지역과 밝은 지역이 명확히 구분되고, 도심지역도 도로와 주거지 등의 클래스에 대해 양호한 분류 결과를 나타냈다. SFF 기법은 전체적으로 양호한 분류 결과를 얻었으나 수계지역이 일부 오분류 된 것을 확인할 수 있었다. 반면 MLC 기법은 그림 3의 (4)와 같이 분류가 제대로 수행되지 못 하였다. 다중분광 영상의 경우, 시각적으로 각 알고리즘 적용 결과를 구분하기 힘들 정도의 분류결과를 보였고, SFF 기법을 적용한 결과 영상은 산림의 어두운 지역과 밝은 지역이 명확히 구분되지 못함을 알 수 있었다. 데이터간 분석에서, SAM 기법은 Hyperion 영상과 ETM+ 영상 모두 좋은 분류 결과를 보이는 반면, SFF는 다중분광 영상에, MLC는 하이퍼스펙트럴 영상에 적합하지 못하다는 것을 결과를 통해 확인할 수 있었다.

정량적 분석 결과를 통해, MLC 기법은 ETM+ 영상에서 좋은 분류 결과(73.96%)를 나타내는 반면, Hyperion 영상에서는 트레이닝 정보를 이용한 알고리즘 적용이 효과적이지 못함을 알 수 있었다. 이 경우 유효 밴드 추출 또는 선택 과정과 같은 전처리를 수행하는 것이 하나의 해결 방안이 될 것이다. 또한, 시각적인 평가와는 달리 SFF와 SAM 기법은 다중분광 영상에서 서로 비슷한 정확도를 보였지만, MLC 결과보다는 다소 낮게 나타났다. 하이퍼스펙트럴 영상의 분류에서 SFF의 전체 정확도는 79.43%로 가장 높게 나타났고, SAM 기법 또한 비교적 높은 정확도(73.74%)를 보였다. 하이퍼스펙트럴 영상의 분류에 있어서는 분포 정보를 고려한 분류 기법보다 벡터 공간에서 분광 패턴의 정보를 이용한 SAM, SFF기법들이 더 좋은 결과를 보임을 알 수 있었다. 아래의 그림 3은 각 알고리즘이 적용된 6개의 분류 결과 영상을 보여주며, 표 1~6은 결과 정확도를 나타낸 것이다.




(1) ETM+ MLC



(2) ETM+ SAM



(3) ETM+ SFF



(4) Hyperion MLC



(5) Hyperion SAM



(6) Hyperion SFF

그림 3. 결과 영상

표2. ETM+ MLC

	나대지	수계	밝은산림	어두운산림	초지	도심지 1	도심지 2
Produce Accuracy	66.67%	71.43%	41.77%	100.00%	90.79%	84.68%	100.00%
Users Accuracy	50.00%	100.00%	100.00%	98.11%	40.83%	88.68%	94.34%
Total Accuracy	73.96%						

표3. ETM+ SAM

	나대지	수계	밝은산림	어두운산림	초지	도심지 1	도심지 2
Produce Accuracy	66.67%	85.71%	47.77%	94.64%	71.05%	50.53%	100.00%
Users Accuracy	3.28%	100.00%	97.40%	92.98%	40.91%	96.00%	86.30%
Total Accuracy	65.86%						

표4. ETM+ SFF

	나대지	수계	밝은산림	어두운산림	초지	도심지 1	도심지 2
Produce Accuracy	66.67%	71.43%	43.82%	100.00%	23.68%	72.48%	100.00%
Users Accuracy	9.09%	100.00%	95.12%	72.02%	33.96%	73.15%	88.14%
Total Accuracy	69.15%						

표5. Hyperion SAM

	나대지	수계	밝은산림	어두운산림	초지	도심지 1	도심지 2
Produce Accuracy	66.67%	85.71%	85.38%	100.00%	7.89%	52.46%	100.00%
Users Accuracy	4.44%	85.71%	75.00%	94.12%	35.29%	82.05%	86.96%
Total Accuracy	78.77%						

표6. Hyperion SFF

	나대지	수계	밝은산림	어두운산림	초지	도심지 1	도심지 2
Produce Accuracy	100.00%	85.71%	73.15%	100.00%	46.67%	83.12%	100.00%
Users Accuracy	25.00%	85.71%	89.34%	96.83%	47.95%	82.05%	84.16%
Total Accuracy	79.43%						

5. 결론

본 연구에서는 MLC, SAM, 그리고 SFF의 분류 알고리즘들을 다중분광 영상과 하이퍼스펙트럴 영상에 적용하여 분류를 수행하고 그 결과를 비교 평가하였다. MLC 기법은 다중분광 영상에서는 높은 분류 정확도를 나타내었지만, 하이퍼스펙트럴 영상에 대해서는 분류가 제대로 수행되지 않았다. 이는 트레이닝 데이터와의 인접성에 기반하여 클래스를 결정하는 다중분광 영상의 분류 기법이 방대한 양의 분광 데이터를 포함하는 하이퍼스펙트럴 영상의 정보를 충분히 반영하지 못 함을 의미한다. MLC 기법을 하이퍼스펙트럴 영상에 적용하기 위해서는 매우 많은 양의 트레이닝 데이터를 필요로 하게 되며 이는 현

실적으로 불가능하고 유효 밴드 추출과 같은 전처리 과정을 통하여 이루어질 수 있을 것이다. 반면, SFF 및 SAM 기법은 하이퍼스펙트럴 영상에서 80%에 가까운 전체 정확도를 나타내어 하이퍼스펙트럴 영상에 효과적인 기법임을 확인할 수 있었다.

그러나 본 연구에서는 대상 지역에 대한 스펙트럴 라이브러리 정보를 활용하지 못 하여 SFF 기법의 효율성을 충분히 평가하지 못 하였고, 분류 클래스의 수가 적어 하이퍼스펙트럴 영상의 분광 정보를 효율적으로 다 사용하지 못 한다는 한계점을 갖는다.

따라서, 향후 연구에서는 스펙트럴 라이브러리를 활용하여 SFF 기법의 구현 및 평가를 수행하고 트레이닝 데이터량과 밴드 수간의 상관관계를 분석해보고자 한다.

참고문헌

- Clark, R. N., Gallagher, A. J., and Swayze, G. A. (1990), Material Absorption Band Depth Mapping of Imaging Spectrometer Data Using the Complete Band Shape Least-Squares Algorithm Simultaneously Fit to Multiple Spectral Features from Multiple Materials, *Proceedings of the Third AVIRIS Workshop, JPL Publication 90-54*, pp. 176-186.
- Green, A. A., Berman, M., Switzer, P, and Craig, M. D. (1988), A Transformation for Ordering Multispectral Data in Terms of Image Quality with Implications for Noise Removal, *IEEE Trans. Geosci. Remote Sensing*, Vol. 26, No. 1, pp. 65-74.
- John A. Richards (1994), *Remote Sensing Digital Image Analysis*, Springer-Verlag, New York, pp. 182-187.
- X. Jia and J. A. Richards (1999), Segmented Principal Components Transformation for Efficient Hyperspectral Remote-Sensing Image Display and Classification, *IEEE Trans. Geosci. Remote Sensing*, Vol. 37, pp. 538-542.
- Youngsinn Sohn and N. Sanjay Rebello (2002), Supervised and Unsupervised Spectral Angle Classifiers, *Photogrammetric Engineering & Remote Sensing, ASPRS*, Vol. 68, No. 12, pp. 1271-1280.
- Anil Cheriyyadat (2003), Limitations of Principal Component Analysis for Dimensionality-Reduction for Classification of Hyperspectral Data, Master Thesis, Mississippi State University.
- C. Lee and D. A. Landgrebe (1997), Decision Boundary Feature Extraction for Neural Networks, *IEEE Trans. Neural Networks*, Vol. 8, pp. 75-83.