

Hyperion 영상의 분류를 위한 밴드 추출

한동엽 · 조영욱 · 김용일* · 이용웅**

서울대학교 지구환경시스템공학부*, 국방과학연구소**

Feature Selection for Image Classification of Hyperion Data

Dong-Yeob Han, Young-Wook Cho, Yong-Il Kim*, and Yong-Woong Lee**

School of Civil, Urban & Geosystem Engineering, Seoul National University*

Agency for Defense Development**

Abstract : In order to classify Land Use/Land Cover using multispectral images, we have to give consequence to defining proper classes and selecting training sample with higher class separability. The process of satellite hyperspectral image which has a lot of bands is difficult and time-consuming. Furthermore, classification result of hyperspectral image with noise is often worse than that of a multispectral image. When selecting training fields according to the signatures in the study area, it is difficult to calculate covariance matrix in some clusters with pixels less than the number of bands. Therefore in this paper we presented an overview of feature extraction methods for classification of Hyperion data and examined effectiveness of feature extraction through the accuracy assessment of classified image. Also we evaluated the classification accuracy of optimal meaningful features by class separation distance, which is also a method for band reduction. As a result, the classification accuracies of feature-extracted image and original image are similar regardless of classifiers. But the number of bands used and computing time were reduced. The classifiers such as MLC, SAM and ECHO were used.

Key Words : Hyperion, Hyperspectral, Classification, Feature Extraction, Separability.

요약 : 다중분광 영상의 정확한 지형지물 분류를 수행할 때 고려해야 할 중요한 요소중에 적절한 분류 클래스의 선정과 선정된 클래스의 분리도가 높아지도록 트레이닝 지역(training fields)을 잡는 것은 특히 중요하다. 최근에 이용되고 있는 위성탐지 하이퍼스펙트럴(hyperspectral) 영상은 많은 밴드를 포함하고 있기 때문에 데이터 처리가 어렵고, 잡음(noise)으로 인하여 다중분광 영상보다 분류 결과가 나쁜 경우도 나타난다. 특히 대상지역의 클래스에 따른 트레이닝 지역의 선정시 일부 클래스에서 하이퍼스펙트럴 밴드수에 비해 상대적으로 적은 수의 트레이닝 샘플로 인하여 공분산 행렬의 계산에 어려움이 따른다. 따라서 본 연구에서는 Hyperion 데이터를 이용한 분류를 수행하기 위하여 밴드 추출 방식을 알아보고, 분류영상의 정확도 평가를 통하여 밴드 추출의 효용성을 시험하였다. 밴드를 줄이는 또 다른 방법인 클래스간 분리도에 따른 최적 밴드를 추출하여 분류정확도를 평가하였

다. 실험 결과, 밴드 추출이나 클래스 분리도에 따라 선택된 영상의 분류 정확도는 분류자(classifier)에 상관없이 전체 밴드를 사용한 원영상과 유사하게 나타났지만, 사용된 밴드수와 계산 시간은 단축되었다. 분류자는 MLC, SAM, ECHO의 3종류가 사용되었다.

1. 서론

하이퍼스펙트럴 영상은 물체의 고유한 반사특성을 구분할 수 있는 10nm~20nm의 밴드폭으로 대상물을 촬영하기 때문에 광물 탐지(Swayze *et al.*, 1992), 수질(Koponen *et al.*, 2002) 및 농작물 관리(Staenz *et al.*, 1998), 식생(Sandmeier and Deering, 1999) 등의 응용분야에서 높은 가능성이 드러나고 있다. 초기 항공기용 하이퍼스펙트럴 영상을 토대로 이루어진 연구는 위성 하이퍼스펙트럴 영상의 취득으로 더 많은 분야에서 가능성이 연구되고 있다. 하이퍼스펙트럴 영상을 이용한 토지이용 분류(Roessner *et al.*, 2001)는 많이 이루어지지 않고 있으며, 주로 분류를 위한 밴드 변환이나 유효 밴드 추출(Pai-Hui *et al.*, 2002) 등에 국한되고 있다. 특히, 하이퍼스펙트럴 영상의 많은 밴드에 포함된 유효정보와 잡음을 구분하는 것은 영상분석의 질을 향상시키고, 분석 속도 및 효율성을 높일 수 있다는 점에서 중요하다.

본 논문에서는 지표면의 토지이용 분류에 필요

한 하이퍼스펙트럴 영상의 유효 정보 추출 알고리를 3장에서 알아보고, 잡음이 제거된 Hyperion 영상과 밴드 추출된 영상의 분류 정확도를 비교하였다. 그리고 분류에 사용되는 밴드수를 줄이기 위하여 클래스 분리도에 따른 최적의 밴드를 선택하여 마찬가지로 분류정확도를 비교하였다. 분류자는 MLC(Maximum Likelihood Classifier), SAM(Spectral Angle Mapper)(Kruse *et al.*, 1990), ECHO(Extraction and Classification of Homogeneous Objects)(Landgrebe, 1980)를 사용하여 분류자의 영향도 검토하고자 하였다. 이를 통하여 밴드수와 분류 정확도와의 관계를 알아보았다. 위의 연구 내용은 Fig. 1의 연구 흐름도로 정리할 수 있다.

2. Hyperion 영상

100nm 내외의 파장영역을 하나의 밴드로 하여 가시광선에서 적외선에 이르는 파장영역에 대한 정보를 수개의 밴드 형태로 취득하는 다중분광(multispectral) 영상과 달리 Hyperion 영상은 10nm 폭을 가진 220개의 밴드로 이루어져 있다. 좁고 연속적인 밴드 폭은 필드(field)나 연구실내에서

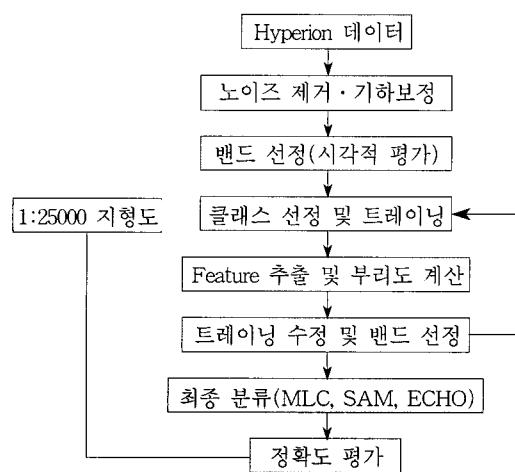


Fig. 1. Flowchart.

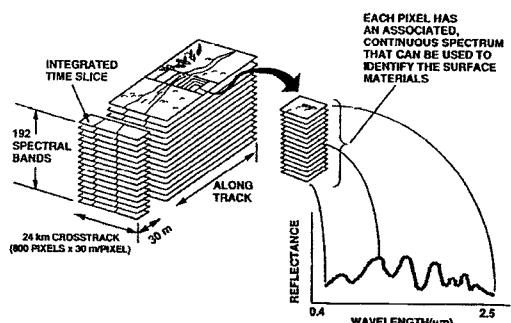


Fig. 2. Concept of imaging spectrometry.

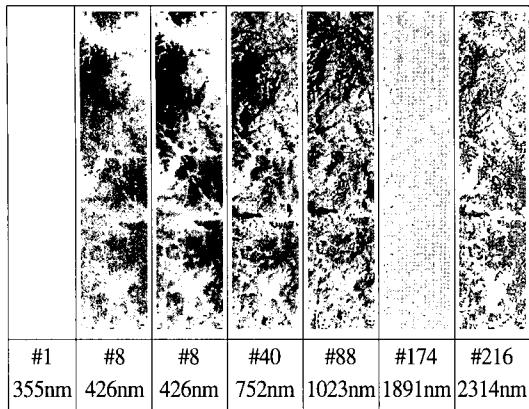


Fig. 3. Hyperion image (band number & central wavelength).

취득된 분광정보와 직접 비교·가능하므로 하이퍼스펙트럴(hyperspectral) 센서 또는 “imaging spectrometer”로 분류된다(Fig. 2).

1984년에 개발된 AVIRIS는 항공기 하이퍼스펙트럴 센서로 하이퍼스펙트럴 영상의 연구를 위한 주요한 데이터원이 되었으며, Hyperion 영상은 본격적인 위성 하이퍼스펙트럴 영상을 제공하고 있다. Hyperion은 Landsat과 같은 궤도를 1분 이내로 돌며 지구를 관측하는 EO-1에 탑재된 센서(ALI, Hyperion, LAC) 중 하나로 TRW에 의해 개발되었으며 0.4~2.5 μ m 파장 범위에 220개 밴드를 가지고 있는 하이퍼스펙트럴 영상을 제공한다 (Barry, 2001). 본 연구에 사용된 Hyperion 데이터는 센서 사양과는 달리 242개의 밴드로 이루어져 있고, 파장대에 따라 정보가 없거나, 잡음이 심하거나 유사한 분광정보를 갖는 밴드 등으로 구성되어 있다(Fig. 3).

3. 밴드 추출(Feature Selection)

다중분광 영상을 분석하는 과정은 일반적으로 아래와 같이 5단계로 나눌 수 있지만 단계별 결과를 참조하여 반복 분석해야 한다(Landgrebe, 2001).

- ① 데이터 검토 : 데이터, 데이터 질, 일반적 특성에 대한 검토 단계로 영상을 시각적으로 살펴보는 단계

② 클래스 정의 : 확인될 수 있는 또는 구분되어야 하는 클래스를 정의하는 것으로 트레이닝 샘플(sample)을 선정

③ 밴드 추출 : 분석에 사용될 특정 밴드가 시각적으로 확인되거나 정량적으로 계산되어야 한다. 즉 단순히 최적 밴드를 선택하거나 유용한 어떤 방법으로 밴드 조합을 계산하는 단계이다.

④ 분석 : 구분을 위한 특정 분석 알고리즘 적용

⑤ 결과 평가 : 결과의 질과 특성을 결정하기 위한 정성적·정량적인 수단의 사용

위와 같은 분석과정에서 초기에 데이터를 파악하는 것이 중요하며, 5단계 중에서 하이퍼스펙트럴 영상을 분류하기 위하여 중요한 ③번 단계까지의 주요 분석과정은 다음과 같다.

1) 시각적인 판단

영상은 다양한 조건에 따라 다른 화소값을 갖게 되며 아직까지 다양한 자연 조건으로 인한 영상의 형성에 대한 체계화한 규칙이 마련되어 있지 않기 때문에 영상에 대한 시각적인 판단이 가장 쉽고 정확하게 유효 밴드를 추출할 수 있는 수단이다.

2) 신호대잡음비(Signal-to-Noise Ratio)

SNR은 특정 밴드의 유용성을 판단하기 위하여 일반적으로 사용되는 것으로 SNR이 큰 레이더영상과는 달리 광학영상에서는 SNR의 밴드별 차이를 비교함으로써 유효밴드를 선정한다. SNR은 임의의 원도우내에서 화소값의 평균과 표준편차의 비로 나타나며 SNR 영상을 시각적으로 확인하여 밴드의 적합성을 판단한다.

3) MNF 변환

MNF 변환(Minimum Noise Fraction Transform)은 영상의 고유 차원을 결정하고 잡음을 분리하여 처리시간을 줄이기 위해 사용되는 것으로 두 번의 주성분 분석(principal component analysis)에 의한 선형 변환이 단계적으로 수행된다(Boardman and Kruse, 1994). 첫 번째 변환은 추정된 잡음의 공분

산 행렬에 근거하여 데이터에서의 잡음을 재해석하는 단계이며, 이 단계를 거치면 밴드간의 상관성이 제거되고 잡음은 단위 분산(unit variance)을 갖는다. 두 번째 단계는 MNF를 수행하여 잡음이 화이트 잡음화(white noise)된 데이터에 표준주성분변환을 수행한다. 의미있는 데이터 차원은 최종 고유값(eigenvalue)과 이에 관련된 영상의 평가에 의해 결정되며, 선택된 고유치 임계값에 근거하여 새로운 영상을 생성한다.

4) 판별 분석법(Discriminant Analysis)

통계량 분석에서 사용되는 판별 분석을 페턴 인식에 적용시킨 것으로, 클래스내의 분산과 클래스간 분산값의 비를 최대화하는 밴드의 선형조합을 생성시키는 것으로 트레이닝 샘플의 통계값을 이용한다(Fukunaga, 1990). 클래스간 평균값의 차이가 크지 않은 경우 비효과적이며, 신뢰할만한 추출 밴드수는 항상 클래스 수보다 하나 적다는 단점이 있다.

5) 결정 경계법(Decision Boundary)

결정 경계법(Lee and Landgrebe, 1997)에서는 영상분류에 필요한 모든 feature 벡터가 분광영역을 몇 개의 영역으로 나누는 결정경계로부터 추출될 수 있다고 한다. Fig. 4에서 클래스 1과 2를 구분하는데 feature 벡터 V1은 도움이 되지 않고, V2는 분류에 유용하다는 것을 알 수 있다. 이와 같이 영상을 분류하기 위하여 유용한 feature 벡터와 유용하지 않은 feature 벡터를 분리할 수 있으며, 이 원리는 하이퍼스펙트럴 영상의 밴드 추출에 적용될 수 있다.

Lee는 유용한 벡터를 찾기 위하여 다음 식의 DBFM(Decision Boundary Feature Matrix)을 정의하였으며, DBFM의 nonzero 고유값에 해당하는 feature 밴드 영상은 전체 영상을 이용한 것과 동일한 분류 정확도를 기대할 수 있다고 하였다.

$$\sum_{DEFM} = \frac{1}{K} \int_s N(X)N^T(X)p(X)dX$$

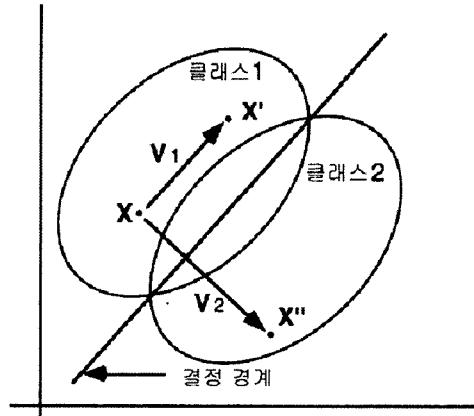


Fig. 4. Feature extraction from decision boundary.

여기에서, $p(X)$: 확률밀도함수

$N(X)$: 점 X 에서 decision boundary에 수직인
단위 벡터

$$K : \int_s p(X)dX$$

S : 결정 경계.

결정 경계법은 트레이닝 샘플의 통계량보다는 샘플을 직접 이용하여 유효 클래스 경계를 결정하는 것으로 원래의 밴드를 선형결합하여 새로운 밴드 변환을 생성하고 고유값을 통한 새로운 밴드의 유효성을 평가하는 것이다. 하지만 샘플수가 적으면 비효과적이며, 너무 크면 계산시간이 길어지는 단점이 있다.

6) 클래스 분리도 측정

분류 확률을 결정하는 트레이닝 단계의 최적화를 위하여 클래스간 분리도 분석을 수행하는 것으로, 밴드조합별 클래스 분리도를 통하여 분류에 이용할 적절한 밴드를 선택할 수 있다. 클래스에 따라 밴드 조합이 달라질 수 있으므로 트레이닝 샘플의 정규화도 고려해야 한다. 분리도 측정방법(어양담, 1999)은 Divergency, Mahalanobis거리, Jeffrey-Matusita 거리, Bhattacharyya 거리, 다변량 조건부 확률계산을 통한 유추 등이 있다.

본 논문에서 사용된 Bhattacharyya 거리에 대한

정의는 다음과 같다.

$$B = [\mu_1 - \mu_2] \left[\frac{\Sigma_1 + \Sigma_2}{2} \right]^{-1} [\mu_1 - \mu_2] + \frac{1}{2} \ln \frac{\left| \frac{1}{2} [\Sigma_1 + \Sigma_2] \right|}{\sqrt{|\Sigma_1||\Sigma_2|}}$$

여기서, μ_x 는 평균 벡터

Σ_x 는 공분산 행렬.

위 식의 첫 번째 항은 클래스의 공분산으로 정규화한 클래스의 평균값에 의한 분리도를 설명하고, 두 번째 항은 클래스의 공분산에 의한 분리도를 나타낸다.

4. 실험결과

사용영상은 2002년 9월 3일 EO-1 위성의 Hyperion 센서로 촬영된 것으로 영상의 기본제원은 Table 1과 같다. 대상지역은 원영상의 아랫부분에 해당하는 경기도 남양, 발안, 군포, 안양을 포함하는 곳이며, 긴 스트립 형태의 영상에서 도심지와 산, 농경지, 수계가 포함되도록 대상지역을 선정하였다. 실험영상의 크기는 974(행) × 256(열) × 242(밴드)이다.

1) 전처리

전처리 과정에서는 영상의 잡음 제거와 기하보정이 수행되었다. 원데이터에 나타나는 세로방향의 줄무늬(line drop)는 영상분류에 큰 오차요인으로 되기 때문에 주위 화소값으로 대체하거나 평균값

Table 1. Hyperion Header Information.

구성항목	제원
처리단계	L1 Data Product
열	256
행	3129
밴드	242
취득일자	2002.09.03
데이터 형	2바이트
포맷	HDF Scientific Data
저장 방식	BIL(Band Interleaved)
Site 경도	126.989400
Site 위도	37.551670

을 이용하여 제거하였다. 영상의 기하보정은 1:25,000 지형도(2002년 6월 수정)에서 기준점을 취득하여 1차 다항식으로 변환하였다.

2) 초기 영상 분석

355.59nm ~ 2577.08nm 파장범위에서 연속적으로 영상이 취득되었기 때문에 지표면 에너지가 흡수되는 파장범위에서 영상정보가 나타나지 않았고, 잡음이 심한 밴드도 많이 존재하였다. 위의 파장

Table 2. Geometric Accuracy of Hyperion Image.

#	Img X	Img Y	X Ref.	Y Ref.	RMSE
1	180.4	-91.9	195964.4	432323.3	0.19
2	140.0	-216.3	193895.1	428898.1	0.38
3	194.4	-176.2	195759.7	429716.0	0.65
4	213.8	-325.4	195285.9	425096.3	1.26
5	146.0	-452.1	192375.0	421875.0	1.25
6	132.4	-357.8	192675.5	424777.3	1.50
7	72.2	-465.3	190158.5	421956.2	1.94
8	247.5	-446.7	195382.5	421296.8	0.83
9	107.5	-936.8	187742.2	407675.3	0.65
10	210.5	-8.39.8	191518.3	409821.1	0.90
11	101.6	-681.4	189425.0	425300.0	0.71
12	96.0	-850.6	188021.9	410336.5	0.77
13	44.3	-388.3	189778.4	424427.1	1.80



Fig. 5. Hyperion image (Left) full scene, (Right) geo-registered study area(rgb:50,27,17).

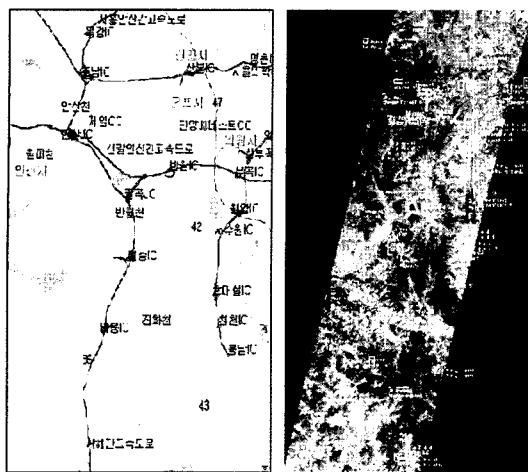


Fig. 6. (Left) Thematic map in study area,
(Right) Selected training fields.

Table 3. Band Selection according to the Image Interpretation.

단계	밴드	범위	히스토그램	시각*
정보 포함	10~56	유	유	양호
	82~97			
	101~119			
	131~164			
	182~184			
	187~218			
잡음 적음**	8~9	유	유	구분가
	57			
	77~81			
	98~100			
	120			
	128~130			
	165, 181			
	219~220			
잡음 심함	121~127	유	무	불가
	166~180			
	185~186			
	221~224			
정보 없음	1~7	무	무	불가
	58~76			
	225~242			

* 시각적인 판단.

** 잡음이 심하거나 화소값 대비가 떨어짐.

영역은 지형지물 분류를 위한 정보를 담고 있지 않거나 잡음으로 작용하므로 본 연구의 실험에서는 사용하지 않았다(Table 3).

3) 영상 분류

대상지역의 복잡한 지형지물 특성과 영상 취득 시기에 작물의 생육상태에 따라 나타나는 농경지 특성으로 인하여 클래스의 조합과 정확도 평가에 어려움이 있었다. 본 실험은 원영상과 feature 추출된 영상, 분리도를 고려한 밴드조합 영상의 분류 정확도를 평가하는 것이 주요 목적이며, 그 과정에서 분류자(classifier)와 클래스 수의 영향이 있는지를 알아보기 위하여 Table 4와 같은 조합으로 실험이 이루어졌다. 사용된 분류자는 MLC, SAM, ECHO이며 MLC와 ECHO는 다중분광 영상에 많이 사용되는 방법이며 SAM은 하이퍼스펙트럴 영상에 주로 사용된다.

Table 4. Test Methods for Classification.

구분		설명
분류자		MLC, SAM, ECHO
사 용 밴 드	①	초기 추출된 영상 (151 밴드)
	②	DBFE(Decision Boundary Feature Extraction) 변환 영상의 상위 60개 밴드
	③	· 151개 원영상에서 클래스 분리도를 고려 한 최적 19개 밴드 조합 · (12클래스) 밴드 : 15 31 44 91 115 116 117 118 130 131 134 135 139 142 143 144 145 151 · (6클래스) 밴드 : 2 6 12 14 24 26 28 30 31 32 33 36 41 62 73 88 107 116 118
	④	· DBFE 변환 영상에서 클래스 분리도를 고려 한 최적 19개 밴드 조합 · (12클래스) 밴드 : 1 2 4 5 6 9 13 14 15 16 17 29 42 46 47 55 59 60 68 · (6클래스) 밴드 : 3 5 7 8 10 11 13 14 15 49 56 73 82 83 87 100 104 113 132
	⑤	Barren1, Barren2, Rice Field, Wet Rice Field, Dry Field, Grass, Urban, Forest, Shadow Forest, Water, Background
	⑥	Barren, Field, Water, Urban, Vegetation, Background

Table 4에서 ②는 DBFE 변환에서 0 이상의 고유값(eigenvalue)을 갖는 밴드를 의미하며, ③은 클래스 분리도를 고려한 것으로 19개 밴드는 DBFE에서 약 92%(12클래스), 99%(12클래스)의 누적 정보량을 갖지만, 실험자가 임의로 선택한 밴드수이다. ④는 DBFE 변환된 영상에 클래스 분리도를 계산하여 19개 밴드를 선택한 것이다. ⑤는 대상 지역의 영상판독으로 구별된 11개 클래스이고, ⑥은 11개 클래스를 6개 클래스로 통합한 것이다.

4) 정확도 평가

Table 5는 트레이닝 영역의 분류에 대한 전체정확도(overall accuracy) 결과를 나타낸 것으로 MLC와 ECHO 분류자는 트레이닝 영역을 대부분 90% 이상 정확하게 분류하였다. 하지만 SAM 분류자는 60% 이하로 정확도가 많이 떨어졌다. 분류 정확도에 차이는 있었지만 분류자가 ① ② ③ ④ 각 방법에 영향을 미치지 않는다는 것을 알 수 있다. 트레이닝 영역의 분류결과는 참조자료를 이용하여 수행된 정확도 평가에서도 비슷하게 나타났다.

Table 5. Overall Accuracies in Training Fields (%).

	MLC		SAM		ECHO	
	⑤	⑥	⑤	⑥	⑤	⑥
①	98.0	97.8	60.9	56.8	98.2	98.4
②	91.6*	95.4*	59.0	58.8	93.8	97.8
③	86.3	91.8	39.6	59.8	93.8	96.3
④	92.1	94.4	48.2	54.4	95.4	97.3

* : 60개 밴드의 경우 Singular matrix가 발생하여 40개로 분류한 결과임.

Table 6. Overall Accuracy using the Reference.

	MLC		SAM		ECHO	
	⑤	⑥	⑤	⑥	⑤	⑥
①	62.0	68.7	48.6	50.5	62.0	69.2
②	58.3	67.3	47.7	50.5	59.7	67.8
③	61.1	63.9	32.9	49.1	63.0	64.8
④	61.6	69.0	41.2	52.3	59.7	70.7

참조자료를 이용한 분류 정확도를 평가하기 위하여 1:25,000 지형도를 사용하여 대상지역내 216 점을 1km 격자 간격으로 계통적 샘플링(systematic sampling)을 하였다. 처음에 영상의 화소와 지형도를 고려하여 선정된 11클래스는 정확도 평가를 위하여 8클래스(barren, water, rice field, dry field, grass, urban, forest, wet rice field)로 수정하였고 6클래스는 background를 제외한 5클래스(barren, field, urban, vegetation, water)로 수정하여 평가하였다. Table 6은 전체 정확도를 나타낸 것이고, Table 7은 Kappa 계수를 나타낸 것이다.

MLC와 ECHO 분류는 대체로 비슷한 분류 정확도를 보였지만 ECHO가 약간 우수한 결과를 나타내었다. 하지만 ECHO는 개개의 화소값과 공간적 분포를 고려하기 때문에 점유면적이 높은 클래스가 확대되는 단점을 보였다. SAM은 정확도가

Table 7. Kappa Coefficient using the Reference.

	MLC		SAM		ECHO	
	⑤	⑥	⑤	⑥	⑤	⑥
①	0.478	0.527	0.324	0.288	0.476	0.534
②	0.429	0.503	0.314	0.288	0.441	0.512
③	0.465	0.455	0.162	0.266	0.482	0.459
④	0.472	0.528	0.255	0.308	0.447	0.549

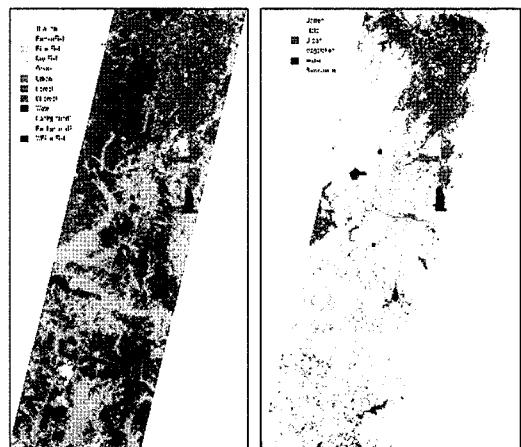


Fig. 6. Classified images: (Left) ①+⑤_ECHO, (Right) ①+⑥_ECHO.

상대적으로 낮았고, 시각적으로도 많은 분류 오차를 생성하였다. ① ② ③ ④의 비교 방법중에서 ③ 방식이 가장 낮은 정확도를 보였으며, 이는 19개의 최적 밴드가 원영상의 클래스 분광정보를 모두 표현하지 못한다는 것을 나타낸다. 즉 단순히 분리도에 따른 최적밴드만으로 feature 추출을 수행해서는 안되며, 추출된 밴드가 원영상을 얼마나 대표할 수 있는지에 대한 평가가 수행되어야 한다. 영상의 분류 정확도가 60~70%로 낮은 이유는 수직 line drop의 제거가 완전하게 이루어지지 않았으며, 복잡한 연구지역에서 지형도를 통한 클래스 자료 수집이 부정확했기 때문으로 여겨진다.

5. 결 론

하이퍼스펙트럴 영상에 MLC를 적용할 경우 트레이닝 화소가 적으면 분류를 수행할 수 없으며, 공분산 행렬을 적당히 추정해서 분류할 수 있지만 클래스 특성을 반영하지 못한다는 단점을 지니고 있다. 따라서 하이퍼스펙트럴 영상에 통계적 감독 분류자를 적용하기 위해서는 클래스 정보를 바탕으로 최적의 밴드를 찾아내는 분리도 평가와 클래스 분류를 위한 영상의 공간변환이 필요하다고 할 수 있다. 이에 대한 본 연구의 실험을 통하여 다음과 같은 결론을 내릴 수 있다.

첫째. 특정 목적에 하이퍼스펙트럴 영상을 사용할 경우 목적에 유효한 정보를 갖고 있는 파장대역의 추출에 대한 폭넓은 연구가 필요하다.

둘째, feature 추출로 생성된 영상의 적정한 유효밴드수에 대한 연구가 필요하며, 이는 다양한 실험을 통하여 검증되어야 한다.

셋째 분리도 평가를 통하여 밴드수와 클래스별 최적 밴드를 선정할 수 있다. 하지만 원영상의 분광정보량을 반영할 수 있는 밴드수가 선정되어야 한다.

넷째, 영상의 잡음 제거, 대기 보정 등 전처리 과정이 제대로 수행되어야 이후 밴드 추출 및 분류 작업의 효율성을 기대할 수 있다.

참고문헌

- 어양담, 1999. 위성영상 분류를 위한 트레이닝 정규화 알고리즘과 클래스 분리도 측정기법 개발, 서울대 대학원 박사학위논문.
- Boardman, J. W. and F. A. Kruse, 1994. Automated spectral analysis: a geological example using AVIRIS data, north Grapevine Mountains, Nevada: in *Proceedings, ERIM Tenth Thematic Conference on Geologic Remote Sensing*, Environmental Research Institute of Michigan, Ann Arbor, MI, I-407-I-418.
- Lee, C. and D. A. Landgrebe, 1997. Decision Boundary Feature Extraction for Neural Networks, *IEEE Transactions on Neural Networks*, 8(1): 75-83.
- Landgrebe, D. A., 1980. The Development of a Spectral-Spatial Classifier for Earth Observational Data, *Pattern Recognition*, 12(3): 165-175.
- Landgrebe, D. A., 2002. Hyperspectral Image Data Analysis as a High Dimensional Signal Processing Problem, (Invited), *Special Issue of the IEEE Signal Processing Magazine*, 19(1): 17-28.
- Landgrebe, D. A. and L. Biehl, 2001. *Multispec Tutorial: An Introduction to Multispec*. Version 5. ENVI Tutorial, Research Systems.
- Freek D. V. and M. D. Steven, 2001. *Imaging Spectrometry: Basic Principles and Prospective Applications*, Kluwer Academic Publishers.
- Hsu P., T. Yi-Hsing, and P. Gong, 2002. Dimension reduction of hyperspectral images for classification applications. *Geographic Information Sciences*, 8(1): 1-8.
- Richards, J. A., 1993. *Remote Sensing Digital Image Analysis*, 2nd Ed., Springer-Verlag.
- Fukunaga, K., 1990. *Introduction to Statistical Pattern Recognition*, New York: Academic.

- Kruse, F. A., K. S. Keirein-Young, and J. W. Boardman, 1990. Mineral Mapping at Cuprite, Nevada with a 63-channel Imaging Spectrometer, *Photogrammetric Engineering and Remote Sensing*, 56: 83-92.
- Barry, P., 2001. Introduction to the Hyperion Instrument & Data Processing, *Hyperion & ALI Data Users Workshop*, <http://eo1.gsfc.nasa.gov/miscPages/Workshop/Sec-03.pdf>.
- Roessner S., K. Segl, U. Heiden, and H. Kaufmann, 2001. Automated differentiation of urban surfaces based on airborne hyperspectral imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 39(7): 1525-1532.
- Koponen, S., J. Pulliainen, K. Kallio, and M. Hallikainen, 2002. Lake water quality classification with airborne hyperspectral spectrometer and simulated MERIS data, *Remote Sensing of Environment*, 79(1): 51-59.
- Sandmeier, S. and D. W. Deering, 1999. Structure Analysis and Classification of Boreal Forests Using Airborne Hyperspectral BRDF Data from ASAS, *Remote Sensing of Environment*, 69(3), 281-295.
- Staenz K., J. C. Deguisse, J. Chen, H. McNairn, T. Szeregi, and M. McGovern, 1998. The Use of Hyperspectral Data for Precision Farming; *ISPRS Commission VII Symposium*, Budapest, Hungary, Sep. 1-4, pp. 38-42.
- Swayze, G. A., R. N. Clark, S. Sutley, and A. Gallagher, 1992. Ground-Truthing AVIRIS Mineral Mapping at Cuprite, Nevada, *Summaries of the Third Annual JPL Airborne Geosciences Workshop*, Volume 1: AVIRIS Workshop. JPL Publication 92-14, pp. 47-49.