

교사 자료의 분광 특징 분리에 의한 감독 분류 성능 향상

김 광 은

InterSys, Inc.

Enhancing Classification Performance by Separating Spectral Signature of Training Data Set

Kwang-Eun Kim

InterSys, Inc.

Abstract : This paper presents a method to enhance the performance of supervised classification by separating the spectral signature of the training data sets for each class. Using clustering technique, a training data set is divided into several subsets which show a pattern of the normal distribution with small value of spectral variances. Then a supervised classification is applied with the divided training data set as training data for the temporary subclasses of the original class. The proposed method is applied to a Landsat TM image of Busan area for the applicability test. The result shows that the proposed method produces better classified results than the conventional statistical classification methods. It is expected that the proposed method will reduce the effort and expense for selecting the training data set for each class in an area which has spectrally homogeneous signature.

Key Words : Classification, Spectral Signature, Separation, Training Data.

요약 : 본 연구에서는 공간 영상 자료의 감독 분류에 있어, 분석자에 의하여 선정된 분류 항목별 교사 자료를 분광 특징별로 다수의 군집으로 분리하고, 각각의 군집을 새로운 분류 항목의 교사 자료로서 설정함으로써 분류 성능을 향상시킬 수 있는 기법을 제안하고자 한다. 특징 분리를 통하여 생성된 교사 자료는 비교적 작은 값의 밴드별 분산값을 가질 뿐 아니라 정규분포 형태의 자료 분포를 보이게 되어 통계적 감독 분류 기법의 적용에 적합한 교사 자료로서의 성격을 가지게 된다. 제안된 기법은 부산 지역에 대한 Landsat TM 영상 자료를 이용하여 그 적용성이 시험되었으며, 기존의 통계적 분류 기법들에 의한 결과와 그 성능이 정성적으로 비교되었다. 시험 적용 결과, 본 기법은 분석자가 선정된 교사 자료의 분광적인 분포 형태에 관계없이 우수한 분류 성능을 나타내는 것으로 판단되며, 따라서 분류 항목의 설정 및 항목별 교사 자료의 선정에 있어 교사 자료의 분광적 특징에 대한 동일성을 유지하기 위한 노력을 줄여줄 것으로 기대된다.

1. 서론

분류 기법은 전통적으로 위성 영상 자료로부터 각종 주제도를 생산하기 위한 효과적인 방법으로 서 취급되어 왔다(Maxwell, 1976). 특히, 감독 분류 기법은 단순한 영상의 분할이 아니라 공간 정보를 생산해낼 수 있는 도구로서 토지 피복도나 토지 이용도의 생산을 위하여 흔히 활용되어져 왔다(전형섭, 2001; Lee et al., 2002).

그러나 전통적인 통계적 감독 분류 기법들은 분류 항목별 교사 자료가 분광 공간 영역에서 정규 분포를 보이고 있다는 가정 하에 전개된 이론들을 그 배경으로 하는 기법들로서, 분석자가 분류 항목을 설정하는 데 있어 인지적인 요소보다는 분광 특성의 동일성을 고려하여 그 분광 특성이 통계적인 변수값들로서 잘 나타내질 수 있도록 해주어야만 한다. 예컨대, 감독 분류 시 흔히 “도심지”라는 분류 항목을 설정하여 활용하나, 많은 경우에 도심지는 매우 다양한 토지 피복 형태를 나타내기 때문에 다른 분류 항목들과 구별될 수 있는 특징적인 분광 특성을 보이지 못한다. 즉, 도심지는 콘크리트와 아스팔트 이외에도 잔디밭, 가로수, 학교 운동장, 서로 다른 색의 건물 지붕 등 매우 다양한 토지 피복 특징을 나타내는 경우가 많다. 특히 최근 많이 활용되고 있는 고해상도 영상 자료의 경우 “도심지”라는 분류 항목으로서 교사 자료를 선정하기란 매우 어렵다.

이와 같은 이유로서 1980년대 이후로 교사 자료의 분광 특성에 대한 통계적 특징에 무관한 분류 기법으로서 인공지능망(Lee and Kim, 2002; Civco, 1993; Benediktsson et al., 1990) 기법이 주목을 받아 왔으며, 최근에는 화소 단위가 아닌 영상을 분할한 후에 분할된 각각의 영역을 단위로 감독 분류를 수행하는 객체 기반 혹은 혼합 분류(Baatz, 1999) 기법 등이 등장하고 있다.

그러나 아직도 육안 분석에 의한 토지 피복도 작성이 분류 기법에 의한 토지 피복도 작성보다 우수한 결과를 보였다는 연구 결과(Lee et al., 2002)가 발표되고 있을 정도로 분류 기법이 현실

적이고 실용적인 토지 피복도 작성 기법으로서 활용되고 있지는 못한 것으로 보인다. 그 이유에는 여러 가지가 있겠으나, 우선 분석자가 의도하는 수 가지 혹은 수십 가지의 종류의 분류 항목으로 실제의 매우 다양하고 복잡한 지표 토지 피복에 의한 분광 특성들을 통계적 변수들로서 특징화하기가 어렵다는 것이 하나의 이유가 될 수 있다.

본 논문에서는 분류 항목의 분광적 특징과 무관하게 분석자가 의도하는 분류 항목별 주제도를 손쉽게 얻을 수 있도록 하기 위하여, 분석자가 설정한 분류 항목별 교사 자료를 분광 특징별로 분리하여 세부 분류 항목으로 세분화하여 분류될 수 있는 기법을 제안하고자 한다. 즉, 특징 분리 결과에 의한 세부 분류 항목별로 분류를 수행한 후에 그 결과를 다시 분석자가 설정한 분류 항목으로서 재설정함으로써, 분석자가 의도하는 항목으로 구성된 주제도를 생산할 수 있다.

2. 교사 자료의 특징 분리

통계적 분류 기법에서는 각 분류 항목별 교사 자료를 선정하고, 교사 자료의 분광적 특징을 평균, 공분산 등의 통계적 변수값들로서 대표하여 나타낸다. 이 때, 통계적 변수값들이 교사 자료의 분광 공간 영역에서의 분포 양상을 잘 대변하기 위해서는 교사 자료가 정규 분포를 보인다는 가정이 필요하게 된다. 또한 각 분류 항목들이 분광 공간 영역에서 서로 잘 분리될 수 있도록 분포하고 있어야 한다. 이에 따라 분석자들은 각 분류 항목을 가능한 한 분광적으로 동질성을 가질 수 있는 항목들로서 설정해야 하며, 동시에 교사 자료의 선정 또한 가능한 한 동일한 토지 피복을 보임으로써 그 분광 특성이 독특한 특징을 보일 수 있도록 이루어져야 한다. 즉, 분석자가 위성 영상으로부터 “경작지”라는 항목의 토지 피복에 대한 정보가 필요한 경우, 경작되고 있는 작물의 종류별로 분광특성이 확연히 다르다면 분석자는 서로 다른 작물이 재배되고 있는 경작지 영역을 “경작

지"라는 하나의 교사 자료 집단으로 선택할 수 없다. 이러한 예는 앞서 언급한 대로 "도심지"라는 분류 항목을 선정하고자 하는 경우 극단적으로 나타나게 된다.

이와 같은 이유로 많은 경우 분석자는 분류 항목을 원하는 수준 이상으로 세분화하게 된다. 즉 "도심지"라는 주제의 토지 피복 정보를 추출하기 위해서 흔히 도심지 내의 다양한 분광적 특성을 육안으로 분석하여 "도심지_1", "도심지_2", "도심지_3" 등의 세부 분류 항목을 잠재적으로 설정하고, 각 세부 분류 항목별로 교사 자료를 별도로 선정하여 감독 분류를 하게 된다. 이 때 많은 노력과 시간이 요구되며 대개 분류 후에는 이들 세부 분류 항목을 하나의 분류 항목으로 병합하는 과정을 거치게 된다.

본 연구에서는 분류 항목별 교사 자료의 분광 특성을 분리하여 동일한 분류 항목을 가지는 다수

의 교사 자료 집단으로 나누고, 이와 같이 생성된 다수의 교사 자료 집단을 이용하여 감독 분류하는 기법을 제안하고 있다. 예를 들어, 분석자는 도심지의 특징적 영역을 "도심지"라는 분류 항목의 교사 자료로서 설정하기만 하면, 본 기법에서는 이 교사 자료를 대상으로 군집화 기법을 적용하여 분광적으로 매우 동질성을 가지는 다수의 세부 교사 자료 집단으로 분리한다. 그리고 이들 세부 분류 항목들을 기준으로 영상 자료를 분류한 후 최종적으로 "도심지"라는 하나의 분류 항목으로 병합하여 나타냄으로써, 분석자가 설정한 분류 항목별 분광적 특징의 고유성 보유 여부와 관계없이 분석자가 의도한 분류 항목을 기준으로 한 분류 결과를 얻을 수 있도록 하였다.

본 기법의 핵심은, 기존의 방법에서 분석자가 분광 특성을 고려하여 분류 항목을 설정하고 각 항목별로 교사 자료를 공간 영역에서 분리하여 설

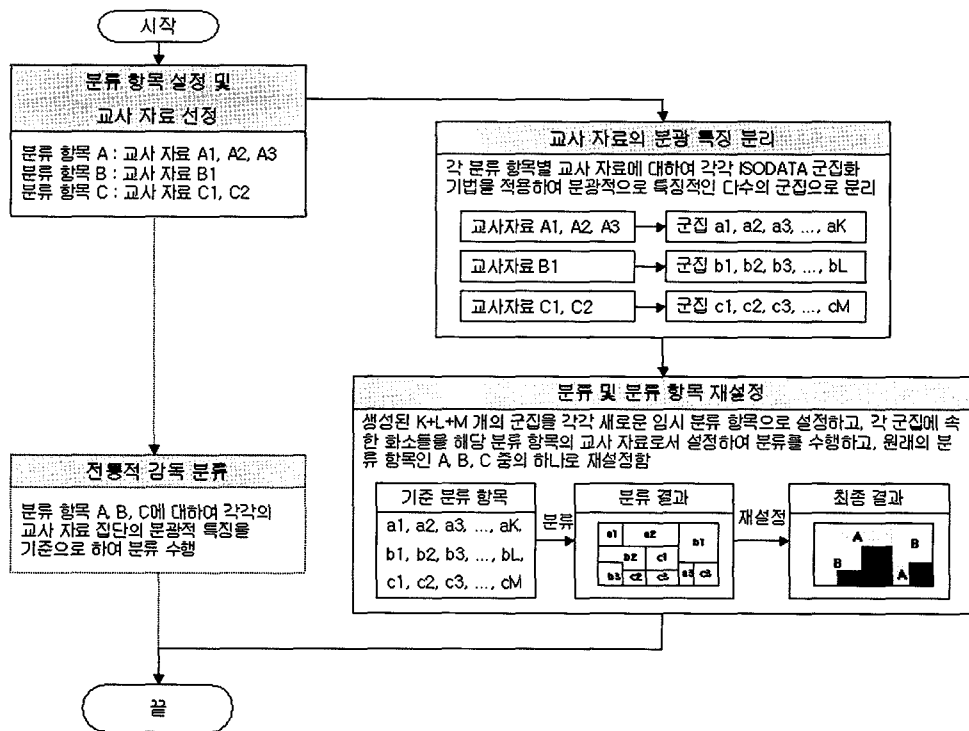


Fig. 1. Flow chart of the procedure for the proposed spectral signature separation classification technique. The dotted line represents the conventional supervised classification procedure.

정해야 하는 부담을 줄이기 위하여, 분석자가 의도하는 분류 항목을 설정하고 그 항목을 대변하는 영역에서 교사 자료를 설정하면 본 기법이 설정된 교사 자료를 분광 영역에서 다수의 교사 자료 집단으로 분리하여 분류를 시행한다는 데 있다.

본 연구에서는 교사 자료의 분광 특징 분리를 위하여 분류 항목별로 교사 자료를 군집화하는 방법을 적용하였다. Fig. 1에는 본 논문에서 제안하는 교사 자료의 특징 분리에 의한 감독 분류 기법의 적용 절차를 흐름도로서 나타냈다.

3. 시험 적용 및 고찰

본 기법은 부산 지역의 Landsat TM 영상 자료를 이용하여 시험 적용되었으며, 분류를 위하여 도심지, 경작지, 산림, 수역의 4개의 분류 항목이 설정되었다. 결과 분석을 용이하게 하기 위하여 가시영역과 근적외영역의 4개 밴드만을 이용하여

분류를 수행하였다. 영상과 분류 항목별 교사 자료가 Fig. 2의 (a)에 나타나 있다. Table 1에는 각 분류 항목별로 선정된 교사 자료의 밴드별 평균값 및 공분산 값과 함께 전체 영상에 대한 밴드별 평균값 및 공분산값을 나타냈다. Table 1을 통해서 알 수 있듯이 도심지에 대한 교사 자료는 수역에 대한 교사 자료에 비하여 매우 큰 분산값을 보인다. 도심지에 대한 교사 자료의 밴드간 공분산값은 표본수의 차이에 의하여 전체 영상에 대한 공분산값보다도 큰 값을 보이고 있다. 이는 도심지라는 분류 항목에 대한 교사 자료가 분광 공간 영역에서 매우 넓은 공간을 차지하고 있음을 의미하며, Fig. 2의 (b)에 나타낸 바와 같이 도심지의 교사 자료는 분광 공간 영역에서 산림 및 경작지의 교사 자료와 구분되기 어려운 분광 특징을 보인다. Fig. 2의 (b)는 각 분류 항목별 교사 자료의 밴드별 평균값을 중심으로 밴드별 표준편차의 2배에 해당하는 영역을 사각형으로서 나타낸 것이다.

Fig. 2의 (c)는 최소거리법(Minimum Distance

Table 1. Statistical parameters of each class before signature separation.

Class	Mean		Covariance Matrix				# of Separated Signatures
	Band 1	Band 2	Band 1	Band 2	Band 3	Band 4	
Forest	Band 1	64.78	13.52	16.18	30.85	40.97	5
	Band 2	44.26		24.47	44.27	63.24	
	Band 3	46.51			90.03	116.78	
	Band 4	58.04				233.20	
Paddy	Band 1	88.71	20.42	14.60	13.38	7.20	5
	Band 2	72.57		20.15	26.73	16.99	
	Band 3	85.73			51.55	37.77	
	Band 4	80.29				53.80	
Urban	Band 1	97.17	335.16	298.58	334.58	245.90	9
	Band 2	74.32		339.24	415.59	293.77	
	Band 3	80.06			579.34	408.46	
	Band 4	69.95				355.65	
Water	Band 1	62.92	2.63	0.75	0.40	0.09	1
	Band 2	36.52		1.79	0.50	0.16	
	Band 3	26.25			1.84	0.08	
	Band 4	15.34				0.55	
Entire Image	Band 1	74.23	163.03	179.84	249.75	147.88	
	Band 2	53.89		217.46	312.78	204.45	
	Band 3	57.43			480.35	334.65	
	Band 4	63.09				405.01	

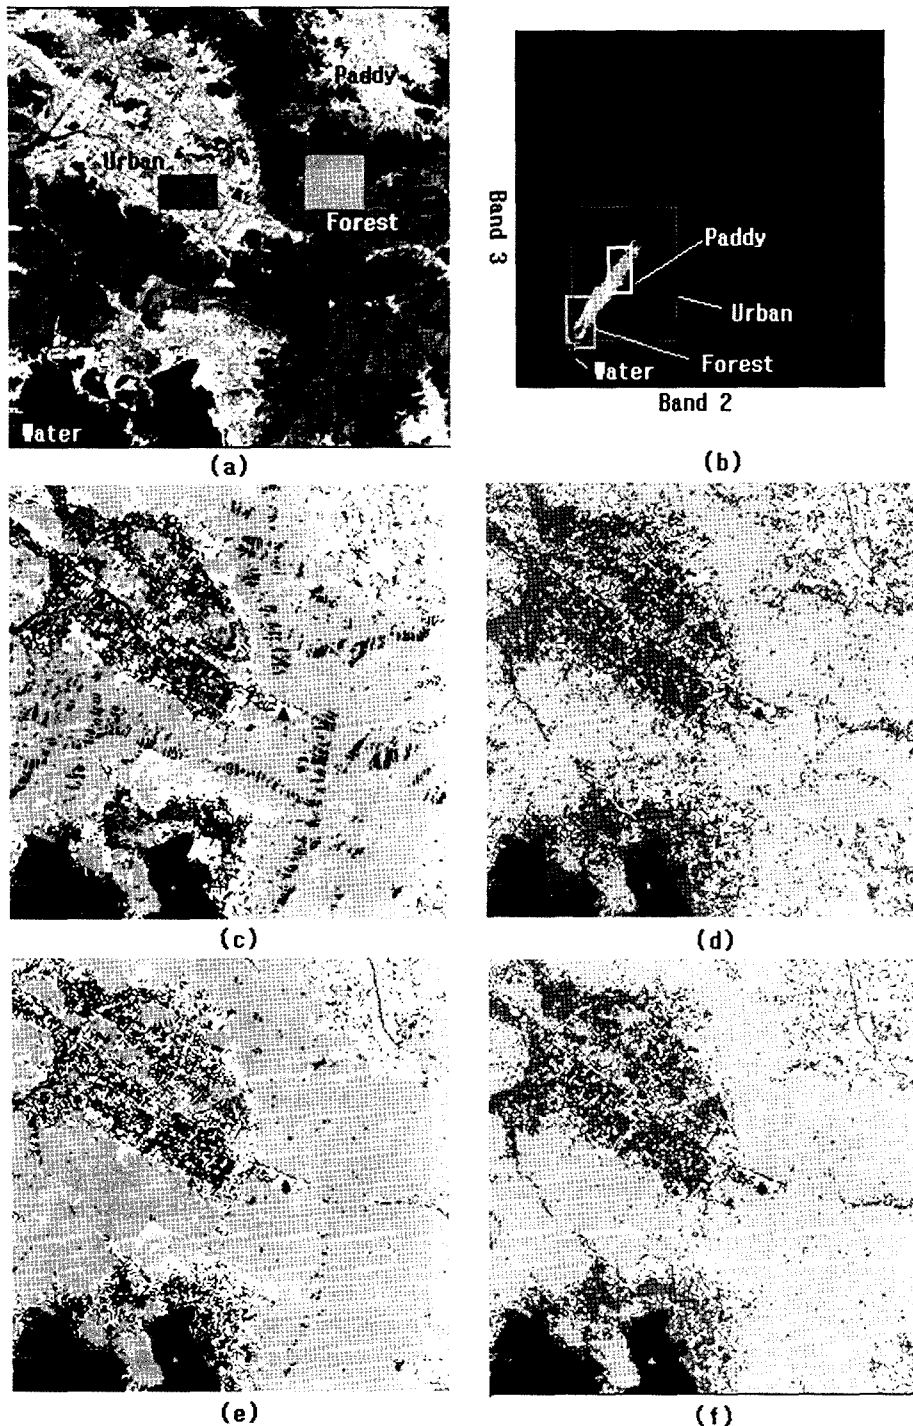


Fig. 2. (a) Sample Landsat TM image and ROIs. (b) Distribution of training data set for each class on scattergram of band 2 and band 3. (c) Classified result by conventional Minimum Distance method. (d) Classified result by conventional Maximum Likelihood method. (e) Classified result by proposed signature separated Minimum Distance method. (f) Classified result by proposed signature separated Maximum Likelihood method.

Table 2. Classification error matrix by conventional Minimum Distance and Maximum Likelihood classification techniques.

Minimum Distance					Maximum Likelihood					
	Water	Paddy	Urban	Forest		Water	Paddy	Urban	Forest	
Water	2470	0	0	430	2900	Water	2460	0	0	2460
Paddy	0	687	508	92	1287	Paddy	0	691	258	951
Urban	0	120	1668	0	1788	Urban	8	121	2212	2435
Forest	0	5	294	3565	3864	Forest	2	0	3991	3993
	2470	812	2470	4087			2470	812	2470	4087

Classification)에 의한 분류 결과로서, 산림 영역의 많은 화소들이 수역으로 분류되고 있음을 알 수 있다. Table 2에는 각각 전통적인 최소거리법과 최대우도법의 적용에 의한 분류 결과에 대한 오류 행렬(Error Matrix)을 나타냈다. 산림 영역의 많은 화소들이 수역으로 분류되고 있는 것은

Fig. 2의 (b)에서 보듯이 수역과 산림에 대한 교사 자료의 중심간 분광 거리가 비교적 가까우며 동시에 산림에 대한 교사 자료의 수역에 대한 교사 자료에 비하여 분광 공간 영역에서 매우 넓은 영역을 차지하고 있기 때문이다. 산림 영역의 많은 화소들이 산림에 대한 교사 자료의 중심까지보다도 수역에 대한 교사 자료의 중심까지의 거리가 더 작게 되는데, 최소거리법은 교사 자료의 분광 공간 영역에서의 분포 넓이는 고려하지 않고 그 중심까지의 분광 거리만을 기준으로 분류하므로 이와 같은 결과가 얻어지는 것은 자명하다.

한편 Fig. 2의 (d)는 최대우도법(Maximum Likelihood Classification)에 의한 분류 결과로서, 최소거리법에 비하여 상대적으로 매우 많은 화소들이 도심지로 분류되고 있으며, 특히 산림 영역에서 도심지로 분류되고 있는 화소들이 산재하고 있음을 알 수 있다. Table 2에 나타낸 최대우도법에 의한 오류 행렬을 보면, 경작지와 산림의 일부 화소들이 도심지로 분류되고 있으나, 최소거리법의 결과와 비교해서는 더 높은 분류 정확도를 보이고 있음을 알 수 있다. 최대우도법에 의한 분류 결과에 있어 산림이나 경작지 영역의 화소들이 도심지로 분류되고 있는 것은, Fig. 2의 (b)에서 보듯이 도심지 항목에 대한 교사 자료의 분광 공간 영역에서 매우 넓게 분포하고 있어 그 공분산값이 매

우 크기 때문이다.

본 고찰을 통해서, 분광 특징을 면밀히 고려하여 충분한 개수의 분류 항목을 설정하고, 분류 항목별 교사 자료가 분광적으로 독특한 특징을 보이도록 선정하지 않는 경우, 통계적 변수값들로서 분류 항목별 분광적 특징을 충분히 나타낼 수 없기 때문에 전통적인 통계적 분류 기법을 통해서 양호한 분류 결과를 얻기가 쉽지 않음을 유추할 수 있다.

이와 같은 문제에 대한 접근 방법으로서 비통계적 분류 기법으로서 인공신경망 알고리즘에 대한 많은 연구(Benediktsson *et al.*, 1990; Hepner *et al.*, 1990, Heermann and Khazenie, 1992, Foody *et al.*, 1995)가 수행된 바 있으나, 현실적으로는 분석자가 영역별 분광적 특징을 고려하여 하나의 분류 항목에 대하여 다수의 교사 자료 집단을 선정하여 각각의 교사 자료 집단을 임시 분류 항목으로 설정하여 분류한 후 분류 항목을 재구성하는 방법이 이용되고 있다. 그러나 이러한 방법은 분석자가 교사 자료를 선정하는 지역의 분광적 균질성을 일일이 검토해야하므로 많은 노력과 시간이 요구되게 된다.

본 연구를 통하여 개발된 기법에서는 분류를 시행하기 이전 단계에서 분류 항목별로 선정된 교사 자료의 분광 특징을 분리하여 분광 공간 영역에서 정규 분포의 분포 양상을 보이며, 또한 밴드별 분산값이 충분히 작은 다수의 교사 자료 집단으로 나누고, 각각의 교사 자료 집단을 기준으로 분류를 수행한다. 본 연구에서는 교사 자료의 분광 특징을 분리하기 위한 방법으로서 교사 자료를 군집화하는 방법을 적용하였으며, 군집화 기법으

Table 3. Statistical parameters of forest class's separated signatures.

Signature	Mean		Covariance Matrix			
	Band	Value	Band 1	Band 2	Band 3	Band 4
Signature 1 of Forest class	Band 1	69.54	5.62	4.57	7.04	3.30
	Band 2	51.20		7.90	10.83	5.32
	Band 3	60.86			23.65	11.41
	Band 4	75.93				26.96
Signature 2 of Forest class	Band 1	65.12	4.38	2.82	6.12	-0.53
	Band 2	45.76		4.34	7.39	0.49
	Band 3	47.32			20.92	-2.29
	Band 4	74.23				23.71
Signature 3 of Forest class	Band 1	65.99	4.69	3.23	5.49	0.01
	Band 2	45.62		5.50	6.79	1.11
	Band 3	49.10			17.52	2.38
	Band 4	60.78				16.06
Signature 4 of Forest class	Band 1	63.14	4.17	2.15	3.98	-0.67
	Band 2	41.75		3.35	4.35	0.40
	Band 3	41.59			11.57	-0.56
	Band 4	49.32				16.84
Signature 5 of Forest class	Band 1	60.58	3.52	2.07	3.46	4.19
	Band 2	38.00		3.56	4.33	5.85
	Band 3	35.15			10.25	9.96
	Band 4	36.50				23.77

로서는 ISODATA 알고리즘을 적용하였다. Table 1의 가장 오른쪽 열에는 각각의 분류 항목별로 생성된 군집의 개수를 나타냈다. 산림 항목에 대한 교사 자료는 총 5개의 군집으로 나누어졌으며, 경작지의 경우 5개, 그리고 도심지 항목의 교사 자료는 9개의 군집으로 나누어졌다. 수역에 대한 교사 자료는 그 밴드별 분산값이 매우 작기 때문에 1개의 군집으로 그대로 사용되었다.

따라서 분석자에 의하여 4개의 분류 항목이 설정되었지만, 본 기법에서는 내부적으로 총 20개의 항목을 기준으로 분류가 수행되게 되며, 분류 후에 다시 도심지, 산림, 수역 및 경작지의 당초 설정되었던 4개의 분류 항목으로 재구성되게 된다.

Table 3은 산림 항목의 교사 자료의 분광 특징 분리에 의하여 나누어진 5개 군집의 밴드별 평균값과 밴드간 공분산값을 보여주고 있다. Table 1에 나타냈던 분류 항목별 교사 자료의 통계값들에서 산림 항목에 대한 밴드 4의 교사 자료에 대한 분산값이 233.2였음에 비하여, 산림 항목에 대한 교사 자료의 특징 분리 결과에서는 밴드 4의 교사

자료에 대한 가장 큰 분산값을 보이는 군집에서 26.96의 분산값을 보이고 있다. 즉, 산림 항목에 대한 교사 자료들이 작은 분산값을 가지며 분광 공간 영역에서 정규 분포 형태의 분포를 보이는 5개의 작은 교사 자료 집단으로 분리되었다.

Fig. 2의 (e)는 본 기법에서 제안하고 있는 교사 자료의 분광 특징 분리 기법을 적용하여 최소거리법으로서 분류한 결과를 보여주고 있다. Fig. 2의 (c)에 나타낸 전통적인 최소거리법에 의한 분류 결과와 비교하여 산림 지역에서 수역으로 오분류되던 현상이 매우 감소하였으며, 우상단의 도로의 경우 매우 향상된 분류 결과를 보이고 있음을 알 수 있다.

Fig. 2의 (f)는 본 기법에서 제안하고 있는 교사 자료의 분광 특징 분리 기법을 적용하여 최대우도법으로서 분류한 결과로서, Fig. 2의 (d)에 나타냈던 전통적인 최대우도법에 의한 분류 결과와 비교하여 도심지로 오분류되었던 산림 및 경작지 지역의 산재하고 있는 많은 화소들이 각각 산림과 경작지로 분류되고 있음을 알 수 있다.

4. 결 론

본 연구에서는 공간 영상 자료의 감독 분류에 있어, 분석자에 의하여 선정된 분류 항목별 교사 자료를 분광 특징별로 다수의 군집으로 나누고, 각각의 군집을 새로운 임시 분류 항목에 대한 교사 자료로서 설정하고 감독 분류를 수행함으로써 분류 성능을 향상시킬 수 있는 기법을 제안하였다.

본 기법의 적용성을 고찰하기 위하여 부산 지역에 대한 Landsat TM 영상 자료를 이용하여 시험하였으며, 시험 적용 결과, 본 기법은 분류 항목별 교사 자료의 분광적인 특성과 관계없이 기존의 감독 분류에 의한 분류 결과보다는 양호한 분류 결과를 얻을 수 있는 것으로 판단되어, 감독 분류를 위한 분류 항목 선정 및 항목별 교사 자료의 선택에 있어 분석자의 노력을 최소화시켜줄 수 있을 것으로 기대된다.

본 기법에서는 각 분류 항목별 교사 자료의 분광 특징을 분리하기 위한 군집화 기법의 적용 과정에서 최대 군집 개수 등 몇 가지 변수들에 대한 입력이 요구되고 있으나, 교사 자료의 밴드별 분산값을 이용함으로써 특징 분리를 위한 변수가 자동 설정될 수 있는 기법에 대한 연구가 현재 진행되고 있다.

한편, 본 기법의 적용시, 분류 과정에서 분광 특징을 비교해야할 분류 항목이 증가됨에 따라 분류 속도가 저하됨을 알 수 있었으나, 본 논문에서는 기법의 원리에 대한 제안과 시험 적용 결과에 대한 정성적인 고찰만이 이루어졌으며, 추후 교사 자료의 특징 분리를 위한 각종 요구 변수의 최적 자동 설정 기법이 추가된 후에는 분류 정확도 및 성능에 대한 정량적 비교 분석이 행하여질 예정이다.

참고문헌

전형섭, 2001. 원격탐사 데이터의 분류 정확도 향상에 관한 연구, 공학박사학위논문, 전북대학교.

Baatz, M. and A. Schape, 1999. Object-oriented and multi-scale image analysis in semantic networks. *Proc. of 2nd International Symposium on Operationalization of Remote Sensing*, ITC.

Benediktsson, J. A., P. H. Swain and O. K. Erosy, 1990. Neural network approaches versus statistical methods in classification of multisource remote sensing, *IEEE Trans. Geosci. Remote Sensing*, 28: 540-551.

Civco, D. L., 1993. Artificial neural networks for land-cover classification and mapping, *Int. J. GIS*, 7: 173-186.

Foody, G. M., M. B. McCulloch and W. B. Yates, 1995. Classification of remotely sensed data by artificial neural network : Issues related to training data characteristics, *Photo. Eng. and Remote Sensing*, 61: 391-401.

Heermann, P. D. and N. Khazenie, 1992. Classification of multispectral remote sensing data using a back-propagation neural network, *IEEE Trans. Geosci. Remote Sensing*, 30: 81-88.

Hepner, G. F., T. Logan, N. Ritter and N. Bryant, 1990. Artificial neural network classification using minimal training set : comparison to conventional supervised classification, *Photo. Eng. and Remote Sensing*, 48:123-130.

Lee, I. S., D. H. Shin, S. M. Ahn, K. S. Lee and S. W. Jeon, 2002. Comparison of visual interpretation and image classification of satellite data. *Korean Journal of Remote Sensing*, 18(3): 163-170.

Lee, S. H. and K. E. Kim, 2002. Study on the effect of discrepancy of training sample population in neural network classification, *Korean Journal of Remote Sensing*, 18(3): 155-162.

Maxwell, E. L., 1976. Multivariate system analysis of multispectral imagery, *Photo. Eng. and Remote Sensing*, 42: 1173-1186.