

IKONOS 영상을 이용한 토지피복분류 기법 분석

An Analysis of Land Cover Classification Methods Using IKONOS Satellite Image

강남이* · 박정기** · 조기성*** · 유 연****

Kang, Nam Yi · Pak, Jung Gi · Cho, Gi Sung · Yeon, Yeon

要 旨

최근 고해상도 위성영상은 자연자원이나 환경 관리에 필요로 하는 토지 피복 및 이용 현황자료 등에 유용하게 사용되고 있는 실정이다. 이에 따라 고액의 투자가 필요로 하는 위성영상의 효율성을 높이기 위하여 영상자료의 분석과정이 중요해지고 있다. 따라서 본 연구에서는 전처리 과정 중 연구대상에 대한 통계값에 대한 계산 및 분석을 수행하였으며, 전통적인 분류 기법인 최대우도 분류 외에도 인공신경망 분류와 SVM 분류에 대하여 설명하고 고해상도 위성영상인 IKONOS영상에 각 분류기법을 적용하여 토지피복분류를 하였으며, 각각의 결과를 오차 행렬을 통해 정확도 분석을 수행하였다. 그 결과 다른 분류 기법에 비해 Support Vector Machines(SVM) 분류 기법이 전체 정확도가 약 86%정도로 가장 우위의 결과물을 도출하였다.

핵심용어 : IKONOS 위성영상, 연구대상, 토지피복분류기법, 오차 행렬

Abstract

Recently the high-resolution satellite images are helpfully using the land cover, status data for the natural resources or environment management. The effective satellite analysis process for these satellite images that require high investment can be increase the effectiveness has become increasingly important. In this Study, the statistical value of the training data is calculated and analyzed during the preprocessing. Also, that is explained about the maximum likelihood classification of traditional classification method, artificial neural network (ANN) classification method and Support Vector Machines(SVM) classification method and then the IKONOS high-resolution satellite imagery was produced the land cover map using each classification method. Each result data had to analyze the accuracy through the error matrix. The results of this study prove that SVM classification method can be good alternative of the total accuracy of about 86% than other classification method.

Keywords : IKONOS Satellite Image, Training Data, Land Cover Classification Method, Error Matrix

1. 서 론

최근 원격탐측기술은 기술발달과 고해상도 영상의 수집이 가능해짐에 따라 국토관리 및 타 분야에 요구되는 정밀한 자료를 제공하고 있다. 또한 원격탐측 영상에 대한 기술적인 연구가 꾸준히 진행되어지고 있는 추세로 원격탐측의 잠재적인 성과물을 기대해 볼 때 고해상도 영상의 활용도는 계속해서 상승될 것이다. 현재 정부에서는 중요한 자료원이 된 고해상도 영상의 중요성을 인식하고 국가적인 투자가 적극적으로 이루어지

고 있다(과학기술부, 2010). 주요 자원인 고해상도 영상자료의 실용화를 위해서는 자료의 분석이 정확히 이루어져야 하지만 현재까지 연구결과에는 정확하고 자세한 정보를 추출하기 어려운 실정이다. 정확한 자료 분석을 위해 높은 공간분광 해상도에 관한 기술 및 분류 알고리즘, 패턴인식에 관한 연구가 활발하게 진행되어지고 있다.

일반적으로 원격탐측에 이용되는 자료의 특성은 각각의 물체의 고유한 특징인 분광특성을 가지고 있다. 자료 분석은 고유한 분광특성에 따라 지상 물체에 대한

2012년 7월 31일 접수, 2012년 8월 30일 채택

* 정희원 · 전북대학교 토목공학과 석사과정(namy186@jbnu.ac.kr)

** 정희원 · 전북대학교 토목공학과학과 박사과정(road001@chol.co.kr)

*** 정희원 · 전북대학교 토목공학과 교수(gscho@jbnu.ac.kr)

**** 교신저자 · 정희원 · 석곡관측과학기술연구원 선임연구원, 공학박사(Yeon.yeu@gmail.com)

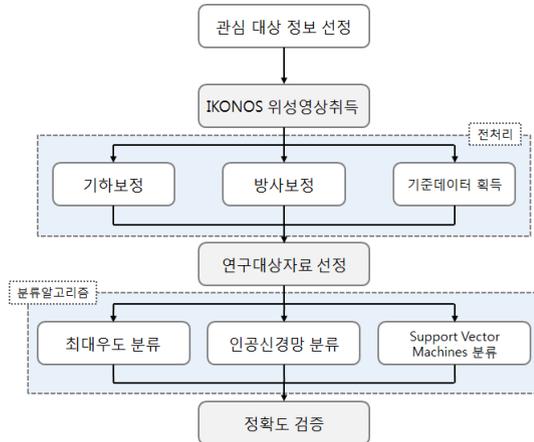


Figure 1. The Flowchart of the study

다양한 정보를 얻어내는 것이다. 자료의 종류 및 분광 특성, 부가 정보 등의 세부사항이 분석 정확도에 영향을 주므로 분석자는 세부사항에 알맞은 분류 알고리즘을 선택하고 군집화하기 위하여 복잡한 결정을 내려야 한다.

전통적인 토지피복 분류 방식으로는 통계적인 알고리즘인 무감독 분류 및 감독 분류, 패턴인식 기법을 적용하는 방법 등이 있다(Richards, 1993). 영상 내에서 연구대상자료를 선정하여 분석하고 유사한 분포특성을 갖는 군집을 설정하는 과정이 감독분류이다(Pierce L., 1998). 각 훈련 자료의 선택은 분류 정확도에 큰 영향을 준다(전영준, 2003). 분류 알고리즘의 발달로 인공신경망 알고리즘, 의사결정 트리 알고리즘, 퍼지 알고리즘 등 다양한 분류 알고리즘이 개발 되었고, 알고리즘은 자료의 종류 및 특성에 따른 서로 다른 결과물을 나타내고 있다. 패턴인식 분야의 분류 알고리즘인 인공신경망과 Support Vector Machines(SVM) 알고리즘은 안정적인 분류 정확도를 나타내고 있다(김중호, 2004).

본 연구에서는 IKONOS 위성영상을 과거 높은 분류 정확도를 나타낸 최대우도법, 인공신경망 알고리즘, Support Vector Machines(SVM) 알고리즘을 적용하여 연구대상을 분석하고 대상지역의 토지피복분류 결과 및 연구대상지역의 현장조사 표준점 추출을 이용한 Error Matrix를 작성하여 분류정확도를 검토하고자 한다. Figure 1은 연구흐름도를 나타낸다.

2. 감독 분류 알고리즘

2.1 영상분류

원격탐측에서 중요한 분석기법으로서 비슷한 분광

특성을 가지는 영상소들을 구분하고자 하는 관심대상으로 선정하여 결과물을 만드는 과정이 영상분류이다. 분류 결과물은 원격탐측 자료의 다양한 특징 중에서 분광특성에 따라 달라지는 각각의 밴드별 영상소의 고유값인 DN(Digital Number)을 기반으로 영상분류과정을 걸쳐 원하는 목적에 맞게 구성된 분류항목 군집으로 구성된 일종의 주제도이다.

그러나 실제 영상분류 작업을 수행하여 얻은 결과물을 살펴보면 각각의 분류 단계의 선정 기준 및 선택에 따라 결과물이 판이하게 달라진다. 이러한 근본적인 문제점은 실제의 대상물의 분광특성을 영상자료의 DN값의 정보와 일치시키는 작업이 쉽지 않기 때문이다. 이는 유사한 분광군집 안에 서로 다른 정보 군집을 포함하는 경우뿐만 아니라 특정 분광 집단이 정보 군집과 일치하지 않는 경우도 발생한다. 따라서 분류 시 분광군집과 정보 군집을 대응시키는 결정은 분석 단계에서 수행하여야 한다.

2.2 분류 알고리즘

2.2.1 최대우도 분류

분류법의 가장 보편적인 방법인 최대우도 분류는 연구대상자료의 분포와 확률에 의존한다. 최대우도 분류의 주 가정은 데이터의 히스토그램이 정규분포라는 것으로 임의의 영상소가 정해진 분류항목에 포함될 개연성을 기초한 방법이다. 그러므로 정규분포의 가정에 따르지 않을 경우 적용이 어려우며 자료 분석을 위해서는 주의가 요구된다.

다중분광 데이터의 경우의 n 차원 다변량 정규확률밀도함수 $p(x)$ 이다. 평균 벡터 U 와 공분산 매트릭스 Σ 는 알 수 없으므로 연구대상자료에서 추정되어 사용된다.

$$p(x) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp\left[-\frac{1}{2}(X - U_i)^T \Sigma_i^{-1} (X - U_i)\right]$$

2.2.2 인공신경망

인간 두뇌의 생물학적 신경계인 뉴런의 활동으로부터 착안하여 공학적으로 이용한 분야로서 일반적인 분류 기법들과는 다르게 인공신경망분류는 일정 목표값을 두고 목표치에 도달할 때까지 반복하는 과정을 거친다. 인공신경망의 처리요소는 단계별로 수개내지 수십 개가 될 수 있는 노드를 가지고 있다.

기본적인 인공신경망의 경우 각각의 노드는 다른 노드로부터의 출력(O)과 연결사이의 연결강도(W)를 곱한 후 모두 합한 값에 활성화 함수($f(x)$)를 적용하여 출력을 한다. 따라서 인공신경망 모형에서는 어떠한 활성

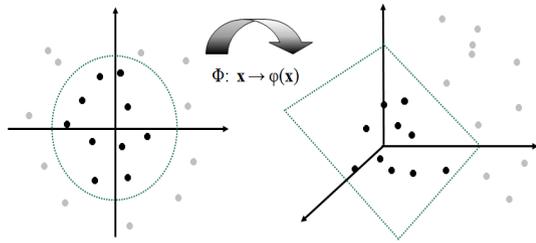


Figure 2. SVM higher-dimensional feature space

화 함수를 선택하느냐에 따라 뉴런의 출력방식이 달라진다.

$$NET = O_1 W_1 + O_2 W_2 + \dots + O_n W_n = \sum_{i=1}^n O_i W_i$$

$$OUT = f(NET) = f\left(\sum_{i=1}^n O_i W_i\right)$$

2.2.3 Support Vector Machines

SVM은 간단한 알고리즘을 통해 작업을 성공적으로 수행하는데 영향을 미치는 요소들을 규명할 수 있다. 기존의 경험적 에러를 최소화 시킨 다중신경망 방법과 비교하여 필요한 파라미터의 일부가 자동적으로 결정하여 구조적 오류를 최소화시킨다. SVM 방법은 클래스 간의 거리를 최대로 분리하는 초평면(hyperplane)을 찾기 위해 데이터를 고차원으로 변환시킨다. 또한 클래스 간의 초평면과 가장 가까운 지점의 데이터를 Support Vector하며, Support Vector와 초평면 사이의 거리를 마진(Margin)이라 한다. 이러한 마진이 최대화 되는 초평면을 찾는 것이 SVM의 기본 원리이다.

SVM 방법의 적용 시 많은 자료와 군집의 분류로 해결이 어려운 경우 초평면을 얻기 위해 커널함수(Kernel function)을 사용하여 특정 공간에서 선형분리를 수행할 수 있다. 대표적인 커널함수 종류에는 Polynomial, RBF, Perceptrori 등이 있다. 본 연구에서는 기본적인 Polynomial 커널 함수를 적용하였다.

3. 연구대상지역 선정 및 분석

3.1 연구대상지역 선정

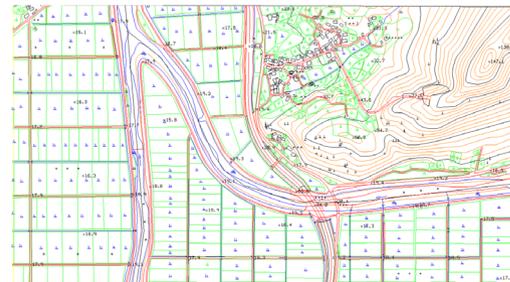
3.1.1 연구대상지역

본 연구의 연구대상지역은 2007년 3월 촬영된 전라북도 고창군 일대로 하갑리 독곡마을로 좌상단(35°26'59.27", 126°37'29.84"), 우하단(35°26'31.32", 126°38'34.11")이며, 면적은 약 1.44km²이다. 이 연구대상지역은 농경지와 하천뿐만 아니라 내대지 및 주택지 등 다양한 군집 정보를 가지고 있어 다양한 분류가 가능한 지역을 선정하였다. Figure 3(a) 연구대상지역의 천연색 영상이며, Figure 3(b)은 수치지도이다.

사용된 영상은 IKONOS 위성의 자료로 1m급 전정색 영상을 가지고 있으며 다중분광 영상의 경우 4m급 공간해상도를 가진다. IKONOS 영상의 경우는 총 4개의 밴드(Bule, Green, Red, Near IR)와 1개의 전정색 Pan 영상을 가지고 있다. IKONOS의 공급사인 Space



(a) Natural color image



(b) Digital Map

Figure 3. The study area

Table 1. The training data selection and number of pixels

분류항목	논	초지	하천	주거지	내대지	교통시설	기타시설	임목지
훈련 집단								
픽셀수	678	379	284	131	390	101	121	602

Imaging사는 전정색 영상과 다중분광영상을 Projective 알고리즘으로 해상도 융합과정을 거쳐서 1m 공상 해상도와 3개의 분광밴드를 갖는 고분해 영상을 공급한다. 본 논문에서는 2003년 4월 22일에 촬영된 영상을 사용하였다. 또한 전처리 과정인 기하보정을 하기 위한 지상기준점 취득을 위하여 국토지리정보원에서 제작한 1:5000 수치지형도의 도엽번호 35611026에서 대상지역 부분을 잘라내어 이용하였다.

3.1.2 자료 전처리

영상분류 작업에 앞서 왜곡이 있는 영상을 제거하는 보정작업이 필요하다. 대표적으로 복사량의 왜곡을 제거하는 방사보정과 기하학적 왜곡을 제거하는 기하보정이 있다. 영상자체의 전처리 과정 후에 위성영상의 밴드들 중에서 분류 목적에 맞게 분류 계급간의 통계적 거리가 계산되는 과정에서 사용될 밴드 수와 조합을 선정하여야 한다.

본 연구에서는 사용되어진 IKONOS 영상이 RPC (Rational Polynomial Coefficients)를 제공하지 않아 수치지도의 도면을 이용하여 대상물의 좌표를 얻는 방법 및 GPS를 이용한 현장조사를 실시하여 지상기준점을 취득하였다. 획득된 지상기준점을 이용하여 ENVI 4.7의 보정 모듈 중 유리수학 모듈을 사용하여 보정을 실시하였다.

영상의 전처리와 밴드 선정이 완료되면 훈련지역의 선정이 필요하다. 연구대상지역은 분류하고자 하는 군집들의 대표적인 부분을 참조 자료를 이용하여 선정하고 계산되는 통계자료를 참조하여 채택한다. 본 연구에서 선정한 정보군집은 국토해양부의 토지 이용현황 분

류를 이용하여 총 8종류로 선정하였으며 Table 1, Table 2는 연구대상지역에서 선정한 연구대상지역 자료의 지점과 선택된영상소 및 각각의 기본적인 통계값을 나타낸다. 연구대상자료의 영상소의 수가 많다는 것이 평균과 분산의 정확도가 높아지는 것은 아니므로 대체적으로 사용밴드의 수의 10~100배의 영상소가 되도록 하는 것이 좋다. 통계값에 따른 결과의 확인으로 연구대상자료의 선택 시 오류가 있음이 확인되었다.

3.2 자료 분석

3.2.1 토지피복분류 결과

전처리 과정을 통해 얻은 IKONOS 위성영상과 참조 자료 등을 통해 얻어진 영상대상자료를 통하여 분류 알고리즘인 최대우도 분류(MLC), 인공신경망 분류(ANN), SVM 분류를 수행하여 얻은 결과는 다음 Table 3과 같다. IKONOS 영상의 경우 다중분광영상의 경우 4m의 공간해상도를 가지므로 이를 통해 분류 지역의 면적을 산출할 수 있었다. 동일한 분류 항목임에도 불구하고 논외의 경우와 같이 약 410000 영상소, 810000 영상소, 770000 영상소와 같이 정량적인 차이를 보이며, 이러한 결과는 다른 분류항목에서도 나타나고 있다. 이는 분류 알고리즘에 따라 분류 결과물이 달라짐을 나타낸다.

이와 같이 각 기법별 토지피복분류 결과를 정량적으로 나타내어 전체적으로 비교하여 보면, 논외의 경우와 같이 하천지역 역시 면적의 차이가 크게 발생하였으며, 주거지 및 기타시설, 나대지는 비슷한 결과를 나타냈다.

정성적 분류와 비교하였을 때 주거지의 경우 현장답사를 통해서 건물의 특성이 농촌지역의 많이 이용되는

Table 2. The training data statistics of each classification method

	임목지			기타시설			초지			주거지		
	Band1	Band2	Band3									
평균	31.02	30.77	37.396	132.36	160.45	186.04	77.351	91.348	83.053	84.58	141.35	250.64
분산	185.25	231.9	311.89	549	696.3	969.82	277.82	421.62	490.55	1037.5	1938.4	77.493
표준편차	13.611	15.228	17.66	23.431	26.387	31.142	16.668	20.533	22.148	32.21	44.027	8.803
최소값	0	0	0	93	119	137	21	16	5	14	70	210
최대값	75	81	96	190	227	255	133	148	146	140	236	255
중간값	37.5	40.5	48	141.5	173	196	77	82	75.5	77.00	153	232.5
	논			하천			나대지			교통시설		
	Band1	Band2	Band3									
평균	71.286	69.923	63.919	28.651	29.947	29.134	230.7	228.87	232.14	171.59	185.35	201.4
분산	1665.5	1501.1	1065.5	289.43	114.09	105.25	861.88	833.39	555.58	279.54	437.07	551.42
표준편차	40.81	38.744	32.642	17.013	10.681	10.259	29.358	28.869	23.571	16.72	20.906	23.482
최소값	26	17	10	5	7	0	159	165	175	121	114	118
최대값	211	193	164	74	57	61	255	255	255	204	233	255
중간값	118.5	105	87	39.5	32	30.5	207	210	215	162	173.5	186.5

재질과 색이였음을 확인하여 선정하였다. 하지만 일부 건물의 경우 콘크리트 등 다른 재질의 형태로 구성되었으며 이로 인해 분류에 오류가 있었다. 대상지역이 도심지 및 기타 지역으로 변경될 경우 주거지의 연구대상 자료 선정의 고려가 필요하다.

Figure 5와 같이 토지피복분류 결과를 영상자체로 확인하면, 농촌지역인 대상지역의 특성상 계절의 영향을 많이 받는 농경지의 분포가 넓고, 하천과 산림 역시 환경적 요인이 큰 영향을 미치므로 분류 결과에 일부분 환경적 요인으로 인한 오분류가 발생하였다. MLC의 경우는 연구대상자료가 정규 확률분포를 따른다는 가정에서 분류를 하므로 오류가 발생한 분류 군집에 대한 연구대상자료의 검토가 필요하다. ANN의 경우 역시 분광정보의 유사성으로 하천과 초지의 오분류가 발생하였지만 그 외의 분류항목에 대해선 양호한 결과물이 나타났다. SVM 분류 결과인 Figure 5(c)를 보면 다른 결과물과 비교하여 정성적 분석결과가 상대적으로 우위에 있음을 알 수 있었지만 SVM 분류 역시 분광정보의 유사성으로 인한 오분류가 발생하였다. 이는 추후 분광정보에 관한 추가적인 분석이 필요하다고 여겨진다.

Table 3. The percentage of class

분류 항목	면적(Pixel)		
	MLC	ANN	SVM
논	416,965	817,012	778,191
초지	253,251	103,609	147,380
하천	329,681	0	81,140
주거지	2,696	4,766	1,827
나대지	96,645	97,390	103,545
교통시설	63,696	21,083	37,580
기타시설	15,594	18,711	16,195
임목지	261,472	377,429	274,142

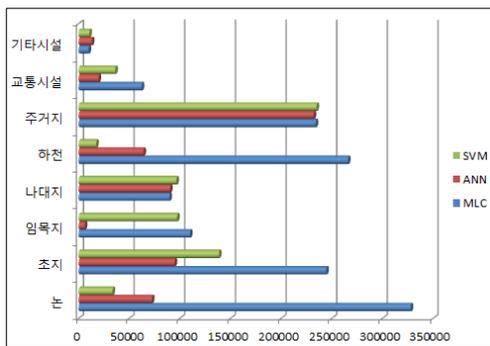
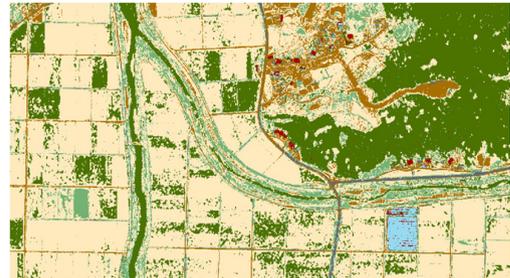


Figure 4. Comparison of area each class



(a) MLC



(b) ANN



(c) SVM



Figure 5. Land cover map

3.2.2 정확도 분석

분류된 자료의 질을 평가하기 위해서는 분류정확도 평가가 필수적이다. 위성영상을 분류결과물은 연구대상자료 선택의 부정확성, 군집간의 분광특성 중복 등으로 인한 오류를 내재하고 있어 이를 정량적으로 분석하여야만 결과물의 응용 가능성을 판단할 수 있다. 따라서 분류의 정확도에 관한 정량적인 분석 방법으로 분류 오차표(Error Matrix)를 많이 사용하고 있다. 이는 분석된 분류결과와 참고자료를 바탕으로 해당란에 수치를 입력하는 도표를 의미한다. 일반적으로 대상지역의 전체에 대한 참고 자료가 필요하지만 본 연구에서는 표본 추출법을 통하여 지점을 선정 후 각 지점의 자료를 취득하여 평가를 수행 하였다. 추후 일반적인 참고 자료를 통한 실제 토지피복도와 분류기법에 따른 토지피복

Table 4. The result of each classification method

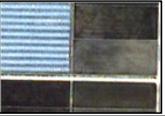
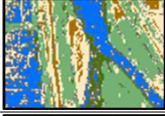
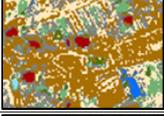
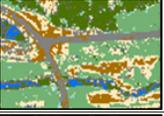
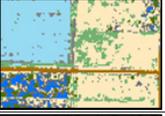
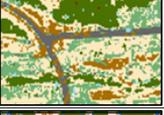
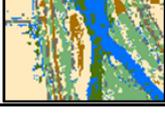
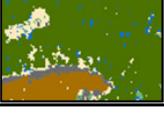
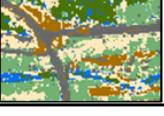
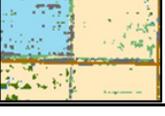
	하천 및 농경지	나대지 및 주거지역	임야	도로 및 초지	기타 및 농경지
원본					
MLC					
ANN					
SVM					

Table 5. The accuracy through the error matrix

분류	정확도 (%)	분류항목								전체 정확도 (%)
		논	주거지	초지	임야	하천	기타	도로	나대지	
MLC	사용자	48	29	51	77	2	96	76	84	47
	생산자	32	6	66	80	4.20	100.0	95	79	
ANN	사용자	90	86	59	53	0	96	95	93	78
	생산자	83	84	43	91	0	99.9	74	61	
SVM	사용자	92	81	76	86	0	98	61	90	86
	생산자	90	10	86	83	12	97.8	100	88	

을 비교한 정확도 비교 검증이 필요로 한다. Table 5는 각 기법별 오차분류 분석 후 나온 정확도를 나타낸다. 생산자 정확도란 분류 연구자가 주어진 기준 내에서 분류가 얼마나 정확하게 이루어졌는지를 판단할 때 사용되며 사용자 정확도는 영상에서 분류된 항목이 실제로 어떻게 표현되고 있는가를 판단할 때 사용되어진다.

SVM과 ANN의 논 지역 분류 결과 정확도가 90%정도로 높은 정확도를 보였으며 하천 및 초지, 임목지의 경우 연구대상자료의 분광 특성의 유사성을 세밀하게 고려하지 못하여 발생된 오분류가 많은 것으로 사료되며 ANN의 경우는 분류 적용과정에서 활성화함수의 사용이 적절하지 않았던 부분이 있었다고 보여진다. 전체적인 정확도를 보면 MLC에 비해 ANN, SVM이 높은 정확도를 나타냈으며 SVM의 경우 다른 2가지 기법에 비해 86%정도의 정확도를 나타내는 것으로 확인하였다.

4. 결론

본 연구는 고해상도 위성인 IKONOS 위성영상을 최대우도분류, 인공신경망(ANN)분류, Support Vector Machines(SVM)분류를 적용하여 분류 결과를 비교분석한 결론은 다음과 같다.

분류알고리즘 적용결과를 각 분류항목별 면적으로 비교하였다. ANN 기법과 SVM 기법의 정확도는 전통적 분류기법인 최대우도법보다 우수하였으며 이중에서 SVM 기법의 경우 78%의 정확도를 보인 ANN 기법에 비해 86%의 정확도로 가장 우위의 결과를 나타냈다.

또한 연구대상자료의 통계치 분석 결과 각 분류항목별로 오류가 있음이 확인되었으며, 일부 훈련 자료 항목은 정규분포를 이루고 있지 않아서 최대우도 분류법에 적용하기에는 적절하지 못했던 것으로 파악되었다. 차후 각 연구대상자료의 분석을 통하여 달라지는 분류 결과물의 정확도를 확인하여야 할 것으로 보인다.

또한 영상분류의 여러 기법을 통해 높은 분류 정확도를 가진 결과물을 도출하기 위해서는 차후에 영상자료의 특성뿐만 아니라 환경적 요소 및 분광 정보의 유사성 등 다양한 조건을 고려한 방법에 관한 연구가 필요하다고 여겨진다.

참고문헌

1. Web., 2011, 국가 GIS 교육센터, <http://www.e-gis.go.kr>
2. 과학기술부, 2010, 국가과학기술지식정보서비스.
3. 일본 리모트센싱 연구회, 1998, 원격탐사개론.
4. 김종호, 2004, SVM을 이용한 객체영상의 계층적 분류, 석사학위논문, 인하대학교.
5. 노영희, 2009, 공간해상도와 분광해상도의 선택적 반영이 가능한 웨이블릿 기반 영상융합 기법 연구, 석사학위논문, 성신여자대학교.
6. 사공호상, 임정호 2002, IKONOS 위성영상을 이용한 토지이용 현황 분석에 관한 연구, 한국 지리정보 추계 학술대회 발표논문집, 한국지리정보학회, pp. 35-43.
7. 양옥진, 2001, 인공신경망의 알고리즘에 의한 토지적합성 분석, 석사학위논문, 조선대학교.
8. 에르덴솜베슬드, 2012, Landsat 위성영상을 이용한 몽골 Туv지역 토지피복변화, 석사학위논문, 전북대학교.
9. 유성근, 1999, 유전자 알고리즘을 이용한 원격탐사자료의 감독분류기법 연구, 석사학위논문, 전북대학교.
10. 전영준, 김진일 2003, IKONOS 위성영상의 토지피복 분석기법, 산업기술연구지 제 17권, pp. 135-144.
11. 전영준, 김진일 2003, 고해상도 위성영상을 위한 감독분류시스템, 한국정보과학회, Vol 9, No3, pp. 301-310.
12. Carpenter, G.A., Gajja, M.N., Gopal, S., Woodcock, C.E., 1997, ART neural networks for remote sensing: vegetation classification from Landsat TM and terrain data, *Geoscience and Remote Sensing, IEEE*, vol 35, No2, pp. 308-325.
13. Davis, C.H., Xiangyun Wang, 2002, Urban land cover classification from high resolution multi-spectral IKONOS imagery, *Geoscience and Remote Sensing Symposium, 2002. IGARSS, IEEE*, Vol 2, pp.1204-1206.
14. Han, J., Lee, S., Chi, K., Ryu, K., 2002, Comparison of neuro-fuzzy, neural network, and maximum likelihood classifiers for land cover classification using IKONOS multispectral data, *Geoscience and Remote Sensing Symposium, IEEE*, Vol 9, pp. 3471-3473.
15. Huang, C., Davis, L.S., Townshend, J.R.G., 2002, An assessment of support vector machines for land cover classification, *Int J Remote sensing*, vol23, No4, pp. 725-749.
16. Pierce L., Samples G., Dobson M.C. and Ulaby, F., 1998, An automated unsupervised/supervised classification methodology, *Geoscience and Remote Sensing Symposium Proceedings, IEEE*, Vol. 4, pp. 1781-1783.
17. Richards, J.A., 1993, *Introduction to remote sensing digital image analysis*, Springer-Verlag, Berlin.
18. Sugumaran, R., Pavuluri, M.K., Zerr, D., 2003, The Use of High-Resolution Imagery for Identification of Urban Climax Forest Species Using Traditional and Rule-Based Classification Approach and Rule-based Classification Approach, *Geoscience and Remote Sensing, IEEE*, Vol 41, No 9, pp. 1933-1939.