

칼라 및 질감 속성 벡터를 이용한 위성영상의 분류

곽장호* · 김준철** · 이준환***

정보통신부 전파연구소*, 서남대학교 전기전자공학과**, 전북대학교 전자공학과***

Satellite Image Classification Based on Color and Texture Feature Vectors

Jang-Ho Kwak*, Joon-Cheol Kim**, and Joon-Whoan Lee***

Radio Research Laboratory of MIC*, Department of Electronic Engineering, Seonam University**

Department of Electronic Engineering, Chonbuk National University***

Abstract : The Brightness, color and texture included in a multispectral satellite data are used as important factors to analyze and to apply the image data for a proper use. One of the most significant process in the satellite data analysis using texture or color information is to extract features effectively expressing the information of original image. It was described in this paper that six vector features were introduced to extract useful features from the analysis of the satellite data, and also a classification network using the back-propagation neural network was constructed to evaluate the classification ability of each vector feature in SPOT imagery. The vector features were adopted from the training set selection for the interesting region, and applied to the classification process. The classification results showed that each vector feature contained many merits and demerits depending on each vector's characteristics, and each vector had compatible classification ability. Therefore, it is expected that the color and texture features are effectively used not only in the classification process of satellite imagery, but in various image classification and application fields.

Key Words : vector features, color and texture, satellite image, classification

요 약 : 위성에서 관측된 다중분광 위성영상 데이터를 이용목적에 따라 분석하고 활용하기 위해서는 영상 자체에 내포된 밝기, 칼라, 질감 등 다양한 특징들이 중요한 정보원으로 이용되고 있다. 특히 질감이나 칼라정보를 이용한 위성영상의 분석과정에서 가장 중요한 문제는 원 영상의 정보를 효율적으로 표현하는 속성을 추출하여 적절히 활용하는 것이다. 따라서 본 논문에서는 위성영상 분석에 유용하게 사용할 수 있는 6개의 속성 벡터들을 선정한 다음 SPOT 위성에서 관측된 영상을 이용하여 각각의 속성들에 대한 분별력을 평가하기 위하여 역전파 신경망(Back-propagation Neural Network)을 이용한 분류 네트워크를 구성하였고, 실험하고자 하는 지역에 대한 훈련집합 선택시 선정된 여섯 개의 속성 벡터들을 분류에 사용될 특징으로 선택하였다. 분류 실험을 수행한 결과 각각의 벡터 속성들은 개개의 특성에 따라 많은 장단점을 내포하고 있었으며, 전반적으로는 비교적 정확한

분류결과를 나타내었다. 따라서 칼라 및 질감 속성 벡터들은 위성영상의 분류과정에 효과적으로 사용될 수 있음은 물론 다양한 영상분석 및 응용분야에서도 유용하게 이용될 수 있을 것으로 기대된다.

1. 서론

위성을 이용한 지구관측 정보는 위성에 탑재된 광학센서와 마이크로파 센서를 통하여 우주상공에서 지구를 관측 촬영한 것으로, 짧은 시간에 넓은 지역을 동시에 관측할 수 있고 반복 측정이 가능하며 관측자료가 디지털 수치로 기록되어 판독이 용이하고 정량화가 가능하므로 지상 정보획득에 많은 이점을 가지고 있다. 또한 관측과장 대역이 가시광선에서 적외선에 이르는 다중 파장대역으로 관측 지역 및 밴드 특성에 따라 다양하고 특색 있는 정보를 취득할 수 있으므로 목적에 따라 우주, 지상, 해양 등 광범위한 분야에서 많은 수요가 예측된다. 특히 정보기술을 기반으로 하는 GIS 시스템의 구축은 지속적으로 위성데이터를 필요로 할 것이다. 그러나 이와 같이 유용성이 많은 위성영상 데이터를 다양한 분야에 효과적으로 적용하고 활용하기 위해서는 이용분야에 적합한 영상처리 및 분석과정이 선행되어야 하며 그 동안 많은 연구와 기술 개발이 이루어져 왔다.

일반적으로 위성영상의 분석과정에서는 칼라, 크기, 형태, 질감, 패턴, 높이, 음영, 위치, 연관성 등의 기본요소들이 사용되며, 특히 위성영상을 이용하여 지상에 분포되어 있는 물체나 지역 등을 식별하고 분류하기 위해서는 밝기, 칼라, 질감(Texture) 등의 특징이 중요한 정보원으로 사용되고 있다(Richards, 1993; Mather, 1993; Dubuisson and Gupta, 1996). Haralick(1974, 1979) 등은 질감 정보를 유출해 내는 다양한 측정방법을 제안하였으며 Landsat 위성영상을 이용하여 실험을 한 결과 레벨 1의 지표분류에서 정확도가 약 7% 정도 향상되었다고 보고하였고, Shin와 Showengerdt(1983)는 밝기 값에 의해 분류를 수행하였을 경우 약 73%의 평균 정확도를 보이는데 반해 밝기 값과 질감을 분류에 적용하였을 경우에는 약 96%

까지 분류 정확도가 향상되었다고 밝히고 있다. 칼라를 이용하는 방법에는 영상의 전반적인 색 분포를 기술하며 계산하기 쉽고 해상도의 변화에 대해 민감성이 적은 칼라 히스토그램이 많이 사용되지만 칼라들의 공간적 상관관계에 대한 정보를 포함하고 있지 않기 때문에 속성으로 사용되기에는 불충분한 점이 있다(Smith, 1996). 따라서 칼라 히스토그램과 영상의 질감 정보 그리고 형태 정보를 결합하여 이용하려는 시도들이 많이 있었으며, Huang(1997) 등이 제한한 칼라 쌍의 공간적 상관관계가 거리에 따라 어떻게 변화하는지를 기술하는 칼라 Correlogram 행렬도 이러한 부류로 간주될 수 있다.

또한 밝기, 칼라, 질감 등 다양한 특징을 이용하여 정보를 추출하고 분석하는 방법에는 크게 통계적인 방법, 구조적인 방법, 모델을 이용하는 방법, 수학적 형태학을 이용하는 방법 등으로 구분될 수 있다. 이중 통계적인 방법이 질감영상 분석에 좋은 결과를 얻을 수 있다고(Ohanian and Dubes, 1992) 하지만 통계적인 성질이 표현되는 행렬을 이용하는 것은 기억 용량이 크고 많은 계산량이 요구되며 서로 상관관계가 많고 행렬 자체가 포함하고 있는 정보를 표현하는데 미흡한 점이 많이 있다(Kim et al., 1998). 따라서 이러한 문제점을 해결할 수 있는 방안 중의 하나는 정보의 유실을 최대한 방지하고 분류시스템 구성에 부담을 주지 않는 범위에서 통계행렬을 다중대역으로 확장하여 칼라와 질감 영상을 효율적으로 분별할 수 있는 벡터 속성을 추출한 다음 위성영상 분석에 적용시키는 것이다.

따라서 본 논문에서는 위성영상 분류에 유용한 속성을 선택하기 위하여 그레이 영상에서 영상의 통계적 성질을 표현하는 SGLDM(Spatial Gray Level Dependence Matrix), GLRLM(Gray Level Run Length Matrix), NSGLDM(Neighboring

Spatial Gray Level Dependence Matrix) 등을 칼라 범위로 확장하여 SCDM(Spatial Color Dependence Matrix), CRLM(Color Run Length Matrix), NSCDM(Neighboring Spatial Color Dependence Matrix) 등의 속성을 정의하였다. 아울러 이들 칼라 영상의 행렬 속성들로부터 유도되어 칼라와 질감 속성을 동시에 검출할 수 있는 6개의 벡터 속성들을 선정하였다. 또한 선택된 벡터 속성들의 분별력을 측정하기 위하여 SPOT 위성으로부터 관측된 전라남도 해안지역의 영상에서 분류 클래스를 산림, 수역, 농경지 등 세 종류로 정하고 각 클래스별로 훈련자료(Training Sites)를 추출한 다음 감독분류에 사용될 특징으로는 벡터 속성들을 적용하여 분별력을 시험하였다. 영상분류 시스템의 구성은 신경망 분류기를 사용하였으며, 각각의 속성 벡터들을 훈련자료 영상을 이용한 유사성 측정과 전체 영상분류에 적용시켜 그 성능을 평가하였다.

2. 칼라 및 질감 속성 벡터의 추출

1) 행렬 속성의 정의

일반적으로 통계행렬을 이용하는 방법에는 이계 통계치를 구하는 SGLDM과 대역신호의 국부적인 신호크기의 변화를 표현하는 NSGLDM 그리고 대역 신호크기의 Run-Length를 표현하는 GLRLM 등이 사용되고 있다. 따라서 이와 같은 속성을 칼라로 확장하여 SCDM, NSCDM, CRLM 등의 속성들을 정의할 수 있다.

(1) SCDM(Spatial Color Dependence Matrix)
SGLDM(Spatial Gray Level Dependence Matrix)에서 확장한 것으로, $I(i, j)$ 를 $n \times n$ 칼라 영상이라 가정하고 $I(i, j) = m$ 을 영상의 (i, j) 위치에 있는 칼라 값을 m 이라 하면, 영상의 칼라 값 사이의 공간 변화와 공간 의존을 표현하는 행렬 SCDM(m, n)은 주어진 거리 d 와 방향 θ 를 파라미터로 하여 다음과 같이 정의할 수 있다.

$$SCDM(m, n) = \text{Card}\{(i, j), (k, l) \in I \times I \mid \rho((i, j), (k, l)) = d, \text{angle}((i, j), (k, l)) = \theta, I(i, j) = m, I(k, l) = n\}$$

여기서, $\text{Card}()$ 는 집합의 원소 개수(Cardinality)를 표현하며, $\rho(i, j)$ 는 화소간의 거리, $\text{angle}(i, j)$ 은 화소간의 각도를 표시한다. 일반적인 거리의 정의는 식(2)를 사용하고 화소간의 각도는 식(3)과 같이 주어진다.

$$\rho((i, j), (k, l)) = \max(|i-k|, |j-l|)$$

$$\text{angle}(i, j), (k, l) = \tan^{-1}((l-j)/(k-i))$$

거리 $d=1$ 인 경우, 방향 θ 는 $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 등이 된다. 이 행렬을 표현하기 위해서 칼라의 종류가 R 개라면, R^2 개의 기억 공간이 요구되며, 칼라의 수의 제공에 비례하는 형태로 많은 기억 공간이 필요하게 된다. Fig. 1에서는 간단한 영상에 대한 $d=1, \theta=0^\circ$ 일 경우의 SCDM을 표현하였다.

(2) NSCDM(Neighboring Spatial Color Dependence Matrix)

NSGLDM(Neighboring Spatial Gray Level Dependence Matrix)에서 확장한 것으로 칼라 영상

m_0	m_0	m_1	m_1
m_0	m_0	m_1	m_1
m_0	m_2	m_2	m_2
m_2	m_2	m_2	m_3

(a) Original Image

	m_0	m_1	m_2	m_3
m_0	4	2	1	0
m_1	2	4	0	0
m_2	1	0	6	1
m_3	0	0	1	2

(b) SCDM ($d=1, \theta=0^\circ$)

Fig. 1. An example of SCDM




Fig. 2. An example of NSCDM




Fig. 3. An example of CRLM

$I(. . .)$ 의 NSCDM은 거리 d 을 파라미터로 하여 다음과 같이 정의할 수 있다.

$$NSCDM(m, n) = Card\{[(i, j) \in I | I(i, j) = m, Card\{(k, l) \in I | (k, l) \neq (i, j), \rho((i, j), (k, l)) = d, I(i, j) = I(k, l)\} = n]\} \quad (4)$$

NSCDM이 SCDM과 다른 점은 방향성을 가지지 않기 때문에 회전에 무관하며, 거리 d 인 이웃한(neighboring) 화소에 대해 국부적으로 계산되기 때문에 SCDM에 비해 병렬 연산이 용이하고 거리 d 가 적은 경우 필요한 기억 공간이 SCDM 보다 적어진다. Fig. 2는 간단한 영상에 대한 NSCDM의 예를 나타내었다.

(3) CRLM(Color Run Length Matrix)

GLRLM(Gray Level Run Length Matrix)에서 확장한 것으로, 칼라 영상 $I(. . .)$ 의 CRLM은 영상의 방향 θ 을 파라미터로 다음과 같이 정의할 수 있다.

$$CRLM(m, n) = Card\{[(i, j) \in I | I(i, j) = m, \tau(m, \theta) = n]\} \quad (5)$$

여기서 $\tau(m, \theta)$ 는 θ 방향의 칼라 값 m 의 run-

length에 해당된다. 따라서 CRLM은 방향성을 가지고 있으며, 방향에 무관한 CRLM을 구성하기 위해서는 각 방향의 CRLM 들을 산술 평균하여 이용할 수 있다. Fig. 3에는 간단한 영상에 대한 CRLM의 예를 나타내었다.

(4) 히스토그램 및 Correlogram

영상 $I(. . .)$ 의 칼라 히스토그램 H 는 다음과 같이 정의된다.

$$H_f(m) = Card\{[(i, j) \in I | I(i, j) = m]\} \quad (6)$$

칼라 영상의 히스토그램이 안고있는 문제를 개선하기 위해 J. Haung(1997) 등이 제안한 영상 $I(. . .)$ 의 칼라 Correlogram은 다음과 같다.

$$Corr(m, n) = Card\{[(i, j), (k, l) \in I \times I | I(i, j) = m, \rho((i, j), (k, l)) = d, I(k, l) = n]\} \quad (7)$$

행렬 $Corr(m, n)$ 은 영상내의 칼라 값이 m 인 화소가 주어졌을 때, 주어진 화소로부터 d 만큼 떨어진 화소의 칼라 값이 n 일 확률을 나타낸다. $Corr(m, n)$ 은 $d = 1$ 인 경우 SCDM의 4 방향에 대한 행렬을 산술 평균한 행렬과 같은 의미를 가진다. 또한 영상 $I(. . .)$ 의 Autocorrelogram은 $Corr(m,$

n)에서 같은 칼라 쌍 사이의 공간적 상관관계를 나타낸다.

$$Autocorr(m) = Corr(m, m) \quad (8)$$

2) 벡터 속성 추출

통계 행렬들을 위성영상 분류에 적용되는 속성으로 사용할 경우 차원이 너무 크기 때문에 SCDM, NSCDM, CRLM, Correlogram 등을 의미 있는 방향으로 투사(projection)하여 NSCDM_R, NSCDM_W, NSCDM_M, CRLM_R, CRLM_W, CRLM_M 등의 위성 영상 분별에 유용한 칼라 및 질감 속성들을 추출할 수 있다.

칼라 영상으로부터 얻어진 행렬 SCDM은 대칭 행렬이다. 또한 식(1)과 식(7)에서 알 수 있듯이 SCDM에서 각도 θ 에 관한 제약을 없애면, 즉 각도 θ 를 모든 방향에 대해 고려할 경우 SCDM은 칼라 Correlogram과 동일함을 알 수 있다. 식(9)는 이 행렬의 주 대각 요소이고, 동일한 칼라 쌍의 공간적 상호관계를 나타내는 것이므로 Autocorrelogram과 일치한다. 또한 방향 θ 의 제약을 없애고 구한 SCDM_D는 식(10)과 같다. 따라서 J. Huang 등이 제안한 칼라 Correlogram은 SCDM의 특별한 형태로 볼 수 있으며, Autocorrelogram은 SCDM의 주 대각 요소를 벡터 형태로 추출한 속성이다. 또한 NSCDM을 가중하여 행 방향으로 합하면 Autocorrelogram이나 SCDM_D와 같게 된다.

$$SCDM_D(m) = SCDM(m, m) \quad (9)$$

$$SCDM_D(m) = \sum_n n \times NSCDM(m, m) \quad (10)$$

NSCDM 행렬도 의미를 부여할 수 있는 방향으로 투사하여 특징 있는 벡터 속성을 정의할 수 있다. NSCDM 행렬을 행 방향으로 투사하면 식(11)과 같고 이것은 칼라 히스토그램을 나타낸다. 또한 가중치를 주고 행 방향으로 투사하면 식(12)와 같이 나타낼 수 있으며, 전술한바와 같이 SCDM_D(m)와 같다. 또한 같은 칼라 쌍의 공간적 평균을 표현하고 있는 NSCDM 행렬로부터 식

(13)을 정의하면 이것은 영상 내에서 어떤 칼라와 이웃하는 화소 중 같은 칼라의 평균 화소 수를 나타내는 질감에 관련된 속성이다.

$$NSCDM_R(m) = \sum_n NSCDM(m, n) \quad (11)$$

$$NSCDM_W(m) = \sum_n n \times NSCDM(m, n) \quad (12)$$

$$NSCDM_M(m) = NSCDM_W(m) / NSCDM_R(m) \quad (13)$$

CRLM의 경우 각 방향으로부터 얻어진 CRLM들을 산술적으로 평균하여 얻어진 CRLM을 행 방향으로 투사하면 식(14)와 같이 나타낼 수 있으며, 영상의 칼라 히스토그램과 유사한 특성을 가진다. 또한 가중하여 투사한 벡터는 식(15)와 같이 나타내며 영상의 히스토그램과 일치한다. 칼라의 평균 run-length를 의미하는 벡터 속성은 식(16)이며, 이것은 칼라 영상의 질감을 표현하는 속성으로 간주될 수 있다. 그리고 CRLM을 각 방향에 대해 구하고 이들을 합하여 얻을 경우 식(17)과 같으며 칼라 히스토그램과 일치한다.

$$CRLM_R(m) = \sum_n CRLM(m, n) \quad (14)$$

$$CRLM_W(m) = \sum_n n \times CRLM(m, n) \quad (15)$$

$$CRLM_M(m) = CRLM_W(m) / CRLM_R(m) \quad (16)$$

$$CRLM_W(m) = NSCDM_R(m) \quad (17)$$

따라서 상기 내용을 요약하면, SCDM에서 방향 θ 에 대한 제약을 무시하고 단순히 두 화소간의 거리만을 고려하면 Color correlogram과 일치한다. 그리고 Color correlogram과 SCDM의 주 대각 요소만을 추출하면 Autocorrelogram이 되며, 이것은 NSCDM을 행 방향으로 가중하여 투사한 NSCDM_W와 동일하다. 또한 방향의 제약을 무시한 SCDM을 행 방향으로 투사하여 정규화 하거나, NSCDM을 행 방향으로 투사하여 얻은 NSCDM_R과 CRLM을 행 방향으로 가중하여 투사한 CRLM_W는 칼라 히스토그램과 일치한다. Table 1은 이상의 벡터 속성을 정리하여 나타내고 있다.

Table 1. Matrix and vector features

행렬	벡터 속성	투사 방법	의미
SCDM	SCDM_D	주 대각 요소 추출	Autocorrelogram
	SCDM_D	행 또는 열 방향 투사	Histogram
NSCDM	NSCDM_R	행 방향 투사	Histogram
	NSCDM_W	가중화 후 행 방향 투사	Autocorrelogram
	NSCDM_M	NSCDM_W/NSCDM_R	이웃하는 평균 동일 칼라 수
CRLM	CRLM_R	행 방향 투사	Run-length 분포
	CRLM_W	가중화 후 행 방향 투사	Histogram
	CRLM_M	CRLM_W/CRLM_R	평균 Run-length 분포

3. 실험 및 고찰

1) 실험 방법 및 사용 영상

본 논문의 실험에서 사용된 영상은 1997년 9월 29일 촬영된 전라남도 보성군 조성면의 득량만 방조제 주변지역인 512×512 크기의 SPOT 다중분광 영상을 사용하였다. Fig. 5의 위성영상은 밴드 1, 2, 3을 각각 Red, Green, Blue로 합성한 영상으로서, 분류하고자 하는 클래스는 영상에서 가지적으로 구분이 되는 산림, 수역, 농경지 등 세 종류로 선정하였으며, 각 클래스에 대한 훈련 데이터는 Fig. 6과 같이 선택하였다(Foody et al., 1995). 분류 방법은 Fig. 4와 같이 RGB 영상을 64개의 등간격 칼라 값으로 양자화 하였으며, 신경망 분류기를 구성하여 6개의 64차원 속성 벡터에 대한 분별력을 실험한 다음 우수 속성을 선별하고, 전체 위성영상을 분류하여 결과를 평가하였다.

2) 분류 네트워크의 구성

분류를 수행하기 위한 네트워크는 Fig. 8과 같이 2층 퍼셉트론(Two-layer perceptron)으로 구성하였으며, 64개의 입력 노드를 갖는 입력 층과 16개의 노드를 갖는 은닉 층(hidden layer) 그리고 출력 층은 3개의 노드를 가지고 있고 인접 층 사이에 완전 연결 구조를 가지도록 구성되었다. 1×64 벡터 입력은 16개의 은닉 노드에서 총체화(aggregation) 되고, 16개의 은닉 노드에서의 출력은 출력 층 노드의 입력으로 연결되어 최종 출력 값을 얻게 된다. 또한 네트워크의 훈련 과정은 Fig. 7에서 나타낸 것과 같이 오류 역전파 알고리즘(Back- Propagation Algorithm)을 이용하였으며, 주어진 입력과 요구되는 출력에 대해 가장 적당한 값을 구하기 위해 Gradient Descent 방법을 사용하였다(Lee et al., 1990).

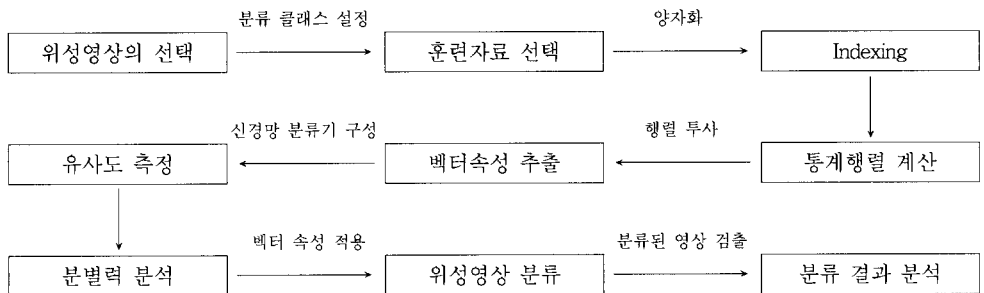


Fig. 4. A Flow chart of the classification process







Fig. 5. SPOT Multispectral Image captured in Sept. 29, 1997.



(a) Tree



(b) Water



(c) Agricultural grass

Fig. 6. Selected training sets

3) 위성영상의 분류 및 결과 분석

위성영상의 분류 실험은 훈련(Training) 과정과 시험(Testing) 과정으로 나누어 진행되었으며, 훈련은 이미 알고 있는 클래스의 영상 데이터를 네트워크의 입력으로 사용하였을 때 출력이 원하는 클

래스가 되도록 노드 파라미터를 반복적으로 조정하는 과정이며, 시험은 훈련과정에서 도출된 파라미터에 의해 영상을 분류하는 과정이다. 실험에 사용된 SPOT 위성영상은 많은 잡음과 고주파 요소를 포함하고 있기 때문에 분류 정확도가 떨어지는 원인이 될 수도 있고, 여섯 개의 벡터 속성들

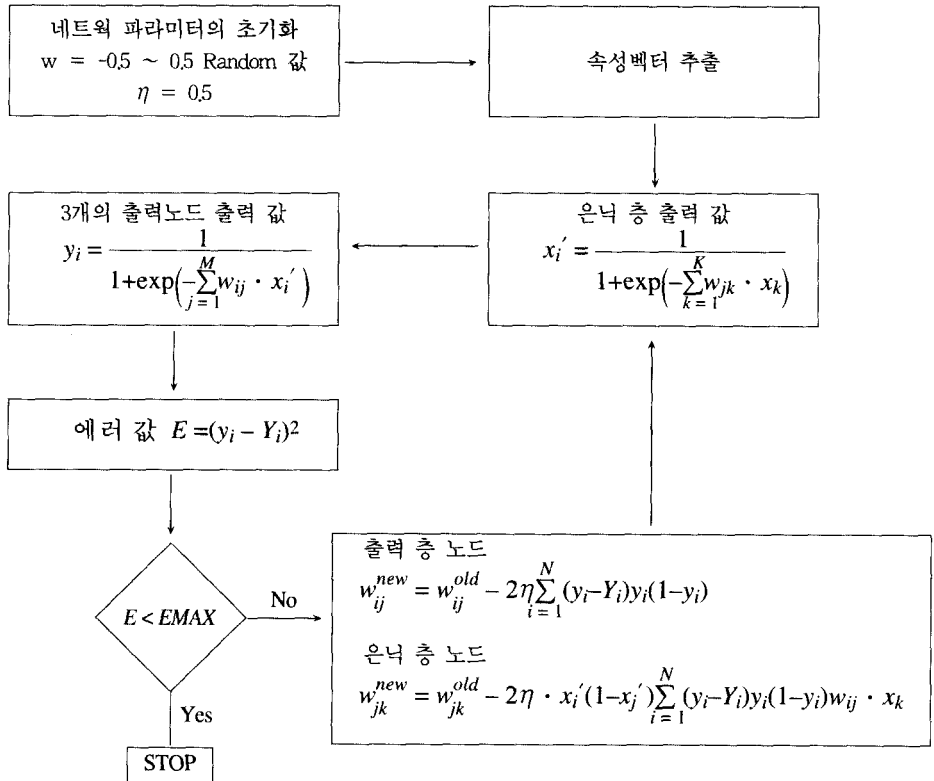


Fig. 7. Training Procedure

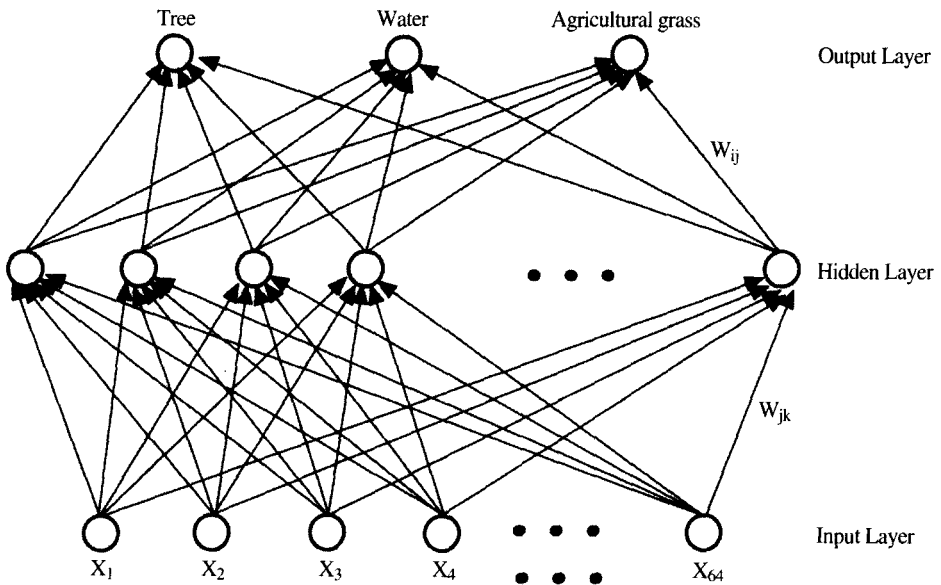


Fig. 8. A two-layer neural network architecture

은 위성영상의 밝기 정보를 포함하고 있기 때문에 전처리 과정에서 질감을 두드러지게 하는 히스토그램 평활화(Histogram Equalization)를 시키면 속성 자체의 의미를 상실할 수 있으므로 전처리 과정은 각각의 밴드를 중요도에 따라 양자화하거나 적응 양자화 기법을 사용하여 256개의 그레이 레벨 수를 줄이는 방법을 사용할 수 있다. 따라서, 본 논문의 실험에서는 고주파 잡음요소를 제거하기 위해 메디안 필터링(Median Filtering)을 이용하였으며, 양자화 과정은 각 밴드의 중요성이 동등하다는 가정 하에 4레벨씩 총 64개의 레벨로 인덱싱(Indexing) 하였다.

또한 전체 영상에 대한 분류 실험을 수행하기 전에 Fig. 6의 훈련자료 영상을 이용하여 6개의 벡터 속성들에 대한 분별력을 시험하였다. 실험에 사용된 영상은 산림, 수역, 농경지에 대해 85×85 크기로 추출된 영상으로서, RGB 영상은 64개의 칼라 값으로 양자화 하였다. 속성 벡터들은 산림, 수역, 농경지 등 각각의 영상에 대하여 윈도우를 16×16 블록으로 설정하고 행과 열 방향으로 4 픽셀 간격씩 이동하며 289개의 속성 벡터를 구하였다. 이중 29개를 무작위로 선정하고 평균을 취한 다음 훈련데이터로 사용하여 나머지 260개의 벡터를 검증하는 방법을 사용하였다. 즉 실험 영상으로부터 6개의 64차원 속성 벡터를 Fig. 8에 도시된 신경망 분류기를 사용하여 분별력 시험을 수행하였으며, 분류결과 최대오류를 0.01로 설정하였을 경우 100%의 정확도를 갖는 우수한 분별력을 나타내었다. 이 결과는 훈련자료영상의 자체 분류 결과이므로 전체 영상에는 존재하는 항목이 훈련자료 영상에는 존재하지 않을 경우와 훈련자료 영상에 존재하는 분류 항목의 샘플들은 동종이며 샘플이 쉽게 추출될 수 있기 때문에 전체 영상을 분류하는 것과는 환경이 상당히 상이하다. 따라서 전체영상 분류 정확도의 측정치가 될 수는 없지만, 사용되는 분류 방법이 훈련자료 영상에 우수하게 작동한다는 것과 여섯 개의 속성 벡터들이 위성영상 분류에 효과적으로 사용될 수 있다는 것을 확인할 수는 있었다.

전체 영상에 대한 분류 실험은 여섯 개의 벡터 속성들 각각에 대하여 수행하였으며, 훈련데이터는 Fig. 6의 산림, 수역, 농경지 등에 대해 윈도우를 81개씩 추출하여 사용하였고, 네트워크의 훈련에서 반복횟수는 5000회 이하가 되도록 지정하였으며 오차한계가 0.01 이하가 될 때까지 반복 수행하도록 설정하였다. Fig. 9에서는 여섯 개의 벡터 속성들을 이용하여 Fig. 5의 영상을 세 개의 클래스로 분류한 결과를 나타낸 것으로 사용지역에 대한 정확한 분류지도(Ground Truth Map)나 검증자료(Reference Data)를 얻기 어려운 관계로 분류 오차 표 작성 및 해석 등 정확한 분류성능 평가는 어렵지만 시각적인 판단에서 볼 때 상당히 좋은 분류 결과를 나타내고 있음을 보여준다. 참고로 그림 9의(b)와 (d)의 결과는 칼라 히스토그램과 동일한 속성으로 동일한 결과를 얻을 수 있음을 보여주고 있다. 산림의 경우 CRLM_R, CRLM_W(NSCDM_R), NSCDM_W 등이 좋은 분류결과를 나타내고 있는 반면 NSCDM_M은 일부분이 농경지 지역화 혼동되어진 것을 볼 수 있으며, 수역의 경우 CRLM_M과 NSCDM_M이 좋은 결과를 나타내고 있고 CRLM_W(NSCDM_R)도 전반적으로 양호한 편이지만 CRLM_R(NSCDM_W)은 육지에 위치하고 있는 일부 수역을 인식하지 못하고 있다. 농경지의 경우는 CRLM_W(NSCDM_R)이 양호한 결과 나타내고 있고 NSCDM_M, CRLM_R, NSCDM_W는 산림 또는 수역 지역과 약간의 오분류를 나타내고 있다. 그러나 전체적인 판단에서 볼 때 여섯 개의 벡터 속성들은 개개의 특성에 따라 장단점을 내포하고 있으며, 전반적으로 비교적 정확한 분류결과를 나타내고 있다.

4. 결론

본 논문에서는 위성에서 전송되는 관측데이터를 이용하여 지상에 분포된 지형 지물 등을 식별하고 분석하여 다양한 정보를 취득하는 과정인 위



(a) Classified image using CRLM_R



(b) Classified image using CRLM_W



(c) Classified image using CRLM_M



(d) Classified image using NSCDM_R



(e) Classified image using NSCDM_W



(f) Classified image using NSCDM_M

Fig. 9. Classification results using feature vectors

성영상 분류에 효과적으로 적용시킬 수 있는 다양한 속성 벡터들의 선정과정을 제시하였으며, SPOT 위성영상을 이용한 실험을 통하여 각각의 속성들에 대한 성능을 분석하였다. 벡터 속성들의

선정과정은 그레이 영상에서 통계적 성질을 표현하는 SGLDM, NSGLDM, GLRLM 등을 칼라 범위로 확장하여 SCDM, NSCDM, CRLM 등의 속성을 정의하였고, 이들 칼라 영상의 행렬 속성들을

의미 있는 방향으로 투사하여 칼라 히스토그램과 질감에 해당되는 속성 정보를 동시에 검출할 수 있는 NSCDM_R, NSCDM_W, NSCDM_M, CRLM_R, CRLM_W, CRLM_M 등 6개의 속성 벡터들을 선정하였다. 선정된 6개의 벡터 속성들의 분류성능 측정은 신경망을 이용한 분류기와 SPOT 위성으로부터 관측된 전남 보성만 지역의 영상을 사용하였으며, 분류 클래스를 산림, 수역, 농경지 등 세 종류로 정하고 실험을 수행한 결과, 칼라 영상의 질감을 표현하는 CRLM_M 속성 벡터, 그리고 칼라 히스토그램 분포와 관련된 NSCDM_R(CRLM_W)들이 가장 우수한 분별력을 나타내었으며, 같은 칼라 값을 가지는 영역을 하나로 간주하여 계수한 CRLM_R, 칼라 쌍의 공간적 상관관계를 표현하는 NSCDM_W 등도 대체적으로 우수한 결과를 얻을 수 있었다. 6개의 벡터 속성 중 임의의 칼라와 이웃하는 화소 중 같은 칼라의 평균 화소 수를 나타내는 NSCDM_M 이 비교적 저조한 결과를 나타냈으나, 전반적으로 벡터 속성들을 위성영상 분류에 이용한 경우 좋은 분별력을 얻을 수 있음을 확인하였다.

따라서 본 논문에서 사용된 6개의 벡터 속성들은 칼라와 질감 속성을 동시에 반영하고 있고, 실험 결과로 나타난 분별력도 우수한 상태이므로 향후 위성영상 분석에 보다 유용하게 사용될 수 있도록 본 논문의 추후 과제로 적응양자화 및 위성영상의 유사성 측도, 분류 정확도 향상 및 평가 등의 관점에서 보완연구를 수행할 계획이다.

참고문헌

본 논문은 '99년도 전파연구소의 공동연구과제로 수행된 연구결과의 일부이며, 실험에 사용된 위성영상을 제공해 주신 인공위성연구센터 원격탐사실에 감사드립니다.

참고문헌

- G. M. Foody, M. B. McCulloch and W. B. Yates, 1995, The effect of training set size and composition on artificial neural network classification, *Int. J. of Remote Sensing*, 16(9): 1707-1723
- John A. Richards, 1993, *Remote Sensing digital Image Analysis*, Springer-Verlag
- J. Kim, S. Kim, W. You and J. Lee, 1998, Vector feature for Textured Color Images and Their Application to Content-Based Image Retrievals, *Proceedings of SPIE, Beijing, China, Electronic Imaging and Multimedia System II*, 3561: 22-32.
- J. Huang, S. Ravi Kumar, Mandar Mitra, Wei-Jing Zhu and Ramin Zabih, 1997, Image Indexing Using Color Correlograms, *IEEE Int. Conf. on CVPR*, 762-768
- Jonathan Lee, Ronald C. Weger, Sailes K. Sengupta and Ronald M. Welch, 1990, A Neural Network Approach to Cloud classification, *IEEE Trans. on Geoscience and Remote sensing*, 28(5): 846-855
- J. R. Smith and S. F. Chang, 1996, Local Color and Texture Extraction and Spatial Query, *IEEE Int. Conf. on Image Processing*, 1101-1104.
- J. R. Smith and S. F. Chang, 1996, Tools and techniques for color images Retrieval, In *Symposium on Electric Imaging: Science and Technology-Storage & retrieval for Image and Video Database IV, IS&T/SPIE Proceedings* 2670.
- M. P. Dubuisson-Jolly and A. Gupta, 1996, Color and Texture Fusion: Application to Aerial Image Segmentation and GIS Updating, *Proc. of the Workshop on Applications of Computer Vision*, 2-7.

- Prul M, Marther, 1993, Computer processing of remotely sensed images, John Wiley.
- P. P. Ohanian and R. C. Dubes, 1992, Performance Evaluation for Four Classes of Textural Features, *Pattern Recognition*, 25(8): 819-833
- Robert M. Haralick, K. Shanmugam and Its'hak Dinstein, 1973, Textural Features for Image Classification, *IEEE Trans. on Systems, Man and Cybernetics*, SMC-3(6): 610-621.
- Robert M. Haralick, 1979, Statistical and Structural Approaches to Texture, *Proceedings of IEEE*, 67(5): 786-804.
- Shin E. H. and R. A. Schowengerdt, 1983, Classification of Arid Geomorphic Surfaces Using Landsat Spectral and Textural Features, *PE & RS*, 49: 337-347.