

위성영상의 감독분류를 위한 훈련집합의 특징 선택에 관한 연구

곽장호* · 이황재* · 이준환**

정보통신부 전파연구소*, 전북대학교 전자공학과**

Feature Selection of Training Set for Supervised Classification of Satellite Imagery

Jang-Ho Kwak*, Hwang-Jae Rhee*, and Joon-Whoan Lee**

Radio Research Laboratory of MIC*, Department of Electronic Engineering, Chonbuk National University**

Abstract : It is complicate and time-consuming process to classify a multi-band satellite imagery according to the applications. In addition, classification rate sensitively depends on the selection of training data set and features in a supervised classification process. This paper introduced a classification network adopting a fuzzy-based γ -model in order to select a training data set and to extract features which highly contribute to an actual classification. The features used in the classification were gray-level histogram, textures, and NDVI (Normalized Difference Vegetation Index) of target imagery. Moreover, in order to minimize the errors in the classification network, the Gradient Descent method was used in the training process for the γ -parameters at each node used. The trained parameters made it possible to know the connectivity of each node and to delete the void features from all the possible input features.

Key Words : fuzzy-based γ -model, feature selection, supervised classification

요약 : 위성에서 관측된 다 대역 위성영상 데이터를 이용목적에 따라 분류하기 위해서는 복잡한 처리과정과 많은 시간을 필요로 하며, 감독분류시 훈련데이터의 선택과 고려되는 다양한 특징 값들은 분류 정확도를 좌우할 만큼 민감한 특성을 나타내고 있다. 따라서 본 논문에서는 훈련데이터의 선택과 다양한 특징 값들 중 실제 영상분류에 기여도가 높은 특징을 추출하기 위하여 페지 기반의 γ 모델을 이용한 분류네트워크를 구성하였다. 훈련집합 선택시 분류하고자 하는 지역의 밝기 분포도, 텍스쳐 특징 그리고 NDVI(Normalized Difference Vegetation Index)를 분류에 사용될 특징으로 선택하였고, 분류네트워크 출력 값의 오류가 최소화 되도록 Gradient Descent 방법을 이용하여 각 노드의 γ 파라미터를 훈련시키는 과정을 채택하였다. 이러한 훈련을 통하여 얻어진 파라미터를 이용하면 각 노드의 연결특성을 알 수 있으며, 다양한 입력 노드의 특징들 중 영상분류에 기여도가 적은 특징들을 추출하여 제거할 수 있다.

주요어 : 페지기반의 γ -모델, 특징추출, 감독분류, 훈련집합 선택.

I. 서 론

SPOT, LANDSAT, IRS 등의 지구관측 위성으로부터 관측된 위성영상 자료는 지구표면에 대한 다양한 정보를 포함하고 있어, 농업, 환경, 군사, 지질, 해양 등의 광범위한 분야에 활용되고 있으며 최근 응용기술의 발달로 인하여 활용범위가 날로 확대되고 있다. 그러나 위성정보는 각 분야마다 필요한 정보의 형태, 공간적 해상도 및 정확도가 상이하고 시간적 주기성과 구름 등 기상조건에 대한 정보의 수용범위가 다르기 때문에 분석에 대한 공정성과 정확도를 높이는 것이 필요하다(정보통신부, 1997).

특히 위성 관측데이터를 이용한 위성영상의 분류과정은 유사한 특성을 갖는 패턴을 동일한 클래스로 배치하는 방법에 따라 크게 무감독 분류(Unsupervised Classification)와 감독 분류(Supervised Classification)로 구분될 수 있는데, 무감독 분류는 훈련집합 없이 영상 자체의 정보만을 이용하여 분류를 수행하며, 감독분류는 일정한 클래스를 정하고 훈련집합을 선택한 다음 분류를 수행하는 방법으로 Maximum Likelihood, Minimum Distance 등의 알고리즘이 사용된다. 그러나 최근에는 이러한 분류방법에 페지-뉴럴 기법을 사용하여 모호하게 나타나는 명확하지 않는 값에 대해 반복적인 학습을 통하여 분류 정확성을 향상시키고자 하는 노력이 이루어지고 있다(Han et al., 1998; 엄과 이, 1996).

페지 이론은 주관적인 정보나 불확실한 정보를 표현하고 어떠한 사실을 판단하는데 있어서 매우 효과적이며, 영상에 나타나는 다양한 특성을 이용하여 클래스를 판단하는 위성영상의 분류과정에 적절히 활용이 가능하다. 이러한 페지 값을 이용하는 연산에는 대표적으로 Union 연산과 Intersection 연산이 있으며 요구되는 출력에 따라 각각의 연산자를 선택하여 사용하여야 한다. 하지만 γ -모델(Zimmermann and Zysno, 1983)은 파라미터의 값에 따라서 Union과 Intersection 연산자의 성질을 동시에 갖기 때문에 연산자를 정의할 필요가 없이

페지 논리 연산이 가능한 분별력을 가지고 있다.

또한 γ -모델과 일반적인 신경망은 외형적으로 유사한 형태를 가지고 있지만, γ -모델에서는 은닉층 노드들에 의미를 부여할 수 있는 반면에 일반적인 다층 신경망에서는 은닉층 노드들에 의미를 부여할 수 없기 때문에 입력노드가 은닉층 노드에 어떤 의미의 영향을 주고 있는지 또는 은닉층 노드가 출력에 어떤 의미의 영향을 주는지를 지적해 낼 수 없다는 점에서 큰 차이를 나타낸다(Lee and Raghu, 1992a). 이러한 점은 정확히 어떤 속성이 의미가 부여된 은닉층 노드에 영향을 주는가를 관찰하여 속성을 줄이는 것에는 γ -모델이 효과적으로 이용될 수 있다는 근거가 된다. 그러므로 γ -모델을 이용하여 분류네트워크를 구성하면 입력 노드의 특징들이 분류 클래스에 기여하는 가중치를 추출할 수 있으며, 분류네트워크의 입력으로 사용되는 다양한 특징들에 대한 평가는 각 특징들의 중요도를 적절히 평가하여 가중치를 적용함으로서 판단과정을 최적화 시킬 수 있고 중요도에 따라 순번을 정하여 특징을 선택함으로서 특징공간의 차원을 감소시키는 역할을 한다.

따라서 본 논문에서는 위성영상 분류에 사용되는 다양한 특징 값이 분류되는 각각의 클래스에 미치는 영향을 분석하고 불필요한 특징들을 추출하여 제거함으로서 분류네트워크를 단순화하는 방법으로 페지 기반의 γ -모델을 사용한 분류네트워크를 구성하였고, SPOT위성 영상을 이용하여 농경지, 수역, 산림, 도심, 구름, 그림자 등 6개의 클래스에 대한 분류 실험을 수행하였다.

II. 페지 기반의 γ -모델을 이용한 위성영상의 분류

일반적으로 위성영상의 분류과정은 Fig. 1과 같이 분류지역의 결정, 훈련집합의 선택, 선택된 훈련집합으로부터 특징추출, 추출된 특징을 기반으로 하는 영상의 분류 등으로 구분될 수 있다. 분류지역의 결정은 사용자의 목적과 주어진 영상에

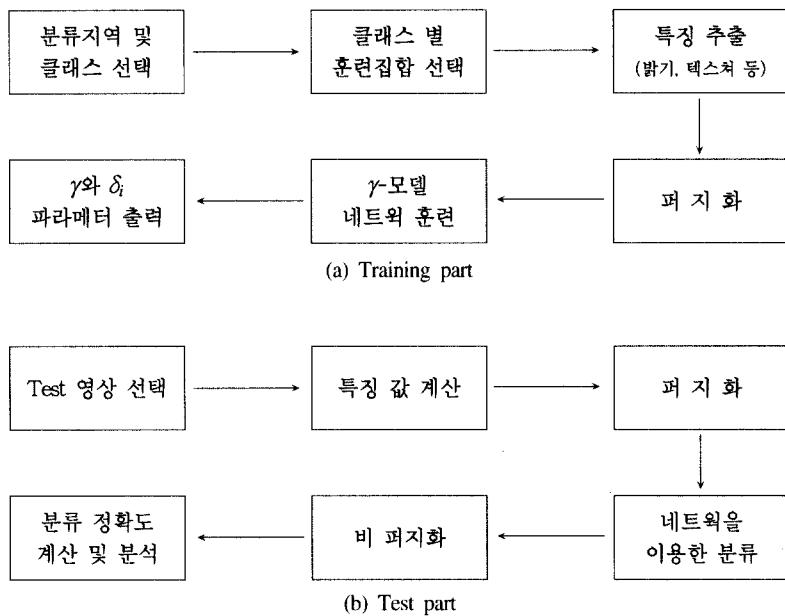


Fig. 1. Flow chart of the classification process

따라 필요한 지역과 분류클래스를 결정할 수 있으며, 훈련집합의 선택은 분류하고자 하는 영상에서 선정하거나 방사학적 보정(Radiometric Correction)에 의해 정규화된 클래스를 포함하는 다른 영상에서 결정할 수 있고 각각의 클래스에 해당하는 지역들 중에서 다른 클래스의 특성과 혼동 가능한 애매한 부분을 포함하여 선택하는 것이 분류의 정확도를 높이는데 효과적이다.

선택된 훈련집합으로부터 특징추출 과정은 위성영상에 포함되어 있는 밝기 분포도, 텍스쳐 특징, NDVI 등 다양한 특징을 추출하여 처리하는 것으로 대역 위성영상에서 각각의 밴드들은 서로 다른 정보들을 포함하고 있으며, 내포되어 있는 정보들을 분류하기 위해서는 다양한 특징의 평가와 선택이 수행되어야 한다(Richards, 1993). 따라서 선택된 훈련집합으로부터 분류에 사용될 특징을 계산한 다음 계산된 특징을 분류네트워크의 입력으로 사용하기 위해 퍼지멤버쉽 함수를 구성하여야 한다. 퍼지멤버쉽 함수는 데이터가 분류클래스에 속하는 소속 정도를 나타내는 퍼지 값으로

일반적으로 히스토그램에 의한 것과 경험적인 방법에 의한 것이 많이 사용된다. 히스토그램을 이용하는 방법은 각 클래스의 훈련데이터로부터 특성에 대한 히스토그램을 계산하며, 정규화된 히스토그램은 확률분포를 가지는 경향이 있으므로 이러한 확률분포 함수로부터 각 클래스의 특성 값을 직접 계산할 수 있다. 히스토그램을 이용하는 방법은 각 클래스의 퍼지멤버쉽 값이 다른 클래스의 퍼지멤버쉽 값에 의해 영향을 받지 않기 때문에 퍼지멤버쉽 함수가 절대적이라고 할 수 있다. 경험적인 방법은 가능성 함수가 가우시안이나 사다리꼴 또는 다른 적당한 형태로 가정되며 퍼지멤버쉽 값을 계산하는데 이용된다. 경험적인 방법은 훈련데이터에 비교적 둔감하다고 할 수 있다(Lin and Lee, 1991; Ken et al., 1996).

본 논문에서는 추출된 특징들을 이용하여 퍼지멤버쉽 함수를 구성하고 퍼지화한 다음 γ -모델로 구성된 네트워크의 훈련자료로 사용하여 위성영상 분류를 수행하였다. 퍼지이론을 기반으로 하는 다중 신경망 구조에서 필요로 하는 다양한 특성의

집합을 결합하는 방법에는 그 동작에 따라서(a) Union 연결(b) Intersection 연결(c) Compensative 연결들로 구분할 수 있으며, Compensative 연결은 다시 Mean 연산자와 Hybrid 연산자로 분류된다 (Lee and Raghu, 1992b). Union 연결은 서로 상이한 형태나 특징으로 표현되는 입력 값들 중 하나의 값만 high를 가져도 high를 출력하는 성질을 가지고 있으며, 가장 일반적인 Union 연산자는 max 연산자이다. Intersection 연결은 Union 연결과는 반대적인 성질을 갖고 있으며 대표적인 연산자는 min 연산자이다. 많은 판단의 문제에서는 Union 연산자와 Intersection 연산자에 의한 특성을 이용하여 해결이 가능하지만 두 특성을 일정부분 씩 포함하는 특성이 요구되기도 한다. 이러한 compensative 연산자는 공리에 의한 Mean 연산자와 전통적인 Union과 Intersection 연산자 쌍의 가중 산술 평균과 기하 평균에 의한 Hybrid 연산자가 있으며, 대표적인 Hybrid 연산자가 γ -모델이다. γ -모델은 Union과 Intersection의 특성을 모두 가지고 있으며 다음과 같이 정의된다.

$$y = \left(\prod_{i=1}^n x_i^{\delta_i} \right)^{1-\gamma} \left(1 - \prod_{i=1}^n (1-x_i)^{\delta_i} \right)^\gamma$$

여기서 $\sum_{i=1}^n \delta_i = n$, $0 \leq \gamma \leq 1$ (1)

y 는 n 개의 입력을 갖는 노드의 출력이고, x_i 는 $[0, 1]$ 의 범위를 갖는 입력이다. δ_i 는 x_i 에 대한 연결강도(Weight)이고, δ_i 가 큰 경우 해당 x_i 에 대한 y 의 감도는 상대적으로 증가한다 (Zimmermann and Zysno, 1983). 또한 γ 는 union과 intersection 성질의 정도를 나타내는 파라미터이며, γ 값이 0에 가까우면 union 성질이 강하며, 1에 가까우면 intersection 성질이 강하게 나타나므로, 연산자를 바꿀 필요 없이 γ 값의 변화만으로도 union과 intersection 및 compensation 연산을 수행할 수 있다.

또한 구해진 훈련 데이터와 멤버쉽 함수를 통하여 네트워크를 훈련시키는 방법은 노드의 실제 출력과 요구되는 출력 값 사이의 오차를 최소화하도록 γ -모델의 파라미터를 결정하는 것이며, 이때

오차함수로 많이 사용되는 오류 자승 합(sum of squares errors)은 다음과 같이 정의된다.

$$E = \sum_{k=1}^N (f_k - Y_k)^2 \quad (2)$$

여기서 N 은 훈련 데이터의 수를 나타내고 f_k 는 노드의 실제 출력, Y_k 는 노드의 요구되는 출력 값을 나타낸다.

γ -모델은 γ 와 δ_i 에 대하여 연속이고 미분 가능하므로, 주어진 입력과 요구되는 출력에 대해 가장 적당한 값을 구하기 위해 Gradient Descent 방법을 사용할 수 있다. 식(1)에서 주어진 γ 와 δ_i 에 대하여 식(3)과 같이 실수 범위의 가인수 a , b , d 를 이용하여 치환하면 γ 와 δ_i 를 제한하는 조건을 고려하지 않아도 된다.

$$\gamma = \frac{a^2}{a^2 + b^2}, \quad \delta_i = \frac{nd_i^2}{\sum_{k=1}^n d_k^2} \quad (3)$$

즉 γ 와 δ_i 의 제약조건은 임의의 실수 범위의 a , b , d 에 의해 결정되고, a , b , d 의 값은 훈련에 의해 갱신되며 γ 와 δ_i 는 a , b , d 에 의해 제약조건을 만족하며 갱신된다.

y_1 과 y_2 를 식(4)와 같이 정의하면

$$y_1 = \prod_{i=1}^n x_i^{\delta_i}, \quad y_2 = 1 - \prod_{i=1}^n (1-x_i)^{\delta_i} \quad (4)$$

새롭게 구해지는 파라미터 a^{new} , b^{new} , d_j^{new} 는 아래 식과 같이 쓸 수 있다.

$$a^{new} = a^{old} - \eta \frac{\partial E}{\partial a} = a^{old} - 2\eta \left(\sum_{k=1}^N (f_k - Y_k) \frac{\partial f_k}{\partial a} \right) \quad (5)$$

$$b^{new} = b^{old} - \eta \frac{\partial E}{\partial b} = b^{old} - 2\eta \left(\sum_{k=1}^N (f_k - Y_k) \frac{\partial f_k}{\partial b} \right) \quad (6)$$

$$d_j^{new} = d_j^{old} - \eta' \frac{\partial E}{\partial d_j} = d_j^{old} - 2\eta' \left(\sum_{k=1}^N (f_k - Y_k) \frac{\partial f_k}{\partial d_j} \right) \quad (7)$$

여기서

$$\frac{\partial f_k}{\partial a} = \frac{2ab^2}{(a^2+b^2)^2} f_k \ln \left(\frac{y_2}{y_1} \right) \quad (8)$$

$$\frac{\partial f_k}{\partial b} = \frac{2ba^2}{(a^2+b^2)^2} f_k \ln\left(\frac{y_1}{y_2}\right) \quad (9)$$

$$\begin{aligned} \frac{\partial f_k}{\partial d_j} = & \frac{2nd_j}{\left(\sum_{k=1}^n d_k^2\right)^2} \left\{ (1-\gamma) \left[\sum_{k=1}^n d_k^2 \ln\left(\frac{x_j}{x_k}\right) \right] + \right. \\ & \left. \gamma \left[\frac{y_2-1}{y_2} \sum_{k=1}^n d_k^2 \ln\left(\frac{1-x_j}{1-x_k}\right) \right] \right\} \end{aligned} \quad (10)$$

식(3)과 새롭게 정의된 a_{new} , b_{new} , $d_{j,new}$ 를 이용하여 새로운 γ 와 δ_j 를 구할 수 있으며, $|\Delta\gamma|$ ($|\gamma^{old} - \gamma^{new}|$)과 $|\Delta\delta_j|$ ($|\Delta\delta_j^{old} - \Delta\delta_j^{new}|$)의 값이 미리 규정된 값 이하가 될 때까지 반복적으로 새로운 파라미터 값을 계산하여 정확한 분류가 수행되도록 네트워크를 훈련시킬 수 있다.

III. 실험 및 고찰

1. 실험대상 지역 및 영상

본 연구의 실험에서 사용된 영상은 1997년 9월 29일 촬영된 전라남도 지역의 SPOT 다중분광 영상으로서, 전체 3284×3000 영상 중 시험 영상은 Fig. 2의 광주/송정리 지역인 512×512 크기의 영상을 사용하였다. Fig. 2의 위성영상은 밴드 1, 2, 3을 각각 Red, Green, Blue로 합성한 영상으로서, 분류하고자 하는 클래스는 영상에서 가시적으로 구분되는 산림, 수역, 농경지, 도심, 구름, 그림자 등 여섯 종류로 선정하였으며, 각 클래스에 대한 훈련 데이터의 크기는 Table 1과 같이 선택하였다.

Table 1. The size of training data

Class	산림	수역	농경지	도심	구름	그림자
Size	64×64	36×36	64×64	64×64	42×42	36×36



Fig. 2. SPOT Multispectral Image captured in Sept. 29, 1997 - Kwangju.

2 분류에 적용될 특징 추출

SPOT 영상은 3개의 밴드(Green, Red, NearIR) 대역을 가지고 있으며, 위성영상 분류에 적용하기 위해 훈련집합으로부터 각 밴드별 밝기 분포도, 식생지수(NDVI) 그리고 텍스쳐가 두드러진 밴드 2 영상으로부터 ASM(Angular Second Moment), Contrast, Correlation, Entropy 등을 계산하여 특징으로 사용하였다. 밝기 특징은 각각의 클래스에 대해 상이하게 나타나는 3개 밴드의 DN(Digital Number) 값 분포를 추출하여 분류특징으로 사용하였으며, 식생지수는 식물의 활력도와 녹피율에 따른 가시광선 및 근적외선 파장대 광선의 반사량의 차이를 이용한다. 왕성하게 생장하는 녹색식물은 근적외선(0.7~1.1μm) 입사량의 40~50%를 반사하고 식물체내의 엽록소는 가시광선의 80~90%를 흡수한다. 활력이 저하되었거나 고사한 식물체는 가시광선의 20~30%를 반사하여 왕성한 식물보다 반사량이 많고, 반면에 근적외선의 반사량은 왕성한 식물에 비해서 적다. 건조한 토양의 가시광선 반사량은 일반적으로 왕성한 식물보다는 많지만 쇠약한 식물보다는 적으며, 반면에 근적외선의 반사량은 식물에 비해서 적다(Jensen, 1986). 따라서 실험에 사용된 식생지수는 다음 식과 같다.

$$NDVI = \frac{Band\ 3 - Band\ 2}{Band\ 3 + Band\ 2}$$

또한 밝기와 NDVI 외에 부가적으로 사용된 4개의 텍스쳐 특징은 일반적으로 많이 사용되는 ASM, Contrast, Correlation, Entropy 등을 적용하였으며, 각각에 대한 정의식은 다음과 같다(Haralick et al., 1973; Weszka et al., 1976; Connors and Harlow, 1980; Unser, 1986).

1) Angular Second Moment:

$$f = \sum_i \sum_j \{(p(i, j))\}^2$$

2) Contrast

$$f = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1, |i-j|=n}^{N_g} p(i, j) \right\}$$

3) Correlation

$$f = \frac{\sum_i \sum_j (ij) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad \text{여기서 } \mu_x, \mu_y, \sigma_x, \sigma_y \text{ 는 } p_x \text{ 와 } p_y \text{ 의 평균과 표준편차.}$$

4) Entropy

$$f = -\sum_i \sum_j p(i, j) \log(i, j)$$

$p(i, j)$: 정규화된 gray-tone spatial dependence matrix의 (i,j)번째 요소

$$= p(i, j) / R$$

$p_x(i)$: $p(i, j)$ 의 행의 합에 의해 구해진 marginal-probability matrix의 i번째 요소

$$= \sum_{j=1}^{N_g} p(i, j)$$

N_g : 양자화된 영상의 gray level

3 계층구조 네트워크의 구성

분류를 수행하기 위한 네트워크는 Fig. 3과 같이 8개의 입력 노드를 갖는 입력 층과 12개의 노드를 갖는 은닉 층(hidden layer) 그리고 6개의 노드를 갖는 출력 층으로 구성되었다. 각각의 밴드별 밝기 데이터는 1개의 은닉 노드에서 aggregation 되고, NDVI와 4개의 텍스쳐는 또 하나의 은닉 노드에서 aggregation 된다. 따라서 2개의 은닉 노드에서의 출력은 최종 노드의 입력으로 사용하여 최종 출력 값을 얻게 된다.

4. 분류 네트워크의 훈련(Training)과 시험(Testing)

위성영상의 분류를 위한 네트워크의 훈련은 Fig. 4와 같이 이미 알고있는 클래스의 영상 데이터를 네트워크의 입력으로 사용하였을 때 출력이 원하는 클래스가 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 정확성이 떨어지는 원인이 된다. 따라서 고주파 잡음요소를 제거하기 위해서는 사용할 영상에 대하여 평활화 작업이 필요하며, 본 실험에서는 메디안 필터링(Median Filtering)을 이용하였다.

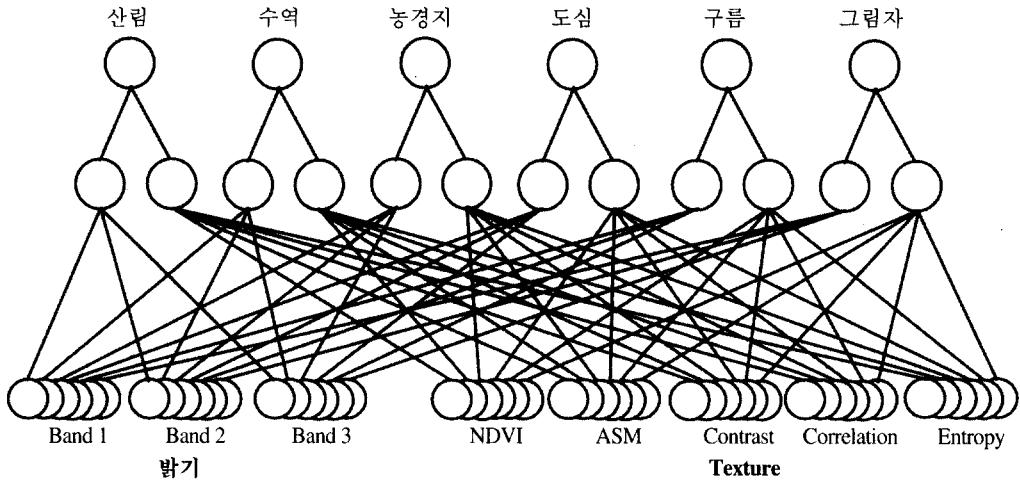


Fig. 3. Structure of the Classification Network

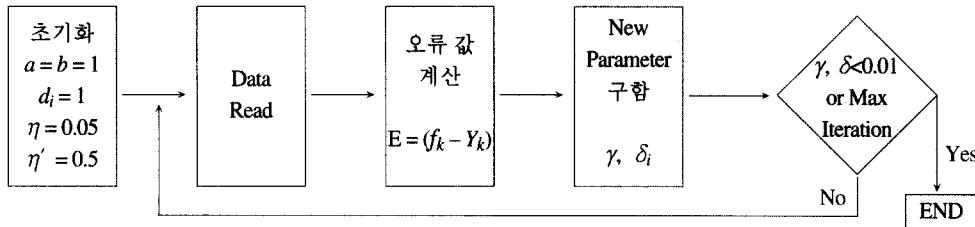


Fig. 4. Training Procedure

또한 퍼지 기반의 γ -모델 네트워크는 입·출력과 연산 값이 모두 퍼지 값으로 이루어져 있으므로 입력되는 훈련과 시험 영상은 모두 퍼지 값으로

변환하는 과정이 필요하다. 따라서 각각에 적절한 퍼지멤버쉽 함수를 구성하는 방법에서는 여러 가지 방법이 있으나 실험에서는 각 클래스에 적합한

Table 2. The Statistics of each features on training set

		Band 1	Band 2	Band 3	NDVI	ASM	Contrast	Entropy	Correlation
산림	평균	61	51	156	0.50334	0.67413	0.10650	0.70180	6,06634
	표준편차	12.35	10.52	26.91	0.07045	0.23620	0.08106	0.47315	1,92069
수역	평균	28	13	16	0.07109	0.81010	0.05882	0.40884	0.06704
	표준편차	5.78	5.58	12.36	0.22114	0.18346	0.05681	0.35613	0.08042
농경지	평균	178	171	185	0.03474	0.07611	1.54734	3.11435	105,72240
	표준편차	27.50	28.87	36.04	0.12699	0.02643	0.49952	0.31174	9,74703
도심	평균	214	217	148	-0.18743	0.38971	3.37532	1.94653	170,93382
	표준편차	40.49	43.42	30.20	0.11598	0.28043	3.52688	1.1057	51,54327
구름	평균	247	247	232	-0.03789	0.90218	0.11018	0.29378	221,71640
	표준편차	19.94	21.29	37.75	0.07077	0.17170	0.18677	0.50501	6,43548
그림자	평균	93	86	63	-0.16089	0.20915	0.37237	1.99073	20,35236
	표준편차	21.32	22.80	23.06	0.09456	0.07734	0.15231	0.43325	6,53450

여섯 개의 영역을 선정하였고, 각각의 데이터에 대한 통계치를 이용하여 가우시안(Gaussian) 함수로 구성하였다. Table 2는 산림, 수역, 농경지, 도심, 구름, 그림자 등 분류클래스에 적용되는 각각의 특징에 대한 통계치를 나타낸 것이며, 구성된 페지멤버쉽 함수를 이용하여 입력 값은 0.01~0.99 범위의 값을 가지게 된다.

네트워크의 훈련에서 반복횟수는 30,000회 이하가 되도록 지정하였으며, $\Delta\gamma = |\gamma_{old} - \gamma_{new}|$ 와 $\Delta\delta_i = |\delta_{i,old} - \delta_{i,new}|$ 는 0.01 이하가 될 때까지 반복 수행하도록 설정하였다. 또한 학습율(Learning Rate)을 나타내는 η 와 η' 는 수렴속도와 안정성을 고려하여 실험적으로 결정된 값인 0.05와 0.5를 사용하였고, 각각의 클래스에 해당하는 훈련데이터가 입력으로 들어오면 그에 해당하는 출력 노드의 값이 0.99가 되도록 하였다. Table 3에서는 이와 같은 네트워크의 훈련과정을 거친 노드 파라미터를 각 클래스별로 나타내었다.

5. 실험결과 분석

실험을 통하여 얻어진 표 3의 노드 파라미터 값을 분석하면, 각 노드의 가중치를 나타내는 δ 를 통해서 위성영상 분류에 적용된 다양한 특징들이 실제로 각각의 분류 클래스에 미치는 기여도를 파

악할 수 있다. 즉 산림의 경우 세 개의 밴드 중 밴드 2가 산림을 분류하는데 주된 역할(Hidden node(I) $\delta_2=2.99942$ 와 Top node $\delta_1=1.15742$)을 하였으며, 텍스쳐에서는 Correlation 특징이 높은 기여도(Hidden node(II) $\delta_4=3.74157$)를 나타내고 있다. 수역에서는 밴드 3가 주된 역할(Hidden node(I) $\delta_3=2.99981$ 와 Top node $\delta_1=1.50727$)을 하였으며 NDVI(Hidden node(II) $\delta_1=2.34069$)와 Entropy(Hidden node(II) $\delta_5=1.79578$) 특징이 많은 기여를 한 것을 볼 수 있다. 특히 그림자에서는 밴드 3만 기여(Hidden node(I) $\delta_3=3.00000$)를 했을 뿐 밴드 1(Hidden node(I) $\delta_1=0.00000$), 밴드 2(Hidden node(I) $\delta_2=0.00000$)는 그림자를 분류하는데 전혀 기여가 없으며, 구름의 경우도 밴드 3(Hidden node(I) $\delta_3=0.00000$)는 분류네트워크에서 제거하여도 분류 결과에는 큰 영향이 없을 것이다. 따라서 본 연구에서 수행한 페지 기반의 γ -모델을 이용한 위성영상 분류방식을 이용하면 분류성능을 손상시키지 않은 상태에서 산림은 밴드 1, 3의 밝기 값, NDVI, ASM, Entropy, 수역에서는 밴드 1, 2의 밝기 값, ASM, Contrast, Correlation, 농경지에서는 NDVI, ASM, Contrast, Entropy, 도심에서는 밴드 1, 3의 밝기 값, NDVI, ASM, Contrast, Entropy, 구름에서는 밴드 2, 3의

Table 3. Result of Training with the γ -model for the structure of fig. 2

클래스		산림	수역	농경지	도심	구름	그림자
파라미터							
Top Node (분류)	γ	0.31412	0.00000	0.32337	0.33832	0.18123	0.10100
	δ_1 (밝기)	1.15742	1.50727	1.15093	1.16707	1.30593	1.46597
	δ_2 (텍스쳐)	0.84258	0.49273	0.84907	0.83293	0.69407	0.53403
Hidden I (밝기)	γ	0.01540	0.00000	0.00958	0.01410	0.00000	0.00000
	δ_1 (밴드 1)	0.00003	0.00011	0.69544	0.16401	2.58360	0.00000
	δ_2 (밴드 2)	2.99942	0.00008	0.71942	2.55727	0.41640	0.00000
	δ_3 (밴드 3)	0.00056	2.99981	1.58515	0.27873	0.00000	3.00000
Hidden II (텍스쳐)	γ	0.45418	0.00000	0.45676	0.45432	0.37928	0.31394
	δ_1 (NDVI)	0.57163	2.34069	0.58403	0.42988	1.34900	1.10000
	δ_2 (ASM)	0.25612	0.12645	0.11253	0.31670	0.07141	0.21202
	δ_3 (Contrast)	0.06556	0.02295	0.05975	0.03237	0.02577	0.00204
	δ_4 (Correlation)	3.74157	0.71413	3.67358	3.72396	3.07103	2.82216
	δ_5 (Entropy)	0.36512	1.79578	0.57011	0.49709	0.48278	0.86377

밝기 값, ASM, Contrast, Entropy, 그림자에서는 밴드 1, 2의 밝기 값, ASM, Contrast, Entropy 등 필요성이 적은 특징을 제거함으로서 분류네트워크를 보다 간단히 할 수 있으며, 분류 클래스에 꼭 필요한 밴드 및 특징을 선택하여 사용할 수 있으므로 판단과정을 최적화시키고 특징 공간의 차원을 감소시키는 역할을 할 수 있을 것이다. 또한 γ 값을 통하여 각 노드가 갖고 있는 속성을 파악할 수 있었다. 수역의 경우 출력 층 노드 및 은닉 층 노드의 모든 값이 0에 근접한 값을 나타내고 있음을 볼 수 있으며, 이것은 각 노드들이 모두 union 연산자로 동작되고 있음을 나타내고 있다. 산림, 농경지, 도심 등의 은닉 층 노드(Ⅱ)와 같이 γ 값이 0.5에 근접한 노드는 compensatory 연산자로 동작되고 있음을 보여준다.

본 논문에서는 훈련데이터(Training data set)를 이용한 실험을 통하여 기여도가 낮은 특징들을 분류네트워크에서 제거시켰을 때 분류성능의 손상상태를 파악하고 기존의 분류 방법인 Maximum

Likelihood 방법과 분류 성능을 비교하였다. 6개의 훈련데이터는 모두 일정하게 36×36 (1296개)을 사용하였으며, 이중 절반(648개)은 훈련데이터로 사용하고 나머지 절반은 검증데이터로 이용하였다. Table 4, 5, 6은 실험결과에 대한 혼돈행렬(Confusion matrix)를 나타낸 것으로 기여도가 낮은 특징들을 제거한 분류결과는 제거하지 않았을 때 보다 약 0.14% 정도의 에러율이 증가하였다. 그러나 부분적으로는 산림, 수역, 그림자에서는 에러율이 증가하였으나 농경지, 도심, 구름 부분은 동일한 결과를 보이고 있다. 따라서 전반적인 판단에서 볼 때 기여도가 적은 특징들을 분류네트워크에서 제외시켜도 분류 성능에는 크게 손상을 입히지 않는 것을 확인할 수 있었다. 또한 Maximum Likelihood 분류방법과 비교하였을 때는 에러율이 전체적으로 약 2.5% 정도 향상된 것을 볼 수 있다.

Fig. 5의 영상은 Fig. 2의 영상을 6개의 클래스로 분류한 결과이다. Fig. 5(a)에서 나타낸 영상은 Maximum Likelihood 분류방법으로 분류된 영상으

Table 4. The confusion matrix using the original network

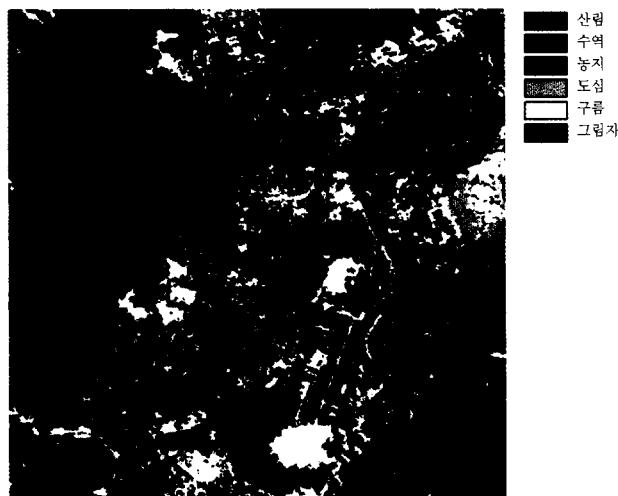
클래스	산림	수역	농경지	도심	구름	그림자	에러율(%)
산림	648	0	0	0	0	0	0
수역	1	645	1	0	1	0	0.5
농경지	4	0	613	31	0	0	5.4
도심	0	0	45	601	1	1	7.3
구름	0	0	39	0	609	0	6.0
그림자	0	0	20	6	0	622	4.0
계	653	645	718	638	611	623	3.86

Table 5. The confusion matrix using the same network after the redundancies have been detected and removed

클래스	산림	수역	농경지	도심	구름	그림자	에러율(%)
산림	647	1	0	0	0	0	0.2
수역	3	643	1	0	0	1	0.8
농경지	4	0	613	31	0	0	5.4
도심	0	0	45	601	1	1	7.3
구름	0	0	39	0	609	0	6.0
그림자	0	0	22	6	0	620	4.3
계	654	644	720	638	610	622	4.0

Table 6. The confusion matrix using the maximum likelihood method

클래스	산 림	수 역	농경지	도 심	구 름	그림자	에러율(%)
산 림	647	0	0	0	0	1	0.2
수 역	3	642	0	0	0	3	0.9
농경지	1	0	571	18	58	0	11.9
도 심	0	0	27	563	22	36	13.1
구 름	0	0	41	4	603	0	6.9
그림자	0	0	8	31	0	609	6.0
계	651	642	647	616	683	649	6.5



(a) Classified image using the maximum likelihood method



(b) Classified image using the γ -model network

Figure 5. Classification results of Fig. 2 image

로서 산림, 구름, 그림자 등은 비교적 좋은 분류 결과를 나타내고 있으나, 도심과 농경지가 약간 혼합되어진 것을 볼 수 있으며, 수역도 그림자로 잘못 인식하고 있다. Fig. 5(b)의 영상은 본 논문에서 제안된 훈련을 통하여 얻어진 네트워크 파라미터를 적용하여 분류한 결과로서, 산림, 구름, 그림자 등은 비교적 좋은 분류 결과를 나타내고 있으나, 일부 수역은 오분류로 인하여 그림자로 잘못 인식하고 있다.

IV. 결 론

지구관측 위성으로부터 전송되는 관측데이터를 이용하여 광범위한 분야에 응용하기 위해서는 위성영상을 처리하고 분석하는 과정이 필수적으로 선행되어야 한다. 따라서 본 논문에서는 분석과정 중의 하나인 영상분류를 수행할 때 적용되는 다중 분광 영상과 다양한 특징들을 보다 효율적으로 선택하는 방법을 제시하였다. 즉 페지 기반의 γ -모델을 이용한 네트워크를 사용하여 SPOT 위성 영상을 산림, 수역, 농경지, 도심, 구름, 그림자 등 여섯 종류의 클래스로 분류하는 과정과 실험 결과를 나타내었다. 본 논문에서 사용된 γ -모델은 페지 결합의 기본 특성인 union 특성과 intersection 특성의 성질을 모두 가지고 있으며, γ 파라미터 값을 변화시킴으로써 각 성질을 나타낼 수 있었다. 또한 훈련 과정에서 구해지는 δ 값을 통하여 다양한 입력 영상 및 특징 값들이 분류클래스에 미치는 영향을 분석할 수 있음으로서 기여도가 아주 적거나 전혀 없는 입력은 네트워크에서 제거함으로써 분류 네트워크를 간소화하고 처리 시간을 줄일 수 있었다. 따라서 분류시스템에서 많은 특징을 입력으로 사용하고 다중 네트워크으로 구성하였을 경우에 이러한 훈련과정을 통하여 기여도가 없는 연결을 제거하면 분류성능에 크게 손상 없이 네트워크를 간소화하고 처리시간을 단축시킬 수 있으며, 분류 클래스에 꼭 필요한 밴드영상 및 특징을 선택하여 사용할 수 있으므로 판단과정을 최적화 시키고 특

징공간의 차원을 감소시키는 역할을 할 수 있을 것이다.

향후 국내에서도 관측위성인 다목적실용위성이 발사되고 최근 관측센서의 발달로 인하여 1m 이하의 고해상도 위성영상의 공급이 가능한 시점에서 위성영상 분류기술의 향상 및 활용은 필수적이라 할 수 있으며, 본 논문도 추후 과제로 분류정확도를 보다 향상시킬 수 있는 보완 연구를 수행할 계획이다.

참고문헌

- 엄기문, 이쾌희, 1996, 위성 영상 분류를 위한 규칙 기반 훈련 집합 선택에 관한 연구, 한국 정보처리학회지, 3(7) : 1763-1772.
- 정보통신부, 1997, 원격영상정보 분석기술 개발, 연구보고서, 159-211.
- Chin-Teng Lin and C.S. George Lee, 1991, Neural-Network-Based Fuzzy Logic Control and Decision System, IEEE trans. on Computers, 40(12) : 1320-1336.
- Jong-Gyu Han, Kwang-Hoon Chi and Jae-Young Suh, 1998, A Neuro-Fuzzy Model Approach for the Land Cover Classification, Proceeding of International Symposium on Remote Sensing, 122-127.
- Joan S. Weszka, Charles R. Dyer and Azriel Rosenfeld, 1976, A comparative Study of Texture Measures for Terrain Classification, IEEE Trans. on Systems, Man and Cybernetics, SMC-6(4) : 269-285.
- John A. Richards, 1993, Remote Sensing digital Image Analysis, Springer-Verlag.
- John R. Jesen, 1986, Biophysical Remote Sensing, Annals, Assoc. of American Geographers, 73: 111-132.
- Ken Nozaki, Hisao Ishibuchi and Hideo Tanaka, 1996, Adaptive Fuzzy Rule-Based

- Classification Systems, IEEE Trans. on Fuzzy Systems, 4(3) : 238-250.
- Lee, Joonwohan and Raghu Krishnapuram, 1992a, Fuzzy-Set-Based Hierarchical Network for Information Fusion in Computer Vision, Neural Networks, 3 : 335-350.
- Lee, Joonwohan and Raghu Krishnapuram, 1992b, Fuzzy-connective-based hierarchical aggregation networks for decision making, Fuzzy sets and Systems 46 : 11-27.
- Michael Unser, 1986, Sum and Difference Histograms for Texture Classification, IEEE Trans. on Pattern Analysis and Machine Intelligence, PAMI-8(1) : 118-125.
- Prul M. Marther, 1993, Computer processing of remotely sensed images, John Wiley.
- Richard W. Conners and Charles A. Harlow, 1980, A Theoretical Comparison of Texture Algorithms, IEEE Trans. on Pattern Analysis and Machine Intelligence, PAMI-2(3) : 204-222.
- 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.
- Zimmermann, H. J. and Zysno, P., 1983, Decisions and Evaluations by Hierarchical Aggregation of Information, Fuzzy Sets and Systems, 10(3) : 243-260.