

뉴로-퍼지 알고리즘을 이용한 원격탐사 화상의 지표면 패턴 분류 시스템 구현

An Implementation of Neuro-Fuzzy Based Land Cover Pattern Classification System for Remote Sensing Image

한종규* · 이상구

Jong Gyu Han* and Sang Gu Lee

* 한국자원연구소, 한남대학교 컴퓨터전자통신공학부

요 약

본 논문에서는 뉴로-퍼지 알고리즘을 이용한 원격탐사 화상의 지표면 패턴분류기를 제안한다. 제안된 패턴 분류기는 일반적인 퍼지 인식기를 가지고 있는 3층 전방향 신경회로망 구조로 되어 있고, 가중치들은 퍼지집합으로 구성된다. 이러한 퍼지-뉴로 패턴분류 시스템을 Visual C++ 환경으로 구현한다. 성능평가를 위해, 기존의 역전파 학습기능을 가진 신경회로망과 Maximum-likelihood 알고리즘을 이용해 처리한 결과와 비교분석한다. 대표적인 지표면 특징을 나타내는 8개의 클래스에 대해 훈련집합을 선정하고, 각각의 분류 알고리즘에 같은 훈련집합을 사용하여 학습시킨 후, 실험화상을 적용하여 지표면 특징을 8개의 클래스로 분류하였다. 실험결과 제안된 뉴로-퍼지 분류기는 여러 개의 클래스로 혼합된 패턴에 대해서 기존의 분류기들에 비해 보다 더 좋은 성능을 보인다.

ABSTRACT

In this paper, we propose a land cover pattern classifier for remote sensing image by using neuro-fuzzy algorithm. The proposed pattern classifier has a 3-layer feed-forward architecture that is derived from generic fuzzy perceptrons, and the weights are composed of fuzzy sets. We also implement a neuro-fuzzy pattern classification system in the Visual C++ environment. To measure the performance of this, we compare it with the conventional neural networks with back-propagation learning and the Maximum-likelihood algorithms. We classified the remote sensing image into the eight classes covered the majority of land cover feature, selected the same training sites. Experimental results show that the proposed classifier performs well especially in the mixed composition area having many classes rather than the conventional systems.

1. 서 론

화상의 처리 및 인식은 많은 분야에서 이용되고 있으며, 특히 근래에 와서 의학 응용, 원격탐사(remote-sensing) 등에서 급속히 발전하여 많은 성과를 올리고 있다. 원격탐사는 주로 항공기나 인공위성에 탑재된 분광감지기를 이용하여 지표면의 대상물에서 반사 또는 방사되는 전자파(electromagnetic wave)를 측정하여 분석함으로써 대상물이나 현상에 대한 해석 및 감시를 하는 기술을 말한다[1]. 항공기나 인공위성으로부터 얻어진 화상으로부터 지표면의 특징을 분류하여 피복도(land cover map)를 작성하는 것은 원격탐사 분야에서 중요하게 다루어지는 분야이며, 여기서 만들어진 자료는 지리정보시스템을 구축하는데 필요한 입력자료로 유용하게 이용될 수 있다[2].

지금까지 연구되어 왔던 패턴 분류 알고리즘은 통

계적 기법으로는 Minimum Distance, Maximum-likelihood, Nearest neighbor, parallel-piped 방법 등이 있으며, 인공지능 기법으로는 신경회로망, Fuzzy c-means, SOFM(Self Organized Feature Map) 등이 있다[3-5]. Maximum-likelihood와 같은 전통적인 통계적분류에서 하나의 화소(pixel)는 확률밀도함수의 가장 높은 소속도를 갖는 클래스에 할당되는데, 이는 각 클래스에 대한 데이터가 가우시안(Gaussian) 분포를 갖는다는 가정이 필요하다. 비록 데이터 분포에 대한 가정이 만족된다 할지라도 분류성능은 사용된 훈련집합의 질(quality)에 의존하게 된다. 이러한 Maximum-Likelihood 분류방법의 문제점들을 해결하기 위해 통계적인 자료의 분포에 대한 가정을 하지 않는 방법들을 사용할 수 있다. 예를 들어, 퍼지나 신경회로망과 같은 분류방법을 사용하게 되었다. 신경회로망은 다양한 응용분야에 적용되어 왔으며, 원

격탐사자료를 분류하는데 있어서 일반적으로 전통적인 통계적기법에 비해 높은 정확성을 보여왔다[6-8]. 그러나, 신경회로망도 다음과 같은 단점을 가지고 있다. 첫째, 신경회로망의 역전파(back-propagation) 학습방법이 최급강하법(steepest descent method)에 기반을 두고 있기 때문에 필연적으로 국부해(local minima)에 빠지게 되고, 둘째, 필요 이상으로 신경회로망의 층 수를 늘리면 학습 시간이 오래 걸리며, 학습시 초기 변수의 설정이 성능에 크게 영향을 미친다. 지금까지의 신경회로망과 퍼지모델을 이용한 대표적인 뉴로-퍼지 시스템인 ANFIS(Adaptive Network-based Fuzzy Inference System)는 퍼지추론 시스템과 기능적으로 같은 적응적 신경회로망 구조를 갖고 있다. ANFIS는 모두 5개의 층으로 구성되어 있으며, 첫번째 층의 각각의 노드들은 퍼지집합의 소속함수로 구성되어 있는 입력노드로 입력값에 대한 소속도를 계산하여 출력하고, 두번째 층의 각 노드는 들어오는 모든 값을 곱하여 출력으로 보내고, 세번째 층에서의 각 노드는 모든 규칙들에 대한 가중치 합과 번째 규칙에 대한 가중치의 비를 계산한다. 네번째 층은 적응노드로 다음 층으로 출력을 위한 함수가 정의되고, 세번째 층의 출력값과의 곱으로 계산되어지며, 다섯번째 층은 들어오는 모든 값을 합계하여 최종 출력값을 계산한다.

본 논문에서 제안하는 뉴로-퍼지 분류기는 일반적인 퍼지 인식기(fuzzy perceptron)를 가지고 있는 3층 전방향(feed-forward) 신경회로망 구조로 되어 있다. 제안된 퍼지 인식기는 일반적인 다층(multi-layer) 인식기 구조로 되어 있지만, 가중치들은 퍼지집합으로 구성되어 있으며, 활성함수, 출력함수, 전이함수는 이를 퍼지집합으로 구성된 가중치에 따라 각각 변하게 된다. 또한 퍼지 삼각소속함수의 변수 a , b , c 를 조정할 수 있도록 구현하였다.

본 논문에서는 원격탐사 화상의 패턴 분류를 위해 퍼지이론과 신경회로망을 융합한 새로운 뉴로-퍼지 패턴 분류 시스템을 제안하고, 기존의 패턴 분류 시스템인 Maximum-likelihood와 역전파 학습알고리즘을 가진 신경회로망 분류 시스템과의 분류 정확성에 대한 성능을 비교분석한다.

2. 알고리즘

2.1 역전파 신경회로망 분류 시스템

신경회로망에서 다중분광영상의 지표면 특징분류를 위한 시스템 구조는 입력층, 은닉층, 출력층으로 구성된다. 입력층에는 영상의 분광영역 개수에 따라 입력

노드가 결정되고, 출력층은 클래스 개수에 따라 출력노드가 구성되며, 은닉층의 수는 반복적인 학습을 통한 시행착오에 의하여 결정된다. 모든 입력과 출력 노드들은 은닉층의 모든 노드들과 상호 연결되어 있으며, 각각의 연결점에는 연관된 가중치와 학습 후의 각각의 클래스에 대한 학습된 정보를 가지고 있게 된다.

신경회로망의 기본적인 요소는 두 가지 기능을 수행하는 처리노드이다. 첫번째 기능은 입력노드의 값들을 합산하여, 처리노드의 출력값을 만들기 위해 임의의 활성함수(activation function)를 통해 전달한다. 역전파 신경회로망 학습에서 가장 많이 사용하는 활성함수는 시그모이드 함수이다. 이 함수는 각 뉴런이 자신의 입력 합을 일정한 범위의 값으로 수축한 후 다음 계층으로 전파하도록 한다. 초기 연결 가중치를 정하는 일반적인 원칙은 없으나 응용의 특성에 따른 적당한 범위들이 많이 나와 있다[9].

교사 패턴인식의 학습단계에서 연결 가중치는 기울기 강하(gradient descent) 방법에 의해 반복적으로 조정된다. 학습 데이터는 학습시키고자 하는 입력 벡터와 입력 벡터에 대한 기대되는 출력 값들로 이루어진 출력 벡터로 구성된다. 학습단계의 목표는 입력에 대응하는 출력이 자신의 목표에 가장 가까이 접근하도록 오차를 최소화하는데 있으며, 이는 학습 시에 가중치 조정이 무한적으로 계속되게 된다. 실제적이고, 효율적인 학습시간을 얻기 위해 최소오차에 대한 학습단계의 비율로 나타내는 학습계수가 명시되어야 한다. 만약 학습계수가 너무 작으면 학습하는데 시간이 오래 걸리고, 너무 크면 오차가 증가한다.

역전파 학습방법은 몇 가지 문제점을 가지고 있는데, 첫째, 국부해(local minima)에 빠지는 문제점을 가지고 있다. 이는 역전파 학습방법이 최급강하법(steepest descent method)에 기반을 두고 있기 때문이다. 둘째, 필요 이상으로 신경회로망의 층 수를 늘리면 학습 시간이 오래 걸리며, 셋째, 학습시 초기 변수의 설정이 성능에 크게 영향을 미친다는 것이다. 이러한 문제점들을 완화하기 위한 방법으로 가중치 수정량을 전단계의 학습에서 계산된 가중치 수정량과 현재 수정량의 무게중심으로 정하는 방법과, 학습 매개변수를 동적으로 적용시키는 적응 매개변수 방법이 있다. 이는 신경회로망이 학습속도를 향상시킬 수 있을 뿐만 아니라, 학습시간 동안에 국부해에 빠지는 것을 방지할 수 있다.

2.2 Maximum-likelihood 분류 시스템

Maximum-likelihood 패턴 분류 시스템은 입력패턴으로부터 분포 특징 패턴을 추출하는 방법으로 확률

밀도함수를 이용하여 훈련 패턴으로부터 모수를 순차적으로 추정하는 parametric model이다. 입력 패턴의 분포를 확률밀도함수로 근사화할 수 있다면 보다 정확한 패턴 정합 값을 얻는 장점이 있다. 식 (1)의 확률밀도함수는 입력 패턴들의 발생이 서로 독립인 n차원 Gaussian이라는 가정하에 성립하게 된다.

$$\begin{aligned} g_i(X) &= p(X/w_i)p(w_i) \\ &= \frac{p(w_i)}{(2\pi)^{(n/2)}|\Sigma_i|^{1/2}} e^{-(1/2)(X-U_i)^T(\Sigma_i^{-1})(X-U_i)} \end{aligned} \quad (1)$$

여기서 n 은 입력 패턴의 수, X 는 입력 벡터, U_i 는 클래스 i 의 평균벡터(mean vector), Σ_i 는 클래스 i 의 공분산 행렬(covariance matrix)을 나타낸다. 평균벡터 U_i , 공분산 행렬 Σ_i 는 식 (2)와 (3)의 비편향적 추정자(unbiased estimator)에 의해 훈련패턴으로부터 추정된다.

$$\hat{\mu}_{ij} = \frac{1}{p_i} \sum_{l=1}^{p_i} x_{jl} \quad j = 1, 2, \dots, n \quad (2)$$

$$\hat{\sigma}_{ijk} = \frac{1}{p_i - 1} \sum_{l=1}^{p_i} (x_{jl} - \hat{\mu}_{ij})(x_{kl} - \hat{\mu}_{ik}) \quad j = 1, 2, \dots, n; k = 1, 2, \dots, n \quad (3)$$

P 는 클래스 i 의 훈련 패턴의 수를 나타낸다. 정합값 계산 시 평균벡터와 공분산 행렬의 역행렬을 구해야 하므로 P 는 적어도 입력 화상의 밴드 수보다 커야 한다. 입력 패턴의 길이가 클 경우 많은 소요시간이 소요되며, 이러한 단점을 개선하기 위하여 확률밀도함수의 정합값을 계산할 때 1로 정규화하는 부분을 제외하고 단순히 지수함수의 내부 변수만으로 계산할 수도 있으며, 이때 공분산 행렬이 대각선 요소만 있는 대각 행렬인 경우 유클리디안 거리 계산 식과 동일한 형태가 된다. 식 (1)에서 상수 π 를 제거하고, 자연로그를 취하면 식 (4)와 같이 나타낼 수 있다.

$$\begin{aligned} g_i(X) &= \log_e p(w_i) - \frac{1}{2} \log_e (\Sigma_i) \\ &\quad - \frac{1}{2} (X - U_i)^T \cdot \Sigma_i^{-1} (X - U_i) \end{aligned} \quad (4)$$

만약, 모든 클래스에 대한 사전확률(a priori probability)이 같다고 가정한다면, 각각의 입력패턴은 가장 높은 사후확률소속도(a posteriori probability membership)를 갖는 클래스에 할당되게 된다. 같은 사전확률에 대해서 사후확률은 밀도의 합과 비례해서 클래스에 대한 입력패턴의 확률밀도로서 계산되어진다.

2.3 뉴로-퍼지 분류 시스템

본 논문에서 제안하는 뉴로-퍼지 분류기는 일반적인 퍼지 인식기를 가지고 있는 3층 전방향 신경회로망 구조로 되어 있다. 제안된 퍼지 인식기는 일반적인 다층 인식기 구조로 되어 있지만, 가중치들은 퍼지집합으로 구성되어 있으며, 활성함수, 출력함수, 전이함수는 이를 퍼지집합으로 구성된 가중치에 따라 각각 변하게 된다. 패턴 분류를 위한 뉴로-퍼지 시스템은 입력 패턴으로부터 퍼지 규칙을 생성하는데 다음과 같이 두 단계로 구성된다. 첫번째 단계에서는 입력 패턴 공간에 대한 퍼지분할을 수행하고, 각각의 퍼지 부분 공간에 대한 퍼지논리 규칙을 찾는다. 두 번째 단계에서는 찾아낼 퍼지논리 규칙들이 퍼지 결론부로 구성된다면 출력공간에 대한 퍼지분할을 수행하게 된다 [10,11]. 생성된 퍼지 규칙은 **IF** x_1 is μ_1 and x_2 is μ_2 and \dots and x_n is μ_n **THEN** the pattern (x_1, x_2, \dots, x_n) belongs to class i 와 같은 형태로 구성된다. x_1, x_2, \dots, x_n 는 입력 벡터를, $\mu_1, \mu_2, \dots, \mu_n$ 는 퍼지집합을 나타낸다. 가중치는 활성화 함수, 출력함수 및 전이함수에 의해 변하게 된다. 또한 퍼지 인식기는 근사화 함수를 사용하는 보통 인식기와 유사하며, **IF**(전전부) **THEN**(후건부)와 같이 언어적 형태의 퍼지 규칙 지식베이스를 생성하기 때문에 이해하기가 쉽다. 본 논문에서 제안된 뉴로-퍼지 패턴 분류시스템의 학습 알고리즘은 다음과 같다.

(1) 입·출력 쌍(p, t)을 선택하여 뉴로-퍼지 분류 시스템으로 전파하고, 출력 벡터 c 를 결정한다.

/* p : 입력 패턴, t : 목표 패턴, c : 출력 벡터 */

(2) 각각의 출력 유닛 c_i 에 대해 델타 값($\delta_i = t_i - a_{ci}$)을 결정한다.

/* a_{ci} : 출력 유닛에 대한 활성함수 값 */

(3) 활성함수 값이 0보다 큰 각각의 규칙 유닛 R 에 대해,

④ 규칙 유닛 R 에 대한 델타 값을 구한다.

$$\delta_R = a_R(1-a_R) \sum_{c \in U_3} W(R, c) \delta_c$$

/* $W(R, c)$: 규칙 유닛과 출력 유닛 사이의 연결 가중치 */

⑤ 다음을 만족하는 x' 를 찾는다.

$$W(x', R)(a_x) = \min_{x \in U_1} \{W(x, R)(a_x)\}$$

/* $W(x, R)$: 입력 유닛 x 와 규칙 유닛 R 사이의 퍼지 연결가중치 */

⑥ 퍼지집합에 대해 퍼지 연결가중치 $W(x', R)$ 은 0보다 큰 학습계수 σ 를 이용하여 퍼지 삼각 멤버소속 함수의 변수 a, b, c 에 대한 델타 값을 결정하고,

$W(x', R)$ 가 다른 연결에서 공유될 수 있어 한번 이상 바뀔 수 있다면 델타 값들을 $W(x', R)$ 에 적용한다.

$$\delta_b = \sigma \cdot \delta_R \cdot (c - a) \cdot \text{sgn}(a_{x'} - b),$$

$$\delta_a = -\sigma \cdot \delta_R \cdot (c - a) + \delta_b,$$

$$\delta_c = \sigma \cdot \delta_R \cdot (c - a) + \delta_b,$$

(4) 설정된 학습 반복횟수나 STOP조건을 만족하면 수행을 멈추고, 그렇지 않으면 (1)단계로 넘어간다.

3. 실험 및 성능비교

3.1 원격탐사 데이터의 특성

원격탐사 시스템은 항공기나 인공위성과 같은 분광감지기를 탑재하기 위한 탑재기(platform)와 지표로부터 반사 또는 방사되는 전자파 에너지를 수집하는 분광감지기, 수집된 원격탐사자료를 처리할 수 있는 화상처리 시스템 등으로 구성되며 수집된 자료는 대체로 사진이나 수치화된 자료로 표시된다. 분광감지기는 지표면의 대상물로부터 반사 또는 방사되는 에너지를 수집하는 기구로서, 전자파를 렌즈와 반사경을 통해 모은 뒤 그 에너지를 검지소자(detector)로 검출하여 여러 개의 파장대, 즉 가시광선, 적외선, 열적외선 등으로 나누어 화상 또는 디지털 수치로서 기록한다. 본 연구에서 사용된 화상은 항공기에 탑재된 AMS라는 분광감지기를 통해 얻어진 자료를 사용한다.

3.2 실험화상

사용된 화상은 대덕연구단지를 대상으로 동시에 6개 파장대의 자료를 획득할 수 있는 AMS센서를 탑재한 항공기에 의해 촬영되었으며, 화상은 해상도가

픽셀당 3 m이고, 크기가 가로·가운데·세로 410×390 pixel, 3개의 가시광선 파장대, 1개의 근적외선 파장대로 이루어져 있다. 대상지역을 대덕연구단지로 선정한 이유는 실제로 이 지역의 지표면 분류정보를 알고 있어 분류기들 간의 성능을 객관적으로 평가할 수 있기 때문이다. 그럼 1은 각각 7-5-3 파장대와 5-3-2 파장대에서 얻어진 화상을 RGB(Red, Green, Blue)로 합성한 화상이다.

3.3 화상처리 및 지표면 특징분류 과정

항공촬영 화상은 항공기의 자세, 지구자전 등과 같은 요인으로 인한 기하학적 왜곡(geometric distortion)과 태양의 고도, 대기상태 등에 의해 발생하는 방사학적 왜곡(radiometric distortion)을 포함하고 있기 때문에 실제의 지형도와 일치하지 않는다. 먼저 본격적인 화상처리를 하기 전에 이러한 왜곡을 보정하는 전처리 단계를 거치게 된다. 이러한 전처리 단계에서 보정작업이 끝나면 분류하고자 하는 클래스를 선정한다. 그리고 각각의 클래스에 대한 훈련집합을 선정한다. 다음에 각각의 분류알고리즘을 이용하여 분류하고, 각각의 분류시스템에 대한 성능을 평가한다. 본 연구에서는 그림 2와 같이 뉴로-퍼지 알고리즘을 이용한 분류시스템을 Win98환경에서 Visual C++(V5.0)을 사용하여 구현하였으며, 구현된 뉴로-퍼지 패턴 분류시스템은 다음과 같이 3부분으로 나뉘어져 있다. 첫째, 뉴로-퍼지 패턴 분류시스템에 사용될 각종 환경 변수들을 설정하는 부분, 둘째, 분류하고자 하는 패턴, 퍼지 규칙, 네트워크 그리고 설정된 환경변수 파일을 읽어 들이고 저장하는 부분, 마지막으로 최종 분류된 결과를 저장하는 부분으로 구성되어 있다. 사용법을 간

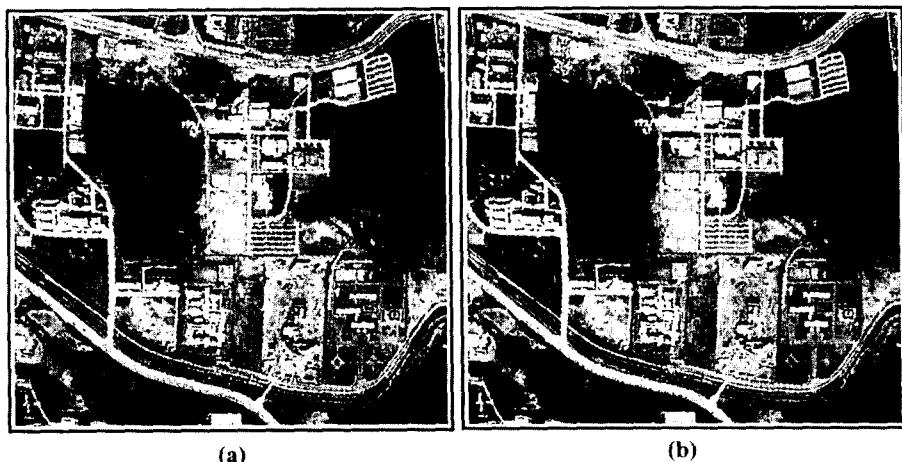


그림 1. (a) 파장대 7-5-3와, (b) 5-3-2를 각각 RGB로 합성한 화상

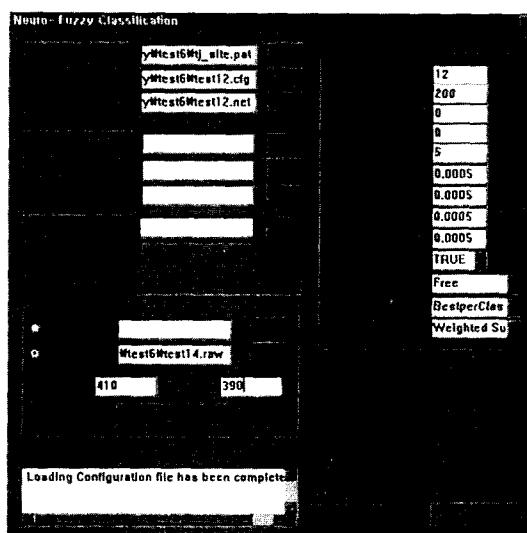


그림 2. 뉴로-퍼지 패턴 분류 시스템

단히 요약하면, 먼저 사용될 환경 변수들을 설정한 다음, 훈련 집합으로 선정된 클래스의 패턴 파일을 읽어들이고, 네트워크를 초기화한다. 그리고, 학습을 수행한다. 학습 결과 생성된 네트워크, 퍼지 규칙 및 환경 변수들은 다음 사용을 위해 저장할 수 있어, 다음에는 학습과정 없이 바로 저장된 파일을 로드하여 분류작업을 수행할 수 있다. 학습이 끝나면 실험화상 패턴파일을 읽어 들여 분류작업을 수행하고, 분류된 결과를 저장한다.

제안된 뉴로-퍼지 패턴 분류 시스템과 Maximum-likelihood와 신경회로망 패턴 분류시스템과의 보다 정확한 성능을 비교하기 위하여 실험 화상에서 지표면의 특징을 대표할 수 있는 8개 클래스에 대한 훈련집합을 그림 3(a)와 같이 선정하여 각각의 분류기를 이용하여 처리하였다. 본 실험에서는 4개의 파장대를 가진 항공촬영 화상에서 각 클래스를 대표하는 778개의 학습패턴을 선택하여 학습을 시켰으며, 학습한 결과를

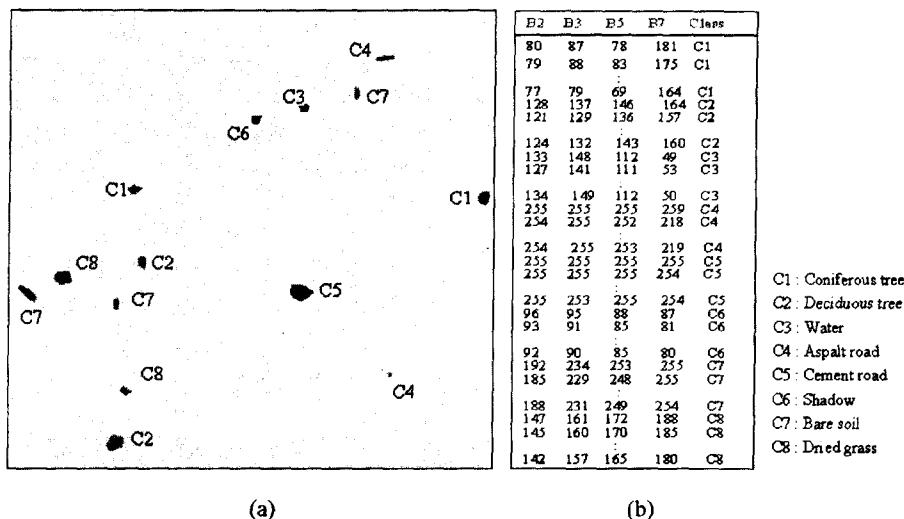


그림 3. (a) 항공촬영화상의 훈련집합으로 선정한 지역 (b) 파장대별 클래스의 DN(digital number)값

표 1. 훈련집합으로 선정된 클래스의 평균 및 표준편차

Class	Class Means				Class Standard Deviation			
	Band 2	Band 3	Band 5	Band 7	Band 2	Band 3	Band 5	Band 7
Coniferous tree	79.21	83.45	72.52	165.18	2.82	6.23	5.6	33.46
Deciduous tree	111.17	117.33	126.85	161.33	13.19	15.79	16.87	12.71
Water	145.167	170.94	153.44	99.62	20.35	33.17	38.31	38.6
Asphalt road	212.42	225.87	223.95	215.23	30.14	28.74	29.57	27.91
Cement road	232.38	239.14	242.14	243.76	38.84	28.66	23.45	20.29
Shadow	94.9	93.75	89.2	89.35	13.64	20.79	26.6	35.23
Bare soil	189.48	227.04	213.76	243.51	21.67	29.07	28.66	21.69
Dried grass	144.56	159.73	166.19	184.16	4.43	6.35	5.74	6.3

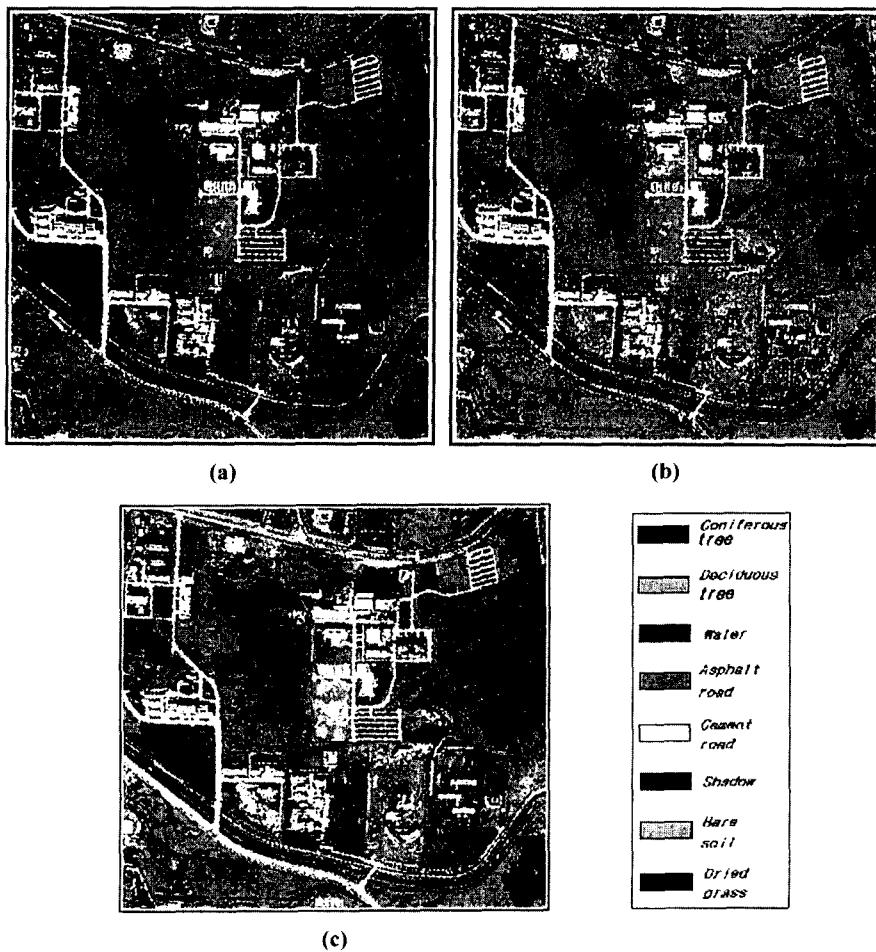


그림 4. (a)뉴로-퍼지, (b)Maximum-likelihood, (c)신경회로망 패턴 분류기를 이용한 분류결과

가지고 학습패턴을 포함한 159,900개의 패턴을 사용하여 분류하고자 하는 각각의 클래스로 분류하였다. 그럼 3(b)는 분류하고자 하는 클래스로 선정된 훈련집합의 과장대별 클래스의 DN(digital number)값을, 표 1은 평균값과 표준편차를 보여준다.

이와 같이 선정된 클래스의 훈련집합에 대하여 다음과 같이 각각의 분류기를 이용하여 분류하였다. 그림 4(a)는 뉴로-퍼지 패턴 분류기를 사용하여 분류한 결과를 보여준다. 먼저 훈련집합으로 선정된 패턴파일을 읽어, 4개 입력파장대의 영역을 12개의 퍼지집합으로 일정하게 분할하고, 뉴로-퍼지 알고리즘에 의해 학습을 시킨다. 뉴로-퍼지 분류기의 구조는 4개의 입력층, 12개의 은닉층, 그리고 8개의 출력층을 갖는 구조로 되어 있다. 학습결과 뉴로-퍼지 분류기는 778개의 생성된 퍼지 규칙들 중 표 2와 같이 104개의 퍼지규칙을 사용한다. 표 3은 학습결과 생성되는 퍼지

표 2. 훈련집합으로부터 생성된 퍼지규칙

- Rule 1:** If I1 is -3 and I2 is -3 and
I3 is -3 and I4 is 3 Then C1

Rule 2: If I1 is -3 and I2 is -3 and
I3 is -3 and I4 is 2 Then C1

Rule 3: If I1 is -3 and I2 is -3 and
I3 is -4 and I4 is 3 Then C1

.....
.....
.....

Rule 102: If I1 is 2 and I2 is 2 and
I3 is 3 and I4 is 3 Then C8

Rule 103: If I1 is 2 and I2 is 2 and
I3 is 3 and I4 is 4 Then C8

Rule 104: If I1 is 1 and I2 is 2 and
I3 is 2 and I4 is 4 Then C8

삼각소속함수의 변수 값을 보여준다. 778개의 훈련집합을 가지고 학습과정을 수행한 후 159,900개의 실험

표 3. 퍼지 삼각소속함수에 의한 생성된 변수들

Band 2			Band 3			Band 5			Band 7			Fuzzy sets
a	b	c	a	b	c	a	b	c	a	b	c	
0.000	19.615	39.230	0.000	19.615	39.230	0.000	19.615	39.230	0.000	19.615	20.472	-6
19.615	39.230	58.415	19.615	39.230	58.846	19.615	39.230	40.069	19.615	20.472	81.260	-5
39.230	58.415	75.837	39.230	58.846	58.846	39.230	40.069	96.429	20.472	81.260	81.260	-4
58.415	75.837	103.031	58.846	58.846	108.574	40.069	96.429	96.429	81.260	81.260	81.260	-3
75.837	103.031	110.101	58.846	108.574	108.574	96.429	96.429	115.352	81.260	81.260	137.336	-2
103.031	110.101	110.101	108.574	108.574	132.570	96.429	115.352	115.352	81.260	137.336	137.337	-1
110.101	110.101	179.286	108.574	132.570	139.639	115.352	115.352	138.679	137.336	137.337	154.677	1
110.101	179.286	179.286	132.570	139.639	182.346	115.352	138.679	194.395	137.337	154.677	154.677	2
179.286	179.286	179.286	139.639	182.346	200.368	138.679	194.395	194.395	154.677	154.677	213.833	3
179.286	179.286	236.932	182.346	200.368	200.368	194.395	194.395	212.263	154.677	213.833	237.579	4
179.286	236.932	236.932	200.368	200.368	254.997	194.395	212.263	240.733	213.833	237.579	248.989	5
236.932	236.932	255.000	200.368	254.997	255.000	212.263	240.733	255.000	237.579	248.989	255.000	6

화상을 가지고 분류를 한다. 여기서 뉴로-퍼지 분류기는 훈련집합에 대해서 97.30%, 실험화상에 대해서 93.23%의 분류 정확도를 보여주고 있다.

일반적으로 제안된 시스템의 성능평가를 위해서는 학습패턴과 실험패턴이 전혀 다른 새로운 데이터를 이용하는 것이 보통이지만, 원격탐사자료의 지표면과 같은 영역패턴을 분류하는데 있어서 학습패턴자료는 분류하고자 하는 전체자료에서 각각의 특징을 대표할 수 있는 자료를 샘플링하여 설정하게 된다. 실험패턴 159,900개에서 학습패턴 778개를 뺀 나머지 실험패턴 159,122개를 가지고 실험을 하여도 분류결과는 같다.

뉴로-퍼지 분류기에서 사용했던 훈련집합과 실험화상을 가지고 Maximum-likelihood 분류기를 이용하여 분류하였다. 그림 4(b)는 Maximum-likelihood 분류기를 사용하여 분류한 결과를 보여준다. Maximum-likelihood 분류기는 훈련집합에 대해 95.8%, 실험화상에 대해 88.7% 정확성의 분류결과를 보였다. 역전파 학습알고리즘을 이용한 신경회로망의 패턴 분류에서 신경망은 반복적으로 연결가중치를 조정하며 38,000번 학습을 수행했다. 그림 4(c)는 신경회로망을 사용하여 분류한 결과를 보여준다. 신경회로망 분류기는 훈련집합에 대해 96.1%, 실험화상에 대해 90.3% 정확성의 분류결과를 보였다.

4. 결론 및 향후 연구

본 논문에서는 원격탐사자료의 지표면 특징분류를 위해 새로운 뉴로-퍼지 알고리즘을 제안하여, Visual C++(V5.0)을 사용하여 구현하였으며, 기존에 가장 많이 사용되어 왔던 Maximum-likelihood와 신경회로망 분류기와의 패턴 분류의 정확성 측면에서 비교 실험을 수행하였다. 실험 자료로 AMS센서에 의해 항공촬

영된 화상으로부터 전문가에 의해 추출된 훈련집합에 대해 학습시킨 다음, 전체 화상에 대해 적용하여 정확성을 분석한 결과 뉴로-퍼지 알고리즘을 이용한 패턴 분류법은 93.2%, Maximum-likelihood 분류법은 88.7%, 신경회로망을 이용한 분류법은 90.3%의 정확도를 보였다. 이것은 입력자료의 분포가 정규분포를 이루고 있어야 한다는 가정이 필요한 Maximum-likelihood 분류법이 지니고 있는 문제점과 학습시 초기 변수의 설정이 성능에 크게 영향을 미치는 신경회로망 분류법이 지니고 있는 단점을 보완했기 때문이다. 하지만 제안된 뉴로-퍼지 패턴분류 시스템에서는 퍼지 규칙들을 생성하고, 최적의 퍼지 규칙을 찾아내는데 있어서 적당하지 못하다. 앞으로 유전자 알고리즘을 뉴로-퍼지 알고리즘에 적용하여 패턴분류 문제에 있어서 최적의 퍼지 규칙을 찾아내는 연구가 계속 이루어져야 할 것이다.

감사의 글

본 논문은 1998년도 한남대학교 교비 학술연구비 지원에 의해 수행되었습니다.

참고문헌

- [1] American Society of Photogrammetry, *Manual of Remote Sensing*, Falls Church, Va., 1985.
- [2] J. Adinarayana and N. Rama krishna, "Integration of multi-seasonal remotely-sensed images for improved landuse classification of a hilly watershed using geographical information systems," *Int. J. Remote Sensing*, vol. 17, No. 9, pp. 1679-1688, 1996.
- [3] G. M. Foody, "Approaches for the production and evaluation of fuzzy land cover classifications from remotely-sensed data," *Int. J. Remote Sensing*, vol. 17,

- No. 7, pp. 1317-1340, 1996.
- [4] F. Maselli, C. Conese, Ljiljana and R. Resti, "Inclusion of Prior Probabilities Derived from a Nonparametric Process into the Maximum-Likelihood Classifier," *Photogrammetric Engineering & Remote Sensing*, vol. 58, No. 2, pp. 201-207, Feb. 1992
- [5] Sang Gu Lee and Jong Gyu Han, "Land Surface Classification of Landsat 5 TM Data Using SOFM and GA," in *Proc. of the IASTED Int. Conf. Artificial Intelligence and Soft Computing*, May 27-30, 1998, Cancun, Mexico.
- [6] J. D. Paola and R. A. Schowengerdt, "A Detailed Comparison of Backpropagation Neural Network and Maximum-Likelihood Classifier for Urban Land Use Classification," *IEEE Trans. Geosci. and Remote Sensing*, vol. 33, pp.981-996, July 1995.
- [7] S. Gopal and C. Woodcock, "Remote Sensing of Forest Change Using Artificial Neural Networks," *IEEE Trans. Geosci. And Remote Sensing*, vol. 34, No. 2, pp.398-404, March 1996.
- [8] T. A. Warner and M. Shank, "An Evaluation of the Potential for Fuzzy Classification of Mutispectral Data Using Artificial Neural networks," *Photogrammetric Engineering & Remote Sensing*, vol. 63, No. 11, pp. 1285-1294, November 1997.
- [9] M. Smith, *Neural Networks for Statistical Modeling*, pp. 95-98, Van Nostrand Reinhold, New Work, 1993.
- [10] Chin-Teng Lin and C. S. George Lee, *Neural Fuzzy Systems*, Prentice Hall 1996.
- [11] Wonkyu Park and Heung-Kyu Lee, "Fuzzy Logic Based Satellite Image Classification Using Automatically Generated Fuzzy Membership Functions and Rules from Training Set," *Journal of the Korean Society of Remote Sensing*, vol. 13, No. 3, pp. 231-249, 1997.
- [12] Sang Gu Lee, Jong Gyu Han and et al., "A Neuro-Fuzzy Classifier for Land Cover Classification," *FUZZ-IEEE '99*, Seoul, Korea, vol. 2, pp. 1063-1068, Aug. 1999.

한종규 (Jong Gyu Han)

1996년 : 한남대학교 컴퓨터공학과 졸업
(공학사)

1999년 : 한남대학교 컴퓨터공학과 졸업
(공학석사)

1999년~현재 : 충북대학교 컴퓨터과학과
(박사과정)

1995~현재 : 한국자원연구소 지구환경
연구부 연구원

관심분야 : 인공지능, 원격탐사, 영상처리, 지리정보시스템, 공간데이터 마이닝, 전문가 시스템

이상구 (Sang Gu Lee) 정회원

1978년 : 서울대학교 전자공학과(공학사)
1981년 : 한국과학기술원 전산학과(이학
석사) 일본, 와세다대학 전기
전자컴퓨터공학과(공학박사)

1996~1998년 : IASTED ASC Interna-
tional Program Committee
1983~현재 : 한남대학교 컴퓨터전자
통신공학부 교수

관심분야: 신경망회로, 퍼지이론, 뉴로-퍼지, 병렬처리, 컴퓨터 구조