

보로노이 공간분류를 활용한 원격 영상 패턴분류 시스템

백 주현[†]·김홍기^{††}

요약

본 논문은 보로노이 공간분류를 활용하여 원격탐사 영상인식을 위한 다층 신경망 분류기를 제안한다. 제안된 다층 신경망 분류기는 보로노이 다각형 영역으로 클래스를 구분하며, 초평면 방정식의 계수를 오류 역전과 학습 초기의 연결 강도, 임계치 그리고 은닉층의 노드 수로 결정한다. 제안된 방법은 오류역전과 학습 알고리즘에서 임의로 정해주던 초기 정보를 사전 분석에 의해 공학적으로 결정함으로써 느린 수렴 속도와 학습실패 등의 단점을 피할 수 있는 장점이 있다. 보로노이 다이어그램에 대한 경계선의 초평면 방정식은 훈련집합의 클래스별 평균 값을 구하여 Mathematica 패키지로 계산하였다. 제안된 다층 신경망에 의한 영상 분류기의 인식능력을 평가하기 위하여 원격탐사 영상인식에서 자주 활용되는 최소거리 분류 방법과 최대우도 분류 방법으로 처리해서 비교한 결과, 최소거리 분류 방법은 실험화상에 대해 81.4%, 최대우도 분류기에 의한 분류는 87.8%, 제안한 방법은 92.2% 정확성을 가진 분류결과를 나타냈다.

Pattern Classification System for Remote Sensing Data using Voronoi Diagram

Ju Hyun Back[†]·Hong Gi Kim^{††}

ABSTRACT

In this paper, we propose a multi layer neural network for recognition of remote sensing data by a Voronoi diagram. The proposed multi-layer neural network distinguishes the classes with the Voronoi polygon area and initializes error back propagation's initial learning of connecting weights, thresholds and the number of hidden layers' nodes with the coefficient of hyper plane equation. The proposed method systematically decides the initial information of error back propagation, so that it have the advantage of improving the slow convergence and local minima of error back propagation. We calculated the hyper plane equation of boundary edges of the Voronoi diagram by converting the mean of each class of training sets into a Mathematica package. To measure the performance of the recognition power by the image classifier, which uses the multi-layer neural network proposed above, we compared it with minimum distance classification and maximum likelihood classification, which is frequently used in the recognition of remote sensing data. The results of minimum distance classification and maximum likelihood classification were 81.4%, 87.8% respectively for the majority of land cover features, while the an accuracy of the proposed method was 92.2%.

키워드 :원격영상, 보로노이 공간분류, 패턴분류, 영상인식

1. 서론

원격 탐사란 대상물에 직접적으로 접촉하지 않고 항공기나 인공위성에 탑재된 계측기를 통해서 지상물체의 특성을 파악하고자 하는 모든 활동을 의미한다. 일반적으로 모든 물질은 전자기파 중 특정한 파장의 전자를 흡수하거나 반사하는 고유한 특성을 가지는데, 이러한 성질을 그 물질의 분광 특성이라고 하며 분광 특성에 의해 파장 대에 따라 반사 또는 복사되는 비율이 달라지기 때문에 각 물체마다 분광반사율(spectral reflectance)이 다르다는 성질을 이용하여 물체를 판별할 수 있다. 원격 영상을 처리하여 인식하는 과정은 관측, 전처리, 특징추출, 그리고 식별단계로 크게 구

분해 볼 수 있다. 특히 원격 탐사자료는 관측시의 기기 상태, 대기조건, 위성의 이동 방향 및 자세, 최종적으로 사용할 지도의 투영법 등에 따라 오류 및 왜곡을 포함하게 된다. 따라서 이러한 에러요소들을 감쇄시키거나 제거하기 위한 전처리 과정이 필요하다. 전처리 과정은 대기의 영향을 배제하기 위하여 복사 전달과정에서 일어나는 대기의 영향을 측정하고 수정, 복원하는 방사보정(radiometric correction)과 수집된 영상의 기하학적 형태가 기준 지도와의 사이에 차이가 있는 경우 이를 보정하는 기하학적인 보정(geometric correction)이 있다. 원격 탐사자료를 이용하여 영상을 추출하고 분류하는 대표적인 방법으로는 평행육면체 분류기법(Parallelepiped Classification : PLC), 최단거리 분류기법(Minimum Distance to Means Classification : MDC), 최대우도 분류기법(Maximum Likelihood Classifi-

† 정희원: 군장대학 컴퓨터응용학부 교수

†† 정희원: 충북대학교 컴퓨터과학과 교수
논문접수: 2001년 5월 7일, 심사완료: 2001년 8월 13일

cation : MLC)과 같은 감독분류(supervised classification)와 K-means 방법, ISODATA(Iterative Self Organizing Analysis Technique)분류 등의 무감독분류(unsupervised classification)를 이용한 방법이 있고, 기타 퍼지로직을 이용한 분류방법과, 신경망의 응용, 보조자료를 이용한 혼성 방법 등이 연구되어지고 있다[1-3]. 이 중에 어떤 알고리즘을 선택할 것인가 하는 것은 분석할 영상의 특징과 분석자가 원하는 결과가 무엇인지에 따라 선택할 수 있다.

한편 보로노이 다이어그램(Voronoi Diagram : 이하 VoD)은 계산기하학(computational geometry)에서 매우 중요한 기하구조로서 계산기하학상의 많은 문제를 푸는 열쇠로 사용되고 있다[4]. VoD는 N개의 점으로 구성된 집합 S가 주어진 경우, 임의의 점이 집합 S에 있는 가장 근거리의 점으로 포함될 수 있도록 각 점들을 수직 이등분한 경계선으로 구분해 놓은 평면이다. 1993년 Bose와 Garga는 다층 신경망 구성에서 각 층간의 초기 연결 강도와 은닉층의 노드 수를 미리 VoD를 이용하여 공학적인 계산으로 정할 수 있는 방법을 제안했다[5]. 즉 분류하고자 하는 패턴들을 서로 보로노이 다각형으로 공간 분류한 후, 보로노이 경계선의 방정식을 계산하여 이들의 계수를 초기 연결 강도로 정하며, 같은 패턴 집합이 두 개 이상의 서로 분리된 다각형 영역일 경우 논리적 AND 노드로 연결한다. 그러나 Bose와 Garga가 제안한 방법으로 설계된 신경망은 새로운 입력 패턴이 발생하면 학습능력이 부여되지 않아 다시 전체 신경망의 연결 강도를 수정해 주어야 하는 단점이 있다. 따라서 전체 집합이 주어진 패턴분류에는 적용할 수 있으나, 훈련집합을 갖고 학습이 필요한 패턴분류, 즉 원격 탐사에 의한 영상인식과 같이 훈련집합을 선정하여 전체 데이터를 인식하는 응용분야에는 적용하기 어렵다.

다층 신경망에서 일반화된 엘타규칙을 적용하는 오류 역전파(Error Back-Propagation : 이하 EBP) 학습은 인공지능을 활용한 제어에 관련된 문제나 패턴인식 문제에 매우 훌륭한 성능을 보이고 있어 자주 활용되고 있다. 그러나 EBP는 은닉 층의 노드 수와 초기 연결 강도를 설계자의 경험에 의해 임의의 값으로 선택함으로써 학습속도가 현저히 떨어지거나 지역 최소치(local minima)에 빠져 학습에 실패할 수 있다는 것은 이미 잘 알려진 사실이다[6-8]. 이러한 단점을 보완하기 위한 방법으로 엘타규칙의 수정, 동적인 학습률 재조정, 경사치의 재사용 등의 다양한 연구가 진행되어 왔다[9, 10].

본 연구에서는 원격 탐사에 의한 영상자료를 패턴분류하기 위한 다층 신경망을 제안한다. 제안된 다층 신경망은 EBP 학습 알고리즘의 학습속도와 학습 실패에 영향을 미치는 초기 연결 강도, 임계치 그리고 은닉층의 수를 VoD를 활용하여 공학적인 계산에 의하여 미리 설정해 준다. VoD에 의한 EBP 학습 알고리즘의 학습속도와 수렴 결과를 확

인하기 위해 본 연구에 앞서 실증한 결과 XOR 문제의 학습횟수는 학습률에 따라 각각 6.4~9.1배, 3 차원 패리티 문제에서는 58~133배정도 빠르게 학습이 종료되었고, 학습실패 경향도 전혀 발생하지 않았다[11].

본 논문의 구성은 2장에서 기존의 원격탐사 영상 분류 알고리즘을 살펴보고, 3장에서는 제안하는 VoD를 활용하여 EBP에 의한 학습 가능한 원격 영상 인식 시스템의 구성에 대해 밝히고, 4장에서는 제안된 원격영상 인식 시스템의 효율성을 보이기 위해 위성영상을 분류할 때 성능 평가를 위해서 기준 척도로 가장 많이 사용되는 최대우도 분류기법, 최소 거리 분류 기법에 의한 방법과 비교한 자료를 표와 그림을 통해 제시하며 5장에서는 결론 및 향후 연구방향을 기술한다.

2 원격탐사 영상 분류 알고리즘

원격탐사 영상자료를 통하여 지형의 형태를 분석하거나 각종 농작지역 분포도 등 각각의 클래스로 구분하기 위한 분류 알고리즘은 크게 감독분류와 무감독분류로 구별할 수 있다. 감독분류는 각 특징에 대한 훈련집합과 같은 사전 지식을 이용하여 분류하는 것을 의미하며, 무감독분류는 사전 지식이 없거나 구하기가 힘든 경우 영상에 대한 기본적인 가정을 가지고 분류하는 것을 의미한다. 감독분류는 분석자의 직접적인 작업상의 제어로 이루어진다. 이 과정에서 인식 가능한 토지피복 형태들이나 그 외 다른 형태의 패턴을 표현하는 픽셀들을 시각을 이용하여 직관적으로 선택하거나, 항공사진, 지상실측자료, 주제도 등을 참조하여 선택하여야 한다. 그 다음 이렇게 인식된 패턴에 따라 컴퓨터 시스템을 이용한 픽셀 값과 선택한 패턴간의 상관성에 기초한 통계 계산 과정을 거치게 된다.

무감독분류는 감독분류에 비해 좀 더 컴퓨터 시스템에 의존적인 방법이다. 이 방법은 컴퓨터가 자료내의 패턴들의 범주를 스스로 정의하여 군집화(clustering) 하므로 영상 내에서 서로 유사한 분광패턴을 찾는 유용한 방법으로 이용되기도 한다. 또한 이 방법은 분류하고자 하는 영상 지역에 대해 별로 아는 바가 없을 경우에 많이 이용되며, 감독분류를 시행하기 이전에 참조자료로 이용하기 위해서 수행하는 방법이다[12, 13].

2.1 최대우도 분류기법(Maximum Likelihood Classification : MLC)

최대우도 분류방법은 원격탐사 영상자료를 분류할 목적으로 가장 일반적으로 자주 사용하는 감독분류이다. 각 훈련지역의 클래스가 정규분포를 이루고 있다고 가정을 하고, 분류하고자 하는 픽셀을 각 훈련지역 클래스에 대한 가능성 P_c 를 계산한 후 최대의 가능성을 갖는 클래스로 분류하는 방

법이다. 이는 각 클래스에 대한 확률 밀도 함수(Probability Density Function : pdf)가 입력패턴들의 발생을 보다 근사화 할 수 있다면 정확한 패턴 정합 값을 얻는 장점이 있다.

영상자료 분류에 다른 알고리즘을 적용할 때 최대우도 분류는 클래스의 확률 밀도 함수가 정규분포에 따른다고 가정하였을 때 최적의 분류 결과를 보여줌으로써 성능 평가를 위해서 가장 많이 비교되는 대표적인 분류척도이기도 하다[14].

조건부 확률에 근거한 베이지안 분류는 주어진 픽셀 x 가 클래스 i 에 속하기 위해서는 조건부확률 $P(\omega_i | x)$ 가 전체 모든 클래스 $i=1 \dots M$ 에 적용하여 다음 수식을 만족해야 한다.

$$x \in \omega_i \quad \text{if } P(\omega_i | x) > P(\omega_j | x) \quad \text{for all } j \neq i \quad (1)$$

그러나 조건부확률 $P(\omega_i | x)$ 은 실제로 계산이 불가능하므로 각 클래스에 대한 훈련 샘플자료가 충분히 있다는 가정 하에 구역 x 에 대하여 클래스 ω_i 로부터 하나의 픽셀을 발견할 수 있는 기대 값의 확률분포를 계산할 수 있다. 즉 여러 개의 랜드를 갖는 다중 분광해상도 밝기 값을 갖는 영역에서 구역 x 에 해당 픽셀이 존재할 확률 $P(x | \omega_i)$ 는 그 픽셀이 각각의 클래스에 속할 상대적 우도(Likelihood)로 구할 수 있다. 따라서 베이지안 조건부확률에 의해 $P(\omega_i | x)$ 는

$$P(\omega_i | x) = \frac{P(x | \omega_i) \cdot P(\omega_i)}{p(x)} \quad (2)$$

로 변환되고 $P(\omega_i)$ 는 훈련 지역 영상자료에서 클래스 ω_i 가 차지하는 전체확률이다. 식 (2)를 베이지안 분류에 적용시켜 공통인자 $p(x)$ 를 제거하면 식 (1)은 다음과 같이 바꿀 수 있다.

$$x \in \omega_i \quad \text{if } P(x | \omega_i) \cdot P(\omega_i) > P(x | \omega_j) \cdot P(\omega_j) \quad \text{for all } j \neq i \quad (3)$$

이제 훈련자료를 통하여 $P(x | \omega_i)$ 를 구할 수 있으므로 식 (1)은 식 (3)으로 대체하여 판별할 수 있다. 수학적인 편리성을 위하여 양변에 단조증가 함수인 자연로그를 취하여

$$\begin{aligned} g_i(x) &= \ln P(x | \omega_i) \cdot P(\omega_i) \\ &= \ln P(x | \omega_i) + \ln P(\omega_i) \end{aligned}$$

라 하면

식 (3)은 최대우도 판별함수 $g_i(x)$ 에 의하여

$$x \in \omega_i \quad \text{if } g_i(x) > g_j(x) \quad \text{for all } j \neq i \quad (4)$$

으로 클래스 i 에 속하는 결정규칙을 정할 수 있다.

총 N 개의 랜드에 대하여 각 클래스에 속하는 훈련자료의 확률밀도함수가 정규분포를 이룬다고 가정하면

$$\begin{aligned} P(x | \omega_i) &= (2\pi)^{-\frac{N}{2}} |\Sigma_i|^{-\frac{1}{2}} \\ &\exp\left\{-\frac{1}{2}(x - m_i)' \Sigma_i^{-1} (x - m_i)\right\} \end{aligned} \quad (5)$$

이며 m_i 와 Σ_i 는 각각 클래스 ω_i 에서의 평균벡터와 공분산 행렬이다. 따라서 판별함수 $g_i(x)$ 는

$$\begin{aligned} g_i(x) &= \ln P(\omega_i) - \frac{N}{2} \ln(2\pi) - \frac{1}{2} \ln |\Sigma_i| \\ &- \frac{1}{2}(x - m_i)' \Sigma_i^{-1} (x - m_i) \\ &\approx \ln |\Sigma_i| - (x - m_i)' \Sigma_i^{-1} (x - m_i) \end{aligned} \quad (6)$$

만약 모든 클래스에 대한 사전확률이 동일하다고 가정하면 각각의 입력패턴은 가장 높은 사후확률 소속도를 갖는 클래스에 할당된다.

2.2 최소거리 분류기법(Minimum Distance to Means Classification : MDC)

최대우도 분류법의 효율성을 위해서는 파라미터로 사용된 각 분광클래스의 평균벡터 m_i 와 공분산행렬 Σ_i 를 정확하게 측정해야 한다. 이는 각 클래스들에 대한 훈련픽셀들이 충분히 존재해야 한다는 조건이 필요하다. 그러나 영상자료의 훈련집합을 해당지역에 대하여 충분하게 갖고 있지 못하는 경우에 특히 평균 m_i 보다 공분산 행렬 Σ_i 의 정보가 신뢰성을 잃게되어 최대우도 분류방법을 신뢰할 수 없게 된다. 따라서 자료가 충분하지 못한 경우 공분산 행렬을 제외하고 파라미터를 평균값으로만 이용한 최소거리 분류법을 대안으로 사용할 수 있다. 즉 각 클래스의 평균과의 거리를 구하여 해당 픽셀을 클래스에 할당하는 기법이다. 최소거리 분류법은 최대우도 분류법에 비하여 매우 빠르게 진행되나 전체 분광도메인(spectral domain)내에서 자료의 흘어짐 정도가 일정하게 대칭을 이루 것이라는 전제조건을 두고 있다. 훈련자료로부터 총 M 개의 클래스에 대한 평균 m_i 를 구한 후 각 픽셀이 해당 클래스에 속할 최소거리 판별함수는 식 (7)과 같이 유clidean 거리로 계산한다.

$$x \in \omega_i \quad \text{if } d(x, m_i)^2 < d(x, m_j)^2 \quad \text{for all } j \neq i \quad (7)$$

유크리디안 거리로 사용된 판별함수 $g_i(x)$ 는

$$\begin{aligned} g_i(x) &= d(x, m_i)^2 = (x - m_i) \cdot (x - m_i) \\ &= x \cdot x - 2m_i \cdot x + m_i \cdot m_i \\ &\approx 2m_i \cdot x - m_i \cdot m_i \end{aligned} \quad (8)$$

이고 최소거리에 대한 개념으로 바꾸면 식 (8)로 바꾸어 판별할 수 있다.

최소거리 분류법은 일차선형 분류기법이므로 다중분광 랜드의 분류에는 최대우도 분류법에 비해 성능이 많이 저하

되지만 훈련샘플 수가 제한되어 있는 경우에는 오히려 우수한 결과를 보인다. 위성탐사 영상자료의 분류를 위하여 유clidean 거리를 이용한 최소거리 분류 패키지로 Orser(Borden et al 1977), Larsys(Phillipps 1973), 그리고 Multi-spec 등이 있다.

2.3 다층 신경망 분류기법(Multi Layer Neural Network)

비선형 시스템을 모델링하고 식별하는데 자주 이용되는 신경망의 모델은 EBP 학습법을 이용한 다층 신경망이다. 다층 신경망의 EBP 학습 알고리즘은 학습을 통해 뉴런들 간의 연결 강도를 조정하여 문제를 해결하고자 하는 감독 학습 알고리즘이다. 즉 출력층의 목적값과 네트워크의 실제 출력값 사이의 오차를 계산하여 네트워크의 파라미터를 조정한다. 활성화 함수는 비선형 함수를 사용한다. 역전파 학습 알고리즘은 최급 강하법을 이용하여 오차제곱의 합이 최소화 되도록 신경망의 연결강도를 반복적으로 변화시켜 나간다. 역전파 알고리즘으로 학습되는 신경망은 고도의 비선형 구조를 파악할 수 있다. 원격탐사 영상인식을 위해서는 영상의 분광영역 개수에 따라 입력층의 노드 수를 결정하고 분류하고자 하는 클래스의 개수에 따라 출력층의 노드 수를 설정해 준다. 초기 신경망의 상태를 결정하는 연결 강도 W_{ij} , W_{jk} 와 바이어스 θ_i , θ_k 를 각각 임의의 수로 초기화하고, 각각의 분광영역 훈련 데이터를 학습 패턴의 값으로 입력층 노드에 투입하여 입력층과 중간층 사이의 연결강도 W_{ij} 와 중간층 노드 j 의 오프셋 θ_j 를 이용하여 중간층 노드 j 의 입력 net_{jp} 와 중간층 노드 j 의 출력 Z_{jp} 를 구한다.

$$net_{jp}^k = \sum W_{ij} O_{ip} + \theta_j, \quad Z_{jp} = f_j(net_{jp}^k) \quad (9)$$

식 (10)에 의해 출력층 노드 k 의 출력 O_{kp} 를 구하고, 훈련영상에 대한 밴드 값과 실제 출력 O_{kp} 와의 오차로부터 출력층 노드 k 에 연결된 연결강도와 출력층 노드 k 의 오프셋에 대한 오차 δ_{kp} 를 구한다.

$$net_{kp}^o = \sum W_{jk} Z_{jp} + \theta_k, \quad O_{kp} = f_k(net_{kp}^o) \quad (10)$$

$$\begin{aligned} \delta_{kp}^o &= (T_{kp} - O_{kp}) f'_k(net_{kp}^o) \\ &= (T_{kp} - O_{kp}) O_{kp} (1 - O_{kp}) \end{aligned} \quad (11)$$

$$\delta_{jp}^k = f'_j(net_{jp}^k) \sum_k \delta_{kp}^o W_{jk} = Z_{jp}(1 - Z_{jp}) \sum_k \delta_{kp}^o W_{jk} \quad (12)$$

오차 δ_{jp} 는 식 (12)의 미분식으로 구하고, 출력층 노드 k 의 오차 δ_{kp} 와 중간층 노드 j 의 출력 Z_{jp} 을 이용하여 중간층 노드 j 와 출력층 노드 k 에 연결된 연결강도 W_{jk} 를 수정한다.

$$w_{jk}^o(t+1) = w_{jk}^o(t) + \eta \delta_{kp}^o Z_{jp} \quad (13)$$

마찬가지로 중간층 노드 j 의 오차 δ_{jp} 입력층 노드 i 의 출력 O_{ip} 을 이용하여 입력층 노드 i 에 연결된 연결 강도 W_{ij} 를 수정한 후, 다음 패턴을 학습시킨다.

$$w_{ij}^k(t+1) = w_{ij}^k(t) + \eta \delta_{ip}^k O_{ip} \quad (14)$$

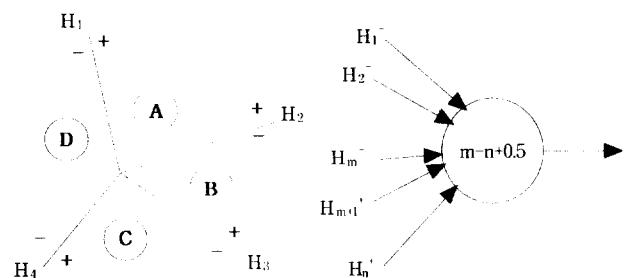
오차 제곱합 즉 $E_p = \frac{1}{2} \sum_{k=1}^M (T_{kp} - O_{kp})^2$ 의 값이 허용치 안에 들어가는 아주 작은 값이 되면 학습을 중지하고, 그렇지 않으면 위의 과정을 반복한다. 여기서 η 는 학습 상수(률)이다.

EBP에서 활성화 함수로 사용되는 시그모이드 함수는 신경망의 임계 함수적인 동작을 잘 표현할 뿐만 아니라 미분 가능하고 수학적으로 편리한 특성을 가지므로 EBP 학습 알고리즘에서 중요한 위치를 차지하고 있다. 그러나 학습자료에 이상치가 존재하는 경우 신경망에 의해 측정된 함수는 이상치 주변에서 진동하게 된다. 따라서 지역 최소치에 빠질 우려가 있으며, 초기 값을 임의로 설정해 주므로 성능 전체에 크게 영향을 줄 수 있고 학습시 시간이 오래 걸리는 단점이 있다[10, 15-19].

3. 보로노이 공간분류에 의한 원격영상 인식 분류 기의 설계

보로노이 다각형이란 집합 S 에서 어떠한 다른 점보다도 P_i 에 근접한 점 (x, y) 의 자취를 말하며, d 차원에 주어진 n 개의 점에 대해 보로노이 다각형으로 분할한 것을 VoD라 한다. 평면상에 주어진 n 개의 점으로부터 VoD를 구하는 방법은 Grahams Scan, Jarvis's march, Divide & Conquer Algorithm, Dynamic Convex hull Algorithm 등을 이용할 수 있다[20].

d 차원 특징공간에서 k 개의 서로 다른 클래스에 속하는 패턴집합이 있을 때 Bose와 Garga는 보로노이 다각형이 각각의 패턴을 나타내는 집합으로 구분하여 VoD를 이용한 신경망을 구성하는 방법을 제시하였다. 이에 따르면 각 클래스가 선형분리 가능한 경우와 하나의 패턴이 두개 이상의 클러스터들로 표현되는 경우 즉, 각 클래스들의 구분이 선형적으로 분리가 불가능한 경우로 구분하여 신경망을 구성하였는데, 전자의 경우는 보로노이 경계선인 초평면의 방정식을 $H_i = \omega_1 x_1 + \omega_2 x_2 + \dots + \omega_{d-1} x_{d-1} + \delta = 0$ 이라고 할때, 신경망을 구성하는 노드의 연결 강도는 방정식의 계수인 $\omega_1, \omega_2, \dots, \omega_{d-1}$ 으로 결정하고, 노드의 임계값은 δ 로 정해 준다[5].

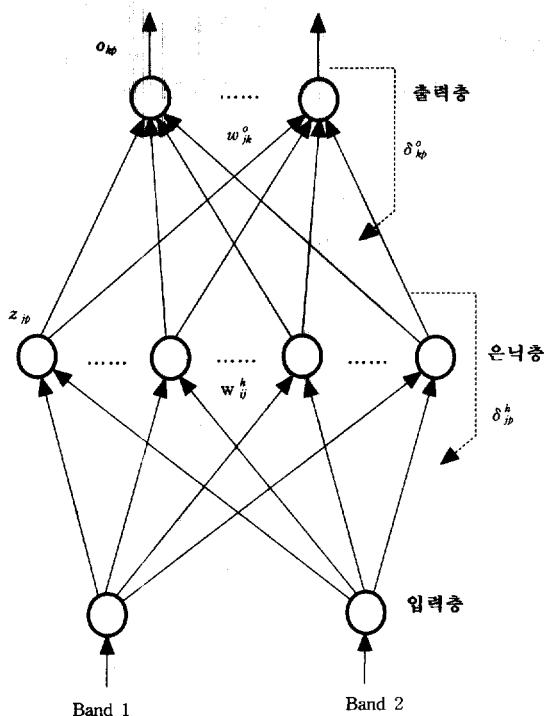


(그림 1) VoD에서 경계선에 의한 클러스터링

입력층에서 관련된 경계선의 영역에 의해 논리적 AND 연산으로 결합하여 출력층으로 정보를 전달하는데 초평면의 반폐구간에 따라 $H > 0$ 인 양의 영역에서의 노드 연결은 1, $H < 0$ 인 음의 영역에서의 노드 연결은 -1로 결정하고 출력층 노드의 임계값은 $m - n + 0.5$ 의 계산값으로 결정 한다. 여기서 m 은 $H < 0$ 에 속하는 경우의 노드 수이고 n 은 전체 연결 노드 수이다.

그러나 각각 클래스의 구분이 보로노이 다각형의 한 영역만으로 표현되지 않고, 하나의 보로노이 경계선만으로 선형적 분리가 불가능한 경우 은닉 층이 존재하는 다층 신경망으로 구성한다. 입력 층으로부터 은닉 층으로의 연결 강도와 노드의 임계치는 같은 방법으로 초평면의 방정식을 구하여 정해주고, 은닉 층에서 출력 층으로의 정보는 논리적 OR 연산으로 결합하여 계산한다. 이때 양의 영역으로 참여하는 연결에 대해서는 1, 음의 영역으로 참여하는 연결에 대해서는 -1로 정해주며 임계값은 $m - 0.5$ 로 계산한다. 여기서 m 은 1의 연결 강도를 갖는 은닉 층의 노드 수이다[5]. 한편 각 층에서의 노드의 활성화 함수로는 역치함수 즉, $f(\text{net}) = \begin{cases} 1, & \text{net} \geq 0 \\ 0, & \text{net} < 0 \end{cases}$ 을 이용한다.

본 연구에서는 VoD에 의한 다층 신경망이 활성화 함수로 역치함수를 사용하여 학습 능력을 갖지 못하는 단점을 시그모이드 함수로 대체하고 EBP의 학습 가능한 알고리즘을 적용하여 VoD_EBP에 의한 원격탐사 영상분류 시스템을 제안한다. 제안된 다층 신경망은 기본 구조로 (그림 2)와 같이 구성되어 있다.



(그림 2) 원격영상 분석을 위한 VoD_EBP의 구조

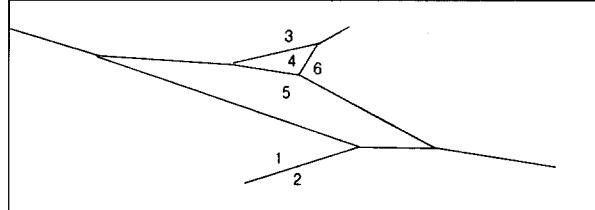
인식하고자 하는 지역의 훈련집합에 대해 각 클래스에 대한 VoD의 구성을 위해 밴드별 평균 값을 대표점으로 취하여 보로노이 경계선의 방정식을 계산해 주었다.

<표 1> 훈련데이터의 밴드별 평균과 표준편차

Class	Class Means				Class Standard Deviation			
	Band1	Band2	Band3	Band4	Band1	Band2	Band3	Band4
Forest	27.01	29.72	45.46	51.06	1.202	2.496	4.679	9.90
Water	33.93	38.14	27.06	28.72	5.11	8.82	8.52	17.29
Rice field	35.29	43.59	48.23	76.53	1.216	2.839	4.650	6.579
Rural area	43.696	59.101	52.558	93.035	3.851	6.552	5.368	12.319
Bare soil	36.99	50.56	50.64	104.80	3.832	6.239	4.720	13.651
Farm	38.63	56.87	54.01	96.60	2.923	5.532	6.980	12.796

<표 1>에 계산된 각 클래스에 대한 밴드별 평균값을 가지고 VoD를 구성하기 위해서 Mathematica(version4.0) 패키지를 이용하였다. (그림 3)은 그 결과로 Band1 과 Band4에 대하여 VoD를 통해서 얻은 훈련집합의 클래스 구분 영역을 보로노이 경계선으로 보이고 있다.

```
<< DiscreteMath`ComputationalGeometry`
data2D = {{27.013, 51.061}, {33.935, 28.715}, {36.989, 104.798},
          {38.626, 96.597}, {35.294, 76.531}, {43.696, 93.035}};
convexhull = ConvexHull[data2D]
{6, 3, 1, 2}
{delval = DelaunayTriangulation[data2D]}
{{1, {2, 5, 3}}, {2, {6, 5, 1}}, {3, {1, 5, 4, 6}}, {4, {5, 6, 3}}, {5, {1,
2, 6, 4, 3}}, {6, {3, 4, 5, 2}}}
{vorvert, vorval} = VoronoiDiagram[data2D];
```



(그림 3) VoD를 통해서 얻은 훈련집합의 경계선

(그림 3)에서 보인 VoD에서 각 클래스를 구분해 주는 보로노이 결점에 대한 (x, y) 좌표 값과 경계선의 방정식은 <표 2>와 같다.

<표 2> 결점의 좌표 값과 경계선의 방정식

보로노이 경계선	좌표 값		경계선의 방정식
	(X_1, Y_1)	(X_2, Y_2)	
H_{12}	(68.48, 51.66)	(30.47, 39.88)	$0.310X_1 + X_2 - 30.437 = 0$
H_{13}	(31.99, 155.85)	(-71.30, 97.11)	$0.569X_1 + X_2 - 137.658 = 0$
H_{15}	(-71.30, 97.11)	(68.48, 51.66)	$0.325X_1 - X_2 + 73.927 = 0$
H_{25}	(68.48, 51.66)	(106.69, 50.57)	$0.029X_1 - X_2 + 53.614 = 0$
H_{26}	(38.81, 60.87)	(106.69, 50.57)	$0.152X_1 - X_2 + 66.759 = 0$
H_{34}	(-1.23, 92.91)	(46.51, 102.43)	$0.199X_1 - X_2 + 93.155 = 0$
H_{35}	(-71.30, 97.11)	(-1.23, 92.91)	$0.060X_1 - X_2 + 92.836 = 0$
H_{36}	(46.51, 102.43)	(40.33, 98.91)	$0.570X_1 + X_2 - 75.939 = 0$
H_{45}	(-1.23, 92.91)	(35.53, 86.80)	$0.167X_1 - X_2 + 92.706 = 0$
H_{46}	(35.53, 86.80)	(46.51, 102.43)	$1.424X_1 + X_2 - 36.223 = 0$
H_{56}	(35.53, 86.80)	(106.69, 50.57)	$0.510X_1 - X_2 + 104.89 = 0$

보로노이 결점 좌표를 갖고 경계선에 대한 방정식을 구한 후 각 클래스의 구분 영역을 양, 음의 영역으로 정해 주면 EBP 신경망 구성을 위한 초기 정보를 모두 획득할 수 있다. VoD를 통해서 신경망을 구성할 때 입력층은 입력벡터의 차원으로 노드 수가 결정되고 은닉층과 출력층의 노드 수는 각각 VoD를 구성하는 모든 경계선 방정식의 개수와 구분하고자 하는 클래스의 개수로 정해준다. 따라서 위의 결과로 은닉층은 11개의 노드를 가지며 출력층은 6개의 노드 수로 결정된다. 대상지역의 영상인식을 위한 훈련 집합의 초기 다층 신경망의 연결 강도와 노드 임계 값은 <표 3>과 같다.

<표 3> VoD에 의한 초기 노드 임계 값

Layer	노드 수	Threshold
Hidden	11	30.437, 137.658, -73.927, -53.614, -66.759, -93.155, -92.836, 75.939, -92.706, 36.223, -104.89
Output	6	-0.5, 0.5, -3.5, -1.5, -1.5, -1.5

<표 4> VoD에 의한 초기 연결 강도

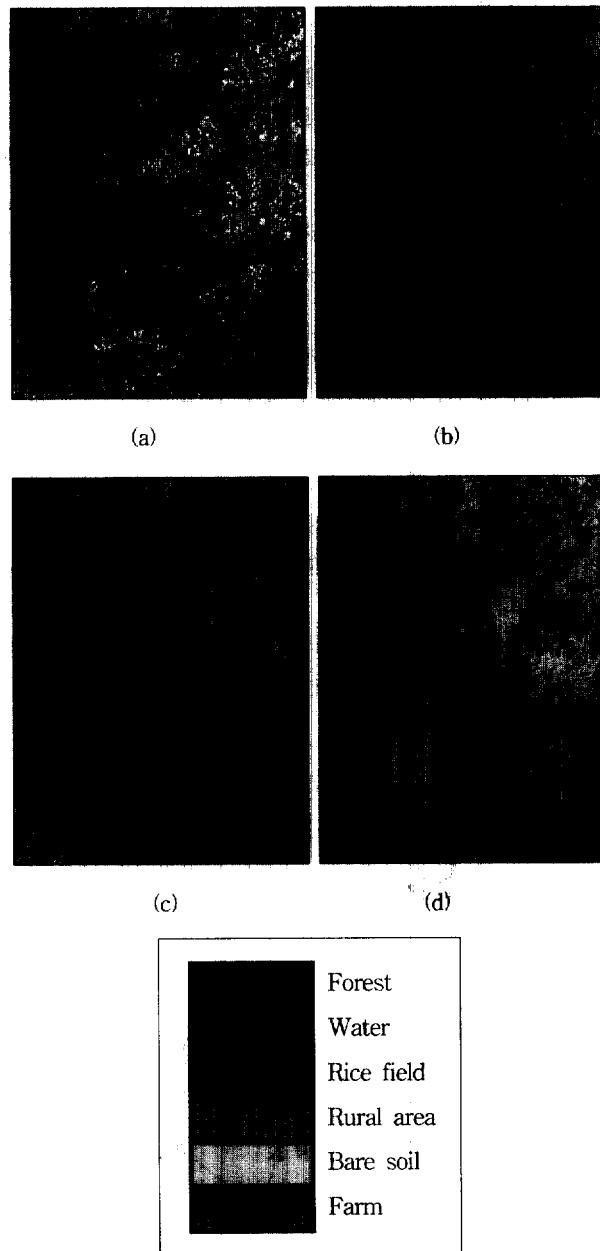
	Weight										
	H ₁	H ₂	H ₃	H ₄	H ₅	H ₆	H ₇	H ₈	H ₉	H ₁₀	H ₁₁
I ₁	.31	.57	.33	.03	.15	.20	.06	.57	.16	1.42	.51
I ₂	+1	+1	-1	-1	-1	-1	-1	+1	-1	+1	-1
O ₁	+1	-1	-1	0	0	1	0	0	0	0	0
O ₂	-1	0	0	-1	-1	0	0	0	0	0	0
O ₃	0	+1	0	0	0	+1	+1	+1	0	0	0
O ₄	0	0	0	0	0	0	0	0	+1	+1	0
O ₅	0	0	+1	+1	0	0	-1	0	-1	0	-1
O ₆	0	0	0	0	+1	0	0	-1	0	-1	+1

4. 실험결과 및 성능비교

제안한 VoD_EBP에 의한 원격영상 인식 시스템의 성능 평가를 위해서 기준 척도로 가장 많이 사용되는 최대우도 방법과 최소거리 방법으로 인식한 경우와 비교해 보았다. 실험에서 사용된 원격탐사 영상자료는 전남 영광군 원자력 발전소 일대를 LANDSAT Thematic Mapper(TM) 인공위성으로 2000년 3월에 촬영한 자료를 실험영상으로 이용하였다. 대상지역의 실제 지표면 상태를 파악하기 위하여 직접 답사하여 조사한 자료와 인공위성에 의해 촬영된 영상 자료를 비교하여 6443개의 훈련집합을 선정하였고, 분류할 대상 패턴으로는 6개(사진 수계 노 거주지역 토지 밖)의 클래스로 정하였다. 일반적으로 제안된 시스템의 성능 평가를 위해서는 학습패턴과 실험 패턴이 서로 다른 새로운 데이터를 이용하는 것이 보통이지만, 원격탐사 자료의 지표면과 같은 영역 패턴을 분류하는데 있어서 학습 패턴 자료는 분류하고자 하는 전체자료에서 각각의 특징을 대표하는 자료를 샘플링하여 선정하게 된다. 본 연구에서는 대상지역 중에서 6개 클래스를 모두 포함하는 지역을 선정하여 전체 304,695개(가로×세로 549×555) 픽셀의 영상자료를 실험

대상으로 하였다.

(그림 4)는 위성에서 촬영된 화상을 RGB 칼라로 합성한 화상이며, (a)는 직접 촬영된 자료의 원래의 화상이고 (b)와 (c)는 각각 최소거리 분류 시스템과 최대우도 분류시스템으로 인식한 그림이며, (d)는 본 연구에서 제안한 VoD_EBP에 의한 다층 신경망 분류시스템의 인식 결과이다.

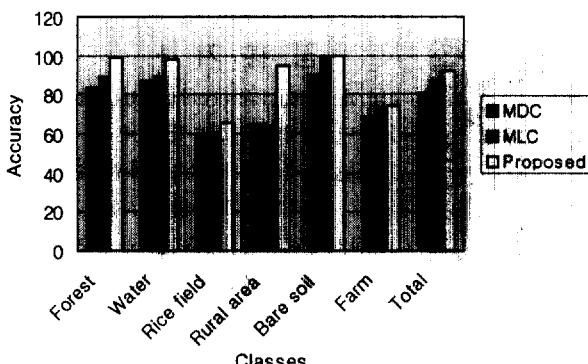


(그림 4) (a) 인공위성 영상자료 (b) 최소거리 분류시스템
(c) 최대우도 분류시스템 (d) VoD_EBP로 인식한 화상결과

<표 5>와 (그림 5)는 실험영상 자료로 사용된 전체 304,695개의 픽셀에 대하여 6개 클래스 별로 정확히 인식이 이루어진 픽셀을 최소거리 분류방법(MDC), 최대우도 분류방법(MLC)과 제안된 VoD_EBP에 의한 다층 신경망 방법에 의해 분류한 결과를 보이고 있다.

〈표5〉 실험영상 픽셀에 대한 정확한 분류 비율

분류	전체 픽셀 수	MDC		MLC		Proposed	
		인식된 픽셀 수	정확도 (%)	인식된 픽셀 수	정확도 (%)	인식된 픽셀 수	정확도 (%)
Forest	84,112	70,542	83.87	75,281	89.50	83,020	98.70
Water	17,251	15,013	87.03	15,411	89.33	16,881	97.85
Rice field	12,785	7,442	58.21	7,820	61.17	8,423	65.88
Rural area	9,610	6,254	65.08	6,154	64.04	9,161	95.33
Bare soil	113,359	102,328	90.27	112,945	99.63	113,156	99.82
Farm	67,578	46,443	68.73	49,912	73.86	50,369	74.53
Total	304,695	248,022	81.40	267,523	87.80	281,009	92.23



(그림 5) 실험영상 픽셀에 대한 정확한 분류 비율 그래프

5. 결론 및 향후 연구방향

본 연구에서는 원격탐사 자료의 지표면 특징분류를 위해 VoD_EBP를 이용한 다층 신경망 영상 분류기를 제안하였다. 다층 신경망을 이용한 원격 영상 분류 방법은 그동안 많이 연구되어 왔으나 제안한 방법은 초기 연결 강도와 임계치, 은닉층의 노드 수를 VoD의 정보를 갖고 미리 체계적으로 정해 줌으로써 빠른 시간 내에 안정된 분류 시스템을 구성할 수 있는 장점이 있다. 제안된 분류 방법은 훈련집합에 대한 사전 정보를 Mathematica 패키지로 분석하여 보로노이 다이어그램을 구성한 후 EBP 학습의 초기 설정 값으로 결정하여 적용하였다. 제안된 시스템의 성능 평가를 위해 최소거리 분류 방법, 최대우도 분류 방법과 패턴 분류의 정확성 측면에서 비교 실험을 수행하였다. 그 결과로 최소거리 분류 방법과 최대우도 분류 방법에서는 각각 실험화상에 대해 81.4%, 87.8%의 정확성을 보였으며, 제안한 방법으로는 92.2%의 정확한 분류결과를 보였다. 이것은 최소거리 분류 방법과 최대우도 방법은 입력자료의 분포가 정규분포를 이루고 있어야 한다는 통계적 가정이 필요하고 신경망에 의한 분류 방법은 학습시 초기 변수의 설정이 성능에 크게 영향을 미치는 단점을 보완했기 때문이다. 그러나 인공위성으로부터 취득한 자료가 다양한 가시광선 파장대와 근적외선 파장대로 이루어져 있으나 VoD_EBP는 각각의 모든 밴드를 충분히 이용하지 못하는 약점이 있다. 이는 입력층에서 여러 개의 자료를 받아들이기 위해 다차원 형태의 보로노이 경계면에 대한 초평면 방정식을 쉽게 구할 수 없

기 때문이다. 이에 대한 연구로 계산기하학 연구분야에서 Qhull 과 rbox 프로그램이 개발되어지고 있지만 초기 신경망을 구성하기 위한 경계선 초평면 방정식을 아직 제공해 주지 못하고 있다. 우리나라로 인공위성이 발사되면서 위성으로 얻어진 영상을 통하여 원격 탐사 및 GIS 분야에 많이 활용하고 있다. 현재 원격탐사 영상인식을 위한 시스템을 구축하기 위하여 신경망을 이용하는 방법 외에 유전자 알고리즘 및 퍼지이론을 접목시킨 연구가 활발히 진행되고 있다. 앞으로 이를 활용하여 제안된 VoD_EBP의 은닉 층을 구분하여 최적의 퍼지규칙을 생성하고 이를 반영시킬 수 있는 VoD를 활용한 뉴로-퍼지시스템을 구축할 수 있는 연구가 보완되어야 할 것이다.

참 고 문 헌

- [1] Godfried T. Toussaint, "Pattern Recognition and Geometrical Complexity," *IEEE, 5-th International Conference on Pattern recognition*, pp.1324-1347, 1980.
- [2] J. A. Hartigan, *Clustering Algorithms*, John Wiley & Sons, 1975.
- [3] 한종규, 이상구, "뉴로-퍼지 알고리즘을 이용한 원격탐사 화상의 지표면 패턴분류 시스템 구현", 퍼지 및 지능시스템학회 논문지, 제9권 제5호, pp.472-479, 1999.
- [4] M. I. Shamos, *Computational Geometry*, Ph.D. theis, Yale Univ., 1978.
- [5] N. K. Bose, "Neural Network Design Using Voronoi Diagrams," *IEEE Transaction on Neural Networks* Vol.4, No. 5, September, 1993.
- [6] Ali A. Minai and Ronald D. Williams, "Backpropagation Heuristics : A study of the Extended Delta-Bar-Delta Algorithm," *IJCNN*, Vol.1, pp.595-600, 1990.
- [7] Norio Bada, "A Hybrid Algorithm for Finding the Global Minimum of Error function of Neural Networks," *IJCNN*, Vol.1, pp.585-588, Jan. 1990.
- [8] Tariq Samad, "Backpropagation Improvements Based on Heuristic Arguments," *IJCNN*, Vol.1, pp.565-568, Jan. 1990.
- [9] P. Burrascano and P. Lucci, "Smoothing backpropagation cost function by Delta-Constraining," *IJCNN*, Vol.3, pp. 75-80, Jun. 1990.
- [10] Van Ooyen and B. Nienhuis, "Improving the convergence of the back propagation algorithm," *Neural Networks*, Vol.78, pp.465-471, 1992.
- [11] 백주현, 김홍기, "보로노이 공간분류를 이용한 오류역전파 신경망의 설계방법", 퍼지 및 지능시스템학회 논문지, 제9권 제5호, pp.490-495, 1999.
- [12] J. A. Richards, "Remote Sensing Digital Image Analysis," Springer-Verlag, New York, pp.181-190, 1995.
- [13] P. M. Mather, "Computer processing of remotely sensed images," John Wiley and Sons, U. K., pp.192-193, 1987.
- [14] J. D. Paola and R. A. Schowengerdt, "A Detailed Comparison of Backpropagation Neural Network and Maxi-

- mum-Likelihood Classifier for Urban Land Use Classification," *IEEE Trans Geosci and Remote sensing*, Vol. 33, pp.981-996, July, 1995.
- [15] Hedong Yang and Clark C. Guest, "Linear Discriminants, Logic Functions, Back-propagation, and Improved Convergence," *IJCNN*, Vol.3, pp.287-292, 90. Jun.
- [16] M. L. Minskey and S. A. Papert, *Perceptrons*, Cambridge, MA : MIT Press, 1988.
- [17] 조성배, 김진형, "오류 역전파 학습 알고리즘의 속도 개선방법 : 분류 및 비교", 한국정보과학회논문지, Vol.18, No.6, pp. 649-660, 1991.
- [18] 권희용 외 4, "바람직하지 않은 포화상태 방지에 의한 역전파 학습의 개선", 한국정보과학회논문지, Vol.20, No.5, pp.656-661, 1993.
- [19] Youngjik Lee, Sang-Hoon Oh and Myung Won Kim, "An Analysis of Premature Saturation in Back Propagation Learning," *Neural Networks*, Vol.6, pp.719-728, 1993.
- [20] D. McCallum and D. Avis, "A Linear Algorithm for finding the convex hull of a Simple polygon," *Information Processing lett*, Vol.9, pp.201-206, Dec. 1979.



백 주 현

e-mail : jhback@kunjang.ac.kr
1988년 성균관대학교 수학과 졸업(학사)
1992년 서강대학교 대학원 정보처리학
(이학석사)
1996년 충북대학교 전자계산학과 박사수료
1996년~현재 군장대학 컴퓨터응용학부
조교수

관심분야 : 인공지능, 패턴인식, 퍼지이론, 인공신경망



김 홍 기

e-mailg : hgkim@cbucc.chungbuk.ac.kr
1961년 연세대학교 수학과 학사
1975년 연세대학교 교육대학원 응용수학
교육학과(교육학 석사)
1985년 중앙대학교 대학원 응용수학
(이학박사)

1980년~현재 충북대학교 컴퓨터과학과 교수
관심분야 : 퍼지이론, 인공신경망, 정보통신