

토지피복분류에 있어 신경망과 최대우도분류기의 비교

A comparison of neural networks and maximum likelihood classifier for the classification of land-cover

전형섭* · 조기성**

Jeon, Hyeong-Seob · Cho, Gi-Sung

要 旨

본 연구에서는 인공위성영상을 이용한 토지피복 분류방법 중 파라메트릭한 분류와 비-파라메트릭한 분류의 대표성을 띤 최대우도 분류법과 신경망을 이용한 분류방법을 사용하여 분류정확도를 비교하였다. 분류정확도의 평가에 있어서 일반적인 분석가들이 사용하는 훈련지역에 대한 분류정확도의 분석뿐만 아니라, 시험지역에 대한 정확도분석을 하였다. 그 결과, 최대우도분류기에 비하여 신경망의 분류기가 일반적인 훈련데이터의 분류에 있어서 약 3% 우월하였으며, 지상점증데이터를 사용한 분류결과에서는 시험에 사용된 두 분류기 모두 빈약한 분류결과를 나타내었으나, 신경망에 의한 분류가 최대우도에 비하여 약 10%정도 보다 신뢰할 수 있는 결과를 얻을 수 있었다.

ABSTRACT

On this study, Among the classification methods of land cover using satellite imagery, we compared the classification accuracy of Neural Network Classifier and that of Maximum Likelihood Classifier which has the characteristics of parametric and non-parametric classification method. In the assessment of classification accuracy, we analyzed the classification accuracy about testing area as well as training area that many analysts use generally when assess the classification accuracy. As a result, Neural Network Classifier is superior to Maximum Likelihood Classifier as much as 3% in the classification of training data. When ground reference data is used, we could get poor result from both of classification methods, but we could reach conclusion that the classification result of Neural Network Classifier is superior to the classification result of Maximum Likelihood Classifier as much as 10%.

1. 서 론

인공위성을 이용한 원격탐사는 지표면에서의 반사광의 분광분해에 의한 관측데이터를 광범위한 영역에서 동시에, 그리고 주기적으로 측정가능하기 때문에 국토관리 및 도시계획, 자원개발 및 환경관리, 군사전략, 그리고, 최근 지리정보시스템의 기초자료로 이용하는데 중요한 수단이 되고 있다¹⁾. 아울러 차후 공간적, 분광적 고해상도 센서를 탑재한 위성의 운항으로 지형공간정보의 데이터로서 위성아이지의 사용은 여러 응용분야에서 광범위한 연구의 주제가 될 것이다²⁾.

일반적으로 원격탐사는 환경적 현상의 특성을 평가,

모니터링, 예측의 3가지 응용분야로 대별할 수 있으며, 그중 지도화(mapping) 즉, 원격탐사 데이터로부터 주제도의 추출은 가장 일반적인 응용분야이며, 다른 연구분야의 기초자료로서 사용되기 때문에 우선적으로 요구되는 연구분야이다³⁾. 또한 과거 수십년동안 주제도 작성이 원격탐사의 가장 일반적인 응용분야중의 하나라고 하지만, 원격탐사 데이터로부터 추출된 주제도의 정확도는 실제 사용하기에 여전히 그 정도가 낮다고 판단되며, 그중 가장 흔히 응용되는 토지피복도 추출, 역시 원격탐사 데이터로부터 정확하게 얻을 수 있다고 판단하기에는 아직 이르다고 할 수 있다⁴⁾. 이에 대한 원인으로는 여러 가지가 있을 수

* 전북대학교 공과대학 토목공학과 박사과정

** 전북대학교 공과대학 토목환경공학부 부교수,
전북대학교 공업기술연구소 연구원

있겠지만, 원격탐사 데이터의 낮은 공간해상도, 분광 해상도, 분류항목에 있어 상세한 항목화의 결여, 그리고 매핑에 사용되는 기법의 낮은 분류정확도 등의 문제점으로 대별 할 수 있다. 그러나 기술의 발달로 인하여 처음 세가지 요인은 어느 정도 점진적으로 완화 시켰지만, 낮은 분류정확도의 문제는 원격탐사의 폭넓은 사용을 계속적으로 제한하고 있다.

일반적으로 위성 이미지 분류는 최대우도(maximum likelihood method)으로 대표되는 통계학적인 이론에 근거한 파라메트릭 분류기를 사용하여 분류되고 있다. 즉, 각 항목의 확률분포를 다차원정규분포로 가정하고, 그의 파라메터를 훈련데이터의 평균벡터와 공분산행렬에서 추정한다. 그러나 설정되는 항목은 주제도를 이용하는 입장에서 정의된 것이고, 반드시 그 항목이 가정된 확률분포를 갖는다고 할 수 없다⁵⁾. 사실 실제적인 원격탐사데이터는 정규분포를 나타내는 예가 그리 많지 않다. 그러므로 최대우도법을 이용한 경우, 항목의 확률분포가 다차원 정규성에 따르지 않을 때, 그것에 의한 분류정확도는 현저하게 저하된다.

한편, 80년대 후반부터 원격탐사분야에 등장한 인공신경망(Artificial Neural Network)은 최대우도법에 비하여 항목의 확률분포를 가정하지 않고 분류를 수행한다는 점과 많은 훈련샘플을 요하지 않는다는 점, 일단 훈련이 되었을 경우 분류가 빠르다는 점, GIS데이터를 결합할 수 있다는 점, 그리고 무엇보다 분류 결과에 있어 최대우도법이상의 분류정확도를 가져왔다는 점에서 시선이 주목되었다. 그러나 신경망은 망의 구조와 클래스의 특성에 관계하는 크기나 구성과 같은 훈련집합의 특성에 따라 분류결과가 일정치 않다는 점과 망을 훈련하는데 시간을 요한다는 점, 그리고 처리가 블랙박스 형태이어서 결과를 설명하기가 어렵다는 제한으로 인해 공식적인 분류방법으로 인정되지 않고 있었으나 최근의 관계문현에서는 하나의 분류방법으로서 제시되는 것을 볼 수 있다^{6,7)}.

따라서 본 연구에서는 많은 분류 방법중 파라메트릭한 분류와 비-파라메트릭한 분류의 대표성을 띤 최대우도 분류법과 신경망을 이용한 분류방법을 사용하여 분류정확도를 비교하였다. 또한 주제도 추출에 있어서 가장 일반적인 토지피복분류의 경우로 대변하여

연구하였으며, 분류정확도의 평가에 있어서 일반적인 분석가들이 사용하는 훈련지역에 대한 분류정확도의 분석뿐만 아니라, 시험지역에 대한 정확도분석을 하였다. 시험지역에 대한 정확도분석으로 인하여 기존의 분류정확도 평가시 비교적 호의적으로 평가되었던 부분을 보다 정확히 평가하여 두 분류기의 성능의 비교하였다. 이러한 비교는 우리 나라와 같이 복잡한 지형·지물을 갖는 지역에 분류방법으로서 신경망 사용의 효과를 강조하고자 하며, 시험지역을 통한 평가는 향후 원격탐사 이미지로부터 보다 근거있는 주제도를 확보하여 안정된 GIS 기초 데이터 구축에 이바지 할 수 있으리라 사료된다.

2. 이론적 고찰

2.1 최대우도법

평균벡터, 공분산행렬과 같은 통계적인 매개변수에 근거하는 최대우도법은 훈련집합 선택으로 이러한 매개변수들을 추출하여 판별함수에 사용함으로서 목표 입력벡터를 정량적으로 계산하여 가장 가능성 있는 정보클래스에 픽셀을 할당한다. 최대우도분류기의 주된 가정은 어떠한 대상클래스의 확률함수가 적당한 정규(Gaussian)확률 밀도함수에 가깝다는 것이다. 그러므로, 정규분포의 가정이 위배되는 경우에 최대우도 분류기를 사용할 때는 주의가 요구된다. 게다가, 뚜렷하게 다봉(multimodal)확률함수를 갖는 클래스는 일반적으로 단봉(unimodel) 함수인 정규확률 밀도함수에 비해 적절하게 분류될 수 없다.

m 개의 패턴클래스가 있다고 가정하자. 그리고 $p(X|\omega_i)$ 를 X 가 클래스 i 의 한 패턴이 될 확률밀도함수라 하자. 또한, $p(\omega_i)$ 를 클래스 i 의 사후확률이라 하자. 그러면 다음 식을 적용하여, 최대우도결정 규칙은 $X \in \omega_i$ 가 된다.

$$p(X|\omega_i)p(\omega_i) \geq p(X|\omega_j)p(\omega_j) \quad (2.1)$$

for all $j = 1, 2, \dots, m$

판별함수는 이러한 최대우도결정규칙을 사용하여 유도된다. 판별함수를 유도하기 위하여 m 개의 클래스에 대한 일련의 손실함수가 정의될 필요가 있다. 실

제적인 의미로는, 주어진 패턴 X 에 대하여 X 가 클래스 i 로 결정됨에 의해 생성되는 평균손실을 최소화하는 것이다. 이러한 최소화하는 문제는 다음과 같은 판별함수를 최대화하는 문제로 변환될 수 있다.

$$g_i(X) = \frac{p(\omega_i)}{(2\pi)^{n/2} |\sum_i|^{1/2}} * \exp[-\frac{1}{2}(X - U_i)^T \sum_i^{-1}(X - U_i)] \quad (2.2)$$

식(2.2)보다 수행하는데 있어서 동일하나, 다소 간단한 판별함수로 \log 를 취하여 다음과 같이 쓰여질 수 있다.

$$g_i(X) = \log_e p(\omega_i) - \frac{1}{2} \log_e |\sum_i| - \frac{1}{2}(X - U_i)^T \sum_i^{-1}(X - U_i) \quad (2.3)$$

일단 문제가 주어지고 통계적인 매개변수들이 훈련데이터로부터 추정되면, 식(2.3)의 2차 항은 실제적인 분류과정에서 아주 세밀하게 변화하며, 각 클래스에 대해서 계산될 것이다. 각 결정영역에 대하여 하나씩 m 개의 판별함수들, $g_i(X)$, $i=1,2,\dots,m$ 가 정의되면, 다음의 결정규칙이 적용된다.

“모든 $j=1,2,\dots,m$ 에 대하여 라면 $X \in \omega_i$ 이다”.
 $g_i(X) \geq g_j(X)$

판별함수에 의해서 추정된 클래스 i 에 존재할 X 의 확률이 다른 클래스에 존재할 확률보다 크다면 X 는 클래스 i 에 속한다는 것을 설명한다^{8) 10)}.

2.2 신경망이론

컴퓨터에 의해 시연되는 모든 신경망은 인공신경망이고, 간단히 신경망이라 한다. 또한 인공뉴런은 망의 노드이다. 실제 두뇌가 어떻게 수행되는가에서 모사되었음에도 불구하고 신경망은 일반적인 계산접근에서 벗어난 문제를 해결하는데 매우 인상적인 결과를 가져다 준다.

가장 널리 사용되고 수용되는 신경망의 하나는 역전파 학습알고리즘을 활용한 다층전향망이다. 어떤 추정에 의하면 모든 신경망 용용의 90%를 차지한다고 한다. 그림 1은 전형적인 삼층전향신경망의 일반적인 구조를 보여준다.

신경망은 입력벡터 $x = [x_1, \dots, x_n, 1]$ 를 받아들여

출력벡터 $o = [o_1, \dots, o_M]$ 를 생산한다. 그러므로 전향망은 다음과 같이 묘사될 수 있다.

$$o = f(x) \quad (2.4)$$

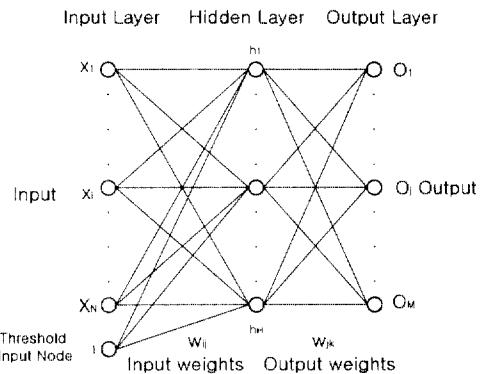


그림 1. 전형적인 삼층전향망

입력층 노드수 N , 은닉층 노드수 H , 출력층 노드수 M 인 망에 대하여 출력값 o_k 는 다음과 같이 계산될 수 있다.

$$o_k = g_1(\sum_{j=1}^H w_{jk}^{[1]} h_j), \quad k=1, \dots, M \quad (2.5)$$

여기서 $w_{jk}^{[1]}$ 는 은닉노드 j 에서 출력노드 k 로의 연결강도이고, g_1 은 활성함수이다. 여기서 은닉층노드 h_j 의 출력값은 다음과 같이 계산된다.

$$h_j = g_2(\sum_{i=1}^N w_{ij}^{[2]} x_i + \theta_j), \quad j=1, \dots, H \quad (2.6)$$

여기서 $w_{ij}^{[2]}$ 는 입력노드 i 에서 은닉노드 j 로의 연결강도이고, θ_j 는 은닉노드 j 로의 상수값 1을 갖는 입력노드로부터의 임계값이고, x_i 는 번째 i 노드의 값이고, g_2 는 변환함수이다.

변환함수에는 계단함수, 경사함수, 시그모이드함수 등이 있으며, 그중 시그모이드 함수가 흔히 사용된다. 이 함수는 다음과 같다.

$$g_2(x) = a(x) = \frac{1}{1+e^{-x}} \quad (2.7)$$

여기서 g_2 는 활성화 함수이다. 활성화 함수 g_2 는 출력노드의 활성화 함수 g_1 과 동일하다.

전향망의 성능은 다음 두가지 요소에 의해 결정된다. 즉, 레이어와 노드의 수 그리고, 연결강도값이다. 입력과 출력노드의 수는 분류의 성질에 의해 이미 결정된다. 은닉층 수와 그층의 노드수는 사용자에 의해 조정될 수 있는 변수이다. 또한 연결강도 값은 망의 성능에 관여하는 매우 중요한 요소이다.

원하는 성능을 얻기 위하여 이들 연결강도값을 조정하는 과정은 망을 훈련한다고 한다. 훈련은 망의 반응이 원하는 거동에 부합되도록 이들 연결강도를 최적화하는 과정이다. 연결강도를 조정하기 위한 훈련 알고리즘으로는 헵의 규칙, 멜타규칙, Widrow-Hoff 학습규칙, 최소 평균제곱규칙, 최급하강법 등이 있다. 훈련과정은 또한 코헨의 학습규칙, 역전파학습, 그로스버그 학습규칙 등과 같이 몇 개 그룹으로 나누어진다. 이들 훈련과정에서 역전파 훈련방법은 가장 훈련학습기법이다.

먼저 훈련데이터는 신경망의 훈련을 위해 준비되어야 한다. 훈련데이터는 망이 모방되어야하는 관계와 표본으로 수집된 입력-출력 쌍으로 구성된다. 망 출력과 원하는 출력사이의 차는 망에 의해 생산된 오차이다. 훈련과정에서 이 오차는 최소화된다. 입력데이터 벡터 $x = [x_1, \dots, x_N]$ 와 원하는 출력데이터 벡터 $d = [d_1, \dots, d_M]$ 를 가진 훈련데이터의 집합 (x, d) 이 있다고 가정하자. 초기 연결강도 w 가 주어지면 출력 벡터 o 는 식(2.5)에 의해 산출될 것이다. 원하는 출력 d 와 실제 출력 o 사이의 오차는 다음에 의해 결정될 수 있다.

$$E = \frac{1}{2} \|d - o\|^2 = \frac{1}{2} \sum_{k=1}^M (d_k - o_k)^2 \quad (2.8)$$

여기서에서 허용오차 E 를 최소화하는 연결강도 w 의 값을 찾는 것이다. 일반적으로 널리 사용되는 방법이 최급하강 알고리즘이다. 역전파 훈련은 단순히 연결강도값의 벡터와 오차함수를 적용한 최급하강 알고리즘이다.

반복단계는 다음과 같이 묘사될 수 있다.

$$\text{new } w = \text{old } w + \Delta w \quad (2.9)$$

여기서 $\Delta w = \Delta w_{ij} = -k \frac{\partial E}{\partial w_{ij}}$, w_{ij} 는 n번째 층의 i번째 노드에서 (n+1)번째 층의 j번째 노드로

의 연결강도이고, k 는 각 반복단계의 변화 크기를 관여하는 비례 상수이다.

오차 E 의 도함수를 계산한 후에 다음과 같은 연결강도변화량을 구한다.

$$\Delta w_{ij} = \epsilon \delta_i h_j \quad (2.10)$$

여기서 $\epsilon = 2k$, $\delta_i = d_i - o_i$ 는 유니트 i에 대한 원하는 출력과 실제 출력사이의 차이고, h_j 는 식(2.6)에 의해 계산된 은닉 유니트의 출력값이다.

δ 의 결정은 출력층에서 시작하여 입력층으로 작업하는 반복적인 과정이다. δ 를 결정하기 위하여 활성화 함수의 도함수가 요구된다. 식(2.7)의 시그모이드 함수를 활성화 함수로 사용한다면 도함수는 다음과 같다.

$$a(x)' = a(x)(1 - a(x)) \quad (2.11)$$

따라서 출력층에 대한 오차신호 δ_i 는 다음과 같이 결정될 수 있다.

$$\delta_i = (d_i - o_i)o_i(1 - o_i) \quad (2.12)$$

여기서 o_i 는 시그모이드 활성화함수를 사용하여 식(2.5)에 의하여 결정된다. 또한 임의 은닉층의 오차신호는 다음에 의해 구할 수 있다.

$$\delta_i = o_i(1 - o_i) \sum_{k=1}^M \delta_k w_{jk}^{(o)} \quad (2.13)$$

식(2.10)에서 식(2.13)은 식(2.9)의 반복적인 최급하강법에 사용되는 각각의 연결강도를 나타낸다. 최급하강법은 적절한 해에 도달하기 위하여 많은 반복을 요하는 매우 느린 알고리즘이다. 이 느린 학습과정을 향상시키기 위하여 일반적으로 모멘텀 항이 소개된다. 모멘텀항은 전의 반복에 사용된 연결강도 변화의 함수이다. 모멘텀항은 각 방향에서 강한 움직임을 강화하고, 반복적인 진동을 제거할 수 있다. 실제문제에서 역전파훈련의 속도를 향상시키는데 도움이 있다고 나타났다. 따라서 최급하강학습 알고리즘은 다음과 같이 나타낼 수 있다.

$$\begin{aligned} \text{new } w &= \text{old } w \\ &+ \alpha \cdot (1 - \alpha) \cdot \Delta w + \beta \cdot \text{old } \Delta w \end{aligned} \quad (2.14)$$

여기서 매개변수 α 는 학습율이고, β 는 모멘텀항의 상대적인 연결강도를 조절한다.

이 알고리즘은 계산된 오차가 오차임계값에 도달하거나 최대반복횟수에 도달했을 때 마치게 된다¹¹⁻¹³⁾.

3. 적용 및 고찰

3.1 연구대상지역 및 표본의 선정

본 연구의 대상지역으로는 크게 두 지역으로 구분하여 실시하였다. 주 대상지역은 훈련데이터를 추출하여 각 분류의 정확도를 평가해 보고자하는 지역으로서 전라북도와 충청남도를 잇는 금강하구언을 중심으로 한 $65.61\text{km}^2(270\times270\text{Pixel})$ 지역이다. 이 지역은 그림 2에서 볼 수 있듯이 도시, 농경지, 삼림, 수역, 습지 등의 토지피복분류에 좋은 표본조건을 갖추고 있어 연구대상지로 선정하였다.

부대상지역은 분류결과의 검증을 위한 지역으로서 전주시 근교를 선정하였다. 이 지역은 전주역과 철로라는 지역적인 특성으로 도시발달에 있어서 다른 근교지역에 비하여 상대적으로 시기적 변화가 현저히 적은 지역으로 기존자료인 항공사진이나 수치지도, 그리고 최근의 아리랑 위성의 자료를 사용함에 무리가 없을 듯하여 이 지역을 선정하였다. 이 지역의 면적은 $11.9\text{km}^2(115\times115\text{ Pixel})$ 이며, 그림 3과 같다.

그림 2. 연구대상지역

본 연구에 사용된 데이터는 Landsat-5 TM으로 1999년 3월 11일에 취득된 이미지이다. 따라서 토지이용/피복분류체계에 있어서 일반적으로 통용되고 있는 USGS의 분류체계중 Landsat TM의 경우에 해당되는 레벨 1의 수준으로 분류하는 것이 마땅하며¹⁰⁾, 대상지역의 특성상 USGS의 9개 클래스중 도시, 농경지, 삼림, 수역, 습지, 나대지의 6개 클래스를 선정하였다.

훈련데이터는 각 클래스에 대하여 각각 150개 픽셀

을 취득하였다. 훈련데이터의 취득방법으로 GPS를 일반적으로 사용하나¹⁰⁾, 본 연구에서는 동질의 넓은 지역을 선택하여 야외조사율 통하여 취득하였다. 또한 훈련데이터 취득시 최소 1×2 픽셀에서 최대 4×4 픽셀까지 현장에 맞게끔 선택적으로 취득하였으며, 그 위치는 그림 2와 같다. 통계적인 분류기 즉, 본 논문에서 최대우도분류기의 경우 훈련데이터를 n 개의 밴드로부터 추출하게 된다면, 각 클래스에 대하여 $>10n$ 화소의 훈련 데이터가 수집되어야 한다는 것이 일반적인 규칙이다¹⁰⁾. 한편 신경망의 경우에는 이러한 제한 조건이 존재하지 않는다. 그러나 본 논문에서는 신경망과 최대우도법의 엄격한 비교를 위하여 각 클래스에 대하여 150픽셀씩 동일하게 추출하여 그림 4와 같은 900픽셀의 시연데이터를 형성하였다.

그림 3. 검증지역

그림 4. 훈련데이터

3.2 영상의 전처리

본 연구에 사용된 이미지는 bulk correction의 전처리 수준을 가진 것이어서 방사보정은 필요가 없었으며 단순한 기하보정만을 실시하였다. 한편 훈련지역과 시험지역 두 지역이 동일한 이미지로부터 추출되었으나 훈련지역의 경우는 기하보정의 resampling과정에서 원데이터를 왜곡시킬 염려가 있어서 훈련데이터로서 가치를 떨어뜨릴 수 있기 때문에 기하보정을 실시하지 않고 사용하였다. 그러나 시험지역에서는 기하보정을 실시하였다. 1/5000의 수치지도로부터 취득된 19개의 지상기준점을 사용하여 Image to Map 방식을 사용하였다. 일반적으로 Landsat TM 1/4scene의 경우 허용오차가 0.5픽셀이어서, 좌표변환은 Affine 변환을 사용하는 것으로 충분하다고 하였으나, 본 연구에서는 이 경우 0.85픽셀정도 오차를 보여서, 3차 다항식 변환을 사용하여 변환하였고, 그 오차는 0.29픽셀(약 8.7m)이었다.

시험데이터지역의 경우 철로라는 방해물로 인하여 비교적 다른 근교에 비하여 그 피복변화 추이가 미약 할지라도 수치지도제작당시에 비하여 변화가 있을 것이다. 따라서 수치지도를 보완할 수 있는 데이터로서 Landsat 이미지 취득전의 항공사진과 후의 아리랑 위성영상을 사용하기 위하여 이들에 대하여 동일한 방법으로 기하보정을 실시하였다. 95년의 항공사진에 대하여 기하보정을 실시한 결과 4.4m정도의 평균제곱근오차를 보였으며, 2000년 4월의 아리랑 위성영상의 경우, 0.7픽셀(4.6m)정도의 평균제곱근오차가 나타났다.

3.3 영상의 분류

3.3.1 최대우도법에 의한 분류

일반적으로 분류를 위해서는 영상처리에 소요되는 비용적인 면을 고려하여 임의의 클래스사이에 최상의 통계적 분리도를 제공하는 밴드의 최적부분집합을 선택하게 된다. 여기에는 각 클래스에 대한 훈련 데이터가 정규 분포라 가정하는 divergence를 사용하는 것이 일반적이다¹⁰⁾.

그러나 본 논문에서는 이러한 차원감소를 통한 비용감소 효과를 도출하고자하는 것이 아니라 두 분류기의 정확도 측면을 고찰하는 데 목적이 있으므로 계산시간의 측면 등의 불리한 점을 감수하고 6개 밴드 모두를 사용하여 분류하였다.

본 논문에서 사용된 최대우도법은 2장의 이론적 고찰에서도 설명되었듯이 각 밴드의 각 클래스에 대한 훈련 데이터 통계가 정규분포라 가정하고, 사상벡터가 나타날 가능성이 가장 큰 클래스에 픽셀 X를 할당하는 분류방법이다. 따라서 식(2.3)을 사용하여 최대우도분류를 C++로 프로그램화하였다. 훈련데이터는 그림 2와 같은 이미지로부터 추출된 그림 4와 같은 900개의 훈련데이터를 사용하였으며, 이들로부터 표본의 평균과 공분산 등, 통계학적 매개변수들이 추출되었다. 식(2.3)과 같은 최대우도분류법에서 첫 번째항은 사전확률의 항으로 사전에 분류를 한 결과라든지 분류지역에 대한 분포비 등의 유용한 사전정보를 포함하는 것이 가능하다. 그러

나 일반적으로는 각 클래스에 대한 자료를 얻기 어렵기 때문에 각 클래스에 대하여 동일하다고 가정하였다.

그림 6. 결과(NN)

먼저 훈련지역에 대한 분류결과(그림 5)를 살펴보면 수역과 산림, 나대지, 그리고 습지에 있어서는 100%의 정확한 분류가 가능하였다. 그러나 농경지에 있어서 나대지로의 오분류, 그리고 도시지역에서 나대지로의 오분류의 결과가 일부 보이고 있다. 이러한 원인은 그림 7,8,9의 나대지, 농경지, 도시지역의 훈련데이터 히스토그램에서 보여주듯이 데이터 값의 전체적인 범위가 이를 세 개 클래스에 있어서 거의 동일하며, 클래스3(농경지)이나 4(도시)에 비하여 클래스 2(나대지)의 분산이 크다는 것이다.

이러한 점은 도시지역이나 특히 농경지에 있어서 평균값과 떨어져 있는 픽셀의 경우 즉, 가능성이 미약한 픽셀의 경우, 이 픽셀에 대하여 나대지의 분산이 크기 때문에 나대지로 분류된 것으로 판단된다. 이러한 영향은 연구지역 전체의 분류에서도 역력히 나타난다. 그림 10은 주연구지역에 대한 분류결과를 보여주는데 농경지가 대부분 나대지로 분류되는 결과를 보여준다. 여기에는 이미지의 취득시기가 농사철이 아닌 휴지기이기 때문에 발생된 문제라 할 수도 있다.

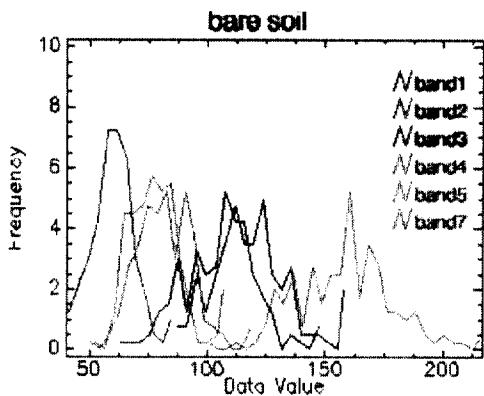


그림 7. 클래스 2의 히스토그램

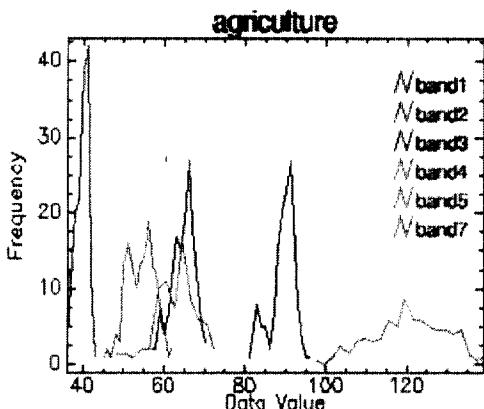


그림 8. 클래스 3의 히스토그램

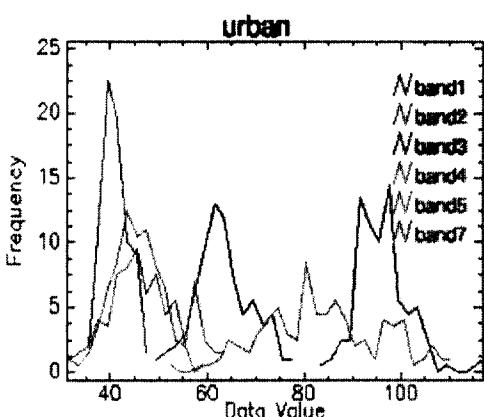


그림 9 . 클래스 5의 히스토그램

그림 10. 최대우도법에 의한 분류결과

3.3.2 신경망에 의한 분류

본 연구에서 사용된 신경망은 최급하강법을 사용한 역전파 학습알고리즘이다. 신경망 구현을 위하여 C++ 언어를 사용하였다. 이론적 고찰에서 언급하였듯이 신경망의 성능을 결정하는 요소로는 은닉층의 수나 그층에 대한 노드수 그리고 연결강도의 값이다. 여기서 한 가지 덧부친다면 학습에 사용되는 파라메터인 학습률과 모멘텀상수의 값일 것이다. 이들의 값을 결정하는데는 정규화된 방법이 없고 시행착오적으로 이들의 값을 구하는 방법이 일반적이다. 또한 은닉층 수를 2개이상으로 사용하였을 경우 뚜렷한 성능의 향상을 기대하기 어렵다는 일반적인 이론에 근거하여 1개의 은닉층을 사용하였다^{[1]-[3]}. 입력층의 노드수는 사용하고자 하는 벤드수인 6개이며, 출력층의 노드 수는 분류하고자 하는 클래스의 수인 6개이다. 은닉층의 노드수는 일단 일정한 수 12개로 고정시켜 놓고 시행착오법으로 최적의 수를 구하였다. 이와 같이 $6 \times 12 \times 6$ 의 신경망이 훈련을 위한 초기 파라메터를 구하기 위하여 사용되었다. 학습데이터로는 최대우도분류기에서 사용되었던 것과 동일한 훈련데이터를 사용하였다.

먼저 학습률과 모멘텀상수의 값을 결정하기 위하여 표 1과 같이 0.1에서 0.8사이의 값을 취하여 신경망을 훈련하였다. 그 결과 학습률이 0.1이고, 모멘텀상수가 0.2일 때 최고의 분류정확도를 산출하였다. 이러한 결과는 시행착오법이며, 훈련을 시킬 때마다 다른 결과를 가져올 수 있으나, 5000회 반복과 0.001의 임

표 1. 학습률과 모멘텀상수의 변화에 따른 반복횟수와 분류정확도

β	0.1		0.2		0.3		0.4		0.5		0.6		0.7		0.8	
α	Cycle	C_P														
0.1	1516	889	820	892	619	886	710	887	729	885	646	890	446	878	612	882
0.2	1480	881	698	871	797	886	550	882	405	880	412	880	360	876	384	881
0.3	763	879	546	876	585	890	457	884	489	883	283	881	249	874	363	868
0.4	442	870	659	876	547	858	320	871	475	878	518	875	413	878	323	867
0.5	428	869	487	873	378	858	505	872	235	856	390	869	283	866	192	861
0.6	491	848	373	856	317	862	338	873	397	867	410	878	329	859	346	858
0.7	371	867	412	852	550	856	361	862	377	874	478	868	443	865	391	869
0.8	455	868	523	859	579	865	377	858	381	853	350	861	412	858	374	867

표 2. 은닉층의 노드수에 따른 반복횟수와 분류정확도

h_n	15		14		13		12		11		10		9	
	no	Cycle	C_P	Cycle	C_P	Cycle								
1	923	889	1003	888	865	891	1554	890	627	887	1234	884	794	882
2	610	882	921	888	1002	891	933	888	929	888	1122	883	1327	884
3	798	888	631	886	819	888	894	890	1014	886	1153	888	1331	883
4	648	886	891	889	762	887	1064	890	673	886	918	889	1008	886
5	929	889	732	888	822	890	812	883	849	886	863	887	999	884
6	607	887	1141	890	881	890	610	886	1361	888	1633	885	1076	891
7	692	888	925	888	587	887	788	887	704	879	937	887	1134	889
8	591	887	807	891	838	889	805	890	889	888	1032	888	1266	890
9	922	889	669	888	1181	888	805	887	896	888	1207	885	1099	891
10	580	883	854	889	768	887	960	889	645	886	954	885	1777	883
mean	730	886.8	857.4	888.5	852.5	888.8	922.5	888	858.7	886.2	1105.3	886.1	1181.1	886.3

제오차안에서 비교적 빠른 수렴치이고, 신경망이 블랙박스형태이어서 일반화하기 어렵기 때문에 여기에서 생성된 학습률과 모멘텀상수를 사용하는 것이 무리가 없을 듯하다.

다음으로 전자에서 생성된 학습률과 모멘텀 항으로 고정시켜놓고 은닉노드의 수를 변화시켜 최적의 은닉층 수를 추출하였다. 그 결과가 표 2와 같으며 13개의 은닉노드를 사용하는 것이 최고의 결과를 가져왔다.

따라서 $6 \times 13 \times 6$ 의 신경망에 학습률과 모멘텀항을 각각 0.1, 0.2를 사용하여 훈련데이터를 분류한 결과를 그림 6에 나타내었다. 최대우도분류기에 비하여 비교적 양호한 결과를 가져왔지만, 이 결과 역시 클래스 2(나대지)에 있어서 클래스5(도시)나 클래스3(농경지)로 오분류됨을 보인다. 이것은 신경망이 블랙박스 형태이기는 하지만, 이미지데이터 값을 정규화하는 과정에서 최대값과 최소값을 사용하는데 그림 7,8,9의 히스토그램에서 보여주듯이 서로가 비슷한 분산형태를 가짐으로서 정규화되는 값이 상대적 비슷하

기 때문일 것이라 사료된다.

주연구지역의 분류결과(그림 11)를 살펴보면 최대우도분류기의 경우에서 많은 농경지가 나대지로 분류되었었는데 신경망의 경우는 이러한 오분류가 없이 양호한 분류결과를 나타낸다는 것을 볼 수 있다.

그림 11. 신경망에 의한 분류결과

3.3.3 수정된 최대우도분류기에 의한 분류

대부분의 원격탐사의 분류에서 클래스마다 발생할 확률은 다를 것이다. 그러나 전자의 최대우도분류기에서 사전확률을 이용할 수 없기 때문에 이를 값이

모든 클래스에 대하여 같다고 가정하고 분류하였다. 본 연구에서는 신경망에서 도출된 클래스의 확률을 사전확률의 값으로 사용하여 보았다. 신경망에서 결과되는 값은 각 픽셀이 임의 클래스에 대하여 출력되는 값으로 이들 값은 각 픽셀에 대하여 그 합이 1이 아니다. 따라서 임의 픽셀에서 각 클래스에 대한 출력의 합이 1이 되도록 이들을 정규화하면 각 클래스에 대한 확률값으로 변환할 수 있다. 이 값을 사전확률로 사용하여 분류한 것이 그림 12이다. 사전확률을 사용함으로서 농경지에 있어 나대지로의 오분류가 약간은 감소한 듯 하다. 그림 10과 13을 비교하여 보면 전체이미지에 대하여서도 나대지에 있어 감소함을 볼 수 있다.

그림 12. 결과(MMLC)

는 픽셀의 분류정확도는 지도의 나머지부분에 비하여 일반적으로 높다¹⁰⁾.

표 3,4,5는 각 분류에 대한 이러한 일반적인 오차행렬을 나타내었으며 여기에서 볼 수 있듯이 94%에서 98%까지 매우 정확한 분류결과를 나타내었다. 그러나 이러한 결과는 훈련데이터 내에서 검증한 결과로서 큰 의미를 가진다고 볼 수 없다.

표 3. 최대우도법에 대한 오차행렬

MLC	Reference data					
	Wat	Bar	Agr	For	Urb	Wet
Water	150	0	0	0	0	0
Bare soil	0	150	35	1	8	0
Agriculture	0	0	115	0	0	0
Forest	0	0	0	149	0	0
Urban	0	0	0	0	142	1
Wet land	0	0	0	0	0	149
Overall Accuracy : 95.0%						
Producer's Accuracy	Wat	100	Bar	100	Agr	76.6
	For	99.3	Urb	94.6	Wet	99.3
User's Accuracy	Wat	100	Bar	77.3	Agr	100
	For	100	Urb	99.3	Wet	100
K_{hat} : 94.0%						

표 4. 신경망에 대한 오차행렬

NN	Reference data					
	Wat	Bar	Agr	For	Urb	Wet
Water	150	0	0	0	0	0
Bare soil	0	132	0	0	6	0
Agriculture	0	9	146	0	0	0
Forest	0	0	0	150	0	0
Urban	0	9	4	0	150	0
Wet land	0	0	0	0	0	150
Overall Accuracy : 97.6%						
Producer's Accuracy	Wat	100	Bar	88.0	Agr	97.3
	For	100	Urb	100	Wet	100
User's Accuracy	Wat	100	Bar	100	Agr	94.2
	For	100	Urb	92.0	Wet	100
K_{hat} : 97.1%						

그림 13. 수정된 최대우도법에 의한 분류

3.4 분류정확도 검증 및 고찰

일부 분석가들은 분류 알고리즘을 훈련에 사용된 픽셀(훈련데이터)에 근거하여 오차평가를 수행하고 있다. 그러나 이를 훈련지역의 위치는 보통 임의적이지 않고, 어떤 토지피복형태가 이미지의 어디에 존재하는지를 이미 알고 있는 것처럼 분석가의 사전지식에 근거한다. 이러한 편의때문에 훈련지역안에서 발견되

이상적인 경우는 시험픽셀을 연구지역에서 추출하는 것이다. 그러나 각 항목의 정확도 평가를 위하여 얼마나 많은 지상참조데이터를 수집해야 하는지를 결정하기가 어렵다. 일부 분석가는 요구되는 샘플 크기를 이항분포와 같은 통계적 수식을 사용하기도 하며, 각 토지피복클래스에 대하여 최소 50개의 샘플을 수집하는 것을 제안하기도 하였다¹⁰⁾.

표 5. 수정된 최대우도에 대한 오차행렬

MMLC	Reference data					
	Wat	Bar	Agr	For	Urb	Wet
Water	150	0	0	0	0	0
Bare soil	0	150	5	1	6	0
Agriculture	0	0	145	0	0	0
Forest	0	0	0	149	0	0
Urban	0	0	0	0	144	1
Wet land	0	0	0	0	0	149
Overall Accuracy :	99%					
Producer's Accuracy	Wat	100	Bar	100	Agr	96.7
	For	99.3	Urb	96.0	Wet	99.3
User's Accuracy	Wat	100	Bar	92.6	Agr	100
	For	100	Urb	99.3	Wet	100
K_{hat} : 98.27%						

본 논문에서는 이러한 문제를 처리하기 위하여 11.9 km²의 시험지역을 선택하여 각 분류기에 대하여 시험하여 보았다. 전자에 설명되었듯이 시험지역은 토지피복 변화가 크지 않고 많은 부가자료를 사용할 수 있는 지역을 선택하였다. 이러한 자료를 사용하여 생성된 참조데이터는 그림 14와 같다. 훈련지역과 동일한 방법으로 최대우도분류와 신경망에 의한 분류, 그리고 신경망의 결과를 사전확률로서 사용한 수정된 최대우도분류를 사용하여 시험지역인 부연구지역에 대하여 분류하여 보았다. 그 결과, 두 최대우도에 의한 분류에서는 전체적인 정확도가 50%정도(일반적인 최대우도분류: 전체 정확도 45%, Kappa 통계치 0.4046, 수정된 최대우도분류: 전체 정확도 59%, Kappa 통계치 0.4968)이었고, 신경망에 의한 분류에 있어서는 75%의 전체적인 정확도가 얻어졌으며, 그 오차행렬을 표 6과 같다.

따라서 우리가 일반적으로 분류하여 사용하는 결과는 분류정확도 평가에 있어서 훈련데이터를 사용한 것으로 실제적인 사용에는 무리가 있는 것으로 판단된다. 또한 최대우도와 신경망의 결과에 있어서 서로 상이한 분류기법의 정확도를 비교를 하는 데 사용되는 Kappa통계치를 비교하여 볼 때^[4] 신경망분류의 정확도가 약 10%정도 우월한 것으로 산출되었다. 이러한 결과는 최대우도분류기에서 데이터가 단봉의 정규분포라는 가정이 실세계의 사상에서는 일치하지 않으며, 이미지에 상존하는 혼재된 픽셀의 문제를 훈련

데이터의 선정과정에서 무시하였기 때문이라 사료된다. 후자의 원인의 경우 우리나라와 같이 토지피복이 복잡한 지역에서 흔히 나타날 수 있는 결과라 생각된다.

본 논문에서는 분류기의 성능평가에 여전상 빈약한 훈련데이터를 사용함이 아쉬움으로 남으나, 향후 보다 세밀한 분류비교를 위하여 GPS 장비를 이용한 훈련데이터와 시험데이터의 수집과 여러시기의 고해상도 이미지를 사용하여 면밀히 분석하는 연구가 진행되어야 한다고 사료된다.

그림 14. 참조데이터 그림 15. 분류결과(NN)

표 6. 신경망에 대한 오차행렬(시험지역)

T_NN	Reference data					
	Wat	Bar	Agr	For	Urb	Wet
Water	74	0	3	0	0	6
Bare soil	0	51	132	12	79	7
Agriculture	50	18	5881	333	295	251
Forest	29	0	945	2124	94	62
Urban	6	11	330	42	1624	3
Wet land	104	1	401	19	29	209
Overall Accuracy :	75%					
Producer's Accuracy	Wat	28.1	Bar	63	Agr	76.5
	For	84	Urb	76.6	Wet	38.9
User's Accuracy	Wat	89.2	Bar	18.2	Agr	86.1
	For	65.3	Urb	80.6	Wet	27.4
K_{hat} : 60.6%						

4. 결 론

원격탐사 이미지를 이용한 각종 주제도의 생성시 일반적으로 사용되는 최대우도분류기와 신경망을 사용한 분류기를 비교하여 본 결과 다음과 같은 결론을 얻을 수 있었다.

첫째, 최대우도분류기에 비하여 신경망의 분류기가 일반적인 훈련데이터의 정확도 비교에 있어서 약 3.1% 우월하다 판단된다.

둘째, 지상점증데이터를 사용한 분류결과에서는 시험에 사용된 두분류기 모두 빈약한 분류결과를 나타내었으나, 신경망에 의한 분류가 최대우도에 비하여 약 10%정도 보다 신뢰할 수 있는 결과를 얻을 수 있었다.

셋째, 향후 GIS데이터의 기초자료로서 위성데이터의 많은 이용이 예상되고 있으나, 실세계의 사상구조가 복잡한 우리의 현실에 맞는 분류기법이 존재하지 않고 있어 이에 대한 개발이 시급하다 판단된다.

참 고 문 헌

1. Yosuke ITO, Sigeru OMATU, “競合型ニューラルネットワークによる土地被覆分類法”, 寫真測量とりモ-トセンシング, Vol.35, No.3, 1996, p5-17.
2. G.G. Wilkinson, "A Review of Current Issues in the Integration of GIS and Remote Sensing Data", INT. J. GIS, 1996, Vol.10, No.1, p85-101.
3. Giles M. Foody and Manoj K. Arora, "Incorporating mixed pixels in the training, allocation and testing stages of supervised classifications", Pattern Recognition Letters 17, 1996, p1389-1398.
4. P.M. Atkinson, N.J. Tate, "Advances in Remote Sensing and GIS Analysis", John Wiley & Sons, 1999. p17-37
5. Lillesand, T.M. and R.W. Kiefer, "Remote Sensing and Image Interpretation 2nd Ed. John Wiley & Sons, 1987
6. Justin D. Paola, Robert A. Schowengerdt, "A detailed comparison of backpropagation neural network and maximum likelihood classifier for urban land use classification", IEEE TG&RS, 1995, Vol.33, No.4, p981-996
7. Justin D. Paola, Robert A. Schowengerdt, "The effect of neural network structure on a multispectral land-use/land-cover classification", PE&RS, 1997, Vol.63, No.5, p535-544.
8. Swain, Ph. and R.C. Davis, "Remote sensing: the quantitative approach", McGraw -Hill, 1978, p148-158
9. John A. Richards, "Remote sensing digital image analysis", Springer-Verlag Berlin Heidelberg New York, 1986, p174-189
10. Jensen, J. R., "Introductory digital image processing : A Remote sensing perspective", 2nd ed. Prentice-Hall, 1996, p197-256
11. Valluru B. Rao and Hayagriva V. Rao, "C++ neural networks and fuzzy logic", MIS, 1993.
12. Ronald R. Yager and Lotfi A. Zadeh, "Fuzzy sets, neural networks, and soft computing", VNR, 1994.
13. Fausett, Laurene V, "Fundamentals of neural networks: architectures, algorithms, and applications", Prentice-Hall, 1994.
14. Hee-Bum Lee, "An integrated classification approach for remote sensing data incorporating fuzzy neural networks, GIS and GPS", Univ. of Wisconsin-Madison, 1997, p170-174