

카테고리분류를 위한 다층퍼셉트론 신경회로망과 최대유사법의 성능비교

Performance Comparison of Multilayer Perceptron Neural Network and Maximum Likelihood Classifier for Category Classification

임 태훈* 서 용 수*
Lim, Tae Hun Seo, Yong Su

要 旨

본 논문에서는 통계적 분류방법인 최대유사 분류법(MLC: maximum likelihood classifier)과 신경회로망을 이용한 분류법인 다층퍼셉트론(MLP: multilayer perceptron) 분류법간의 분류성능을 비교 평가하였으며, 또한 MLP 분류법에서 문제가 되고 있는 학습률(learning rate), 운동량 상수(momentum constant), 은닉층의 노드수에 따른 MLP 분류법의 분류성능을 평가하였다. 부산지역에 대한 실제 인공위성 화상데이터인 Landsat TM 화상데이터를 사용하여 MLP 분류법과 MLC 분류법의 성능을 비교한 결과 MLP 분류법의 성능이 더 우수함을 확인할 수 있었으며, 학습률, 운동량 상수 및 은닉층의 노드수에 따른 분류성능도 평가하였다.

ABSTRACT

In this paper, the performances between maximum likelihood classifier based on statistical classification and multilayer perceptrons based on neural network approaches were compared and evaluated. Experimental results from both neural network method and statistical method are presented. In addition, the nature of two different approaches are analyzed based on the experiments.

1. 서 론

지상관측용 인공위성으로부터 수집된 화상데이터는 토지이용 지도(land-use map)의 작성, 환경조사, 자원 탐사, 재해조사 및 군사적인 용도 등 여러 분야에 이용되고 있다.

이 화상데이터는 파장 대역별로 수집되는 다중분광 화상데이터(multispectral image data)로서 위와 같은 목적으로 활용하기 위해서는 원화상이 가지는 정보들을 이용하여 각 화소를 카테고리별로 분류해야 한다.

즉, 카테고리 분류(category classification)란 화상데이터의 각 화소를 도로, 주택지, 산림 등의 각 카테고리 분류하는 것을 의미한다.

카테고리 분류방법으로는 기존의 통계적인 분류방법과 최근의 새로운 방법으로 신경회로망을 이용한 분류방법으로 크게 나눌 수 있다. 통계적인 분류방법으로는 최단유클리드거리(MED: minimum Euclidean distance)법과 최대유사법(MLC: maximum likelihood classifier)등이 있다. MED 분류법은 트레이닝 데이터들의 평균값만을 특징값으로 이용하는 간단한 방법이

*동서대학교 대학원 전자공학과

*동서대학교 전자기계공학부 조교수

나 분류정답률이 높지 못하다. MLC 분류법은 트레이닝 데이터들의 평균값과 데이터들간의 분산, 공분산 값을 특징값으로 이용하는 분류법으로 분류정답률이 대단히 높으며, 데이터들의 확률밀도 함수가 Gaussian 분포를 가진다면 가장 우수한 분류방법이다. 그러나, 일반적인 데이터들의 확률밀도 함수는 Gaussian 분포가 아닐 경우가 보통이며, 이러한 데이터 분포를 가질 때는 분류정답률이 낮다[1]-[3].

신경회로망을 이용한 분류방법은 1990년 초기에 시작되어 관심을 가지게 된 최근의 분류방법으로 데이터들의 확률밀도 함수를 가정하지 않는 것이 큰 장점이다. 그러나, 이 방법의 단점은 신경회로망을 구성하기 위한 일반적인 판단 기준이 되는 이론이 없다. 그래서, 학습률은 얼마로 할 것인지, 운동량은 얼마로 할 것인지, 은닉층의 개수는 몇 개로 할 것인지를 결정하기가 매우 어렵다[1],[4].

신경회로망 모델로는 여러 가지 형태의 모델이 적용될 수 있지만 가장 널리 사용되는 신경회로망 모델은 다층퍼셉트론(MLP: multilayer perceptron) 모델 [5]-[7]이다. 이 MLP 모델은 오차 역전파 알고리즘(error back propagation algorithm)에 의해 트레이닝되는 다층순방향 회로망(multilayer feed-forward network)에 근거한 것으로 비선형 활성화함수(nonlinear activation function)로 시그모이드 함수(sigmoidal function)가 사용된다. 이 MLP가 처음으로 다중분광 화상데이터를 분류하는데 사용되기 시작한 것은 1989년 Decatur 논문이다[6],[8],[9]. 이후 Benediktsson et al.[10], Bishof et al.[2], Heermann et al.[4], Paola et al.[1] 등이 MLP로 분류 처리했다. MLP 이외의 신경회로망(N. Net: neural network) 모델로서는 Structured N. Net, radial-basis function N. Net, dynamic N. Net, binary diamond N. Net 등이 있으나[6], MLP 모델이 대표적으로 가장 널리 사용되고 있다.

신경회로망을 이용한 분류방법으로 대표적 방법인 MLP 분류법과 기존의 통계적 방법으로 가장 우수한 분류법인 MLC 분류법간의 분류성능 비교를 여러 논문에서 행하여 왔다. 분류성능을 비교한 결과 어떠한 논문들에서는 MLC분류법이 우수한 성능을 나타낸다

고 말하고 있으며[10],[11], 다른 논문들에서는 MLP 분류법이 더 우수한 성능을 나타낸다고 말하고 있다 [1],[2],[4],[12].

본 논문의 목적은 MLC 분류법과 MLP 분류법간의 분류성능을 비교 평가하는데 있으며, 또한 MLP 분류법에서 문제가 되고 있는 학습률(learning rate), 운동량 상수(momentum constant), 은닉층의 노드수에 따른 MLP 분류법의 분류성능을 검토해 보기 위함이다. 부산지역에 대한 인공위성 화상데이터인 Landsat TM 화상데이터를 사용하여 MLP 분류법과 MLC 분류법의 성능을 비교한 결과 MLP 분류법의 성능이 더 우수함을 확인할 수 있었으며, 학습률, 운동량 및 은닉층의 노드수에 따른 분류성능 평가도 함께 나타냈다.

2. 이 론

2.1. 최대유사 분류법(MLC: maximum likelihood classifier)

MLC 분류법은 각 카테고리별 확률밀도 함수를 Gaussian 분포로 가정하는 것으로 이러한 분포를 가질 경우는 가장 좋은 분류정답률을 나타내는 것으로 가장 널리 사용되는 분류법이며, 성능을 평가하는데 참고적인 분류법으로 자주 사용된다. 분류 알고리즘은 조건부 확률의 원리인 Bayes 정리에 근거한 분류 방법이다.

카테고리 분류할려는 화상데이터 P를 행렬로 표현하여 $P = [P_{hv}]$ 로 나타내고, 이것을 n개 종류의 카테고리 (w_1, w_2, \dots, w_n)으로 분류하려고 한다. 화소 P_{hv} 가 카테고리 w_j 로부터 관측된 데이터일 확률 $P(w_j | P_{hv})$ 는 Bayes정리에 의해서

$$p(w_j | P_{hv}) = \frac{p(w_j) \cdot (P_{hv} | w_j)}{p(P_{hv})} \quad \text{식(1)}$$

로 표현된다. 여기서 $j = 1, 2, \dots, n$ 로서 카테고리 수를 뜻한다.

이 식을 다음과 같은 순서로 전개해서 판별함수 (decision function)로 나타내기로 한다. 우선, 이 식에서 카테고리별로 값을 동일하게 가지는 것은 수식에서 없애고, 다음으로 양변에 대수(logarithm)를 취하고, 또 $P(w_j)$ 는 카테고리 w_j 의 출현 확률이므로 사전에 알수가 없으므로 출현확률을 동일하게 보아서 수식에서 없애고, Gaussian 분포 함수에 대한 확률밀도 함수로 표현한 후, 판별 함수 $f_j(P_{h_v})$ 로 나타내면

$$f_j(P_{h_v}) = \log |\Sigma_j| + (P_{h_v} - M_j)^t \cdot \Sigma_j^{-1} \cdot (P_{h_v} - M_j) \quad \text{식(2)}$$

- 이때, $j = 1, 2, 3, \dots, n$: 카테고리 수
- h : 화상의 수평 방향 좌표
- v : 화상의 수직 방향 좌표
- t : 전치 행렬
- -1 : 역행렬
- M_j : 평균 벡터
- Σ_j : 공분산 행렬

이 된다. 이 판별함수 $f_j(P_{h_v})$ 를 카테고리 수 만큼 계산하여 그 중에서 가장 작은 값을 나타내는 카테고리 w_j 에 화소 P_{h_v} 가 속하는 것으로 분류한다.

2.2. MLP(multilayer perceptron)

: 다층퍼셉트론)분류법

MLP 모델은 오차 역전파(error back propagation) 알고리즘, 혹은 일반화 델타룰 (generalized delta rule) 이라고도 하며, 신경회로망을 트레이닝 시키기 위해 현재 가장 널리 사용되고 있는 방법이다. 회로망의 구성 형태는 이웃한 층(layer)끼리만 연결을 가지고, 같은 층 내에서는 연결을 가지지 않는 다층(multilayer) 구조로 되어있다. 그림 2.1은 그 구조를 나타낸다.

정보가 인가되는 층을 입력층(input layer)이라고 하고, 처리된 정보가 나타나는 층을 출력층(output layer)이라고 한다. 입력층과 출력층 사이의 모든 중간 층을 은닉층(hidden layer)이라고 하는데 여러 개의

은닉층이 사용될 수 있으며, 그림 2.1은 두 개의 은닉 층을 가지는 경우를 나타내고 있다. 층과 층간의 모든 연결은 수치값(numerical value)을 가지고 있는데 이것을 가중치(weight)라고 한다. w_{ij} 는 노드 i 로부터 노드 j 에 이르는 연결 가중치를 표시한다. 입력층의 노드수는 각 대역수가 되고, 출력 층의 노드수는 분류하고자 하는 카테고리수가 되며, 은닉층의 노드수

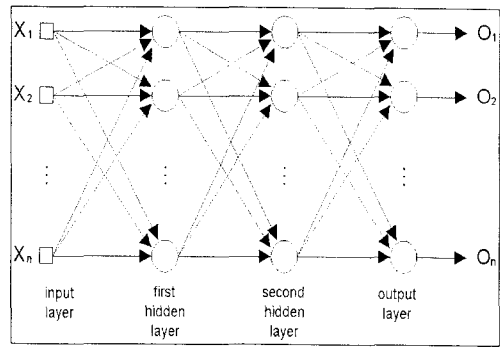


그림 2.1 두 개의 은닉층을 가진 MLP 신경 회로망의 구조

는 몇 개로 해야 한다는 뚜렷한 이론적인 지침이 없으므로 실험적으로 결정해야 한다.

MLP 분류법은 트레이닝 데이터{ $[X(n), D(n)]$; $n = 1, 2, \dots, N$ }를 가지고 다음과 같은 순서로 처리를 행한다.

1) 초기화

모든 연결 가중치 값들을 랜덤(random)한 작은 값으로 초기화 한다.

2) 트레이닝 데이터의 인가

트레이닝 데이터들은 입력노드에 인가하여 순방향 신호 전달(forward computation)과 역방향 오차계산(backward computation)을 반복 수행한다.

3) 순방향 신호전달(forward computation)

입력층에 인가되는 트레이닝 데이터 벡터를 $X(n)$, 출력층에 나타나야 할 목표 출력치 벡터를 $D(n)$ 할 때 트레이닝 데이터 $[X(n), D(n)]$ 를 신경

회로망에 인가하여 층과 층간의 순방향 순차 신호 전달이 이루어질 때 층(layer) ℓ 의 노드 j 에서 활성레벨(internal activity level) $v_j^{(\ell)}(n)$ 는

$$v_j^{(\ell)}(n) = \sum_{i=0}^p w_{ji}^{(\ell)}(n) \cdot y_i^{(\ell-1)}(n) \quad \text{식(3)}$$

이고, 층 ℓ 에서 노드 j 의 출력신호 $y_j^{(\ell)}(n)$ 는

$$y_j^{(\ell)}(n) = \frac{1}{1 + \exp(-v_j^{(\ell)}(n))} \quad \text{식(4)}$$

이다. 만약, 첫 번째 은닉층(즉, $\ell = 1$)의 노드 j 이면,

$$y_j^{(0)}(n) = x_j(n) \quad \text{식(5)}$$

이다. 이때 $x_j(n)$ 는 트레이닝 입력벡터 $X(n)$ 의 j 번째 요소이다. 또 만약, 출력층(즉, $\ell = L$)의 노드 j 이면,

$$y_j^{(L)}(n) = o_j(n) \quad \text{식(6)}$$

이다. 따라서 오차 신호를 계산하면,

$$e_j(n) = d_j(n) - o_j(n) \quad \text{식(7)}$$

이다. 이때 $d_j(n)$ 는 목표 출력벡터 $D(n)$ 의 j 번째 요소이다.

4) 역방향 오차 계산(backward computation)

층과 층간의 역방향 local gradient δ 는

$$\delta_j^{(L)}(n) = e_j^{(L)}(n) o_j(n) [1 - o_j(n)] \quad \text{식(8)}$$

: 출력층 L 의 노드 j 인 경우

$$\delta_j^{(\ell)}(n) = y_j^{(\ell)}(n) [1 - y_j^{(\ell)}(n)] \cdot$$

$$\sum_k \delta_k^{(\ell+1)}(n) \cdot w_{kj}^{(\ell+1)}(n) \quad \text{식(9)}$$

: 은닉층 ℓ 의 노드 j 인 경우

따라서, 일반화 델타룰에 의한 층 ℓ 에서 연결

가중치 $w_{ji}^{(\ell)}(n+1)$ 는

$$w_{ji}^{(\ell)}(n+1) = w_{ji}^{(\ell)}(n) + \alpha [w_{ji}^{(\ell)}(n) - w_{ji}^{(\ell)}(n-1)] + \eta \delta_j^{(\ell)}(n) y_i^{(\ell-1)}(n) \quad \text{식(10)}$$

로 조정된다. 이때 η 는 학습률 파라미터 이고, α 는 운동량 상수이다.

5) 반복 실행(iteration) : 새로운 트레이닝 데이터들을 계속 인가하면서, 전체 트레이닝 데이터에 대한 평균자승 오차(average squared error) ξ_{av} 는

$$\xi_{av} = \frac{1}{2N} \sum_{n=1}^N \sum_{j \in C} e_j^2(n) \quad \text{식(11)}$$

여기서, $e_j^2(n)$ 는 출력 층의 노드 j 에서 자승 오차이고, 오차 $e_j(n)$ 는 식 (7)의 관계이다.

이며, 이 오차가 미리 정의된 충분히 적은오차값에 도달하거나 혹은 만족할 만한 적은 값이 될 때까지 처리순서 2)부터 5) 까지를 반복 실행한다[5],[7].

3. 실험 결과 및 고찰

3.1 실험을 위한 화상데이터

분류법들 간의 성능을 평가하기 위하여 실제 인공 위성 분광 화상데이터를 사용하여 카테고리 분류를 수행하였다. 사용된 분광 화상데이터는 1989년 8월 31일 Landsat 5호에 의해 촬영된 부산지역에 대한 TM 화상데이터로, 총 7개 대역중 공간 분해능이 $120 \times 120 m^2$ 인 대역 6을 제외한 공간 분해능이 $30 \times 30 m^2$ 인 대역 1 ~ 5 및 대역 7의 6개를 분류에 사용하였으며, 화상의 크기는 512×400 이고, 각 화소는 256 회색준위(gray level)를 가진다.

분류할 카테고리수는 잡초지역(grass: GRA), 농업 지역(field: FLD), 도로(road: RD), 주택지(residential: RSD), 산림지역(forest: FOR), 바다(sea: SEA) 및 강(river: RIV)의 7개로 하였다.

트레이닝 데이터와 테스트 데이터는 각 대역의 조합에 의한 칼라화상의 확대 화상과 지도를 토대로하여 선정하였으며, 트레이닝 데이터로는 총 42개 지역에 대한 1991개 화소를 선정하여 분류를 수행하였다. 테스트 데이터로는 트레이닝 데이터를 수집할 때와 마찬가지로 지역에서 2148개 화소를 선정하여 분류성을 시험하였다. 표 3.1은 트레이닝 데이터와 테스트 데이터의 수를 나타내고 있다.

표 3.1 카테고리별 트레이닝 및 테스트 데이터의 수

Category	Training data	Test data
Grass(GRA)	286	284
Field(FLD)	280	309
Road(RD)	288	236
Residential(RSD)	280	284
Forest(FOR)	285	315
Sea(SEA)	280	305
River(RIV)	292	416
Total	1,991	2,148

3.2 MLC 분류법의 실행

MLC 분류를 행하기 위한 처리순서는 다음과 같다.

- step 1. 인공위성 화상데이터: Landsat TM 데이터
- step 2. 트레이닝 데이터 선정: 트레이닝 데이터 화소들의 x, y 위치를 선정한다.
- step 3. File Point 계산: 트레이닝 데이터들의 2차원적 x, y 위치들을 1차원적 file point 위치로 변환한다.
- step 4. 평균벡터 계산: 트레이닝 데이터들의 화소값의 평균값을 계산한다.
- step 5. 분산, 공분산 계산: 각 카테고리별로 Band 1 ~ Band 7까지의 분산과 공분산값을 계산한다.
- step 6. 행렬식, 역행렬 계산: 각 카테고리 별로 분산, 공분산 행렬에 대한 행렬식과 역행렬값을 계산한다.

step 7. MLC법에 의한 분류: 트레이닝 데이터들로부터 계산한 평균값, 분산, 공분산, 행렬식의 값을 이용하여 판별식 식(2)의 값을 계산 한후, 카테고리 분류를 행한다.

step 8. 분류정답률 계산: 분류처리 결과에 대한 분류정답률을 계산한다.

step 9. 분류결과 화상을 Display한다.

트레이닝 데이터로부터 구한 각 카테고리의 평균벡터는 표 3.2와 같다.

표 3.2 트레이닝 데이터의 각 카테고리별 평균벡터

Category	Band1	Band2	Band3	Band4	Band5	Band7
GRA	86.25	40.53	44.01	67.64	78.38	32.22
FLD	79.06	36.65	32.82	102.41	74.63	23.56
RD	99.56	45.17	53.24	46.62	67.30	39.36
RSD	108.52	51.50	63.14	58.12	94.20	57.00
FOR	69.34	28.24	23.79	80.12	63.72	18.54
SEA	78.89	29.56	23.80	11.78	7.75	3.56
RIV	90.86	46.61	54.68	23.60	7.55	3.35

3.3 MLP 분류법의 실행

3.3.1 MLP 분류를 위한 신경회로망의 구성

MLP 분류를 행하기 위한 신경회로망은 다음과 같이 구성하였으며 그림 3.1과 같다.




그림 3.1 본 실험에 사용한 MLP회로망 구성

입력 노드수는 특징량의 갯수에 의해 결정되므로, 본 논문에서는 6개 대역의 화소값을 특징량으로 사용하므로, 6개 입력노드를 가지는 신경회로망이 된다. 또한, 트레이닝 데이터의 화소 값을 [0, 1] 구간의 값으로 정규화(normalize)하여 입력노드에 인가했다. 은닉층 수는 1개로 하였으며, 은닉층의 노드수는 12 - 26개에 대하여 실험한 결과, 가장 적은 오차를 나타내는 것을 선택하였다. 본 논문에서는 은닉층의 노드수를 17개로 선택하였다. 출력노드수는 분류하고자 하는 카테고리 수에 의해 결정되며, 본 논문에서는 7개 카테고리로 분류하므로 7개의 출력노드를 가지는 회로망이 된다. 출력노드에 나타나는 값중 가장 큰 값을 가지는 것을 해당 카테고리로 분류한다.

그림 3.2는 MLP 분류법의 처리순서도를 나타내고 있다.

3.3.2 MLP 분류법의 처리결과 고찰

표 3.3은, 진동횟수가 적고 안정된 상태에서 빠른 시간내에 학습이 가능한, 학습률 η 와 운동량 상수 α 를 0.7, 0.3으로 선택한 상태에서, 은닉층 노드수를 12개에서 26개까지 변화시키면서, 평균자승 오차값이 만족할 만한 상태에 도달하게 되는, 반복횟수

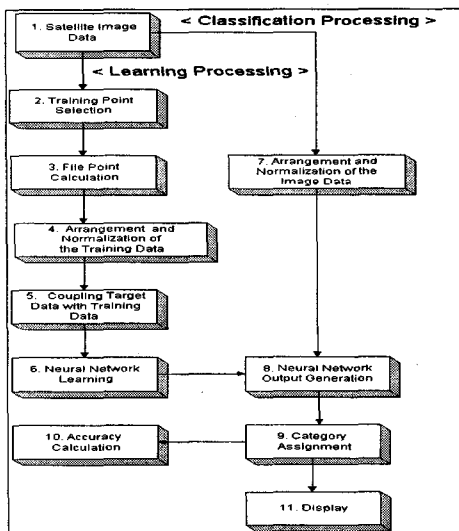


그림 3.2 MLP 분류법 처리 순서도

15,000회 실행시킨 결과에 대한 평균자승 오차값과 분류정답률을 나타내고 있다.

표 3.3에서 알수 있는 바와 같이 은닉층의 노드수가 12에서 26까지 모두에서 분류정답률이 98% 이상이며, 분류정답률의 차이는 0.25%이하로 그 차이가 적다. 본 실험에서는 평균자승 오차가 가장적고, 분류정답률이 가장 높은 것으로 은닉층 노드수를 17로 선택했다.

표 3.3 은닉층 노드수의 변화에 따른 분류성능 비교

Number of Hidden Node	Average Squared Error	Classification Accuracy(%)
12	0.0205	98.79
13	0.0200	98.89
14	0.0186	98.99
15	0.0183	98.94
16	0.0199	98.89
17	0.0169	99.04
18	0.0177	98.99
19	0.0194	98.89
20	0.0181	98.99
21	0.0193	98.99
22	0.0193	98.99
23	0.0188	98.99
24	0.0193	98.99
25	0.0179	98.99
26	0.0186	98.99

그림 3.3은 학습률 η 와 운동량상수 α 를 임의로 0.7, 0.3으로 선택한 상태에서 은닉층 노드수를 12개에서 26개까지 변화시키면서 15,000회 반복 실행시킨 결과에 대한 학습곡선으로 은닉층 노드수가 14, 16, 17, 20, 25에 대한 학습곡선을 나타낸 것이다. 학습곡선에서 검정색으로 나타낸 것은 은닉층 노드수가 14개일 때이고, 초록색은 은닉층 노드수가 16개일 때이고, 적색은 은닉층 노드수가 17개일 때이고, 노란색은 은닉층 노드수가 20개일 때이고, 청색은 은닉층 노드수가 25개일 때를 나타내고 있다. 이 그림에서

평균자승 오차값이 가장 적은 것은 은닉층 노드수가 17개일 때로 진동이 가장 빨리 멈추고 안정되게 학습되고 있음을 알 수 있다. 이는 표 3.3에서 평균자승 오차값이 0.0169로 가장 적고, 분류정답률이 99.04%로 가장 높은 경우의 학습곡선임을 알 수 있다. 다음으로 평균자승 오차값이 적은 것은 은닉층 노드수가 25, 20, 14, 16개일 때의 순서인데, 25, 20, 14개일 때는 평균자승 오차값의 차이가 적으므로 표 3.3에서와 같이 분류정답률은 모두 98.99%로 동일함을 알 수 있다. 16개일 때는 평균자승 오차값이 가장 크므로 이에 대한 분류정답률은 98.89%로 이들 5가지 경우 중 가장 낮다. 따라서 높은 분류정답률을 얻기 위해서는 첫째, 평균자승 오차값이 적은 것 둘째, 오차값이 비슷하다면 학습시 진동횟수가 작은 것 셋째, 진동횟수가 비슷하다면 학습이 끝날 때 진동이 없는 것이어야 함을 확인할 수 있다. 따라서 이들 결과를 종합해 볼 때 은닉층 노드수는 17개로 선택하는 것이 가장 적당함을 알 수 있다.




그림 3.3 은닉층 노드수의 변화에 따른 학습곡선(learning curves)

표 3.4는 은닉층 노드수를 17로 선택한 상태에서 학습률과 운동량 상수를 변화시키면서 15,000회 반복 실행시킨 결과에 대한 평균자승 오차값과 분류정답률을 나타내고 있다. 표 3.4에서 알 수 있는 바는 학습률과 운동량 상수가 각각 0.9, 0.9일 때와 0.7, 0.9일 때를 제외한 모든 경우에서 평균자승 오차값은 0.025 ~ 0.016 정도의 범위로 작은 값을 가지며, 분류정답률도

98%이상으로 높다.

표 3.4 학습률(η)과 운동량 상수(α)의 변화에 따른 분류성능 비교

Learning Rate η	Momentum Constant α	Average Squared Error	Classification Accuracy(%)
0.1	0.1	0.0224	98.84
0.1	0.3	0.0213	98.59
0.1	0.5	0.0200	98.64
0.1	0.7	0.0192	98.79
0.1	0.9	0.0196	98.69
0.3	0.1	0.0199	98.81
0.3	0.3	0.0175	98.74
0.3	0.5	0.0256	98.99
0.3	0.7	0.0173	98.94
0.3	0.9	0.0177	98.99
0.5	0.1	0.0204	98.84
0.5	0.3	0.0171	98.99
0.5	0.5	0.0186	98.99
0.5	0.7	0.0165	99.09
0.5	0.9	0.0309	98.34
0.7	0.1	0.0172	98.89
0.7	0.3	0.0169	99.04
0.7	0.5	0.0162	99.04
0.7	0.7	0.0180	99.04
0.7	0.9	0.1172	81.96
0.9	0.1	0.0181	98.94
0.9	0.3	0.0179	98.99
0.9	0.5	0.0176	98.99
0.9	0.7	0.0172	98.99
0.9	0.9	0.4997	14.41

평균자승 오차는 학습률이 0.7이고 운동량 상수가 0.5일 때 가장 적은 값을 나타내고, 분류정답률은 학습률이 0.5이고 운동량 상수가 0.7일 때 가장 높은 값을 가진다.

그림 3.4는 은닉층 노드수를 17로 선택한 상태에서 학습률과 운동량 상수를 변화시키면서 15,000회 반복

실행시킨 결과에 대한 학습곡선으로 학습률과 운동량 상수가 각각 (0.1, 0.3), (0.3, 0.7), (0.5, 0.7), (0.7, 0.5), (0.9, 0.3)에 대한 학습곡선을 나타낸 것이다. 학습곡선에서 점정색으로 나타낸 것은 학습률과 운동량 상수가 각각 0.1, 0.3일 때이고, 초록색으로 나타낸 것은 학습률과 운동량 상수가 각각 0.3, 0.7일 때이고, 적색으로 나타낸 것은 학습률과 운동량 상수가 각각 0.5, 0.7일 때이고, 노란색으로 나타낸 것은 학습률과 운동량 상수가 각각 0.7, 0.5일 때이고, 청색으로 나타낸 것은 학습률과 운동량 상수가 각각 0.1, 0.3일 때를 나타내고 있다. 이 그림에서 평균자승 오차값이 가장 적은 것은 0.7, 0.5일 때로 평균자승 오차값은 가장 적지만, 분류정답률은 두 번째로 높다. 0.5, 0.7일 때는 평균자승 오차값은 두 번째이지만, 분류정답률은 가장 높다. 따라서 평균자승 오차값이 적다고 분류정답률이 더 높은 것은 아니다. 또한 알 수 있는 것은 평균자승 오차값의 차이가 적을 때는 분류정답률에 미치는 영향이 적음을 확인 할 수 있었다.

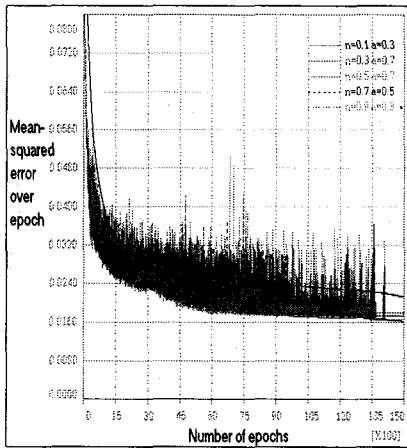


그림 3.4 학습률과 운동량 상수의 변화에 따른 학습곡선(learning curves)

3.3.3 결과 및 고찰

은닉층 노드수의 선택방법은 임의의 학습률과 운동량 값을 선택한 후 은닉층 노드수를 변화시켜 가장 적은 평균자승 오차값을 나타내는 노드수를 선택한다.

학습률 η , 운동량 α 의 선택방법은, 첫번째 방법으로, 최적의 값이 존재하여 고정시킨 상태에서 학습시키는 것이 아니라 $\eta = 0.7$, $\alpha = 0.5$ 정도에서 시작하여 진동이 없는 상태까지 학습시킨후 진동이 생기는 시점에서 점차 η 와 α 값을 변동시키면서 학습시키면 적은 반복횟수로도 평균자승 오차값이 가장 적은 상태로 학습시킬 수 있다. 두번째 방법으로는 $\eta = 0.7$, $\alpha = 0.5$ 또는 $\eta = 0.7$, $\alpha = 0.3$ 으로 고정시킨 상태에서 평균자승 오차값이 현저히 감소하지 않는 시점까지 반복 학습시킨다. 이 두가지 방법을 비교할 때 첫번째 방법의 분류정답률이 높으나, 그 차이는 미약하고, 학습과정에 관여하여 진동 여부를 확인 해야하는 번거로움이 있으므로 두번째 방법이 바람직하다.

은닉층 노드수의 변화는 분류정답률에 대해 적은 영향을 미치고, 또한 평균자승 오차값의 차이에 따른 분류정답률에 대한 영향도 적음을 확인 하였다.

높은 분류정답률을 얻기 위해서는 첫째, 평균자승 오차값이 적은 것 둘째, 오차값이 비슷하다면 학습시 진동횟수가 적은 것 셋째, 진동횟수가 비슷하다면 학습이 끝날 때 진동이 없는 것어야 함을 확인할 수 있었다.

3.4 MLC 및 MLP 분류법에 의한 분류 결과

3.4.1 분류정답률 비교

MLC 분류법과 MLP 분류법에 대하여 트레이닝 데이터와 테스트 데이터에 대한 분류정답률을 계산한 결과는 각각 표 3.5 및 표 3.6에 나타낸 바와 같다. 표 3.5에서 전체적인 분류정답률은 MLC의 97.5% 보다 MLP 분류법의 99.1%가 1.5%정도 개선되었으며, 오분류률로 볼 때는 MLC는 2.42%이고, MLP는 0.9%로 MLC에 비하여 약 2.5배 낮다. 부분적으로도 잡초지역은 MLC가 96.15% 이나, MLP는 100%로 높은 등 모든 카테고리에서 MLP 분류법의 분류정답률이 높다.

이들 표 3.5 및 3.6에서 분류정답률을 비교해 보면, 트레이닝 데이터와 테스트 데이터 모두에서 MLC 분류법보다는 MLP 분류법의 분류정답률이 우수하였다.

표 3.5 트레이닝 데이터에 대한 각 분류법의 분류정답률

Actual category	Number of pixels	Classification method	Assigned category							PCC**
			(A)	(B)	(C)	(D)	(E)	(F)	(G)	
GRA(A)	286	MLC	275	11						96.15
		MLP	286							100.00
FLD(B)	280	MLC	2	275	2	1				98.21
		MLP	2	278						99.29
RD(C)	288	MLC	2		270	14	1	1		93.75
		MLP	1		279	6	1	1		96.87
RSD(D)	280	MLC			3	276		1		98.57
		MLP			1	278		1		99.29
FOR(E)	285	MLC	1	1			283			99.30
		MLP	1				284			99.65
SEA(F)	280	MLC						277	3	98.93
		MLP						280		100.00
RIV(G)	292	MLC	3	1				1	287	98.29
		MLP	4						288	98.63
Average PCC** : MLC 97.58%, MLP 99.10%										
Overall PCC** : MLC 97.59%, MLP 99.09%										

표 3.6 테스트 데이터에 대한 각 분류법의 정답률

Actual category	Number of pixels	Classification method	Assigned category							PCC**
			(A)	(B)	(C)	(D)	(E)	(F)	(G)	
GRA(A)	283	MLC	273	8			2			96.47
		MLP	277	1	1		4			97.88
FLD(B)	309	MLC		308			1			99.68
		MLP		305			4			98.71
RD(C)	236	MLC	7	2	217	6	4			91.95
		MLP	3	1	221	3	6		2	93.64
RSD(D)	284	MLC		1	2	280	1			98.59
		MLP	1		2	280	1			98.59
FOR(E)	315	MLC		3			312			99.05
		MLP	2	1			312			99.05
SEA(F)	305	MLC			1			298	6	97.70
		MLP						299	6	98.03
RIV(G)	416	MLC	1	2			1	2	410	98.56
		MLP	1	2			1	2	410	98.56
Average PCC** : MLC 97.43%, MLP 97.78%										
Overall PCC** : MLC 97.67%, MLP 97.95%										

3.4.2 분류결과 화상

MLC 분류법 및 MLP 분류법에 의한 분류결과 화상은 각각 그림 35 및 그림 36 과 같다.

그림 35 및 그림 36에서 각 카테고리별 색상은 잡초지역은 짙은청색으로, 농업지역은 적색으로, 도로는 분홍색으로, 주택지역은 녹색으로, 바다지역은 노란색으로, 강지역은회색으로 나타나고 있다. 이들 두 개의




그림 35 실 화상데이터에 대한 MLC 분류 결과화상

분류결과 화상에서 눈에 띄게 오분류된 것은 도심의 빌딩이나 시멘트 구조물들이 도로로 분류되고 있는데, 이는 분류 카테고리수가 7가지로 제한되어 있기 때문이다. 이들 오분류된 것을 개선시키기 위해서는 도로와 주택지를 도로, 빌딩, 시멘트 구조물 및 주택지 등으로 분류 카테고리수를 세분화 하여야한다. MLC 분류 결과화상에 비하여 MLP 분류 결과화상에서는 농업지역내의 잡초지역, 산림




그림 36 실 화상데이터에 대한 MLP 분류 결과화상

지역 주변의 잡초지역에 대한 오분류가 줄어들고, 바다부분에서 도로나 강으로 오분류되는 것이 줄어들며, 강지역에서 바다로 오분류되는 것이 줄어들음 확인 할 수 있다.

4. 결 론

본 논문에서는 기존의 통계적 분류방법인 MLC 분류법과 최근의 새로운 방법인 신경회로망을 이용한 MLP 분류법의 분류성능을 비교 검토하였다. 분류 실험은 실제의 인공위성 분광 화상데이터를 사용하여 행한 결과, 트레이닝 데이터와 테스트 데이터 모두에서 MLC 분류법보다는 MLP 분류법의 분류정답률이 우수함을 확인 할 수 있었다.

은닉층 노드수의 선택방법은 임의의 학습률과 운동량 값을 선택한 후 은닉층 노드수를 변화시켜 가장 적은 평균자승 오차값을 나타내는 노드수를 선택한다.

학습률 η , 운동량 α 의 선택방법은, 본문 3.3.4절에서 논의한 두가지 방법을 비교할 때 첫 번째 방법의 분류정답률이 높으나, 그 차이는 미약하고, 학습과정에 관여하여 진동 여부를 확인해야 하는 번거로움이 있으므로 두 번째 방법이 바람직하다.

은닉층 노드수의 변화는 분류정답률에 대해 적은 영향을 미치고, 또한 평균자승 오차값의 차이에 따른 분류정답률에 대한 영향도 적음을 확인 하였다.

높은 분류정답률을 얻기 위해서는 첫째, 평균자승 오차값이 적은 것 둘째, 오차값이 비슷하다면 학습시 진동횟수가 적은 것 셋째, 진동횟수가 비슷하다면 학습이 끝날 때 진동이 없는 것어야 함을 확인할 수 있었다.

본 논문에 이어 계속 진행해 나갈 연구과제는 공간정보의 정의와 결합방법에 의한 분류성능을 평가해 보는 것인데, MLP 분류법은 공간정보의 정의 및 추가가 MLC 분류법 보다 용이하므로 다중 분광 화상데이터의 카테고리 분류법으로는 신경회로망에 의한 분류 방법이 더 성능이 우수한 방법이 될 것으로 생각 된다.

참 고 문 헌

- [1] D. Paola and R. A. Schowengerdt, "A Detailed Comparison of Back-propagation Neural Network and Maximum-Likelihood Classifiers for Urban Land Use Classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 33, no. 4, pp. 981-996, July 1995.
- [2] H. Bischof, W. Schneider, and A. J. Pinz, "Multispectral Classification of Landsat-Image using Neural Network," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 30, pp. 482-490, May 1992.
- [3] T. Yoshida and S. Omatu, "Neural Network Approach to Land Cover Mapping," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 32, no. 5, pp. 1103-1109, Sept 1992.
- [4] P. D. Heermann and N. Khazenie, "Classification of Multispectral Remote Sensing Data using a Back-Propagation Neural Network," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 30, pp. 81-88, Jan. 1992.
- [5] S. Haykin, *Neural Networks A Comprehensive Foundation*, Macmillan Publishing Company, 1994.
- [6] C. H. Chen, *Fuzzy Logic and Neural Network Handbook*, McGraw-Hill, Inc. 1996.
- [7] R. P. Lippmann, "An Introduction to Computing with Neural Networks," *IEEE, Acoust., Speech, Signal Processing Mag.*, pp. 4-22, Apr 1987.
- [8] S. E. Decatur, "Application of Neural Networks to Terrain Classification," in *Proc. IJCNN*, Washington D. C., 1989, vol. 1, pp. 283-288.
- [9] S. B. Serpico and F. Roli, "Classification of Multisensor Remote Sensing Images by Structured Neural Networks," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 33, no. 3, pp. 562-578, May 1995.
- [10] J. A. Benediktsson, P. H. Swain, and O. K. Ersoy, "Neural Network Approaches Versus Statistical Methods in Classification of Multisource Remote Sensing Data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 28, no. 4, pp. 540-552, July 1990.
- [11] D. L. Civco, "Landsat TM Image Classification with an Artificial Neural Network," in *Proc. ASPRS-ACSM Ann. Meeting*, Baltimore, MD, vol. 3, pp. 67-77, 1991.
- [12] I. Kanellopoulos, G. G. Wilkinson, and J. Megier, "Intergration of Neural Network and Ststistical Image Classification for Land Cover Mapping," in *Proc. IGARSS*, Tokyo, Japan, pp. 511-513, Aug. 1993