

인공신경망 이론을 이용한 위성영상의 카테고리분류

Multi-temporal Remote-Sensing Image Classification Using Artificial Neural Networks

강문성(서울대) · 박승우(서울대) · 임재천*(서울대)

Kang, Moon Seong · Park, Seung Woo · Lim Jae Chon

Abstract

The objectives of the thesis are to propose a pattern classification method for remote sensing data using artificial neural network. First, we apply the error back propagation algorithm to classify the remote sensing data. In this case, the classification performance depends on a training data set. Using the training data set and the error back propagation algorithm, a layered neural network is trained such that the training pattern are classified with a specified accuracy. After training the neural network, some pixels are deleted from the original training data set if they are incorrectly classified and a new training data set is built up. Once training is complete, a testing data set is classified by using the trained neural network. The classification results of Landsat TM data show that this approach produces excellent results which are more realistic and noiseless compared with a conventional Bayesian method.

I. 서론

인공신경망을 이용한 위성영상의 피복분류는 1990년 초기에 시작되어 관심을 가지게 된 최근의 분류방법으로 데이터들의 확률밀도 함수를 가정하지 않는 것이 가장 큰 장점이다. 인공신경망 모델로는 여러 가지 형태의 모델이 적용될 수 있지만 가장 널리 사용되는 인공신경망 모형은 다층퍼셉트론(multilayer perceptron, MLP)모델이다 (Paola 등, 1995; Heermann 등, 1992). 이 MLP 모델은 오류 역전파 알고리즘(error back propagation algorithm, EBP)에 의해 트레이닝 되는 다층 순방향 회로망 (multilayer feed-forward network)에 근거한 것으로 비선형 활성화함수(nonlinear activation function)로서 시그모이드 함수(sigmoidal function)을 사용하고 있다.

본 연구의 목적은 다시기의 Landsat TM 영상을 이용한 소유역의 토지피복변화를 평가하기 위하여, 시험유역을 선정하고, 다시기 위성영상을 대상으로 최대우도분류법에 의한 감독분류 및 무감독 분류를 수행하며, 인공신경망이론을 이용한 카테고리 분류를 수행하고, 각각의 분류 방법의 성능을 평가 비교하는 데 있다.

II. 모형의 구성

1. 최대우도법

MLC 분류법은 각 카테고리별 확률밀도 함수를 Gaussian 분포로 가정하는 것이다. MLC 분류법은 Gaussian 분포를 가질 경우에 가장 좋은 분류정답율을 나타내는 것으로 보고되고 있으며, 성능을 평가하는데 참고적인 분류법으로 가장 널리 사용되는 분류법이다. 분류 알고리즘은 조건부 확률의 원리인 Bayes 정리에 근거한 분류 방법이다.

2. 인공신경망 모형

2.1 신경망의 기본 연산과정

신경망 모형의 연산과정은 가장 많이 보고되어지고 있는 다층 퍼셉트론을 중심으로 소개하도록 한다. 신경망의 연산은 인간 두뇌의 처리과정을 수학적으로 표현한 처리소자에 의해서 이루어진다. Fig. 1은 인간의 두뇌를 모델링 한 기본적인 신경망 단일소자인 뉴런의 구조를 보여주고 있다.

뉴런의 연산과정은 Fig. 1에서와 같이 입력자료 (input signal)인 X_i 와 연결강도 (synaptic weights)의 벡터인 W_{ji} 에 의한 곱의 형태로 나타내어지는 결합함수 (summing junction)인 Σ 가 계산된다. 이 결합함수로부터 출력이 선형 또는 비선형적인 특성을 가지게 하는 활성화함수 (activation function)를 통해 출력의 과정으로 연산이 수행되어진다.

단지 입력층과 출력층으로만 구성된 단순 퍼셉트론의 한계를 보완하기 위해 입력층과 출력층 사이에 하나 이상의 은닉층을 둔 것이 다층 퍼셉트론이다. Fig. 2는 은닉층이 하나인 전형적인 다층 퍼셉트론의 구조를 보여주고 있다.

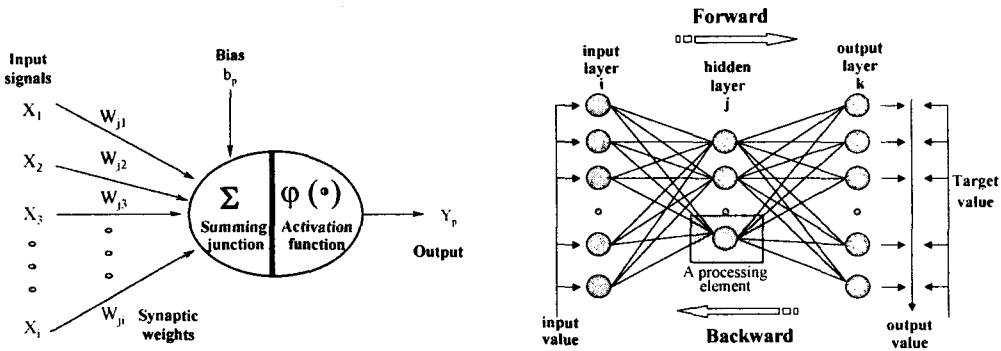


Fig. 1. Architecture of artificial neural network

Fig. 2. Structure of multilayer neural network

2.2 모형의 구성

본 연구에서의 카테고리 분류 모형은 다층 신경망 구조로 구성되며, 학습방법은 신경망 이론에서 가장 널리 이용되고 있는 오류역전파 (error back propagation, EBP) 알고리즘을 사용하였다. 오류역전파 알고리즘은 일반화된 델타규칙 (generalized delta rule)으로서, 출력층의 오차를 먼저 계산하고, 오차의 미분으로 표현되는 값을 은닉층으로 역전파시켜 연결강도를 반복적으로 조정해 나가는 방법이다.

다층 순방향 신경망(feed-forward neural networks) 훈련은 실측치와 모의치의 비선형 최소 사승인 가중함수를 최소화하는 것으로서 교사훈련(supervised training)이라고 한다. 이것은 다음 식 (1)과 같이 나타내어진다.

$$E = \frac{1}{2} \sum_{p=1}^n \sum_{k=1}^m (y_{pk} - d_{pk})^2 \quad (1)$$

여기서, E는 총오차, n은 실측치의 패턴 수, m은 총 출력단위, y_{pk} 는 실측된 반응인 목표 출력값으로서 카테고리, d_{pk} 는 모델에 의한 모의 출력값으로서 모의 카테고리를 나타낸다.

본 모형에서는 최적화기법인 경사하강법에 학습과정에서 발생할 수 있는 지역 최소값(local minima value) 문제와 오차를 최소화하고 수렴속도를 향상시키기 위해 적응학습률(adaptive learning rate)에 모멘텀법(momentum)을 고려하였으며, 식 (2)와 같이 나타내어진다.

$$\Delta W_{kj}(t+1) = \eta \delta_{pk} h_{kj} + \alpha \Delta W_{kj}(t) \quad (2)$$

여기서, $\Delta W_{kj}(t+1)$ 는 연결강도의 조정량, δ_{pk} 는 p번째 패턴에 대한 출력층의 오차, α 는 모멘텀 계수이다. 모멘텀 계수는 0에서 1 사이의 값을 가지며, Pahan Pao에 의하면 실험적으로 제안된 모멘텀 계수는 0.9, 학습률은 0.7이었다(김주환, 1993). 선행 연구에 의하면, 모멘텀 계수는 주로 0.9~0.95를 사용하였으며, 본 연구에서는 모멘텀 계수와 학습률을 병행하여 오차의 감소 여부를 확인하여 증감시킴으로써 최적의 값을 추출하였고, 그 결과 모멘텀 계수는 0.95, 학습률은 0.7인 것으로 나타났다.

은닉층에서의 최적 노드수를 얻기 위한 방법으로 Rissanen(1978)가 제안한 Bayesian Information Criterion (BIC)을 사용하였으며, 그 식은 다음과 같다.

$$BIC = M \ln(MSE) + P \ln M \quad (3)$$

여기서, M은 신경망의 자료수, MSE는 평균사승오차, 그리고 P는 매개변수의 수(weights and biases)를 나타낸다.

2. 3 모형의 입출력 자료

본 모형의 시그모이드 함수는 최소값 0과 최대값 1을 전달하므로 모든 자료는 이론적인 정규화 범위로 변환하였으며, 식 (4)와 같다.

$$X' = \left[\frac{1}{(X_{max} - X_{min})} \right] \times (X - X_{min}) \quad (4)$$

여기서, X' 은 변환된 변수이고, X_{max} 와 X_{min} 은 보정 기간동안 사용된 실측자료의 최대값과 최소값이다.

본 연구에서는 모형의 입력층에서의 화소값을 고려하여 여러 형태의 모형을 구성하였으며, 최적 모형으로 Model76모형을 선정하였다. Model76 모형은 위성영상의 7개 밴드를 입력층으로 하고, 출력층으로 7개의 카테고리를 변수로 선정하여 구성하였다. 구성된 각 모형의 식은 다음과 같다.

$$Model76; O(c1, c2, c3, c4, c5, c6) = fuction(B(1), B(2), B(3), B(4), B(5), B(6), B(7)) \quad (5)$$

여기서, O(ci)는 카테고리별 출력값, B(i)는 i번째 밴드의 화소값이다.

Ⅲ. 영상처리

1. 시험구역

본 연구의 시험구역은 경기도 화성군 봉담읍과 팔탄면 소재 발안저수지와 기천저수지 유역을 선정하였다. 본 소유역을 택한 이유는 산간지, 중산간지, 평탄지, 취락지 등 다양한 토지피복상태를 보이고 있어, 위성영상을 이용한 우리나라 농촌 소유역의 토지피복변화를 평가하는데 용이하기 때문이다. 또한, 1996년부터 서울대 농공학과에서 수문/수질관측을 통한 강우-유출 특성 분석 자료와 비점오염원의 정량적 해석 자료가 구축되어 있기 때문에 다양한 토지피복상태에 따른 수문·수질 변화 분석이 용이하기 때문이다.

2. 위성영상 자료

위성영상의 전처리는 워크스테이션 ERDAS IMAGINE-8.3.0 (1997)을 사용하였고, 위성영상의 분석은 지리정보 및 위성영상의 분류를 목적으로 개발된 PC용 IDRISI (Eastman, 1990)를 이용하였다.

분류 대상 위성영상은 Table 1에서와 같이 Landsat-5의 Thematic Mapper Sensor에 의하여 관측된 Path 116/Row 34의 영상중 남동쪽 사분을 사용하였다. 대상영상은 경기도 일대와 서해 지역, 충청북도, 그리고 서울 등의 일부지역이 포함되어 있다. Landsat-5 위성은 1984년에 발사되었으며, 상공 700~900 km, 회전주기 매 16일, 그리고 분광밴드는 7개이며, 공간해상력은 30 m×30 m 이다.

Table 1. Characteristics of Remote sensing data

No. of Scene	Path-Row	Date	Time	Cloud Coverage (%)	Data Size (MB)	REMARK
1	116-34	00/03/20	01:45:02	2	279.9	TM
2	116-34	98/11/10	01:50:02	0	279.9	TM
3	116-34	96/09/01	01:27:59	1	279.9	TM
4	116-34	92/09/22	01:33:01	0	279.9	TM
5	116-34	90/04/10	01:31:12	0	279.9	TM

3. 위성영상의 전처리

인공위성의 자세, 지구의 회전, 곡률 등에 따른 왜곡이 생기게 되며, 이와 같은 상대적인 변위에서 발생하는 기하학적인 왜곡을 보정해 주어야만 한다. 또한, 영상 반사치의 영향으로 발생하는 요인을 제거하기 위해 방사량 보정을 실시하였다. 좌표변환을 실시하여 최소자승법에 의해 RMSE (Root Mean Square Error)을 계산한 결과는 Table 2에서와 나타내는 바와 같다.

Table 2. Results of resampling

No. of Scene	Date	Time	GCP			
			No. of GCP	X residual	Y residual	RMSE
1	00/03/20	01:45:02	34	0.1376	0.0734	0.1559
2	98/11/10	01:50:02	34	0.1338	0.0848	0.1584
3	96/09/01	01:27:59	34	0.1097	0.1099	0.1553
4	92/09/22	01:33:01	34	0.1160	0.1308	0.1749
5	90/04/10	01:31:12	34	0.1068	0.1162	0.1578
평균				0.12	0.10	0.16

4. 밴드의 선정

다시기 영상의 토지이용분류를 위한 밴드의 선정은 식생정보를 잘 반영하는 식생지수 및 수분과 광물의 특성을 반영하는 지수밴드로 구성하였다.

식생지수는 식물의 활력도 및 녹피율에 따른 가시광선 및 근적외선 파장대 광선의 반사량의 차이를 이용하여 추출한다. 현재까지 개발된 식생지수 중에서 가장 정교한 것은 Kauth와 Thomas(1976)가 Gram-Schmidt의 연속직교기법 (Sequential Orthogonalization Technique)을 이용하여 개발한 Tasseled Cap 변환지수이다. 따라서, 본 연구의 토지이용분류에 사용된 식생지수는 토양명도지수 (Soil Brightness Index), 녹색식생지수 (Green Vegetation Index), 그리고 토양수분지수 (Soil Moisture Index)이다. 본 연구에서 사용한 Tasseled Cap 변환계수는 Table 4에서와 같다. 지수밴드는 반사체의 식생이외의 정보를 추출하기 위해 물과 광물의 특성을 반영한 것으로서, 물의 경우 밴드구성은 TM2/TM1, 광물의 경우 TM3/TM1, TM5/TM7, 그리고 TM5/TM4로 구성하였다.

Table 3. Tasseled Cap transformation coefficients of TM data (Crist and Cicone, 1984)

Index	TM BAND					
	1	2	3	4	5	7
SBI	0.33138	0.33121	0.55177	0.42514	0.48087	0.25252
GVI	-0.24717	-0.16263	-0.40639	0.85468	0.05493	-0.11749
SMI	0.13929	0.22490	0.40359	0.25178	-0.70133	-0.45732

*SBI; Soil Brightness Index, GVI; Green Vegetation Index, SMI; Soil Moisture Index

5. 토지피복분류 결과

Fig. 5는 시험지구의 재배열을 통한 다시기 영상에 대해 최대우도법에 의한 토지피복분류의 결과 예를 보여주고 있다.




Fig. 5 The Image of Land Cover Classification for Resampling Area.

IV. 요약 및 결론

본 연구에서는 다시기의 Landsat TM 영상을 이용한 소유역의 토지피복변화를 평가하기 위하여, 시험유역을 선정하고, 다시기 위성영상을 대상으로 최대우도분류법에 의한 감독분류 및 무감독 분류를 수행하였으며, 인공신경망이론을 이용한 카테고리 분류를 수행하여, 각각의 분류방법의 성능을 평가 비교함으로써, 신경망 이론의 위성영상 분류기법에의 적용성을 평가하였다.

참고문헌

1. 강문성, 박승우, 2000. 다시기 위성영상을 이용한 소유역의 토지피복변화 평가, 한국농촌계획 학회지, 제6권 제2호, pp. 50-57.
2. 강문성, 박승우, 2001. 인공신경망 이론을 이용한 소유역에서의 장기유출해석, 한국농공학회 지, 제43권 제2호, pp. 69-77.
3. 최진규, 강문성, 2000. 신경망 (이론)과 수자원 분야에의 이용, 한국관개배수지.
4. Heermann P. D. and N. Khazenie, 1992. Classification of Multispectral Remote Sensing Data Using a Back-propagation Neural Network, IEEE Transactions on Geoscience and Remote Sensing, Vol. 30, No. 1, pp. 81-88.
5. Jackson, T.J., R.M. Ragan, and W.N. Fitch, 1977, Test of Landsat-Based Urban Hydrologic Modeling, J. Water Resour. Plann. Manage. Div., ASCE 103(WR1) : 141-158.
6. Jensen, John R., 1996, Introductory Digital Image Processing : A Remote Sensing Perspective, Englewood Cliffs, New Jersey , Prentice-Hall.
7. Paola D. and R. A. Schowengerdt, 1995. 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.