

퍼지 신경회로망을 이용한 원격감지 영상의 분류

(Classification of Remotely Sensed Images Using Fuzzy Neural Network)

李駿幸*, 黃錫胤**, 金孝成***, 李在旭*, 徐龍洙****

(Jun Jae Lee, Seok Yoon Hwang, Hyo Sung Kim, Jae Uk Lee, and Yong Su Seo)

요 약

본 논문에서는 원격감지 영상데이터(remotely sensed image data)를 분류하기 위해 퍼지 신경회로망을 이용하는 방법을 제안한다. 이 신경회로망은 기존의 역전파 알고리즘에서 입·출력값을 실수값에서 퍼지값으로 대체시킨 퍼지 역전파 알고리즘을 사용한다. 제안한 퍼지 역전파 신경회로망(FBPNN: fuzzy back propagation neural network)분류법에서는 훈련 데이터의 각 영역별 히스토그램으로 부터 퍼지패턴을 발생시켜, 이 퍼지패턴을 실수값과 함께 퍼지 신경회로망으로 입력시킨다. 퍼지패턴의 첨가로 인하여 입력 데이터의 복잡한 경계를 더욱 잘 학습시킬 수 있으므로 기존의 역전파 신경회로망(BPNN: back propagation neural network)분류법보다 일반화 및 근사화가 우수함을 확인할 수 있다.

Abstract

This paper describes the classification of remotely sensed image data using fuzzy neural network, whose algorithm was obtained by replacing real numbers used for inputs and outputs in the standard back propagation algorithm with fuzzy numbers. In the proposed method, fuzzy patterns, generated based on the histogram of each category for the training data, are put into the fuzzy neural network with real numbers. The results show that the generalization and approximation are better than that of the conventional network in determining the complex boundary of patterns.

I. 서 론

지상관측용 인공위성으로부터 수집된 원격감지 영

* 正會員, 東西大學校 컴퓨터工學科

(Dept. of Computer Eng., Dongseo Univ.)

** 正會員, 大邱大學校 數學科

(Dept. of Mathematics, Taegu Univ.)

*** 學生會員, 釜山大學校 電子工學科

(Dept. of Electronic Eng., Pusan Nat'l Univ.)

**** 正會員, 東西大學校 電子工學科

(Dept. of Computer Eng., Dongseo Univ.)

接受日字: 1997年11月18日, 수정완료일: 1998年1月23日

상데이터는 토지이용 지도(land-use map)의 작성, 환경조사, 자원탐사, 재해조사 및 군사적인 용도 등 여러 분야에 이용되고 있다. 이 영상데이터는 파장 대역별로 수집되는 다중분광 영상데이터(multispectral image data)로서 위와같은 목적으로 활용하기 위해서는 원영상이 가지는 정보들을 이용하여 각 화소를 영역별로 분류해야 한다. 즉, 영역분류(category classification)란 영상데이터의 각 화소를 도로, 주택지, 산림 등의 각 영역으로 분류하는 것을 의미한다¹⁻⁸⁾

원격탐지 데이터의 영역분류에서 문제점은 하나의 화소가 여러 가지 성분이 섞인 경우에 (mixed pixel) 이를 가지고 훈련시키면 오류가 많이 발생한다는 것이

다^[4-8]. 실제 실험에 사용된 인공위성에서 촬영한 영상 데이터는 하나의 화소가 $30 \times 30 \text{m}^2$ 로 지표면의 여러 가지 성분으로 섞여있는 경우가 대부분이다. 따라서 이런 영역을 고려하지 않는다면 분류 성능을 향상시키기 어렵다. 따라서 각 화소가 어떤 영역에 속하는 정도(possibility)를 0에서 1사이의 실수값으로 나타내는 소속함수(membership function)에 의해 정의되는 퍼지집합으로 보고 접근하는 여러 방법들이 제시되어 왔다. 각 화소는 여러 소속정도(membership grade)를 가질 수 있으며, 섞인 영역이나 불확실한 영역을 퍼지 집합에 의해 적절하게 모델링할 수 있다. 원격감지 영상데이터에 적용될 때, 퍼지 소속정도는 하나의 화소가 어떤 영역에 속하는 정도를 나타낸다. 문제는 각 화소에 대한 소속정도를 어떻게 결정하며, 이 어떤 분류 알고리즘을 사용할 것인가 하는 것이다. Cannon 등^[4]과 Zeno 등^[5]은 각각 퍼지 c-means 알고리즘과 퍼지이완 알고리즘을 개발하였다. 이들의 연구에서는 영역이 퍼지집합으로 간주되고 퍼지집합 연산이 영역에 속한 화소의 소속정도를 조정하기 위해 사용되어졌다. Kent 등^[6]은 퍼지 소속함수를 처리하기 위해 다변수 가우스 랜덤 필드(multivariate Gaussian random field)에 기반한 방법을 제시하였으며, Wang^[7]은 스펙트럼 공간상에서 화소의 그룹을 퍼지 파티션(fuzzy partition)으로 간주하고 분류 파라미터를 추정하는 방법을 제안하였다. 그러나 이런 방법들의 대부분이 통계학적인 방법에 기반을 두었으므로 처리속도가 느리고 계산량이 많다. Foody^[8]는 신경회로망의 출력값이 각 영역에 속하는 정도를 나타낸다는 것을 실험적으로 보여주었으나 퍼지이론에 근거한 해석이 결여되어 있다.

최근에 Ishibuchi 등^[9]은 퍼지패턴을 처리할 수 있는 퍼지 신경회로망을 제안하였는데, 이 회로망은 기존의 다층퍼셉트론 형태를 그대로 유지하면서 입력 패턴과 출력패턴을 퍼지값으로 확장한 퍼지 역전파 알고리즘으로 여러가지 패턴분류 문제에서 좋은 결과를 나타내었다. 이 회로망은 입력이 실수값인 경우에도 그대로 적용이 되며 여기에 퍼지패턴을 추가하여 전문가 시스템에 적용하는데 유용하다. 문제는 각 화소에 퍼지 소속정도를 어떻게 할당하는가 하는 것이다.

본 논문에서는 각 화소가 임의의 영역에 속하는 정도를 퍼지 소속함수에 의해 정의되는 퍼지집합으로 간주하고 각 영역에 대한 모든 화소의 히스토그램에 기

반하여 퍼지 소속함수를 모델링하고 이를 퍼지 신경회로망으로 분류하는 방법을 제시한다. 먼저, 각 화소가 어떤 영역에 어느정도 속해 있는지를 결정하는 것이다. 이전의 논문들이 퍼지사상(fuzzy event)의 복잡한 확률적인 척도를 사용하였으나, 본 논문에서는 최근에 Lee 등^[10]이 매우 심한 임펄스 잡음을 제거하기 위해 발생시킨 히스토그램 기반의 퍼지 소속함수를 사용한다. 그러나 Lee 등의 방법에서 전체 영상으로부터 여러형태의 퍼지 소속함수를 얻기 위해 복잡한 알고리즘을 사용하는 것과 달리 본 논문에서는 영상에서 추출된 이미 알고 있는 각 영역별 히스토그램으로부터 하나의 소속함수만 얻기 때문에 매우 간단하다. 또한 이런 소속함수는 분류영역에 대한 퍼지패턴이므로 퍼지 소속함수에 의한 퍼지규칙을 다시 설정할 필요가 없다. 이 퍼지패턴은 실수 데이터를 훈련시킬 때 함께 훈련에 참여하는 지식기반으로 동작하는 형태를 띤다. 따라서 본 논문의 방법은 실수패턴만 학습시키는 기존의 방법에 비해, 분류하고자 하는 영역의 수만큼 퍼지패턴을 함께 참여시켜 분류성능을 향상시킨다. 또한 퍼지 소속함수 및 패턴의 결정이 각 대역별로 각 영역에 속하는 화소에 대한 히스토그램으로부터 결정하기 때문에 계산이 매우 간단하고 속도가 빠르다.

II. 퍼지 신경회로망을 이용한 영역분류

본 논문에서는 각 화소가 임의의 영역에 속하는 정도를 퍼지 소속함수에 의해 정의되는 퍼지집합으로 간주하고 각 영역에 대한 모든 화소의 히스토그램에 기반하여 퍼지 소속함수를 모델링하여 이를 신경회로망으로 분류하는 방법을 제시한다. 이전의 통계학적인 방법과 달리 퍼지 신경회로망은 이러한 함수를 처리하는 데 매우 좋은 결과를 나타낸다.

그림 1은 제안한 퍼지 신경회로망 분류방법을 나타낸 것이다. 먼저, 각 대역에서 학습을 위해 사용할 훈련데이터를 추출하고 이 데이터로부터 각 영역에 속하는 화소들에 대해 히스토그램을 구한다. 다음, 히스토그램으로부터 퍼지 소속함수를 발생시켜 분류하고자 하는 영역의 수 만큼 퍼지패턴을 만든다. 마지막으로 각 대역에서 추출한 실수값과 함께 퍼지패턴을 사용하여 퍼지 신경회로망을 훈련시킨다. 이 퍼지 신경회로망은 Ishibuchi 등이 제안한 것으로 입력·출력을 퍼지값으로 처리할 수 있는 회로망이다.




그림 1. 제안한 퍼지 신경회로망에 의한 원격감지 영상 데이터의 분류 방법

Fig. 1. The proposed classification scheme of remotely sensed image data using fuzzy neural network.

1. 퍼지 신경회로망

Ishibuchi 등에 의해 제안된 퍼지 신경회로망은 역전파 알고리즘을 사용하는 다층 퍼셉트론 (multilayer perceptron) 구조를 그대로 유지하면서, 입력값과 출력값을 퍼지값으로 확장한 퍼지 역전파 알고리즘을 사용한다^[9]. 이 신경회로망은 입력이 실수값인 경우에도 그대로 적용될 뿐만 아니라, 여기에 퍼지패턴을 추가하여 전문가 시스템에 적용하는데도 유용하다. 그 이후에 퍼지 입력, 퍼지 가중치, 퍼지 출력으로 일반화한 퍼지 신경회로망을 제시했으나, 본 논문에서는 실수 가중치를 가지는 [9]의 신경회로망을 사용한다.

퍼지값(fuzzy number) 및 실수값(real number)을 각각 대문자(e.g., A, B, C, ...)와 소문자(e.g., a, b, c, ...) 로 표기하면 퍼지 입력 벡터 $X_p = (X_{p1}, \dots, X_{pn})$ 에 대한 퍼지 입력-출력 관계는 다음과 같이 정의 된다^[9].

$$\text{Input units : } O_{pi} = X_{pi}, \quad i = 1, 2, \dots, n \quad (1)$$

$$\text{Hidden units : } O_{pj} = f(\text{Net}_{pj}), \quad j = 1, 2, \dots, n' \quad (2)$$

$$\text{Net}_{pj} = \sum_{i=1}^n w_{ji} O_{pi} + \theta_j \quad (3)$$

$$\text{Output units : } O_{pk} = f(\text{Net}_{pk}) \quad (4)$$

$$\text{Net}_{pk} = \sum_{j=1}^{n'} w_{kj} O_{pj} + \theta_k \quad (5)$$

여기서 가중치 w_{ji} , w_{kj} ,와 바이어스 θ_j , θ_k 는 실수값이고 이 퍼지 신경회로망의 구성은 기존의 다층 퍼셉트론 신경회로망 구조를 그대로 유지하면서 입력값과 출력값을 퍼지값으로 대체시킨 것이다.

식(1)-(5)에서 각 층의 입력-출력 관계는 Zadeh의 확장 원리 [11]에 의해 정의된다. 이것은 퍼지연산이

퍼지 신경회로망의 입력과 출력의 관계를 계산하는데 이용된다는 것을 의미한다^[12]. 즉, 식 (1)-(5)에서 퍼지값의 의 덧셈, 곱셈 및 비선형 매핑이 퍼지 신경회로망을 정의하는데 사용된다.

$$\mu_{A+B}(z) = \max \{ \mu_A(x) \wedge \mu_B(y) \mid z = x + y \}, \quad (6)$$

$$\mu_{kA}(z) = \max \{ \mu_A(x) : z = kx \}, \quad (7)$$

$$\mu_{f(Net)}(z) = \max \{ \mu_{Net}(x) \mid z = f(x) \} \quad (8)$$

여기서 A, B, Net는 퍼지값이고, $\mu_*(\cdot)$ 은 퍼지값의 소속함수를 나타낸다. \wedge 는 최소연산자(minimum operator)이며, $f(x) = 1/(1 + \exp(-x))$ 는 퍼지 신경회로망의 은닉층과 출력층의 활성화함수(activation function)이다.

퍼지값에서 위의 연산은 수치적으로(Numerically)으로 계산할 때 수준집합(level sets : i.e., α -cuts)에서 수행된다. 퍼지값 X의 h-수준집합은 다음과 같이 정의 된다.

$$[X]_h = \{ x \mid \mu_X(x) \geq h, x \in R \} \quad \text{for } 0 < h \leq 1 \quad (9)$$

여기서 $\mu_X(x)$ 는 X의 소속함수이고 R은 모든 실수값의 집합이다. 퍼지값의 수준집합이 폐구간이 되므로, $[X]_h$ 는 다음과 같이 표기된다.

$$[X]_h = [[X]_h^L, [X]_h^U] \quad (10)$$

여기서 $[X]_h^L, [X]_h^U$ 는 각각 h-수준집합 $[X]_h$ 의 하한(Lower)과 상한(Upper)이다. 구간 산술(interval arithmetic) [12]로부터, 퍼지값의 연산은 h-레벨집합에 대해 다음과 같이 다시 쓸 수 있다.

$$\begin{aligned} [A]_h + [B]_h &= [[A]_h^L, [A]_h^U] + [[B]_h^L, [B]_h^U] \\ &= [[A]_h^L + [B]_h^L, [A]_h^U + [B]_h^U] \end{aligned} \quad (11)$$

$$\kappa[A]_h = \kappa [[A]_h^L, [A]_h^U] = \begin{cases} [\kappa[A]_h^L, \kappa[A]_h^U] & \text{if } \kappa \geq 0 \\ [\kappa[A]_h^U, \kappa[A]_h^L] & \text{if } \kappa < 0 \end{cases} \quad (12)$$

$$\begin{aligned} f(\text{Net})_h &= f([[\text{Net}]_h^L, [\text{Net}]_h^U]) \\ &= [f([\text{Net}]_h^L), f([\text{Net}]_h^U)] \end{aligned} \quad (13)$$

이것으로 볼 때 기존의 신경회로망은 하나의 노드에 하나의 실수값을 계산하는데 비해, 퍼지 신경회로망에

서 퍼지값의 연산은 h -수준을 변화시켜가면서 퍼지값의 하한값과 상한값을 계산하면 된다. 따라서 퍼지 입력벡터 X_p 에 일치하는 n 차원의 출력 벡터를 $T_p = (T_{p1}, T_{p2}, \dots, T_{pn})$ 라 하면 이 퍼지 신경회로망의 비용함수(cost function)

$$e_p = \sum_h h \cdot e_{ph} = \sum_h \sum_{k=1}^n h \{ ([T_{pk}]_h^L - [O_{pk}]_h^L)^2 / 2 + ([T_{pk}]_h^U - [O_{pk}]_h^U)^2 / 2 \} \quad (14)$$

가 된다. 여기서 O_{pk} 는 k 번째 출력 노드의 퍼지 출력값이며, 실수값을 처리하는 비용함수에 비해 각 h -레벨에서 실제 출력값과 목표값과의 차를 상한과 하한 각각에 대해 처리한 다음 더하는 것으로 정의된다. 이로부터 가중치 w_{ji}, w_{kj} 를 유도하는 학습 알고리즘은 참고문헌 [9]에 나타나 있다.

2. 원격감지 영상데이터의 퍼지표현 및 퍼지패턴 발생

원격감지 영상데이터의 한 화소값은 그 지형에 대한 분광특성을 나타내며 일반적으로 한 화소는 여러 영역으로 혼합되어 있다. 즉, 하나의 화소는 순수한 화소(pure pixel)이라기 보다는 여러 가지 성분이 혼합된 화소(mixed pixel)로 나타난다. 일반적으로 하나의 화소가 하나의 영역에만 속한다면 그 분광특성과 일치하는 하나의 영역으로 분류되며, 이 화소는 그 영역에 대한 소속정도(membership grade)가 1이 되고, 다른 영역에 대한 소속정도는 0이 된다. 따라서 분류하고자 하는 영역을 퍼지집합으로 나타내므로써 하나의 화소는 하나의 영역에 어느정도 속하고 다른 영역에도 어느 정도 속하는지를 표현할 수 있다^[3-7]. 문제는 각 화소가 어떤 영역에 어느정도 속해 있는지를 결정하는 것이다. Wang [7]에서는 퍼지파티션을 가정하고 퍼지사상(fuzzy event)의 확률적인 척도에 의해 퍼지평균(fuzzy mean)과 퍼지공분산(fuzzy covariance)을 구하여 기존의 평균과 공분산을 대신하는 최대유사(maximum likelihood)법으로 분류하였다. 그러나 이 방법 역시 기존의 확률적인 접근을 벗어나지 못하고 있다. 최근에 Lee 등은 매우 심한 임펄스 잡음을 제거하기 위해 가중평균 메디안 필터(weighted median filter)를 제안하였는데, 여기서는 퍼지집합의 소속정도를 전체 영상의 히스토그램으로부터 계산하여 어두움(dark), 중간(medium), 밝음(light) 세 퍼지함수를 구

한다. 따라서 본 논문에서도 히스토그램으로부터 퍼지소속함수를 구한다. 그러나 영상 데이터에서 두드러진 세 개의 피크치를 구하고 밸리를 추출하는 등의 복잡한 과정의 heuristic 알고리즘을 사용하는 Lee 등의 방법과 달리 본 논문에서는 각 영역에 대한 히스토그램에서 하나의 피크치(peak value)와 좌우에서 0이 되는 지점만을 찾으면 되므로 소속함수를 결정하는 것이 매우 간단하다.

퍼지집합의 각각은 화소의 명암도로서 분류하고자 하는 영역 즉, 잡초지역(grass: GR), 농업지역(field: FL), 도로(road: RD), 주거지역(residence: RSD), 산림지역(forest: FR), 바다(sea: SEA), 강(river: RIV)에 속하는 정도를 표시하며 각각의 소속정도는 특정 명암도를 가지는 한 화소 j 가 i 영역에 속하는 정도를 나타낸다. 그림 2는 주어진 화소가 임의의 한 영역에 속하는 퍼지집합을 나타낸다. 소속정도는 일반적으로 구간 $[0, 1]$ 사이의 값이며 "1"은 완전소속(full membership), "0"은 무소속(no membership)을 나타낸다. 이 그림에서 명암도(gray level) 160은 농업지역(FL)에도 속하고, 도로지역(RD)에도 속하는 것으로서 속하는 정도가 각각 0.6, 0.2이다.

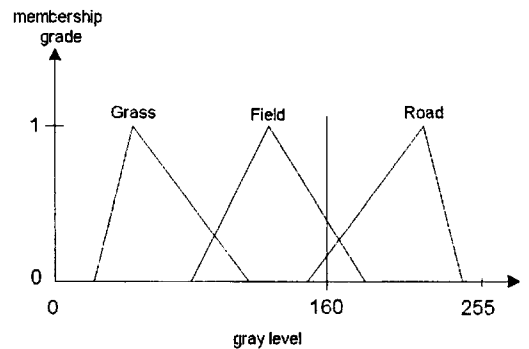


그림 2. 퍼지집합에 대한 소속함수의 예
Fig. 2. Example of membership function for the fuzzy sets.

위의 그림에서 삼각형 퍼지집합의 소속 함수는 다음 방정식에 정의되는 $L-R$ 형 퍼지값이다^[13].

$$f(x) = \begin{cases} L \left(\frac{m-x}{\alpha} \right) & \text{for } x \leq m, \\ R \left(\frac{x-m}{\beta} \right) & \text{for } x \geq m \end{cases} \quad (15)$$

여기서 $L(y) = R(y) = \max(0, 1-y)$ 이고, $f(x)$ 는 세 개의 변수 $[m, \alpha, \beta]$ 로써 m 은 가운데의 피크치에 해당하

는 명암도 값이고, a 는 왼쪽 폭(left spread)이고 β 는 오른쪽 폭(right spread)이다.




그림 3. 대역 1의 잡초지역에 대한 학습 데이터의 히스토그램으로부터 발생된 퍼지 소속함수
Fig. 3. Fuzzy membership function generated from the histogram of grass training data for band 1.

본 논문에서 각 영역에 대한 $L-R$ 형 소속함수는 훈련 데이터의 각 영역에 대한 히스토그램으로부터 쉽게 유도될 수 있다. 그림 3(a)는 훈련 데이터에서 7개의 분광 대역 영상 데이터중에서 대역 1에서 잡초(grass)영역에 속하는 화소에 대한 히스토그램을 나타내며, 그림 3(b)는 기준 히스토그램으로부터 구성된 퍼지소속함수를 보여주고 있다. 히스토그램의 피크치인 명암도(m)에 해당하는 지점을 소속정도(membership grade)를 1로 놓고, 소속정도가 0이되는 지점(α, β)는 적절한 문턱치를 사용하여 그 이하를 0으로 놓은 상태에서 왼쪽과 오른쪽에서부터 각각 시작하여 0이 아닌 지점 $[\alpha, \beta]$ 을 발견하여 구한다. 이는 거의 영역에 속하지 않는 패턴을 훈련시 퍼지함수에 포함시키지 않으므로써 수렴속도를 빠르게 하고 분류율의 향상을 가져오게 하기 위함이다. 위의 경우를 한 대역에 대해 각 영역에 대한 히스토그램을 구하고 소속함수를 구성하면 그림 4와 같이 되며 나머지 다른 대역에 대해서도 마찬가지로 방법을 적용하므로써 각 대역별로 $[m, \alpha, \beta]$ 로 표현되는 퍼지 소속함수를 얻을 수 있다.

이렇게 해서 어떤 대역에서 임의의 명암도 값을 갖는 한 화소는 각각의 영역에 속하는 정도의 소속함수에 의해 정의되는 크기를 갖는다. 다음 문제는 이런 소속함수를 갖는 각 화소에 대해 어떤 분류기를 사용하여 분류하는가에 관한 것이다. 이러한 소속함수에 기반하여 각 화소마다 처리하는 것은 시간이 오래걸릴 뿐만 아니라 기존의 통계적인 방법과 다를 바 없다. 그러나 히스토그램상에서 보이는 소속함수는 그대로 퍼지 패턴으로 간주 될 수 있다. 이런 퍼지 패턴은 각 화소를 고려하지 않고 전체 훈련 데이터에서 전체적인 분포상태를 보여주는 척도로 사용된다.




그림 4. 대역 1의 각 영역에 대한 퍼지 소속함수
Fig. 4. Fuzzy membership function of each categories for band 1.

3. 실수값 및 퍼지값에 의한 영역분류

본 논문에서는 원격감지 영상데이터의 분류를 위해 실수값외에 퍼지패턴을 추가하므로써 분류효율을 높이고자 한다. 실수값만을 가지고 학습시킬 경우에는 한 화소가 여러 영역의 성분으로 혼합된 경우를 고려하지 못하므로 분류효율이 낮다는 것이 지적되어 왔다. 또한 퍼지패턴만으로 영역을 분류하는 경우에는 패턴 수가 적으므로 학습속도는 빠르나 전체적인 정보만을 고려하므로 각 화소에 대한 개별적인 학습이 이루어지지 않아 분류 효율이 낮다. 따라서 본 논문에서는 그림 1에서 제안한 것처럼 훈련데이터와 이들의 히스토그램으로부터 발생시킨 퍼지값을 함께 신경회로망의 입력으로 사용하여 분류 성능을 개선 시킨다. 따라서 이를 수행하기 위한 신경회로망의 구성은 그림 5와 같다. 입력 노드수는 분광대역의 수와 같고, 출력 노드수는 분류하고자 하는 영역의 수와 같다. 그리고 각 입력노드에 입력되는 값은 실수값 또는 퍼지값이고, 출력값은 이미 알고 있는 값이므로 실수값이다. 제안한 방법의 학습 알고리즘의 수행순서는 다음과 같다.

- Step 1 : 각 훈련 데이터에서 각 대역별 히스토그램을 구하고 퍼지값 및 퍼지패턴을 발생시킨다
- Step 2 : 신경회로망의 가중치 및 바이어스를 초기화한다
- Step 3 : 훈련데이터의 실수값을 신경회로망에 입력시키면서 가중치를 갱신시킨다
- Step 4 : 퍼지패턴을 신경회로망에 입력시키면서 가중치를 갱신시킨다.
여기서 퍼지패턴을 $h = h_1, h_2, \dots, h_n$ 까지 수행한다.
- Step 5 : 수렴 기준을 만족할 때까지 Step 3으로 가서 반복 실행시킨다.

7개로 하였다. 훈련 데이터와 테스트 데이터는 각 대역의 조합에 의한 칼라영상의 확대영상과 지도를 토대로하여 선정하였으며, 훈련 데이터로는 총 42개 지역에서 1991개 화소를 선정하였고, 테스트 데이터는 2148개 화소를 선정하여 분류를 수행하였다.

영역분류실험을 하기 위한 신경회로망의 구성에 있어서 입력 노드수는 특징량의 개수에 의해 결정되며, 본 논문에서는 6개 대역을 사용하므로, 6개의 입력노드를 가지는 신경회로망이 된다. 은닉층의 노드수는 17개 [3]로 선택하였으며, 출력노드 수는 분류하고자 하는 영역수에 의해 결정되므로, 본 논문에서는 7개의 출력노드를 가지는 회로망이 된다. h -레벨의 수는 5개($h=0.2, 0.4, 0.6, 0.8, 1$)로 하였다. 5개의 간격(interval) 입력 벡터가 하나의 퍼지 뉴런으로부터 발생되어 학습되는 것을 의미하므로, 퍼지 데이터의 한 epoch에 요하는 학습 시간은 h -레벨의 선택에 의존한다. 따라서, 본 논문에서는 5개의 h -레벨을 선택했기 때문에 기존의 BPNN(역전파 신경회로망)과 동일 상태에서 비교하면 FBPNN(퍼지역전파 신경회로망)의 학습 횟수는 퍼지신경회로망보다 5배가 된다. 출력노드에 나타나는 값중 가장 큰 값을 가지는 것을 해당 영역으로 분류한다.

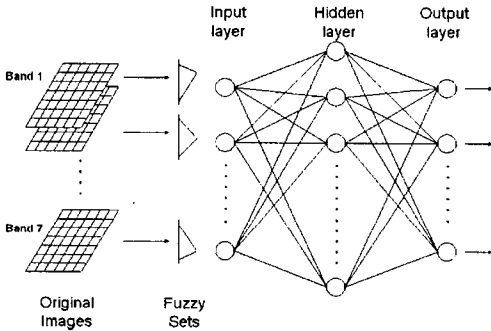


그림 5. 본논문의 영역분류를 위한 퍼지 신경회로망의 구성

Fig. 5. Fuzzy neural network architecture for category classification in this paper.

III. 실험 결과 및 고찰

분류성능을 평가하기 위하여 실제 인공위성 원격감지 영상데이터를 사용하여 영역분류를 행하였다. 사용된 영상데이터는 Landsat 5호에 의해 촬영된 부산 지역에 대한 TM 데이터로, 총 7개 대역중 공간해상도가 120×120 m인 대역 6을 제외한 공간해상도가 30×30 m인 대역 1 ~ 5 및 대역 7의 6개를 사용하였으며, 영상의 크기는 512×400 화소이고, 각 화소는 256 회색준위(gray level)를 가진다. 그림 6은 실험에 사용한 영상데이터에서 7개 대역중 대역 1에 대한 데이터를 영상으로 나타낸 것이다. 분류할 영역수는 잡초지역(grass: GR), 농업지역(field: FL), 도로(road: RD), 주거지역(residence: RSD), 산림지역(forest: FR), 바다(sea: SEA) 및 강(river: RIV)의




그림 6. 실험에 사용한 영상데이터의 대역 1에 대한 영상

Fig. 6. Remotely sensed image of the band 1 for the study area.

실험은 퍼지신경회로망의 학습패턴을 1991개의 훈련데이터에서 추출한 7개의 1)퍼지패턴만으로 구성된 경우, 2)실수 패턴만으로 구성된 경우, 그리고 3)실수와 7개의 퍼지패턴을 결합한 경우 등이며 이들 각각에 대하여 영역분류를 수행한 후 비교·분석하였다.

1. 퍼지패턴만으로 학습한 경우의 분류결과

퍼지 신경회로망의 학습패턴을 퍼지패턴만으로 구성한 경우로, 퍼지패턴은 각 훈련 데이터의 대역별 히스토그램에서 피크치에 해당되는 명암도의 퍼지 소속정도를 1로, 문턱치를 통한 맨 끝점의 퍼지 소속정도를 0으로 하는 L-R형의 삼각 퍼지 소속함수를 구성한다. 따라서 각 영역에 해당하는 7개의 퍼지패턴이 퍼지 신경회로망으로 인가된다. 문턱치는 2, 학습횟수는 10,000회이며, Pentium PC 133MHz에서 소요시간은 40분정도이다. 훈련 데이터와 테스트 데이터에 대한 분류율을 계산한 결과는 각각 92.209%, 92.635%로 나타났으며, 같은 시간동안에 실수값으로만 학습시킨 기존의 BPNN 분류법에서는 분류율이 각각 86.386%, 87.431%로 나타났다. 이는 많은 실수 패턴에 비해 단지 7개의 퍼지패턴만 학습한 결과로 수렴속도가 빠르지만, 학습시간이 증가할수록 93%선에서 머문다. 이러한 결과로 볼 때 퍼지패턴 만으로는 수렴속도를 빨리하면서 전체적인 정보를 고려할 수는 있으나 한 화소에 대한 개별적인 정보를 고려하지 못하므로 최종적으로 분류성능 98%에 도달하는 기존의 BPNN에 훨씬 못미친다.

2. 실수값만으로 학습한 경우의 분류결과

이것은 기존의 BPNN 분류법과 같은 것으로 실수값과 퍼지패턴을 결합한 경우와 비교하기 위해 다음절에서 함께 다룬다.

3. 실수값과 퍼지패턴을 결합한 경우

퍼지 신경회로망의 학습패턴은 훈련데이터로 선정된 1991개를 학습에 포함하고 여기에 7개의 퍼지패턴을 추가하여 총 1998개로 구성한 경우와 1991개의 실수값만을 가지고 수행한 기존의 BPNN 분류법과 비교하였다. FBPNN에 실수값만 입력한 경우는 기존의 BPNN 분류법과 같다. 여기서 퍼지패턴은 각 훈련데이터의 대역별 히스토그램에서 피크치에 해당되는 명암도 값을 퍼지 소속정도 1로, 문턱치를 통한 맨 끝점을 퍼지 소속정도 0으로 하는 삼각형의 퍼지 소속함수를 구성한다. 문턱치는 1, 학습횟수는 1,000회로 했으며, 소요시간은 6시간정도이다. 그리고 삼각형의 퍼지 소속함수 대신 가우스 분포를 가정하여 평균과 분산을 구하여 실험하였으나 별로 차이가 없음을 알 수 있었다. 또한 퍼지 멤버쉽 함수를 결정하는 변수 $[m, \alpha, \beta]$

에서 m 은 피크치와 평균값으로 각각 해 보았으나 피크치의 결과가 약간 우수하였고, α, β 의 값에 의해 성능에 영향을 미쳤다. 문턱치를 크게하면 α, β 가 작아져서 수렴은 빠르나 더 적은 수의 패턴을 포함하여 성능이 저하된다. 반대로 문턱치를 0로 하면 전부 다 포함하므로 히스토그램의 끝에 있는 성분으로 인해 수렴속도가 느려질뿐 아니라 인식률도 저하된다. 따라서 본 논문에서는 여러 실험을 거쳐 문턱치를 5로 하여 그 이하의 빈도수를 가지는 것은 0으로 하여 α, β 를 구하였다.

표 1. 훈련데이터에 대한 각 분류법의 분류율
Table 1. Correct classification rate of each classification method for the training data.

Actual category	No.	Method	Assigned category							
			(A)	(B)	(C)	(D)	(E)	(F)	(G)	%
GR(A)	286	BPNN	285				1			99.65
		FBPNN	284	1				1		99.30
FL(B)	280	BPNN	2	277				1		98.93
		FBPNN	2	277				1		98.93
RD(C)	288	BPNN	2		276	8	1	1		95.83
		FBPNN	1		275	10	1	1		95.49
RSD(D)	280	BPNN			2	277		1		98.93
		FBPNN			1	278		1		99.29
FR(E)	285	BPNN	1	1				283		99.30
		FBPNN	1					284		99.65
SEA(F)	280	BPNN						275	5	98.21
		FBPNN						280		100
RIV(G)	292	BPNN	4						288	98.63
		FBPNN	4						288	98.63
Average %			: BPNN 98.498%, FBPNN 98.754%							
Overall %			: BPNN 98.493%, FBPNN 98.744%							

기존의 BPNN 및 FBPNN 분류법에서 훈련데이터와 테스트데이터에 대한 분류율을 계산한 결과는 표 1 및 표 2와 같다. 학습소요시간에 따른 분류율은 처음에는 FBPNN이 퍼지패턴을 포함하므로 몇번의 반복회수내에 90%에 이르는 좋은 결과를 나타낸다. 그러나 점차시간이 증가할수록 일정한 값으로 수렴한다. 더 이상 변하지 않는 똑같은 시간(6시간)에서 기존의 BPNN분류법은 분류율이 훈련데이터에서 98.498%이고 테스트데이터에 대해서 97.350%로서, 훈련데이터와 테스트데이터에서 분류율의 차이가 1.148%인데 비해, FBPNN분류법은 각각 98.754%, 97.888%로 분류율이 높았을 뿐 아니라 이들 사이의 차이가 0.866%로 적게 나타났다. 이러한 분류율의 개선효과가 나타나는 이유는 퍼지패턴의 첨가로 말미암아 FBPNN 분류법이 입력 데이터의 복잡한 경계(decision boundary)를

더욱더 잘 학습시킬 수 있으므로 기존의 BPNN 분류 방법보다 일반화 및 근사화가 우수하기 때문으로 생각된다.

표 2. 테스트데이터에 대한 각 분류법의 분류율

Table 2. Correct classification rate of each classification method for the test data.

Actual category	No.	Method	Assigned category							%	
			(A)	(B)	(C)	(D)	(E)	(F)	(G)		
GR(A)	283	BPNN	278	2				3		98.23	
		FBPNN	279	1				3		98.59	
FL(B)	309	BPNN		306				3		99.03	
		FBPNN		306				3		99.03	
RD(C)	236	BPNN	5	1	219	6	5			92.80	
		FBPNN	4	1	220	7	3		1	93.22	
RSD(D)	284	BPNN		2	3	278	1			97.89	
		FBPNN			2	280	2			98.59	
FR(E)	315	BPNN	2	2				311		98.73	
		FBPNN	2	1				312		99.05	
SEA(F)	305	BPNN							292	13	95.74
		FBPNN								298	7
RIV(G)	416	BPNN	1	2				1		412	99.04
		FBPNN	1	2				1		412	99.04

Average % : BPNN 97.350%, FBPNN 97.888%

Overall % : BPNN 97.579%, FBPNN 98.091%

IV. 결 론

본 논문에서는 퍼지 신경회로망을 이용하여 원격감지 영상데이터를 분류하는 방법을 제시하였다. 먼저 상데이터를 퍼지집합으로 간주하고 각 분류영역에 대한 히스토그램 기반의 소속함수를 발생시켰다. 이러한 퍼지모델로부터 영역을 분류하기 위해 실수패턴과 퍼지패턴을 함께 학습에 참여시킴으로써 분류효율이 향상됨을 알 수 있었다. 즉, 기존의 역전파 신경회로망을 이용한 분류법과 퍼지패턴을 추가한 FBPNN 분류법의 분류성능을 비교 검토하였다. 분류실험은 실제의 인공위성 원격감지 영상데이터를 사용하여 행한 결과, 기존의 BPNN 분류법보다는 퍼지패턴을 추가한 FBPNN 분류법이 분류율에서 우수할 뿐만아니라, 일반화 및 근사화가 우수하여 학습에 포함시키지 않은 훈련 데이터를 포함할 수 있음을 확인하였다. 나아가 시스템의 분류성능을 향상시키기 위하여 각 화소에 대한 퍼지패턴을 퍼지 소속함수에 기반하여 처리하는 일반화된 퍼지분류기에 대한 연구가 수행되어야 하겠다.

참 고 문 헌

- [1] H. Bischof, W. Schneider, and A. J. Pinz, "Multispectral Classification of Landsat-Image using Neural Network," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 30, pp. 482-490, May 1992.
- [2] J. D. Paola and R. A. Schowengerdt, "A Review and Analysis of Backpropagation Neural Networks for Classification of Remotely-sensed Multispectral Imagery," *Int. J. Remote Sensing*, vol. 16, no. 16, pp. 3033-3058, 1995.
- [3] 임태훈, 서용수, "신경회로망을 이용한 인공위성 분광화상 데이터의 영역분류," 1996년도 대한전자공학회 추계 종합학술대회 논문집(B), 제 19권 제 2호, pp. 1436-1439
- [4] R. L. Cannon, J. V. Dave, J. C. Bezdek, and M. M. Trivedi, "Segmentation of a Thematic Mapper Image Using the Fuzzy C-means Clustering Algorithm," *IEEE Trans. Geosci. Remote Sensing*, vol. GE-24, pp. 400-408, May 1986.
- [5] S. D. Zenzo, R. Bernstein, S. D. Degloria, and H. G. Kolsky, "Gaussian Maximum Likelihood and Contextual Classification Algorithms for Multicrop Classification," *IEEE Trans. Geoscience Remote Sensing*, vol. GE-25, pp. 805-814, Nov. 1987.
- [6] J. T. Kent and K. V. Mardia, "Spatial Classification Using Fuzzy Membership Models," *IEEE Trans. Pattern Analysis and Machine Intell.*, vol. 10, no. 5, pp. 659-671, 1988.
- [7] F. Wang, "Fuzzy Supervised Classification of Remote Sensing Images," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 28, no. 2, pp. 194-201, March 1990.
- [8] Geles M. Foody, "Relating the Land-Cover Composition of Mixed Pixels to Artificial Neural Network Classification Output," *Photogrammetric Engineering & Remote Sensing*, vol. 62, no. 5, pp. 491-499, May 1996.
- [9] Hisao Ishibuchi, Ryosuke Fujioka, and


Hideo Tanaka, "Neural Networks That Learn from Fuzzy If-Then Rules," *IEEE Trans. on Fuzzy Systems*, vol. 1, no. 2, pp. 85-97, 1993.

- [10] Chang-Shing Lee, Yau-Hwang Kuo, and Pao-Ta Yu, "Weighted Fuzzy Mean Filters for Image Processing," *IEEE Trans. Fuzzy Sets and Systems*, vpl. 89, pp. 157-180, 1997.
- [11] L. A. Zadeh, "The Concept of a Linguistic

Variable and Its Application to Approximate Reasoning Parts 1-3", *Information Science*, vol. 8, pp. 199-249, 301-357, vol. 9, pp. 43-80, 1975.


- [12] Kaufmann, A., and Gupta, M. M., *Introduction to Fuzzy Arithmetic*, Van Nostrand Reinhold, 1985.
- [13] L. A. Zadeh, "Fuzzy Sets," *Inform. contr.*, vol. 8. pp. 338-353, 1965.

저 자 소 개



李 駿 宰(正會員)

1962年 5月 31日生. 1986年 8月 경북대학교 전자공학과 졸업(공학사). 1990年 8月 경북대학교 대학원 전자공학과 졸업(공학석사). 1994年 8月 경북대학교 대학원 전자공학과 졸업(공학박사). 1991年 9月 ~ 1993年 7月 경북대학교 조교 1995年 3月 ~ 현재 동서대학교 컴퓨터공학과 전임강사. 1998年 2月 ~ 1999年 2月 Georgia Tech. 연구교수. 주관심 분야는 영상처리, 패턴인식, 컴퓨터 비전, 신경회로망 등임.



徐 龍 洙(正會員)

1951年 7月 6日生. 1975年 2月 경북대학교 전자공학과 졸업(공학사). 1982年 2月 동아대학교 대학원 전자공학과 졸업(공학석사). 1992年 2月 경북대학교 대학원 전자공학과 졸업(공학박사). 1990年 3月 ~ 1991年 2月 日本 群馬대학 전기전자공학과(연구교수). 1979年 3月 ~ 1994年 2月 경남전문대학 전자과 부교수. 1994年 3月 ~ 현재 동서대학교 정보통신공학과 조교수. 주관심 분야는 화상처리 및 인식, Remote Sensing, Medical Imaging, 정보통신 등임



金 孝 成(學生會員)

1971年 12月 9日生 1998年 2月 동서대학교 전자공학과 졸업(공학사). 1998年 3月 ~ 현재 부산대학교 전자공학과 석사과정 재학중. 주관심 분야는 컴퓨터 비전, 패턴인식 등임



黃 錫 胤(正會員)

1978年 2月 경북대학교 수학과 졸업(이학사). 1983年 2月 대구대학교 대학원 수학과 졸업(이학석사). 1989年 2月 계명대학교 대학원 수학과 졸업(이학박사). 1991年 ~ 현재 대구대학교 수학과 부교수. 주관심 분야는 퍼지 및 신경회로망, 패턴인식, 영상처리 등임



李 在 旭(正會員)

1975年 2月 경북대학교 전자공학과 졸업(공학사). 1981年 2月 동아대학교 대학원 전자공학과 졸업(공학석사). 1989年 8月 동아대학교 대학원 컴퓨터공학과 졸업(공학박사). 1992年 3月 ~ 현재 동서대학교 컴퓨터공학과 부교수. 주관심 분야는 컴퓨터 알고리즘, 인공지능, 시뮬레이션 등임