

# 위성탐사 이미지에서 혼합화소의 해석에 관한 연구

## An Analysis of Mixed Pixel in the Remote Sensing Image Data

김진일\*  
KIM, Jin-Il\*

박민호\*\*  
PARK, Min-Ho\*\*

김성천\*\*\*  
KIM, Sung-Chun\*\*\*

### 要 旨

본 논문은 위성탐사 이미지의 분류에서 한 화소(SPOT HRV의 밴드 1-3의 경우 20m x 20m)에 포함된 혼합된 정보의 분류를 시도한다. 먼저 기존의 분류기법에서 발생하는 정보의 손실과 혼합화소에 내포된 정보의 불확실성에 대해 알아보고 이를 해결하기 위한 방법으로 퍼지 시그모이드 함수와 역전파 신경망을 이용한 기법을 제안하며, 이를 실험하고 비교 분석한다.

### ABSTRACT

The aim of this study is to classify mixed information in a pixel of a remote sensing image data (in the case of SPOT HRV's band 1~3, 20m × 20m). First, the loss of information and the uncertainty of mixed pixel are examined. To solve the problems, methods by fuzzy sigmoid function and back-propagation neural network are suggested. Then, the study simulates and comparatively analyzes the two methods.

### 1. 서 론

위성에 의한 원격탐사의 연구는 1972년 NASA(미항공우주국)에 의해 ERTS-1(Earth Resources Technology Satellite-1)이 발사된 이후, 지구의 광범위한 지역의 정보를 주기적으로 쉽게 취득할 수 있다는 점에서 지속적인 연구가 되어왔다. 또한, 이에 대한 이미지 처리 기술의 발달로 국토 관리, 환경 보존, 자원 개발, 군사 전략 등 실용적 이용에서도 상당한 진척을 가져왔다.

일반적으로 사용되는 원격탐사를 위한 인공위성의

탐재 센서는 LANDSAT의 MSS와 TM 그리고 SPOT의 HRV 등이다. 각 센서의 IFOV(Instantaneous Field Of View)는 분광 밴드에 따라 차이가 있으나 LANDSAT의 MSS는 79m×79m, TM의 경우 30m×30m이며, SPOT의 HRV인 경우(밴드 1~3) 약 20m 정도이다. 또한, 화소를 표현하기 위한 비트 수는 6~8비트로 64~256가지의 분광 강도로 물체의 분류를 가능하게 한다. 이러한 탐재 센서의 한계는 대상 물체의 윤곽 파악이나 물체의 정확한 크기 및 분류를 하는데 장애 요인이 되며, 이로 인해 위성이미지 데이터의 실용적 사용에 상당한 제약을 받는다. 즉, 위성

\* 동의대학교 컴퓨터공학과 조교수

\*\* 수원대학교 도시공학과 강사

\*\*\* 서강대학교 전자계산학과 교수

탐사 이미지 분류에서는 한 화소가 하나의 항목(one-pixel-one-class)으로 분류가 된다는 점이다. 그러나 실제 상황에서는 한 화소가 하나의 분류만으로는 적절히 표현할 수 없는 복합적 범주의 패턴이나 혼합된 형태의 분류를 갖는다. 즉, 위성이미지 내의 혼합 화소(mixed pixel : mixel)의 문제가 야기된다.

위성이미지 분류의 최근 연구 동향은 1980년대 후반에 들면서 인공지능, 퍼지, 신경망 이론이 본격적으로 등장하면서 기존의 통계적 이론에서 보다 개선된 제안들이 속속 소개되고 있다. 이에 퍼지 기법을 적용하여 분류의 개선을 시도한 연구<sup>1)2)3)</sup>가 있으며, 특히 1990년 왕(F.Wang)의 연구는 혼합 화소에 대한 퍼지 귀속도의 적용으로 정보의 손실을 줄였다는데 의의를 가질 수 있다. 또한, 신경망 이론의 위성이미지 분류에의 적용에 대한 연구<sup>4)5)6)</sup>에서도 기존의 MLC(Maximum Likelihood Classification) 방법보다 나은 결과를 얻을 수 있음을 보인다.

신경망 이론의 새로운 제안으로는 사루(Y.Salu)에 의해 제안된<sup>7)</sup> 이진 다이아몬드 신경망이 있으나, 이는 오히려 MLC보다 못한 결과였으며 최근의 연구는 역전파 신경망 이론의 적용이다<sup>8)</sup>. 이는 신경망 이론이 기존의 통계적 분류에서 수용하지 못하는 정규 분포에 대한 편차가 위성이미지에서는 많이 발생한다는 점이며, 이 점이 신경망 이론의 적용에 긍정적인 장점으로 부각되는 점이다<sup>8)</sup>. 그 외에 연관된 연구로는 원격탐사의 분류 정확도를 평가하기 위한 기준의 제안<sup>9)10)</sup>이 있으며, 특히, 원격탐사 이미지의 분류 정확도 향상을 위해 보다 해상도가 높은 이미지를 중첩시켜 해석하는 방법도 제안<sup>11)</sup>되고 있다.

본 연구에서는 퍼지 시그모이드 함수를 사용한 새로운 mixel처리 기법을 제안하며, 또한 역전파 신경망을 위성탐사 이미지 분류에 적용기 위한 구조를 소개하고 이의 mixel 처리를 위한 형태를 제안한다. 그리고 두 기법간의 장단점들을 비교 평가할 것이다.

## 2. 혼합화소에 의한 정보의 손실

위성으로 부터 취득한 이미지 데이터는 다음의 4가

지 해상도를 갖는다. 첫째는 공간 해상도(spatial resolution)로서 위성이미지 상의 한 화소에 해당하는 실제 지상의 면적을 뜻하며, 둘째는 방사량 해상도(radiometric resolution)로서 미세한 에너지의 차이를 감지해내는 센서의 능력을 말한다. 세째는 분광 해상도(spectral resolution)로서 센서가 물체로부터의 방사량을 몇개의 밴드로 분해하여 감지할 수 있는가를 나타내는 것으로 밴드의 수와 비례한다. 마지막으로 시간적 해상도(temporal resolution)는 위성이 같은 지역을 탐사할 수 있는 주기를 나타낸다. 이 중에서 분광 해상도와 방사량 해상도는 한 사물에 대한 분광 방사 특성을 동시에 취득할 수 있다는 점에서 물체의 분류에 직접적인 정보를 제공한다. 또한, 공간 해상도의 제한은 본 연구에서 추구하고자 하는 mixel의 혼합분류에 대한 근본 원인이 되며, 이의 분류에서 일률적으로 하나의 영역(category)으로만 할당한다면 여기 내포한 복합된 다른 영역의 정보는 손실을 가져올 것이다. 이는 다른 화상 이미지 처리와 비교하여 한 화소에 많은 불확실성(uncertainty)이 포함되기 때문에 이의 해석을 위해서는 필수적으로 인공지능적인 기법의 도입이 요구되는 바이다. 그림 2.1은 공간 해상도의 한계속에 포함된 한 화소의 혼합된 형태를 보여준다.




그림 2.1 혼합화소(mixel)의 예

## 3. 퍼지 함수의 적용

### 3.1 기본 이론

본 절에서는 mixel의 분석을 위한 새로운 방법을 제안하기 위한 기본 이론을 정의한다.

(정의3-1)퍼지 시그모이드 함수(fuzzy sigmoid function)

퍼지 시그모이드 함수 S는

$$S(v; \alpha, \beta, \gamma) = \begin{cases} 0 & v \leq \alpha \\ 2 \left( \frac{v-\alpha}{\gamma-\alpha} \right)^2 & \alpha \leq v \leq \beta \\ 1 - 2 \left( \frac{v-\gamma}{\gamma-\alpha} \right)^2 & \beta \leq v \leq \gamma \\ 1 & v \geq \gamma \end{cases}$$

(단,  $\alpha, \beta, \gamma$ 는 각각 범위의 하한값, 중간값, 상한값이고  $v$ 는 발생된 사건(event)값이다.)

로 정의된다.

앞의 정의는 크리스프 값(crisp value)을 퍼지수로 변환시키기 위한 퍼지 함수로 채용되며, 그림 3.1은 퍼지 시그모이드 함수 S에 대한 그래프를 보여준다.




그림 3.1 퍼지 시그모이드 함수

그림 3.2와 같은 형태의 분류 대상 화소가 있을 때 이 정의를 적용하면 분류하고자 하는 화소  $P_{mn}$ 의 퍼지수를 얻기 위한  $\alpha, \beta, \gamma$ 는 다음과 같이 구할 수 있다.

동일 밴드 내의 분광 강도의 최소값  $\alpha_i$ 는

$$\alpha_i = \text{MIN}\{B_i(P_{mn}), B_i(P_{m-1,n}), B_i(P_{m+1,n}), B_i(P_{m,n-1}), B_i(P_{m,n+1}), B_i(P_{m+1,n-1}), B_i(P_{m-1,n+1}), B_i(P_{m-1,n-1}), B_i(P_{m+1,n+1})\} \quad (\text{식 3.1})$$

(단  $i=1,2,3$  밴드)

이고, 최대값  $\gamma_i$ 는

$$\gamma_i = \text{MAX}\{B_i(P_{mn}), B_i(P_{m-1,n}), B_i(P_{m+1,n}), B_i(P_{m,n-1}), B_i(P_{m,n+1}), B_i(P_{m+1,n-1}), B_i(P_{m-1,n+1}), B_i(P_{m-1,n-1}), B_i(P_{m+1,n+1})\} \quad (\text{식 3.2})$$

(단  $i=1,2,3$  밴드)

이다. 또한, 이의 평균값  $\beta_i$ 는 다음과 같다.

$$\beta_i = (\alpha_i + \gamma_i) / 2 \quad (\text{단, } i=1,2,3 \text{ 밴드}) \quad (\text{식 3.3})$$

이를 이용한 퍼지수는 (정의 4-1)을 이용하여 구할 수 있으며, 이때 각 밴드의 퍼지수  $F_i$ 는

$$F_i = S(P_{mn}(B_i); \alpha_i, \beta_i, \gamma_i) \quad (\text{단, } i=1,2,3 \text{ 밴드}) \quad (\text{식 3-4})$$

로 구할 수 있다.





그림 3.2 다중 분광 밴드에서 분류 대상 화소( $P_{mn}$ )와 그 인접 화소

### 3.2 실험 및 고찰

#### (1) 간단한 예의 적용

본 연구를 위한 실험 데이터는 임의의 다중 분광 화소에 대한 혼합화소를 대상으로 했으며, 그림 3.3은 3개의 밴드에 대한 분광강도와 그의 인접화소를 보여 주고 있다.



(a) 3개의 밴드의 분광강도

band-1	125	124	128	130	100*
	130	128	110*	80*	68*
	126	125	86*	52	50
	123	126	75*	48	51
	128	129	70*	52	53

(b) 인접화소

그림 3.3 3개의 밴드에 대한 분광강도와 그의 인접화소 (\*는 mixel로 가정함)

그림 3.3의 (a)에서 각 화소의 인접화소를 참조하여 (식 3.1)~(식 3.4)를 적용하여 밴드-1에 대한 \*로 표시된 혼합화소의 최대, 최소, 평균 및 그의 퍼지수를 구해 보면

ex1) 80\*의 경우 (밴드-1 에서)

최대 분광 강도 ( $\gamma_i$ ) - 130  
 최소 분광 강도 ( $\alpha_i$ ) - 50  
 평균 분광 강도 ( $\beta_i$ ) - 90    이므로  
 $F_1 = S(80;50,90,130)$   
 $= 2((v-\alpha)/(v-\gamma))^2 \div 0.28$

ex2) 110\*의 경우 (밴드-1 에서)

최대 분광 강도 ( $\gamma_i$ ) - 130  
 최소 분광 강도 ( $\alpha_i$ ) - 52  
 평균 분광 강도 ( $\beta_i$ ) - 91    이므로  
 $F_1 = S(110;52,90,130)$   
 $= 1 - 2((v-\gamma)/(v-\alpha))^2 \div 0.89$

와 같이 구할 수 있다.

그림 3.4는 A와 B영역으로 분류한 결과와 mixel에 대한 퍼지 시그모이드 함수를 적용한 결과를 보여준다.

A	A	A	A	0.72
A	A	0.89*	0.28	0.10*
A	A	0.45	B	B
A	A	0.15	B	B
A	A	0.13	B	B

그림 3.4 영역 A, B로의 분류 결과와 mixel의 퍼지수

다음은 퍼지 시그모이드 함수를 적용한 mixel의 분류 과정이다.

(단계 1) 밴드 별로 나누어 인접화소를 기준으로 한 퍼지수를 계산한다.

(단계 2) mixel분류를 위한 기준을 결정한다.

(단계 3) 단계 2에 따라 mixel의 정량성과 방향성을 판별한다.

이상의 과정으로 처리되며, mixel의 정량성에 대한 판단 규칙은 다음과 같다.

[Algo. 3-1] 2개의 분류항목에 대한 mixel의 분류

가정

분류항목 A와 B는 기존의 분류기법에 따라 분류됨.

규칙

IF RV(A) > RV(B) THEN F(M) represents membership grade of category A
단, RV(A) : 분류항목 A의 분광 강도의 평균값
RV(B) : 분류항목 B의 분광 강도의 평균값
F(M) : mixel의 퍼지수

[Algo. 3-2] 3개의 분류항목에 대한 mixel의 분류

가정

분류항목 A, B, C는 기존의 분류기법에 따라 분류됨.

가능 mixel의 종류

: A&B, A&C, B&C, A&B&C

규칙

- (1) 좌상단에서 우하단 순서로 혼합화소를 분류한다.
(2-1) 분류항목이 명백한 2가지일 때는 [Algo. 3-1]의 방법에 따른다.
(2-2) 분류항목이 3가지의 요소로 구성되어 있을 때에는 다음의 규칙에 따른다.
IF RV(A) > RV(B) > RV(C) THEN F(M) represents membership grade of category A,
1-F(M) is shared category B and C
단, RV(A) : 분류항목 A의 분광 강도의 평

균값

RV(B) : 분류항목 B의 분광 강도의 평균값

F(M) : mixel의 퍼지수

(3) GO TO (1) until all mixels are classified.

(2) 결과의 고찰

본 방법의 장점으로는 학습 데이터가 필요없을 뿐만 아니라 간단하게 프로그램이 가능하다는 점이다. 그런데 앞의 (단계 2)에 대한 기준 결정이 매우 중요하며, 이는 퍼지수 F ≥ 0.95 이거나 F ≤ 0.05인 경우에는 mixel로 구분하지 않는다든지(오차의 한계를 줌), 밴드에 따른 분류의 영향에 대한 강도(weight)의 결정 문제 등은 분류항목의 분광특성에 따른 고려가 되어야 할 것이다. <그림 3-4>에서 보는 바와 같이 0.89\*의 경우는 A와 B의 혼합비율에 약 9:1로 추정 가능할 것이며, 0.10\*는 A,B의 혼합 비율이 1:9가 될 것이며 이의 방향성은 인근 화소를 참고로 결정할 수 있다.

4. 역전파 신경망의 적용

4.1 기본이론

인간의 두뇌 구조를 모방하여 좀 더 효과적인 인식 수단으로 사용하고자하는 노력은 지금까지 여러 학자들에 의해 지속되어 왔고 실제로 최근들어 매우 만족할 만한 연구 결과가 발표되고 있다. 이러한 신경망의 학습 알고리즘으로 유명한 것은 헤브의 학습 규칙(Hebbian Learning Rule), 퍼셉트론(Perceptron Rule), 역전파 규칙(Back-Propagation Rule), 델타 학습 규칙(Delta Rule) 등이 있으나 이중 역전파 신경망이 일반적으로 많이 사용되고 있다.

역전파 신경망은 그림 4.1과 같이 입력 패턴을 받아들이는 입력층, 몇개의 중간층 그리고 출력층으로 구성되어 있다. 이 때 중간층의 수는 정해져 있지 않으므로 적용하고자 하는 문제의 특성에 맞게 실험적으로 결정될 수 있다.




그림 41 전형적인 역전파 신경망 층 구조

역전파 신경망은 교사 학습을 원칙으로 하고 있는데 학습시키고자하는 모든 패턴들에 대해 이미 알고 있는 기대 출력값과 실제 출력값들 사이의 평균 제곱 오차(mean square error)를 최소화하기 위하여 신경망 내의 뉴런 간의 연결 강도를 반복적으로 조정하면서 학습을 수행한다. 학습은 전향 처리와 후향 처리로 나누어 볼 수 있다. 전향 처리는 입력 패턴이 활성화 함수에 의해 연산되어 출력값을 계산하는 과정이고, 후향 처리는 앞의 출력값과 기대 출력값과의 차이를 이전 층으로 역전파 시키는 과정이라고 볼 수 있다. (식 4.1)은 뉴런의 입력값과 중간층과의 연결 강도를 연산하여 중간층의 뉴런(net)으로의 입력값을 계산한다.

$$net_i = \sum_{j=1}^n w_{ij}a_j \quad (식 4.1)$$

(단,  $a_j$ 는  $j$ 번째 뉴런의 입력 신호,  
 $w_{ij}$ 는  $i$ 번째 뉴런에서  $j$ 번째 뉴런으로의 연결 강도,  
 $net_i$ 는  $i$ 번째 뉴런으로의 입력 총합)

그러나 (식 4.1)에 의해 계산된 값은 다음 층의 입력으로 전달되기 위해 (식 4.2)와 같은 시그모이드 함수에 의해 다시 연산된다.

$$\frac{1}{1 + \exp(-x)} \quad (식 4.2)$$

중간층을 통과한 후 출력층으로부터 얻을 수 있는 실제 출력값은 (식 4.3)과 (식 4.4)와 같이 기대 출력값과의 차이가 계산되어 이전의 연결 강도를 조정할 후 이전 층으로 역전파시켜 준다.

$$\delta_i = t_i - O_i \quad (식 4.3)$$

(단,  $t_i$ 는  $i$ 번째 뉴런의 기대 출력값,  
 $O_i$ 는  $i$ 번째 출력층 뉴런의 출력값,  
 $i$ 는 출력층의 뉴런의 수 (=1,2,3,...))

$$\Delta W_{ij} = \eta \delta_i \cdot O_j \quad (\text{식 4.4})$$

(단,  $\Delta W_{ij}$ 는 각 층 뉴런 사이의 변화된 연결 강도,  
 $\eta$ 은 임의의 상수로써 학습률로 표현되는 gain)

$$W_{ij} = W_{ij} + \Delta W_{ij} \quad (\text{식 4.5})$$

이때 최초의 연결 강도는 보통 난수(random value)로 주어진다. 이 연결 강도는 반복적인 수행을 통해 변경되고, 교차 신호와 최종 출력 신호와 일치되는 순간 더 이상의 작업을 수행하지 않게 된다. 그러나, 신경망 시스템의 가장 큰 단점은 뉴런의 수가 많아질 때 반복 학습의 횟수가 증가한다는 것이므로 반복 학습의 횟수를 줄이는 것과 지역 최소(local minima)에 따른 오 분류의 해소가 큰 과제가 된다.

본 논문에서는 최초로 주어지는 연결 강도를 임의의 수로 부여하지 않고 입력되는 신호가 발생했을 때 센서를 통해 취득되는 각 밴드의 디지털 값을 퍼지화한 후 이 퍼지수를 입력층과 중간층 사이의 연결 강도로 부여한다. 이와 같이 퍼지수를 연결 강도에 적용시킨 퍼지함수 기반 역전파 신경망(Fuzzy Back-Propagation neural network : FBP)을 구성한다. 다음 식은 역전파 신경망의 입력층과 중간층 사이의 연결 강도로 사용하며, 이는 (정의 3-1)에 따른다.

$$W_{ij} = S(P_{mm}(B_i); \alpha_i, \beta_i, \gamma_i) \quad (\text{식 4.6})$$

(단,  $I = 1, 2, 3$  밴드,  
 $j =$  중간층 뉴런의 수)

## 4.2 실험 및 고찰

### (1) 모형(prototype)의 구성

본 논문에서는 다음 그림 4.2와 같이 하나의 입력층과 중간층 그리고 출력층으로 된 구조를 갖는다. 이때,  $B_1, B_2, B_3$ 은 각기 다른 밴드(LANDSAT-TM의 경우 총 7개의 밴드가 있으므로 이중 3개의 밴드를 선택적으로 사용했음을 의미함)로 취득된 8비트의 입

력 패턴으로 이는  $input$ 으로 계산되고, 다음으로  $jput$ 은 입력 신호와 입력층과의 연결 강도를 곱한 중간층의 출력값이다.  $out$ 은 신경망을 통과한 출력값이 되고  $T_1, T_2$ 는 실제 조사를 통해 얻은 기대 출력값이 된다. 즉, 이 기대 출력값과  $out$ 이 일치하게 되면 성공적으로 학습을 마치게 되고 그렇지 않으면 오차가 계산되어 이전 층으로 역전파된다.




그림 4.2 제한된 역전파 신경망의 층 구조

력 패턴의 수는 위성에 탑재된 센서의 분광 해상도에 따른 갯수를 최대로 줄 수 있으며, 이의 선택은 학습의 효율성을 위하여 분류 대상에 따른 결정이 될 것이다. 2개의 기대 출력값은 본 연구의 최종 목표로 두고 있는 혼합 화소의 분석을 위한 구성 비율을 염두에 둔 결정이다.

### (2) 결과의 고찰

본 실험에서는 학습 수렴 속도의 개선을 위한 방법을 고려하여 연결 강도의 조정을 퍼지수에 적용시킴으로써 현격한 학습 속도의 개선을 가져왔다. 또한, 학습률( $\eta$ )의 조정을 통해서 학습 수렴에 매우 많은 영향을 줄을 알 수 있었다. 그러나, 이 2개의 값을 적절히 조정하여 최적의 학습 수렴 및 지역최소를 극복할 수 있겠으나 이 최적값을 구하는 문제는 다음 연구로 미루기로 한다.

표 4.1 역전과 신경망의 학습 속도 비교표

training counts	10	20	30	40	50	54	100	150	166	200	250	300
FBP : target1	.58728	.59812	.59972	.59996	.59999	.6	.6	.6	.6	.6	.6	.6
target2	.41987	.40289	.40043	.40006	.40001	.4	.4	.4	.4	.4	.4	.4
BP : target1	.54384	.57001	.58377	.59114	.59514	.59617	.59975	.59999	.6	.6	.6	.6
target2	.45609	.42995	.41621	.40885	.40486	.40383	.40035	.40001	.4	.4	.4	.4

(a) target1=0.6,target2=0.4인 경우


training counts	10	20	30	40	50	73	100	150	200	225	250	300
FBP : target1	.66587	.69254	.69824	.69958	.69990	.7	.7	.7	.7	.7	.7	.7
: target2	.34113	.30882	.30207	.30050	.30012	.3	.3	.3	.3	.3	.3	.3
BP : target1	.58663	.63641	.66261	.67734	.68601	.69521	.69860	.69985	.69998	.7	.7	.7
: target2	.41330	.36355	.33737	.32265	.31399	.30479	.30140	.30015	.30002	.3	.3	.3

(b) target1=0.7,target2=0.3인 경우


training counts	10	20	30	40	50	92	100	150	200	250	282	300
FBP : target1	.70177	.73665	.74584	.74866	.74956	.75	.75	.75	.75	.75	.75	.75
: target2	.30501	.26490	.25462	.25149	.25049	.25	.25	.25	.25	.25	.25	.25
BP : target1	.60732	.66729	.69875	.71688	.72802	.74553	.74666	.74945	.74991	.74998	.75	.75
: target2	.39262	.33268	.30123	.28311	.27197	.25447	.25334	.25055	.25009	.25002	.25	.25

(c) target1=0.75,target2=0.25인 경우


그림 4.3과 표 4.1은 역전과 신경망의 적용결과이며, BP에 비해 FBP의 학습수렴이 빠름을 알 수 있다. 즉, 퍼지 역전과 신경망의 경우는 학습 횟수면에서 기존의 역전과 신경망에 비해 적게는 100회 내지 200회 정도의 빠른 학습 수렴을 보여준다.



(b) target1=0.7,target2=0.3인 경우



(a) target1=0.6,target2=0.4인 경우



(c) target1=0.75,target2=0.25인 경우

그림 4.3 역전과 신경망의 학습 수렴 그래프



본 퍼지 역전과 신경망의 적용은 mixel 분류를 위한 최초의 제안이 될 것이며, 이를 통한 mixel의 분류는 용이할 것으로 사려되나 혼합형태에 대한 training 데이터의 부족으로 학습량의 부족에 따른 오차가 문제로 남을 것이다. 또한, mixel속에 포함된 방향성에 대한 고려도 분류항목의 분광 특성과 학습 데이터의 부족에 따른 분류의 문제점으로 지적된다.

## 5. 결 론

본 연구에서는 위성탐사 이미지의 혼합화소에 대한 분류를 위한 두 가지의 모형을 제안했다. 퍼지 시그모이드 함수를 적용하는 경우, 프로그램의 용이성이나 혼합화소의 정량성과 방향성 결정에 어려움이 없으나 분류의 기준 결정에서 물체에 따른 밴드의 선정이나 분광강도의 특성에 따라 이를 결정해야 하는 어려움이 따른다. 다음으로, 역전과 신경망의 적용에서는 학습에 의한 분류의 정확성 면에서는 문제가 없으나, 혼합형태에 대한 학습 데이터의 부족함에 따른 학습능률이 한정될 것이라는 점이 실용적 이용에 제한을 받을 것이다.

향후의 과제로는 실제 원격탐사 데이터에서 혼합화소에 포함된 복수개의 범주를 효과적으로 분류하고, 그의 방향성 결정을 위한 보다 개선된 연구를 수행할 것이다.

## 감사의 글

이 논문은 1994년도 한국학술진흥재단의 공모과제 연구비에 의하여 연구되었음

## 참 고 문 헌

1. Cannon, R.L., Dave, J.V., Bezdek, J.C., and Trivedi, M. M. "Segmentation of a thematic image using the fuzzy c-means clustering algorithm", IEEE Trans. on Geoscience and Remote Sensing, Vol.24, NO.3, pp.400-408, 1986.
2. Kent, J.T., and Mardia K.V., "Spatial classification using fuzzy membership models", IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol.10, NO.5, pp.659-671, 1988.
3. Wang, F., "Improving remote sensing image analysis through fuzzy information representation", PE&RS, Vol.56, pp.1163-1169, 1990.
4. Benediksson, J.A., Swain, P.H., and O.K. Ersoy, "Neural network approaches versus statistical methods in classification of multisource remote sensing data", IEEE Trans. on Geosci. Remote Sensing, Vol.28, NO.4, pp.540-552, July, 1990.
5. Lee, J., Weger, R.C., Sengupta, S.K. and Welch, R.M., "A neural network approach to cloud classification", IEEE Trans. on Geosci. Remote Sensing Vol.28, NO.5, pp.846-855, 1990.
6. McCellan, G.E., DeWitt, R.N., Mathesoh, I.N. and Moc, G.O., "Multispectral image processing with a three-layer backpropagation network", in Proc.IJCNN'89(Washington DC), Vol.1, pp. 151-153, 1989.
7. Salu, Y. and Tilton, J., "Classification of multispectral image data by the binary diamond neural network and by nonparametric, pixel-by-pixel methods", IEEE Trans. on Geosci. and Remote Sensing, Vol.31, NO.3, pp.606-617, May, 1993.
8. Bishop, H., Schneider, W. and Pinz, A.J., "Multispectral classification of LANDSAT images using neural networks", IEEE Trans. on Geosci. and Remote Sensing, Vol.30, NO.3, pp.482-490, May, 1992.
9. Foody, G.M., "On the compensation for chance agreement in image classification accuracy assessment", PE&RS, Vol.58, NO.10, pp.1459-1460, Oct., 1992.
10. Gopal, S. and Woodcock, C., "Theory and methods for accuracy assessment of thematic maps using fuzzy sets", PE&RS, Vol.60, NO.2, pp.181-188,

Feb, 1994.

11. Munechika,C.K., Warnick,J.S., Salvaggio,C. and Schott,J.R, "Resolution enhancement of multispectral image data to improve classification accuracy", PE&RS, Vol.59, NO.1, pp.67-72, Jan., 1993.
12. ERDAS Inc., ERDAS Field Guide, 2nd Ed., Ver.7.5, July, 1991.
13. Lillesand,T.M. and R.W.Kiefer, Remote Sensing and Image Interpretation, 2nd Ed, John Wiley & Sons, 1987.
14. Heermann,P.D. and Khazenie,N., "Classification of multispectral remote sensing data using a back-propagation neural network", IEEE Trans. on Geosci. and Remote Sensing, Vol.30, NO.1, pp.81-88, Jan., 1992.
15. Kim,J.I. and Kim,S.C. "An Efficient Classification Algorithm of Mixed Pixel in Remote Sensing Image Data", 12th IASTED International Conference Proceeding, Annecy France, pp 14-18, May 1994.
16. Kim,J.I. and Kim,S.C., "Fuzzy Approaches for Improving a Classification Accuracy in Remote Sensing Image Data", IEEE/SMC '94 Conference, San Antonio, U.S.A Proceeding Vol.1, pp 354-359, Oct. 1994.