

# 위성 영상 분류를 위한 규칙 기반 훈련 집합 선택에 관한 연구

엄 기 문<sup>†</sup> · 이 쾌 희<sup>†</sup>

## 요 약

기존의 위성 영상 분류를 위한 훈련 집합의 선택은 대부분 사용자가 직접 측량하거나 지도로부터 얻어진 데이터를 이용하여 수작업을 통하여 얻는 것이 보통이다. 그러나 이러한 작업에는 시간과 비용이 많이 소요되며, 같은 지역 내에서도 사용하는 특징값의 변화가 다양하게 나타날 수 있다. 이러한 다양성은 신경망으로 하여금 분류 데이터에 대한 강인성은 줄 수 있으나, 학습 시간이 많이 소요되는 단점을 수반하게 된다. 본 논문에서는 이러한 문제점을 해결하기 위하여 훈련 집합의 선택시 먼저 분류하고자 하는 지역의 대역별 밝기 분포를 조사하여 일정한 조건을 만족하는 화소들만을 훈련 집합으로 선택하는 알고리즘을 제안하였다. 이 알고리즘을 사용하여 SPOT 위성으로부터 얻은 다중 분광 영상에 대해 훈련 집합을 선택하고 역전과 신경망에 의해 학습한 후 분류한 결과, 기존의 사용자에 의해 선택된 훈련 집합보다 초기의 수렴속도가 빠르고, 분류 성능이 좋은 결과를 보였다. 또한 밝기 정보외에 NDVI (Normalized Vegetation Index)와 텍스처 특징을 이용함으로써 분류 성능이 개선됨을 확인하였다.

## A Study on the Rule-Based Selection of Training Set for the Classification of Satellite Imagery

Gi Mun Um<sup>†</sup> · Kwae Hi Lee<sup>†</sup>

### ABSTRACT

The conventional training set selection methods for the satellite image classification usually depend on the manual selection using data from the direct measurements of the ground or the ground map. However this task takes much time and cost, and some feature values vary in wide ranges even if they are in the same class. Such feature values can increase the robustness of the neural net but learning time becomes longer. In this paper, we propose a new training set selection algorithm using a rule-based method. By the technique proposed, the SPOT multispectral Imagery is classified in 3 bands, and the pixels which satisfy the rule are employed as the training sets for the neural net classifier. The experimental results show faster initial coverage and almost the same or better classification accuracy. We also showed an improvement of the classification accuracy by using texture features and NDVI.

### 1. 서 론

최근에 인공위성으로부터 얻을 수 있는 영상 데이터는 그 종류와 양에 있어서 방대하다. 이 중 실제로 많이 쓰이는 데이터는 LANDSAT (LANDSATellite) 위성의 MSS (Multi Spectral Scanner)·TM (Thematic Mapper) 데이터나 SPOT 위성의 전정 (panchromatic)

<sup>†</sup> 정 회 원: 서강대학교 전자공학과  
논문접수: 1996년 10월 24일, 심사완료: 1996년 11월 22일

·다중 분광 (multispectral) 영상 등이다. 특히 이들 데이터를 사용한 위성 영상의 분류는 농작물 분포 조사, 식생 조사, 스테레오 정합을 위한 전처리 등 응용 분야가 매우 넓다. 스테레오 정합시 전처리 단계로서 영상의 분류를 통하여 영상을 대표적인 몇가지 지역으로 나누고, 정합장들의 크기를 지역별 특성에 따라 다르게 함으로써 정합효율을 높일 수 있다. 본 논문에서는 이러한 목적을 위하여 위성 영상을 산림, 농경지, 강 및 호수 등의 지역으로 분류하였다.

기존의 영상 분류 기법은 크게 감독 분류(Supervised Classification)와 무감독 분류(Unsupervised Classification)로 나눌 수 있는데, 위성 영상의 분류에는 감독 분류가 많이 사용된다. 감독 분류의 대표적인 것으로는 최대 가능성(maximum likelihood) 알고리즘, 최소 거리(minimum distance) 알고리즘 등이 있다[1]. 이들은 주로 대역별 화소의 밝기를 특징으로하여 분류하는 통계적 분류 알고리즘이다. 최근에는 컴퓨터 기술의 발달로 신경망을 이용한 분류 알고리즘 [2]도 많이 연구되고 있다.

이러한 분류 기법들의 성능에 영향을 미치는 중요한 요소로서 크게 두 가지를 들 수 있다. 첫째 요소는 훈련 집합 (training set)의 특성이다. 감독 분류에서는 훈련 집합을 각 지역마다 대표성이 있는 화소들을 잘 선택해야만 훈련집합과 시험집합에 대한 분류기의 성능차이가 줄어들게 되므로 영상 분류 과정에서 매우 중요한 역할을 한다. 위성 영상 분류를 위한 기존의 훈련집합선택은 특별한 규칙 없이 직접 사용자가 육안으로 특정 지역이라고 판단되는 영역을 설정함으로써 선택되는 것이 일반적이었다.

둘째 요소는 분류의 기준이 되는 특징인데, 이것은 각 지역마다 구분할 수 있게 만드는 기준이 되므로, 각 클래스 간에는 차이가 크며, 동일 클래스 내에서는 차이가 거의 없는 특징을 사용하여야 한다. 기존의 위성 분류에서는 한 화소 (one pixel)의 각 대역별 밝기값이 주로 사용되었다.

그러나 최근 센서의 발달로 인해 영상의 해상도가 증가하면서 기존의 방법을 고해상도의 영상에 그대로 적용할 경우 서로 다른 클래스간에 중복되는 밝기들이 많이 발생하거나, 동일 클래스 내에서도 밝기 변화가 심해지는 경우에는 분류가 제대로 이루어지지 못하였다. 이러한 문제점을 해결하기 위해 NDVI

[3]를 이용하거나, 중심 화소와 주위 화소의 밝기 관계까지 고려하는 기법에 대한 연구가 이루어졌다. 주위화소를 고려하는 기법의 대표적인 것으로서 텍스처 (texture) 특징 추출 기법 [4-7]이 있는데, 이 기법은 식생이나 농작물 분포 등 비교적 클래스가 많은 경우에 주로 이용되었으며, 분류하는 영상에 따라 성능 차이를 보이는 단점을 가지고 있다.

본 논문에서는 기존의 훈련집합 선택과정에서 분류 성능은 그대로 유지하면서 수작업 의존성을 줄이고, 과정의 자동화를 위하여 일정한 규칙을 통한 훈련집합 선택 알고리즘을 제안하였다. 또한 분류하는 지역의 종류를 산림, 농경지, 강, 호수 또는 산림, 농경지, 호수로 사용하였을 경우 NDVI와 텍스처 특징을 이용함으로써 분류 성능이 개선됨을 실험적으로 확인하였다.

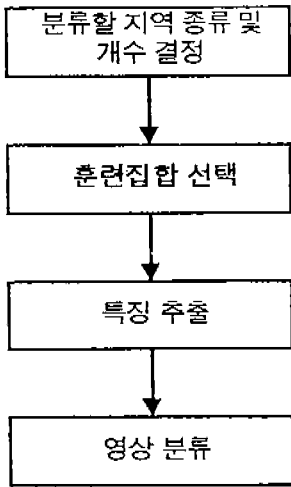
본 논문의 구성은 먼저 2장에서 기존의 위성 영상 분류 과정에 대해 기술하였고, 3장에서는 본 논문에서 제안한 훈련집합 선택 알고리즘에 대해 기술하였다. 4장에서는 두 위성 영상에 대해 제안한 알고리즘을 사용하여 실험한 결과를 보이고 분석하였으며, 5장에서 결론을 제시하였다.

## 2. 위성 영상 분류 과정

일반적으로 위성 영상의 분류에 많이 사용되는 감독 분류 과정은 그림 1과 같이 크게 4 단계로 구성된다. 즉 주어진 영상에 대해 분류할 지역의 종류와 갯수를 결정하고, 각 지역에 대해 훈련집합을 선택하며, 선택된 훈련집합으로부터 특징을 추출한 다음 구해진 특징을 기준으로 하여 영상을 분류하게 된다.

첫 번째 단계에서 분류할 지역의 결정은 사용자의 목적과 주어진 영상에 따라 결정된다. 예를 들어 어떤 지방의 농작물 분포를 조사할 경우에는 벼, 밀, 수수 등과 같이 농경지를 세분화하여 분류할 지역을 정하고, 광산 지대의 광물 분포를 조사할 경우에는 광물의 종류에 따라 분류할 지역을 정하게 된다. 본 논문의 경우에는 고도가 높고 고도 변화가 심한 산림지역, 고도가 비교적 낮고 고도 변화가 크지않은 농경지역, 고도 추정이 곤란하고 정합이 잘되지 않는 강이나 호수 지역의 세 지역으로 분류하였다.

두 번째 단계인 훈련집합을 선택하는 과정은 보통



(그림 1) 영상분류를 위한 감독 분류 과정  
(Fig. 1) Conventional Supervised Classification Process

사용자가 임의로 해당되는 지역의 표본 (sample)을 추출한 후 그 지역의 지도나 항공사진과의 비교 또는 직접 측량을 하게 된다. 이 때 각 훈련 집합은 주어진 지역에 대해 경계에 의해 둘러싸인 영역이 선택되며, 이를 훈련 필드 (training field)라고 부른다.

세 번째 단계는 이렇게 선택된 훈련집합으로부터 분류에 사용될 특징을 계산하는 과정이다. 여기에 사용되는 특징으로는 앞에서 언급한 바와 같이 각 대역에서의 밝기, 표준편차, NDVI [3], 텍스처 특징 등이 있으며, NDVI와 텍스처 특징 중 가장 많이 사용되는 ASM과 CON의 정의식 [1]은 다음 식과 같다.

$$NDVI = \frac{NearIR - Red}{NearIR + Red} \quad (1)$$

$$ASM = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \Phi^2_M(i, j) \quad (2)$$

$$CON = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i, j)^2 \Phi_M(i, j) \quad (3)$$

식 (1)의 NearIR과 Red는 각각 자외선 대역과 Red 대역의 화소밝기값이며, 식 (2)와 (3)에서  $\Phi(i, j)$ 는 공간 밝기 의존 행렬이며,  $N_g$ 는 양자화 단계이다. 여기서 ASM 특징은 영상의 동질성에 대한 척도가 되며, CON 특징은 영상에서의 지역적인 밝기 변화척도가 된다. 한편 지역별로 계산된 특징은 필요에 따라 영

상 분류기의 학습에 사용된다.

마지막 단계는 구해진 특징과 영상 분류기를 사용하여 주어진 영상을 분류하는 단계이다. 영상 분류기로서 많이 사용되는 방법에는 최대 가능성 분류(Maximum Likelihood Classification), 최소 거리 분류(Minimum Distance Classification) 등이 있으며, 최근에는 본 논문에서와 같이 오류 역전파 알고리즘을 이용한 다층 신경망을 이용한 연구도 이루어지고 있다[8].

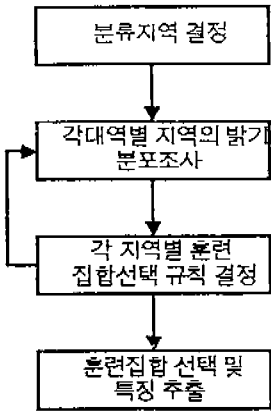
이러한 분류의 과정에서 분류 결과의 성능에 가장 영향을 많이 주는 단계는 훈련집합 선택 단계이다. 기존의 사용자에게 의한 훈련집합 선택방법은 비교적 정확하게 훈련집합을 선택할 수 있고, 원하는 지역을 자유롭게 훈련집합으로 선택할 수 있다는 장점이 있으나, 지역의 경계 부근에서 특징값들의 차이가 커질 우려가 있어 신경망 학습시 초기 수렴속도가 느리게 된다. 또한 많은 수의 훈련집합을 얻기 위해서는 그만큼의 수작업에 따른 부담이 커지게 된다. 따라서 본 논문에서는 훈련집합 선택과정에서 수작업에 의존성을 줄이면서 동일지역 내에서 특징값의 차이가 비교적 적은 화소들만을 훈련집합으로 선택하기 위한 알고리즘을 제안하였다.

### 3. 제안한 훈련집합 선택 알고리즘

본 논문에서 제안한 훈련집합 선택 알고리즘은 먼저 분류하고자 하는 지역 각각에 대해 대역별로 밝기 분포를 조사하여 밝기 범위에 의해 결정되는 선택 규칙을 세운 다음, 이 규칙을 만족하는 화소들만을 그 지역의 훈련집합으로 선택하는 것이다. 그림 2는 제안한 알고리즘의 순서도를 나타낸다.

이 알고리즘을 보다 구체적으로 기술하면 다음과 같다.

- 1) 먼저 입력 영상으로부터 분류하고자 하는 지역을 정한다. 지역의 종류는 사용자가 입력 영상에 포함된 지역을 조사하여 결정하게 되는데, 본 논문에서 주로 사용한 지역은 산림, 농경지, 강, 호수 등이다.
- 2) 다음으로 영상 대역별로 각 지역의 밝기 분포 범위를 조사한다. 예를 들어 강이나 호수 등 물을 포함한 지역은 NearIR 대역에서 그 파장의 빛을 거의 흡수하므로, 지역들에 비해 매우 낮은 밝기



(그림 2) 제안한 훈련 집합 선택 알고리즘의 순서도  
 (Fig. 2) Flow chart of the training set selection algorithm proposed.

값을 가진다. 따라서 이 대역을 이용함으로써 강이나 호수지역을 쉽게 분류할 수 있다. 한편 농경 지역은 재배되는 작물의 종류에 따라 일반적으로 빛이 반사되는 양의 차이가 크고, 특히 green 대역에서 다른지역에 비해 반사량도 크게 나타난다. 그러나 산림지역에서는 green 대역에서의 반사량보다 흡수량이 많아 상대적으로 평균 밝기가 낮으며 분포 범위도 적게 나타난다. 따라서 농경지역과 산림지역의 구분에 green 대역이 많은 역할을 하게 된다.

3) 대역별로 밝기 분포 조사 결과를 바탕으로 그 지역에 속하는 대부분의 화소들이 속하도록 각 대역의 밝기 범위를 결정한다. 예를 들어 본 논문의 실험에서 사용한 영상은 SPOT 위성의 다중 분광 영상으로서 Red, Green, NearIR 대역으로 구성된다. 따라서 표 1에 주어진 바와 같이 세 대역에

<표 1> 실험 영상 1의 훈련집합에 대한 밝기 범위  
 <Table 1> The gray level range of training set for the experimental image 1.

대역 분류 지역	Red 대역	Green 대역	NearIR 대역
산 림	40~47	28~32	36~41
농경지	43~56	35~46	36~54
강	49~51	33~37	21~33
호 수	42~44	27~29	19~20

대해 각 지역의 밝기 범위를 결정할 수 있다.

위와 같이 결정된 밝기 범위를 사용하여 각 지역별에 대해 각 대역별 밝기가 주어진 범위 내에 속하는 화소만을 훈련집합으로 선택하는 규칙을 정한다. 즉 이 규칙을 식으로 표현하면 다음과 같이 쓸 수 있다.

$$\begin{aligned}
 & \text{If } class\ k.Red_{min} \leq P(i, j).Red \leq class\ k.Red_{max} \text{ and} \\
 & \quad class\ k.Gr_{min} \leq P(i, j).Gr \leq class\ k.Gr_{max} \text{ and} \\
 & \quad class\ k.NIR_{min} \leq P(i, j).NIR \leq class\ k.NIR_{max} \\
 & \text{then select } P(i, j) \text{ as a training pixel of class } k \quad (4)
 \end{aligned}$$

여기서,  $class\ k.Red_{min}$ ,  $class\ k.Gr_{min}$ ,  $class\ k.NIR_{min}$ 은 각각 클래스 k에 대한 각 대역의 최소 밝기를,  $class\ k.Red_{max}$ ,  $class\ k.Gr_{max}$ ,  $class\ k.NIR_{max}$ 은 각각 클래스 k에 대한 각 대역의 최대 밝기를 나타낸다. 또한  $P(i, j).Red$ ,  $P(i, j).Gr$ ,  $P(i, j).NIR$ 은 각각 화소  $P(i, j)$ 의 Red, Green, NearIR 대역의 밝기이다.

식 (4)의 조건은 각 대역별로 주어진 조건을 동시에 만족해야만 훈련집합의 원소로 선택되므로 하나의 대역밝기값 범위가 여러 지역에 대해 중복되더라도 나머지 대역의 밝기에 의해 구분될 수 있다. 표 1에서 산림 지역과 농경지역의 구분에는 Green 대역이 많은 역할을 하게 되며, 강이나 호수 지역과 나머지 지역의 구분에는 NearIR 대역이 유용함을 알 수 있다. 또한 강과 호수 지역은 Red 대역과 Green 대역을 이용함으로써 구분될 수 있음을 알 수 있다.

- 4) 2)~3)의 과정을 분류할 모든 지역에 대해 반복하여 각 지역별로 훈련집합의 선택 규칙을 결정한다.
- 5) 위의 과정을 거쳐 결정된 규칙에 따라 훈련집합을 선택하고, 이로부터 분류에 사용될 특징값들을 계산한다.

이와 같이 선택된 훈련집합은 실제 사용자에 의해 하나의 지역마다 하나의 훈련필드를 선택하였을 때 보다 훈련집합의 화소 개수도 많이 얻을 수 있으며, 특징이 일관성을 가지는 화소들을 많이 포함하게 된다. 따라서 신경망에 의한 학습시 초기 수렴 속도가 향상됨을 확인할 수 있었으며, 또한 시험집합에 의한

시각적인 분류 성능도 기존의 선택방법과 성능이 거의 동일하거나 좋은 분류 결과를 보였다.


#### 4. 실험 결과 및 분석

##### 4.1 실험 조건 및 환경

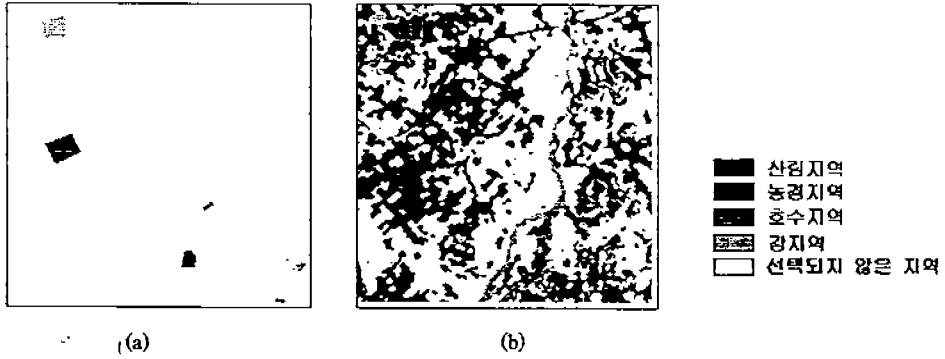
본 논문에서 사용한 영상은 대전 지역의 SPOT level 1A 다중 분광 영상(multispectral image) 전체 3000×3000 크기의 영상 중 Red, Green, NearIR 대역별로 256×256 크기의 두 영상을 사용하였다. 그림 3와 6의 (a), (b), (c)는 각각 분류에 사용한 영상의 Red, Green, NearIR 대역 영상을 나타낸다. 분류하는 클래스는 그림 3의 경우 산림, 농경지, 강, 호수의 네 종류로 하였으며, 그림 6에서는 산림, 농경지, 호수의 세 종류로 정하였다. 그림 4(a)는 그림 3에 대해 기존의 훈련 집합 선택 방법인 사용자에 의해 선택된 훈련집

합을 나타내며, 그림 4(b)는 본 논문에서 제안한 알고리즘을 이용하여 선택된 훈련집합을 나타낸다. 여기서 각각의 클래스는 산림은 밝기 50, 농경지는 밝기 100, 호수는 밝기 150, 강은 밝기 200, 선택되지 않은 훈련 집합은 밝기 250을 할당하였다. 이 때 선택되지 않은 훈련집합의 화소들은 시험 집합으로 사용되었다. 사용자에 의해 선택되는 훈련집합은 사용자에 따라 달라질 수 있으므로 세사람의 사용자가 먼저 임의로 훈련집합을 선택한 후, 모호성이 있는 경계부분을 제외하고 공통적으로 선택한 부분만을 사용하였다.

그림 5와 7은 그림 3과 6의 영상에 대해 기존의 알고리즘과 제안한 알고리즘을 이용하여 분류한 결과이다. 이 때, 두 그림의 (a), (b), (c)는 기존의 알고리즘을 사용하여 훈련집합을 선택하였으며, (d)는 제안한 알고리즘을 사용하여 훈련집합을 선택하였다. 분류된 클래스는 그림 5의 경우, 산림 지역은 밝기 50, 농



(그림 3) SPOT 위성 영상 1  
 (a)Red 대역 (b)Green 대역 (c)NearIR 대역  
 (Fig. 3) SPOT satellite imagery 1  
 (a)Red band (b)Green band (c)NearIR band



(그림 4) 선택된 훈련 집합  
 (a)기존의 방법 (b)제안한 방법  
 (Fig. 4) Selected training sets  
 (a)Conventional method. (b)Proposed method.

경 지역은 밝기 100, 호수 지역은 밝기 150, 강 지역은 밝기 200을 할당하여 표시하였으며, 그림 7의 경우 산림지역은 100, 농경지역은 150, 호수지역은 200으로 할당하였다. 또한 최대 가능성 분류시 각 클래스는 동일한 확률을 가진다고 가정하였으며, 모든 화소를 분류하였다.

한편 신경망을 이용한 분류시 신경망의 계층수는 3층을 사용하였는데, 먼저 입력노드의 경우 기존의 알고리즘 결과인 그림 5과 8의 (c)에서는 3개를 사용하였으며, 제안한 알고리즘 결과인 (d) 경우에는 III 장에서 기술한 NDVI와 2개의 텍스처 특징을 추가하여 6개를 사용하였다. 이 때, 각 특징은 0~1 사이의 값으로 정규화하여 사용하였다. 한편 출력 노드의 경우에는 분류하는 각 클래스마다 출력 노드를 하나씩 할당하여 그림 5의 경우에는 4개, 그림 7의 경우에는 3개를 사용하였다. 이 때 원하는 클래스의 출력은 0.9로, 나머지 클래스의 출력을 0.1로 정하였다. 또한 역전파 알고리즘은 수렴속도가 느리기 때문에 이의 개선을 위해 적응 학습률 및 모멘텀 갱신 규칙[8]을 사용하였다. 이 규칙은 매 4회 반복횟수마다 출력층에러가 감소하면 학습률과 모멘텀을 20% 증가시키고, 에러가 증가하면 학습률과 모멘텀을 50%감소 시키게 된다. 한편, 최대 반복 회수는 25000회이고, 에러가 0.001이하로 될 때까지 학습하도록 하였다.

은닉층의 노드 갯수는 다음과 같은 Paola의 계산법 [8]을 고려하여 최소은닉층 노드갯수를 결정한 후 여


러개의 은닉층 갯수를 실험한 후 비교적 시간과 성능 면에서 적당한 11개로 정하였다

은닉층의 수 =

$$\frac{2 + class\text{갯수} \cdot band\text{갯수} + \frac{1}{2} \cdot class\text{갯수} \cdot (band\text{갯수}^2 + band\text{갯수}) - 3}{band\text{갯수} + class\text{갯수}} \quad (5)$$

#### 4.2 실험 결과 및 분석

그림 3의 영상은 대부분의 지역이 농경지이고, 농경지 가운데로 강이 지나감을 볼 수 있다. 또한 강 주변에 산림 지역이 일부 나타나며, 저수지로 만들어진 호수가 좌측 상단에 보이고 있다. 그림 5는 이 영상에 대한 분류 결과를 나타내고 있다. 그림 5(a)는 최대 가능성 알고리즘에 의한 분류 결과로서 호수와 산림 지역에서는 대부분 좋은 분류 결과를 보이지만, 강지역의 경우 가운데 부분만 분류가 잘 되었을 뿐 나머지 부분에서는 산림이나 농경지로 오분류되는 지역이 많이 나타났다. 그림 5(b)는 최소 거리 알고리즘에 의한 분류 결과로서 강지역과 호수 지역, 산림 지역 등에서 최대 가능성 알고리즘의 결과보다는 좋은 결과를 보이고 있다. 그러나 농경 지역에서 산림 지역으로 오분류되는 지역이 아직 많이 남아 있음을 볼 수 있다. 그림 5(c)는 기존의 훈련집합선택 알고리즘에 의해 선택된 훈련집합을 사용하고, 신경망을 이용하




(그림 5) 그림 3 영상에 대한 분류 결과  
 (a)최대 가능성 방법 (b)최소 거리 방법  
 (c)기존의 훈련집합 선택에 의한 신경망 방법  
 (d)제안한 훈련집합 선택에 의한 신경망 방법  
 (Fig. 5) Classification results of Fig 3 imagery.

(a)Maximum likelihood method  
 (b)Minimum distance method  
 (c)Neural network method by conventional training set selection.  
 (d)Neural network method by proposed training set selection.


여 학습한 후 분류한 결과이다. 산림 및 호수지역은 비교적 잘 분류되었으나, 강지역은 호수로 오분류되는 지역이 많고, 농경지역 또한 호수 지역이나 강지역으로 오분류되는 지역이 많음을 볼 수 있다. 그림 5(d)는 제안한 훈련집합 선택 알고리즘을 사용하고, NDVI와 텍스처 특징인 ASM과 CON을 세 대역 밝기값에 추가하여 분류한 결과이다. 산림, 농경지, 호수, 강 동 전 지역에 걸쳐 기존의 알고리즘에 비해 좋은 결과를 보이고 있다. 실제 지역의 정확한 분류 지도(ground truth map)를 얻기가 어려운 관계로 정량

적인 성능 비교는 어렵지만, 시각적 판단과 지역의 연속성 측면에서는 제안한 알고리즘의 결과가 우수하다고 볼 수 있다.

그림 6의 영상은 산림 지역과 농경지가 대부분이며, 왼쪽 상단에 호수 지역이 존재하는 영상이다. 그림 7은 그림 6 영상에 대한 분류 결과를 나타내고 있는데, 그림 5와 동일한 방법을 사용하여 분류한 결과이다. 그림 7(a)는 최대 가능성 알고리즘에 의한 분류 결과로서 산림, 농경지, 호수의 세 지역이 그림 5 영상에서의 결과보다는 좋은 결과를 보이고 있지만 산



(그림 6) SPOT 위성 영상 2  
 (a)Red 대역 (b)Green 대역 (c)NearIR 대역  
 (Fig. 6) SPOT satellite imagery 2  
 (a)Red band (b)Green band (c)NearIR band




(그림 7) 그림 6 영상에 대한 분류 결과  
 (a)최대 가능성 방법 (b)최소 거리 방법  
 (c)기존의 훈련집합 선택에 의한 신경망 방법 (d)제안한 훈련집합 선택에 의한 신경망 방법  
 (Fig. 7) Classification results of Fig 6 imagery.

(a)Maximum likelihood method (b)Minimum distance method  
 (c)Neural network method by conventional training set selection.  
 (d)Neural network method by proposed training set selection.



림 지역의 일부 중 밝은 밝기를 가지는 부분은 농경지로 오분류되는 지역도 나타나고 있다. 그림 7(b)의 최소 거리 알고리즘에 의한 분류는 최대 가능성 알고리즘 결과와 거의 유사한 결과를 보이고 있음을 볼 수 있다. 그림 7(c)는 기존의 훈련집합 선택 알고리즘을 사용하고, 신경망에 의한 분류결과인데 일부 산림 지역이 호수지역으로 오분류되는 지역이 나타나고 있다. 이것은 학습이 제대로 이루어지지 못한 원인으로 보인다. 그림 7(d)는 제안한 훈련집합 선택 알고리즘을 사용하고 신경망을 이용한 분류결과인데, (c)의 결과보다는 오분류되는 지역이 감소되었음을 볼 수 있다. 따라서 제안한 훈련 집합 선택 알고리즘은 영상의 종류에 관계없이 기존의 알고리즘에 비해 향상된 성능을 보이고 있음을 확인할 수 있다.

다음 그림 8은 그림 3 영상에 대한 학습 오차 곡선 일부를 나타낸 것인데, (a)가 기존의 훈련집합 선택에 의한 오차곡선이고, (b)가 제안한 훈련집합 선택에 의한 오차곡선이다. 여기서 학습에는 (a)의 경우 967개의 데이터가, (b)의 경우 28,198개의 데이터가 사용되었다. 따라서 전체적인 수렴속도는 (a)의 경우가 더 적게 걸리지만, 그림에서 보듯이 초기(b)의 경우가 (a)의 경우보다 초기 수렴속도가 빠름을 볼 수 있다.



(그림 8) 각 훈련집합들을 사용한 신경망 학습 오차 곡선 (Fig. 8) Learning error curve of neural network using each training set.

- (a) 기존의 훈련집합 선택 방법
- (a) Conventional training set selection.
- (b) 제안한 훈련집합 선택 방법
- (b) Proposed training set selection.

### 5. 결론 및 추후 과제

본 논문에서는 스테레오 정합시 지역에 따라 정합 방법을 달리 적용하기 위한 전처리 과정으로서 SPOT 인공위성 다중 분광 영상을 산림, 농경지, 강 및 호수 등으로 분류하였다. 본 논문에서는 감독 분류 과정의 중요한 요소인 훈련 집합의 선택에서 지역별 밝기 분포에 따라 규칙을 세우고 이를 이용하여 훈련집합을 선택하는 알고리즘을 제안하였다. 이렇게 함으로써 사용자가 훈련집합을 선택함에 따라 발생하는 훈련 집합 개수의 제한, 수렴 시간 증가 등의 문제점을 줄일 수 있었다. 또한 제안한 알고리즘에 의해 선택된 훈련집합을 사용하여 오류역전파 신경망에 학습시킨 후 분류를 수행한 결과, 기존의 사용자의 선택에 의한 알고리즘보다 거의 동일하거나 좋은 성능을 보임을 알 수 있었다. 또한 기존의 분류 특징으로 많이 사용하는 세 대역 밝기값이외에 NDVI와 화소간의 관계를 고려하는 텍스처 특징을 추가 특징으로 사용함으로써 클래스가 비교적 적은 경우에 텍스처 특징 및 NDVI의 유용성을 실험적으로 확인할 수 있었다.

최근에 우리나라에도 인공위성이 발사되면서 이에 관련된 연구 분야 특히 원격 탐사 및 GIS 분야에도 관심이 높아지고 있으며, 연구 활동도 점차 많이 이뤄지고 있다. 또한 가까운 장래에는 다목적 위성이 발사되어 우리 위성으로부터 얻어진 영상을 이용할 수 있을 것이다. 이러한 영상 자료를 보다 효과적으로 사용하기 위해서는 위성 영상 처리 기술에 대한 습득이 필수적이라 할 수 있으며, 본 논문도 이러한 기술에 대한 연구에 효율적으로 응용될 수 있으리라 기대된다. 추후 과제로는 보다 정확한 훈련집합의 선택을 위한 선택 규칙의 보완 연구가 필요하리라 생각된다.

### 참고 문헌

- [1] J. A. Richards, 'Remote Sensing Digital Image Analysis', Springer-Verlag, NewYork., pp. 181-190, 1995.
- [2] R. P. Lippmann, "An Introduction to Computing with Neural Nets," IEEE ASSP Magazine, pp. 4-22, April 1987.
- [3] P. M. Mather, 'Computer processing of remotely-

sensed images', John Wiley and Sons, U. K., pp. 192-193, 1987.

- [4] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Texture features for image classification," IEEE Trans. Syst. Man and Cybern., Vol. SMC-3, No. 6, pp. 610-621, Nov. 1973.
- [5] R. W. Connors and C. A. Harlow, "A theoretical comparison of texture algorithms," IEEE Trans. Pattern Anal. Machine Intell., Vol. PAMI-2, pp. 204-222, 1980.
- [6] J. A. Weska, C. R. Dyer, and A. Rosenfeld, "A comparative study of texture measures for terrain classification," IEEE Trans. Syst., Man, Cybern., Vol. SMC-6, pp. 269-285, 1976.
- [7] M. M. Galloway, "Texture analysis using gray level run lengths," Comput. Graphics Image Processing, Vol. 4, No. 2, pp. 172-179, June 1975.
- [8] J. D. Paola and R. A. Schowengerdt, "A Detailed Comparison of Backpropagation Neural Network and Maximum-Likelihood Classifiers for Urban Land Use Classification," IEEE Trans. Geoscience and Remote Sensing, Vol. GRS-33, No. 4, pp. 981-996, 1995.



**엄 기 문**

1991년 서강대학교 전자공학과 졸업(학사)  
 1993년 서강대학교 대학원 전자공학과(공학석사)  
 1993년~현재 서강대학교 대학원 전자공학과 박사과정

관심분야: 신호처리, 컴퓨터 비전



**이 개 희**

1971년 서울대학교 전기공학과 졸업(학사)  
 1973년 서울대학교 대학원 전기공학과(공학석사)  
 1983년 미국 남가주대학교 전기공학과(공학박사)  
 1983년~현재 서강대학교 전자

공학과 교수

관심분야: 자동제어, 신호처리