

## 수정 이방성 분산 복원을 이용한 영상 분류

이상훈

경원대학교 산업공학과

### Image Classification Using Modified Anisotropic Diffusion Restoration

Sang-Hoon Lee

Department of Industrial Engineering, Kyungwon University

**Abstract :** This study proposed a modified anisotropic diffusion restoration for image classification. The anisotropic diffusion restoration uses a probabilistic model based on Markov random field, which represents geographical connectedness existing in many remotely sensed images, and restores them through an iterative diffusion processing. In every iteration, the bonding-strength coefficient associated with the spatial connectedness is adaptively estimated as a function of brightness gradient. The gradient function involves a constant called “temperature”, which determines the amount of discontinuity and is continuously decreased in the iterations. In this study, the proposed method has been extensively evaluated using simulated images that were generated from various patterns. These patterns represent the types of natural and artificial land-use. The simulated images were restored by the modified anisotropic diffusion technique, and then classified by a multistage hierarchical clustering classification. The classification results were compared to them of the non-restored simulation images. The restoration with an appropriate temperature considerably reduces error in classification, especially for noisy images. This study made experiments on the satellite images remotely sensed on the Korean peninsula. The experimental results show that the proposed approach is also very effective on image classification in remote sensing.

**Key Words :** Image Restoration, Image Classification, Anisotropic Diffusion, Remote Sensing, Markov random field.

**요약 :** 본 연구는 원격탐사 영상분류 과정에 수정 이방성 분산 복원을 제안하고 있다. 수정 이방성 분산 복원은 많은 원격탐사 영상에 나타나는 지리적 연결성을 대표하는 Markov random field에 기반한 확률적 모형을 사용하고 있고 반복적인 확산과정을 통해 영상복원을 수행한다. 제안 확산과정은 지리적 연결성과 연관된 응집력 계수를 위하여 brightness gradient의 함수를 사용하며 매 반복 단계마다 adaptive하게 추정한다. 응집력 계수의 gradient의 함수는 반복과정 동안 지속되어야 하는 불연속성의 크기를 결정하는 온도상수를 포함하고 있으며 이 온도 값은 반복과정이 진행되는 동안 감소가 되도록 설정된다. 본 연구에서는 자연적 토지사용 형태와 인위적 토지사용 형태를 대표하는

다양한 패턴으로부터 생성된 모의자료를 사용하여 수정 이방성 분산 복원을 적용한 영상분류에 대한 실험 평가를 실시하였다. 적절한 온도를 선택한 복원 영상에 대한 분류는 관측영상의 분류보다 정확한 결과를 생성하였고 특히 noise가 많은 영상에 대한 적용은 괄목만한 향상을 보여 주었다. 또한 한반도의 위성 원격탐사 자료에 대한 실험을 실시하였고 제안된 수정 이방성 분산 복원의 적용은 실제 관측 자료에도 매우 효과적임을 알 수 있었다.

## 1. 서 론

지구환경 연구를 위한 많은 원격탐사 영상의 scene에서 동일 특성의 토지사용 구획(patch)들은 지역적 연속성을 갖고 있다. 이 사실에 근거하여 서로 이웃하고 있는 지역들은 비슷한 혹은 동일한 강도(intensity) 값을 가질 확률이 크다. 그러므로 원격탐사 영상자료를 이용한 토지사용 분류에서 지역적 연속성을 고려하는 것은 중요하다. 지역적 연속성을 고려하기 위해 영상분류 과정은 수치 영상(digital image)의 공간적 특성과 관련된 문맥정보(contextual information)를 사용한다. 그러나 영상분류 과정에서 문맥 정보를 사용하는 것은 계산상 복잡성을 요구하므로 일반적으로 광범위한 지역에 대한 관측 자료인 큰 크기의 원격탐사 영상을 위해서 문맥정보를 사용하는 영상분류는 비효율적일 수 있다. 본 연구에서는 큰 크기의 원격탐사 영상을 효율적으로 분류하기 위해서 수정 이방성분산(MAID: Modified Anisotropic Diffusion) 영상복원 후 비문맥 영상분류 기법을 적용할 것을 제안하고 있다.

영상처리에서 영상의 공간구조에 의거한 문맥 정보를 사용하는 것은 처리결과의 정확성을 향상시키는 데 매우 중요하다. 최근의 통계 영상 처리학에서는 공간적 연결성과 관련된 문맥정보를 위해 Markov Random Field(MRF)(Kindermann and Snell, 1982)를 이용하고 있다. 영상처리 과정의 MRF는 서로 이웃하고 있는 화소들은 같은 클래스에 속할 확률이 높다는 영상구조의 국지적 특성을 대표하고 있으며 Gibbs Random Field(GRF)(Georgii, 1979)상에 정의된 lattice-like 물리적 시스템 안에 존재하는 분자의 상태로서 화소의

형태를 간주함에 의해 수치영상 분석에 적용되어 진다. 특히 MRF 문맥정보를 사용하는 영상처리 기법은 computer vision 분야에서 영상의 texture 분석을 위해서 광범위하게 개발되어왔다. 최근에는 원격탐사 다중분광(multi-spectral) 영상자료의 무감독 영상분류(Yamazaki and Gingras, 1999)를 포함한 다양한 활용분야에서 MRF기법이 이용되고 있다.

원격탐사 영상자료는 일반적인 원인에 의한 noise 외에도 관측과 전송 중 주로 기계적 문제와 대기영향으로 발생한 noise에 의해 오염될 수 있다. 이러한 이유 때문에 위성영상 감지기에 의해 탐지된 수치영상들이 원래의 지구표면 상황을 나타내기에는 완전하지 않은 경우 좀 더 정확한 정보를 얻기 위해서는 영상복원 과정을 필요로 한다. 본 연구에서 제안된 영상 복원은 서로 이웃하고 있는 지역간의 공간적 종속성을 영상과정에 포함시키기 위해 GRF의 하나의 특수한 형태를 사용하고 있으며 이방성 분산(Perona and Malik, 1990)을 통하여 반복적으로 영상을 복원한다. 본 연구에서는 복원된 영상에 대해 비문맥 유사계수를 사용하는 다중단계 계층군집 무감독 분류법(이상훈, 2003)을 적용하여 영상분류를 수행하였으며 지상의 토지사용 형태를 대표하는 다양한 형태의 모의(simulation) 영상자료를 사용하여 영상복원이 분류에 끼치는 영향을 광범위하게 조사하였다.

본 논문은 다음과 같이 구성되어 있다. 2절은 수정 이방성분산 복원에 대한 자세한 설명을 포함하고 있고, 3절에서는 다중단계 무감독 분류법이 간략히 재조명되었으며 4절에서 모의자료를 사용하여 제안된 알고리듬 대한 평가와 효율성에 대한 검증을 하였고, 또한 한반도에서 관측된 원격탐사

자료에 대한 적용 결과 보여 주고 있다. 마지막으로 5절은 논문의 결론을 포함하고 있다.

## 2. 수정 이방성분산 영상 복원

영상과정은 각각 관측강도와 원래강도(복원하고자 하는 강도)와 관련된 두개의 continuous random field를 결합한 형태로 가정되어 진다. 이러한 복합 stochastic 모형의 영상과정에 대해서 최적의 영상 복원을 결정하는 목적함수는 Bayesian 이론에 근거하여 구성된다. Bayesian 기법은 관측 영상  $\mathbf{X}$ 가 주어진다면 원래강도 영상  $\mu$ 에 대한 사후확률 분포의 mode로부터 최대 사후추정치 (*maximum a posteriori*: MAP)를 발견하는 것으로서 다음의 log penalty 함수를 최대화하는 것과 일치 한다:

$$LPN = \log P(\mathbf{X} | \mu) + \log P(\mu) \quad (1)$$

오른 쪽의 두 번째 항목은  $\mu$ 의 특성에 대한 사전 정보를 나타낸다. 본 연구에서는 영상복원을 위한 공간적 연속성을 확률적으로 계량화하기 위하여, 즉  $\mu$ 에 관한 사전 정보를 제공하는 하나의 형식으로 MRF모형을 사용한다.

Hammersley-Clifford 이론(Kindermann and Snell, 1982)의 결과로서 나타난 MRF와 GRF의 동일화에 의거하여 lattice-like 물리적 시스템에 대한 하나의 에너지함수에 대한 지정은 문자간의 상호작용을 모형화하기 위해 사용되어진 Gibbs measure를 결정하는 것이고 또한 이러한 지정은 MRF를 결정하는 것이다.

총 화소수가  $n$ 인 주어진 영상의 화소 색인집합을  $I_n$ 이라 할 때  $R_i$ 가  $i$ 번째 화소의 이웃들의 색인집합이라 하면  $R = \{R_i, i \in I_n\}$ 이  $I_n$ 의 neighborhood 시스템이다. 그러면 graph  $\{I_n, R\}$ 의 clique  $c$ 는  $c$ 에 속하는 서로 다른 모든 화소쌍이 서로 이웃이 되는  $I_n$ 의 소집합(subset)이고  $C$ 는 모든 clique의 집합이라면  $\mu$ 에 대한 graph  $\{I_n, R\}$ 와 연관된 GRF는 다음과 같이 정의 된다:

$$P(\mu) = z^{-1} \exp\{-E(\mu)\} \quad (2)$$

$$E(\mu) = \sum_{c \in C} V_c(\mu)$$

$z$ : 표준화 상수(normalizing constant)

$V_c$ : 잠재 함수(potential function)

$\mu$ 와  $c$ 에만 단지 그의 값이 의존하는 잠재함수  $V_c$ 와 clique 시스템  $C$ 에 대한 상술(specification)로 지역 클래스 모형을 위한 Gibbs measure를 공식화 하기 충분하다. 본 연구에서 pair-potential 함수 (Georgii, 1979)의 항목으로 만 표현되어 지는 에너지함수를 가진 하나의 특별한 형식의 GRF를 사용한다. pair-potential 함수  $\{V_p(r, s) | (r, s) \subset I_n\}$ 는  $C_p$ 를 pair-clique 시스템이라 할 때  $V_p(r, s) = V_p(s, r)$ 이고 만약  $r = s$ 이거나  $(r, s) \notin C_p$ 이라면  $V_p(r, s) = 0$ 인 대칭 함수 군이다.

이웃하고 있는 화소들은 서로 비슷한 강도를 가질 확률이 높다고 가정하는 것이 당연하다. 이러한 가정아래 이웃하고 있는 화소들 간의 원래 강도차이의 함수인 pair-potential 함수는 영상과정에서 공간적 연속성을 계량화 할 수 있다. 그러므로 MRF의 에너지함수는 영상복원을 위하여 원래 강도 과정의 확률구조를 정의하기 위해  $\mu$ 의 2차 함수의 항목으로 상술되어질 수 있다: 만약  $[v]^2$ 이 벡터  $v$ 의 각 요소의 자승 값이라면

$$E_p(\mu) = \sum_{(r, s) \in C_p} \alpha_{rs} [\mu_r - \mu_s]^2 \quad (3)$$

$\mu_r$ :  $r$ 번째 화소의 원래강도 벡터

$\alpha_{rs} = \alpha_{sr}$ :  $r$ 번째와  $s$ 번째 화소간의 응집력(bonding strength)을 나타내는 비음(non-negative) 계수

다중분광 밴드 분석에서 공간적 종속성은 일반적으로 분광밴드별로 독립적으로 작용한다는 가정을 가진다. 이러한 가정아래 공간적 종속성에 근거한 본 연구에서 제안된 영상복원은 분광밴드 별로 개별적으로 수행한다. 원래강도  $\mu$ 의 확률구조로 사용되는 GRF의 식(3)의 에너지함수는 단일밴드에 대해서 다음과 같이 표현되어 진다:

$$E_p(\mu) = \mu' \mathbf{A} \mu \quad (4)$$

위의 식에서  $\mathbf{A} = \{A_{ij}, i, j \in I_n\}$ 는 다음과 같은 요소를

가지는 응집력 계수의 행렬이다:

$$A_{ij} = \begin{cases} \sum_{k \in R_i} \alpha_{ik}, & \text{if } j = i \\ -\alpha_{ij}, & \text{if } j \in R_i \\ 0 & \text{otherwise.} \end{cases} \quad (5)$$

가산 가우시안(additive Gaussian) 영상모형의 가정아래 관측강도  $\mathbf{X}$ 의 조건하에 원래강도  $\mu$ 의 사후확률은 random noise 분산행렬  $\Sigma = \text{diagonal}\{\sigma_i^2, i \in I_n\}$ 이 주어진다면

$$f(\mu | \mathbf{X}) = (\mathbf{X} - \mu)' \Sigma^{-1} (\mathbf{X} - \mu) + \mu' \mathbf{A} \mu \quad (6)$$

그리고 식 (6)으로부터 log-likelihood 방정식 시스템은

$$\Sigma^{-1}(\mathbf{X} - \mu) - \mathbf{A}\mu = \mathbf{0}. \quad (7)$$

식 (7)의 방정식 시스템은 다음과 같이 재구성 될 수 있다:

$$\mu = \mathbf{D}^{-1} \mathbf{S} \mu - \mathbf{D} \Sigma^{-1} \mathbf{X} \quad (8)$$

$$\mathbf{D} = \{D_{ij}, i, j \in I_n \mid D_{ii} = \sigma_i^{-2} + A_{ii} \text{ and } D_{ij} = 0 \text{ for } i \neq j\}$$

$$\mathbf{S} = \{S_{ij}, i, j \in I_n \mid S_{ii} = 0 \text{ and } S_{ij} = A_{ij} \text{ for } i \neq j\}$$

원래강도가 식 (4)의 에너지함수의 GRF의 확률 구조를 가진다면 point-Jacobian 반복법(Varga, 1962)을 사용하여 MAP에 의한 원래강도 영상은 식 (8)로부터 반복적으로 추정될 수 있다:  $i$ 번째 화소의 관측값과  $h$ 번째 단계에서 복원값을  $x_i$ 와  $\hat{x}_i^h$ 라고 하고  $\hat{x}_i^0 = x_i$ 이면

$$\hat{x}_i^h = D_{ii}^{-1} \left( \sigma_i^{-2} - \sum_{j \in R_i} S_{ij} \hat{x}_j^{h-1} \right), \quad \forall i \in I_n \quad (9)$$

식 (9)의 반복식은 다음과 같은 조건에서 유일해(unique solution)로 수렴한다.

$$D_{ii}^{-1} \sum_{j \in R_i} S_{ij} < 1, \quad \forall i \in I_n. \quad (10)$$

식 (5)의 응집력 계수의 행렬은 위의 수렴조건을 만족시킨다. 그러나 대부분의 실제적용의 경우 응집력 계수를 알 수 없다. 그러므로 본 연구에서는 계수를 추정하기 위하여 각 반복단계에서 adaptive 하게 계수를 선택하는 이방성 확산 기법을 이용한다. 계수  $\alpha_{rs}$ 는 매 반복단계에서 brightness gradient

의 함수로서 간선되어 진다:

$$\alpha_{rs} = g(|\nabla_{rs}|) = g(|x_r - x_s|), \quad (r, s) \in C_p. \quad (11)$$

식 (11)에서 함수  $g$ 는 다음과 같은 형태를 갖는다:

$$g(|\nabla_{rs}|) = \exp \left[ -\frac{\nabla_{rs}^2}{K} \right] \quad (12)$$

혹은

$$g(|\nabla_{rs}|) = \frac{1}{1 + \nabla_{rs}^2/K}. \quad (13)$$

확산과정의 “온도”(temperature) 상수로 알려진 식 (12)과 (13)에서  $K$ 는 반복과정동안 지속되어야 하는 불연속성(discontinuities)의 크기를 결정하는 주어진 상수이며 이 값의 크기의 정도는 추정된 영상의 smoothing 정도를 결정짓는다. 일반적으로 온도 상수는 확산과정이 진행됨에 따라 감소되도록 설정된다. 초기단계의 높은 온도는 확산의 범위를 확장시켜 화소의 복원 값이 넓은 지역의 이웃들로부터 영향을 받게 하며 후기단계에서는 온도를 낮추어 확산을 국지화하여 단지 근접하고 있는 비슷한 수준의 이웃간에 같은 수준을 가지도록 화소의 복원 값을 추정한다.

### 3. 다단계 계층군집 영상분류

본 연구에서 영상분류를 위해 사용한 기법은 계층구조에 기반을 두고 유사/비유사 계수(similar/dissimilar coefficient)에 의해 두 지역의 합병을 수행하는 계층군집(Anderberg, 1973)에 기반하는 무감독 분석법이다. 다단계 계층군집 영상분류는 크게 두 단계로 이루어진다. 첫 번째 단계는 공간화장 영상분할 단계로 영상의 계층구조에 의해 공간적으로 근접하고 있는 이웃집단간의 결합을 통하여 최종적으로 전체영상의 공간 내에서 서로 이웃하고 있는 집단들의 물리적 특성이 서로 다르도록 영상을 분할하는 과정이다. 이 단계에서는 상호최근사 지역이웃쌍(MCRNP: Mutual Closest Regional Neighbor Pair)들 중에서 최선의 결합을 선택하는 계층군집 기법을 이용하고, 영상

분할의 계산/기억 상의 효율성 증가를 위하여 경계폐쇄에 의한 다중창 작업(multi-window operation)을 사용한다. 두 번째 단계는 결합지역의 공간적 제약 없이 영상분할 단계에서 분할된 집단을 계층군집에 의해 적은 한정적인 수의 클래스로 분류하는 과정이다(이상훈, 2003).

본 연구에서는 영상분류를 위한 계층군집의 비유사 계수( $\lambda$ )로서 각 집단의 공분산 행렬이 동일하다는 가정아래 Mahalanobis 거리에 근거한 계수를 사용하였다:  $\mathbf{x}_k$ 가  $k$ 번째 화소의 관측 값 벡터이고,  $\hat{\Sigma}_A$ 은 추정 동일 공분산 행렬이고,  $G_j$ 와  $n_j$ 는 집단  $j$ 에 속한 화소들의 색인 집합과 총 화소수라면,

$$\begin{aligned} \lambda(r, s) &= M_u - (M_r + M_s) & (14) \\ M_j &= \sum_{k \in G_j} (\mathbf{x}_k - \bar{\mathbf{x}}_j)' \hat{\Sigma}_A^{-1} (\mathbf{x}_k - \bar{\mathbf{x}}_j) \text{ and } \bar{\mathbf{x}}_j = \frac{\sum_{k \in G_j} \mathbf{x}_k}{n_j} \text{ for } j = r, s \\ M_u &= \sum_{k \in G_r} (\mathbf{x}_k - \bar{\mathbf{x}}_u)' \hat{\Sigma}_A^{-1} (\mathbf{x}_k - \bar{\mathbf{x}}_u) + \sum_{k \in G_s} (\mathbf{x}_k - \bar{\mathbf{x}}_u)' \hat{\Sigma}_A^{-1} (\mathbf{x}_k - \bar{\mathbf{x}}_u) \\ \bar{\mathbf{x}}_u &= \frac{\sum_{k \in G_r} \mathbf{x}_k + \sum_{k \in G_s} \mathbf{x}_k}{(n_r + n_s)} \end{aligned}$$

식 (14)에서 추정 공분산 행렬은  $3 \times 3$  크기의 창을 이용하여 전 영상의 관측 값으로부터 추정할 수 있다:  $W_i^{3 \times 3}$ 가  $i$ 번째 화소를 중앙으로 하는  $3 \times 3$  크기의 창에 속하는 화소들의 색인집합이면,

$$\begin{aligned} \hat{\Sigma}_A &= \frac{1}{n} \sum_{i \in I_n} \sum_{k \in W_i^{3 \times 3}} (\mathbf{x}_k - \bar{\mathbf{x}}_i)(\mathbf{x}_k - \bar{\mathbf{x}}_i)' \text{ and} \\ \bar{\mathbf{x}}_i &= \frac{1}{9} \sum_{k \in W_i^{3 \times 3}} \mathbf{x}_k. & (15) \end{aligned}$$

## 4. 실험 결과

### 1) 모의자료 실험

본 연구에서는 제안된 수정 이방성 영상 복원의 평가를 위하여 가산 가우시안 노이즈 영상모형에 의하여 생성된 단일 혹은 다중밴드 모의자료를 사용하였다. 모의자료에서 영상의 질, 즉 noise 수준을 나타내기 위해 SNR(signal-to-noise)을 평균

noise 편차에 대한 최소 클래스간의 강도 차이로서 정의하였다. 모의실험을 위하여 8비트(bit)의  $1024 \times 1024$  크기의 자료를 사용하였으며 평가 목적 상 최소 클래스간의 강도 차이가 10이고 각 밴드의 클래스의 평균강도와 분산 값이 동일하도록 하였다. 이러한 모의자료는 자연적 혹은 인위적 토지 사용을 대표하는 패턴을 이용하여 여러 noise 수준을 가지고 생성되었다. 모의실험에서 algorithm는 영상분류 후 계산된 오류율에 의해 평가되었다. 분류 오류율은 원래 패턴에서 각 화소의 클래스와 분류에 의해 추정된 화소의 클래스를 비교하여 총 화소수와 잘못 분류된 화소 수와 비율로 정의되며 분류 오류율을 구하기 위하여 추정된 클래스를 공통적으로 가장 많은 수의 화소를 포함하고 있는 원래 패턴의 클래스와 일치 시켰다.

첫 번째로 자연 산림과 같이 지상의 자연적 토지 사용형태를 대표하는 패턴 A와 B를 사용하여 SNR = 0.5, 1.0, 1.5, 2.0, 4.0의 5개 noise 수준에서 단일 밴드 자료를, SNR = 0.2, 0.33, 0.5, 1.0, 2.0의 5개 noise 수준에서 3 밴드 자료를 생성하여 모의된 영상자료에 대하여 MAID에 의해 복원한 후 영상분류를 수행하였다. Fig. 1에 보여진 패턴 A는 단일 토지사용 형태를 가진 구획이 공간적으로 넓게 퍼져있는 지상의 scene을 묘사하고 있고 패턴 B는 공간적 연속성이 적은 패턴으로 좀 더 복잡하게 작은 구획들로 구성된 scene을 묘사하고 있다. 본 실험에서는 응집력 계수로서 식 (12)의 brightness gradient 함수를 사용하였고 식 (9)의 화소의 분산 값은 식 (15)에서처럼  $3 \times 3$  크기의 창을 이용하여 추정되었다. 식 (12)의 gradient 함수의 온도 값은 확산과정의 반복단계가 진행됨에 따라 다음과 같이 감소하도록 설정하였다:

$$K_h = K_{h-1}/\zeta_K, h = 1, 2, \dots \quad (16)$$

초기 온도  $K_0$ 와 온도감소 계수  $\zeta_K$ 에 따른 분류 결과의 영향을 알아 보기위하여  $\zeta_K = 1.0$ 과 2.0에 대하여  $K_0$ 의 값을 변화시키면서 모의실험을 수행하였다. SNR = 0.5, 1.0, 1.5의 수준을 가진 패턴 A와 B의 단일밴드 모의영상 자료를 MAID에 적

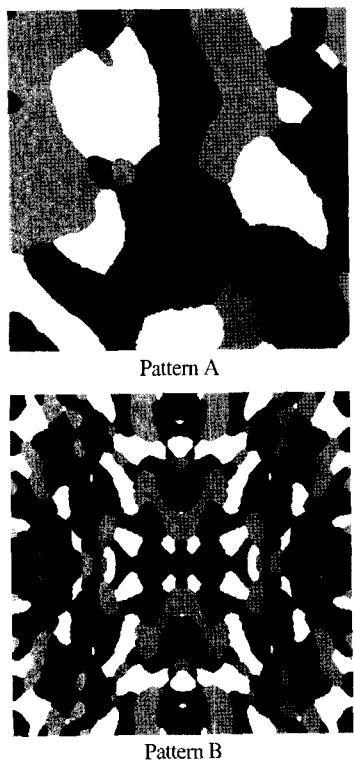


Fig. 1. Image Pattern representing natural land-use.

용한 후 분류한 결과가 Figs. 2와 3에 나타나 있다. 이러한 결과를 살펴보면 확산의 반복과정에서 온도를 낮추어 가는 것이  $\zeta_K = 1.0$ 인 일정한 온도를 사용하는 것보다 더 정확한 분류를 하였고 MAID에 의한 복원 후 분류를 수행하였을 경우 그렇지 않은 경우보다 월등한 분류의 정확성을 보여주었다. 패턴 A의 모의영상 자료의 경우 MAID 적용은 분류 오류율을 SNR = 0.5에서 43.9%에서 2.24%로, SNR = 1.0에서 37.2%에서 0.52%, SNR = 1.5에서 1.42%에서 0.22%로 최대한 감소시켰으며, 패턴 B의 경우는 SNR = 0.5에서 44.2%에서 5.57%, SNR = 1.0에서 13.3%에서 1.54%, SNR = 1.5에서 3.5%에서 0.69%로 최대한 감소시켰다. 정확한 분류를 위해서 noise 수준이 커짐에 따라 MAID는 더 높은 초기 온도 값을 필요로 하며 영상의 질이 안 좋은 경우 MAID의 적용은 영상분류에 더욱 효과적 이었다. Figs. 4와 5는 각각 패턴 A와 B의 SNR = 1.0수준을 가진 단일밴드 모의

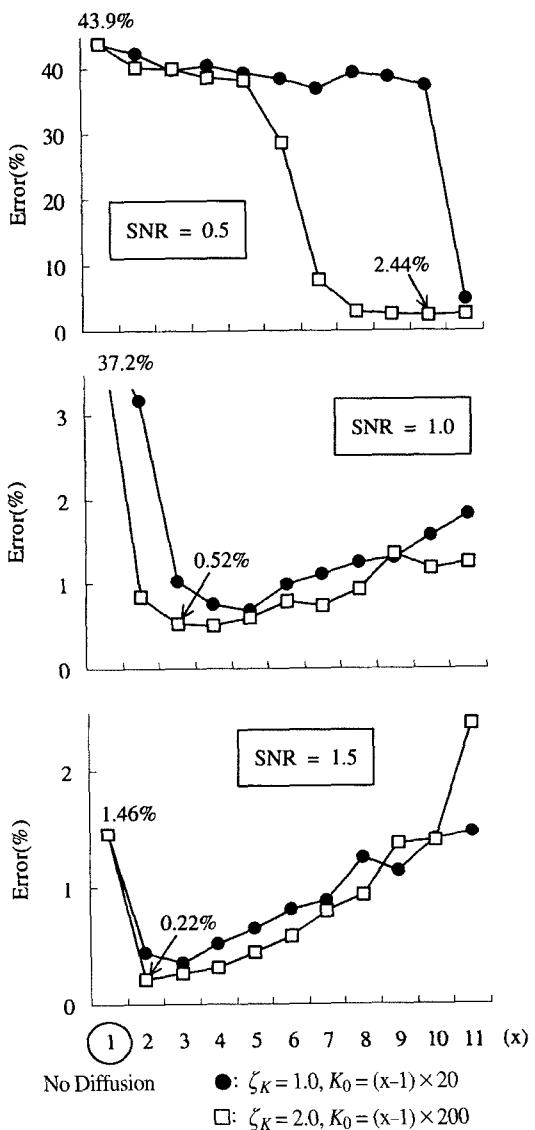


Fig. 2. Classification error in percentage when using various  $K_0$ s in MAID for single band images simulated from Pattern A with different SNRs.

영상, MAID 복원 후 영상, 분류영상을 담고 있다. 이 figure에서 모의영상과 MAID 복원 후 영상은 자세한 noise 정도와 MAID의 효과를 나타내는 소 지역의 확대 영상을 포함하고 있다. 그리고 Table 1에서 보여 지는 것처럼 다중밴드의 영상자료에 대해서 MAID를 적용한 실험 결과는 단일밴드 자료의 결과와 유사했다. 패턴 A의 3 밴드모의영상

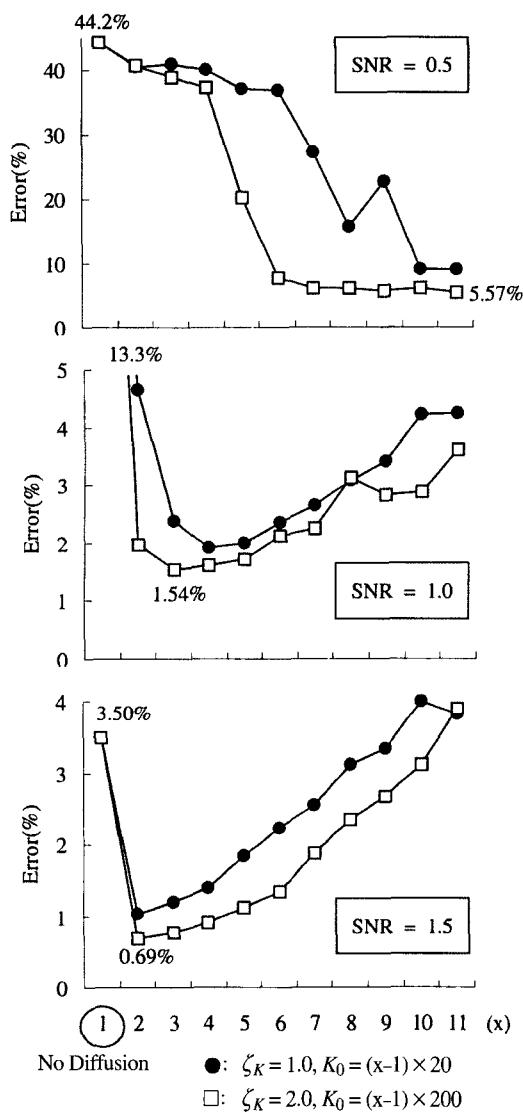


Fig. 2. Classification error in percentage when using various  $K_0$ s in MAID for single band images simulated from Pattern A with different SNRs.

자료의 경우 MAID 적용은 분류 오류율을 SNR = 0.2에서 25.9%에서 3.87%로, SNR = 0.33에서 11.4%에서 1.9%, SNR = 0.5에서 3.64%에서 0.94%로 최대한 감소시켰으며, 패턴 B의 경우는 SNR = 0.2에서 33.6%에서 10.7%로, SNR = 0.33에서 18.3%에서 5.25%, SNR = 0.5에서 7.62%에서 2.91%로 최대한 감소시켰다. Tables 2와 3에서

Table 1. Classification error in percentage when using various  $K_0$ s with  $\zeta_K$  in MAID for 3 band images simulated from Pattern A and B with different SNRs.

SNR	$K_0$	Error(%)	
		Pattern A	Pattern B
0.2	No Diffusion	25.9	33.6
	2000	25.7	31.6
	4000	10.3	19.7
	6000	6.95	15.7
	8000	5.77	14.1
	10000	4.93	12.1
	12000	4.28	11.5
	14000	4.03	<b>10.7</b>
	16000	<b>3.87</b>	11.5
	18000	4.13	12.2
	20000	4.80	11.2
	No Diffusion	11.4	18.3
0.33	500	8.43	12.7
	1000	5.19	9.00
	1500	3.19	6.20
	2000	2.49	6.04
	2500	2.26	<b>5.25</b>
	3000	<b>1.90</b>	5.43
	3500	2.47	5.50
	4000	2.13	6.17
	4500	2.37	6.01
	5000	2.51	6.40
	No Diffusion	3.64	7.62
0.5	200	2.65	5.27
	400	1.58	4.26
	600	1.49	3.55
	800	1.10	3.07
	1000	0.99	3.05
	1200	1.03	<b>2.91</b>
	1400	<b>0.94</b>	3.62
	1600	1.09	3.31
	1800	1.16	3.62
	2000	1.24	3.84

는 패턴 A와 B로부터 생성된 SNR = 2.0의 단일 밴드 영상과 SNR = 1.0의 3 밴드 영상에 대한 MAID의 영향을 보여주고 있다. 이 결과에서 보듯이 양질의 영상의 경우 높은 초기온도를 사용한 MAID 복원은 분류의 정확성을 떨어트린다.

다음으로 본 연구는 모의실험을 Fig. 6에 보여

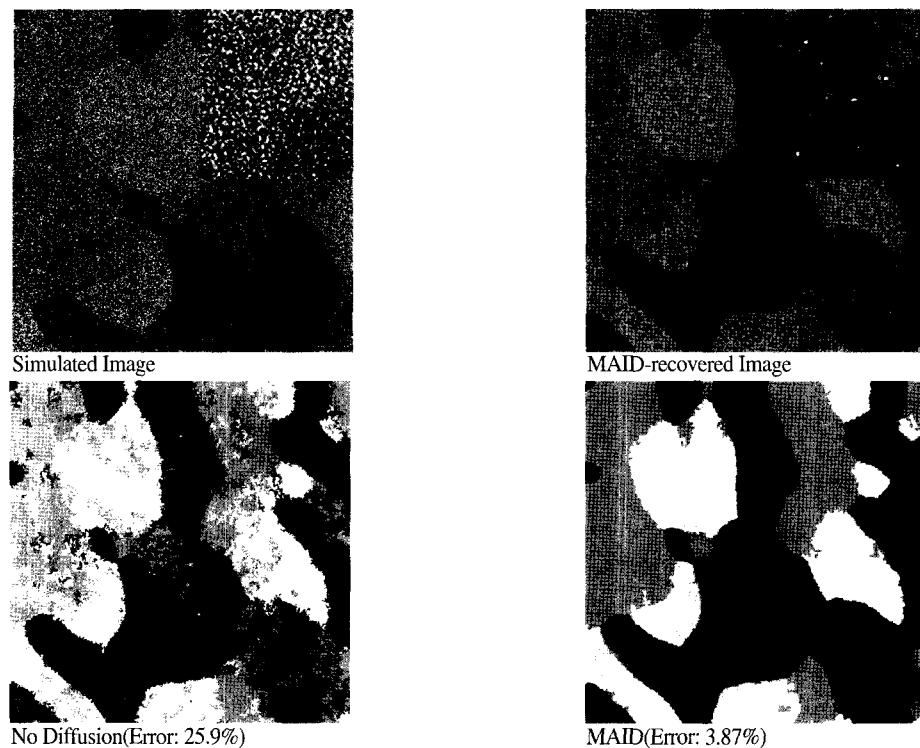


Fig. 4. Classification results of 3 band simulated images of Pattern A with SNR = 0.2 ( $K_0 = 1000$  and  $\zeta_K = 2.0$  for MAID).

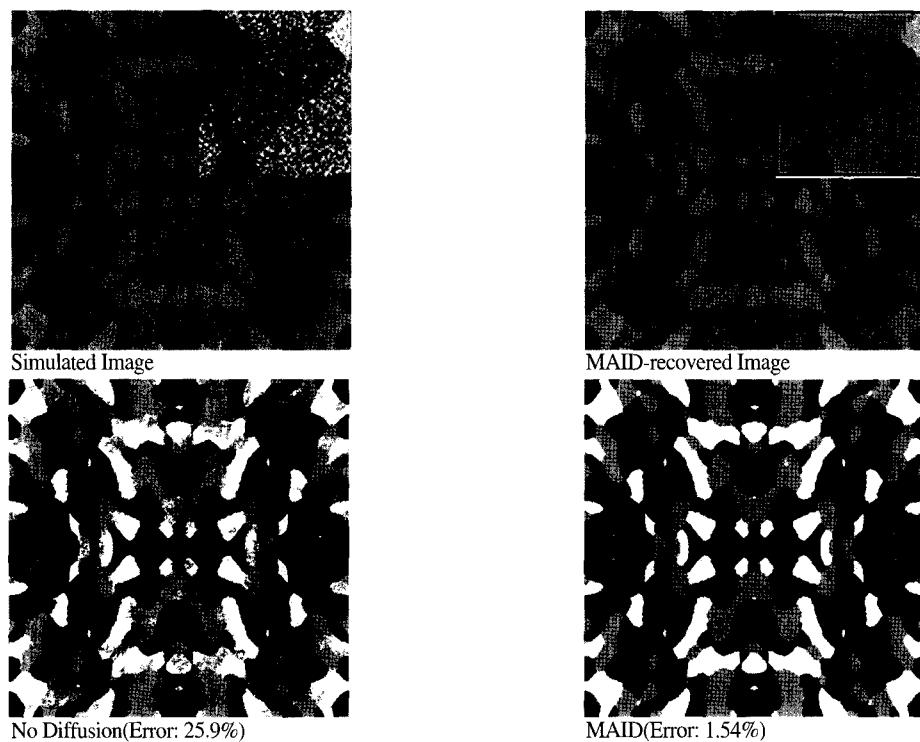


Fig. 5. Classification results of single band simulated images of Pattern B with SNR = 1.0 ( $K_0 = 1000$  and  $\zeta_K = 2.0$  for MAID).

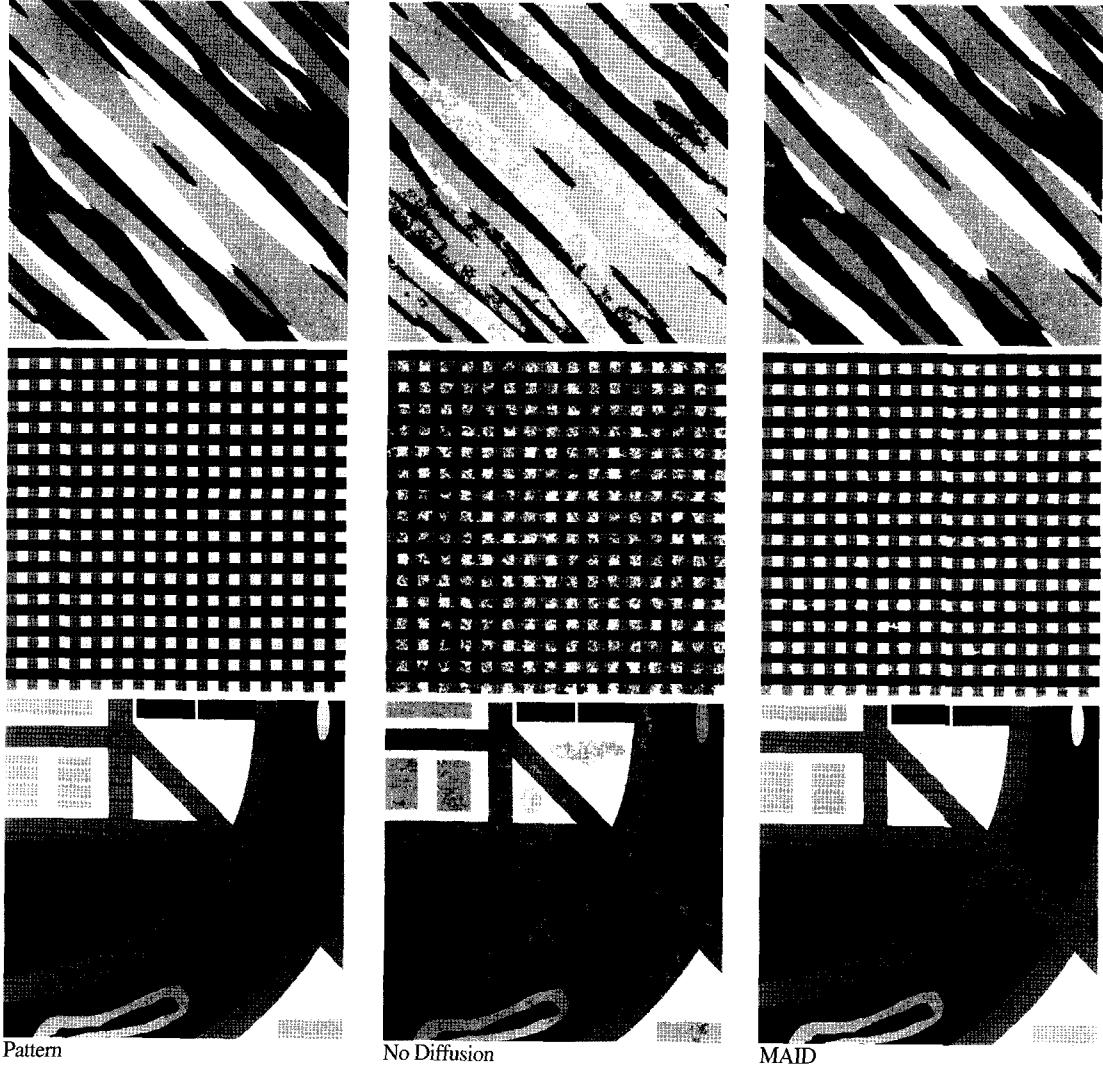


Fig. 6. Classification results of single band images simulated from Pattern C(top), D(middle), and E(bottom) with SNR = 1.0 ( $K_0 = 1000$  and  $\zeta_K = 2.0$  for MAID).

Table 2. Classification error in percentage when using various  $K_0$ s with  $\zeta_K = 2.0$  in MAID for single band images.

Pattern	$K_0$	No Diffusion	100	1000	10000
	SNR				
A	2.0	0.43	<b>0.10</b>	0.36	2.91
B	2.0	1.20	<b>0.39</b>	1.06	8.18
C	0.5	38.3	36.7	<b>5.79</b>	7.35
	1.0	23.2	2.88	<b>1.91</b>	6.02
D	0.5	51.4	47.4	16.7	<b>15.2</b>
	1.0	35.6	8.57	<b>3.86</b>	10.3
E	0.5	23.4	19.7	<b>5.99</b>	6.08
	1.0	13.1	1.42	<b>0.48</b>	4.47

Table 3. Classification error in percentage when using various  $K_0$ s with  $\zeta_K = 2.0$  in MAID for 3 band images.

Pattern	$K_0$	No Diffusion	100	1000	10000
	SNR				
A	1.0	0.44	<b>0.36</b>	0.79	2.67
B	1.0	1.29	<b>1.02</b>	2.71	7.21
C	0.2	33.2	29.8	30.4	<b>8.26</b>
	0.5	5.87	4.41	<b>2.61</b>	7.16
D	0.2	49.0	<b>51.0</b>	44.6	<b>23.1</b>
	0.5	16.7	15.0	<b>5.71</b>	13.6

지는 다른 형태의 패턴에 의해 생성된 자료에 대해서 확장하였다. 패턴 C는 지역적 연속이 방향성을 가진 scene을 나타내며 패턴 D와 E는 각각 경작지와 같이 인위적 토지사용 형태와 도시지역을 대표한다. Tables 2와 3과 Fig. 6는 확장 실험의 결과를 담고 있다. 이러한 결과는 이전의 패턴 A와 B의 모의자료에 대한 실험의 결과와 마찬가지로 적절한 초기온도의 MAID는 분류의 정확성을 크게 향상시키고 있음을 보여주고 있다.

## 2) 원격탐사 자료 실험

본 실험에서는 경기도 용인/능평 지역(지상 좌표: 127:07:30, 37:22:30, 127:15:00, 37:15:00)으로

부터 2000년 9월 4일 관측된 LANDSAT ETM+에 대해서 영상복원 없이 영상분류를 수행한 결과와 MAID를 적용한 후 영상분류를 수행한 결과를 비교하였다. 이 분석에서는 토지피복의 추출을 위하여 가장 효과적이라고 일반적으로 알려진 green, red, NIR의 3개 밴드로 구성된 영상자료에 대해 영상분류를 수행하였다. Fig. 7은 관측된 3 밴드 자료의 회색조 영상 그리고 4개 클래스로 구성된 관측 자료의 분류 영상과 MAID 복원 자료의 분류 영상을 보여주고 있다. MAID 복원은 2500의 초기 온도와 2의 온도감소 계수를 사용하였다. 두 분류 결과를 살펴보면 MAID 복원 자료의 분류 영상이 대체적으로 분석지역의 토지사용 구분을

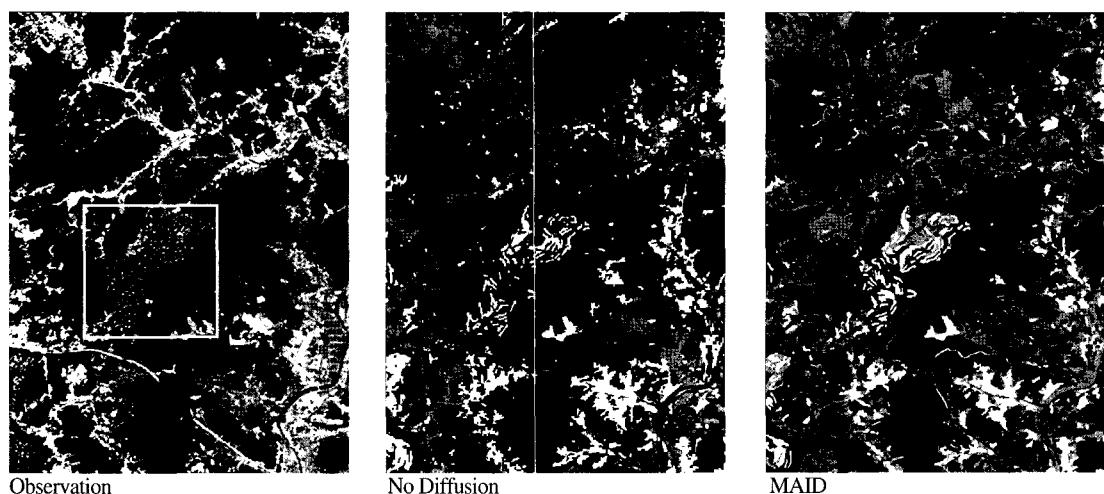


Fig. 7. Classification results of LANDSAT ETM+ (3 band: green, red, NIR) observed from Yongin/Knungpyung area with 4 classes ( $K_0 = 2500$  and  $\zeta_K = 2.0$  for MAID).



Fig. 8. Classification results of the rectangular area in the observation image of Fig. 7.



Fig. 9. Classification results of IKONOS panchromatic image observed from Gangnam area with 4 classes ( $K_0 = 50$  and  $\zeta_K = 2.0$  for MAID).

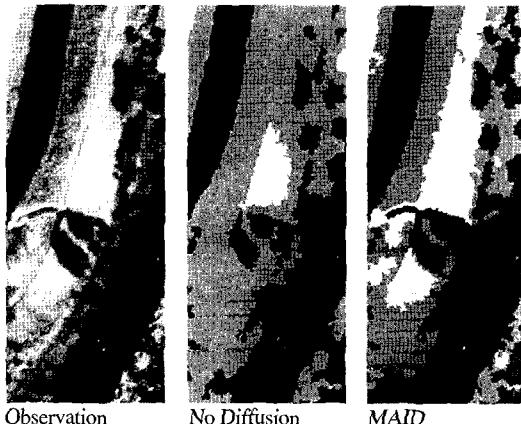


Fig. 10. Classification results of the rectangular area in the observation image of Fig. 9.

더 명확하게 하여주고 작은 크기의 토지사용 구획에 대해서도 더욱 정확한 분류를 하고 있다. Fig. 8은 실험지역의 중앙부분에 위치하고 있는 골프장 지역의 분류 영상이다. 이 소지역의 확대 분류 결과는 MAID 적용이 분류의 정확성을 증가시키는 매우 효과적인 접근법임을 알 수 있다.

서울 강남지역으로부터 관측된 1m의 공간해상도를 가진  $1024 \times 1024$ 크기의 IKONOS 범색 영상에 대하여 실험을 수행하였다. Fig. 9에 정사 보정된 관측 범색영상이 전시되어 있고 또한 분류 결과를 보여주고 있고 Fig. 10은 Fig. 9의 관측영상에 표시된 사각형 지역의 확대된 분류 영상이다. 이러한 결과 역시 앞의 실험의 경우와 마찬가지로 영상분류에서 MAID의 적용에 의한 정확성 향상

을 잘 보여주고 있다.

## 5. 결 론

본 연구에서는 원격탐사의 영상분류 과정에서 수정 이방성 분산 영상 복원을 적용할 것을 제안하고 있다. 본 연구의 수정 이방성 분산 복원은 이웃 지역간의 지리적 연결성을 대표하는 MRF모형에 기반하여 반복적인 확산과정을 통하여 영상을 복원하는 기법이다. 영상복원의 모형에서는 지역적 연결성의 강도를 나타내기 위해 이웃하고 있는 화소간의 응집력 계수를 사용하고 있다. 이방성 분산 복원에서는 응집력 계수는 brightness gradient의 함수를 사용하여 매 반복단계에 adaptive하게 추정한다. 이러한 추정계수는 각 단계에서 이웃하고 있는 화소들의 값 차이의 함수로서 이웃이 위치하고 있는 방향에 따라 서로 다른 값을 가진 이방성 계수이다. 응집력 계수의 gradient 함수는 추정된 영상의 smoothing 정도를 결정짓는 온도상수를 포함하고 있으며 본 연구에서는 확산과정이 진행됨에 따라 감소되도록 설정되었다. 본 연구의 다양한 모의자료 실험에서 보여 지는 것처럼 적절한 초기온도 값을 선택하여 영상복원을 하는 것이 정확한 영상분류를 위해 매우 중요하다. 영상의 noise 수준이 높을수록 높은 초기온도를 사용해야 하며 밴드 수가 증가함에 따

라 역시 초기온도를 높여야 한다. 모의실험에서 적절한 초기온도를 사용한 수정 이방성 분산 복원 후 영상분류를 수행하였을 경우 관측영상에 대한 분류에 비하여 월등한 분류의 정확성을 보여 주었다. 그러나 양질의 영상에 대한 높은 초기온도의 사용은 관측영상이 갖고 있는 정확한 정보를 왜곡 시켜 잘못된 분류결과를 생성한다.

모의자료 실험에서 뿐만 아니라 위성 원격탐사 영상에 대한 수정 이방성 분산 복원은 분류 결과를 향상시키는 데 매우 효과적임 보여주고 있다. 그러나 도시지역의 고해상도자료의 경우 관측 영상으로부터 많은 시각적 정보를 얻을 수 있음에도 불구하고, 제안된 영상복원 후 분류결과도 도시가 포함하고 있는 복잡한 구조를 정확하게 묘사하고 있지 않다. 이러한 이유는 자동차나 가로수와 같이 자세한 도시 구조를 통계적으로 정확하게 분석하기 위해 1m보다 더욱 세밀한 공간 해상도가 필요하고 범색 영상의 단일 파장대 정보만 가지고는 다양한 물리적 특성이 혼합되어 있는 도시의 구조물을 구별하기 부족하다. 또한 건물의 그림자와 같이 도시 특성상 발생할 수 있는 장애요인이 도시지역에 대한 분석의 어려움을 야기 시킨다.

## 사 사

본 연구는 경원대학교 학술연구비 지원사업과

과학기술부 원격탐사기술개발사업의 일환으로 진행되었습니다.

## 참고문헌

- 이상훈, 2003. 다단계 계층군집 영상분류법을 이용한 토지 피복 분석, 대한원격탐사학회지, 19(2): .
- Anderberg, M. R., 1973. *Cluster Analysis for Application*, Academic Press, New York.
- Kindermann, R. and J. L. Snell, 1982. *Markov Random Fields and Their Application*, Amer. Math. Soc., Providence, R. I.
- Georgii, H. O., 1979. *Canonical Gibbs Measure*, Springer-Verlag, Berlin.
- Yamazaki, T. and D. Gingras, 1999. Unsupervised multispectral image classification using MRF models and VQ method, *IEEE Trans. Geosci. Remote Sensing*, 37: 1173-1176.
- Perona, P. and J. Malik, 1990. Scale-space and edge detection using anisotropic diffusion, *IEEE Trans. Pattern Anal. Machine Intell.*, 12: 629-639.
- Varga, R. S., 1962. *Matrix Iterative Analysis*, Prentice-Hall Inc.