

MRF 기반 반복적 경계지역내 분류수정

이 상 훈

경원대학교 산업공학과

MRF-based Iterative Class-Modification in Boundary

Sang-Hoon Lee

Department of Industrial Engineering, Kyungwon University

Abstract : This paper proposes to improve the results of image classification with spatial region growing segmentation by using an MRF-based classifier. The proposed approach is to re-classify the pixels in the boundary area, which have high probability of having classification error. The MRF-based classifier performs iteratively classification using the class parameters estimated from the region growing segmentation scheme. The proposed method has been evaluated using simulated data, and the experiment shows that it improve the classification results. But, conventional MRF-based techniques may yield incorrect results of classification for remotely-sensed images acquired over the ground area where has complicated types of land-use. A multistage MRF-based iterative class-modification in boundary is proposed to alleviate difficulty in classifying intricate land-cover. It has applied to remotely-sensed images collected on the Korean peninsula. The results show that the multistage scheme can produce a spatially smooth class-map with a more distinctive configuration of the classes and also preserve detailed features in the map.

Key Words : MRF, Region Growing, Classification, Class Modification, Remote Sensing.

요약 : 본 연구에서는 수정이방성복원 후 지역확장분할 영상분류의 분류오류를 Markov Random Field(MRF) 기반 분류자를 사용하여 개선시킬 것을 제안하고 있다. 제안 접근법은 지역확장분할 분류에 의해 생성된 결과에서 분류오류의 발생 가능성이 높은 경계지역을 정의하고 경계지역내의 화소들에 대해 재분류를 수행하여 수정하는 것이다. 재분류를 위한 MRF 기반 분류자는 지역확장분할 분류에 의해 추정된 클래스 수와 클래스 특성 값을 기반으로 하여 분류를 수행하는 반복적인 기법이다. 모의자료에 대한 실험은 제안 기법이 분류 정확성을 향상시킴을 보여주었다. 그러나 실제적으로 많은 탐사지역의 피복형태는 매우 복잡한 구조를 갖고 있으므로 일반적 MRF 기반 기법의 사용은 원격탐사 영상의 정확한 분석을 이끌어 내지 못할 수 있으므로 본 연구는 다중 분류자를 사용하는 다단계 경계지역 수정기법을 제안한다. 한반도의 실제 원격탐사 영상자료에 대한 적용결과는 다단계 기법의 효과성을 잘 보여주고 있다. 다단계 반복적 경계지역 내 분류수정은 분석지역에 존재하는 자세한 구조를 보존하는 한편 지역적 명확한 구분의 분류결과를 생성한다.

1. 서론

원격탐사에서 수집된 지표면영상은 한정된 수의 클래스(class)들로 분류되어 진다. 각 클래스는 화소(pixel)들의 집단으로 같은 클래스에 속한 화소들의 지상지역은 동일한 물리적 특성을 가지고 있으며 서로 다른 클래스에 속한 화소들의 지역적 특성은 동일하지 않다. 클래스와 연계된 지역의 물리적 특성은 감지 시스템의 관측 값의 통계적 특성에 의해 대표되어 진다고 가정한다. 원격탐사의 영상분류(image classification)에서 많은 경우 관측지역의 특성에 관한 사전정보가 주어지지 않으므로 지역적 특성과 관련된 통계적 특성 값의 추정을 포함하는 무감독(unsupervised) 분석기법은 중요하다. 효율적인 무감독 분석기법으로 지역확장분할에 기반을 둔 다단계 영상분류법(이상훈, 2001)이 제안되어 졌고 그리고 한반도 토지 피복 분석을 위하여 LANDSAT ETM+과 KOMPSAT-1 영상자료에 다단계 영상분류법이 적용되었다(이상훈, 2003a). 수치영상(digital image)은 하위수준의 두개 이상의 작은 지역(sub-region)들이 상위수준의 하나의 더 큰 지역으로 합해지고 현재의 상위수준의 지역들이 다음 상위수준에서 다시 더 큰 지역으로 합해지는 계층구조(hierarchical structure) (Tanimoto and Klinger, 1990)를 가지고 있다. 이러한 계층구조에 기반하여 지역확장분할 영상분류법은 유사/비유사 계수(similar/dissimilar coefficient)에 의해 두 지역의 합병을 수행하는 계층집단연결(hierarchical clustering)기법(Anderberg, 1973)을 사용하고 있다.

영상처리에서 영상의 공간구조에 의거한 문맥 정보(contextual information)를 사용하는 것은 처리 결과의 정확성을 향상시키는 데 매우 중요하다. 최근의 통계 영상처리학에서는 공간적 연결성과 관련된 문맥정보를 위해 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 의해서 수치영상 분석에 적용되어 진다. 특히 MRF 문맥정보를 사용하는 영상처리기법은 computer vision분야에서 영상의 texture 분석을 위해서 광범위하게 개발되어왔다. 최근에는 원격탐사 다중분광(multispectral) 영상자료의 무감독 영상분류(Yamazaki and Gingras, 1999)를 포함한 다양한 활용분야에서 MRF기법이 이용되고 있으며 지역확장분할 영상분류의 계층군집에서 공간문맥정보를 사용하기 위하여 MRF를 이용하는 기법이 Lee and Crawford(2004)에 의해 개발되었다. 그러나 방대한 크기의 영상자료에 MRF 계층군집기법을 적용하는 것은 계산상의 막대한 비용을 초래하므로 지역확장분할에 직접적으로 공간문맥정보를 사용하는 대신 분할 전 전처리과정(preprocessing)으로 GRF의 하나의 특수한 형태를 사용하는 수정이방성분산에 의해 반복적으로 영상을 복원한 후 분류에 적용하는 접근법이 제안되었다(이상훈, 2003b). 수정이방성분산에 의해 복원된 영상의 분류결과는 복원되지 않은 영상을 사용한 경우보다 영상분류 결과를 괄목할 정도로 향상시켜주었지만 여전히 클래스 간의 경계지역에서 상당한 분류 오류를 발생하고 있음을 모의자료 실험을 통하여 알 수 있다. Fig. 1의 Pattern A를 사용하여 SNR=1.0의 노이즈 수준으로 모의된 단일밴드 영상자료에 수정이방성분산-지역확장분할 영상분류(Modified Anisotropic Diffusion-Region Growing Segmentation based Classification: MAID-RGSC)를 적용하였다. 분류결과로서 Fig. 2의 상단에 나타난 오류도(error map)는 경계지역에서의 분류오류를 잘 보여주고 있다.

본 연구에서는 MAID-RGSC 후 분류오류가 발생할 가능성이 높은 경계지역의 화소들에 대해 재분류를 실시하는 MRF 기반 분류자(classifier)를 사용할 것을 제안 하고 있다. MRF 기반 분류자는 수치영상과정을 관측강도의 연속(continuous) 과정과 클래스와 관련된 이산(discrete)과정을 합성하는 복합과정으로 가정 하고 Gaussian 분포와



Fig. 1. Pattern map of 5 classes and image of single band simulated with SNR = 1.0.




Fig. 2. Results of classification using MAID-RGS and MRF-IBM for observed image of SNR = 1.0 in Fig. 1.

MRF에 기반한 목적함수를 사용한다. 분석지역의 클래스의 수는 무감독 MAID-RGSC에 의해 추정하고 무감독 분석에 의해 구해진 클래스의 특성 값을 초기 값으로 하여 제안 기법은 경계지역의 화소들의 재분류를 반복적으로 수행하고 반복 단

계마다 클래스의 특성 값을 갱신한다. 또한 본 연구에서는 토지피복 형태가 복잡한 지역으로 관측된 실제 관측영상자료를 분석하기 위하여 서로 다른 특성을 가진 여러 분류자들로부터 구해진 결과를 사용하는 다단계 기법을 제안하고 있다.

본 논문은 다음과 같이 구성되어 있다. 2절에서는 MAID-RGS 영상분류에 대한 간략한 review와 함께 MRF 기반 분류자에 대한 설명을 하고 있고, 또한 모의자료를 사용하여 제안된 MRF 기반 분류자의 사용에 대한 평가와 효율성에 대한 검증을 하였고 3절에서는 복잡한 토지피복 형태를 가진 지역으로부터 관측된 영상 자료를 위한 다단계 기법에 대한 설명과 함께 한반도의 원격탐사 자료에 대한 적용결과 보여 주고 있다. 마지막으로 4절은 논문의 결론을 포함하고 있다.

2. MRF 기반 분류자에 의한 경계지역 분류수정

1) MAID-RGS 영상분류

MAID-RGSC는 수정이방성분산에 의해 복원된 영상자료에 대해 지역확장분할 영상분류기법을 적용하는 무감독 접근법이다. 영상복원을 위한 목적함수는 수치영상과정을 각각 관측강도와 원래 강도(복원하고자하는 강도)와 관련된 두개의 연속 random field를 결합한 형태로 가정하고 Bayesian 이론에 근거하여 구성된다. 이 목적함수에서 관측 영상 \mathbf{X} 는 Gaussian 분포로 가정되어지고 원래영상 μ 에 관한 사전 정보를 제공하는 하나의 형식으로 MRF 모형을 사용한다.

Hammersley-Clifford 이론(Kindermann and Snell, 1982)의 결과로서 나타난 MRF와 GRF의 동일화에 의거하여 lattice-like 물리적 시스템에 대한 하나의 에너지함수에 대한 지정은 분자간의 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 모

든 clique의 집합이라면 μ 에 대한 graph $\{I_n, R\}$ 와 연관된 GRF는 다음과 같이 정의 된다:

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

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

z : 표준화 상수(normalizing constant)

V_c : 잠재 함수(potential function)

단지 μ 와 c 에만 그의 값이 의존하는 잠재함수 V_c 와 clique 시스템 C 에 대한 상술(specification)은 원래강도의 모형을 위한 Gibbs measure를 공식화하기 충분하다.

다중분광 밴드 분석에서 공간적 종속성은 분광 밴드별로 독립적으로 작용한다는 가정아래 분광 밴드별로 개별적으로 영상복원을 수행한다. μ 의 확률구조로 pair-potential 함수(Georgii, 1979)의 항목으로만 표현되어지는 에너지함수를 가진 GRF를 사용하고 관측강도 \mathbf{X} 가 Gaussian 분포를 가진다고 가정한다면 의 원래강도 μ 의 사후확률은

$$\ln f(\mu | \mathbf{X}) \propto (\mathbf{X} - \mu)' \Sigma^{-1} (\mathbf{X} - \mu) + \mu' \mathbf{A} \mu. \quad (2)$$

위의 식에서 $\Sigma = \text{diagonal}\{\sigma_i^2, i \in I_n\}$ 은 Gaussian 노이즈의 분산행렬이고 $\mathbf{A} = \{A_{ij}, i, j \in I_n\}$ 이고 A_{ij} 는 i 번째 화소와 j 번째 화소간의 응집력 계수이다. 그러면 사후확률 분포의 mode로부터 μ 의 최대 사후추정치(maximum a posteriori: MAP)는 복원 값으로 다음과 같은 식에 의해 반복적으로 추정된다: i 번째 화소의 관측값과 h 번째 단계에서 복원 값을 x_i 와 y_i^h 라하고 $y_i^0 = x_i$ 이면

$$y_i^h = D_{ii}^{-1} \left[\sigma_i^{-2} - \sum_{j \in R_i} S_{ij} \hat{x}_j^{h-1} \right], \forall i \in I_n. \quad (3)$$

위의 식에서 $D_{ii} = \sigma_i^{-2} + A_{ii}$ 이고 $S_{ij} = A_{ij}$ 이다.

본 연구에서는 응집력 계수를 추정하기 위하여 각 반복단계에서 brightness gradient의 함수로서 갱신되어지는 이방성 확산 기법을 이용하였고(이상훈, 2003b) 식 (2)에서 공분산 행렬은 3×3 크기의 창을 이용하여 추정할 수 있다: \mathbf{x}_k 가 k 번째 화소의 관측 값 벡터이고 $\mathbf{W}_i^{3 \times 3}$ 가 i 번째 화소를 중앙으로 하는 3×3 크기의 창에 속하는 화소들의

색인집합이면,

$$\hat{\Sigma} = \frac{1}{9} \sum_{k \in W_i^{3 \times 3}} (\mathbf{X}_k - \bar{\mathbf{X}}_i)(\mathbf{X}_k - \bar{\mathbf{X}}_i)' \text{ and } \bar{\mathbf{X}}_i = \frac{1}{9} \sum_{k \in W_i^{3 \times 3}} \mathbf{X}_k. \quad (4)$$

수정이방성분산 영상복원 후 영상분류를 위해 사용한 기법은 유사/비유사 계수(similar/dissimilar coefficient)에 의해 두 지역의 합병을 수행하는 계층군집(Anderberg, 1973)에 기반하는 무감독 분석법이다(이상훈, 2001). 영상분류는 크게 두 단계로 이루어진다. 첫 번째 단계는 지역확장분할 단계로 영상의 계층구조에 의해 공간적으로 근접하고 있는 이웃집단간의 결합을 통하여 최종적으로 전체 영상의 공간 내에서 서로 이웃하고 있는 집단들의 물리적 특성이 서로 다르도록 영상을 분할하는 과정이다. 이 단계에서는 상호최근사 지역이웃쌍(mutual closest regional neighbor pair)들 중에서 최선의 결합을 선택하는 계층군집 기법을 이용하고, 영상분할의 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 한정적인 수의 클래스로 분류하는 과정이다.

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

$$\lambda(r, s) = M_u - (M_r + M_s) \quad (5)$$

$$M_u = \sum_{k \in G_r} (\mathbf{y}_k - \bar{\mathbf{y}}_u) \hat{\Sigma}_A^{-1} (\mathbf{y}_k - \bar{\mathbf{y}}_u) + \sum_{k \in G_s} (\mathbf{y}_k - \bar{\mathbf{y}}_u) \hat{\Sigma}_A^{-1} (\mathbf{y}_k - \bar{\mathbf{y}}_u)$$

$$M_j = \sum_{k \in G_j} (\mathbf{y}_k - \bar{\mathbf{y}}_j) \hat{\Sigma}_A^{-1} (\mathbf{y}_k - \bar{\mathbf{y}}_j) \text{ and } \bar{\mathbf{y}}_j = \frac{\sum_{k \in G_j} \mathbf{y}_k}{n_j} \text{ for } j = r, s$$

$$\bar{\mathbf{y}}_u = \frac{\sum_{k \in G_r} \mathbf{y}_k + \sum_{k \in G_s} \mathbf{y}_k}{(n_r + n_s)}$$

추정 공분산 행렬은 식(4)에서 처럼 3×3 크기의 창을 이용하여 전 영상의 관측 값으로부터 추정할 수 있다:

$$\hat{\Sigma}_A = \frac{1}{n} \sum_{i \in I_n} \sum_{k \in W_i^{3 \times 3}} (\mathbf{y}_k - \bar{\mathbf{y}}_i)(\mathbf{y}_k - \bar{\mathbf{y}}_i)' \text{ and } \bar{\mathbf{y}}_i = \frac{1}{9} \sum_{k \in W_i^{3 \times 3}} \mathbf{y}_k. \quad (6)$$

2) MRF 기반 반복경계수정

MRF 기반 반복경계수정(MRF-based Iterative Boundary Modification: MRF-IBM)에 사용되어지는 MRF 기반 분류자는 수정이방성분산 영상복원에서 처럼 수치영상과정을 위해서 복합과정을 가정한다. 그러나 영상복원의 수치영상과정과 달리 관측강도의 연속 random field와 클래스 과정의 이산 random field의 결합과정으로 가정하고 서로 인접하고 있는 지역은 같은 클래스를 가질 확률이 높다는 공간적 연속성을 계량화하기 위해 MRF를 사용한다. 그러므로 분석영상의 클래스 수가 m 이고 $\Omega_m = \{1, 2, \dots, m\}$ 가 클래스 색인 집합이고 영상의 클래스벡터를 $\omega = \{\omega_i, i \in I_n\}$ 라 한다면 식(1)에서 μ 대신에 ω 를 대치함에 의해 ω 에 대한 graph $\{I_n, R\}$ 와 연관된 GRF가 정의된다. 관측강도 X 가 Gaussian 분포를 가진다는 가정아래 노이즈 분산 행렬 $\Sigma = \text{diagonal}\{\sigma_i^2, i \in I_n\}$ 이 주어지고 ω 의 확률구조로 pair-potential 함수의 항목으로만 표현되어지는 에너지함수를 가진 GRF를 사용한다면 ω 의 사후확률은

$$f(\omega | \mathbf{X}) \propto -[\mathbf{X} - \mu(\omega)]' \Sigma^{-1} [\mathbf{X} - \mu(\omega)] + \sum_{(r, s) \in C} V_{rs}(\omega) - \ln \left\{ \sum_{\theta \in \Omega} \exp \left[\sum_{(r, s) \in C} V_{rs}(\theta) \right] \right\}. \quad (7)$$

위의 식에서 $\mu(\omega)$ 는 클래스 평균값 벡터이고 Ω 는 모든 가능한 클래스 구성의 집합이고

$$V_{rs}(\omega) = \begin{cases} \beta, & \text{if } \omega_r = \omega_s \\ -\beta, & \text{otherwise.} \end{cases} \quad (8)$$

만약 i 번째 화소를 제외한 모든 화소의 클래스가

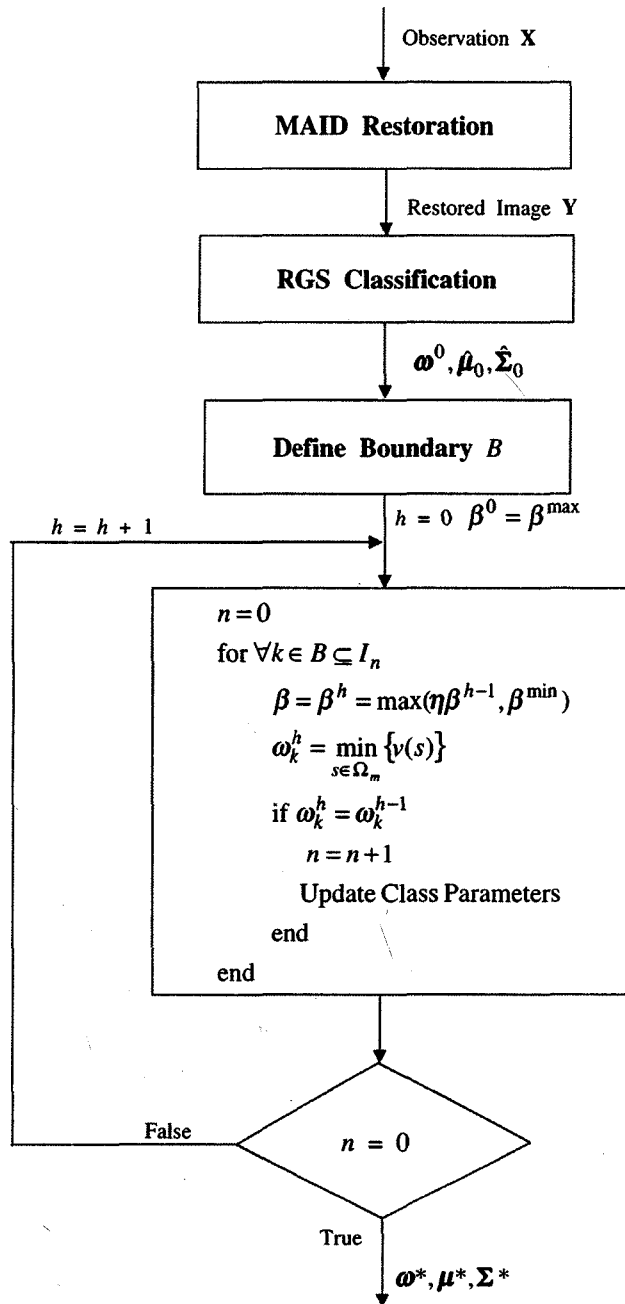


Fig. 3. MRF-IBM.

주어진다면

$$f(\omega_i | \mathbf{X}, \omega \setminus \omega_i) \propto -[X_i - \mu(\omega_i)]^T \Sigma_i^{-1} [X_i - \mu(\omega_i)] + \sum_{(i,j) \in C} V_{ij}(\omega). \quad (9)$$

주어진 차수 b 에 대해서 경계지역 B 는 화소 k 중심의 window $W_k^{b \times b}$ 내의 모든 화소의 클래스가 동일하지 않은 화소 k 들의 집합이다. MRF-IBM은 경계지역외의 화소들의 클래스는 알려졌다는 가

정아래 경계지역에서 식(9)의 조건부 사후확률을 최대화 하는 화소의 클래스를 반복적으로 계산함에 의해 ω 의 MAP을 구하는 것이다. 만약

$$V_{rs}^{0l}(\omega) = \begin{cases} 0, & \text{if } \omega_r = \omega_s \\ 1, & \text{otherwise} \end{cases} \quad (11)$$

이라면 식(9)의 최대화는

$$v(\omega_i) = [\mathbf{x}_i - \boldsymbol{\mu}(\omega_i)]^T \boldsymbol{\Sigma}_i^{-1} [\mathbf{x}_i - \boldsymbol{\mu}(\omega_i)] + b \sum_{(i,j) \in C} \pi_c V_{rs}^{0l}(\omega) \quad (12)$$

의 최소화에 일치한다. 식 (12)에서 β 는 화소간 공동 응집력 계수이고 π_c 는 clique 형태(두 화소간의 거리와 방향)에 따른 근접(proximity) 계수이고 $\sum_{c \in C} \pi_c = 1$. 그리고 β 는 반복단계가 증가함에 따라 global optimum에서 local optimum을 발견하기 위해 지속적으로 감소하도록 h 단계에서 다음과 같이 정의되어 질 수 있다: 응집력 계수의 최대 값(β^{\max})과 최소 값(β^{\min})이 주어진다면

$$\beta^h = \max(\eta \beta^{h-1}, \beta^{\min}), h = 1, 2, \dots \quad (13)$$

위의 식에서 $\beta^0 = \beta^{\max}$ 이고 $0 < \eta \leq 1$. 반복과정은 모든 화소에서 클래스의 변화가 일어나지 않을 때 끝날 것이다. Fig. 3은 MRF-IBM의 알고리즘과 제안된 영상분류 전체 과정을 요약하고 있다.

3) 모의자료 실험

MAID-RGS 영상분류 결과에 대한 MRF-IBM의 효율성이 다양한 패턴으로부터 생성된 모의자료를 사용하여 평가되었다. Fig. 2에서는 Fig. 1에 전시된 영상자료에 대한 MAID-RGS 분류 결과와 $\beta^{\max} = 100, \beta^{\min} = 5, \eta = 0.8$ 을 사용한 MRF-IBM의 결과가 비교되었다. Fig. 2의 오류도에서 보여주듯이 MAID-RGS 영상분류의 클래스 간의 경계지역의 오류는 현저히 감소하였음을 알 수 있다. Figs. 4, 5, 6은 다른 형태의 패턴으로부터 생성된 모의자료들에 대한 실험결과를 보여주고 있다. 그리고 Tables 1과 2에서는 서로 다른 노이즈 수준에서 생성된 단일 밴드 자료와 3 밴드 자료들에 대해 서로 다른 응집력 계수를 사용한 MRF-IBM의 결과를 MAID-RGS 영상분류 결과를 비교하였다. Table들에 나타난 결과를 보면 패턴의 형태가 단순할수록

MRF-IBM의 효과가 증대되며 밴드 수가 증가할수록 더 큰 응집력 계수를 사용하는 것이 효과적이고 너무 큰 값의 응집력 계수의 사용은 오히려 분류결과를 악화시킬 수 있다는 것을 암시하고 있다. 또한 너무 작은 값의 응집력 계수는 공간문맥정보보다 주어진 관측 값에 의존한 분류결과를 생성하므로 비효과적일 가능성이 많다.

3. 다단계 MRF-IBM

실제 원격탐사 지역의 토지피복형태는 앞 절에서 모의자료 실험에 사용한 패턴보다 더욱 복잡한 형태를 가진다. MRF 기반의 분류자는 관측 값에 의한 정보보다 주위의 문맥정보를 중시하여 자주 과도한 공간적 smoothing을 수행하려는 경향이 있으므로 분석영상 내에 존재하는 도로와 같은 자세한 구조를 구분하는 데 실패할 가능성이 있다. 이러한 문제점을 해결하기 위해 본 연구에서는 다중 분류자(multiple classifiers)의 결과들을 합성하여 사용하는 다단계 MRF-IBM(MMRF-IBM)을 제안하고 있다. 제안된 MMRF-IBM에서는 다중 분류자로서 MAID-RGS 분류결과, MAID-RGS 분류결과에 기반한 최대우도 분류자(Maximum Likelihood Classifier: MLC), 그리고 최대 응집력 계수의 MRF-IBM을 사용하고 있다. MLC는 자세한 구조를 구분할 수 있지만 분류에서 관측 값의 정보만 사용하므로 노이즈에 민감한 분류결과를 생성하고 최대 응집력 계수의 MRF-IBM은 일정한 크기의 지역에 대한 명확한 구분을 가진 분류도를 생성하지만 자세한 구조를 구분하기가 어렵다. MMRF-IBM는 MAID-RGS 분류의 원래 결과와 함께 두 극단의 분류 결과에 기반하여 경우에 따라 서로 다른 응집력 계수를 사용하는 MRF-IBM을 수행하는 기법이다. MMRF-IBM에서는 경계지역을 분류 결과에 불확실성이 존재하는 화소들의 집합으로 정의한다. 즉 세 가지 분류 결과가 모두 동일하지 않은 화소들의 집합으로 정의한다. MLC와 MAID-RGS 분류의 결과가 일치하다면




Fig. 4. Results of classification using MAID-RGS and MRF-IBM for simulated image of SNR = 1.0 using Pattern B of 5 classes (lower: enlarged image of sub-area).

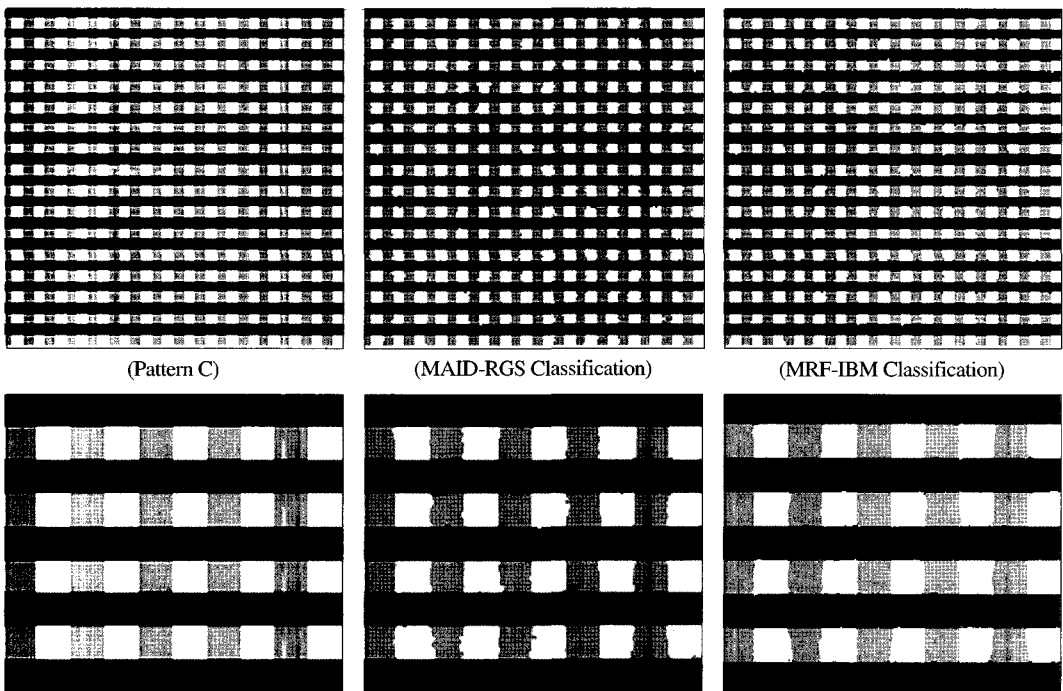


Fig. 5. Results of classification using MAID-RGS and MRF-IBM for simulated image of SNR = 1.0 using Pattern C of 4 classes (lower: enlarged image of sub-area).




Fig. 6. Results of classification using MAID-RGS and MRF-IBM for simulated image of SNR = 0.5 using Pattern D of 7 classes (lower: enlarged image of sub-area).

화소의 관측 값이 주위의 문맥정보보다 더욱 신뢰할 수 있고 MAID-RGS 분류와 최대 응집력 계수의 MRF-IBM의 결과가 일치하다면 주위의 문맥 정보가 관측 값의 정보보다 더 신뢰할 수 있다고 가정할 수 있다. 그러므로 전자의 경우는 적은 응집력 계수(β_1)를 사용하고 후자의 경우는 큰 응집력 계수(β_2)를 사용하고 그 외의 경우는 앞의 경우들의 계수 값 사이의 적절한 크기의 응집력 계수(β_0)를 사용한다. 편의상 응집력 계수의 초기값은 γ_{max} 가 주어진다면 $\beta_i^0 = \gamma_{max} \beta_i^{min}, i = 0, 1, 2$ ($\beta_1 < \beta_0 < \beta_2$)으로 정의된다. Fig. 7은 MMRF-IBM의 과정을 보여주고 있다.

MMRF-IBM은 서울 강남지역으로부터 관측된 1m의 공간해상도를 가진 1024×1024 크기의 IKONOS 범색 영상에 적용되었다. Fig. 8은 정사 보정된 관측 범색영상과 분류 결과를 보여주고 있고 Fig. 9는 Fig. 8의 관측영상에 표시된 사각형 지역의 확대된 영상이다. 확대영상을 살펴보면

MMRF-IBM는 MLC의 자세한 구조와 MAID-RGSC의 지역간의 구분의 명확성을 가진 분류도를 생성함을 알 수 있다. 다음으로 경기도 용인/능평 지역(지상 좌표: 127:07:30, 37:22:30, 127:15:00, 37:15:00)으로부터 2000년 9월 4일 관측된 LANDSAT ETM+에 대해서 적용한 후 영상 분류를 수행한 결과를 비교하였다. 이 분석에서는 토지피복의 추출을 위하여 가장 효과적이라고 일반적으로 알려진 Green, Red, NIR의 3개 밴드로 구성된 영상자료에 대해 영상분류를 수행하였다. Fig. 10은 관측된 3 밴드 자료의 회색조 영상 그리고 3개 클래스로 구성된 분류도를 보여주고 있다. 그리고 Fig. 11은 Fig. 10에 표시된 소지역의 확대한 영상이다. 이 소지역의 확대 분류 결과는 MAID-RGSC이 구분하기 실패한 도로를 MMRF-IBM은 밝혀내고 있다는 것을 보여주고 있다.

Table 1. Errors in Percent in Classifications of MAID-RGS and MRF-IBM for Simulated Images of Single Band Using 4 Patterns ($\beta^{\max} = 100, \beta^{\min} = 5, \eta = 0.8$ for IBM-A and $\beta^{\max} = 1000, \beta^{\min} = 50, \eta = 0.8$ for IBM-B)(IBM/RGS: Error Reduction Rate in Percentage by MRF-IBM).

Pattern	SNR	RGS	IBM-A	IBM/RGS	IBM-B	IBM/RGS
A	0.5	2.44%	1.00%	41%	1.89%	77%
	1.0	2.20%	0.62%	28%	0.46%	21%
B	0.5	5.89%	3.13%	53%	6.00%	102%
	1.0	5.52%	2.19%	40%	1.55%	28%
C	1.0	2.25%	1.50%	67%	3.66%	163%
	1.5	0.59%	0.34%	58%	1.14%	193%
D	0.5	2.51%	0.89%	35%	1.14%	45%
	1.0	2.36%	0.48%	20%	0.34%	14%

Table 2. Errors in Percent in Classifications of MAID-RGS and MRF-IBM for Simulated Images of 3 Bands Using 3 Patterns ($\beta^{\max} = 100, \beta^{\min} = 5, \eta = 0.8$ for IBM-A and $\beta^{\max} = 1000, \beta^{\min} = 50, \eta = 0.8$ for IBM-B)(IBM/RGS: Error Reduction Rate in Percentage by MRF-IBM).

Pattern	SNR	RGS	IBM-A	IBM/RGS	IBM-B	IBM/RGS
A	0.2	3.41%	1.95%	57%	2.04%	60%
	0.3	2.89%	1.04%	36%	1.03%	36%
B	0.2	11.09%	7.76%	70%	7.70%	69%
	0.3	8.78%	3.76%	43%	3.57%	41%
C	0.3	11.58%	8.53%	74%	8.15%	70%
	0.5	6.76%	3.68%	54%	3.52%	52%

4. 결 론

효율적인 무감독 분석기법으로 제안된 지역확장분할에 의한 영상분류는 일반적인 화소별 분류기법보다 분류의 정확성을 가지고 있으며 대부분의 분류오류는 내부지역이 아니라 서로 다른 클래스를 가진 지역간의 경계부분에서 발생한다. 특히 GRF 기반 수정 이방성 분산법에 의한 복원된 영상에 지역확장분할의 적용은 분류의 정확성을 괄목하게 개선시키고 내부지역에 비해서 경계부분에서 분류오류의 발생이 상대적으로 현저하다. 본 연구에서는 수정이방성복원 후 지역확장분할 영상분류의 분류오류를 MRF 기반 분류자를 사용하여 개선시킬 것을 제안하고 있다. 제안 접근법은 지역확장분할 분류에 의해 생성된 결과에서 분류오류의 발생 가능성이 높은 경계지역을 정의하고

경계지역내의 화소들에 대해 재분류를 수행하여 수정하는 것이다. 재분류를 위한 MRF 기반 분류자는 지역확장분할 분류에 의해 추정된 클래스 수와 클래스 특성 값을 기반으로 하여 분류를 수행하는 반복적인 기법이다. 경계지역내 반복적 분류수정의 적용에 대한 효과는 모의자료 실험을 통하여 검증되었으며 특히 공간적 연속성이 큰 영상자료에 대한 개선은 괄목만 한 것이었다. 그러나 지역확장분할 분류는 화소 별 분류기법보다 지역간의 명확한 구분을 가진 분류도를 생성하지만 분석영상 내에 존재하는 자세한 구조를 발견하는 데 실패할 가능성이 있다. 또한 MRF 기반 기법 역시 공간맥정보에 의존하므로 작은 크기의 세밀한 지역적 특성을 무시할 가능성이 크다. 그러므로 실제로 많은 탐사지역의 피복형태는 매우 복잡한 구조를 갖고 있으므로 일반적 MRF 기반 기

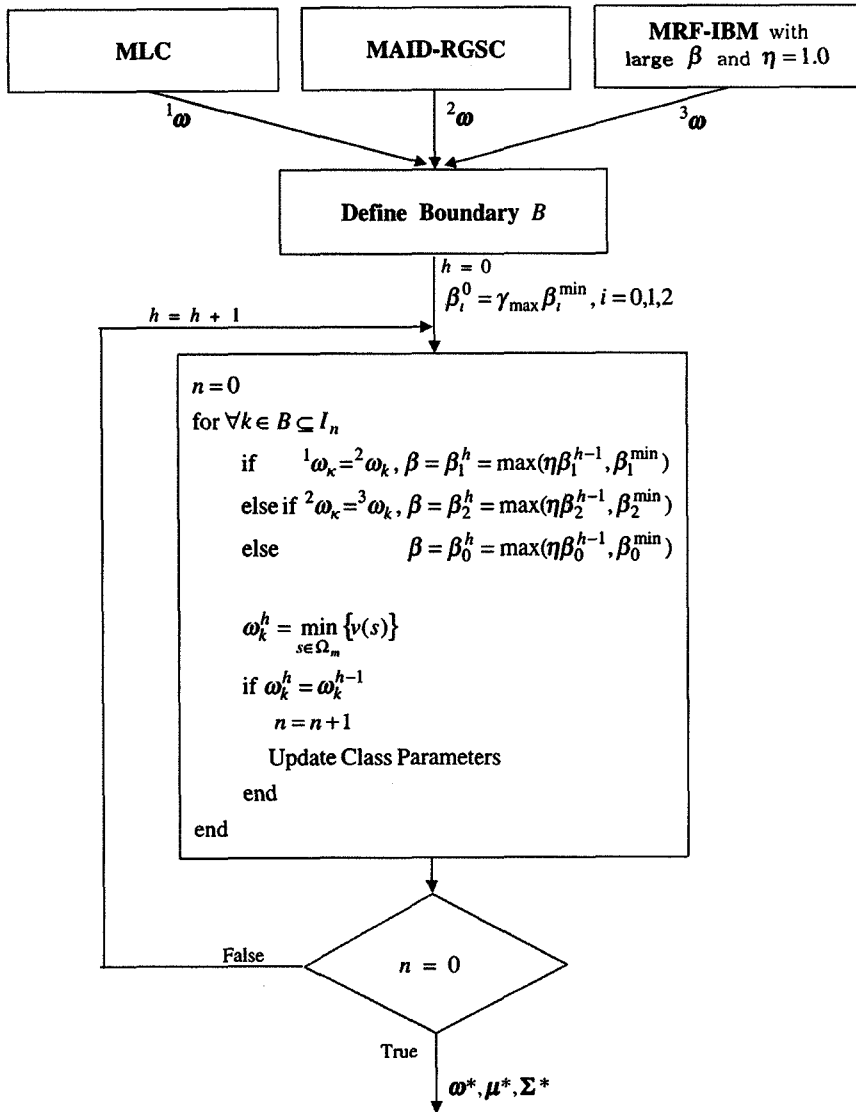


Fig. 7. MMRF-IBM

법의 사용은 원격탐사 영상의 정확한 분석을 이끌어 내지 못할 수 있으므로 본 연구는 다중 분류자를 사용하는 다단계 경계지역 수정기법을 제안하고 있다. 다단계 기법은 지역확장분할 분류에 의한 분류 결과, 최대우도 분류자에 의한 분류결과 그리고 MRF 기반 분류자에 의한 smoothing한 분류 결과에 근거하여 재분류를 수행하는 방법이다. 한반도의 실제 원격탐사 영상자료에 대한 다단계 기법의 적용결과는 분류수정의 효과성을 잘 보여

주고 있다. 다단계 반복적 경계지역 내 분류수정은 분석지역에 존재하는 자세한 구조를 보존하는 한편 지역적 명확한 구분의 분류결과를 생성한다.

사 사

본 연구는 경원대학교 학술연구비 지원사업의 일환으로 진행되었습니다.




Fig. 8. Results of classification using MAID-RGSC, MLC and MMRF-IBM for IKONOS panchromatic image observed from Gangnam area in Seoul, Korea.




Fig. 9. Results of classification for enlarged sub-area image of Fig. 8 (from left, Observation, MAID-RGSC, MLC, MMRF-IBM).




Fig. 10. Results of classification using MAID-RGS, MLC and MMRF-IBM for 3 band image (Green, Red, and NIR) of LANDSAT ETM+ observed from Yongin-Nungpyung area in Kyunggi-do, Korea on September of 2000.

참고문헌

- 이상훈, 2001. 공간지역확장과 계층집단연결기법을 이용한 무감독 영상분류, 대한원격탐사학회지, 17(1): 57-70.
- 이상훈, 2003a. 다단계 계층군집 영상분류법을 이용한 토지 피복 분석, 대한원격탐사학회지, 19(2): 135-148.
- 이상훈, 2003b. 수정 이방성 분산 복원을 이용한 영상 분류, 대한원격탐사학회지, 19(6): 479-490 .
- Anderberg, M. R., 1973. *Cluster Analysis for Application*, Academic Press, New York.
- Kindermann, R. and J. L. Snell, 1982. *Markov Random*




Fig. 11. Results of classification for enlarged sub-area image of Fig. 10.

Georgii, H. O., 1979. *Canonical Gibbs Measure*, Springer-Verlag, Berlin.

Lee, S. and M. M. Crawford, 2004. Unsupervised Multistage Image Classification Using Hierarchical Clustering with a Bayesian Similarity Measure, *IEEE Trans. Image*

Processing, accepted.

Yamazaki, T. and D. Gingras, 1999. Unsupervised multispectral image classification using MRF models and VQ method, *IEEE Trans. Geosci. Remote Sensing*, 37: 1173-1176.