

공간지역확장과 계층집단연결 기법을 이용한 무감독 영상분류

이 상 훈

경원대학교 산업공학과

Unsupervised Image Classification Using Spatial Region Growing Segmentation and Hierarchical Clustering

Sang-Hoon Lee

Dept. of Industrial Engineering, Kyungwon University

Abstract : This study proposes a image processing system of unsupervised analysis. This system integrates low-level segmentation and high-level classification. The segmentation and classification are conducted respectively with and without spatial constraints on merging by a hierarchical clustering procedure. The clustering utilizes the local mutually closest neighbors and multi-window operation of a pyramid-like structure. The proposed system has been evaluated using simulated images and applied for the LANDSAT ETM+ image collected from Youngin-Nungpyung area on the Korean Peninsula.

Key Words : image segmentation, image classification, unsupervised analysis, hierarchical clustering, multi-window operation

요약 : 본 연구는 무감독 영상분류를 위하여 공간지역 확장을 통하여 영상을 분할한 후 분할된 집단을 한정된 수의 클래스로 분류하는 다중단계 기법을 제안하고 있다. 제안된 알고리듬은 무감독 분석을 위하여 작은 집단들을 단계적으로 큰 집단들로 합병해 가는 계층집단연결 기법에 기반을 두고 있다. 다중단계 기법의 영상분할 단계는 공간적으로 근접하고 있는 이웃지역간의 결합을 통하여 최종적으로 전체영상 공간내의 모든 집단에 대해서 서로 이웃하고 있는 집단들의 물리적 특성이 서로 다르도록 영상을 분할하는 과정이고, 영상분류 단계는 결합 지역의 공간적 제약 없이 영상 분할 단계에서 분할된 지역을 상대적으로 적은 수의 클래스로 분류하는 과정이다. 제안 된 알고리듬에서 사용하고 있는 계층집단연결 기법의 계산/기억 상의 복잡성을 완화시키기 위해 상호최근사 이웃쌍과 다중창 작업을 사용하고 있다. 모의 자료를 사용하여 제안 된 알고리듬 대한 평가와 효율성을 검증하였고 경기도 용인·능평지역의 LANDSAT ETM+ 자료에 적용한 결과를 예시하고 있다.

1. 서 론

원격탐사에서 수집된 지표면영상은 한정된 수

의 클래스(class)들로 분류되어 진다. 각 클래스는 화소(pixel)들의 집단으로 영상분석에서는 같은 클래스내의 화소들에 해당하는 지상지역은 동일한

물리적 특성을 가지고 있으며 서로 다른 클래스에 속한 지역들의 특성은 동일하지 않고, 클래스와 연계된 지역의 물리적 특성은 감지 시스템의 관측 값의 통계적 특성에 의해 대표되어 진다고 가정한다. 영상분류(image classification)를 위하여서는 최대우도 분류법(maximum likelihood classification)과 같이 관측지역의 클래스 수와 각 클래스의 관측 값의 통계적 특성에 대한 사전 지식이 필요한 감독기법을 일반적으로 사용한다. 클래스의 수가 알려져 있을 경우 클래스의 통계적 특성에 대한 사전정보는 훈련본(training sample)을 사용하여 얻는다. 그러나, 훈련과정을 통하여 클래스의 통계적 특성 값을 추정하기 위하여서는 대단히 많은 경비가 필요할 뿐 아니라 지상의 많은 지역은 정치적 혹은 지형적 이유 때문에 접근이 불가능하므로 많은 경우 정확한 훈련지역을 설정하는 것은 매우 어렵거나 불가능하다. 감독기법에 의한 영상분류에서는 분석지역내의 클래스의 수의 선택에 따라 분석결과에 상당한 차이가 있지만, 시간에 따라 지표면 현상이 변하므로 정확한 클래스의 수의 결정 또한 매우 어렵다. 그러므로, 원격탐사자

료의 영상분류를 위해서는 관측지역의 특성에 관한 사전정보 없이 지역적 특성과 관련된 통계적 특성 값의 추정을 포함하는 무감독(unsupervised) 분석기법은 매우 중요하다.

영상분할/분류(image segmentation/classification)에 있어 고려되어야 할 가장 중요한 제약중의 하나는 수치영상(digital image)이 계층구조(hierarchical structure)를 갖고 있다는 것이다 (Tanimoto and Klinger, 1990). 즉, 계층구조에서는 하위수준의 하나 이상의 작은 지역(sub-region)들은 상위수준의 하나의 더 큰 지역으로 합해지고 현재의 상위수준의 지역들은 다음 상위수준에서 다시 더 큰 지역으로 합해진다. 이러한 계층구조에 기반을 두고 유사/비유사 계수(similar/dissimilar coefficient)에 의해 두 지역의 합병을 수행하는 계층집단연결(hierarchical clustering) 기법은 무감독 분석을 위한 가장 적합한 방법이다 (Anderberg, 1973). 그러나, 원격탐사의 영상자료와 같이 방대한 요소를 포함하는 분석에서는 단계별로 두 개의 소집단을 하나의 집단으로 결합해 가는 일반적 계층집단연결 기법은 계산/기억 상의 막대한 비용을

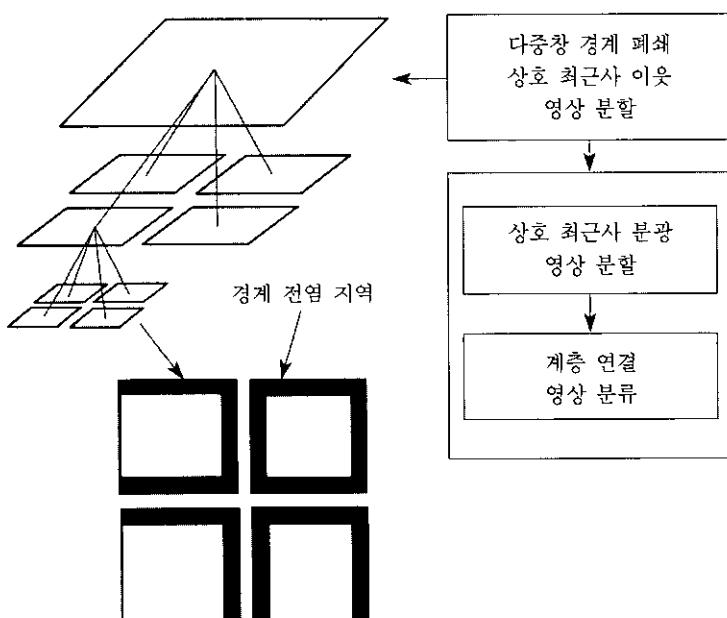


Fig. 1. Multi-stage image classification

초래하므로 실질적으로 적절하지 못하다. 본 연구는 원격탐사 영상자료의 무감독 영상분류를 위하여 공간지역화장 영상분할을 통한 다중단계 계층집단연결 분류법(MHCC: Multi-stage Hierarchical Clustering Classification)을 제안하고 있다.

다중단계 계층집단연결 분류법은 Fig. 1에서 보여지는 것처럼 크게 두 단계로 이루어진다. 첫 번째 단계는 지역화장 영상분할 단계로 영상의 계층구조에 의해 공간적으로 근접하고 있는 이웃집단간의 결합을 통하여 최종적으로 전체영상의 공간내에서 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 계층집단연결 기법을 이용하고, 영상분할의 계산/기억 상의 효율성 증가를 위하여 피라미드(pyramid) 계층구조의 다중창작업(multi-window operation)을 사용한다. 두 번째 단계는 결합지역의 공간적 제약 없이 영상분할 단계에서 분할된 집단들을 상대적으로 적은 한정적인 수의 클래스(class)로 분류하는 과정으로 상호최근사 분광이웃쌍(MCSNP: Mutual Closest Spectral Neighbor Pair)들 중에서 집단간의 결합을 수행하는 영상분할과 모든 집단간의 결합을 고려하는 영상분류의 두 개의 세부단계로 이루어진다.

본 논문은 다음과 같이 구성되어 있다. 2절과 3절에서 다중단계 계층집단연결 분류법의 세부적 요소들에 대한 자세한 설명을 하고 있고, 4절에서 모의자료를 사용하여 제안된 알고리듬 대한 평가와 효율성에 대한 검증을 하였고, 또한 용인·능평 지역에서 관측된 LANDSAT ETM+ 자료에 다중단계 계층연결 분류법을 적용한 결과를 보여주고 있다. 마지막으로 5절은 논문의 결론을 포함하고 있다.

2. 계층집단연결

계층집단연결 분석은 유사성이 많은(혹은 비유

사성이 적은) 작은 집단들을 순차적으로 더 큰 집단으로 합병시켜 나가는 과정을 통하여 같은 클래스 내의 요소들의 특성이 서로 동일 혹은 유사하고 서로 다른 클래스집단의 요소들과는 상이하도록 한정적인 수의 클래스로 전체집단을 분류하는 기법이다. 그리고 집단간의 유사/비유사성을 측정하는 유사/비유사 계수에 근거하여 집단간의 결합을 수행하고 주어진 집단연결 중지규칙(stopping rule)을 사용하여 최선의 분류형태를 결정한다. 본 연구의 다중단계 기법은 비유사 계수를 사용하는 계층집단연결에 기반을 두고 있으며 영상분할 단계에서는 집단간의 합병을 서로 이웃하고 있는 집단에 한정하고 있고 영상분류 단계에서는 공간적 제약을 고려하지 않는다.

1) 비유사 계수

주어진 영상의 계층집단연결에서 h 번째 단계에서 전체영상이 m 개의 집단으로 분할되었다고 했을 때, $J_m = \{1, 2, \dots, m\}$ 은 분할집단들의 색인집합이고 G_j^h 가 집단 j 에 속하는 화소들의 집합이라면 $\mathbf{G}^h = \{G_j^h, j \in J_m\}$ 는 h 번째 단계에서 집단형태를 나타내는 분할집단들의 집합이다. 앞으로 임의의 단계 표시인 h 는 편의상 생략하고 분할집단들 중 집단 r 과 집단 s 가 결합하여 형성된 집단은 u 의 색인을 가진다. 즉

$$G_r \cup G_s = G_u, r, s \in J_m.$$

그리고 \mathbf{G}_u 는 \mathbf{G} 에서 G_r 과 G_s 대신 G_u 를 교체한 집단형태를 나타낸다.

관측강도 X 에 대해서 \mathbf{G}_u 의 비유사 계수는

$$\begin{aligned} \lambda_u &= \Delta_q(X | \mathbf{G}_u) - \Delta_q(X | \mathbf{G}) \\ P(X | \mathbf{G}) &\propto \exp \{-\Delta_q(X | \mathbf{G})\} \\ P(\mathbf{G}_u | X, \mathbf{G}) &\propto \exp \{-\lambda_u\}. \end{aligned} \quad (1)$$

그러므로 비유사 계수 λ_u 에 의한 집단연결은 매 단계 가능한 집단간의 합병으로 이루어질 수 있는 집단형태들 중에서 최대우도를 가지는 집단형태가 이루어지도록 합병을 한다. Δ_q 는 관측자료가 갖고있는 집단형태에 대한 정보를 측정하는 값

으로 해석할 수 있으며 일반적으로 집단의 평균강도(mean intensity)와 관측강도간 차이의 합수로서 취해진다. 집단과 관계된 모수들은 새로운 합병에 의해 매 단계 생성되어야 하므로 모수에 대한 추정은 단지 그 단계에서 합병된 집단들과 관련하여 국부적으로(locally) 수행되어져야 한다. 본 연구에서는 가산 가우시안(additive Gaussian) 영상모형 가정아래, 즉

$$X = \mu + \varepsilon, \varepsilon \sim N(\mathbf{0}, \Sigma)$$

μ : 평균강도

ϵ : 노이즈(Σ : 노이즈 공분산행렬)

다음과 같이 정의된 비유사 계수를 사용한다:

$$\begin{aligned}\lambda_u &= \log_e |\hat{\Sigma}_u| - \log_e |\hat{\Sigma}_r| - \log_e |\hat{\Sigma}_s| \\ \hat{\Sigma}_j &= \frac{1}{n_j} \sum_{k \in G_j} (\mathbf{x}_k - \hat{\mu}_j)(\mathbf{x}_k - \hat{\mu}_j)' \\ \hat{\mu}_j &= \frac{1}{n_j} \sum_{k \in G_j} \mathbf{x}_k\end{aligned}\quad (3)$$

n_i : 집단 G_i 의 화소 수

x_k : k 번째 화소의 관측강도.

일반적으로 다중밴드 자료의 활용에서 정확한 밴드간의 상관관계를 구하기가 어렵고 정확한 상관관계를 알고 있지 않은 적용에서 상관관계를 추정하여 사용한 경우 밴드간의 상관관계를 고려하지 않은 결과보다 많은 차이를 나타내지 않으나 공분산행렬의 행렬치(determinant) 계산에 의한 계산상의 복잡성은 심각하게 증가한다. 그리고, 오히려 잘못된 상관관계에 대한 추정치에 의해 결과의 오류가 발생할 수 있다. 본 연구의 무감독 분석에서는 밴드간의 상관관계를 고려하지 않은 대각행렬의 공분산행렬을 사용하였다.

2) 집단연결 중지규칙

계층집단연결에서 분석영상의 최선의 분류형태 즉 최적의 클래스 수를 결정하는 문제는 매우 중요하다. 모집단의 특성 값에 근거한 모형(parametric model)을 사용한 분석에서는 가장 전통적

인 일반화된 우도비율 검증법(generalized likelihood ratio test)처럼 대부분 중지규칙은 카이자승분포(chi-squared distribution)의 가정아래 모형의 우도(likelihood)에 기반을 두고 있다. 그러나, 원격탐사의 영상처럼 분석대상의 크기에 비해서 적은 수의 클래스를 가지는 모형의 분석에서는 카이자승분포의 가정은 궁극적으로(asymptotically) 조차 적합하지 않다. 그러므로 대체수단으로 영상분류에서는 대부분 모형선택을 위한 정보기준(Akaike, 1978)(Won and Derin, 1992)을 사용하고 있으며 여러 저자의 실험을 통하여 영상분석을 위하여 가장 효과적인 정보기준의 하나는 슈바르쓰(Schwarz)에 의해 제안된 기준이다 (Schwartz, 1978)(Rissanen, 1978):

$$SIC = -\log_e (\text{Maximum Likelihood}) + 0.5m_p \log_e n \quad (4)$$

m_p : m 개의 클래스를 가지는 집단형태
에서 추정하여지는 독립모수의 수

n : 분석영상의 전체화소수.

영이 아닌 사전확률(non-zero prior probability)과 베이즈로스(Bayes' loss)에 대한 궁극적 근사(asymptotic approximation)에 의해 구해지는 SIC(Schwarz Information Criterion) 기준은 견본 수가 적은 분석에 대해서 그의 궁극적 특성 때문에 적정한 모형선택에 실패할 수 있으나 일반적으로 많은 학소 수를 가지는 영상의 분석에서는 적정한 클래스 모형을 선택하기 위해서는 적합한 접근법이다.

SIC를 사용하는 계층연결집단에서는 두 개의 작은 집단이 하나의 큰 집단으로 합병되기 위해서는 합병에 의한 로그우도(log-likelihood)의 증가가 $0.5 \log n$ 에 합병 전과 후의 독립모수의 차이를 곱한 값보다 적어야 한다. (3)의 비유사 계수를 사용하는 본 연구의 계층집단연결에서는 평균강도 값과 대각행렬 공분산행렬에 대한 추정치를 사용하므로 p 벤드 영상자료에 대한 SIC 중지규칙은 다음과 같다:

$$\lambda_n \geq p \log_e n. \quad (5)$$

그러나 SIC 모형선택기준에 의해 계층집단연결의 중도단계에서 심각한 오류를 발생시키는 집단간의 합병을 방지할 수 있으나 분석영상의 크기에 비해 매우 적은 수의 클래스를 가지는 일반적 영상자료 적용의 경우에서는 SIC 중지규칙도 원래의 영상이 가지고 있는 적은 수의 클래스를 가지는 분류형태를 선택하는 데는 실패한다. 그러므로 본 연구에서는 실제 적용에서 최선의 분류형태를 결정하기 위한 경험적 규칙(heuristic rule)을 3.3절에서 제시하고 있다.

3. 다중단계 계층집단연결 영상분류(MHCC)

계층집단연결 기법은 계산/기억 상의 복잡도(complexity)가 매우 높으므로 원격탐사자료처럼 방대한 크기의 영상분석에서 계층집단연결을 이용하기 위해서는 이러한 복잡도를 완화시켜야 한다. 그러므로 제안 알고리듬은 계산/기억 상의 효율성을 증가시키기 위해서 영상을 분할한 후 분할집단들을 한정된 수의 클래스로 분류하고 영상분할에서 상호최근사 개념과 다중창 구조를 이용하고 있다.

1) 상호최근사 지역이웃쌍(MCRNP) 영상분할

공간지역화장 영상분할은 서로 이웃하고 집단간의 합병을 통하여 서로 이웃하고 집단들이 서로 상이한 특성을 가지도록 전체 분석영상을 여러 집단으로 분할하는 과정이다. m 개의 집단으로 분할된 임의의 단계에서 J_m 이 집단색인들의 집합이고 $R_j \subseteq J_m$, $j \in J_m$ 는 J_m 의 소집합(subset)으로 집단 j 에 이웃하고 있는 집단들의 색인집합이라고 하면 집단 j 의 CRN(최근사 지역이웃)은 다음과 같이 정의된다:

$$\text{CRN}(j) = \operatorname{argmin}_{k \in R_j} \{\lambda(j, k)\} \quad (6)$$

$\lambda(j, k)$: 집단 j 와 집단 k 의 합병과 연관된 비유사 계수.

그리고 집단 j 와 집단 k 가 다음과 같은 필요충분조건에 의해 MCRNP(상호최근사 지역이웃쌍)으로 정의된다:

$$k = \text{CRN}(j) \text{ and } j = \text{CRN}(k), \quad (7)$$

공간지역화장 접근법은 J_m 에 속한 집단과 그의 CRN의 모든 쌍들 중에서 최소 비유사 계수를 가지는 쌍을 합병한다. 최소 비유사 계수의 쌍은 MCRNP이어야 하므로 MCRNP들 중에서만 최선의 합병 쌍을 검색하면 된다.

2) 다중창 경계폐쇄

서로 공간적으로 이웃하고 있는 집단의 쌍만을 결합하는 공간지역화장 영상분할의 계층집단연결에서는 각 단계에서 합병이 고려되는 쌍들은 MCRNP에 국한되므로 최선의 합병 쌍을 위한 검색대상의 수는 현저히 감소한다. 그러나 방대한 크기의 영상분석에서 전체영상의 모든 화소를 개개의 집단으로 가정하여 화소 수와 일치하는 집단 수를 가지는 분할형태로 초기화하여 알고리듬을 수행한다면 이웃집단집합을 저장하기 위한 막대한 기억량이 필요하고 MCRNP 집합을 검색하기 위하여 여전히 많은 계산시간이 요구된다. 계산/기억 상의 복잡도를 완화시키기 위하여 본 연구는 피라미드 유사구조에 의한 다중창 전략을 채택하였다. Fig. 1은 3개 수준의 사분목(quad-tree) 구조를 사용하는 다중창 구조의 예시를 보여주고 있다. 그러나 다중창 작업에서 개개의 창에 대해서 독립적으로 영상분할을 수행한다면 창의 경계지역에서 분할은 비정상적인 결과를 초래될 것이다. 본 연구에서는 경계폐쇄(boundary blocking) (Lee, 1990) 작업을 통하여 이러한 문제점을 극복하였다. 경계폐쇄 작업은 피라미드 구조의 최상층수준을 제외한 그 아래 수준에 있는 각 창에서 분할작업을 수행할 때 초기에 근접한 창들과의 경계지역에 위치해 있는 집단들을 합병폐쇄 전염집단으로 지정한다. 계층집단연결에서 합병을 수행해 나가는 과정에서 선택된 최선의 합병 쌍 중 하나의 집단

이 전염집단이라면 다른 하나의 집단도 전염집단이 되며 이러한 집단의 쌍은 합병이 되지 않는다. 경계폐쇄 영상분할에서는 SIC 중지규칙에 의해서나 혹은 MCRNP 집합의 모든 쌍들이 전염되었을 때 합병과정은 중지한다.

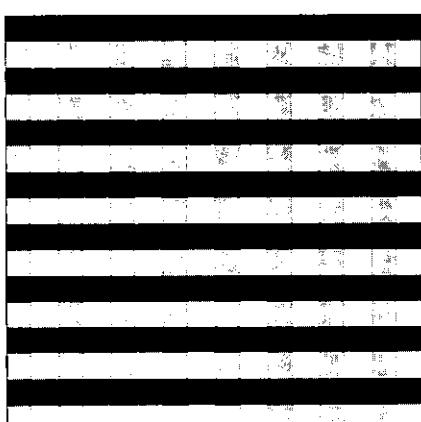
3) 분할집단분류

영상분할 단계에서 서로 이웃하고 있는 집단들이 서로 다른 특성을 가지고는 분할된 집단들은 영상분류 단계에서 한정적인 수의 클래스집단들로 분류된다. 영상분류는 초기에 모든 집단간의 결합을 고려하는 계층집단연결 기법을 사용하므로 초기의 결합가능 수에 따라 계산/기억 량은 지수적으로 증가한다. 그러므로 영상분할 단계의 결과로서 생성된 분할집단의 수가 많을 경우 알고리듬의 효율성은 현저히 저하된다. 본 연구에서는 영상분류 단계는 초기 분할집단의 수에 따라 계산/기억 량의 지수적인 증가를 막기 위하여 영상분류 전에 공간지역확장 영상분할단계에서처럼 공간적 근접성에 의해 결합가능집단을 제한하는 대신 비유사 계수의 근사성에 의해 결합가능집단을 제한하는 상호최근사 영상분할을 수행한다.

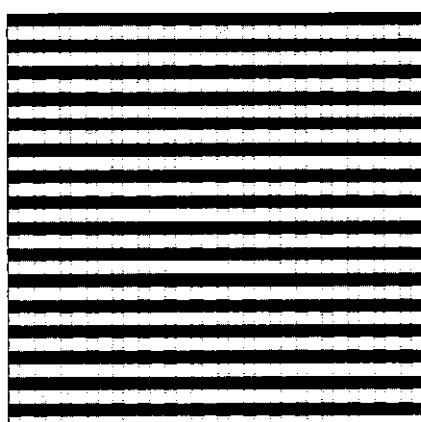
집단 j 와 집단 k 의 비유사 계수가 (5)의 SIC 중지규칙에 해당되지 않는다면, 즉 $\lambda(j, k) < p \log_e n$ 이

라면, 집단 k 는 집단 j 의 분광이웃이고 또한 집단 j 는 집단 k 의 분광이웃이다. 공간지역확장 영상분할단계로부터 m 개의 집단이 생성되었다면 $S_j \subseteq J_m$, $j \in J_m$ 는 J_m 의 소집합(subset)으로 집단 j 에 분광이웃하고 있는 집단들의 색인집합이라고 하면 집단 j 의 CSN(최근사 분광이웃)은 (6)에서 R_j 를 S_j 로 대치하고, MCSNP는 (7)에서 CSN을 사용하여 정의된다. 그러면 m 개의 집단에 대해 MCSNP를 이용하여 계층집단연결을 수행한 다음 나온 결과를 사용하여 마지막으로 영상분류를 수행 한다.

앞 절에서 서술한 바와 같이 SIC 중지규칙에 의한 결정된 분류형태는 방대한 영상자료의 실제적 분석에서는 대부분 너무 많은 클래스의 수를 생성하므로 본 연구에서는 상대적으로 적은 적정수의 클래스를 가진 최선의 분류형태를 결정하기 위해 다음과 같은 사실을 이용하였다: 계층집단연결에서 적합하지 못한 집단들간의 합병이 이루어지는 단계에서는 비유사 계수 값의 급격히 증가할 것이다. 이러한 사실에 기초하여 연속적인 합병단계에서 비유사 계수의 변화율이 가장 큰 단계에서 최적의 클래스의 수를 결정하도록 하였다. 즉 현 단계의 비유사 계수와 다음 합병단계의 계수의 비율이 최대인 단계에 일치하는 클래스 수를 가지고 최선의 분류형태를 선택하였다.



Pattern A (4 Classes)



Pattern B (4 Classes)

Fig. 2. Image patterns for evaluation of image segmentation.

4. 실험 결과

다음의 제안된 알고리듬에 대한 본 연구의 평가 실험은 가산 가우시안 노이즈 영상모형의 모사자료와 550MHz 펜티엄 III PC의 LINUX 시스템을 사용하였고 영상의 절 측 노이즈 수준을 나타내기 위하여 SNR(signal-to-noise)을 평균 노이즈 편차에 대한 최소 클래스간의 강도 차이로서 정의되었다. 본 연구에서는 밴드별 8비트(bit)의 단일/다중 밴드 모의영상자료를 사용하였고 평가 목적 상 각 밴드의 클래스의 평균강도와 강도편차가 동일하도록 생성하였다. 그리고, 각 밴드의 화소 값은 8비트이므로, 즉 0~255내의 값으로 한정되어 있으므로, 모의영상이 주어진 SNR 수준과 일치하는 가우시안 노이즈를 가지기 위해서는 노이즈 편차에 비해 가능하면 클래스의 평균강도 값은 가능하면 0과 255로부터 차이가 동시에 커야하므로 모의관측영상은 SNR 수준에 따라 적절히 평균 노이즈 편차와 최소 클래스간의 강도 차이를 변화시켜 생성하였다.

본 절의 실험에서 영상분할의 오류를 측정하기 위하여 다음과 같은 통계 값을 정의한다:

$$MSE_{error} = \sqrt{\frac{\sum_{i=1}^n \sum_{k=1}^p (\hat{\mu}_{ik} - \mu_{ik})^2}{np}} / \delta_m$$

$\hat{\mu}_{ik}$: 영상분할 결과의 i 번째 화소에 대한 k 번째 밴드의 추정 평균강도 값

μ_{ik} : 영상분할 결과의 i 번째 화소에 대한 k 번째 밴드의 원래 평균강도 값

n, p : 분석 영상의 총 화소와 밴드 수

δ_m : 영상 내의 클래스간의 최소 평균강도 차이.

첫 번째로 MCNRP와 다중창 경계폐쇄의 영상분할을 Fig. 2에 보여진 두 개의 패턴을 사용한 모의영상자료에 적용하였다. 노이즈의 수준에 따라 다중밴드 영상에서 밴드정보량의 증가가 알고리듬의 결과에 주는 영향과 노이즈 수준의 향상에 따른 단일밴드 영상분할 결과에 대한 영향을 알아보기 위하여 공간지역확장 영상분할에서 원래의 패턴이 갖고있는 분할 지역의 수와 일치하도록 영상이 분할되도록 분할과정을 수행한 후 분할영상의 MSE_{error} 값을 구하였다. 예를 들어 A 패턴의 1024×1024 모의영상의 경우 256개의 소지역으로 분할이 되도록 하였다. 영상분할 결과에 대한 MSE_{error} 값은 Table 1에 보여지고 Fig. 3은 A 패턴을 사용한 3가지 SNR 수준의 (a) 3밴드 모의관측영상과 그들의 (b) 분할 후의 결과영상을 보여주고 있다. Fig. 3의 모의영상에서는 SNR 수준이 낮을수록 최소 클래스간의 강도 차이가 작으며, 분할영상에서의 화소 값은 화소가 속한 분할지역의 추정된 평균강도이다. 그리고 각 밴드의 강도(색) 수준이 동일하므로 3밴드 영상은 회색수준의 영상과 유사하게 보여 진다. Table 1의 결과는 SNR 수준이 낮을수록 밴드 수의 증가에 따라 분할결과가 더욱 향상되고 있음을 보여 주고 있고 단일밴드 영상자료에 대한 실험결과는 A 패턴보다 B 패턴의 분할결과가 SNR 수준에 더욱 영향을 받고 있음을 보여주고 있다. Fig. 3에서 보여지듯이 3밴드 자료를 사용하였을 때 분할영상은 $SNR=0.5$ 인 경우에는 주어진 패턴과 비교하여 많

Table 1. Results of MSE_{error} of Image Segmentation for Simulated Noisy Images

SNR	Pattern A				Pattern B	
	1 Band	3 Bands	5 Bands	10 Bands	SNR	1 Band
0.5	0.74	0.34	0.26	0.19	1.0	0.50
1.0	0.38	0.15	0.11	0.08	2.0	0.18
1.5	0.21	0.08	0.06	0.04	3.0	0.09
2.0	0.13	0.06	0.04	0.03	4.0	0.05

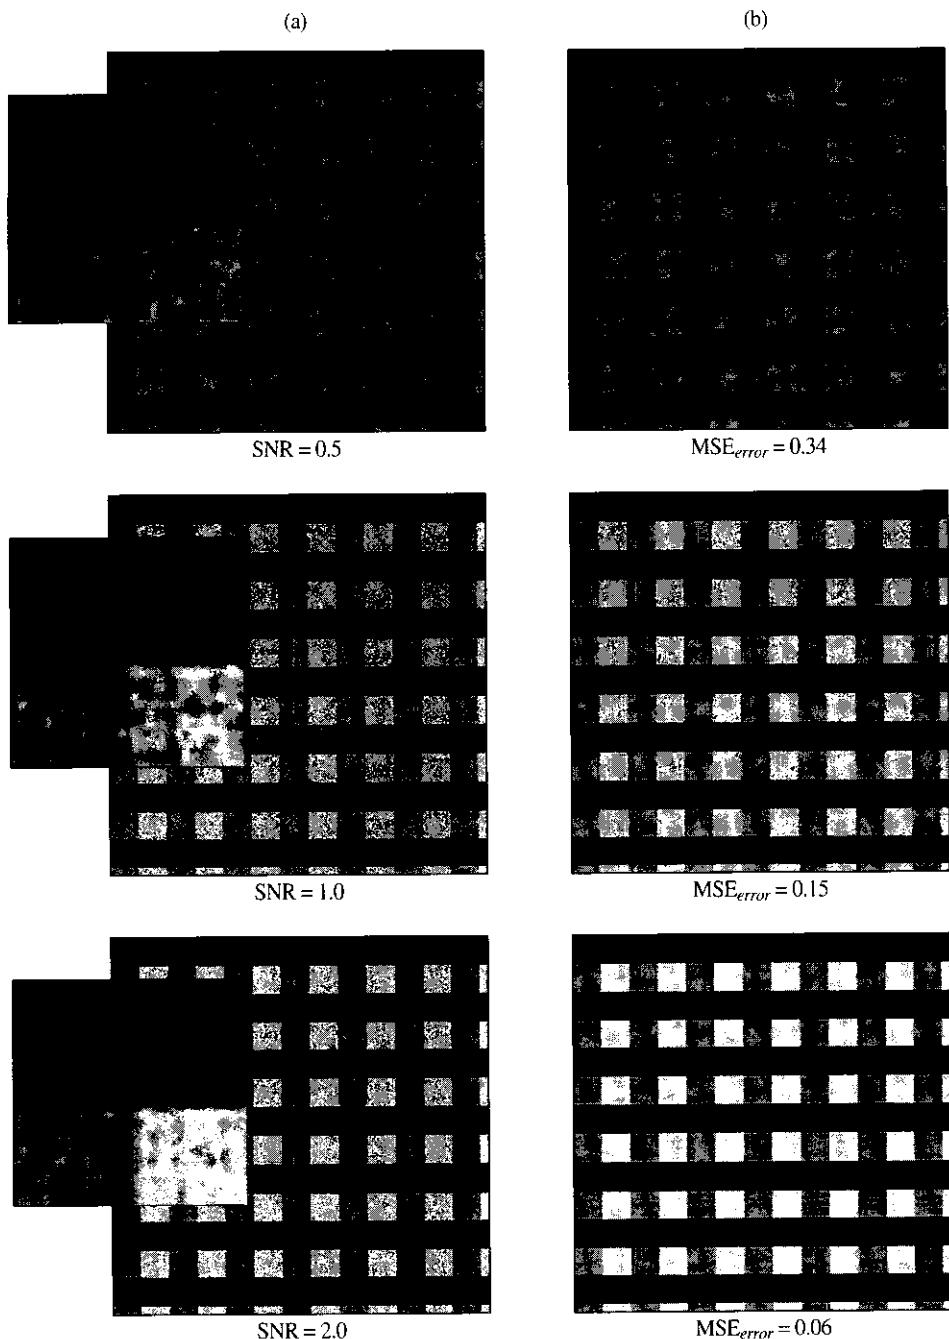


Fig. 3. 3band simulated noisy images (enlarged sub-images) (a) and segmented intensity images (b) of Pattern A.

은 오류를 포함하고 있으나 $\text{SNR} \geq 1.0$ 에서는 거의 정확한 패턴을 나타내고 있다. 여러 실험을 한 결과 분할영상과 오류 값의 비교한 결과 $\text{MSE}_{\text{error}}$

값이 대략 0.2~0.3이 하이면 분할영상이 노이즈가 없는 원래의 영상을 적절하게 표현하고 있는 것으로 나타났다. Table 1과 Fig. 3에서 보여진 결과를

절대적인 기준으로 삼을 수는 없으나, 이러한 결과는 영상의 관측환경이 좋지 않은 경우는 다중밴드 자료가 필요하고 복잡한 지상패턴을 위해서는 영상의 질이 좋아야 한다는 것을 암시하고 있다.

Table 2는 512×512 크기의 단일밴드 영상자료를 위한 공간지역확장 영상분할의 다중창 경계폐쇄 작업에서 다층 구조의 여러 수준에 따른 CPU 사용시간과 MSE_{error} 값을 보여주고 있다. 공간지역확장 영상분할과정에서 2단계이상의 다층구조를 사용한 경우 CPU 사용시간은 현저히 감소된 반면 분할 오류수준은 다층 구조의 단계 수에 관계없이 일정하였다. 그리고 다층 구조의 최하위 수준에서 32×32 크기의 창을 사용하여 영상의 여러 크기와 밴드 수에 대해 실험을 하였다. Table 3

에서 보여지는 것처럼 영상분할을 위한 CPU 사용시간은 분석 영상의 크기/밴드 수가 증가함에 따라 선형적으로 비례하여 증가하고 있다. 이러한 결과는 영상의 크기에 따라 계산 량이 지수적으로 증가하는 계층집단연결 기법을 다중창 경계폐쇄 작업을 통하여 무감독 영상분석을 위하여 효율적으로 사용할 수 있음을 보여주고 있다.

다음으로 앞에서 사용된 모의관측영상 자료를 사용하여 영상분할 후 분할된 집단을 분류하는 MHCC에 대한 실험을 하였다. 이 실험에서는 주어진 모의 영상을 원래의 패턴이 가지고 있는 클래스의 수와 일치하도록 분류한 후 총 화소 수에 대한 잘못 분류된 화소 수의 비율로써 분류영상의 오류를 측정하였다. Table 4에 보여지는 오류율의

Table 2. Comparisons of Computational Time for Segmentation of Single-band 512×512 Imagery with Different Levels of Hierarchical Structure in Multi-window Operation.

Level	Base-window Size	CPU Time(sec)	MSE_{error}
5	16×16	12.85	0.20
4	32×32	12.28	0.20
3	64×64	13.88	0.19
2	128×128	24.94	0.20
1	256×256	76.70	0.20
0	512×512	365.72	0.20

Table 3. Comparisons of Computational Time of Image Segmentation with Base-windows of 32×32 in Bottom Level of Hierarchical Structure.

1 Band Image		1024×1024 Image	
Size	CPU Time(sec)	Number of Band	CPU Time(sec)
512×512	12.28	3	67.96
1024×1024	56.32	5	83.14
2048×2048	255.47	10	169.05

Table 4. Comparisons of Classification Error in Percent (The estimated number of classes is shown in parenthesis when it is not equal to the true one).

SNR	Pattern A				Pattern B	
	1 Band	3 Bands	5 Bands	10 Bands	SNR	1 Band
0.5	52.80(2)	7.47	3.69	2.64	1.0	20.65
1.0	13.73	1.66	0.77	0.31	2.0	2.65
2.0	1.30	0.19	0.07	0.01	3.0	0.64

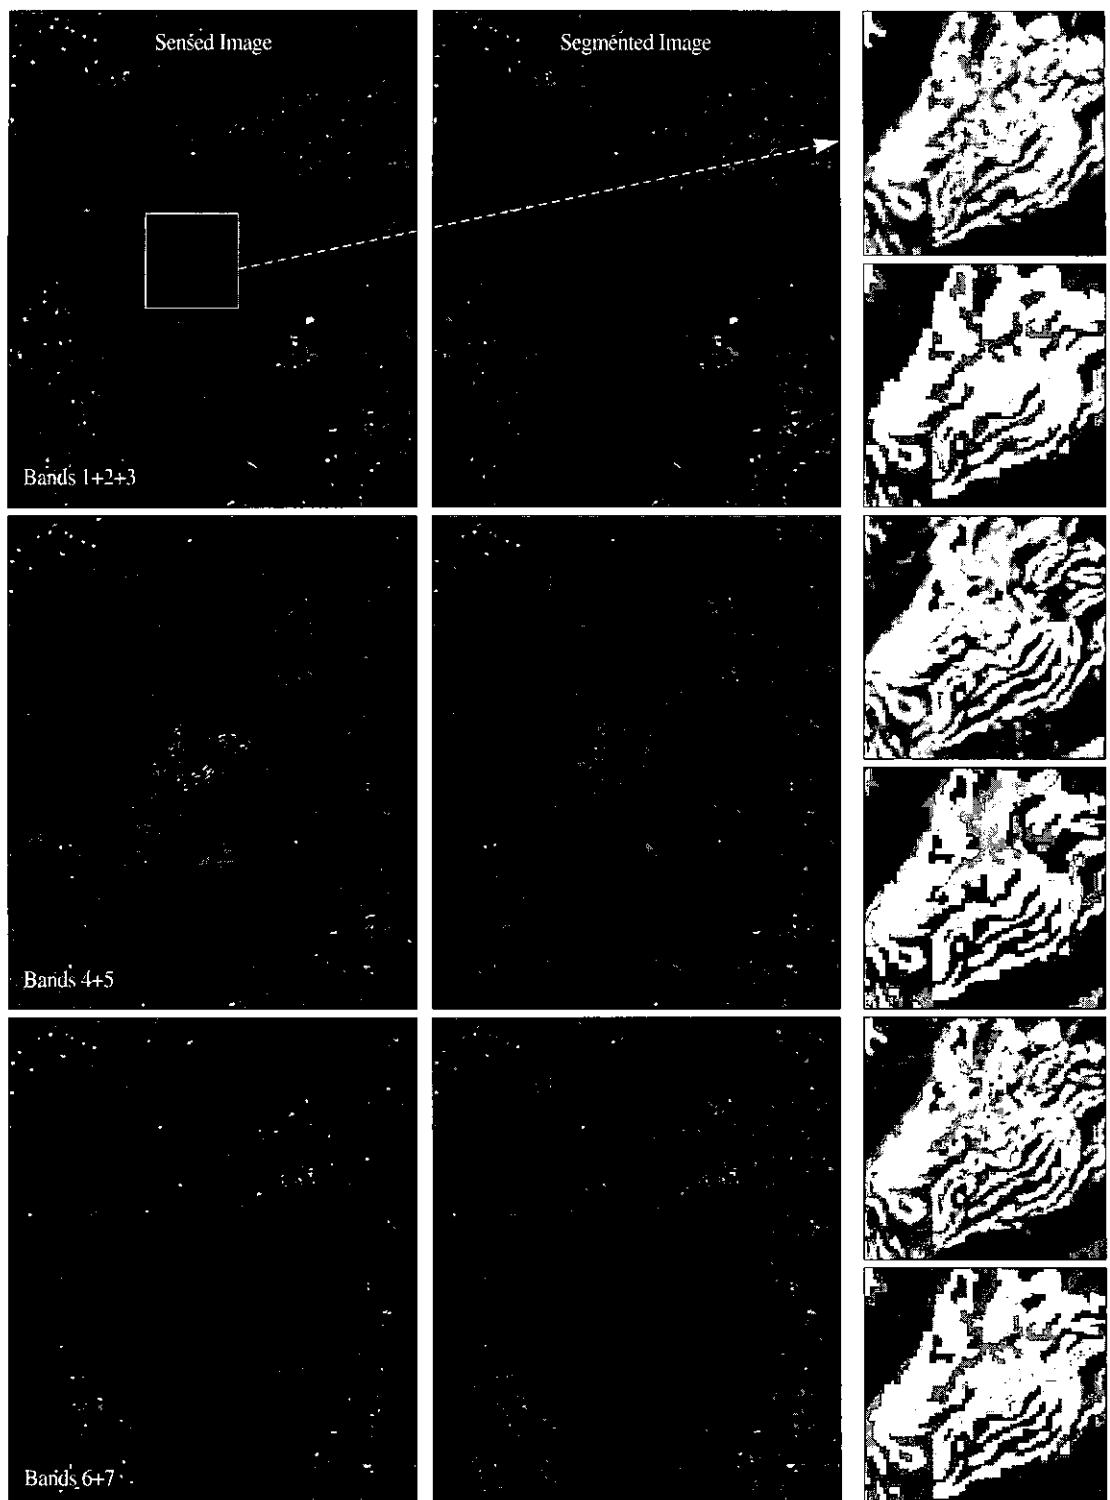


Fig. 4. Gray-scaled LANDSAT ETM+ 7 band image of Yongin-Nungpyung area observed at September 4, 2000 and its segmentation results, remotely-sensed (upper) and segmented (lower) images of sub-region with histogram equalization.

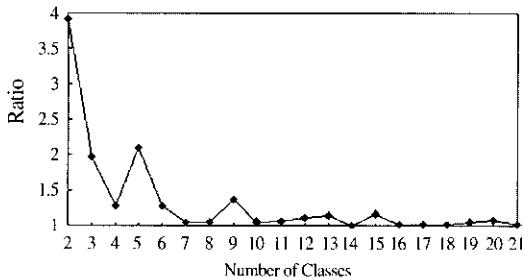


Fig. 5. Change ratio of dissimilarity coefficients in last 20 successive mergings of MHCC for LANDSAT ETM+

백분율의 결과를 살펴보면 MHCC의 영상분류 수행능력은 노이즈가 많은 단일밴드의 영상을 제외하고 우수함을 알 수 있다. 또한 계층집단연결에서 연속적인 합병과정에서 비유사 계수의 변화율이 가장 큰 단계에서 클래스의 수를 결정하였을 때 단지 단일밴드의 영상에서 가장 노이즈가 심한

경우(즉 SNR=0.5)일 때만을 제외하고 모든 경우의 실험에서 원래의 패턴이 가지고 있는 4개의 클래스를 정확히 추정하였다. MHCC에서 영상 분류를 위한 시스템의 CPU 사용 시간은 지역확장 영상분할 과정에 비해 무시할 만한 수준이었다.

Fig. 4는 2000년 9월 4일 용인·능평지역(지상 좌표: 127:07:30E, 37:22:30N, 127:15:00E, 37:15:00N)으로부터 관측된 LANDSAT ETM+의 7개 밴드 영상에 대해서 3개 혹은 2개 밴드(1+2+3, 4+5, 6+7)의 합성 영상을 회색 수준화한 영상과 최대 분할집단 수를 5000개로 한정하여 LANDSAT ETM+의 7개 밴드자료를 사용하여 공간지역확장 영상분할을 수행한 결과를 보여주고 있다. 또한 실험지역의 중앙부분에 위치하고 있는 골프장 지역의 관측 및 분할영상에 대해 히스토그램 이퀄라이제이션(histogram equalization)을 적용한 후 확대한 영상이 Fig. 4에 포함되어 있다.

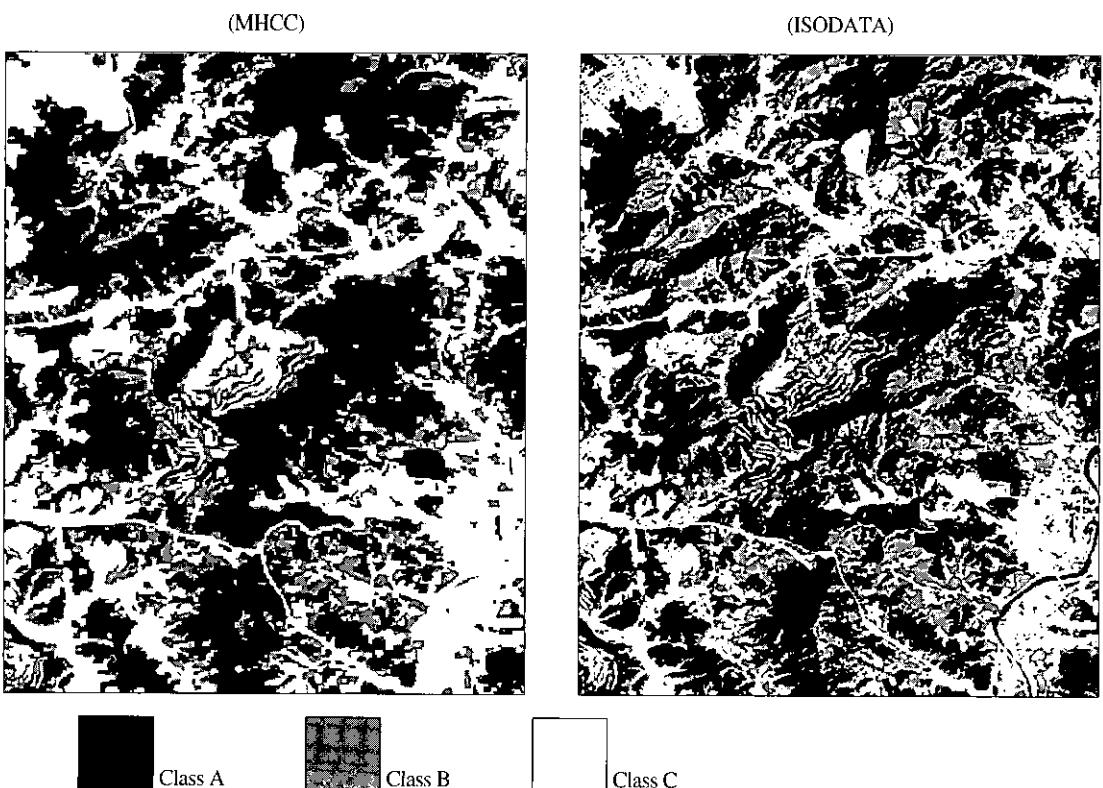


Fig. 6. Classified images with 3 classes using MHCC and ISODATA classifier.

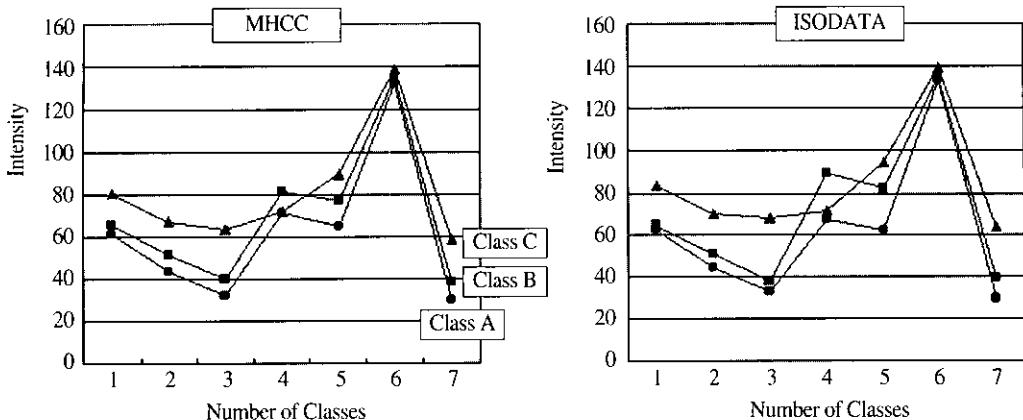


Fig. 7. Estimated mean intensities of 3 classes using MHCC and ISODATA classifier.

이러한 결과는 MHCC의 분할단계에서 생성된 집단화된 영상은 주어진 영상을 적절하게 표현하고 있음을 보여주고 있다. 그러므로 주어진 영상의 분류는 이러한 집단들에 대한 분류에 의해 수행되어 질 수 있다. Fig. 5는 MHCC 분류의 마지막 20단계에서 합병과정의 비유사 계수의 변화율을 보여주고 있다. 실제 원격탐사 자료를 분석하는 경우 분석결과의 사용목적에 따라 적정한 클래스의 수가 달라 질 수 있기 때문에 정확한 클래스의 수를 결정하기가 쉽지 않다. Fig. 5에서 보여지듯 9, 5, 3, 2개의 클래스에 해당되는 지점에서 상대적으로 급격한 변화율을 가졌으므로 이러한 클래스의 수 중에서 하나를 선택할 수 있다. 그리고 비교목적 상 가장 보편적으로 이용되는 무감독 분석법의 하나인 ISODATA 분류기법을 LANDSAT자료에 적용하였다. Fig. 6은 MHCC와 ISODATA 분류기법에 의한 3개 클래스 분류영상을 보여주고 있으며 Fig. 7은 각 클래스의 7개 밴드의 평균강도 값을 보여주고 있다. MHCC 분류영상에서는 A 클래스는 산림지역, B클래스는 준 산림지역, C 클래스는 도시 및 개발지역으로 추정되나 ISODATA의 분류에서는 주로 산림지역의 사면의 방향에 따른 그림자 지역과 밝은 지역이 A와 B 클래스로 구별되었다. ISODATA기법은 우측하단의 도시지역에서 하천이 명확히 다른 인근 지역과 구별되었으나 MHCC는 분할단계에서는 관측영상과 같이 4+5

와 6+7 밴드의 영상에서 하천을 식별할 수 있도록 집단화되었으나 분류과정을 통하여 인근지역과 합병되었음을 알 수 있다. MHCC와 ISODATA 분류기법의 결과를 비교할 때 ISODATA의 분류영상이 영상의 화질에 대한 개선으로 MHCC의 분류영상보다 관측 값에 대한 더욱 충실한 표현일 수 있다. 그러나 지표면의 피복형태는 연속성을 갖고 있으므로 즉 서로 다른 피복형태들이 서로 섞여있는 것이 아니라 어느 정도의 범위까지는 같은 특성의 토지사용이 연속적으로 이어진다. 그러므로 원격탐사에서처럼 연속적인 클래스지역을 갖고있는 지역으로부터 수집된 영상을 위해서는 MHCC가 더욱 적절한 분류를 수행하고 있다.

5. 결 론

본 연구는 공간지역화장 영상분할을 통한 다중 단계 계층집단연결 분류기법을 제안하고 있다. 제안된 알고리듬에서 사용되는 계층집단연결기법은 계산/기억 상의 복잡성을 요구하므로 본 연구는 상호최근사 이웃쌍을 이용하여 최선의 합병을 선택하기 위한 검색범위를 축소하였고 다중창 구조를 이용하여 계층집단연결에서 초기 합병대상 수를 감소시킴으로써 알고리듬의 효율성을 증가시켜 방대한 원격탐사 영상자료의 분류를 위하여 계

층집단연결 기법의 실제적 적용을 가능하게 하였다. 특히 경계폐쇄 작업을 통한 다중창 구조의 사용은 알고리듬의 계산 효율을 현저히 증가시키는 반면 결과의 최적성은 그대로 유지하게 된다.

MHCC는 공간지역확장에 의해 분할된 집단들에 대해 분류를 함으로써 개개 화소 관측 값에 의해 분류를 수행하는 것이 아니라 서로 근접하고 있는 화소들의 집단적인 특성에 의해 분석영상을 분류를 한다. 일반적으로 원격탐사에서 영상자료는 개개의 화소에 따라 토지사용이 달라지는 것이 아니라 어느 정도의 공간적 분포를 가지고 토지사용이 이루어지고 있는 피복형태의 지표면으로부터 관측되어 지므로 MHCC의 분류영상은 개개 화소의 특성에 의해 분류되는 보편적인 기법의 결과보다 지역의 집단적 특성을 잘 표현하고 있다. 특히 관측환경의 불완전성 혹은 기계의 오류 등에 의해 점점이 형태의 노이즈(speckle noise)에 대해서는 공간지역확장 영상분할을 통한 분류는 더욱 효과적이다.

사 사

본 연구는 경원대학교 연구지원사업과 정보통신부 대학기초 연구지원사업으로 진행되었음을 밝히며 연구에 필요한 LANDST ETM+ 영상자

료를 제공해주신 국민대학교 산림과학대학 원격 탐사실에 감사를 드립니다.

참고 문헌

- Akaike, H., 1978. A new look at statistical model identification, *IEEE Trans. Automat. Control*, 19: 716-192.
- Anderberg, M.R., 1973. *Cluster Analysis for Application*, Academic Press, NY.
- Lee, S, 1990. An unsupervised hierarchical clustering image segmentation and an adaptive image reconstruction system for remote sensing, *Ph.D. Thesis*, The University of Texas at Austin.
- Rissanen, J., 1978. Modeling by Shortest Data Description, *Automatica*, 14: 461-471.
- Schwartz, G., 1978. Estimation of the dimension of a model, *Annal. Math. Statist.*, 6: 461-464.
- Tanimoto, S. and A. Klinger, 1980. *Structured Computer Vision*, Academic, New York.
- Won, C.S. and H. Derin, 1992. Unsupervised segmentation of noisy and textured images using Markov random fields, *Comp. Vis. Graph. Im. Proc.*, 54: 308-328.