

퍼지 클래스 벡터를 이용하는 다중센서 융합에 의한 무감독 영상분류

이 상 훈

경원대학교 산업공학과

Unsupervised Image Classification through Multisensor Fusion using Fuzzy Class Vector

Sang-Hoon Lee

Department of Industrial Engineering, Kyungwon University

Abstract : In this study, an approach of image fusion in decision level has been proposed for unsupervised image classification using the images acquired from multiple sensors with different characteristics. The proposed method applies separately for each sensor the unsupervised image classification scheme based on spatial region growing segmentation, which makes use of hierarchical clustering, and computes iteratively the maximum likelihood estimates of fuzzy class vectors for the segmented regions by EM(expected maximization) algorithm. The fuzzy class vector is considered as an indicator vector whose elements represent the probabilities that the region belongs to the classes existed. Then, it combines the classification results of each sensor using the fuzzy class vectors. This approach does not require such a high precision in spatial coregistration between the images of different sensors as the image fusion scheme of pixel level does. In this study, the proposed method has been applied to multispectral SPOT and AIRSAR data observed over north-eastern area of Jeollabuk-do, and the experimental results show that it provides more correct information for the classification than the scheme using an augmented vector technique, which is the most conventional approach of image fusion in pixel level.

Key Words : Multisensor Fusion, Fuzzy Classification, Unsupervised Classification, Satellite Image.

요약 : 본 연구에서는 무감독 영상분류를 위하여 특성이 다른 센서로 수집된 영상들에 대한 의사 결정 수준의 영상 융합기법을 제안하였다. 제안된 기법은 공간 확장 분할에 근거한 무감독 계층군집 영상분류기법을 개개의 센서에서 수집된 영상에 독립적으로 적용한 후 그 결과로 생성되는 분할지역의 퍼지 클래스 벡터(fuzzy class vector)를 이용하여 각 센서의 분류 결과를 융합한다. 퍼지 클래스 벡터는 분할지역이 각 클래스에 속할 확률을 표시하는 지시(indicator) 벡터로 간주되며 기대 최대화(EM: Expected Maximization) 추정 법에 의해 관련 변수의 최대 우도 추정치가 반복적으로 계산되어진다. 본 연구에서는 같은 특성의 센서 혹은 밴드 별로 분할과 분류를 수행한 후 분할지역의 분류 결과를 퍼지 클래스 벡터를 이용하여 합성하는 접근법을 사용하고 있으므로 일반적으로 다중센서의 영상의 분류기법에 사용하는 화소수준의 영상융합기법에서처럼 서로 다른 센서로부터 수집된 영상

의 화소간의 공간적 일치에 대한 높은 정확도를 요구하지 않는다. 본 연구는 한반도 전라북도 북서 지역에서 관측된 다중분광 SPOT 영상자료와 AIRSAR 영상자료에 적용한 결과 제안된 영상 융합기법에 의한 피복 분류는 확장 벡터의 접근법에 의한 영상 융합보다 서로 다른 센서로부터 얻어지는 정보를 더욱 적합하게 융합한다는 것을 보여주고 있다.

1. 서론

지구관측위성의 증가와 함께 다양한 사양을 갖춘 위성영상자료의 획득이 가능하게 되었고, 센서에 따라 서로 다른 공간해상도와 파장영역의 영상들의 장점을 함께 활용하고자 하는 관심이 증가하고 있다. 일반적으로 센서에서 감지되는 신호는 공간 해상도, 파장 폭, 감지 시간 등의 인자에 의하여 제한을 받게 되므로, 어느 하나의 인자에 우선하여 영상을 촬영하면 다른 인자는 그 만큼 희생되어야 한다. 즉 공간해상도가 높은 영상을 얻기 위해서는 파장 폭을 상대적으로 넓게 해야 하고, 반대로 파장 폭을 좁게 하여 여러 파장대의 영상을 얻기 위해서는 공간해상도를 낮추어야 한다. 가령 SPOT 위성영상에서 10m 해상도 자료는 광역의 파장 폭으로 흑백영상을 얻는 데 반하여, 공간 해상도를 20m로 낮추면 여러 파장대의 영상을 얻을 수 있다 (Carper *et al.*, 1990)(Cliche *et al.*, 1985). 이와 같이 공간해상도와 분광 영역을 달리하는 영상 자료를 융합하는 연구가 활발히 진행되고 있다.

원격탐사의 영상융합에서 동시에 또는 서로 다른 시간에 두 개 또는 그 이상의 센서들에 의해 얻어지거나 서로 다른 시간대에 얻어지는 특정 지역의 지표면의 정보는 단일 센서에서 획득할 수 없는 그 지역에 대한 특성을 분석하기 위해 결합된다. 즉 영상융합은 개개의 센서들로부터 얻어진 자료와 관련되는 불확실성을 줄이기 위한 것이다. 영상융합은 일반적으로 화소수준, 특징수준과 의사결정 수준과 같이 세 가지 수준에서 이루어진다 (Pohl and Van Generer., 1998; Taxt and Solberg, 1997). 화소에 기반을 둔 융합에서는 분할 혹은 분류 같은 영상처리 작업들의 능력을 향상시키기 위해 화소별로 서로 다른 영상들로부터 정보를 결합

하고 특징에 기반을 둔 융합은 영상으로부터 빼내어지는 특징들을 결합 한다. 의사결정 수준의 융합은 더 높은 개념의 수준에서 정보를 결합하는 것으로 매우 다른 특성의 센서 간의 융합이나 자연 환경의 다른 지역들을 참조하는 센서들에서 정보를 융합하는 경우이다. 이러한 수준별 영상융합 과정은 Fig. 1에 도식적으로 보여주고 있다.

다른 센서들로부터의 영상들의 융합은 몇 가지 추가적인 전 처리 과정을 요구하고 일반적인 영상 분류 기법에서는 해결할 수 없는 여러 어려움들이 제기된다. 개개의 센서는 자신의 고유한 특성을 가지고 있고 영상 수집과정은 수정되거나 삭제되어야만 하는 다양한 인공적인 요소들을 포함한다. 또한 원격탐사 영상들은 기하학적 보정이 필요하고 영상 융합을 위해서 서로 다른 센서로 관측된 영상들 간의 공간적 연결성을 보여 줄 공통 공간 참조(common spatial reference)가 필요하다. 예를 들어 화소 별 정보의 결합에 근거한 영상 융합에서는 영상들이 같은 공간 해상도를 갖고 있지 않으면 그들이 같은 크기의 화소 크기를 가지도록 재 표본추출을 하여야 하며 정확한 영상간의 상호 등록(co-registration)이 필요하다.

원격탐사 안에서의 영상융합에의 주된 접근 방법은 통계적 기법이다. 통계적인 방법들은 일반적이고 잘 이해되어 있는 이론적인 기초를 가지고 있고 modeling을 위한 강력한 도구의 집합을 포함하고 있다. 이러한 통계적인 기법은 최신 기술의 인공지능 기법과 결합하여 많은 효과적인 영상융합 기법이 개발되었다(Ehlers, 1991; Franklin and Blodgett, 1993; Hall, 1992; Nunez *et al.*, 1999). 본 연구에서는 무감독 영상분류를 위하여 특성이 매우 다른 센서로 수집된 영상들에 대한 의사 결정 수준의 영상 융합기법을 제안하였다. 제안된 기법

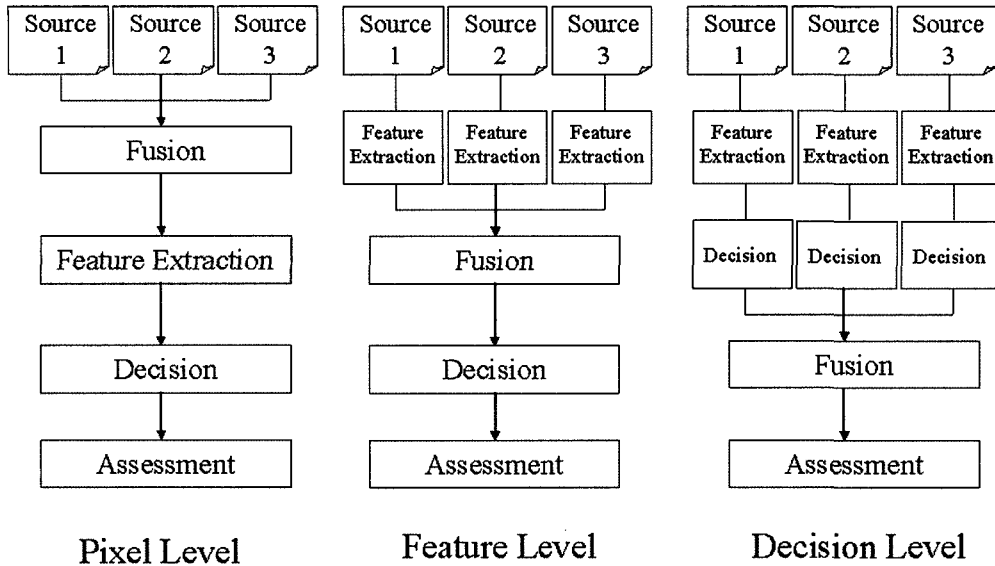


Fig 1. Levels of image fusion processing.

은 공간 확장 분할에 근거한 무감독 계층군집 영상분류기법(이상훈, 2001)을 개개의 센서에서 수집된 영상에 독립적으로 적용한 후 그 결과로 생성되는 퍼지 클래스 벡터를 이용하여 각 분류 결과를 융합하고 있다. 본 연구는 한반도 전라북도 북서지역(익산 남서쪽 만경강 포함한 호남평야 지역)에서 관측된 다중분광 SPOT 영상자료와 AIRSAR 영상자료에 적용한 결과를 보여준다.

2. 분할지역의 퍼지 클래스 벡터

전체 영상이 M 개의 지역으로 분할이 되었을 때 M 개의 분할지역을 K 개의 클래스로 분류하는 경우를 고려해 보자. $J_M = \{1, 2, \dots, M\}$ 과 $K_L = \{1, 2, \dots, L\}$ 은 각각 분할지역과 클래스들의 색인 집합이라 하자. G_j 가 분할지역 j 에 속하는 화소들의 색인 집합이고 \mathbf{x}_k 는 화소 k 의 관측 벡터이라 할 때 $\mathbf{X}_j = \{\mathbf{x}_k, k \in G_j\}$ 는 분할지역 j 에 속하는 화소들의 관측 벡터들의 집합이다. 그러면 \mathbf{X}_j 는 L 클래스들 중 어느 한 클래스 i 와 연관이 되어 있고 이 클래스는 추정이 될 것이다. \mathbf{X}_j 와 K_L 간의 연관성은 관측되지

않은 벡터 $\mathbf{s}_j = \{s_{ij}, i \in K_L\}$ 에 의해 완전히 상술되어 질 수 있다. 만약 분할지역 j 가 클래스 i 에 속한다면 가장 이상적인 경우는

$$s_{ij} = \begin{cases} 1, & k = i \\ 0, & k \neq i \end{cases}$$

분할지역의 완전한 자료집합인 $\mathbf{Z} = \{(\mathbf{X}_j, \mathbf{s}_j), j \in J_M\}$ 의 혼합 확률은 다음과 같이 표현되어 지고 \mathbf{s}_j 는 분할지역 j 의 퍼지 클래스 벡터로 간주 될 수 있다:

$$F(\mathbf{Z} | \mathbf{W}, \Theta) = \prod_{j \in J_M} \prod_{i \in K_L} w_i^{s_{ij}} f_i^{s_{ij}}(\mathbf{X}_j | \Theta_i) \quad (1)$$

$\mathbf{W} = \{w_i, i \in K_L\} : \sum_{i \in K_L} w_i = 1$ 을 만족하는 확률 분포 $\{f_i, i \in K_L\}$ 와 연관된 가중치 집합 $\Theta = \{\theta_i, i \in K_L\}$: 클래스 정의하는 모수 집합.

미관측 요소가 포함된 불완전 자료 집합이 주어졌을 때 기대 최대화(EM: Expected Maximization) 추정 법은 미관측 요소와 관련된 변수의 최대 우도 추정치를 반복적으로 계산한다. 그러면 $\mathbf{X} = \{\mathbf{X}_j, j \in J_M\}$ 에 대한 미관측 변수 $\mathbf{s} = \{\mathbf{s}_j, j \in J_M\}$ 의 최대 우도 추정치를 EM에 의해 산출한다(Liang et al., 1992). 추정과정은 두 가지 단계로 나누어진

다. 첫 단계는 E-step으로 미관측 변수 s 의 기대 값을 계산하는 단계이고 두 번째 단계는 E-step에서 계산된 s 의 기대 값을 사용하여 모수 (W, Θ)의 최대 우도 추정치를 추정하는 M-step이다. EM 과정은 최초로 모수의 초기 값이 주어지면 E-step에서 s 의 기대 값을 계산하고 M-step에서 모수를 추정하고 다시 M-step에서 추정된 모수들을 이용하여 E-step에서 새로운 기대 값을 계산하는 방식으로 E-step과 M-step을 반복적으로 수행하여 추정 모수의 수렴 값을 구한다. 만약 가산 가우시안 (additive Gaussian) 영상모형을 가정하면 즉

$$f_i(\mathbf{X}_j|\theta_i) \equiv |\Sigma_i|^{-\frac{n_j}{2}} \exp\left\{-\frac{1}{2} \sum_{j \in G_i} (\mathbf{x}_j - \boldsymbol{\mu}_i)' \Sigma_i^{-1} (\mathbf{x}_j - \boldsymbol{\mu}_i)\right\} \quad (2)$$

- Σ_i : 클래스 i 의 공분산 행렬
- $\boldsymbol{\mu}_i$: 클래스 i 의 평균 강도 벡터
- n_j : 지역 j 의 화소 수.

h 번째 반복 단계에서 E-step에서 퍼지 클래스 벡터는 다음과 같이 계산된다:

$$s_{ij}^h = \frac{w_i^h f_i(\mathbf{X}_j|\theta_i^h)}{\sum_k w_k^h f_k(\mathbf{X}_j|\theta_k^h)}, \forall j \in J_M, \forall i \in K_L. \quad (3)$$

그리고 M-step에서 각 클래스에 관련된 모수들의 최대 우도 추정치를 구한다:

$$w_i^{h+1} = \frac{1}{n} \sum_{j \in J_M} n_j s_{ij}^h$$

$$\boldsymbol{\mu}_i^{h+1} = \frac{1}{n w_i^{h+1}} \sum_{j \in J_M} \left(s_{ij}^h \sum_{k \in G_j} \mathbf{x}_k \right) \quad (4)$$

$$\Sigma_i^{h+1} = \frac{1}{n w_i^{h+1}} \sum_{j \in J_M} s_{ij}^h \sum_{k \in G_j} (\mathbf{x}_k - \boldsymbol{\mu}_i^{h+1})' (\mathbf{x}_k - \boldsymbol{\mu}_i^{h+1})$$

$$\Sigma_i^{(h+1)} = \frac{1}{n w_i^{(h+1)}} \sum_{j \in J_M} s_{ij}^{(h)} \sum_{k \in G_j} (\mathbf{x}_k - \boldsymbol{\mu}_i^{(h+1)})' (\mathbf{x}_k - \boldsymbol{\mu}_i^{(h+1)})$$

$n = \sum_{j \in J_M} n_j$: 전체 영상의 화소 수.

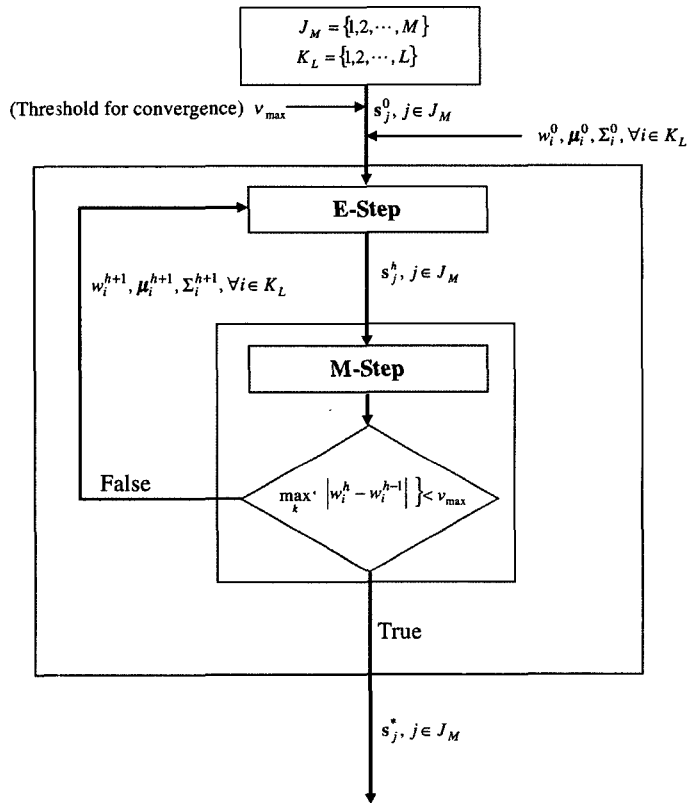


Fig. 2. Generation of fuzzy class vector.

Fig. 2에서 퍼지 클래스 벡터의 계산 과정을 도식적으로 보여주고 있다.

3. 퍼지 클래스 벡터에 근거한 무감독 다중 센서 영상분류

다중 센서로부터 수집된 영상들은 개개의 센서 별로 공간 확장 영상분할을 수행한 후 각 센서 별로 생성된 분할지역을 합성하여 다시 공간적 참조 영상에 모든 센서에서 분할지역의 특성이 공통적으로 일치하는 새로운 영상분할을 수행한다. Fig. 3에 독립적으로 두 개의 서로 다른 센서에 영상분할을 적용한 결과를 합성한 예를 제시하고 있다. 다음에 새로 생성된 분할지역 $\{G_j, j = 1, \dots, M\}$ 에 대해 각 센서 별로 무감독 계층군집 영상분류를 수행한 후 개개의 분류 결과의 조합에 의해 새로운 클래스를 결정한다. k 번째 센서의 영상자료를 분류하였을 경우 L_k 의 클래스로 분류되었다면 분석 영상의 분류결과 조합에 의해 가능한 클래스 수는 $L = \prod_k L_k$ 이다.

이 절에서 변수의 첨자에서 i 와 j 는 화소가 속한 각각 클래스와 분할지역의 색인을 나타내고 (k)는 센서의 색인이다. 분할지역 $\{G_j, j = 1, \dots, M\}$ 에 대해 앞 절에서 설명한 방법에 의해 각 센서에서 개별적으로 퍼지 클래스 벡터 $\{s_j^{(k)}, j = 1, \dots, M\}$ 을 구할 수 있고 이 퍼지 클래스 벡터는 각 센서

에서 분할지역이 각 클래스에 속할 확률을 표시하는 지시벡터로 간주될 수 있다. 그러면 각 분할지역별 모든 센서간의 지시 벡터의 요소 값끼리의 곱은 모든 센서에서 분할지역이 해당 동일 클래스에 속하는 확률을 나타내는 지시벡터라 할 수 있다. 즉 각 센서의 분류결과와의 조합에 의해 생성된 분류형태에 대한 분할지역 j 의 융합 지시 벡터는 다음과 같이 구성 된다:

$$ss_j = \left\{ ss_{ij} = \prod_k s_{ij}^{(k)}, i = 1, \dots, L \right\} \quad (5)$$

$$\sum_{i=1}^L ss_{ij} = 1.$$

ss_j 의 요소 중 최대 값을 갖는 요소에 해당하는 클래스를 분할지역 j 의 클래스로 배정할 수 있다. 그러나 융합 지시 벡터에 근거한 분류에서 각 센서의 지시 벡터 $s_{ij}^{(k)}$ 가 모두 1에 가까운 값을 갖는 경우는 클래스 배정에 대한 불확실성이 매우 적으나 그렇지 않은 경우는 클래스 배정에 잘못을 가져 올 수 있다. 센서의 특성상 특정 센서만이 특정 클래스를 정확히 분류할 수 있는 경우가 이에 해당한다. 본 연구에서는 주어진 임계 확률 UC_{EM} 이용한 다수표(majority voting)기법에 의해 클래스를 배정한다. 즉 분할지역의 퍼지 클래스 벡터의 요소 값을 각 센서 별로 UC_{EM} 과 비교하고 그 요소 값이 UC_{EM} 보다 큰 경우의 수를 세었을 때 그 수가 가장 많은 클래스를 그 지역의 클래스로 배정하고 동일 수가 여러 경우가 발생했을 때는

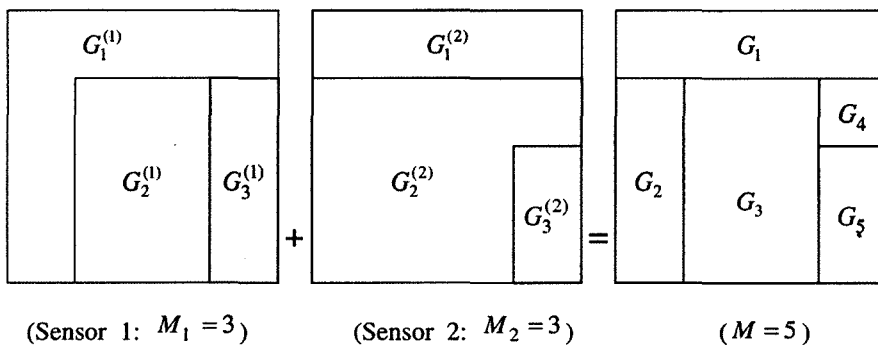


Fig. 3. Image partition resulting from combining the image segmentations in two different sensors.

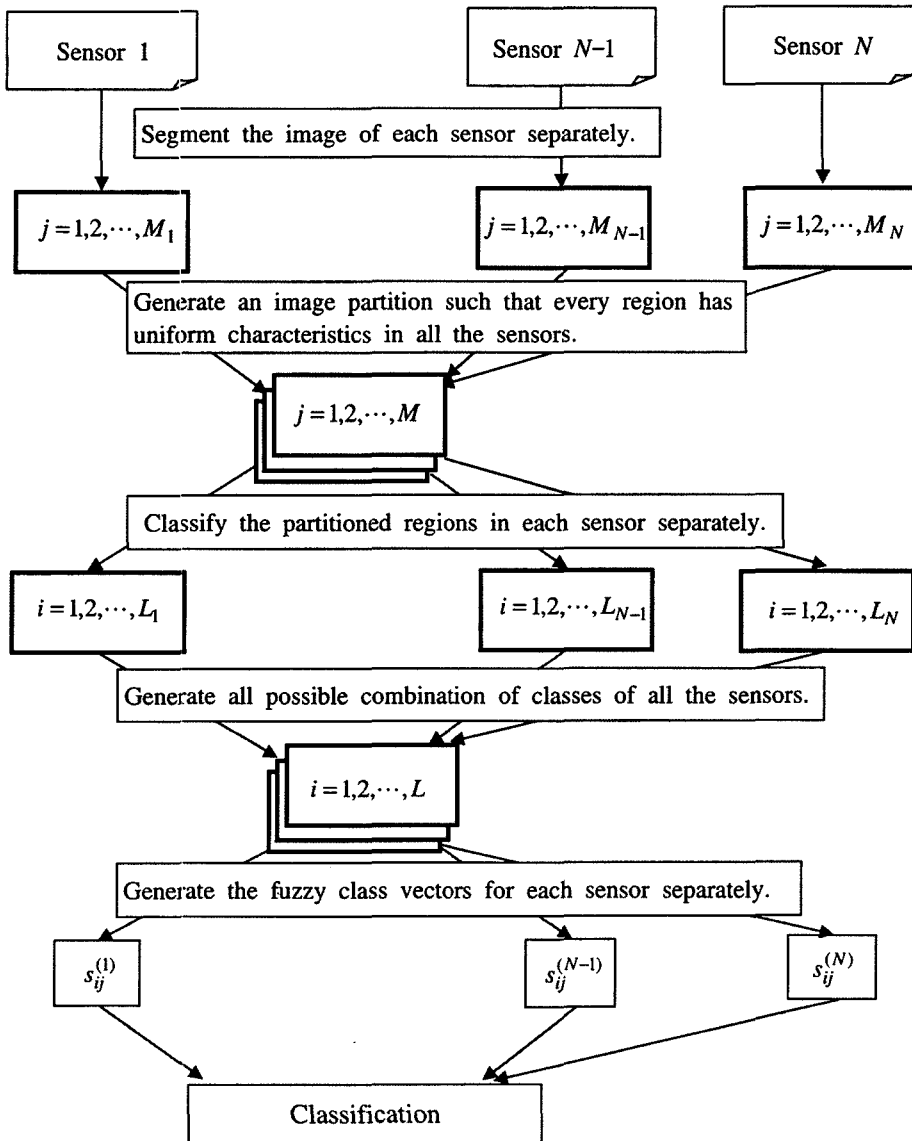


Fig. 4. Classification for imagery of N-sensors using fuzzy class vector.

UC_{EM} 보다 클 때만의 요소 값의 곱이 최대인 경우의 클래스로 배정한다. Figs. 4와 5는 앞의 융합을 통한 분류과정에 대한 요약을 보여준다.

그러나 일반적으로 조합에 의한 가능한 클래스 수는 실제의 클래스 수에 비해 매우 큰 값을 가지고 있으므로 본 연구에서는 분류단계 전에 모든 가능한 조합으로부터 불확실한 클래스를 제거하는

예비 단계를 거친다. 융합 지시 벡터의 최대 값이 작은 값을 갖는다면 클래스 배정에 불확실성이 존재하는 것을 의미하므로 조합에 의해 가능한 클래스 수에 대해서 구해진 융합 지시 벡터의 최대 값이 주어진 임계 값 UC_{CL} 보다 크다면 분할지역에 클래스를 배정하고 그렇지 않으면 분할지역에 클래스를 배정하지 않는다. 지역을 할당받은 클래스

for $j = 1, 2, \dots, M$

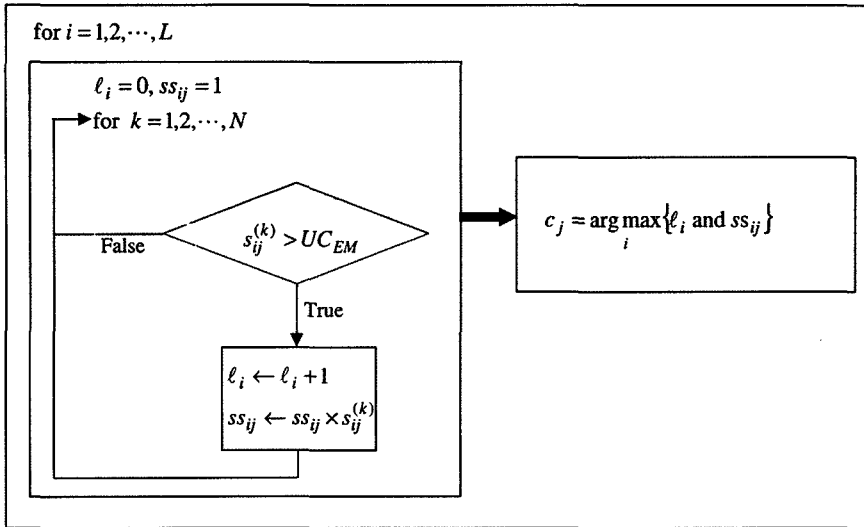


Fig. 5. Classification in Fig. 4.

는 현 영상이 관측된 scene에 존재하는 피복 형태에 해당한다고 할 수 있고 그렇지 않은 클래스는 관측상의 문제나 서로 다른 피복 형태의 경계상의 문제로 발생하는 왜곡된 피복 형태로 볼 수 있다. 그러면 분할지역을 배정 못 받은 클래스를 배제한 후 새로이 생성된 분류형태에 대해 각 센서 별로 다시 퍼지 클래스 벡터를 계산하여 분할지역의 분류를 수행한다. 그리고 클래스의 최소 화소수가 주어진다면 분류 후 최소 화소 수를 만족하지 못하는 클래스를 배제한 후 다시 퍼지 클래스 벡터를 계산하여 분할지역의 분류를 수행한다.

4. 원격탐사자료 실험

본 연구에서 제안된 영상 융합에 의한 영상 분류에 대한 평가 실험을 위해 한반도 전라북도 북서지역(익산 남서쪽 만경강 포함한 호남평야 지역)에서 관측된 다중분광 SPOT 영상자료와 AIRSAR 영상자료를 사용하였다. AIRSAR 영상자료는 2000년 9월 30일에 한반도 지역에 대해 수

행된 PACRIM2000 미션(mission)에 의해 관측되었으며 본 연구에서는 3개 밴드(P, L, C)의 POLSAR 모드(mode) 자료를 사용한다. POLSAR 모드 자료에서는 모든 밴드는 각각 4가지 모드(HH HV VH VV)에 대한 자료를 구성하고 있으므로 각 3개의 밴드는 각 모드에 해당하는 4개의 소밴드로 구성되며 사용된 AIRSAR자료는 총 12개 밴드의 자료로 간주된다. 다중분광 SPOT 영상자료는 2000년 10월 4일에 관측된 자료로 레벨 1B 수준(기하보정 포함)에서 처리된 3개 밴드(Green, Red, NIR)의 공간 해상도 20m×20m를 가진 자료이다. 그러나 AIRSAR 영상자료는 비행시스템과 영상감지 시스템의 특성에 따른 변형에 대한 보정이 이루어 지지 않았으므로 일정한 화소 격자를 가지지 않은 자료이다.

AIRSAR 영상자료는 기하 보정된 SPOT영상자료를 참조 영상으로 하여 2차원의 다항모형을 사용하여 RMS오류가 0.5화소 이하가 되도록 기하 보정시켰다. 그리고 두 센서의 영상자료의 공간 해상도를 일치시키기 위해 최근사 이웃(Nearest Neighbor)법에 의해 재 표본추출을 수행하여 공간

해상도 6m×6m의 1024×1536크기의 총 15개 밴드 (SPOT 3개 밴드+AIRSAR 12개 밴드) 영상자료를 생성하였다.

우선 계층군집 영상 분류법을 이용하여 SPOT 자료와 각 AIRSAR 3개 밴드에 대해서 13개의 클래스로 분류하였다. 그리고 AIRSAR 자료의 12개 밴드에 대해 계층군집 영상분류를 수행하였고 또한 AIRSAR 자료의 12개 밴드와 SPOT 3개 밴드로 15개 밴드의 확장 벡터를 구성하여 분류를 수행하였다. 분석 지역은 대표적으로 10개의 토지 피복특성으로 이루어져 있으나 분류과정에서 잘못된 결합으로 인한 평가의 부정확성의 문제를 완화시키기 위해 3개의 클래스 수가 많은 단계에서 분류를 마치도록 하였다.

분석 지역의 10개의 특성 지역에 대해 55087화소에 해당하는 지상 실사 자료 표본을 실사와 GIS 자료를 이용하여 추출하였다. Table 1은 실사 자료의 각 피복 형태별 분포를 보여주고 있다. 이 지상 실사 자료를 이용하여 분류 결과에 대한 오류율을 구하였다. 각 클래스의 해당 피복 형태는 추정된 클래스에 포함된 각 토지 피복 형태의 지상 실사 표본 지점의 수에 의해 정해진다. 즉 클래스의 피복 형태는 가장 많은 실사 자료 지점을 가지는 토지 피복 형태로 정해진다. Table 2는 이러한 다수원칙에 의해 피복 분류를 하였을 때 분

류 결과의 오류율을 보여주고 있다. AIRSAR 자료만을 사용한 분석은 정확한 토지 피복 분류를 보여 주지 않고 AIRSAR 자료는 확장 벡터의 형태로 포함되었을 경우 SPOT의 광학 영상 자료만을 사용한 경우보다 토지 피복 분류에 대해 더 많은 정보를 제공해 주지 못하는 것으로 보여진다. 특히 L 밴드와 C 밴드는 토지 피복 분류에 대해 올바른 정보 보다는 왜곡된 정보를 제공해 피복 분류 분석의 결과를 악화시킬 수 있다. 그러므로 SPOT 밴드와 P 밴드로 구성된 7개 밴드의 확장 벡터를 구성하여 다시 분류를 수행하였다. 이러한 분류 결과로 발생된 피복 형태에 따른 추정된 클래스별 실사 자료 수의 분포와 분류 오류율이 Table 3에 보여진다.

다음에는 영상 융합에 의해 분류를 수행하였다. 앞에서 서술된 것처럼 L 밴드와 C 밴드는 토지 피복 분류에 대해 악화를 시킬 수 있으므로 우선 SPOT 밴드와 P 밴드로부터 나온 각각 나온 분류 결과의 조합을 영상 융합에 사용하였다. 융합에 의해 13개의 클래스로 분류한 결과가 Tables 4에 보여지고 있다. 10개의 피복 특성 분류에서 교통 지역, 주거지역, 기타대지, 기타재배지는 실제적으로 서로 복잡하게 혼합되어 있어서 이 실험에 사용한 영상자료의 공간 해상도로는 정확히 구별 분류하기가 힘들다. Fig. 6은 교통지역, 주거지역, 기타대지, 기타재배지를 한 개의 피복형태로 간주했을 때 피복 분류 영상을 보여준다. 이 경우 분류 오류율은 0.02이하로 감소한다.

Table 1. 10개의 피복형태에 대한 실사자료 분포.

피복형태	화소 수
교통지역	1654
주거지역	2750
기타대지	773
논	24457
밭	5392
기타재배지	2328
침엽수림	1972
혼효림	657
습지	1300
수역	13804
계	55087

Table 2. 실사자료와 비교한 오류율.

사용밴드	확장밴드수	오류율
SPOT	3	0.13
P	4	0.27
L	4	0.47
C	4	0.51
PLC	12	0.30
SPOT/PLC	15	0.15
SPOT/P	7	0.09
SPOT+P+L+C	(Fusion)	0.05

Table 3. 피복특성 형태에 따른 SPOT/P 확장밴드 영상의 계층군집 영상분류에 의해 추정된 클래스별 실사자료 수의 분포와 분류 오류율.

피복형태 클래스	교통 지역	주거 지역	기타 대지	논	밭	기타 재배지	침엽 수림	혼효림	습지	수역	오류율
1	0	12	0	8982	2	0	0	0	0	0	0
2	29	0	16	10587	9	1	0	326	0	0	0.03
3	0	105	19	6	3	69	0	296	0	0	0.41
4	87	2222	50	2	8	522	0	0	0	0	0.23
5	117	128	63	4141	88	313	0	0	0	0	0.15
6	315	166	51	0	0	728	0	0	0	0	0.42
7	41	0	0	0	0	0	0	0	5	2700	0.02
8	65	66	54	1	9	474	1	33	1295	0	0.35
9	1000	0	505	0	0	193	0	0	0	0	0.41
10	0	44	15	70	2443	4	2	0	0	0	0.05
11	0	7	0	668	2486	20	2	2	0	0	0.22
12	0	0	0	0	344	4	1967	0	0	0	0.15
13	0	0	0	0	0	0	0	0	0	11104	0

Table 4. 피복특성 형태에 따른 SPOT영상과 AIRSAR영상의 융합에 의해 추정된 클래스별 실사자료 수의 분포와 분류 오류율.

피복형태 클래스	교통 지역	주거 지역	기타 대지	논	밭	기타 재배지	침엽 수림	혼효림	습지	수역	오류율
1	0	36	0	<u>6031</u>	0	0	0	0	0	0	0.01
2	39	1	16	<u>14773</u>	0	0	2	12	0	0	0
3	26	0	10	179	3	1	0	<u>575</u>	0	0	0.28
4	210	292	33	0	0	<u>918</u>	0	0	0	0	0.37
5	209	<u>2119</u>	23	15	0	181	0	0	0	0	0.17
6	33	110	114	7	0	<u>971</u>	3	33	42	0	0.26
7	2	0	0	0	0	23	0	0	<u>1256</u>	0	0.02
8	0	0	0	0	0	0	<u>1967</u>	0	0	0	0
9	<u>1072</u>	0	509	0	0	121	0	0	0	0	0.37
10	11	126	0	<u>3385</u>	21	0	0	0	0	0	0.04
11	52	0	0	0	0	0	0	0	2	<u>2700</u>	0.02
12	0	66	68	67	<u>5368</u>	113	0	37	0	0	0.06
13	0	0	0	0	0	0	0	0	0	<u>11104</u>	0.00

5. 결론

레이더 센서와 광학센서처럼 서로 다른 분광 특성을 가진 센서로부터 수집된 자료는 지표면의 피복 특성의 판별을 위해서 서로 다른 특징을 가진다. 그러므로 이러한 다른 특성의 센서의 자료

를 사용하여 지표면 피복분류의 정확성을 증가 시킬 수 있다. 여러 센서로부터 관측되는 단일 혹은 다중 밴드 자료를 연결하여 단일 센서의 다중 밴드로 간주하는 화소별 영상융합의 확장 벡터 기법은 일반적인 다중분광 기법을 사용할 수 있는 장점을 가지고 있지만 서로 다른 센서로부터 관측되



Fig. 6. Classification results using SPOT and AIRSAR images for north-eastern area of Jeollabuk-do.

는 영상간의 정교한 상호 등록이 필요하고 서로 다른 특성의 값을 동시에 고려함으로써 발생하는 밴드 값 간의 상쇄로 인해 왜곡된 정보를 산출할 수 있다. 본 연구에서는 같은 특성의 센서 혹은 밴드 별로 분할과 분류를 수행한 후 분할지역이 각 클래스에 속할 확률을 나타내는 퍼지 클래스 벡터를 이용하여 분할지역에 대한 분류 결과를 합성하는 접근법을 사용하고 있다.

본 연구의 원격탐사 자료 실험에서 확장 벡터를 사용하는 접근법과의 비교를 위해 편의상 서로 다른 두 센서로부터 수집된 영상에 대해서 동일한 digital 영상 격자구조를 사용하였다. 그러나 제안된 영상 융합 접근법은 서로 다른 센서의 영상 분석 결과를 합성하기 위해 서로 다른 센서의 영상간의 공간 좌표를 연결시키는 mapping 시스템이나 공간 참조 시스템(spatial reference system)을

필요로 하나 각 화소간의 정확한 공간적 일치가 이루어지도록 하는 기하보정 및 재 표본추출과정(resampling)을 반드시 필요로 하지 않는다. 그리고 분할지역에 대하여 센서 별 분류결과를 확률적으로 융합하므로 일반적으로 사용하는 화소 수준의 융합 기법에서처럼 서로 다른 센서로부터 수집된 영상의 화소간의 공간적 일치에 대한 높은 정확도를 요구하지 않는다.

본 연구에서는 제안된 영상 융합에 의한 영상 분류법을 한반도 전라북도 북서지역에서 관측된 다중분광 SPOT 영상자료와 AIRSAR 영상자료에 적용하였고 그 실험결과들은 개별적 분류 결과의 영상 융합에 의한 피복 분류는 확장 벡터의 접근법에 의한 영상 융합보다 서로 다른 센서로부터 얻어지는 정보를 더욱 적합하게 융합한다는 것을 보여주고 있다.

참고문헌

이상훈, 2001. "공간 지역 확장과 계층 집단 연결 기법을 이용한 무감독 영상분류," 대한원격탐사학회지, 17, 7-70.

Carper, W. J., T. M. Lillesand, and R. W. Kieffer, 1990. The use of Intensity-Hue-Saturation transformations for merging SPOT Panchromatic and multispectral imagedata., *Photogrammetric Engineering and Remote Sensing*, 56: 459-467.

Cliche, G., F. Bonn, and P. Teillet, 1985. Integration of the SPOT Pan channel into its multispectral mode for image sharpness enhancement, *Photogrammetric Engineering and Remote Sensing*, 51: 311-316.

Pohl, C. and J. L. Van Genderen, 1998. Multisensor image fusion in remote sensing: concepts, methods and applications, *Int. J. Remote Sensing*, 19: 823-854.

Taxt, T. and A. H. S. Solberg, 1997. Information

- fusion in remote sensing, *Vision in Astronomy*, 41: 337-342.
- Ehlers, M., 1991. Multisensor image fusion techniques in remote sensing, *ISPRS J. Photogrammetry and Remote Sensing*, 46: 19-30.
- Franklin S. E. and C. F Blodgett, 1993. An example of satellite multisensor data fusion., *Computers and Geoscience*, 19: 577-583.
- Hall, D. L. , 1992. *Mathematical techniques in multisensor data fusion*, Norwood: Artech House Inc.
- Nunez, J., X. Otazu, O. Fors, A. Prades, V. Pala, and R. Arbiol, 1999. Multiresolution-based image fusion with additive wavelet decomposition, *IEEE Trans. Geosci. and Remote Sensing*, 37: 1204-1211
- Liang, Z., R. J. Jaszczak, and R. E. Coleman, 1992. Parameter Estimation of FiniteMixture Using the EM Algorithm and Information Criteria with Application to Medical Image Processing, *IEEE Trans. Nucl. Sci.*, 39: 1126-1133.