

반복최적화 무감독 분광각 분류 기법을 이용한 하이퍼스펙트럴 영상 분류에 관한 연구

조현기*† · 김대성* · 유기윤** · 김용일**

서울대학교 대학원 지구환경시스템공학부*, 서울대학교 공과대학 지구환경시스템공학부**

A Study on the Hyperspectral Image Classification with the Iterative Self-Organizing Unsupervised Spectral Angle Classification

Hyun Gee Jo*†, Dae Sung Kim*, Ki Yun Yu**, and Yong Il Kim**

School of Civil, Urban & Geosystem Engineering, Seoul National University

Abstract : The classification using spectral angle is a new approach based on the fact that the spectra of the same type of surface objects in RS data are approximately linearly scaled variations of one another due to atmospheric and topographic effects. There are many researches on the unsupervised classification using spectral angle recently. Nevertheless, there are only a few which consider the characteristics of Hyperspectral data.

On this study, we propose the ISOMUSAC(Iterative Self-Organizing Modified Unsupervised Spectral Angle Classification) which can supplement the defects of previous unsupervised spectral angle classification. ISOMUSAC uses the Angle Division for the selection of seed points and calculates the center of clusters using spectral angle. In addition, ISOMUSAC perform the iterative merging and splitting clusters. As a result, the proposed algorithm can reduce the time of processing and generate better classification result than previous unsupervised classification algorithms by visual and quantitative analysis. For the comparison with previous unsupervised spectral angle classification by quantitative analysis, we propose Validity Index using spectral angle.

Key Words : Hyperspectral Remote Sensing, Unsupervised Classification, Spectral Angle Classification, Seed Point Selection, Validity Index.

요약 : 분광각(Spectral Angle)을 이용한 분류는 같은 종류의 지표 대상물의 분광 특성이 대기 및 지형적인 영향으로 인해 원점을 기준으로 유사한 분광각을 가지며, 선형적인 분포 모양을 가진다는 가정에 기초한 분류 방식이다. 최근 분광각을 이용한 무감독 분류에 대한 연구가 활발히 이루어지고 있으나, 하이퍼스펙트럴 데이터의 특성을 반영한 효과적인 무감독 분류에 대한 연구는 미진한 상태이다. 본 연구는 하이퍼스펙트럴 영상 분류에 있어서 기존 무감독 분광각 분류(USAC, Unsupervised Spectral Angle Classification) 연구에서 나타난 문제점들을 보완한 반복최적화 무감독 분광각 분류(ISOUSAC, Iterative Self-Organizing USAC) 기법을 제안하고 있다. 이를 위해, 무감독 분광각 분류에 적합한 각 분할(Angle Range Division) 기법을 적용하여 군집 초기 중심을 설정하였고, 군집 중심 계산에 있어서 각 중심을 이용

하였다. 뿐만 아니라 병합(Merge)과 분할(Split)을 통한 유동적인 군집 분석을 수행하였다. 결과를 통해, 제안된 알고리즘이 기존의 기법보다 수행 시간뿐 아니라 시각적, 정량적인 면에서 우수한 결과를 도출하였으며, 분광각을 이용한 군집 유효성 지수(Validity Index)를 제안함으로써 기존의 무감독 분광각 분류와 정량적 비교를 수행하였다.

1. 서론

모든 지표 대상물은 빛의 반사 및 흡수 등으로 인해 각 파장에 대해서 고유한 밝기값을 나타내기 때문에, 같은 종류의 지표 대상물들은 비슷한 분광반사 패턴을 가진다 (Youngsinn, 2002). 하이퍼스펙트럴 데이터는 이러한 지표 대상물의 파장 특성을 높은 분광 해상도를 이용하여 효과적으로 취득함으로써 다중분광 데이터보다 좀 더 세분화된 분석이 이루어질 수 있다. 하지만, 많은 밴드 수와 신뢰도가 낮은 트레이닝 데이터의 취득으로 인하여 영상을 분류함에 있어서 오히려 낮은 결과 정확도를 나타내는 현상이 발생하기도 한다. 이런 문제를 해결하기 위해 최근에는 하이퍼스펙트럴 데이터에 효과적인 새로운 알고리즘에 대한 연구가 활발히 이루어지고 있다.

분광각(Spectral Angle)을 이용한 원격탐사 데이터의 분석은 같은 종류의 지표 대상물들의 분광특성은 대기 및 지형적인 영향으로 인해 원점을 기준으로 유사한 각을 지니며, 선형적인 분포 모양을 가진다는 특성에 기초한 새로운 접근 방식이다(Youngsinn, 2002, Jensen, 2004).

하지만, 분광각 분류에 관한 연구들은 주로 감독 분류에 적용되었다(Kruse *et al*, 1993b; Youngsinn, 2002). 또한 기존의 무감독 분광각 분류는 유사도 평가에 있어서 분광각을 사용하였으나, 군집(Cluster) 중심을 계산하는데 있어 거리 개념을 사용한 한계점이 있으며, 원점으로부터 매우 다른 거리에 있는 화소를 동일한 군집으로 할당한다는 단점이 있다(Kai-Yi, 2002; Arel Weisberg, 1999; James Norman, 2004).

본 연구는 무감독 분광각 분류에 적합한 군집 초기 중심(Seed Points)을 결정하는 방법을 제시하였고, 기존의 무감독 분류와는 달리 군집 중심을 계산하는 데 있어서 각 평균을 사용하였다. 또한 병합(Merge)과 분할(Split)을 통한 유동적인 군집 분석을 수행하여 더욱 개선된 분광각 분류 알고리즘을 개발하였다. 끝으로 기존의 무감독 분광각 분류와의 정량적 비교를 위해 분광각 분류에 적합한 군집 유효성 지수를 제안하여, 기존의 연

구와의 정량적 비교를 수행하였다.

2. 알고리즘

1) 무감독 분광각 분류

무감독 분광각 분류는 같은 종류의 지표 대상물의 분광특성은 대기 및 지형적인 영향으로 인해 원점을 기준으로 유사한 분광각을 지니며, 선형적인 분포를 가진다는 특성에 기초하여 유사한 분광각을 지니는 화소들을 군집화한다. 무감독 분광각 분류는 다음의 식을 통해서 화소와 군집의 중심 간의 분광각($\theta_{i,c}$)을 구한다.

$$\theta_{i,c} = \cos^{-1} \left(\frac{\sum_{k=1}^m x_{i,k} \mu_{c,k}}{\sqrt{\sum_{k=1}^m x_{i,k}^2 \sum_{k=1}^m \mu_{c,k}^2}} \right) \quad (1)$$

여기서,

$x_{i,k}$: 임의 화소의 k 밴드 화소값

$\mu_{c,k}$: c 군집 중심의 k 밴드 화소값

m : 밴드 수

분광차원에서 최소 거리 개념(Spectral Distance Rule)을 기반으로 분류를 수행하는 K-means, ISODATA, Hierarchical Clustering 등의 무감독 분류 기법과는 달리 무감독 분광각 분류는 최소 분광각 개념(Spectral Angle Rule)에 근거하여 분류를 수행한다. 그림 1과 그림 2는 최소 거리 개념과 최소 분광각 개념의 차이를 나타내고 있다.

아래의 그림에서 분광 차원에 세 화소(A, B: 군집의 중심(Seed Point), C: 임의의 화소)가 분포하고 있을 때, 최소 거리 법칙에 의하면 B와 C사이의 거리가 A와 C사이의 거리보다 작으므로, C는 B와 동일한 군집으로 분류되는 반면, 최소 분광각 개념에 의하면 A와 C 사이의 분광각이 B와 C 사이의 분광각보다 작으므로, C를 A와 동일한 군집으로 분류된다.

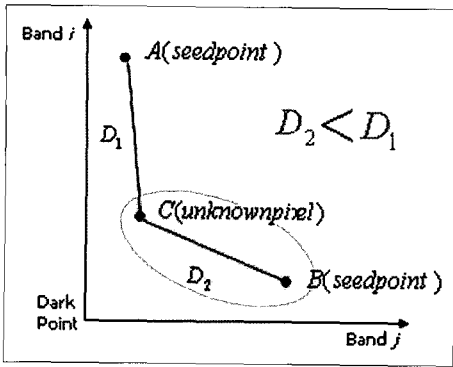


그림 1. Spectral Distance Rule.

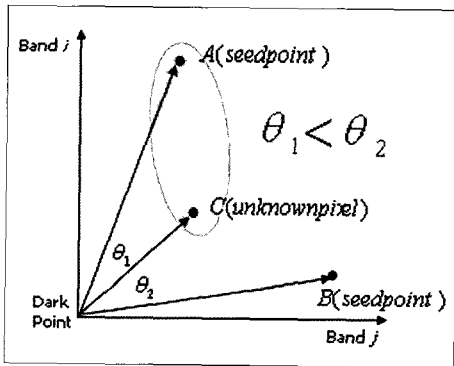


그림 2. Spectral Angle Rule.




그림 3. Poor correlated reflectance spectra (James Norman, 2004).

최소 거리 개념에 근거한 기존의 무감독 분류는 화소값의 분포 형태에 민감하지 못하다는 한계점이 있다. 예를 들어, 그림 3에서 두 대상물의 화소값 분포는 그림 4에서의 두 대상물 사이의 화소값의 분포에 비해 매우 다름에도 불구하고 유클리디안 거리가 0.01 작으므로 동일한 군집으로 분류될 수 있다. 이 때문에 기존의 무감독 분류

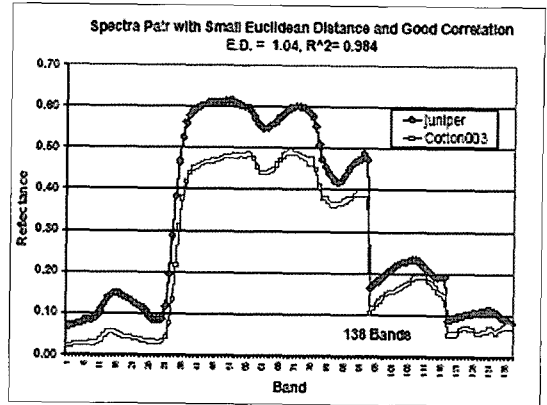


그림 4. Well correlated reflectance spectra (James Norman, 2004).

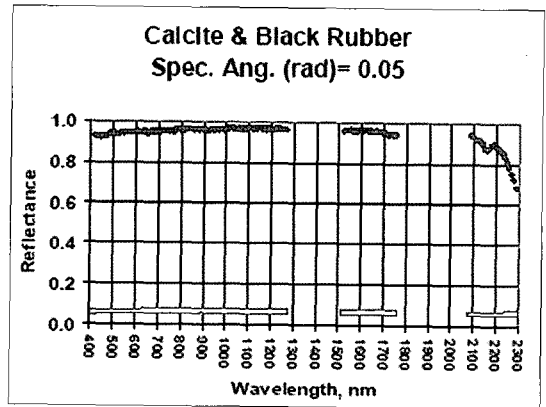


그림 5. The defect of unsupervised spectral angle classification (James Norman, 2004).

는 화소값의 분포를 고려하지 않음으로써, 좁은 폭을 가지는 연속적인 많은 수의 밴드를 가지는 하이퍼스펙트럴 데이터의 특성을 반영하지 못한다는 한계점이 있다.

반면 무감독 분광각 분류는 유사한 분광각을 지니지만, 원점으로부터 거리가 매우 다른 화소를 동일한 군집에 할당하는 한계점이 있다. 그림 5에서 두 대상물은 원점으로부터의 거리는 매우 다르지만, 유사한 분광각 (0.05 rad) 지니기 때문에 무감독 분광각 분류를 수행할 경우 동일한 군집으로 할당된다.

2) 반복최적화 무감독 분광각 분류

반복최적화 무감독 분광각 분류는 최소 분광각 법칙을 기반으로 유사도를 측정한다는 점에서 기존 무감독 분광각 분류와 유사하다고 할 수 있다. 그러나 군집의

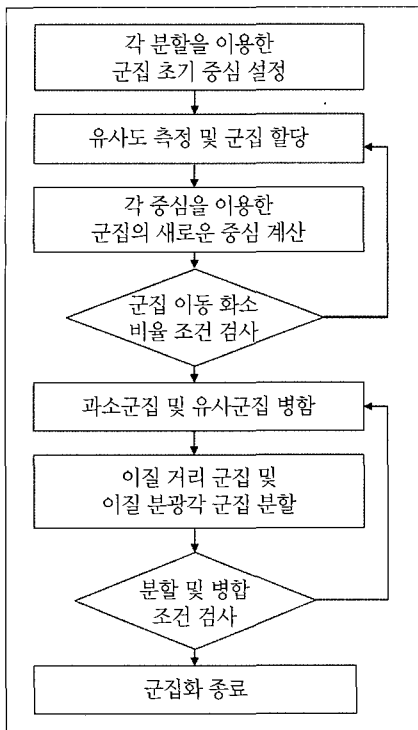


그림 6. Flow chart of ISOMUSAC.

중심을 계산하는 단계에서 무감독 분광각 분류는 거리를 이용하여 군집의 중심을 구한 반면, 반복최적화 무감독 분광각 분류는 각을 이용하여 군집 중심을 구하였다(김대성, 2005). 또한 군집 초기 중심을 설정 시, 각 분할 방법을 적용하고, 군집화 종료 후, 반복최적화 무감독 분류(ISODATA, Iterative Self-Organizing Data Analysis Technique)에 기반한 병합과 분리를 수행함으로써 유동적인 군집 분석을 할 수 있도록 기존의 무감독 분광각 분류를 보완하였다. 반복최적화 무감독 분광각 분류 과정은 그림 6에서 설명하고 있다.

(1) 각 분할 초기 군집 중심 설정

각 분할 방법은 모든 화소에 대해서 각각의 밴드와 화소가 이루는 각 중 최대각과 최소각을 검색하여 최대각과 최소각을 사용자가 지정한 군집의 수만큼 등각으로 분할하여 군집의 초기 중심(Seed Point)을 지정하는 기법이다. 먼저 각 화소가 밴드축과 이루는 각($\theta_{i,k}$)을 계산하여, 각 밴드 축에 대해서 최대각과 최소각을 등각으로 나누어 군집의 초기 중심각($\theta_{c,k}$)을 구한다(식2). 각 밴드 축과 이루는 초기 중심각의 코사인 값을 전체 화소

의 원점으로부터 거리 평균과 곱하여 군집 초기 중심을 구한다(식 7).

$$\theta_{i,k} = \cos^{-1} \left[\frac{x_{i,k}}{\sqrt{\sum_{k=1}^m x_{i,k}^2}} \right] \quad (2)$$

$$\theta_{c,k} = \theta_{\min,k} + \frac{\theta_{\max,k} - \theta_{\min,k}}{n-1} \times (C-1) \quad (3)$$

$$\mu_{c,k} = \text{distancemean} \times \cos(\theta_{i,k}) \quad (4)$$

여기서,

m : 밴드수

n : 사용자가 지정한 군집 수

$x_{i,k}$: i 번째 화소의 k 밴드 화소값

$\theta_{i,k}$: 각 화소가 밴드축과 이루는 각

$\theta_{c,k}$: 군집의 초기 중심각

$$\text{distancemean} = \frac{1}{N} \sum_{i=1}^N \sqrt{\sum_{k=1}^m x_{i,k}^2}$$

(2) 유사도 측정

유사도 측정 단계에서는 최소 분광각 법칙에 근거하여, 먼저 임의의 화소와 군집 중심과의 분광각을 계산한 후, 임의의 화소를 최소 분광각을 가지는 군집에 할당한다. 임의의 화소와 군집 중심과의 분광각($\theta_{i,c}$) 계산은 앞에서 언급한 식 1을 통해서 구할 수 있다.

(3) 군집 중심 계산

기존의 무감독 분광각 분류는 군집 중심을 계산하는 단계에서 유클리디안 거리를 이용한 거리 중심을 계산한 반면, 본 연구에서는 각 중심을 이용하여 군집 중심을 계산하였다. 그림 7와 그림 8는 거리 중심과 각 중심의 차이점을 나타내고 있다.




그림 7. Calculation center of cluster using spectral distance.




그림 8. Calculation center of cluster using spectral angle.




그림 9. Merging insignificantly small clusters.

각을 이용한 군집 중심을 계산은 다음의 식을 통해 수행된다. 먼저 군집에 할당된 화소에 대하여 각 밴드 축과 이루는 각을 계산한 후(식 5), 군집에 할당된 모든 화소의 각 밴드 축과 이루는 각을 평균한다(식 6). 각 밴드 축과 이루는 평균 각의 코사인 값을 군집에 할당된 화소의 원점으로부터 거리 평균과 곱하여 군집 중심을 구한다(식 7).

$$\theta_{i,k} = \cos^{-1} \left[\frac{x_{i,k}}{\sqrt{\sum_{k=1}^m x_{i,k}^2}} \right] \quad (5)$$

$$\mu_{\theta,i,k} = \frac{1}{N_c} \sum_{i=1}^{N_c} \theta_{i,k} \quad (6)$$

$$\mu_{c,k} = \text{distancemean} \times \cos(\theta_{i,k}) \quad (7)$$

여기서,

N_c : 군집에 할당된 화소 수

$$\text{distancemean} = \frac{1}{N} \sum_{i=1}^N \sqrt{\sum_{k=1}^m x_{i,k}^2}$$

(4) 병합

군집화가 종료된 후, 무감독 군집에 포함된 화소수가 매우 작은 경우(과소 군집), 두 군집이 매우 유사한 경우(유사 군집) 병합을 수행한다.

① 과소 군집 병합

군집에 포함된 화소의 수(N_i)가 사용자가 지정한 최소 군집 화소 수($\text{Min } N$) 보다 작은 경우 병합을 수행한다.

$$\text{if } N_i < \text{Min } N \rightarrow \text{Merge} \quad (8)$$

여기서,

N_c : 군집에 포함된 화소수

$\text{Min } N$: 최소 군집 화소 수

이 때 군집에 포함된 화소 각각에 대해서 다른 군집 중심과의 분광각을 계산하여 최소값을 가지는 군집에 할당하게 된다. 그림 9은 과소 군집 병합 과정을 나타내고 있다.

② 유사 군집

두 군집이 매우 유사한 경우 즉, 두 군집 중심간의 분광각(θ_{μ_r, μ_j})이 사용자가 지정한 임계값($\text{Min } \theta_{\mu}$)보다 작은 경우 두 군집을 병합(식 9)한다. 그림 10은 유사 군집 간 병합 과정을 나타내고 있다.

$$\text{if } \theta_{\mu_r, \mu_j} < \text{Min } \theta_{\mu} \rightarrow \text{Merge} \quad (9)$$

여기서,

θ_{μ_r, μ_j} : 두 군집 중심간의 분광각

$\text{Min } \theta_{\mu}$: 사용자가 지정한 최소 군집 중심간 분광각

(5) 분할

한 군집 내에서 원점으로부터의 거리가 이질적인 화소집단이 존재하는 경우(이질 거리 군집) 및 분광각이 이질적인 화소 집단 존재할 경우(이질 분광각 군집) 군집 분할을 수행한다.




그림 10. Merging exceedingly similar clusters.

① 이질 거리 군집 분할

군집에 포함된 화소들의 원점으로부터 거리를 계산하여, 표준편차를 구했을 때 사용자가 지정한 임계값 ($MaxStd(D_i)$) 보다 매우 큰 경우 군집에 포함된 화소들의 원점으로부터 거리를 히스토그램을 생성하였다. 생성된 히스토그램에 대해서 지역적 최대치 필터(Local Maximum Filter) 분석을 수행하여 $Min N/2$ 보다 큰 지역적 최대점이 2개 이상인 경우 지역적 최대점 사이에 있는 최소점(Split Point)에서 분할을 수행한다. 여기서 화소의 원점으로부터 거리는 식 10에 의해 구할 수 있다.

$$D_{x_{i,c}} = \sqrt{\sum_{k=1}^m x_{i,c}^2} \quad (10)$$

$$\text{if } Std(D_{x_{i,c}}) > MaxStd(D_i) \rightarrow \text{Split at Split Point} \quad (11)$$

위의 방법으로 군집 분할을 수행함으로써 유사한 분광각을 가지나 원점으로부터의 거리가 매우 다른 화소를 동일한 군집으로 구분한다는 기존 기법의 단점을 개선할 수 있다. 그림 11은 이질 거리 군집 분할을 나타내고 있으며, 그림 12 거리 히스토그램 분석을 설명하고 있다.




그림 11. Splitting cluster which has dissimilar spectral distance pixels.

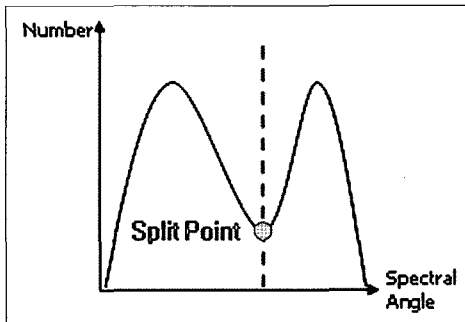


그림 12. Analysis of distance histogram.

② 이질 분광각 군집 분할

군집 내에 포함된 화소와 군집 중심간의 분광각을 계산하여 표준편차를 구했을때, 사용자가 지정한 임계값 ($MaxStd(\theta_i)$)보다 큰 경우 90% 신뢰구간 보다 큰 분광각을 가지는 화소들을 미분류 군집으로 분할한다. 이후 각각의 군집 중심을 재계산후, 미분류 군집의 재할당을 수행한다. 이때 화소와 군집 중심 간의 분광각은 식 1을 통해서 구하며, 식 12에 의해 이질화소를 분할하게 된다.

$$\text{if } Std(\theta_i) > MaxStd(\theta_i) \rightarrow \text{Split at } (mean(\theta_{i,c}) + 1.96 Std(\theta_{i,c})) \quad (12)$$

다음 그림 13은 이질 분광각 군집 분할을 나타내고 있다.




그림 13. 이질 분광각 군집 분할.

(6) 군집 유효성 지수

군집 유효성 지수는 군집 결과의 밀집도(Compactness)와 분리도(Seperability)를 평가하는 지수로 기존의 군집 유효성 지수는 D 지수(Dunn, 1974), DB 지수(Davis, 1979), S_Dbw 지수(Halkidi, 2001) 등이 있으나(Halkidi 2001), 이는 유클리디안 거리를 이용한 것으로, 분광각을 이용한 분류의 군집 유효성을 평가하는데 적합하지 않다. 때문에 본 연구에서는 무감독 분광각 분석의 군집 유효성을 평가하기 위하여 분광각을 이용한 새로운 군집 유효성 지수(SAVI, Spectral Angle Validity Index)를 제안하였다. 제안된 군집 유효성 지수는 다음과 같다.

$$SAVI = \frac{1}{K(K-1)/2} \sum_{k=1}^{K-1} \sum_{kk=k+1}^K \frac{\max(\theta_{C_k}) + \max(\theta_{C_{kk}})}{(\theta_{C_k C_{kk}})} \quad (13)$$

여기서,

θ_{C_k} : k번째 군집에 포함된 화소 간 분광각

$\theta_{C_k C_{kk}}$: k번째 군집과 kk번째 군집 중심 간 분광각


3. 알고리즘의 적용 및 결과

1) 사용 데이터

본 연구에서는 EO-1에 탑재된 Hyperion 센서에 의해 취득된 영상을 데이터로 사용하였다. Hyperion 센서는 pushbroom 방식 센서로 약 7.7km 관측 폭을 가지고, 30m 공간해상도와 0.4 μ m~2.5 μ m의 분광해상도를 가지며, 242개의 밴드로 구성되어 있다. 242개의 밴드 중 Null 밴드를 제외한 194개의 밴드를 추출하였다. 대상 지역은 안양, 서울 지역으로 2004년 4월 3일에 취득된 영상이다. 그림 14는 대상 지역의 Hyperion 영상이다.

2) 연구 결과

제안된 알고리즘의 유효성을 검증하기 위해 세 가지 방법으로 그 결과를 분석하였다. 우선 군집 초기 중심 설정에 있어 각분할 방법이 더 효과적인지 안양지역 영상에 대해 시각적인 분석과 반복 연산 횟수를 단일 패스 방법(Single Pass) 및 범위 분할 방법(Range Division)과 비교해 보았다. 다음으로 반복최적화 무감독 분광각 분류가 K-means 및 기존 무감독 분광각 분류보다 우수한 결과를 도출할 수 있는지 시각적, 정량적으로 평가하였으며, 끝으로 기존의 무감독 분광각 분류 기법과 군집 유효성 지수를 이용한 정량적 평가를 수행하였다.



(a) 안양 지역

(b) 서울 지역

그림 14. Hyperion scenes of study areas.

(1) 각분할 군집 초기 중심 설정 결과

군집 초기 중심 설정에 있어서 군집 개수를 11개부터 20개까지 증가시켜가면서 각분할 방법, 단일 패스 방법, 범위 분할 방법의 반복 연산 횟수를 비교하였으며, 군집 개수 12개에 대해서 수계 지역 분류 결과를 시각적으로 비교해보았다. 단일 패스 방법은 영상의 첫 행에서 사용자가 지정한 군집 수만큼의 화소를 초기 중심으로 지정 하는 방법으로, 연산 횟수가 적다는 장점이 있으나, 영상의 첫 행의 화소본포에 분류 결과가 영향을 받는다는 한계점이 있다. 범위 분할 방법은 영상 화소가 가지는 최대 값과 최소 값을 사용자가 지정한 군집 수로 분할하여 군집 초기 중심을 지정하는 방법으로 가장 일반적으로 사용되고 분류 정확도는 높으나, 분광각 분류 적용 시 반복 연산 횟수가 증가하는 한계점이 있다.

표 1은 군집 개수에 따른 각분할 방법, 단일 패스 방법, 범위 분할 방법의 반복 연산 횟수이다.

반복 연산 횟수 비교 결과 각 분할 방법은 단일 패스 방법에 비해 반복 연산 횟수가 약 16% 감소되었으며, 범위 분할 방법에 비해 약 26% 감소된 것을 확인할 수 있었다.

단일 패스 방법, 범위 분할 방법, 각분할 방법을 수계 지역에 시각적으로 비교해본 결과 단일 패스 방법은 도시 지역 어두운 부분이 수계 지역으로 오분류가 발생하였으며, 범위 분할 방식과 각분할 방식은 수계지역을 잘 분류하였으나, 연산 횟수에 있어서 각분할 방식이 보다 효율적임을 확인할 수 있었다. 그림 15는 단일 패스 방법, 범위 분할 방법, 각분할 방법을 안양 수계 지역에 시각적으로 비교해본 결과이다.

표 1. Comparison of iteration number.

| 군집개수 | 단일패스 | 범위분할 | 각분할 |
|------|------|------|-----|
| 11 | 35 | 44 | 33 |
| 12 | 33 | 42 | 25 |
| 13 | 29 | 32 | 28 |
| 14 | 33 | 34 | 23 |
| 15 | 34 | 40 | 29 |
| 16 | 31 | 34 | 26 |
| 17 | 38 | 39 | 24 |
| 18 | 36 | 40 | 34 |
| 19 | 35 | 39 | 31 |
| 20 | 34 | 40 | 30 |




그림 15. Result of classification (Anyang City).




그림 16. Classification results of water class (Anyang City).

(2) 반복최적화 무감독 분광각 분류 결과

① 시각적 평가

반복최적화 무감독 분광각 분류 결과의 유효성을 검증하기 위해서 K-Means 및 기존의 무감독 분광각 분류 결과와 반복 최적화 무감독 분광각 분류 결과를 시각적으로 분류해 보았다. 이를 위하여 안양 지역에 대해서는 수계 및 나대지 영역을, 서울 지역에 대해서는 수계 지역을 위주로 평가하였다.

먼저 안양 지역의 경우, K-Means 분류는 어두운 산림 지역과 수계 지역을 구분하지 못하는 데 반해 기존의 무감독 분광각 분류와 반복최적화 무감독 분광각 분류는 수계 지역을 잘 구분한 것을 확인할 수 있었다. 반면, 나대지의 경우 기존의 무감독 분류는 밝은 산림 지역이 나대지 지역에 포함되었으나, 반복 최적화 무감독 분광각 분류 기법에서는 나대지 지역과 밝은 산림 지역이 구분된 것을 확인할 수 있었다. 그림 16와 그림 17는 안양 지역에 대한 각각의 분류 기법의 수계 지역 및 나대지 분류 결과이다.

다음 서울 지역의 경우, K-Means와 기존 무감독 분광각 분류, 반복 최적화 무감독 분광각 분류 모두 수계 지역을 잘 분류했으나, K-Means 분류 결과에서는 수계로 분류된 군집에 약간의 도시 지역이 포함된 것을 확인할 수 있었다. 그림 18은 서울 수계 지역에 대한 각각의 분류 기법의 결과이다.

② 정량적 평가

반복 최적화 무감독 분광각 분류 결과를 K-means




그림 17. Classification results of soil class (Anyang City).






그림 18. Classification results of water class (Seoul City).



(a) (b) (c) (d)
최대 우도 최소 거리 Mahalanobis 분광각

그림 19. Results of supervised classification (Anyang City).




(a) (b) (c) (d)
최대 우도 최소 거리 Mahalanobis 분광각

그림 20. Results of supervised classification (Seoul City).


및 기존 무감독 분광각 분류 결과와 정량적으로 비교하기 위한 검증 데이터를 추출하기 위해 먼저 감독 분류 방법 중 최대 우도 분류, 최소 거리 분류, Mahalanobis 분류, 분광각 분류를 수계, 나대지, 밝은 산림, 어두운 산림, 도시의 5개 클래스에 대해서 수행하였다. 4가지 감독 분류 결과에서 모두 동일한 클래스로 분류된 화소들을 검증점(Check Point)으로 추출한 결과 안양지역 영상에서는 총 59833개, 서울 지역 영상에서는 총 73274개의 검증점이 추출되었다. 그림 19는 안양 지역 감독 분류 결과이며, 그림 20은 서울 지역 감독 분류 결과이다.

추출된 검증점들을 기준 자료로 하여 두 대상 영상의 분류 정확도(Overall Accuracy)를 측정하여 결과를 평가하였다. 안양 지역에 대해서 반복 최적화 무감독 분광각 분류 결과의 정확도가 기존의 무감독 분광각 분류 결과보다 약 4%, K-Means 결과보다 약 6% 높았으며, 서울 지역에 대해서는 반복 최적화 무감독 분광각 분류의



(a) K-Means (b) USAC (c) ISOMUSAC

그림 21. Results of unsupervised classification (Anyang City).



(a) K-Means (b) USAC (c) ISOMUSAC

그림 22. Results of unsupervised classification (Seoul City).

정확도가 기존 무감독 분광각 분류 결과보다 약 3%, K-Means 분류 결과 보다 약 0.2% 더 높음을 확인하였다.

그림 21은 안양 지역에 대한 K-Means, 기존 무감독 분광각 분류, 반복최적화 무감독 분광각 분류를 결과이며, 그림 22는 서울 지역에 대한 K-Means, 기존 무감독 분광각 분류, 반복최적화 무감독 분광각 분류를 결과이며, 표 2는 정확도 평가 결과이다.

다음으로, 군집의 이동 화소 비율을 측정하여 반복

표 2. Accuracy of classification results.

| Accuracy | K-Means | USAC | ISOMUSAC |
|----------|---------|--------|----------|
| 안양 지역 | 75.79% | 77.36% | 81.26% |
| 서울 지역 | 84.94% | 82.47% | 85.18% |




그림 23. Comparison of astringency (Anyang City).




그림 24. Comparison of astringency (Seoul City).

표 3. Analysis of validity index.

| | 안양 지역 | | 서울 지역 | |
|------|--------|----------|--------|----------|
| | USAC | ISOMUSAC | USAC | ISOMUSAC |
| SAVI | 2.6941 | 2.5745 | 2.0632 | 1.0826 |
| DB | 9.4664 | 7.7229 | 7.6170 | 6.3225 |

최적화 무감독 분광각 분류 기법과 기존 무감독 분광각 분류 기법 그리고 K-Means 분류 기법의 수렴성을 비교해본 결과, 반복 최적화 무감독 분광각 분류의 경우 기존 무감독 분광각 분류와 K-Means 분류보다 높은 수렴성을 나타내는 것을 확인할 수 있었다. 그림 23은 안양 지역에 대해서 수렴성을 비교한 그래프이며, 그림 24는 서울 지역에 대해서 수렴성을 비교한 그래프이다.

끝으로, 반복 최적화 무감독 분광각 분류 기법과 기존 무감독 분류 기법을 제안된 유효성 지수(SAVI) 및 기존 군집 유효성 지수 중 DB 지수를 통해 두 지역에 대해서 비교해보았다. 그 결과 과천 지역에 대해서 반복 최적화 무감독 분광각 분류 기법의 SAVI가 기존의 무감독 분광각 분류 결과 보다 약 0.12 감소된 것을 알 수 있었으며, DB 지수의 경우 약 1.7이 감소된 것을 확인할 수 있었다. 또한 서울 지역에 대해서 반복 최적화 무감독 분광각 분류 기법이 제안된 유효성 지수에 있어서 약

1.2, DB 지수의 경우 약 1.3이 감소된 것을 확인할 수 있었다. 이를 통해서 반복 최적화 무감독 분광각 분류 기법이 기존의 무감독 분류 기법보다 밀집도 및 분리도가 우수한 것을 확인할 수 있었다.

4. 결론

본 연구에서는 분광각 분류 기법을 기반으로 각 분할 군집 초기 중심 설정, 각을 이용한 군집 중심 계산 및 병합과 분할 과정을 적용함으로써, 기존 무감독 분광각 분류를 보완한 개선된 무감독 분광각 분류 알고리즘을 제안하고, 무감독 분광각 분류 결과를 평가하기 위한 분광각 군집 유효성 지수를 제시하였다.

연속적인 많은 수의 밴드를 가지는 하이퍼스펙트럴 데이터는 높은 분광 해상도로 인해 감독 분류 수행 시 신뢰도가 낮은 트레이닝데이터를 취득할 경우 분류 결과의 정확도를 신뢰할 수 없게 되므로 본 논문에서는 트레이닝 데이터를 필요로 하지 않는 무감독 분류에 관한 연구를 수행하였다.

무감독 분류 시 분류 정확도에 큰 영향을 미치는 군집 초기 중심 설정에 있어서, 본 연구는 각 분할 기법을 제안하고 이의 계산 효율 및 시각적 평가를 수행하여 유효성을 검증하였다. 또한, 기존의 무감독 분광각 분류 기법은 군집 중심을 계산하는 데 있어서 거리 중심을 사용한 데 반해 제안한 기법에서는 각을 이용한 군집 중심 계산을 수행함으로써 완전한 각 기반의 무감독 분류 기법을 적용하였다. 더불어 ISODATA 분류 기법에 기반한 병합과 분할 과정을 추가하여 유사한 분광각을 가지나 원점으로부터 매우 다른 화소들을 동일한 군집에 할당하는 기존의 무감독 분광각 분류의 한계점을 보완하였다.

제안한 기법의 검증을 위해 안양과 서울 지역의 Hyperion 영상을 대상으로 분류를 수행하고, 그 결과를 K-Means 및 기존의 무감독 분광각 분류 결과와 비교 평가 하였다.

시각적 평가에 있어서 K-Means와 기존의 무감독 분광각 분류가 수계와 어두운 산림 혹은 내대지와 밝은 산림 지역을 잘 구분하지 못하는데 비해, 제안한 반복 최적화 무감독 분광각 분류는 보다 개선된 결과를 도출

하였다. 또한 정량적 평가를 위해 분류 정확도 및 본 연구에서 제안한 군집 유효성 지수(SAVI)와 기존의 군집 유효성 지수(DB) 평가를 수행한 결과 제안한 기법이 모든 평가에서 가장 우수한 결과를 나타냄을 확인하였다.

본 연구를 통해 기존의 하이퍼스펙트럴 영상 분류 기법들의 단점을 보완하고, 정확도와 안정성을 향상시킨 반복 최적화 무감독 분광각 분류 기법을 제안하였다. 제안한 기법의 신뢰도를 높이기 위해 우선 하이퍼스펙트럴 밴드 추출에 관한 연구가 필요하다. 또한 향후 보다 다양한 하이퍼스펙트럴 영상에 적용하고 평가해보는 작업이 필요하며, 대상 지역에 대한 분광 정보 획득을 통해 정확한 기준 데이터를 이용한 정확도 평가가 요구된다. 이와 더불어 사용자의 개입을 최소화하기 위해 분할과 병합과정에 있어서 임계값 설정의 자동화가 필요하다.

참고문헌

- 김대성, 김용일, 2005. "The Modified Unsupervised Spectral Angle Classification (MUSAC) of Hyperion, Hyperion-FLAASH and ETM+ Data Using Unit Vector", ISRS, 134-137.
- 조현기, 김대성 김용일, 2005. "반복최적화. 무감독 분광각 분류 기법을 이용한 하이퍼스펙트럴 영상 분류에 관한 연구", 한국공간정보시스템학회 추계학술대회, 36-41.
- Arel Weisberg, Michelle Najarian, Brett Borowski, Jim Lisowski, and Bill Miller, 1999. "Spectral Angle Automatic cLuster rouTine(SAALT): An Unsupervised Multispectral Clustering Algorithm", Aerospace Conference, IEEE, 4: 307-317.
- Davis, D. L. and Bouldin, D. W., 1979. "A Cluster Separation Measure", IEEE, 4: 95-104.
- Granahan J. C. and Sweet J. N., 2001. "An Evaluation of Atmospheric Correction Techniques Using the Spectral Similarity Scale", IEEE 2001 International. Geoscience and Remote Sensing Symposium, 5: 2002-2024.
- John R. Jensen, 2004. "Introductory Digital Image Processing", Pearson Education, NJ, USA, 450-453.
- James Norman, 2003. "The Spectral Similarity Scale and its Application to the Classification of Hyperspectral Remote Sensing Data", IEEE Work Shop, 92-99.
- Kai-Yi Huang, 2002. "A Synergistic Automatic Clustering Technique (SYNERACT) for Multispectral Image Analysis", PE & RS, ASPRS, 68(1): 33-49.
- Maria Halkidi, Yannis Batistakis, and Michalis Vazirgiannis, 2001. "On Clustering Validation Techniques", JIIS (Journal of Intelligent Information System), 17: 107-145.
- S. Phillips, 2002. "Reducing the Computation time of the ISODATA and K-means unsupervised classification algorithms", in Proc. 22nd IEEE International. Geoscience. and Remote Sensing Symposium, 3: 1627-1629.
- T. Kanungo, D. M. Dount. N. S. Netanyahu, C. Piatko, R. Silverman, and A. Y. Wu, 2002. "An Efficient K-means Clustering Algorithm: Analysis and Implementation", IEEE Trans, Pattern Anal. Mach, Intel., 24: 881-892.
- Youngsinn Sohn and N. Sanjay Rebello, 2002. "Supervised and Unsupervised Spectral angle Classification", PE & RS, ASPRS, 68(12): 1271-1280.