

독립 요소 분석 기반의 KOMPSAT EOC영상 무감독 분류

Unsupervised Classification of KOMPSAT EOC Imagery Based on Independent Component Analysis

변승건 · 이호영 · 이쾌희

Seung-Gun Byoun, Ho-Yong Lee, and Kwae-Hi Lee

서강대학교 전자공학과

서울시 마포구 신수동 1, 121-742

Tel : +82-02-704-4088, FAX : +82-02-704-4088

E_mail : seungun@eerobot1.sogang.ac.kr, lhy2502@eerobot1.sogang.ac.kr

요약: 독립 요소 분석 (Independent Component Analysis: ICA)는 텍스처를 의미 있는 특징으로 변환하는 강인한 영상 필터를 생성하기 위한 확률적 방법이다. ICA는 고차 통계적 특성을 사용하여 ICA 필터와 독립 요소를 동시에 학습한다. 제안한 분류 방법은 fast ICA 알고리즘을 사용하여 KOMPSAT 영상으로부터 ICA 필터를 생성한 다음, 필터에 의해 투영된 텍스처들의 특징들을 독립 평면상에서 무감독 방법으로 분류한다. KOMPSAT 영상은 텍스처 성분이 뚜렷하지 않는 영역이 존재하기 때문에 본 논문에서는 투영된 특징 값들과 윈도우 내의 정규화된 평균 화소값으로 특징 벡터를 재구성 하였다. 분류 방법으로는 K-means 클러스터링을 적용하였다. 6.6m 해상도를 가진 KOMPSAT 흑백 영상에 대해 제안한 방법은 우수한 분류 성능을 보인다.

1. 서론

흑백 위성영상의 텍스처 특징을 추출하기 위해 본 논문에서 적용한 방법은 독립 요소 분석(ICA)이다. ICA는 관찰된 영상 신호에 대해 상호간의 통계적 의존성을 없애거나 최소화된 선형 조합으로 변환시키는 방법이다 [6]. Central limit 이론에 의해 독립 변수들 합은 가우시안 분포를 가지게 되며, ICA는 이러한 가우시안 특성을 가진 mixing 데이터

에서 비가우시안 특성이 최대가 되도록 하여 상호간에 의존성이 없는 독립 요소를 추출하는 수학적 기법이다. 현재까지 흑백 영상에서 추출한 ICA필터를 사용하여 영상 분류한 예는 매우 드물다 [10] [3].

제안한 위성영상 분류 방법은 크게 전처리, ICA기반의 필터 추출, 테스트 영상에 대한 분류 등 세 단계로 구성 된다. 전처리 과정에서는 인접한 화소의 대비를 강조하고 텍스처의 특징을 최대화 하고자 KOMPSAT 전체 영상에 대해 샤프닝을

수행한다 [5].

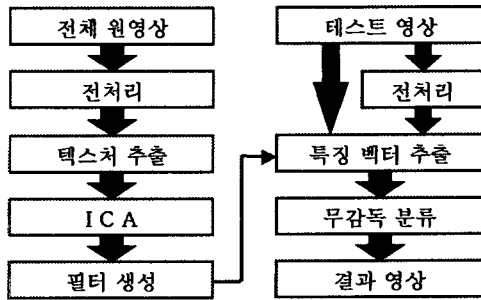


Fig.1. Flowchart of classification system

다음 단계에서는 샤프닝을 수행한 전체 영상에서 얻은 텍스처 샘플에 대해 ICA를 수행하여 필터를 생성한다. 마지막 분류 단계에서는 테스트 영상과 샤프닝된 테스트 영상이 동시에 입력이 되어, 이전 단계에서 구한 ICA 필터를 이용하여 분류될 특징 벡터를 생성하며, K-means 클러스터링 방법을 적용하여 최종적으로 특징 벡터들을 분류한다.

본 논문의 구성은 다음과 같다. 2장에서는 비가우시안 성분을 최대화하여 mixing된 신호를 독립적인 신호로 변환시키는 ICA의 수학적 개념에 대해서 소개한다. 3장에서는 영상에서 랜덤하게 얻어진 텍스처들로부터 ICA필터를 생성하는 방법을 보인다. 또한 식별력 있는 ICA필터의 개수를 선택하는 방법을 소개하고, 필터에 의해 얻어지는 특징값과 화소들의 정규화된 평균값을 사용하여 분류될 특징 벡터를 재구성하는 방법을 소개한다. 4장에서는 제안한 흑백 위성 영상 분류 방법의 분류 성능을 보였으며, 마지막으로 5장에서는 결론 및 추후 과제로 끝을 맺었다.

2. 독립 요소 분석

관찰된 랜덤 벡터가 \mathbf{x}_{obs} 이고, 독립적인 소스 벡터가 $\mathbf{s} = [s_1, s_2, \dots, s_n]^T$ 이면, ICA 선형 모델은 다음과 같다 [8].

$$\mathbf{x}_{obs} = \mathbf{A}\mathbf{s} \quad (1)$$

$$\mathbf{s} = \mathbf{W}\mathbf{x}_{obs} \quad (2)$$

주어진 \mathbf{x}_{obs} 만으로 독립 소스 벡터 \mathbf{s} 와 mixing 행렬 $\mathbf{A} (m \times n)$, 또는 separating 행렬 $\mathbf{W} (n \times m)$ 를 추정하는 것이 ICA이다. 식 (1)에서 \mathbf{x}_{obs} 는 각 기저벡터 $\mathbf{a}_i (i=1, \dots, n)$ 와 대응되는 독립 소스 벡터의 요소 s_i 의 선형 조합으로 표현된다. 유사하게 식 (2)에서 독립 요소 s_i 는 \mathbf{W} 의 행 벡터와 \mathbf{x}_{obs} 의 행렬 곱으로 생성되며 $\mathbf{w}_i^T (i=1, \dots, m)$ 가 \mathbf{x}_{obs} 를 독립 평면에 투영시키는 ICA 필터가 된다.

독립 요소 추정을 위해 식 (2)로부터 (편의상 \mathbf{x}_{obs} 를 \mathbf{x} 라 표기함) 추정치 y 는 다음과 같은 선형 조합으로 표현될 수 있다 [6].

$$y = \mathbf{w}_i^T \mathbf{x} = \mathbf{w}_i^T \mathbf{A}\mathbf{s} = \mathbf{z}^T \mathbf{s} \quad (3)$$

여기서, $\mathbf{z} = \mathbf{A}^T \mathbf{w}_i$ 이며, 추정된 하나의 독립 요소 y 는 가중치 벡터 \mathbf{z}^T 와 원래의 내재된 독립 요소 s_i 의 선형 결합으로 표현된다.

$\mathbf{w}_i^T \mathbf{x}$ 의 비가우시안 특성을 최대화 하면서 \mathbf{z}^T 가 하나의 '0'이 아닌 요소를 갖도록 하는 것이 ICA의 목적이며, 이때 추정치 y 가 하나의 내재된 독립요소에 대응 되게 된다. m 차원 벡터 \mathbf{w}_i^T 의 비가우시안

특성은 두개의 독립 요소 $-s_i$ 와 s_i 에 대응되는 $2m$ 개의 local maxima를 가지게 되므로 독립 요소의 부호는 변할 수 있다.

본 논문에서 사용한 fast ICA 알고리즘은 비가우시안을 측정하기 위해 negentropy의 특성을 사용한다 [9]. 최대 엔트로피 기반의 근사화된 방법을 사용하며 하나의 nonquadratic 함수 G_i 를 사용할 경우는 아래와 같은 근사화된 식으로 표현 될 수 있다 [7].

$$J(y) \propto [E\{G(y)\} - E\{G(v)\}]^2 \quad (4)$$

여기서, v 는 0의 평균과 1의 분산을 가진 가우시안 변수이다. Negentropy를 근사화 한 식 (4)는 빠른 계산 시간을 가지며, 다음의 G 함수를 선택 할 수 있다 [6].

$$G_1(y) = \frac{1}{a_1} \log \cosh(a_1 y) \quad (5)$$

$$G_2(y) = -\exp\left(\frac{-y^2}{2}\right)$$

식 (5)에서 a_1 은 상수로써 $1 \leq a_1 \leq 2$ 구간에서 정의 되나 보통 1을 사용한다. 독립 성분의 비상관 관계는 0의 평균을 가지는 변수가 입력일 경우 기본적인 요구 조건이다. ICA의 전처리로 입력 랜덤 벡터들은 0의 평균을 가지고 비상관 관계가 되기 위해 whitening을 수행하게 된다. Whitening은 eigenvector (\mathbf{E})와 eigenvalue (\mathbf{D})를 이용하여 수행 될 수 있으며, whitened된 데이터 벡터 \mathbf{v} 는 다음과 같다.

$$\mathbf{v} = \mathbf{D}^{-1/2} \mathbf{E}^T \mathbf{x} \quad (6)$$

행렬 $\mathbf{V} = \mathbf{D}^{-1/2} \mathbf{E}^T$ 는 whitening 행렬이며 \mathbf{v} 는 whitening 행렬 \mathbf{V} 를 이용하여 식 (1)에서 보였던 ICA 선형 모델은 다음과 같이 표현될 수 있다.

$$\mathbf{v} = \mathbf{V}\mathbf{x} = \mathbf{V}\mathbf{A}\mathbf{s} = \mathbf{B}\mathbf{s} \quad (7)$$

nonquadratic 함수 G 의 도함수를 g 라 하면 식 (5)의 도함수는 아래와 같다.

$$\begin{aligned} g_1(y) &= \tanh(a_1 y) \\ g_2(y) &= y \exp(-y^2/2) \end{aligned} \quad (8)$$

Fast ICA 알고리즘은 다음과 같이 수행된다.

- ① 가중 벡터 \mathbf{b} 의 초기 값을 랜덤하게 결정한다.
- ② $\mathbf{b}^+ = E\{\mathbf{v}g(\mathbf{v}^T \mathbf{b})\} - E\{g'(\mathbf{v}^T \mathbf{b})\}\mathbf{b}$
- ③ $\mathbf{b} = \mathbf{b}^+ / \|\mathbf{b}^+\|$
- ④ 만약 수렴하지 않았다면 ②로 다시 돌아간다.

여기서, 수렴이라는 말은 이전 \mathbf{b}^- 와 \mathbf{b} 가 같은 방향을 가질 때 이다. 위의 반복 수행 알고리즘은 한 개의 벡터 \mathbf{b} 를 찾기 위해 수행 되는 것이다. 만일 여러 개의 \mathbf{b} 를 동시에 구하려면, 같은 local maxima를 찾는 것을 방지 하기 위해 모든 반복 때마다 새롭게 생성된 독립 요소가 이전에 생성된 독립 요소와의 직교화(orthogonalization) 제약 조건을 두면서 독립 요소들을 찾는다. 이전에 찾아진 독립 요소의 상관성을 없애기 위한 직교화 방법은 다음과 같다 [8].

$$\mathbf{B} = (\mathbf{B}^T \mathbf{B})^{-1/2} \mathbf{B} \quad (9)$$

매 반복 수행마다 직교화를 위해 추정된 \mathbf{B} 에 대해 위의 식이 수행된다.

3. 제안한 흑백 위성영상 분류 방법

ICA 필터를 추정하기 위해서 KOMP-SAT 전체 영상에서 10,000개의 샘플을 취하여 훈련 DB (Database) \mathbf{X} 의 열 벡터를 구성하였다. 프로그램의 수행 시간을 단축하기 위해 m 개 ($m < n_r$)의 PC기저 벡터에 의해 PC평면에 투영된 계수들이 ICA의 입력으로 사용된다. SVD (Singular Value Decomposition)의 수행으로부터 얻어진 \mathbf{U}_m 을 최대한값에 대응되는 m 개의 PC기저 벡터로 표기하면, 훈련 DB \mathbf{X} 는 다음과 같이 표기 할 수 있다.

$$\begin{aligned} \mathbf{X} &= \mathbf{U}_m \mathbf{D}_m \mathbf{V}_m^T \\ \mathbf{R}_m &= \mathbf{U}_m^T \mathbf{X} \end{aligned} \quad (10)$$

PC평면에 투영된 계수 행렬 \mathbf{R}_m 이 필터를 추출하기 위한 ICA의 입력이 되며, ICA를 수행하기 전에 \mathbf{R}_m 은 각 행벡터가 0의 평균을 가지도록 변형된다. 입력 $\mathbf{R}_m - \bar{\mathbf{R}}_m^{row}$ 은 ICA에 의해 다음과 같이 분해 된다.

$$\begin{aligned} \mathbf{R}_m - \bar{\mathbf{R}}_m^{row} &= \mathbf{A} \mathbf{S} \\ \mathbf{W}(\mathbf{R}_m - \bar{\mathbf{R}}_m^{row}) &= \mathbf{S} \end{aligned} \quad (11)$$

여기서, $\bar{\mathbf{R}}_m^{row}$ 은 각 행벡터의 평균값으로 구성된 벡터이다. ICA 알고리즘은 ICA 필터 \mathbf{W} 를 통해 입력 텍스처들이 독립적인 특징 \mathbf{s} 가 되도록 수행 된다. 분류될 영상의 모든 위치에서의 윈도우 텍스처를 벡터 \mathbf{x}_{Test} 라 하면, \mathbf{x}_{Test} 와 ICA 필터와의 내적으로 얻어지는 독립

특징 벡터 \mathbf{s}_{Test} 는 다음과 같이 얻어 질 수 있다.

$$\mathbf{W}(\mathbf{U}_m^T \mathbf{x}_{Test} - \bar{\mathbf{R}}_m^{row}) = \mathbf{s}_{Test} \quad (12)$$

효율적인 식별자로써의 필터 개수 m 를 선택하기 위해 본 논문에서 사용한 방법은 다음과 같다 [4].

$$\sigma_{between} = \sum_i (\bar{\mathbf{S}}_i - \bar{\mathbf{S}})^2 \quad (13)$$

$$\sigma_{within} = \sum_i \sum_j (\mathbf{S}_{ij} - \bar{\mathbf{S}}_i)^2 \quad (14)$$


$$r = \frac{\sigma_{between}}{\sigma_{within}} \quad (15)$$

$\bar{\mathbf{S}}$ 는 전체 훈련 텍스처들로 산출된 독립 성분들에 대한 평균이고 $\bar{\mathbf{S}}_i$ 는 i 번째 독립 벡터에 대한 계수들의 평균이다. 본 실험에서는 식 (15)에 따라 가장 효율적인 필터의 개수를 $m = 100$ 으로 고정하였다.

제안한 위성영상 분류 방법에서는 가장 큰 3개의 독립 특징 값들과 윈도우 내의 화소값을 고려하여 다음과 같이 분류될 특징 벡터를 재구성 하였다.

$$\begin{aligned} \mathbf{s}_{new} &= [s_{max1} \quad s_{max2} \quad s_{max3} \quad \bar{\mathbf{x}}_{Test}]^T \\ [s_{max1}, s_{max2}, \Lambda, s_{maxm}]^T &= sort(\mathbf{s}) \end{aligned} \quad (16)$$


$[s_{max1}, s_{max2}, \Lambda, s_{maxm}]^T$ 는 독립 특징 벡터 \mathbf{s} 의 요소들을 내림차순으로 정렬한 벡터이고, $\bar{\mathbf{x}}_{Test}$ 는 테스트 윈도우 내의 정규화된 평균 화소값이다. 테스트 영상의 각 좌표에서 새로운 특징 벡터 \mathbf{s}_{new} 가 생성되며, K-means 클러스터링 방법을 이용하여 최종적으로 특징 벡터들을 분류 하게 된다.



(a) Test Image1



(b) Test Image2



(c) Test Image3

Fig.2. Original images and classified images by proposed method

Table.1. Classification accuracy for randomly acquired samples

Image Num	Test Image1					Test Image2			Test Image3		
Class Num	Class1	Class2	Class3	Class4	Class5	Class1	Class2	Class3	Class1	Class2	Class3
Num of Sample	198	279	210	195	18	315	297	288	207	510	183
Accuracy (%)	86.4	83.9	83.1	87.7	83.3	92.7	91.9	89.4	88.4	82.7	86.9

4. 실험 결과

실험에 사용한 영상은 2000년 3월 1일 취득 된 청주지역 영상이며 분류를 위해 400×400의 크기의 총 3장의 테스트 영상이 사용되었다. 그리고 23x23 크기의 윈도우를 사용하였다. 분류성능을 측정하기 위해서 테스트 영상에서 랜덤 하게 900개의 좌표에 대해 할당된 클래스의 정확성을 평가 하였다.

Fig.2. (a)의 테스트 영상1은 산림, 대지, 도심지 등이 함께 존재하는 영상이다. 5개의 클래스로 분류하였으며 Class1은 산림에 대한 영역, Class2는 산 경계 부위에 존재하는 초지, Class3는 대지, Class4는 낮은 건물이 분포하는 도심지역, Class5는 아파트와 같은 높은 건물이 존재하는 도심지역을 나타낸다. 분류된 영상에서는 직사각형 모양의 아파트가 비교적 잘 검출 됨을 확인할 수 있다. 그러나 낮은 건물이 있는 도심지역 중에 텍스처 성분이 거의 없고 화소값도 초지와 비슷한 지역은 Class2로 잘못 분류된 지역이 다소 존재한다. (b)의 테스트 영상2는 대체적으로 산림, 초지, 농경지와 약간의 주거지가 존재하는 영상이다. 3개의 클래스로 영상을 분류 하였으며 Class1은 산림, Class2는 초지, Class3는 농경지 및 약간의 주거지를 나타낸다. 실험 영상을 5개의 클래스로 분류하였을 때는 주거지의 분포가 하나의 클래스로 검출 되나 너무 세밀한 분류로 인해 테스트 샘플에 대한 분류 성능이 다소 저하된 결과를 보였다.

(c)의 테스트 영상3은 산림, 농경지 및 대지, 도심지가 존재하는 영상이다. Class1은 산림, Class2는 농경지 및 대지, Class3은 도심지의 분포를 나타낸다. 영상에서 알 수 있듯이 농경지와 도심에 약간 존재하는 대지와는 시각적으로 구분하기가 매우 애매하다. 따라서 Class2는 농경지와 약간의 대지를 동시에 포함한다.

5. 결론

세 장의 테스트 영상에 대해 제안한 방법은 우수한 분류 성능을 보였으며, 특히 여러 종류의 텍스처가 존재하는 도심지에서 아파트와 같은 높은 건물이 분류된 것은 특이 할만 하다. 또한 이 방법은 특별히 고정해야 할 임계값이 없기 때문에 일반적으로 사용하기가 용이하다. 다른 향상된 무감독 분류 알고리즘의 적용은 더욱 우수한 결과를 산출할 수 있을 것으로 기대된다. 또한 정규화된 평균 화소값을 특징값으로 사용하기 때문에 텍스처 성분이 거의 없는 지역의 분류 결과는 평균 화소값에 많이 의존하는 경향을 볼 수 있다. 이점은 효과적인 분류를 위해 앞으로 개선되어야 할 중요한 과제이다.

참고문헌

- [1] M. S. Bartlett, J. R. Magellan, T. J. Sejnowski, "Face recognition by Independent component analysis", in Trans. IEEE Neural Networks, vol. 13, pp. 1450 -1464, Nov. 2002.
- [2] A. J. Bell, T. J. Sejnowski, "The

- independent Component of natural scenes are edge filters”, in *Vision Research*, vol. 37, no. 23, pp. 3327–3338, 1997.
- [3] Seung-Gun. Byoun, K. H. Lee, “A Classification Technique for Panchromatic Imagery Using Independent Component Analysis Feature Extraction”, in *Proc. ISRS*, vol.5, pp. 23–28, Nov. 2002.
- [4] G. Donato, M. S. Bartlett, J. C. Hager, P. Ekman, T. J. Sejnowski, “Classifying Facial Actions,” in *Trans. IEEE PAMI*, vol. 21, no. 10, 1999.
- [5] R. Gonzalez, R. E. Woods, *Digital image processing—second edit.* Prentice Hall Inc, 2002
- [6] A. Hyvarinen, “Survey on Independent Component Analysis,” *Neural computing surveys*, vol. 2, pp. 94–128, 1999.
- [7] A. Hyvarinen, E. Oja, “A fast fixed-point algorithm for independent component analysis,” *Neural Computation*, vol. 9, pp. 1483–1492, Jul. 1997.
- [8] A. Hyvarinen, J. Karhunen, *Independent Component Analysis.* John wiley & Sons Inc, 2001.
- [9] A. Hyvarinen, “Fast and robust fixed-point algorithms for independent component analysis”, in *Trans. IEEE Neural Networks*, vol. 10, pp. 623–634, Mar. 1999.
- [10] J. Karvonen, M. Simila, “Independent component analysis for sea ice SAR image classification”, in *Proc. IEEE IGARSS*, vol. 3, no. 3, pp. 1255 –1257. 2001.
- [11] K. I. Kim, K. Jung, S. H. Park, H. J. Kim “Texture classification with kernel principal component analysis,” *Electronics Letters*, vol. 36, no. 12, pp. 1021 –1022, Jun. 2000.
- [12] P.Meenakshisundaram, K.Rao, “A new approach for textural classification of Landuse Categories using aerial photographs,” in *Proc. IEEE IGARSS*, vol 5, pp. 2781 –2784, 1989.
- [13] Y. Qiyao, C. Moloney, F. M. Williams, “SAR sea-ice texture classification using discrete wavelet transform based methods,” in *Proc. IEEE IGARSS*, vol. 5, pp. 3041 –3043, 2002.