

# 위성 영상데이터의 주성분변환 및 주성분 기반 영상분류

서용수<sup>1\*</sup>

## Principal Component Transformation of the Satellite Image Data and Principal-Components-Based Image Classification

Yong-Su SEO<sup>1\*</sup>

### 요 약

원격탐사(remote sensing) 기술의 비약적인 발전과 함께 위성 영상데이터의 분광대역수가 급속히 증가하고 있다. 대역수의 증가로 영상데이터 량이 급격히 증가하게 되고, 이에 따라 이들 데이터를 처리하기 위해서는 처리속도가 빠른 영상처리 기술이 필요하게 되었다. 분광 대역 수를 줄여 빠르게 처리하는 한가지 방법으로 널리 사용되고 있는 것이 주성분 변환법이다. 본 논문에서는 주성분 변환법에 대한 처리과정에 대해 논하였으며, 위성 영상데이터를 주성분 변환한 결과인 주성분 영상데이터를 분석하였다. 분석결과 실험 영상데이터의 경우, 3개의 주성분( $PC_1$ ,  $PC_2$ ,  $PC_3$ )의 누적 백분율 분산 값이 99.1%로 이는 3개의 주성분이 거의 대부분의 정보를 가지고 있음을 알 수 있었다. 3개의 주성분 영상데이터만을 사용한다면 데이터 저장을 위한 메모리 용량이나 데이터 전송시간 및 처리시간을 크게 감소시킬 수 있다. 또한 본 논문에서는 주성분 영상데이터를 최대유사 분류법과 신경회로망을 이용한 다층 퍼셉트론 분류법으로 분류하고 결과를 평가한 후, 주성분 변환법이 갖는 차원축소 효과를 분석하였다. 분석결과 주성분 3개를 사용한 분류결과와 주성분 6개를 사용한 분류결과간의 분류정답률이 크게 차이가 나지 않았다. 이는 분류에 사용하는 영상데이터 수를 6개 차원에서 3개 차원으로 줄여도 비슷한 분류성능을 얻을 수 있음을 확인할 수 있었다.

**주요어:** 주성분변환, 최대유사 분류법, 다층 퍼셉트론 분류법, 차원축소 기법

### ABSTRACT

Advances in remote sensing technologies are resulting in the rapid increase of the number of spec

tral channels, and thus, growing data volumes. This creates a need for developing faster techniques for processing such data. One application in which such fast processing is needed is the dimension reduction of the multispectral data. Principal component transformation is perhaps the most popular dimension reduction technique for multispectral data. In this paper, we discussed the processing procedures of principal component transformation. And we presented and discussed the results of the principal component transformation of the multispectral data. Moreover principal components image data are classified by the Maximum Likelihood method and Multilayer Perceptron method. In addition, the performances of two classification methods and data reduction effects are evaluated and analyzed based on the experimental results.

**KEYWORDS:** *Principal Component Transformation, Maximum Likelihood Method, Multilayer Perceptron Method, Dimension Reduction Technique*

## 서 론

위성 영상데이터(satellite image data)는 보통 여러 개의 파장범위로 분리된 분광대역(spectral band)별로 수집되고 있다. Landsat TM 영상데이터의 경우 분광대역 수가 7개이나, 일반적으로 다중분광 영상데이터(multispectral image data)는 수 개에서 수십 개의 분광대역을 가진다. 위성 영상데이터의 각 대역들 간에는 서로 상관(correlation)관계가 높다. 이렇게 상관관계가 높다는 것은, 각 대역들 간에 정보의 중복성(redundancy)이 높음을 의미하고, 정보의 중복성이 높은 원래의 분광대역 영상데이터들을 가지고 영상을 분석하는 것은 처리과정의 복잡성, 처리시간 및 처리비용의 증가로 인하여 비효율적이다. 또한, 최근의 센서 기술의 발전으로 인해 하이퍼분광(hyperspectral) 영상데이터의 경우에는 수백 개의 분광대역을 가진다(Richards 등, 1999). 이러한 하이퍼분광 데이터는 예전에 비해서 지표면에 대해서 더욱 상세하고 풍부한 정보를 공급하게 되었다. 그러나, 분광대역의 증가로 인해 데이터 량이 증가하게 되고, 데이터 량의 증가로 인해 데이터를 분석하기 위해서는 여러 가지 문제점이 발생하게 되었다. 즉, 분광대역의 증가로 인해 그 동안 사용해오던 기존의 분류법은 사용이 불가능하게 되었다. 기존의 분류법을 사용하기 위해서는 분광

대역 수를 줄이기 위한 차원축소(dimension reduction)라는 전 처리단계가 필요하게 되었다. 분광대역 수를 줄이기 위한 차원축소 기법으로 가장 널리 사용되는 것이 주성분 변환(PCT : principal component transformation)법이다(Kaewpijit 등, 2002). 위성 영상데이터의 주성분 변환법은 영상분류(Chen 등, 2002), 영상디스플레이(Tyo 등, 2003), 변화검출, 영상데이터 융합(Gonzalez-Audicana 등, 2004) 등의 여러 분야에 응용되고 있다.

본 논문에서는 위성 영상데이터의 주성분 변환에 대한 처리방법을 논한 후, Landsat TM 다중분광 영상데이터를 주성분 변환한 주성분 영상데이터를 분석하였다. 또한 주성분 영상데이터를 최대유사(maximum likelihood)법과 신경회로망을 이용한 다층 퍼셉트론(multilayer perceptron)법으로 분류(Haykin, 1994; 임태훈과 서용수, 1996)하여 분류성능을 평가한 후, 주성분 변환의 차원축소 효과를 분석하는데 목적이 있다.

## 주성분변환 방법

다중분광 영상데이터의 분광 대역수가  $n$ 개 일 때, 이들 데이터( $B_1, B_2, \dots, B_n$ )로부터 계산되는 공분산 행렬(covariance matrix)  $C$ 는 식

(1)과 같이 표현할 수 있다.

$$C = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1n} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \dots & \sigma_{nn} \end{bmatrix} \quad (1)$$

이때, 행렬의 대각선상의 원소  $\sigma_{ii}$  는 대역  $i$  의 분산 값이고, 비 대각선상의 원소  $\sigma_{ij}$  는 대역  $i$ 와 대역  $j$ 간의 공분산 값이다. 대각선상의 각 원소의 값에 비해서 비 대각선상의 원소의 값이 비교적 큰 값인 경우에는 상관관계가 높다고 한다.

공분산 행렬  $C$ 로 표현된 아래의 식(2)를 특성방정식(characteristic equation)이라고 하며, 이 방정식을 풀이하면  $n$ 개의 근( $\lambda_1, \lambda_2, \dots, \lambda_n$ )을 구할 수 있고, 이들 근을 공분산 행렬의 고유값(eigenvalue)이라 한다(Zill 등, 1992).

$$|C - \lambda I| = 0 \quad (2)$$

이때,  $I$ 는 단위행렬,  $|C - \lambda I|$ 는 행렬식

$n$ 개의 고유값들을 계산한 후 크기 순으로 나열한다.  $k$ 번째의 고유값  $\lambda_k$ 에 대한 고유벡터  $K_k$ 는 아래의 식(3)을 풀이하여 계산한다.

$$(C - \lambda_k I)K_k = 0 \quad (3)$$

이 때,  $k$  는 1, 2, ...,  $n$

이 방정식을  $n$ 개의 고유값들에 대해서 풀이하면  $n$ 개의 열 벡터( $K_1, K_2, \dots, K_n$ )들을 구할 수 있고, 이들 벡터를 고유벡터(eigenvector)라 한다. 각 고유벡터를 표현하면 아래의 식(4)와 같다.

$$K_1 = \begin{bmatrix} K_{11} \\ K_{21} \\ \vdots \\ K_{n1} \end{bmatrix}, K_2 = \begin{bmatrix} K_{12} \\ K_{22} \\ \vdots \\ K_{n2} \end{bmatrix}, \dots, K_n = \begin{bmatrix} K_{1n} \\ K_{2n} \\ \vdots \\ K_{nn} \end{bmatrix} \quad (4)$$

이들  $n$ 개의 각 고유벡터들을 아래의 식(5)와 같이 구성한 것을 주성분 변환행렬이라고 하며  $W$ 로 나타내기로 한다.

$$W = \begin{bmatrix} K_1^T \\ K_2^T \\ \vdots \\ K_n^T \end{bmatrix} = \begin{bmatrix} K_{11} & K_{21} & \dots & K_{n1} \\ K_{12} & K_{22} & \dots & K_{n2} \\ \vdots & \vdots & \vdots & \vdots \\ K_{1n} & K_{2n} & \dots & K_{nn} \end{bmatrix} \quad (5)$$

이 변환행렬  $W$ 을 사용해서 아래의 식(6)과 같이 변환하는 것을 주성분변환이라 한다.

$$\begin{bmatrix} PC_1 \\ PC_2 \\ \vdots \\ PC_n \end{bmatrix} = \begin{bmatrix} K_{11} & K_{21} & \dots & K_{n1} \\ K_{12} & K_{22} & \dots & K_{n2} \\ \vdots & \vdots & \vdots & \vdots \\ K_{1n} & K_{2n} & \dots & K_{nn} \end{bmatrix} \cdot \begin{bmatrix} B_1 \\ B_2 \\ \vdots \\ B_n \end{bmatrix} \quad (6)$$

다시 말해서, 주성분변환이란 분광 대역수가  $n$ 개인 다중분광 영상데이터( $B_1, B_2, \dots, B_n$ )들로부터 계산해낸 주성분 변환행렬  $W$ 을 가지고 식(6)과 같이 행렬의 곱셈을 행하여,  $n$ 개의 주성분 영상데이터( $PC_1, PC_2, \dots, PC_n$ )들을 계산하는 것을 뜻한다. 주성분변환 중에 화소값이 (-)값을 가질 수도 있다. 이 경우에는 화소값이 (+)값을 가지도록 주성분 공간의 원점을 이동(origin shift)시킨다. 이렇게 이동처리해도 주성분변환에는 영향이 없다. 이를 원점 이동에 무관한 효과라 한다(Richards 등, 1999).

이상은 주성분 변환법에 대한 처리과정을 논한 것으로, 이를 단계별로 요약하면 다음과 같다.

단계 1 : 대역수가  $n$ 개인 다중분광 영상데이터( $B_1, B_2, \dots, B_n$ )들로부터  $n \times n$ 의 공분산행렬  $C$ 를 계산한다.

단계 2 : 식(2)의 특성방정식을 풀이하여  $n$ 개의 고유값( $\lambda_1, \lambda_2, \dots, \lambda_n$ )들을 계산한 후 크기 순으로 나열한다.

단계 3 : 각 고유값들에 대해서 식(3)의 연

립 방정식을 풀이하여 식(4)와 같은  $n$ 개의 고유벡터( $K_1, K_2, \dots, K_n$ )들을 계산한다.

단계 4 : 이들 고유벡터들을 식(5)와 같이 구성하여 주성분 변환행렬  $W$ 를 구한다.

단계 5 : 다중분광 영상데이터( $B_1, B_2, \dots, B_n$ ) 들과 변환행렬  $W$ 를 식(6)과 같이 곱셈하여 주성분 영상데이터( $PC_1, PC_2, \dots, PC_n$ )들을 계산한다.

## 실험 결과 및 고찰

### 1. 실험 영상데이터

실험에 사용된 위성 영상데이터는 Landsat TM 센서에 의해 촬영된 부산지역에 대한 것으로서, 총 7개 대역중 공간 해상도가 120 m 인 대역 6을 제외하고 공간 해상도가 30 m 인 대역 1~5 및 대역 7까지 6개 대역의 데이터를 실험에 사용하였다. 영상의 크기는 512×400 화소이고, 각 화소는 256 회색준위(gray level)를 가진다. 실험 영상데이터 6개 대역의 영상을 나타낸 것은 그림 1과 같다.

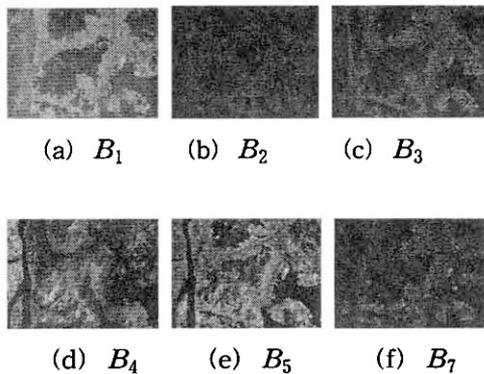


FIGURE 1. 실험 영상데이터 6개 대역의 영상

실험 영상데이터에 대한 각 대역별 평균, 분산 및 백분을 분산 값들을 계산한 결과는 표 1과 같다.

TABLE 1. 실험 영상데이터의 대역별 평균 및 분산 값

Parameter	Spectral Bands					
	$B_1$	$B_2$	$B_3$	$B_4$	$B_5$	$B_7$
Mean	88.71	39.70	42.87	60.01	64.88	30.54
Variance	243.83	100.38	300.52	662.27	950.13	391.23
% Variance	9.20	3.79	11.34	25.00	35.87	14.77

표 1에서 영상데이터의 평균은 대역 1에서 88.71로 가장 크므로 영상의 밝기는 대역 1, 대역 5, 대역 4 등의 순서이고, 분산은 대역 5에서 950.13으로 가장 크므로 콘트라스트가 높은 영상은 대역 5, 대역 4, 대역 7 등의 순서임을 알 수 있다. 전체 대역에 대한 분산값의 총합은 약 2648.4이다. 분산값의 총합에 대한 각 대역의 백분을 분산값은 대역 5가 35.87로 가장 큰 비율을 갖고 있으며, 크기 순으로 나열해서 25.00, 14.77, 11.34, 9.20, 3.79의 비율을 갖는다.

### 2. 실험 영상데이터의 주성분변환

실험 영상데이터에 대한 공분산 행렬을 계산한 결과는 표 2와 같다.

TABLE 2. 실험 영상데이터의 공분산 행렬

Band	$B_1$	$B_2$	$B_3$	$B_4$	$B_5$	$B_7$
$B_1$	243.83	150.01	255.91	-64.74	258.77	251.00
$B_2$		100.38	171.18	-10.47	182.10	160.53
$B_3$			300.52	-25.76	315.79	279.66
$B_4$				662.27	500.31	124.33
$B_5$					950.13	539.58
$B_7$						391.23

표 2에서 행렬의 대각선상의 각 원소는 각 대역의 분산으로, 분산 값의 총합은 표 1에서와

같이 2648.4 이다. 또한, 행렬의 비 대각선상의 각 원소는 공분산 값이다.

표 2의 공분산 행렬에 대한 6개의 고유값 ( $\lambda_1, \lambda_2, \dots, \lambda_6$ )들을 계산한 후 크기 순으로 나열하고 백분율 고유값들을 계산한 결과는 표 3과 같다.

TABLE 3. 공분산 행렬에 대한 고유값 계산결과

Parameter	Eigenvalues					
	$\lambda_1$	$\lambda_2$	$\lambda_3$	$\lambda_4$	$\lambda_5$	$\lambda_6$
Eigenvalue	1776.6	763.03	85.47	13.80	7.99	1.412
% Eigenvalue	67.0	28.8	3.2	0.52	0.30	0.053

표 3에서 각 고유값들은 크기가 급격히 감소함을 알 수 있다. 고유값들의 총합은 2648.4로서 표 2의 각 대역의 분산 값의 총합과 같음을 알 수 있다. 6개의 각 고유값들에 대한 6개의 고유벡터( $K_1, K_2, \dots, K_n$ )들을 계산한 후, 구성한 변환행렬  $W$ 는 아래의 식(7)과 같다.

$$W = \begin{bmatrix} K_1^T \\ K_2^T \\ K_3^T \\ \vdots \\ K_6^T \end{bmatrix} = \begin{bmatrix} 0.242 & 0.169 & \dots & 0.433 \\ 0.402 & 0.226 & \dots & 0.232 \\ -0.290 & -0.327 & \dots & 0.336 \\ -0.670 & 0.076 & \dots & -0.342 \\ 0.441 & 0.050 & \dots & -0.723 \\ -0.221 & 0.897 & \dots & 0.051 \end{bmatrix} \quad (7)$$

이 변환행렬  $W$ 를 식 (6)에 대입하여 아래의 식(8)과 같이 행렬의 곱셈을 행하여 6개의 주성분 영상데이터( $PC_1, PC_2, \dots, PC_6$ )들을 계산한다

$$\begin{bmatrix} PC_1 \\ PC_2 \\ PC_3 \\ \vdots \\ PC_6 \end{bmatrix} = \begin{bmatrix} 0.242 & 0.169 & \dots & 0.433 \\ 0.402 & 0.226 & \dots & 0.232 \\ -0.290 & -0.327 & \dots & 0.336 \\ -0.670 & 0.076 & \dots & -0.342 \\ 0.441 & 0.050 & \dots & -0.723 \\ -0.221 & 0.897 & \dots & 0.051 \end{bmatrix} \cdot \begin{bmatrix} B_1 \\ B_2 \\ B_3 \\ \vdots \\ B_6 \end{bmatrix} \quad (8)$$

### 3. 주성분 영상데이터

계산결과와 주성분 영상데이터( $PC_1, PC_2, \dots, PC_6$ )들을 영상으로 나타낸 것은 그림 2와 같고, 이들에 대한 평균값, 분산값, 백분율 분산값 및 누적 백분율 분산값들을 계산한 결과는 표 4와 같다.

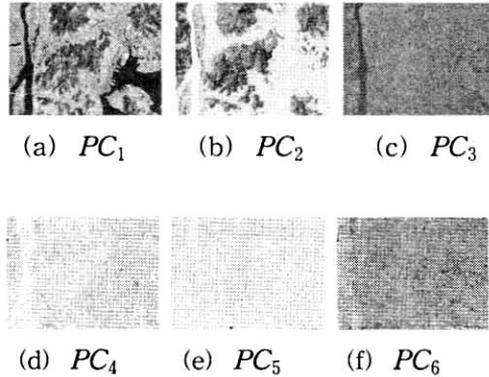


FIGURE 2. 주성분 영상데이터 6개의 영상

TABLE 4. 주성분 영상데이터의 평균, 분산 및 백분율 분산 값

Parameter	Principal Components					
	$PC_1$	$PC_2$	$PC_3$	$PC_4$	$PC_5$	$PC_6$
Mean	121.63	15.81	-53.12	-36.78	28.45	-0.490
Variance	1776.6	763.03	85.47	13.80	7.99	1.412
%Variance	67.08	28.81	3.22	0.52	0.30	0.053
Cumulative %Variance	67.08	95.89	99.11	99.63	99.93	100.00

그림 2에서  $PC_1$ 과  $PC_2$ 은 콘트라스트가 아주 높은 영상임을 알 수 있고  $PC_3, PC_4, PC_5, PC_6$  들은 화소 값의 동적범위(dynamic range)가 좁아서 콘트라스트가 낮은 영상임을 알 수 있다. 이러한 사실은 표 4의 분산 값들과 백분율 분산 값들에서 더욱 명확히 확인할 수 있다. 표 4에서 영상데이터의 평균값은  $PC_1$ 에

서 121.63으로 가장 크고, 분산값은  $PC_1$ 에서 1776.6으로 가장 크며, 차례로 763.03, 85.47, 13.80, 7.99, 1.412로 값이 급격히 감소하고 있다. 주성분 3개( $PC_1, PC_2, PC_3$ )의 누적 백분율 분산 값은 99.1%로 이들 3개의 주성분들이 거의 대부분의 정보를 갖고 있음을 알 수 있다. 이러한 특성은 주성분변환이 데이터 량의 차원 축소(dimension reduction), 데이터 량 감소(data reduction) 효과가 있음을 잘 나타내고 있다. 표 3에서 분광대역 데이터에 대한 각 고유값( $\lambda_1, \lambda_2, \dots, \lambda_6$ )들은 표 4에서 각 주성분 데이터의 분산 값들에 해당됨을 알 수 있고, 표 1에서 분광대역 데이터들의 분산 값의 총합 2648.4는 표 4에서 주성분 데이터들의 분산 값의 총합 2648.4와 같음을 알 수 있다. 따라서 주성분변환 전후의 분산 값의 총합은 동일하게 보존됨을 알 수 있다.

주성분 데이터에 대한 공분산 행렬을 계산한 결과는 표 5와 같다.

TABLE 5. 주성분 데이터의 공분산 행렬

PCs	$PC_1$	$PC_2$	$PC_3$	$PC_4$	$PC_5$	$PC_6$
$PC_1$	1776.6	0.008	-0.003	0.006	-0.004	-0.010
$PC_2$		763.036	-0.005	-0.003	0.005	-0.000
$PC_3$			85.472	0.000	-0.000	-0.000
$PC_4$				13.807	0.000	0.000
$PC_5$					7.996	-0.000
$PC_6$						1.412

PCs : Principal Components.

표 5에서 행렬의 대각선상의 각 원소는 각 주성분 데이터의 분산 값으로 표 4에서와 같다. 비 대각선상의 모든 원소의 값이 거의 0 임을 알 수 있다. 이는 주성분 데이터들 간에는 상관 계수가 0 임을 의미한다. 이러한 특성은 주성분변환이 차원축소, 데이터 량 감소 효과가 있음을 잘 보여주고 있다.

#### 4. 주성분 기반 영상분류

주성분 변환이 갖는 특징추출, 차원축소, 데이터 량의 감소 효과를 알아보기 위해서, 주성분 영상데이터들을 기반으로 영상분류 실험을 행하였다. 사용한 분류법은 최대유사(MLH : Maximum Likelihood)법과 신경회로망을 이용한 다층퍼셉트론(MLP : Multilayer Perceptron)법으로 분류하였다(임태훈과 서용수, 1996). 이들 2가지 분류법(MLH법, MLP법)을 사용해서 6가지 실험방법( $PC_6, PC_5, PC_4, PC_3, PC_2, PC_1$ )으로 분류한 후, 분류성능 평가와 함께 주성분 변환의 차원축소, 데이터 량 감소 효과를 분석하였다.

6가지 실험방법의 의미는 다음과 같다. 실험방법  $PC_6$ 은 주성분 데이터 6개( $PC_1 \sim PC_6$ )를 사용한 분류 실험을 뜻하고, 실험방법  $PC_5$ 은 주성분 데이터 5개( $PC_1 \sim PC_5$ )를 사용한 분류 실험을 뜻하며, 실험방법  $PC_4$ 은 주성분 데이터 4개( $PC_1 \sim PC_4$ )를 사용한 분류 실험을 뜻하며, 실험방법  $PC_3$ 은 주성분 데이터 3개( $PC_1 \sim PC_3$ )를 사용한 분류 실험을 뜻하며, 실험방법  $PC_2$ 은 주성분 데이터 2개( $PC_1, PC_2$ )를 사용한 분류 실험을 뜻하며, 실험방법  $PC_1$ 은 주성분 데이터 1개( $PC_1$ )를 사용한 분류 실험을 뜻한다.

분류할 클래스 수는 잡초지(grass, 286개 화소), 농경지(field, 280개 화소), 도로(road, 288개 화소), 주택지(residential, 280개 화소), 산림(forest, 285개 화소), 바다(sea, 280개 화소) 및 강(river, 292개 화소)의 7개로 선정하였으며, 총 1991개의 화소를 트레이닝 데이터(training data)로 선정하였다.

##### (1) 최대유사(MLH)법의 분류결과

MLH 분류법을 사용해서 6가지 실험방법으로 분류한 후, 대표적인 3가지 실험방법( $PC_6, PC_4, PC_3$ )의 트레이닝 데이터에 대한 분류 정답률을 계산한 결과는 표 6과 같다.

TABLE 6. MLH 분류법으로 트레이닝 데이터에 대한 분류 정답률 계산 결과

Actual Class	No. of Pixels	Method	Assigned Class							PCC (%)
			(A)	(B)	(C)	(D)	(E)	(F)	(G)	
(A) Grass	286	PC_6	275	11						96.15
		PC_4	273	11	1		1			95.45
		PC_3	267	12	5	1	1			93.36
(B) Field	280	PC_6	2	275		2	1			98.21
		PC_4	2	274		2	2			97.86
		PC_3	3	274		2	1			97.86
(C) Road	288	PC_6	2		270	14	1	1		93.75
		PC_4	3		270	13	1	1		93.75
		PC_3	5		269	12	1	1		93.40
(D) Residential	280	PC_6			3	276		1		98.57
		PC_4			3	276			1	98.57
		PC_3	6		3	270		1		96.43
(E) Forest	285	PC_6	1	1			283			99.30
		PC_4	2	4			279			97.89
		PC_3	1	6			278			97.54
(F) Sea	280	PC_6					277	3		98.93
		PC_4					276	4		98.57
		PC_3					276	4		98.57
(G) River	292	PC_6	3	1				1	287	98.29
		PC_4	3	1				1	287	98.29
		PC_3	3	1	1			29	258	88.36
Average PCC		PC_6: 97.60%, PC_4: 97.20%, PC_3: 95.07%								

PC\_6 : Classified using the 6 principal components ( $PC_1 \sim PC_6$ ).

PC\_4 : Classified using the 4 principal components ( $PC_1 \sim PC_4$ ).

PC\_3 : Classified using the 3 principal components ( $PC_1 \sim PC_3$ ).

PCC : Percent of correct classification.

표 6에서는 지면 사정과 표의 복잡성을 피하기 위해서 실험방법 PC\_6, PC\_4 및 PC\_3의 결과만을 나타냈다. 평균 분류 정답률(Average PCC)을 계산한 결과, 주성분 데이터 6개를 사

용한 실험방법 PC\_6과 주성분 데이터 4개를 사용한 실험방법 PC\_4의 분류 정답률은 각각 97.60%, 97.20%로 거의 유사하였다. 또한, 주성분 3개만을 사용한 실험방법 PC\_3의 분류 정답률도 95.07%로 실험방법 PC\_6과 실험방법 PC\_4에 비해서 크게 뒤지지 않는 분류 정답률을 나타내고 있음을 알 수 있다.

## (2) 다층 퍼셉트론(MLP)법의 분류결과

MLP 분류법을 사용해서 6가지 실험방법으로 분류한 후, 대표적인 3가지 실험방법(PC\_6, PC\_4, PC\_3)의 트레이닝 데이터에 대한 분류 정답률을 계산한 결과는 표 7과 같다.

TABLE 7. MLP 분류법으로 트레이닝 데이터에 대한 분류 정답률 계산 결과

Actual Class	No. of Pixels	Method	Assigned Class							PCC(%)
			(A)	(B)	(C)	(D)	(E)	(F)	(G)	
(A) Grass	286	PC_6	286							100
		PC_4	285				1			99.65
		PC_3	284		1		1			99.30
(B) Field	280	PC_6	2	278						99.29
		PC_4	2	278						99.29
		PC_3	2	277			1			98.93
(C) Road	288	PC_6	2	1	276	7	1	1		95.83
		PC_4	1		275	9	2	1		95.49
		PC_3	4		273	8	2	1		94.79
(D) Residential	280	PC_6			1	278		1		99.29
		PC_4			3	276		1		98.57
		PC_3	2		3	274		1		97.86
(E) Forest	285	PC_6	1				284			99.65
		PC_4	1	2			282			98.95
		PC_3	1	2			282			98.95
(F) Sea	280	PC_6					280			100
		PC_4					280			100
		PC_3					244	36		87.14
(G) River	292	PC_6	4						288	98.63
		PC_4	5	1					286	97.95
		PC_3	6					2	284	97.26
Average PCC		PC_6: 98.96%, PC_4: 98.56%, PC_3: 96.32%								

표 7에서 평균 분류 정답률을 계산한 결과 실험방법 PC\_6 및 PC\_4의 분류 정답률은 각각 98.96%, 98.56%로 거의 유사하였다. 또한, 주성분 3개만을 사용한 실험방법 PC\_3의 분류 정답률도 96.32%로 실험방법 PC\_6과 실험방법 PC\_4에 비해서 크게 뒤지지 않는 분류 정답률을 나타내고 있음을 알 수 있다.

지면 사정으로 인해 표 6과 표 7에서 완전히 나타내지 못한 3가지 실험방법(PC\_5, PC\_2, PC\_1)을 포함시켜 전체 6가지의 실험방법(test method)에 대한 MLH와 MLP 분류법의 분류결과를 요약해서 나타낸 것은 표 8과 같다.

**TABLE 8.** 전체 실험방법에 대한 MLH와 MLP법의 분류결과 요약

Classification Method	Test Method					
	PC_6	PC_5	PC_4	PC_3	PC_2	PC_1
MLH	97.60%	97.35%	97.20%	95.07%	90.97%	64.29%
MLP	98.96%	98.95%	98.56%	96.32%	87.65%	56.84%

PC\_6 : Classified using the 6 principal components(  $PC_1 \sim PC_6$ ).

PC\_5 : Classified using the 5 principal components(  $PC_1 \sim PC_5$ ).

PC\_4 : Classified using the 4 principal components(  $PC_1 \sim PC_4$ ).

PC\_3 : Classified using the 3 principal components(  $PC_1 \sim PC_3$ ).

PC\_2 : Classified using the 2 principal components(  $PC_1, PC_2$ ).

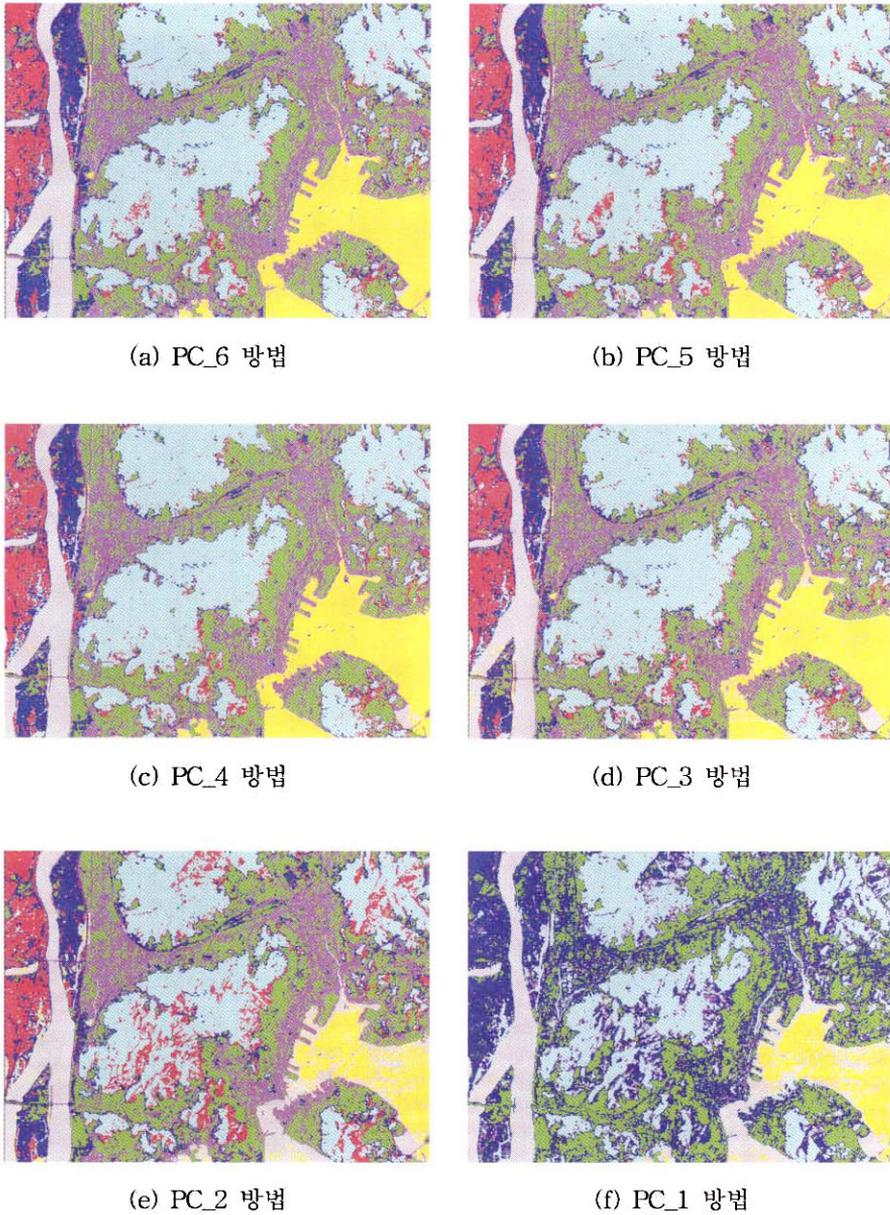
PC\_1 : Classified using the 1 principal component(  $PC_1$ ).

표 8의 MLH 분류법에서, 실험방법 PC\_6, PC\_5, PC\_4 들의 분류 정답률은 각각 97.60%, 97.35%, 97.20%로 분류 정답률이 거의 같다. MLP 분류법에서도, 실험방법 PC\_6, PC\_5, PC\_4 들의 분류 정답률은 각각 98.96%, 98.95%, 98.56%로 거의 같다. 이들 사실로부터, MLH 분류법보다는 MLP 분류법의 분류성능이 훨씬 우수함을 알 수 있다. MLH 분류법과 MLP 분류법 모두에서 실험방법 PC\_6, PC\_5,

PC\_4 들의 분류성능은 거의 동일함을 알 수 있다. 또한, 실험방법 PC\_3이 실험방법 PC\_6에 비해서 크게 뒤지지 않는 분류 정답률을 나타내고 있다. 이는 분류에 사용되는 영상데이터의 차원 수를 6개 차원(dimension)에서 3개 차원으로 50% 감소시켜도 비슷한 분류 정답률을 얻을 수 있음을 뜻한다. 차원 수를 줄이게 되면, MLH 분류법에서는 행렬의 차원 수를 줄여 계산 량과 계산속도를 향상시키게 되고, 신경회로망을 이용한 MLP 분류법에서는 신경회로망의 입력노드 수와 노드간의 가중치(weight)의 수를 줄일 수 있게 되어 계산 량과 계산 속도를 향상시키게 된다. 특히 수백 개의 분광대역을 갖는 하이퍼분광(hyperspectral) 데이터의 경우에는 더욱 효율적으로 영상을 분류할 수 있을 것으로 예상된다.

(3) 분류결과 영상 비교

분류성능이 우수한 MLP법의 분류결과 영상을 나타낸 것은 그림 3과 같다. 표 8의 MLP 분류법에서, 실험방법 PC\_6, PC\_5, PC\_4, PC\_3들의 분류 정답률이 각각 98.96%, 98.95%, 98.56%, 96.32%로 거의 비슷한 것과 같이, 이들 실험방법들의 분류결과 영상인 그림 3 (a), (b), (c), (d)에서도 거의 유사한 영상을 나타내고 있다. 그림 3 (e)의 영상은 실험방법 PC\_2의 분류 정답률이 실험방법 PC\_6, PC\_5, PC\_4, PC\_3들에 비해서 크게 낮으므로, 그림 3 (a), (b), (c), (d)의 영상에 비해서 바다(sea)에서 강(river)으로의 오 분류와 산림(forest)에서 농경지(field)로의 오 분류가 특히 많이 나타나고 있다. 그림 3 (f)의 영상에서는 실험방법 PC\_1의 분류 정답률 56.84%가 나타내는 바와 같이 산림(forest)의 상당 부분이 잡초지(grass)로 오 분류되고 있으며, 바다(sea)의 상당 부분이 강(river)으로 오 분류되고 있다. 또한, 농경지(field), 도로(road), 주택지(residential)등은 대부분이 잡초지(grass)로 잘못 분류된 결과영상을 보여주고 있다.



### Legend

						
Grass	Field	Road	Resid	Forest	Sea	River

FIGURE 3. MLP법에 의한 6개의 주성분 기반 분류결과 영상

## 결 론

본 논문에서는 위성 영상데이터의 주성분 변환법을 논하였으며 Landsat TM 영상데이터를 주성분 변환한 후 주성분 영상데이터를 분석하였다. 또한 주성분 영상데이터를 최대유사(MLH) 분류법과 다층 퍼셉트론(MLP) 분류법으로 분류한 후 분류성능 평가와 함께 주성분 변환법의 차원축소 효과를 분석하였다. 분석 결과 다음과 같은 결론을 얻을 수 있었다.

첫째, 위성 영상데이터를 주성분 변환한 결과, 주성분 3개( $PC_1$ ,  $PC_2$ ,  $PC_3$ )의 누적 백분율 분산 값은 99.1%로 이들 3개의 주성분들이 거의 대부분의 정보를 가지고 있음을 알 수 있었다. 이는 주성분변환이 차원축소 혹은 데이터 량 감소효과가 대단히 큼을 수치로 잘 보여 주었다.

둘째, 주성분 기반 영상분류 실험결과, MLH 분류법보다 MLP 분류법의 분류성능이 훨씬 우수함을 확인할 수 있었다. MLH 분류법과 MLP 분류법 모두에서 실험방법  $PC_6$ ,  $PC_5$ ,  $PC_4$  들의 분류 정답률이 거의 유사하였다.

셋째, 주성분 3개만을 사용한 실험방법  $PC_3$  이, 주성분 데이터 6개를 사용한 실험방법  $PC_6$ 에 비해서 크게 뒤지지 않는 분류 정답률을 나타내었다. 따라서 주성분 변환기법을 영상분류에 이용하면 영상데이터의 차원 수를 반으로 줄여도 비슷한 분류성능을 얻을 수 있는 차원축소 효과를 확인할 수 있었다.

향후 주성분 변환기법을 분광대역수가 훨씬 많은 하이퍼스펙트럴(hyperspectral) 데이터에 적용하여 성능을 평가하는 일과 주성분 변환기법을 데이터 압축(data compression), 변화검출(change detection), 영상융합(image fusion) 등에 응용하는 연구가 계속되어야 할 것이다. **KAGIS**

## 참고문헌

- 임태훈, 서용수. 1996. 카테고리 분류를 위한 다층퍼셉트론 신경회로망과 최대유사법의 성능 비교. 한국지형공간정보학회지 4(2):137-147.
- Chen, H. and C.H. Chen. 2002. Hyperspectral image data unsupervised classification using Gauss-Markov random fields and PCA principle. IEEE International Geoscience and Remote Sensing Symposium. Toronto, Canada, June 24-28, 2002. Vol. 6, pp.1431-1433.
- Gonzalez-Audicana, M., J.L. Saleta, R.G. Catalan and R. Garcia. 2004. Fusion of multispectral and panchromatic images using improved IHS and PCA mergers based on wavelet decomposition. IEEE Trans. on Geoscience and Remote Sensing 42(6): 1291-1299.
- Haykin, S. 1994. Neural Networks : A Comprehensive Foundation. Macmillan College Publishing Company, New York, USA. pp.138-235.
- Kaewpijit, S., J.L. Moigne and T. El-Ghazawi. 2002. A Wavelet-based PCA Reduction for Hyperspectral Imagery. IEEE International Geoscience and Remote Sensing Symposium. Toronto, Canada, June 24-28, 2002. Vol. 5, pp.2581-2583.
- Richards, J.A. and X. Jia. 1999. Remote Sensing Digital Image Analysis : An Introduction, Third Edition. Springer-Verlag, Berlin Heidelberg, Germany. pp.239-288.
- Tyo, J.S., A. Konsolakis, D.I. Diersen and R.C. Olsen. 2003. Principal-Components-Based Display Strategy for Spectral Imagery. IEEE Trans. on Geoscience and Remote Sensing 41(3):708-717.
- Zill, D.G. and M.R. Cullen. 1992. Advanced Engineering Mathematics. PWS Publishing Company, Boston, MA, USA. pp.430-454. **KAGIS**