

# Reference Map을 이용한 시계열 image data의 자동분류법

## Automatic Classification Method for Time-Series Image Data using Reference Map

홍 선 표\*  
(Sun Pyo Hong\*)

### 요 약

본 논문에서는 시계열 image data를 안정되고 높은 정확도로 분류할 수 있는 자동분류법을 제안하였다. 제안한 방법은 대상 영역에 관한 분류도가 존재하던 가, 아니면 최소한 시계열 image data 중 어느 한 image data가 분류되어 있다고 하는 전제조건에 그 기초를 두고 있다. 분류도는 training area를 선정하기 위하여 사용하는 기준주체도로 사용되어진다.

제안한 방법은 1) 기준주체도를 사용한 training data의 추출, 2) training data의 균질성에 의거한 변화화소의 검출, 3) 검출된 변화화소에 대한 clustering, 4) training data의 재구성, 5) maximum likelihood classifier와 같은 판별법에 의한 분류 등 5개의 단계로 구성된다.

제안한 방법의 성능을 정량적으로 평가하기 위하여 4개의 시계열 Landsat TM image data를 제안한 방법과 숙련된 operator가 필요한 기존의 방법으로 각각 분류하여 비교 검토하였다. 그 결과, 기존의 방법으로는 숙련된 operator가 필요하고, 분류도를 얻기까지 수일이 소요되는 데 반하여, 제안한 방법으로는 숙련된 operator 없이, 신뢰성 있는 분류도를 수 시간 내에 자동으로 얻을 수 있었다.

### ABSTRACT

A new automatic classification method with high and stable accuracy for time-series image data is presented in this paper. This method is based on prior condition that a classified map of the target area already exists, or at least one of the time-series image data had been classified. The classified map is used as a reference map to specify training areas of classification categories.

The new automatic classification method consists of five steps, i.e., extraction of training data using reference map, detection of changed pixels based upon the homogeneity of training data, clustering of changed pixels, reconstruction of training data, and classification as like maximum likelihood classifier.

In order to evaluate the performance of this method qualitatively, four time-series Landsat TM image data were classified by using this method and a conventional method which needs a skilled operator. As a result, we could get classified maps with high reliability and fast throughput, without a skilled operator.

### I. 서 론

인공위성으로부터 주기적으로 얻어지는 시계열 image data를 대상으로 한 처리는, 도시·자연환경 또는 토지이용의 추이 파악이나<sup>1,2,3)</sup>, 자연재해·경작지·삼림천이의 감시<sup>4,5)</sup> 등과 같은 각종 분야에 일찍부터 시도되어 왔다<sup>6,7)</sup>. 최근에는 시계열 image data를 분류정도향상을 목적으로 한 처리방법에 관한 연구도 활발하게 이루어지고 있다<sup>8)</sup>. 본 논문에서는 시계열 image data처리를 분류정밀도향상

을 목적으로 하지 않고, 토지피복상황 등과 같은 시간적 추이를 파악하기 위한 처리에 주안점을 두고 있다.

토지피복상황 등과 같은 시간적 추이의 파악을 목적으로 한 시계열 image data의 처리에 관해서는 후술하는 바와 같이 많은 문제가 있으나, 특히 수십 장에 달하는 시계열 image data를 대상으로 하는 대규모처리에서는 처리에 개재하는 인간의 부담이 매우 크므로, 이를 현실적인 수준까지 경감시킬 수 있는 처리방법이 무엇보다도 요구되고 있다. 기존방법은 아예 큰 문제가 있는 바, 본 논문에서는 이 문제를 해결하기 위한 시계열 image data의 자동분류법을 제안한다.

먼저 기존방법의 문제점을 2절에서 정리하고, 3절에서

\*시립인천전문대학 제어계측공학과  
접수일자: 1996년 11월 11일

제안방법을 기술한다. 다음에 제안하는 방법을 평가하기 위하여 수행한 실험결과를 4절에서 기술하고, 마지막으로 실험결과에 근거하여 제안방법을 평가한다.

## II. 시계열 image data처리에 있어서 기존방법의 문제점

토지피복상황 등의 시간적 추이를 파악하고자 할 경우, 기존방법으로는 다음의 2가지가 있다<sup>9)</sup>.

- 1) 각 시기의 관측영상에 대하여 변화분을 검출하여, 그 변화분의 내용을 검토하는 방법
- 2) 각 시기의 관측영상을 각각 분류하여, 얻어진 각 시기의 분류내용을 해석·평가하는 방법

1)의 경우에 있어서는 spectral data 자체나, band간 연산의 결과 등과 같이 적당한 특징공간에 있어서 각 화소의 특징벡터의 변위를 구하는 방법<sup>10,11,12)</sup>, 시계열 image data를 1개의 multi-band 영상으로 취급하여, 회귀분석이나 주성분분석을 행하는 방법<sup>13,14,15)</sup>, 또한 각기 다른 시기의 2매의 image data가 동종의 데이터가 아닌 경우는 공간분해능 및 pseudo spectral data를 작성하여, spectral 공간에서 2시기의 벡터변위량을 구하는 방법<sup>16)</sup> 등, 다양한 방법이 제안되어 있으나, 실용화에 충분한 분류정밀도를 가지고 변화를 검출할 수 있는 방법은 보고되어 있지 않다.

한편 2)의 경우에는, 기본적으로 단일 image data의 분류처리가 반복되어지므로, 단일 image data의 분류에 있어서의 문제가 마찬가지로 발생된다. 시계열 image data의 분류처리에서는, 그 처리 목적 상 충분히 높은 분류정밀도가 요구되고, 또한 그 것이 여러 시기에 걸쳐서 안정되게 얻어 질 수 있어야 한다.

판별법으로서 통계적으로 최적의 결과를 얻을 수 있는 Maximum Likelihood Method를 사용할 경우, 최적의 결과를 얻기 위해서는 그에 상응하는 training data를 준비할 필요가 있다<sup>17,18)</sup>. 그러나, 근래의 SPOT HRV, Landsat TM 등의 고해상도 센서로부터 얻어지는 image data가 대상의 경우에는 supervised training data의 추출 그 자체가, 인간의 능력상 어렵다는 점이 지적되고 있는데<sup>19,20)</sup>, 그와 같이 어려운 작업을 각 시기의 image data에 대하여 일일이 행하는 것은 더욱 어려운 일이다. training data를 추출하기 위해서는 많은 시간과 노력이 요구되는 것이 아니라, 대상지역에 관한 지식까지 요구된다. 따라서 현지조사를 행하는 시간까지 고려하면, 전체적으로 상당한 시간이 이로 인해 소요된다. 뿐만 아니라 현지조사 자체가 불가능한 경우도 있는 데, 이럴 경우에는 supervised training data의 추출이 곤란하다. 또한 높은 분류정밀도를 얻기 위해서는 training data의 선정 시 상당한 숙련이 필요하다.

이상의 training data의 추출에 관한 문제 이외에도 분류에 소요되는 계산시간이 대상 image data의 수가 증가함

에 따라 그만큼 늘어나게 되는 문제도 있으나, 이는 최근의 컴퓨터의 급속한 발달을 고려하면, 향후 심각한 문제가 되리라는 생각되지 않는다. 그러나, training data의 추출에 관한 문제는 앞으로도 계속 심각한 문제가 되리라고 예상되는 바, 본 논문에서는 training data의 자동추출방법을 모색하고 이를 통한 시계열 image data의 자동분류법을 제안한다.

## III. 제안하는 시계열 image data의 자동분류법

### 3.1 기존방법의 문제점 및 착안점

전술한 1)의 방법으로는 변화검출수법을 개선하지 않는 한, 시계열 image data에 관한 유효한 처리방법을 실현하기는 어렵다. 대기효과나 태양에 의한 음영효과, sensor의 calibration 정밀도, 지표면의 수분량이나, 식생의 경년·경시변화를 고려하면, 현시점에서 충분한 정밀도를 가진 변화검출방법을 개발하는 것은 매우 어려운 일이다.

한편 2)의 방법에 있어서, 판별법으로서 일반적으로 사용되어 지고 있는 Maximum Likelihood Method를 사용할 경우의 중요한 문제점은 인간에 의한 training data의 추출에 기인하는 문제이다. 따라서 training data의 추출을 자동화함으로써, 그 문제를 해결할 수 있다. 물론, 단일 image data의 분류에 있어서 문제가 되는 분류의 절대정밀도에 관한 문제는 남지만, contextual 분류, texture 분류, 해석적 분류, fuzzy 분류, AI적 분류 등 근래에 시도되고 있는 분류방법에 관한 연구성과를 고려할 때, 이 문제는 향후 해결될 가능성이 있다. 경우에 따라서는 절대정밀도 보다는 오히려 기존의 분류도(기준도)를 기준으로 분류정밀도가 요구되는 경우도 있으므로, 절대정밀도 보다는 상대정밀도가 중요한 경우도 있다.

이상으로부터, 본 연구에서는 2)의 방법, 즉, 시계열 영상 데이터를 각각 분류하는 방법을 채용하고, 이 경우의 문제점을 해결하기 위하여 training data 추출의 자동화에 주목했다.

### 3.2 제안방법

일반적으로 대상지역의 토지피복상황은 시기에 따라 변하지만, 그 변화는 대상지역의 image data 전체가 변하는 것이 아니고, 부분적으로 일어나게 된다. 따라서, 단일 대상지역에 관하여 상당히 정확한 분류도가 이미 존재한다면, 그 분류도를 시계열 image data의 각각의 image data에 overlay 시키고, 그에 따라 결정되는 영역을 training area로 하여 training data를 추출하는 것이 가능하게 된다. 이 점이 본 제안방법의 기본이 되는 착안점이다.

기준이 되는 분류도(주제도)의 존재를 가정하는 것은, 지역단위의 토지피복상황조사나 삼림의 식생조사 등을 통하여 얻어질 수 있으므로 비현실적인 가정은 아니라고 생각된다. 만일 기준이 되는 주제가 존재하지 않을 경우에는, 한 매의 image data에 대하여 종래의 분류처리를

행함으로써, 기준이 되는 분류도를 얻을 수도 있다. 이후 training area를 선정하기 위하여 사용하는 분류도를 기준 주제도라고 부르기로 한다.

상기와 같이 추출되어진 training data에는 기준주제도에 내재되어 있는 오류나 토지피복상황이 변화함에 따라서 잘못 추출된 화소가 존재하고 있는 것이 당연하다. 이러한 적당하지 않은 각 training data 중의 화소는 수정을 해야하는 데 다음과 같은 과정을 거쳐서 수정이 가능하다. 즉, 먼저 추출된 각 training class에 있어서, class중심으로부터 떨어져 존재하고 있는 화소(이것을 변화화소로 부르기로 한다)를 검출하여, 이를 제거하면 올바른 training data가 얻어질 수 있으리라 생각되어진다. 또한 제거된 화소집합은 새로운 training class를 형성할 가능성이 있으므로, 버리는 것이 아니라, 그것을 대상으로 clustering을 행함으로써 새로운 class를 자동 생성한다. 이와 같이 수정, 생성된 class를 분류 class로써 대상 image data를 분류한다면, 인간이 개제하지 않고 분류를 행하는 것이 가능하다.

또한 새롭게 생성된 class는 기준주제도의 토지피복항목에 대응시켜야 하는 데, 본 제안방법의 경우는 문헌<sup>22)</sup>에서 보여주고 있는 최단거리법 등의 자동대응수법을 적용함으로써 자동화할 수 있다.

이상을 정리하면, 제안방법은 다음의 순서에 따라서 행하여진다.

(1) 기준주제도를 시계열 image data의 각각에 overlay시키고, 그로 인해 결정되는 영역을 training area로 하여 training data를 추출한다(이것을 1차 training data라고 부르기로 한다).

(2) 1차 training data로부터 변화화소를 추출한다. 변화화소의 추출은 1차 training data의 각 class의 중심으로부터 통계적으로 떨어져있는 화소를 그 class로부터 추출함으로써 행해진다.

한편 1차 training data에 대해서는 변화화소를 제거한 후에 각 class의 통계량을 재계산하여 둔다.

(3) 추출된 변화화소를 대상으로 clustering을 행하여, 새로운 training class를 생성한다.

(4) 수정된 1차 training data와 새롭게 생성된 training data를 merge하여, 분류용의 training data(이를 2차 training data라고 부르기로 한다)를 작성한다.

(5) 2차 training data를 사용하여, Maximum Likelihood Method 등과 같은 판별법을 이용하여 분류를 행한다.

그림 1은 본 제안방법의 흐름을 나타내고 있다. 더욱이 본 방법에서는 대상 image data의 모든 화소가 training data로 사용됨으로써, 기존의 방법에 있어서 샘플개수가 적은 데서 기인하는 통계적인 왜곡은 최소한으로 억제되는 이점도 있다.

본 제안방법을 적용하기 위해서는, clustering 방법이나 판별법으로 무엇을 사용할 것인지를 결정할 필요가 있다. 또한 이러한 방법을 어떠한 특징공간에서 실행할 것

인지를 정의해 둘(어떠한 특징량을 사용할 것인지도 결정해 둘) 필요가 있다. 이러한 점에 대해서는 본 제안방법을 실제로 적용할 때에 적당한 방법이나 특징량을 사용하면 되는 데, 본 논문에서는 계층적 clustering, Maximum Likelihood Method에 의한 화소분류법, spectral feature를 사용하였다.

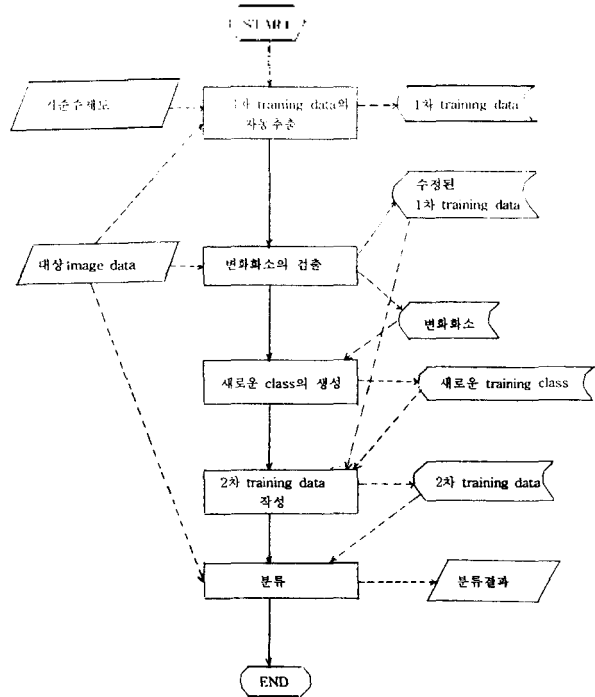



그림 1. 제안하는 자동분류법의 흐름도

#### IV. 실험

제안한 방법을 평가하기 위하여, 다음과 같은 실험을 행하였다. 실험대상으로서는 춘하추동의 각 시기에 해당하는 표 1과 같은 4시기의 Landsat TM image data를 사용하였다(그림 2). 대상지역은 분류정밀도의 정량적 평가를 행하기 위하여 넓이가 약 2km, 길이가 약 10km에 달하는 test site<sup>23)</sup>(그림 3)가 설치되어 있는 일본 관동지방의 相模川유역을 선정하였다. 이 test site는 상세한 현지 조사에 의하여 digital 토지피복 map(test site data이라 부르기로 한다)이 이미 작성되어 있어서, 이를 사용하면, 분류 후 정량적 평가를 실시할 수 있다. 본 실험에서 사용한

표 1. 실험 대상 image data

대상지역	일본 관동지방 相模川유역
대상지역의 크기	12.8km × 12km
대상 sensor image data	Landsat TM image data
image data 크기	512 × 480 화소
재매일 화소 크기	25m × 25m
사용채널	1, 2, 3, 4, 5, 7
데이터 수집시기	1/23('85), 5/21('87), 8/6('86), 11/4('84)




(a) 시기: 1월



(b) 시기: 8월



(c) 시기: 5월



(d) 시기: 11월

그림 2. 4 시기 TM image data



그림 3. 분류정밀도평가의 기준으로 사용한 test site data

test site data는 1986년에 작성된 것이다.


먼저, 기존방법에 의하여 분류를 행하였다. 즉, 4개의 각 시기의 image data에 대하여, 각각 수작업으로 추출된 training data를 이용하여 Maximum Likelihood Method로 분류를 행하였다. 기존 방법에 사용된 training data는,

분류에 상당히 숙련된 operator가 상세한 현지조사를 행한 후에 각 시기별로 training data를 추출한 것으로서, 그림 4에 이에 의한 분류결과를 나타내었다.

다음에는 이 4개의 분류결과중의 어느 하나를 기준주제도로 사용하여, 다른 3 시기의 image data를 대상으로 본 연구에서 제안한 자동분류법으로 분류를 행하였다. 4개의 각 시기의 분류결과를 각각 기준주제도로서의 실험을 행한 이유는, 사용한 주제도에 대한 최종분류결과와의 의존성을 평가하기 위한 것이다.

설정된 분류항목을 표 2에 나타내었다. 표 2의 좌단의 항목은 기존방법에 의한 분류시 설정한 분류항목이다. 분류항목은 14개이지만, 각각이 복수의 class를 가지고 있으므로 실제로는 총 58개의 class가 존재한다.

분류정밀도의 추정은 test site data에 근거하여 행하였다. test site data는 52개의 토지이용·피복항목으로 구성되어 있으므로, training data를 추출하기 위하여 설정된 분류항목과의 정합을 위하여 표 2의 우단과 같이 5개의 대분류항목으로 merge하여, 이 5개의 항목으로 분류정밀도에 대한 평가를 행하였다.



(a)시기: 7월



(b)시기: 8월



(c)시기: 5월



(d)시기: 11월

그림 4. 기존방법에 의한 분류 결과

표 2. 분류항목

TM image data 분류항목 (class 수)	test site 항목	정밀도평가용 대분류항목
1. 침엽수림 (3)	침엽수, 활엽수	수목
2. 활엽수림 (5)	죽림, 과수원	
3. 혼합림 (3)	혼합림	
4. 음영 (2)		
5. 논 (9)	논	논
6. 시가지 (4)	주백, 빌딩, 창고	도시
7. 주택지 (6)	공장, 역, 도로	
8. 공정 (5)	펜크리트	
9. 바다 (3)	연못, 하천	
10. 강 (2)	pool, 바다	수역
11. 밭 (4)	밭, 온실, 초지	기타
12. 초지 (5)	나대지, 조성지,	
13. 나대지 (4)	모래, 운동장	
14. 모래 (1)		
14항목 58 class		5 항목


1차 training data 중의 변화화소의 추출은, 각 class의 중심으로부터 통세적인 거리로 2.5이상 떨어져 있는 화소를 구함으로써 행하여 졌다. 실제로 추출된 변화화소

의 화소수는 각 시기의 image data에 따라 다르지만, 대상 image data의 20%~30%정도이다. 그림 5에 각 시기의 분류결과를 기준주제도로 하였을 때, 나머지 3 시기의 image data에 대하여 추출한 변화화소의 분포(백색 부분)를 나타내었다.


변화화소에 대하여 clustering을 행한 결과, 새롭게 생성된 class의 수는 약 40~60개 정도이다. 1차 training data의 class수는 기준주제도의 class수와 같은 58개이므로, 결과적으로 2차 training data의 class수는 약 100~120개가 되었다. 사용한 clustering은 계층적 Ward법<sup>18)</sup>을 사용하였고, 변화화소 전부를 1개의 data set로 처리하였다. 또한 class와 category와의 대응관계는 자동적으로 행하였다<sup>22)</sup>.

제한한 방법에 의한 분류결과를 그림 6에 나타내었다. 또한 기존방법에 의하여 얻어진 분류결과와 정밀도와 제한한 방법에 의하여 얻어진 분류결과와 정밀도를 표 3에 나타내었다.


표 3의 우단에 표시한 평균치는 5개의 항목의 정밀도를 각 분류항목의 면적에 따른 가중평균치이다. 이 수치




(a)시기:1월



(b)시기:8월



(c)시기:5월



(d)시기:11월

그림 5. 추출된 각 시기의 변화화소의 분포

는 test site data자신의 오류나 4 시기의 image data와 test site와의 위치정합시의 오차에 의한 영향도 포함하고 있으리라 생각되므로, 이점을 고려해서 종합적으로 검토하면, 다음과 같은 사실을 알 수 있다.

표 3. 분류정밀도

단위: %


대상 image data	분류 방법	수목	논	도시	수역	기타	평균
1월	기준방법	31.7	52.0	88.1	63.0	31.6	63.3
	기준주제도(5월)	21.4	52.6	89.2	56.9	36.6	64.4
	기준주제도(8월)	18.7	43.9	89.2	60.4	36.4	63.5
	기준주제도(11월)	23.1	45.5	88.2	61.6	36.2	63.4
5월	기준방법	25.0	49.2	84.5	61.2	38.0	62.5
	기준주제도(1월)	19.1	42.6	86.0	72.9	37.7	62.8
	기준주제도(8월)	28.3	41.2	83.3	67.7	39.4	62.1
	기준주제도(11월)	19.3	54.4	86.3	66.0	32.1	62.1
8월	기준방법	23.5	60.6	86.6	75.9	37.6	65.2
	기준주제도(1월)	24.8	60.5	88.8	72.5	36.3	65.8
	기준주제도(5월)	27.9	59.5	84.6	68.9	40.3	64.8
	기준주제도(11월)	17.8	60.1	85.6	70.3	41.7	65.2
11월	기준방법	21.0	74.0	86.1	63.1	38.8	65.8
	기준주제도(1월)	24.6	65.8	86.8	64.4	38.1	65.5
	기준주제도(5월)	18.5	69.1	87.1	61.6	40.4	66.0
	기준주제도(8월)	25.6	69.6	84.0	62.0	43.5	65.9

(1)제안한 방법에 의한 평균분류정밀도는 숙련된 operator에 의한 기존의 방법과 거의 비슷하거나 더 높다(그차는 -0.4%부터 +1.1%의 범위로, 낮은 경우는 4회, 높은 경우는 7회임).

(2)제안한 방법에 의한 평균분류정밀도는, 사용한 기준주제도 자신의 정밀도에 그다지 의존하지 않는다(변동은 1%이내임).

(3)각 시기간의 평균분류정밀도는 62.1%~66.0%로 상당한 편차를 보인다. 이는 5월의 image data의 논외의 경우에서 현저히 보여주듯이, 판별법으로 사용한 Maximum likelihood Method의 한계에 의한 결과이다. 즉, 5월의 논은 수역이나 대지 등으로 판별되는 spectral feature상 다양한 형태를 가지고 있다.

(4)제안한 방법에 의한 처리시간은 HP9000/835 mini computer(공칭16MIPS)에서 실행시킨 경우, 1개의 image data를 처리하는 데, 약 8시간이 소요되었다. 이의 대부분의 시간(약 7.5시간)은 계층적 clustering의 처리시간이다. 비계층적 clustering기법을 적용한다면, 30분 정도 걸리므로, 전체 처리시간을 1시간 정도로 단축할 수 있으리라 생각된다<sup>24)</sup>.



(a)시기: 1월



(b)시기: 8월



(c)시기: 5월



(d)시기: 11월

그림 6. 제안방법에 의한 분류결과

(5) 기존수법에서는 현지조사를 고려하면, 분류결과가 얻어지기까지 2~3주간 필요하다.

### V. 제안한 방법의 평가

실험결과로부터 다음과 같은 평가가 얻어진다.

(1) 상세한 현지조사를 행한 숙련된 operator에 의한 기존의 방법과 거의 비슷한 분류정밀도를 얻을 수 있었다.

(2) 얻어진 분류정밀도는 사용된 기준주제도에 그다지 의존하지 않는다.

(3) 각 시기의 분류정밀도는 토지피복의 물리적인 상황에 의존한다. 이것은 본 제안방법중에 사용한 Maximum Likelihood Method에 의한 화소분류법의 한계에 의존하는 것으로서, 각 시기에 걸쳐서 일정한 분류정밀도를 얻기 위해서는 contextual 분류 등과 같이 판별법을 개량할 필요가 있다.

(4) 본 제안수법에 의한 전체처리시간은 1 매의 image data 당 8시간정도이다. 그러나, clustering 방법을 변경함으로써, 1시간 정도로 단축할 수 있다.

이상으로부터, 내부에 사용되어진 clustering방법이나 Maximum Likelihood Method에 의한 화소분류법에 대해서는 개량의 여지가 있기는 하나, 본래 목적한 training data의 자동추출에 관해서는 당초의 목적을 달성했다고 생각된다.

### VI. 결 론

인공위성에 의한 지구관측데이터가 근래에 급속도로 축적되고 있는 배경으로부터, 시계열 image data의 처리는 급후 점점 더 중요한 문제가 되리라 생각된다. 본 연구에서는 토지피복상황 등과 같은 시간적 추이의 파악을 목적으로 시계열 image data의 분류처리에 주목하여, 기존방법의 주요한 문제는 수작업에 의한 training data의 추출에 있다고 생각되는 바, training data의 추출을 자동화함으로써 이 문제를 해결하고자 시도했다.

제안한 시계열 image data의 자동분류법으로 실험을 행한 결과, 제안한 방법은 적어도 기존의 방법에 의한 분류정밀도를 가지고 단시간에 분류처리가 행해질 수 있음

이 확인되었다. 특히 최근의 위성 sensor의 해상도는 계속 높아지고 있는 추세이므로, 기존의 수작업에 의한 처리는 점점 더 어려워지리라 예상되는 바, 이러한 방법의 중요성은 점점 더 커져리라 생각된다.

### 참 고 문 헌

1. W. J. Todd, 1977: Urban and regional land use change detected by using Landsat data, *J of Research by the US Geological Survey*, Vol. 5, 527-534.
2. S. Gordon, 1980: Utilizing Landsat imagery to monitor land use change-A case study of Ohio, *Remote Sensing of Environment*, Vol. 9, 189-196.
3. J. P. Howarth, E. Boasson, 1983: Landsat digital enhancement for change detection in urban environment, *Remote Sensing of Environment*, Vol. 13, 149-160.
4. C. J. Tucker, 1979: Red and photographic infrared linear combinations for monitoring vegetation, *Remote Sensing of Environment*, Vol. 8, 127-150.
5. A. J. Richardson, A. K. Milne, 1983: Mapping fire burns and vegetation regeneration using principal components analysis, *Proc. of IGRASS'83*.
6. J. R. Shepard, 1964: A concept of change detection, *Photogrammetric Engineering*, Vol. 30, 648-651.
7. J. R. Anderson, 1977: land use and land cover changes-A framework for monitoring, *J. of Research by the Geological Survey*, Vol. 5, 143-153.
8. S. Hong, et. al., 1990: A high accuracy landcover classification method of multi-temporal images using Dempster-Shafer model, *Proc. 11th Asian Conf. on Remote Sensing*, p81-p88.
9. A. Singh, 1989: Digital change detection techniques using remotely sensed data, *Inter. J. Remote Sensing*, Vol. 10, No. 6, 989-1003.
10. J. R. Jenson, D. L. Toll, 1982: Detecting residential land use development at the urban fringe, *Photogrammetric Engineering and Remote Sensing*, Vol. 48, 629-643.
11. R. F. Nelson, 1983: Detecting forest canopy change due to insect activity using Landsat MSS, *Photogrammetric Engineering and Remote Sensing*, Vol. 49, 1303-1314.
12. J. E. Colwell, F. P. Weber, 1981: Forest change detection, *Proc. 15th Inter. Symp. on Remote Sensing of environment(Ann Arbor)*.
13. J. R. Jenson(editor), 1983: Urban/suburban land use analysis, *Manual of Remote Sensing*, Vol. 2, second edition (American Society of Photogrammetry), 1571-1666.
14. R. A. Weismiller, et. al., 1977: Change detection in coastal zone environment, *Photogrammetric Engineering and Remote Sensing*, Vol. 43, 1533-1539.
15. G. F. Byrne, et. al., 1980: Monitoring landcover change by principal component analysis of multi-temporal Landsat data, *Remote Sensing of environment*, Vol. 10, 175-184.
16. 瀬戸, 吉村, 1990: 異種データ間比較による變化解析方式の提案, *日本リモートセンシング 學會誌*, Vol. 10, No. 1, 5-17.
17. P. H. Swain, S. M. Davist(editor), 1978: *Remote Sensing-The Quantitative Approach*, McGRAW-HILL, 302-306.
18. 高木幹雄, 下田陽久監修, 1991: 畫像解析ハンドブック, 東京大學出版會, 645-668.
19. H. Shimoda, et. al., 1987: Effects of spatial resolutions to landcover classification accuracies for SPOT HRV and Landsat TM data, *Inter. Archives of Photogrammetry and Remote Sensing*, Vol. 27, Part B, 544-553.
20. K. Fukuc, et. al., 1987: Evaluations of unsupervised methods for land-cover/use classifications of Landsat TM data, *Inter. Archives of Photogrammetry and Remote Sensing*, Vol. 27, Part B, 180-194.
21. 竹内, 1991: 畫像情報の曖昧さを考慮した土地被覆變化の抽出, *寫眞測量とリモートセンシング*, Vol. 30, No. 4, 65-70.
22. 洪善杓, 福江澤也, 下田陽久, 坂田俊文, 1991: クラスとカテゴリの對應關係に關する検討, *日本寫眞測量學會秋季學術講演會論文集 B-3*.
23. 昭和60-62年度科學研究費補助金特定研究(1)研究成果報告書, 1988: 陸地における衛星利用技術に關する研究, 12-25.
24. アンナ・ド N, 洪善杓, 下田陽久, 坂田俊文, 1991: 高解像度衛星データに對する UNSUPERVISED LEARNING の最適化(II), *日本寫眞測量學會秋季學術講演會論文集 A-6*.

### ▲홍 선 표(Sun Pyo Hong)

1982년 2월: 아주대학교 공과대학 전자공학과(공학사)

1985년 2월: 한국과학기술원 전기 및 전자공학과(공학석사)

1993년 2월: 일본 동해대학대학원 광공학과(공학박사)

1985년 3월~1993년 2월: 한국과학기술연구원 시스템공학연구소 연구원

1993년 3월~1996년 2월: 한서대학교 전산정보학과 조교수

1996년 3월~현재: 시립인천전문대학 제어계측공학과 조교수

※주관심분야: 영상정보처리, 멀티미디어, 이동통신