

## Chapter 15

---

# Supervised Image Classification

**ROI and Signature Editing**

**Applying Various Classifiers**

**Neural Network Classifier**


감독 분류(Supervised Classification)는 분류되어야 할 분류 항목들을 사전에 설정하고 영상 자료의 화소들을 설정된 분류 항목 중의 하나로 분류해 내는 과정으로 이번 장에서는 GIS layer 생성을 위해 감독 분류법을 사용하여 영상을 분류하는 방법에 대해 배웁니다.

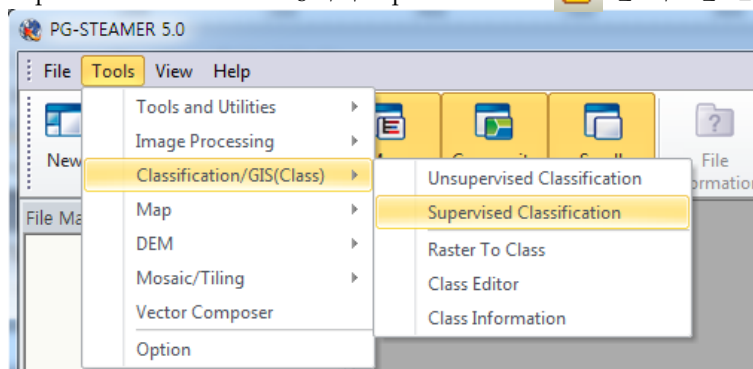
### ROI and Signature Editing

---

이번 실습에서는 관심 대상 영역(ROI)과 Signature를 편집하는 방법에 대해 배웁니다.


#### [ 실습 15a ]

1. PG-STEAMER를 실행합니다.
2. Supervised Classification 툴 버튼을 클릭합니다.
3. Supervised Classification 창에서 Open XDM File  툴 버튼을 클릭합니다.




4. Open 대화상자에서 Chapter15에 있는 **etm.xdm** 파일을 선택하여 엽니다.
5. Image Composition 항목에서 RGB mode를 선택하고 Red Band, Green Band, Blue Band를

각각 Band 3, Band 2, Band 1으로 지정합니다.




6. Make Training Data Set  툴 버튼을 클릭합니다.


7. Image Composition 항목에서 Color Mode를 RGB로 지정합니다.



8. R Band, G Band, B Band를 각각 Bands 3, Band 2, Band 1으로 지정합니다.




9. New ROI를 클릭하고 Polygon을 선택합니다.

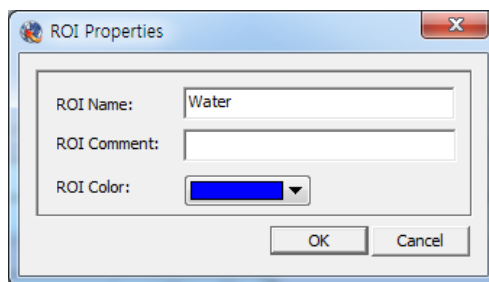


## Chapter 15: Supervised Image Classification


10. 아래 그림과 같이 물에 해당하는 지역을 디지털라이징해서 ROI를 만듭니다. 디지털라이징을 끝내려면 마우스 더블 클릭합니다. (ROI가 너무 크면 처리시간이 길어지므로 작게 만듭니다)




11. ROI Properties 대화상자에서 ROI Name을 “Water”로 입력하고 ROI color를 Blue로 선택합니다.



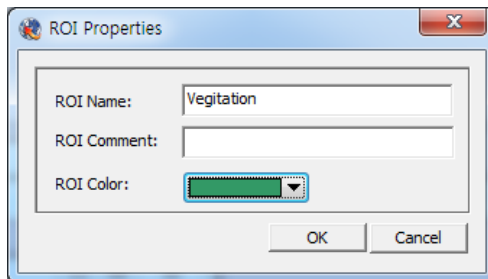
12. OK를 클릭합니다.
13. New ROI를 클릭하고 Polygon을 선택합니다.




14. 아래 그림과 같이 식생지역을 디지털라이징해서 ROI를 만듭니다. 디지털라이징을 끝내려면 마우스 더블 클릭합니다.



15. ROI Properties 대화상자에서 ROI Name을 “Vegetation”으로 입력하고 ROI color를 Green으로 선택합니다.



16. OK를 클릭합니다.
17. New ROI를 클릭하고 Polygon을 선택합니다.




18. 아래 그림과 같이 공항 지역을 디지털라이징해서 ROI를 만듭니다. 디지털라이징을 끝내려면 마우스 더블 클릭합니다.



19. ROI Properties 대화상자에서 ROI Name을 “Built-up”로 입력하고 ROI color를 Yellow로 선택합니다.


## Chapter 15: Supervised Image Classification

---




20. OK를 클릭합니다.


21. Create Class를 클릭합니다.



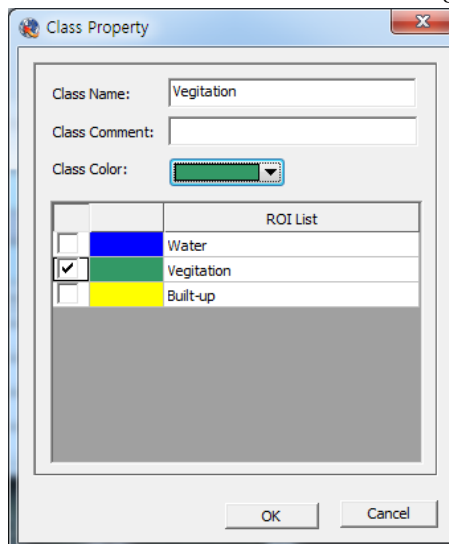
22. Class Properties 대화상자에서 Class Name을 “Water”로 입력하고 Class Color를 Blue로 선택합니다. ROI List에서 Water를 체크하고 OK를 클릭합니다.



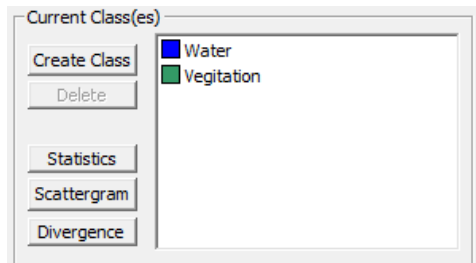
23. Create Class를 클릭합니다.



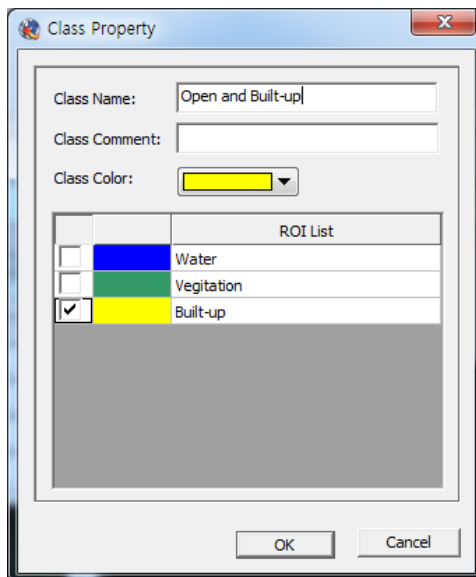
24. Class Properties 대화상자에서 Class Name을 "Vegetation"으로 입력하고 Class Color를 Green으로 선택합니다. ROI List에서 Vegetation을 체크하고 OK를 클릭합니다.



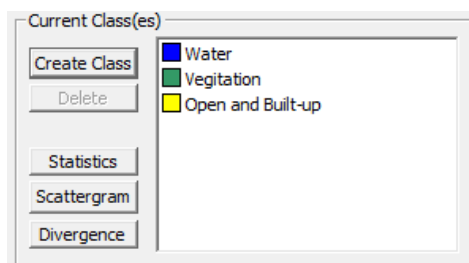
25. Create Class를 클릭합니다.



26. Class Properties 대화상자에서 Class Name을 “Open and Built-up”으로 입력하고 Class Color를 Yellow로 선택합니다. ROI List에서 Built-up을 체크하고 OK를 클릭합니다.

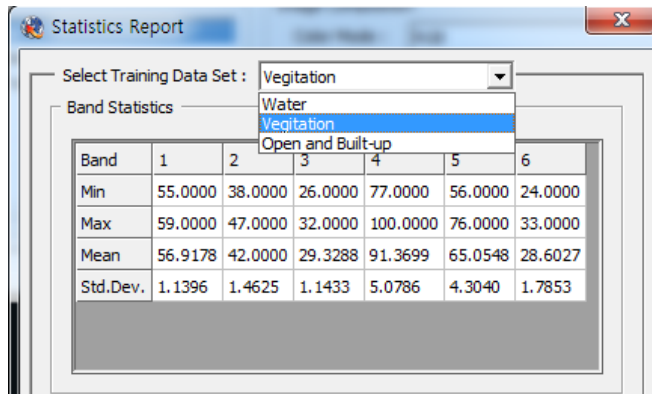


27. Statistics를 클릭합니다.

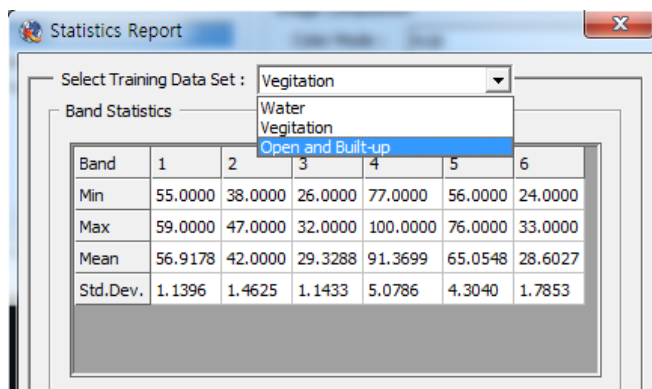





28. Statistics Report 대화상자의 우측 하단 모서리 부분을 마우스로 누른 채 drag하여 대화상자를 늘립니다.
29. Select Training Data Set 리스트에서 Vegetation을 선택합니다.



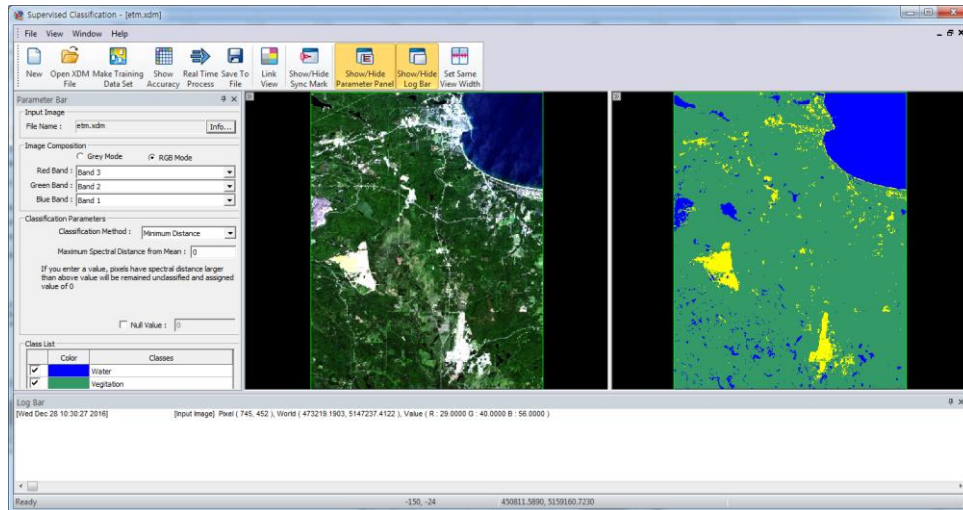
30. Select Training Data Set 리스트에서 Open and Built-up을 선택합니다.



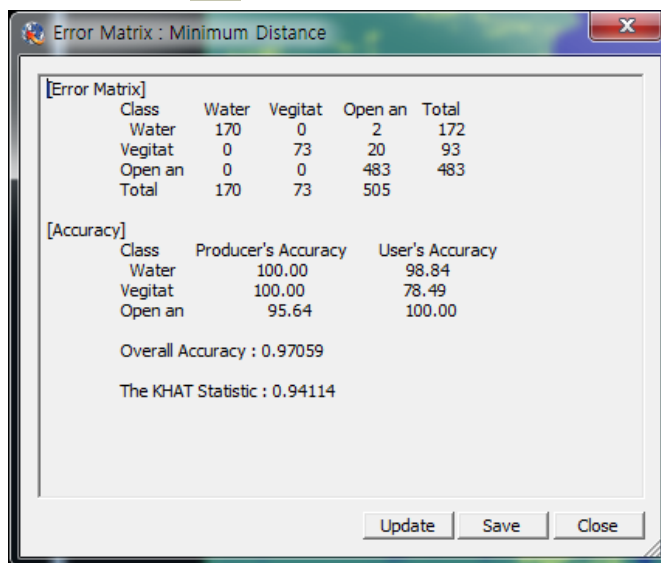
31. Close를 클릭합니다.
32. Training Data Sets 대화상자에서 OK를 클릭합니다.
33. Yes를 클릭하여 ROI와 signature를 저장합니다.
34. RTP  를 버튼 클릭합니다.

표

## Chapter 15: Supervised Image Classification



35. Show Accuracy  톨 버튼을 클릭합니다.



36. Error Matrix 대화상자를 닫습니다.

37. Supervised Classification 창은 닫지 않습니다.

---

## Applying Various Classifiers

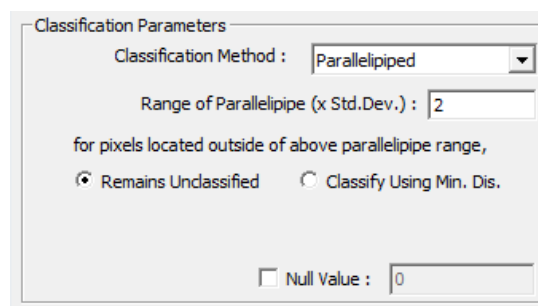
---


이번 실습에서는 분류법에 대해 알아봅니다.


이 실습은 실습 15a에 이어서 실시합니다. 만약 실습 15a를 끝마치지 않았다면 실습 15b를 시작하기 전에 실습 15a를 끝마쳐야 합니다.


### [ 실습 15b ]


1. Classification Method 리스트에서 Parallelipiped를 선택합니다.



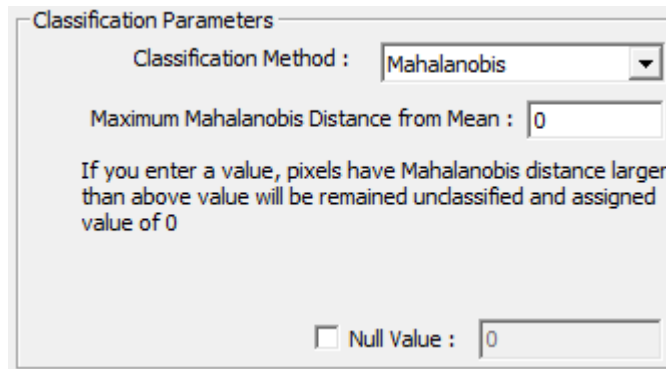
2. RTP  톨 버튼을 클릭합니다.





3. Show Accuracy  툴 버튼을 클릭하고, Error Matrix 대화상자를 닫습니다.




4. Classification Method 리스트에서 Mahalanobis를 선택합니다.



5. RTP  톨 버튼을 클릭합니다.



6. Show Accuracy  톨 버튼을 클릭하고, Error Matrix 대화상자를 닫습니다.

## Chapter 15: Supervised Image Classification

Error Matrix : Mahalanobis

[Error Matrix]				
Class	Water	Vegitat	Open an	Total
Water	170	0	0	170
Vegitat	0	73	0	73
Open an	0	0	505	505
Total	170	73	505	

[Accuracy]		
Class	Producer's Accuracy	User's Accuracy
Water	100.00	100.00
Vegitat	100.00	100.00
Open an	100.00	100.00


Overall Accuracy : 1.00000  
The KHAT Statistic : 1.00000


Update Save Close


7. Classification Method 리스트에서 Maximum-likelihood를 선택합니다.

Classification Parameters

Classification Method :

8. RTP  툴 버튼을 클릭합니다.



9. Show Accuracy  툴 버튼을 클릭하고, Error Matrix 대화상자를 닫습니다.

Error Matrix : Maximum Likelihood

[Error Matrix]				
Class	Water	Vegitat	Open an	Total
Water	170	0	0	170
Vegitat	0	73	0	73
Open an	0	0	505	505
Total	170	73	505	

[Accuracy]		
Class	Producer's Accuracy	User's Accuracy
Water	100.00	100.00
Vegitat	100.00	100.00
Open an	100.00	100.00

Overall Accuracy : 1.00000  
The KHAT Statistic : 1.00000

Update Save Close

10. Classification Method 리스트에서 Spectral Angle Mapper를 선택합니다.


Classification Parameters


Classification Method : Spectral Angle Mapper

Maximum Spectral Angle (in radian) : 0

If you enter a value, pixels have Spectral Angle larger than above value will be remained unclassified and assigned value of 0

☐ Null Value : 0


11. RTP  톨 버튼을 클릭합니다.

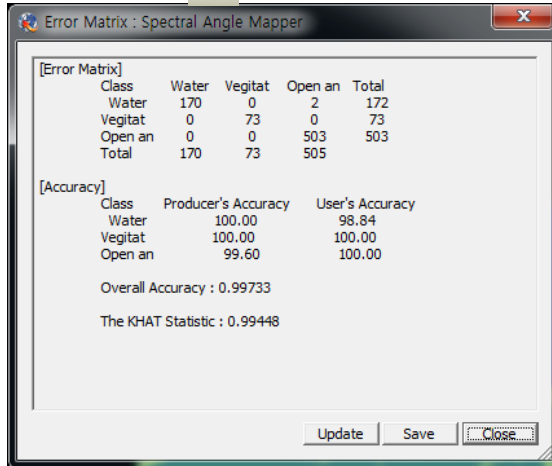




## Chapter 15: Supervised Image Classification

---

12. Show Accuracy  툴 버튼을 클릭하고, Error Matrix 대화상자를 닫습니다.



The dialog box titled "Error Matrix : Spectral Angle Mapper" displays classification results. It contains two tables: [Error Matrix] and [Accuracy].

Class	Water	Vegitat	Open an	Total
Water	170	0	2	172
Vegitat	0	73	0	73
Open an	0	0	503	503
Total	170	73	505	

Class	Producer's Accuracy	User's Accuracy
Water	100.00	98.84
Vegitat	100.00	100.00
Open an	99.60	100.00

Overall Accuracy : 0.99733  
The KHAT Statistic : 0.99448

Buttons: Update, Save, Close

13. Linkview 툴을 클릭합니다.




14. 마우스를 수평으로 drag합니다.

15. Exit를 클릭합니다.

16. Save To File  툴 버튼을 클릭합니다.

17. File Name을 클릭합니다. File name에 "S3Classes"를 입력하고 Save를 클릭합니다.





18. XDM File Save 대화상자의 Save를 클릭합니다.

19. Supervised Classification 창은 닫지 않습니다.

## Neural Network classifier

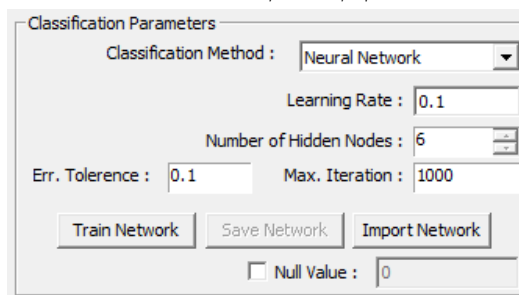
---

이번 실습에서는 인공 신경망 분류에 대해 배웁니다.

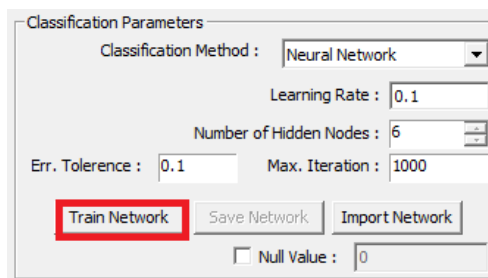
이 실습은 실습 15b에 이어서 실시합니다. 만약 실습 15b를 끝마치지 않았다면 실습 15c를 시작하기 전에 실습 15b를 끝마쳐야 합니다.

### [ 실습 15c ]

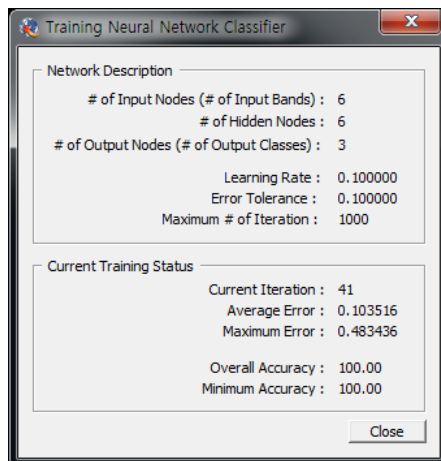
1. Classification Method 리스트에서 Neural Network를 선택합니다.





2. Train Network를 클릭합니다.



3. Training Neural Network Classifier 대화상자를 닫습니다.

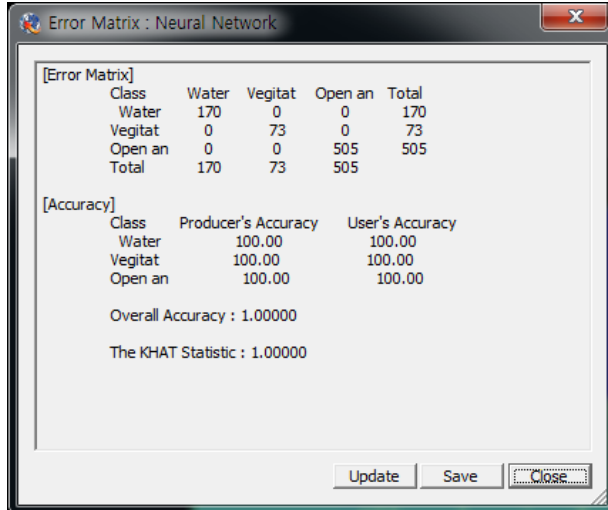


4. RTP  톨 버튼을 클릭합니다.



## Chapter 15: Supervised Image Classification

5. Show Accuracy  툴 버튼을 클릭합니다.



The dialog box titled "Error Matrix : Neural Network" displays classification results. It contains two tables: [Error Matrix] and [Accuracy].

**[Error Matrix]**

Class	Water	Vegitat	Open an	Total
Water	170	0	0	170
Vegitat	0	73	0	73
Open an	0	0	505	505
Total	170	73	505	505

**[Accuracy]**

Class	Producer's Accuracy	User's Accuracy
Water	100.00	100.00
Vegitat	100.00	100.00
Open an	100.00	100.00

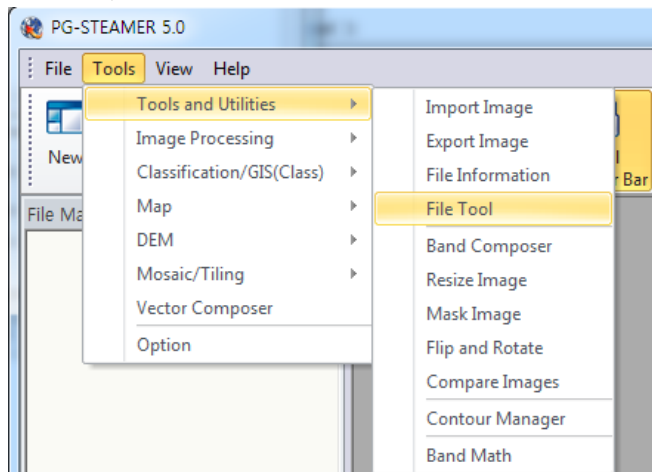
Overall Accuracy : 1.00000  
The KHAT Statistic : 1.00000

Buttons: Update, Save, Close

6. Error Matrix 대화상자를 닫습니다.
7. Supervised Classification 창을 닫습니다.

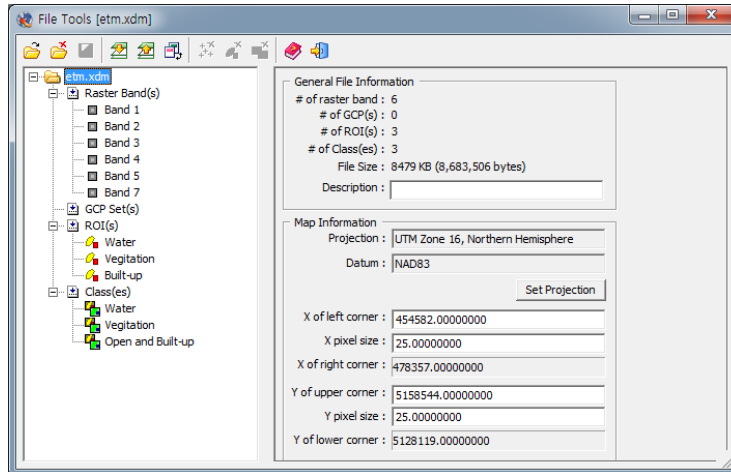
ROI와 SIG를 XDM 포맷으로 저장합니다.

8. Menu에서 Tools and Utilities의 File Tools를 선택합니다. (Menu → Tools and Utilities → File Tools)

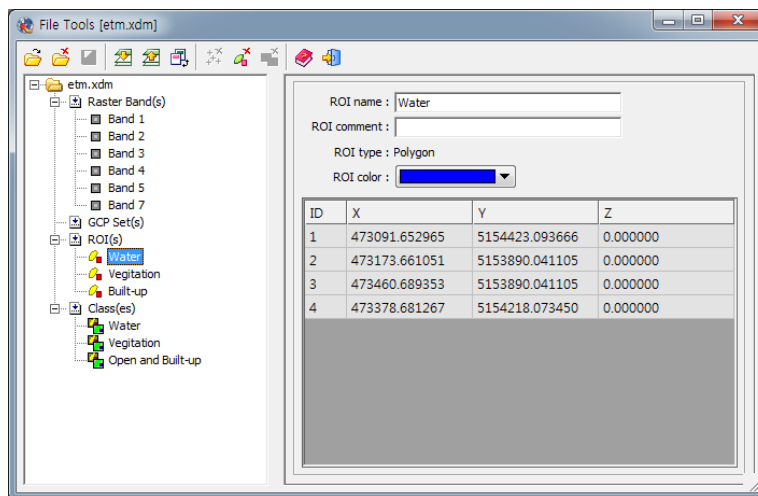


9. Open Input File  툴 버튼을 클릭합니다.
10. Chapter15에 있는 ETM.XDM 파일을 선택하여 엽니다.

11. ROIs와 Classes가 나타납니다.

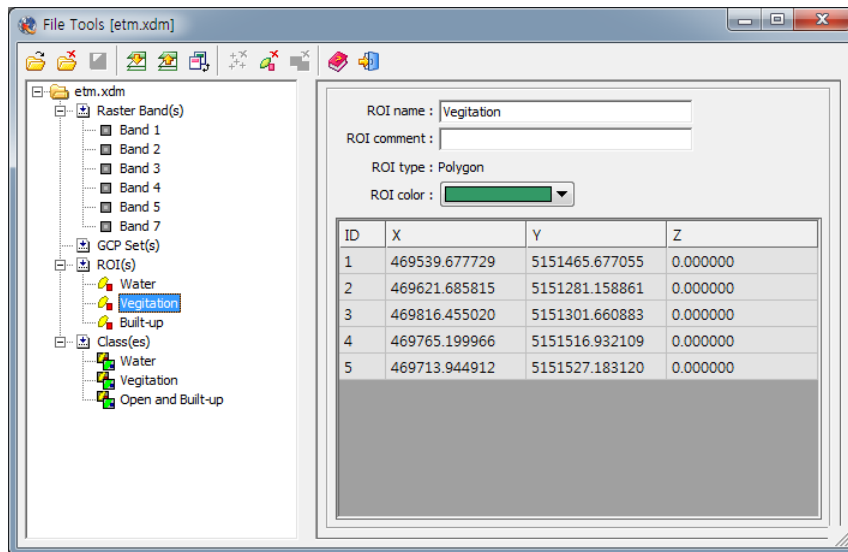



12. ROI(s)에서 Water를 클릭합니다.



13. Class(es)에서 Vegetation을 클릭합니다.

## Chapter 15: Supervised Image Classification



14. Exit  툴 버튼을 클릭합니다.

## Appendix

---

# 이론적 배경 : 감독 분류

## Chapter 15: Supervised Image Classification

---

무감독 분류에서는 분류되어야 할 분류 항목을 사전에 결정하지 않고 단지 유사한 특징의 화소들을 군집화하는데 반해, 감독 분류에서는 분류되어야 할 분류 항목(class) 들일 사전에 설정하고 영상 자료의 화소들을 설정된 분류 항목 중의 하나로서 분류한다.

이 때, 분류하고자 하는 화소가 어떤 분류 항목에 속하게 될지를 결정하는데 있어, 화소와 분류 항목간의 특징의 유사성을 비교할 수 있어야 하는데, 이를 위해서는 분류 항목의 분광적 특징을 설정해두어야 할 필요가 있다.

따라서, 각각의 분류 항목에 대한 분광적 특징을 설정하기 위한 과정으로서 각각의 분류 항목에 대하여 그 분류 항목을 대표할 수 있는 대표 화소들을 추출하며 이를 훈련 자료 혹은 교사 자료(*training data*)라고 부른다.

결국, 감독 분류는 분류 항목을 설정하고 각 분류 항목별로 훈련 자료를 추출하여 영상 전체 화소에 대하여 어떤 분류 항목의 훈련 자료와 가장 유사한지를 판단하여 해당 화소를 가장 유사한 특징을 보이는 훈련 자료의 분류 항목으로 할당하는 과정이라 할 수 있다.

즉, **그림 1**에 나타낸 바와 같이 영상 자료 지역에 대하여 영상과 함께 지도 혹은 현지 조사로부터 수집한 정보를 이용하여 분류 항목을 설정하는 것이 첫 번째 과정이 되며, 다음 단계로서 설정된 분류 항목별로 해당 분류 항목을 대표할 수 있는 대표 화소들, 즉 훈련 자료를 선정해야 한다.

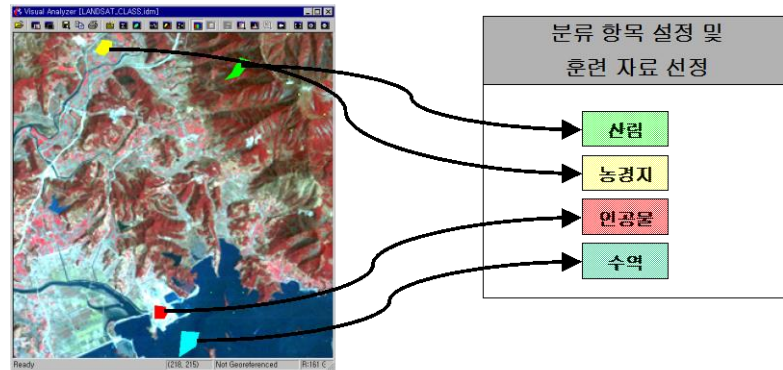
분류 항목별로 선정된 훈련 자료에 대한 분광적 특징은 대개의 경우 밴드별 평균값 및 공분산 등의 통계적 변수로서 나타내지며, 분류 과정은 모든 화소에 대하여 가장 유사한 특징을 보이는 훈련 자료가 어떤 것인지를 식별하여 해당 화소를 그 훈련 자료가 속한 분류 항목으로 분류하게 된다.

이 때, 밴드별 평균이나 공분산 등의 통계적 변수를 기준으로 유사성을 판단하는 분류 기법들을 통계적 분류 기법이라 하며 여기에는 **최소거리법(Minimum Distance)**, **평행사변형법(Parallelipiped)**, **최대우도법(Maximum Likelihood)**, **분광각도법(Spectral Angle Mapper)** 등이 포함된다.

한편 **인공신경망(Neural Network)** 기법은 통계적 변수들을 사용하지 않고 직접 훈련 자료들을 이용하게 된다.




## 1 단계



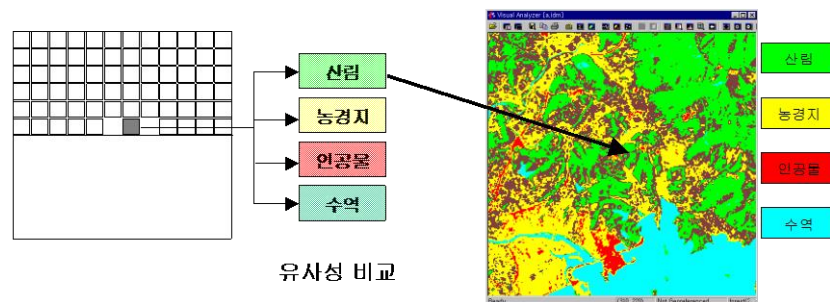
영상과 함께 해당 지역에 대한 다른 종류의 공간 정보를 이용하여 분류 항목을 설정하고 각 분류 항목별로 해당 분류 항목을 대표할 수 있다고 판단되는 대표 화소들을 훈련 자료로서 추출한다.

## 2 단계



분류 항목별 훈련 자료의 특징을 추출하고 분석한다. 대개 훈련 자료의 특징은 밴드별 평균 및 공분산 등의 통계적 변수로서 추출된다.

## 3 단계



모든 화소에 대하여 각 분류 항목과의 유사성을 비교하여 가장 유사한 분류 항목으로 해당 화소를 분류한다.

그림 1. 감독 분류 과정의 절차. 감독 분류는 분류 항목을 설정하고 각 분류 항목별로

훈련 자료를 추출하여 영상 전체 화소에 대하여 어떤 분류 항목의 훈련 자료와 가장 유사한지를 판단하여 해당 화소를 가장 유사한 특징을 보이는 훈련 자료의 분류 항목으로 할당하는 과정이다.

### ● 훈련 자료의 선정 및 특징 추출

앞서 설명한대로 통계적 분류 기법들은 평균이나 공분산 등의 통계적 변수들로서 훈련 자료들의 특징을 나타낸다. 따라서 훈련 자료들이 통계적 모형에 적합한 분포를 보여야 한다는 전제가 따른다.

통계적 분류 기법들이 동일하게 사용하는 전제 조건은 훈련 자료가 가우시안 분포라는 조건이다. 즉, 그림 2의 (a)에 나타낸 바와 같이 훈련 자료가 가우시안 분포를 보이는 경우에는 화소 a는 그 평균값과의 거리가 더 가까운 분류 항목 B로 분류된다. 그러나, 그림의 (b)에 나타낸 바와 같이 훈련 자료가 가우시안 분포를 보이지 않는 경우에는 화소 a는 그 평균값과의 거리가 분류 항목 B와 더 가깝지만 실제로는 분류 항목 A로 분류되어야 옳다고 할 수 있다.




그림 2. (a)에서와 같이 훈련 자료가 가우시안 분포인 경우에는 화소 a는 그 평균값과

의 거리가 더 가까운 분류 항목 B로 분류된다. 그러나, (b)에 나타난 바와 같이 훈련 자료가 가우시안 분포를 보이지 않는 경우에는 화소 a는 그 평균값과의 거리가 분류 항목 B와 더 가깝지만 실제로는 분류 항목 A로 분류되어야 옳다고 할 수 있다.

이와 같은 이유로 선정된 분류 항목별 훈련 자료들이 가우시안 분포를 보이는지 아닌지를 확인하는 과정은 매우 중요하다. 만일 가우시안 분포를 보인다면 통계적 분류 기법들의 적용을 통해서 고품질의 분류 결과를 기대할 수 있으나, 그렇지 않다면 통계적 분류 기법이 아닌 인공지능망 기법 등을 적용하거나 혹은 분류 항목이나 훈련 자료를 다시 설정해야 한다.

그림 3에서는 분류 항목에 대하여 훈련 자료를 선정하면서 훈련 자료의 자료값 분포를 확인하고 있는 과정을 나타냈다.

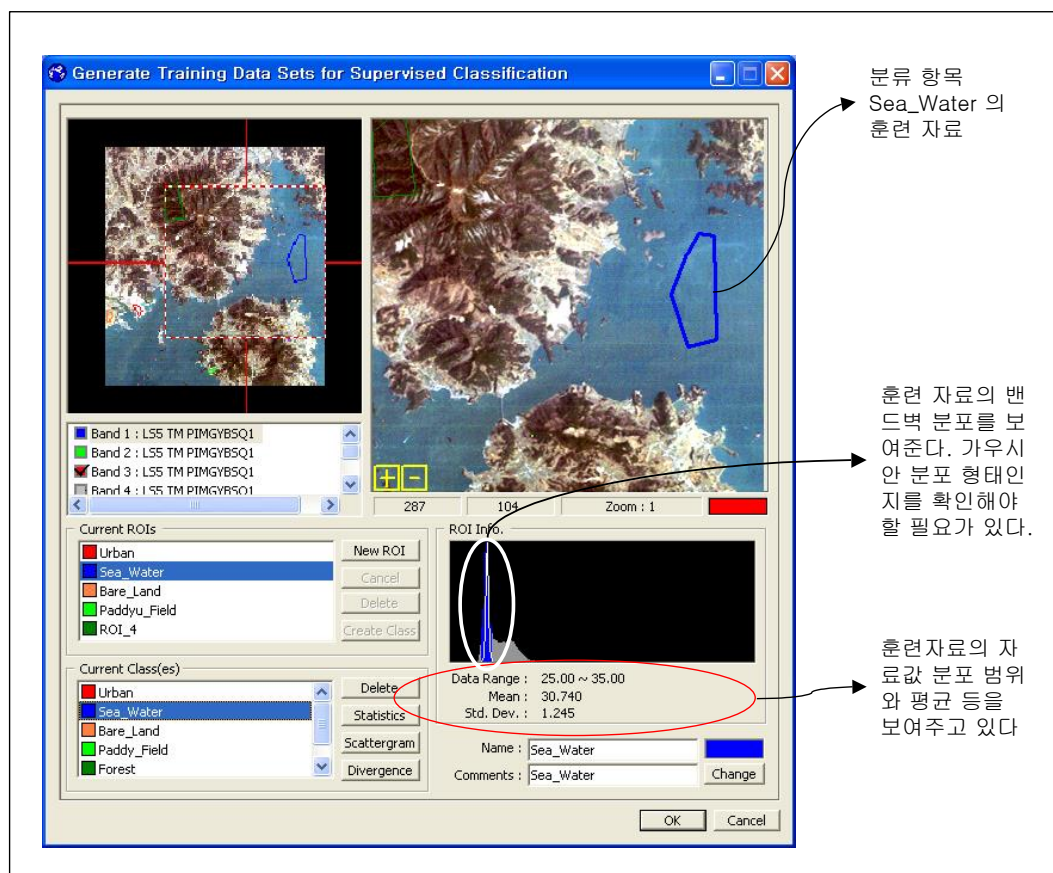


그림 3. 분류 항목별 훈련 자료들을 선정하고 있는 모습. 훈련 자료의 분포에 대한 사전 지식과 충분한 이해는 성공적인 분류를 위하여 필수적이다.

또한 서로 다른 분류 항목의 훈련 자료들은 서로 다른 분광적 특징을 가지고 있어야만 한다. 즉, 분류 항목간 분리도가 좋아야 사용자가 의도한 분류 결과를 얻을 수 있

다. 예컨대, 아스팔트 도로와 아스팔트로 포장된 광장에 대하여 “도로”와 “광장”의 서로 다른 분류 항목을 설정하는 것은 도로와 광장이 동일하게 아스팔트로 포장되어 있어 그 분광적 특징이 서로 다를 수 없기 때문에 분류가 불가능하다. 따라서, 설정된 분류 항목별로 훈련 자료들이 분광 공간상에서 충분히 구분될 수 있는지도 분류 결과의 질에 매우 중요한 영향을 미친다. 이를 위해서 흔히 다음과 같은 방법들이 사용된다.

- ✓ 영상 자료의 스캐터그램 상에 직접 훈련 자료들의 평균값과 표준편차값을 이용하여 그 영역을 그림으로 나타내 본다.
- ✓ 훈련 자료간의 분광 공간상에서의 거리를 분석해본다. 이 때 실제 훈련 자료의 분리도를 분석하기 위해서는 단순히 중심간 거리보다는 자료값의 분포 형태를 반영할 수 있는 가중 거리의 개념이 필요하다.
- ✓ 훈련 자료간 Divergence를 분석해본다.

그림 4는 훈련 자료들의 평균값과 표준편차값을 이용해서 전체 영상 자료의 스캐터그램 상에 분류 항목별 훈련 자료들의 분포 양상을 나타냄으로써 분류 항목간의 분리도를 분석하고 있는 과정을 나타냈다.

분류 항목별 훈련 자료간의 거리를 통하여 분류 항목간의 분리도를 측정하기 위해서는 다음과 같은 Jeffries-Matusita 거리가 사용된다.

$$JM_{ij} = \sqrt{2(1 - e^{-\alpha})}$$

$$\alpha = \frac{1}{8}(\mu_i - \mu_j)^T \left( \frac{C_i + C_j}{2} \right) (\mu_i - \mu_j) + \frac{1}{2} \ln \left( \frac{|(C_i + C_j)/2|}{\sqrt{|C_i| \times |C_j|}} \right)$$

$C_i$  는 분류 항목  $i$  의 훈련 자료에 대한 공분산 행렬

$|C_i|$  는 분류 항목  $i$  의 훈련 자료에 대한 공분산 행렬의 Determinant

$\mu_i$  는 분류 항목  $i$  의 훈련 자료에 대한 평균값 벡터

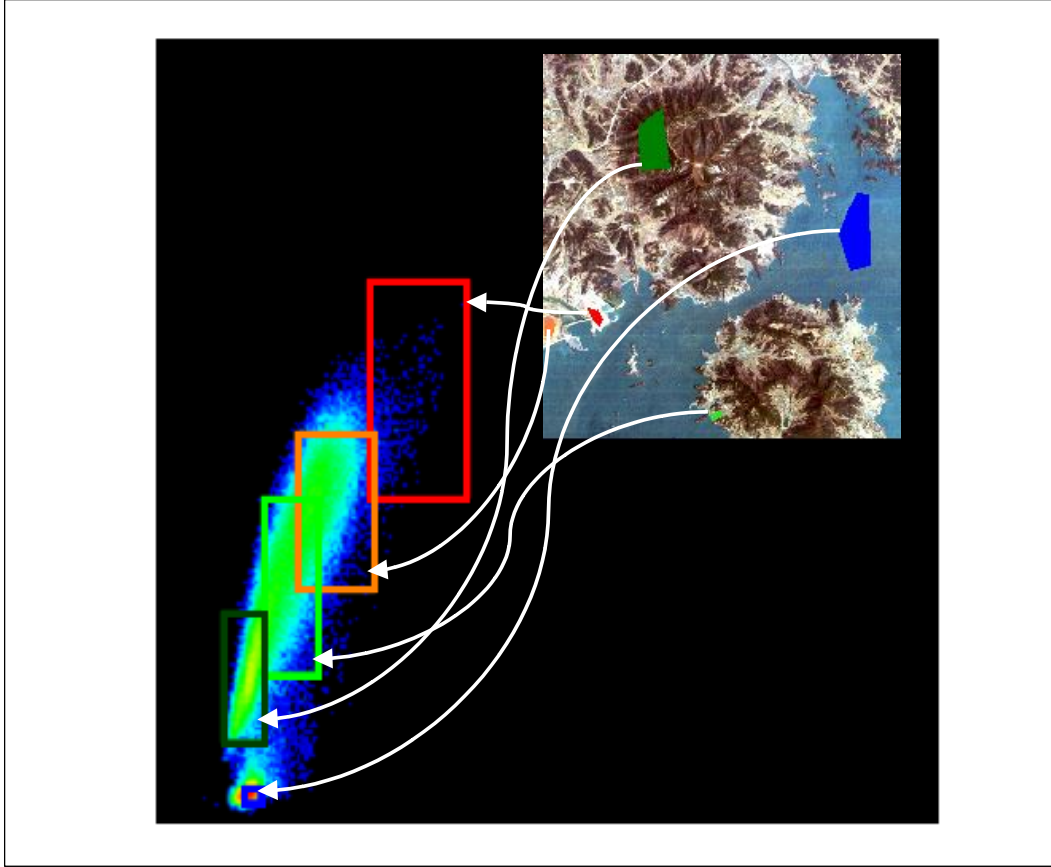


그림 4 훈련 자료들의 평균값과 표준편차값을 이용해서 전체 영상 자료의 스캐터 그램 상에 분류 항목별 훈련 자료들의 분포 양상을 나타냄으로써 분류 항목간의 분리도를 분석하고 있는 과정.

JM 거리는 **최소값이 0**이며 **최대값은 1414**로서 그 값이 클수록 해당 분류 항목간의 분리도가 좋음을 나타낸다.

한편 분류 항목간의 분리도를 나타내는 또 다른 변수로서 *Transformed Divergence* 도 흔히 사용되는데, 분류 항목  $i$  와  $j$  간의 *Transformed Divergence* **TD<sub>ij</sub>** 는 다음과 같이 계산된다.

$$TD_{ij} = 2 \left( 1 - \exp\left(-\frac{D_{ij}}{8}\right) \right)$$

$$D_{ij} = \frac{1}{2} \text{tr}((C_i - C_j)(C_i^{-1} - C_j^{-1})) + \frac{1}{2} \text{tr}((C_i^{-1} - C_j^{-1})(\mu_i - \mu_j)(\mu_i - \mu_j)^T)$$

$C_i$  는 분류 항목  $i$  의 훈련 자료에 대한 공분산 행렬

$\mu_i$  는 분류 항목  $i$  의 훈련 자료에 대한 평균값 벡터

$tr$  은 행렬의 trace

TD는 최소값이 0이며 최대값은 2000으로서 그 값이 클수록 해당 분류 항목간의 분리도가 좋음을 나타낸다.

그림 5은 4 개의 분류 항목간 분광 거리, Transformed Divergence, 그리고 Jeffries-Matusita 거리가 계산되고 있는 예를 나타냈다.

이와 같이 영상 자료를 분류함에 있어 분류 기법뿐 아니라 분류 항목별 훈련 자료의 특징과 분리도가 그 결과의 질에 매우 중용한 영향을 미치며, 또한 훈련 자료의 분광 특징과 분포 특징에 따라서 적절한 분류 기법을 선택할 수 있어야 한다.

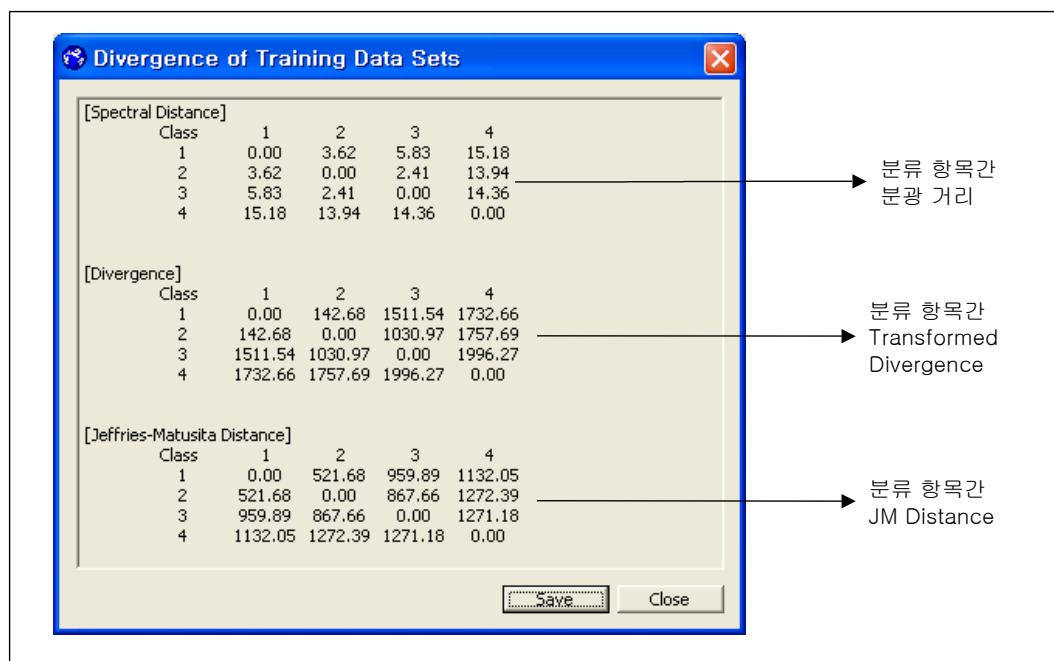


그림 5. 분류 항목간의 분리도(Separability)에 대한 분석을 위하여 흔히 Transformed Divergence 와 Jeffries-Matusita 거리가 이용된다.

## ● 최소 거리법(Minimum Distance Classifier)

최소 거리법에서는 입력 화소로부터 모든 분류 항목의 훈련 자료에 대한 중심까지의 거리를 계산하여 그 거리가 가장 짧은 분류 항목으로 해당 화소의 항목을 설정한다. 이 때, 거리는 단순한 분광 공간상에서의 거리로서 특정 화소 X 로부터 분류 항목 A

간의 거리는 다음과 같이 계산된다.

$$SD_A = \sqrt{\sum_{i=1}^n (\mu_{A,i} - X_i)^2}$$

$n$  은 영상 자료의 밴드 개수

$X_i$  는 해당 화소의  $i$  밴드의 수치 화소값

$\mu_{A,i}$  는 A 분류 항목 훈련 자료의 밴드별 평균값

최소 거리법은 **그림 6**에 나타낸 바와 같이 단순히 훈련 자료의 중심까지의 거리만을 계산하여 분류를 수행하므로 매우 빠르다는 장점을 가지나 훈련 자료의 분포 특성을 고려하지 못한다는 단점을 가지고 있다.

즉, **그림 7**의 경우에서와 같이 훈련 자료가 분포하고 있다면 화소 X는 분광 거리 개념에서는 분류 항목 B에 가장 가까우므로 최소 거리법으로는 분류 항목 B로 분류된다. 그러나 실제 훈련 자료의 분포를 고려한다면 화소 X는 분류 항목 A로 분류되는 것이 타당하다.




그림 6 입력 화소 X는 그 중심까지의 거리가 가장 가까운 분류 항목 B로 분류된다.

### ● 평행 사변형법(Parallelipiped Classifier)

앞서 최소 거리법은 단순히 훈련 자료의 중심까지의 거리만을 계산하여 분류를 수행하므로 훈련 자료의 분포 특성을 고려하지 못한다는 단점을 가지고 있음을 알았다. 평행 사변형법은 훈련 자료의 분포 특성을 고려할 수 있는 가장 간단한 형태의 분류 기법으로서, 분류 항목별 훈련 자료의 평균과 표준편차를 이용하여 훈련 자료의 분포 영역을 설정하고 모든 화소에 대하여 해당 화소가 속하는 영역의 분류 항목으로 분류를 수행한다.

즉, 그림 7에 나타낸 바와 같이 훈련 자료에 대하여 밴드별 평균값과 밴드별 표준편차값을 이용하여 분광 공간상에서 분류 항목별 영역을 설정하고 입력 화소가 어느 영역에 속하는지를 통해서 분류를 수행함으로써 화소 X는 분류 항목 A로 분류되게 된다.

이 때, 영역 설정을 위한 범위를 대개 표준 편차를 기준으로 설정하게 되는데, 예를 들어 1.0의 값을 입력하면  $\mu \pm s$ , 2.0의 값을 입력하면  $\mu \pm 2.0 \times s$ 를 각 밴드별 길이로 하여 평행사변형 영역을 설정하게 된다.

평행 사변형법에서는 어떤 입력 화소들은 어떠한 평행사변형에도 속하지 않을 수도 있으며 이러한 경우 미분류 화소로서 남겨두거나 혹은 최소거리법을 적용하기도 한다




그림 7. 평행 사변형법을 적용하면 입력 화소 X는 분류 항목 A의 평행사변형 영역에 포함되게 되므로 분류 항목 A로 분류된다.

### ● Mahalanobis 거리법(Mahalanobis Distance Classifier)

Mahalanobis 거리는 단순한 분광 거리가 아니라 다음과 같이 훈련 자료의 공분산 행렬이 포함되는 거리 개념으로서 훈련 자료의 분포 양상이 함께 고려된다.



$$D_i = (X - \mu_i)^T C_i^{-1} (X - \mu_i)$$

$D_i$  는 입력 화소의 분류 항목  $i$  까지의 Mahalanobis 거리

$X$  는 입력 화소 벡터(밴드별 수치 화소값 행렬)

$C_i$  는 분류 항목  $i$  의 훈련 자료에 대한 공분산 행렬

$\mu_i$  는 분류 항목  $i$  의 훈련 자료에 대한 평균값 벡터

$T$  는 전치 행렬을 의미함

그림 8 에 나타낸 바와 같이 단순한 분광 거리 개념에서는 입력 화소  $X$ 로부터 분류 항목 B 까지의 거리가 가장 가까우나 Mahalanobis 거리를 기준으로 하는 경우에는 분류 항목 A까지의 거리가 가장 가깝게 되어 화소  $X$  는 분류 항목 A로 분류된다.

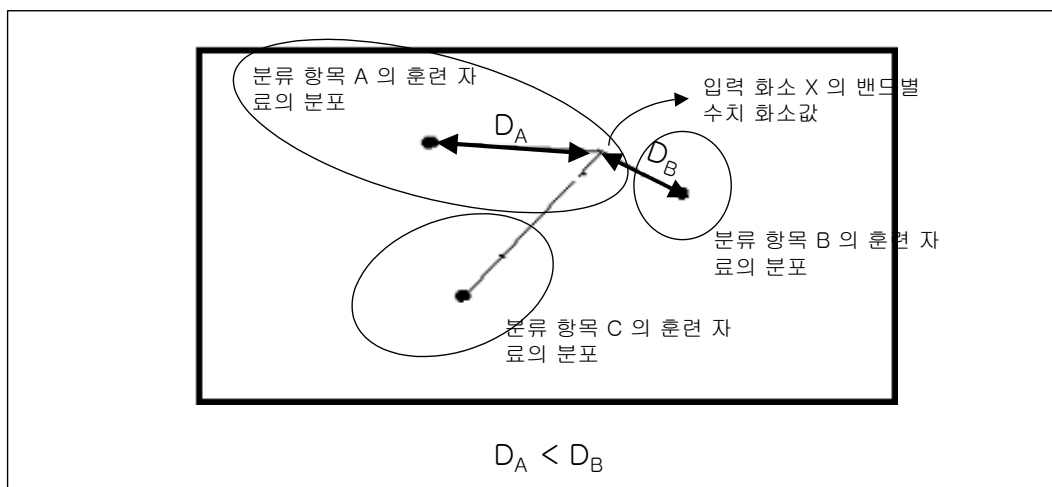


그림 8. Mahalanobis 거리 개념에서는 화소  $X$ 로부터 가장 거리가 가까운 분류 항목은 A가 된다.

### ● 분광 각도법(Spectral Angle Mapper)

분광 각도법에서는 분광 공간상에서의 거리 개념으로 유사도를 판별하는 것이 아니라 입력 화소와 각 분류 항목별 훈련 자료가 중심이 이루는 각도로서 유사도를 판별하는 분류 기법이다.

분류 항목 A의 훈련 자료의 중심 벡터를  $A$ 라 하고 입력 화소  $X$ 에 대한 벡터를  $X$

라고 할 때, 즉  $n$  개의 밴드를 가지는 영상 자료라고 하면,

$$A = (a_1, a_2, a_3, \dots, a_n)$$

$$X = (x_1, x_2, x_3, \dots, x_n)$$

와 같이 주어졌을 때, 입력 화소  $X$  가 분류 항목  $A$  와 이루는 분광 각도는 다음과 같다.

$$\theta = \cos^{-1} \left( \frac{A \cdot X}{\|A\| \|X\|} \right)$$




그림 9. 입력 화소  $X$  는 분광 공간상에서 그 분광 각도가 가장 작은 분류 항목  $B$  로 분류된다.

### ● 최대 우도법(Maximum Likelihood Classifier)

최대 우도법은 정규 분포를 기본으로 한 확률 밀도 함수에 의한 분류 기법으로서 통계적 분류 기법 중 가장 우수한 성능을 보이는 것으로 알려져 있다. 단, 정규 분포에 의한 확률 밀도 함수를 근간으로 하므로 훈련 자료가 정규 분포의 형태를 보이는 경우에만 우수한 성능을 기대할 수 있다.

최대 우도법에서 우도(likelihood)  $D$  는 다음과 같이 계산된다.

$$D_i = \ln(a_i) - 0.5 \ln(|C_i|) - 0.5 (X - \mu_i)^T C_i^{-1} (X - \mu_i)$$

$D_i$  는 입력 화소의 분류 항목  $i$  까지의 Likelihood

$X$  는 입력 화소 벡터(밴드별 수치 화소값 행렬)

$C_i$  는 분류 항목  $i$  의 훈련 자료에 대한 공분산 행렬

$\mu_i$  는 분류 항목  $i$  의 훈련 자료에 대한 평균값 벡터

$I$  는 전치 행렬을 의미함

$a_i$  는 사전 확률(Priori Probability)로서 사전 확률을 사용하지 않는 경우 1.0 이 된다.




그림 10. 분류 항목 A, B 의 훈련 자료의 평균과 분산값은 동일하나 그 자료 분포 방향이 다르다. 최대 우도법에서는 화소 X 는 (a)의 경우에는 분류 항목 A로, 그리고 (b)의 경우에는 분류 항목 B로 분류된다.

그림 10 에 나타냈듯이 최대우도법에서는 훈련 자료의 분포 방향까지도 고려된 분류가 이루어짐으로써 통계적 분류 기법들 중 가장 우수한 분류 성능을 나타내는 것으로 알려져 있다.

즉, 그림 10 의 (a)와 (b)에서 분류 항목 A, B 의 훈련 자료의 평균과 분산값은 동일하나 그 자료 분포 방향이 다르다. 최대 우도법에서는 화소 X 는 (a)의 경우에는 분류 항목 A로, 그리고 (b)의 경우에는 분류 항목 B로 분류된다.

### ● 인공 신경망(Neural Network)

인공 신경망 기법에서는 그림 11 에 나타낸 바와 같이 입력층, 은닉층, 출력층을 구성하고, 입력층에는 입력 영상 자료의 밴드 개수에 해당하는 수의 입력 노드를, 그리고 출력층에는 분류 항목의 개수에 해당하는 수의 출력 노드를 설정한다. 은닉층에는 적절한 수의 은닉 노드를 설정해야 하는데, 대개 입력 노드나 출력 노드 개수의 2 ~ 3배 정도의 은닉 노드를 설정한다. 노드들이 설정되면 모든 노드들을 서로 연결하는 연결강도값을 임의의 값으로 초기화 시킨다.

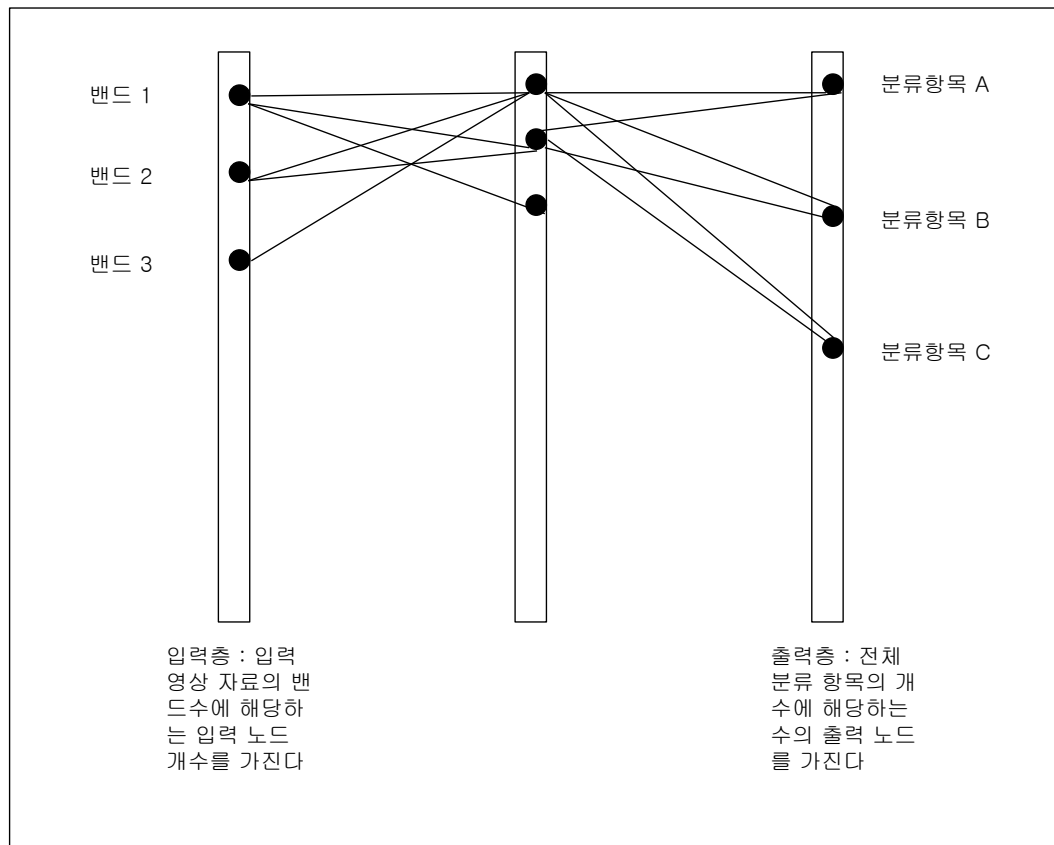


그림 11 인공 신경망 기법에서는 입력층, 은닉층, 출력층을 구성하고, 입력층에는 입력 영상 자료의 밴드 개수에 해당하는 수의 입력 노드를, 그리고 출력층에는 분류 항목의 개수에 해당하는 수의 출력 노드를 설정한다. 훈련 자료를 입력시켜면서 출력층에서 기대하는 값이 계산되어 나오도록 각 노드를 연결하는 연결 강도값들을 반복적으로 갱신시킨다.

이제 각 분류 항목별 훈련 자료의 각각의 화소를 입력층의 각 노드에 입력하고 다음의 수식을 이용하여 은닉층 노드의 값을 계산하고, 은닉층 노드의 값들은 다시 출력층 노드의 출력값을 계산하는데 이용된다.

$$u_j = \sum_i w_{ji} a_i$$

여기에서,  $a_i$ 는 입력 노드에의 입력값이고,  $w_{ji}$ 는 입력노드와 출력 노드를 연결하는 연결 강도값이다. 실제 출력 노드의 값은 대개 활성화 함수를 이용하여 계산되는데, 가장 흔히 이용되는 활성화 함수는 시그모이드 함수로서 다음과 같다.

$$f(u_j) = \frac{1}{1 + \exp(-u_j)}$$

이와 같은 과정을 거쳐 하나의 화소가 입력층에 입력되었을 때 최종적으로 출력층의 출력값이 결정되게 되는데, 입력된 화소의 분류 항목에 따라 이미 원하는 출력값이 설정되어 있다. 즉, 총 분류 항목이 5개 인 경우에 출력 노드는 5개가 설정되며 입력 화소의 분류 항목이 2번째 노드에 해당되는 분류 항목이었다고 하면 출력층에서의 기대값은 (0.0, 1.0, 0.0, 0.0, 0.0)이 된다.

이와 같은 출력 노드에서의 기대값을 라하고, 식 시그모이드 함수에 의하여 계산된 실제 출력 노드에서의 값을  $O$ 라고 하면 그 오류는 다음과 같다.

$$E = \frac{1}{2} \sum_k (T_k - O_k)^2$$

인공신경망 기법의 훈련 단계에서의 최종 목표는 이 오류를 최소화하여 모든 훈련 자료에 대하여 해당 출력 노드에서 최대값이 되도록 하는 것이다. 즉 오류를 최소화하기 위하여 반복적으로 노드간 연결 강도값을 갱신해주어야 한다. 이와 같은 과정을 인공 신경망을 학습시킨다고 하며 다음과 같은 식에 의하여 노드간 연결 강도값의 변경치를 계산하게 된다.

$$\Delta W_{kj} = -\eta \frac{\partial E}{\partial W_{kj}}$$

여기에서  $\eta$ 는 흔히 학습률이라고 부르는 변수로서 인공신경망의 성공적인 훈련을 위하여 매우 중요한 역할을 하게된다. 즉,  $\eta$ 가 너무 작을 경우 노드간 연결 강도값

$w_{ji}$ 의 변화가 너무 적게 되어 매우 많은 반복 학습을 해야되는 경우가 발생 하며, 즉,  $\eta$ 가 지나치게 큰 경우에는 제대로 훈련되지 못한 채로 발산되는 수도 있다.

이와 같은 방법으로 연결 강도값들이 결정되면 인공신경망이 훈련이 완료된 것이며, 이제 실제 영상 자료의 모든 화소들을 입력하여 화소들이 어떤 분류 항목(출력 노드)에서 최대값을 보이는지를 확인함으로써 분류 작업이 수행된다.

### ● 정확도 평가(Accuracy Assessment)

분류된 결과는 그 결과의 타당성을 평가하기 위하여 정확도 평가를 실시한다. 대개 감독 분류 결과에 대하여 정확도 평가가 적용된다. 무감독 분류의 경우에는 그 지역에 대한 사전 정보가 없기 때문에 정확도 평가를 하기 위한 기준 자료가 없다는 면에서 정확도 평가가 적용되지 않는다.

엄밀한 의미에서 분류 결과에 대한 정확도 평가는 이루어질 수 없다. 그 이유는 분류 결과에 대한 정확도를 분석하기 위해서는 사전에 정확한 “정답”을 알고 있어야만 하는데, 위성 영상을 이용하여 수행되는 분류 결과에 대한 “정답”으로 사용할 수 있는 정보는 없기 때문이다. 만일 이러한 사전 정보가 있다면 위성 영상을 분류하는 행위 자체가 불필요하다.

최신의 위성 영상을 이용하여 기존의 정보를 갱신하고 하는 경우에도 분류의 정확도 평가는 무의미하다. 그 이유는 이러한 경우에는 위성 영상의 분류 결과를 “정답”으로 하여 기존 정보를 수정하고자 하는 의도이기 때문이다.

그러므로, 분류 결과에 대한 정확도 평가는 일반적으로 기준 자료를 이용하여 이루어 지는데, 이는 결국 기준 자료에 대한 정확도일뿐 영상 자료 전체에 대한 분류 정확도가 될 수는 없다.

가장 일반적으로는 분류를 위하여 사전에 설정된 훈련 자료를 기준 자료로서 이용하여 평가를 하는 것이 일반적이다. 보다 객관성을 확보하고자 분류 항목별로 설정된 훈련 자료를 분류를 위한 자료와 정확도 평가를 위한 자료로서 나누어서 분류시에는 분류를 위한 훈련 자료만을 이용하고, 정확도 평가는 이들 훈련 자료를 제외한 나머지 훈련 자료를 기준 자료로서 사용하여 정확도 평가를 수행하기도 한다.

정확도 평가 작업 자체는 매우 단순하다. A, B, C의 세 가지 분류 항목으로 분류를 수행하는 경우를 가정하자. 분류 항목 A의 기준 자료 개수가 30 개라 하고, 분류 항목 B의 기준 자료 개수도 30 개, 그리고 분류 항목 C의 기준 자료는 40개라고 가정할 때, 분류 항목 A의 기준 자료 30개중 28개가 분류 항목 A로 분류되었고, 나머지 2개의 기준 자료 중 1개는 분류 항목 B로, 그리고 나머지 1개는 분류 항목 C로 분류되었다고 하면 그림 12과 같은 테이블이 작성될 수 있다.

	분류 항목 A의 기준 자료
분류 항목 A로 분류된 화소	28
분류 항목 B로 분류된 화소	1
분류 항목 C로 분류된 화소	1
합계	30

그림 12 분류 항목 A의 기준 자료 30개중 28개가 정확하게 분류되었으므로, 분류를 직접 수행하여 분류 결과를 생산해낸 생산자 입장에서는 분류 정확도는  $28/30 * 100\% = 93\%$ 가 된다.

그러면, 분류 작업을 직접 수행한 분석자(생산자)의 입장에서는 30개의 화소중 28개가 정확히 분류되었으므로 분류에 대한 생산자 정확도(producer's accuracy)는  $28/30 * 100 = 93\%$ 가 된다.

분류 항목 B의 경우에 전체 30개 기준 자료 중 15개가 분류 항목 B로 분류되었고, 나머지 16개의 기준 자료 중 15개는 분류 항목 A로, 그리고 나머지 1개는 분류 항목 C로 분류되었다고 하고, 분류 항목 C의 기준 자료는 전체 40개 중 20개가 분류 항목 C로 분류되었고, 나머지 20개의 기준 자료 중 15개는 분류 항목 A로, 그리고 나머지 5개는 분류 항목 B로 분류되었다고 하면 최종적으로 그림 13에 나타난 바와 같은 테이블이 작성될 수 있다.

이 때, 같은 방법으로 분류 항목 B는  $15/30 * 100\% = 50\%$ , 그리고 분류 항목 C는  $20/40 * 100\% = 50\%$ 의 생산자 정확도를 보인다고 말할 수 있다. 한편 전체적으로는 총 100개의 기준 자료( $30+30+40$ ) 중 63개( $28+15+20$ )의 자료가 정확히 분류되었으므로 전체 정확도(overall accuracy)는  $63/100 * 100\%$ 이다.

한편, 분류 결과를 생산해낸 입장이 아닌 분류 결과를 받아 보는 입장에서는 분류 항목 A로 분류되어 있는 화소 57개 자료( $28 + 14 + 15$ ) 중 실제 분류 항목 A인 자료는 28개 이므로 정확도를  $28/57 * 100\% = 49\%$ 라고 생각할 수 있다. 이와 같은 시각은 분류 결과를 생산한 생산자가 아니라 분류 결과를 받아보는 사용자 입장이므로 사용자 정확도(user's accuracy)라고 하며 그림 14에 나타난 바와 같이 정리될 수 있다. 이와 같은 테이블을 오차 행렬(error matrix) 혹은 정확도 행렬(contingency matrix)라고 부른다.

	분류 항목 A	분류 항목 B	분류 항목 C
분류 항목 A로 분류된 화소	28	14	15
분류 항목 B로 분류된 화소	1	15	5
분류 항목 C로 분류된 화소	1	1	20
합계	30	30	40
생산자 정확도	$93\%(28/30*100)$	$50\%(15/30*100\%)$	$50\%(20/40*100\%)$

## Chapter 15: Supervised Image Classification

그림 13 분류 항목 A의 기준 자료 30개중 28개가 정확하게 분류되었으므로, 분류를 직접 수행하여 분류 결과를 생산해낸 생산자 입장에서는 분류 정확도는  $28/30 * 100\% = 93\%$  가 된다. 마찬가지로 분류 항목 B는 50%, 분류 항목 C도 50%의 분류 정확도를 가지고 있다.

	분류 항목 A	분류 항목 B	분류 항목 C	합계	사용자 정확도
분류 항목 A 로 분류된 화소	28	14	15	57	49% (28/57*100%)
분류 항목 B 로 분류된 화소	1	15	5	21	71% (15/21*100%)
분류 항목 C 로 분류된 화소	1	1	20	22	91% (20/22*100%)
합계	30	30	40	100	
생산자 정확도	93% (28/30*100%)	50% (15/30*100%)	50% (20/40*100%)		

그림 14 오차 행렬과 생산자 및 사용자 정확도.

한편 **Kappa 계수**는 분류에 있어 우연히 옳게 분류될 수 있는 확률을 제거하여 보다 더 정확한 분류 정확도를 정량적으로 나타내기 위하여 제안된 계수로서 다음의 식과 같이 옳게 분류된 전체 화소 수에서 우연히 옳게 분류될 수 있는 화소 수를 뺀 값을 전체 화소 수에서 우연히 옳게 분류될 수 있는 화소 수를 뺀 값으로 나눈 값이 된다.

$$k = \frac{\text{옳게분류된전체화소수} - \text{우연히옳게분류될수있는화소수}}{\text{전체화소수} - \text{우연히옳게분류될수있는화소수}}$$

이 때, 우연히 옳게 분류될 수 있는 화소의 수는 다음과 같은 방법으로 계산된다. 즉, 분류 항목 B 의 기준 자료 30개 중 우연히 분류 항목 C 로 분류될 수 있는 화소의 수는 (분류 항목 C 로 분류된 전체 화소 수 X 분류 항목 B 의 전체 기준 자료 수) / (전체 화소수)이다. 즉, 그림14에서 분류 항목 C 로 분류된 전체 화소 수는 22개이고 분류 항목 B 의 전체 기준 자료 수는 30개이므로  $22 \times 30 / 100 = 6.6$  이다. 즉, 분류 항목 B의 기준 자료 중 우연히 분류 항목 C로 분류될 수 있는 자료의 수는 약 7개 이다.

이와 같은 방법으로 분류 항목 A, B, C 의 기준 자료 중 우연히 분류 항목 A, B, C 에 분류될 수 있는 화소의 수는 각각  $17(57 \times 30 / 100)$ ,  $6(21 \times 30 / 100)$ ,  $9(22 \times 40 / 100)$ 로 계산된다. 따라서 전체적으로 우연히 옳게 분류될 수 있는 화소의 수는  $32(17+6+9)$ 가 된다. 따라서 그림 14 에 나타난 오차 행렬에 대한 Kappa 계수는 다음과 같이 계산된다.

$$k = \frac{63 - 32}{100 - 32} \times 100\% = 45.5\%$$

전체 정확도가 63% 과 비교할 때 Kappa 계수에 의한 정확도는 45.5%로 매우 낮음을



알 수 있다.

그림 15 에는 입력 영상 자료와 분류 결과에 대한 오차 행렬의 예를 나타냈다. 오차 행렬을 이용한 정확도 평가는 사용되는 기준 자료의 제한성으로 말미암아 분류 결과에 대한 정확도 평가라기보다는 훈련 자료의 질과 훈련 자료의 특징에 따른 적절한 분류 기법이 사용되었는가 등 분류 과정 및 절차가 적절했는지를 나타내는 지표라 하겠다.

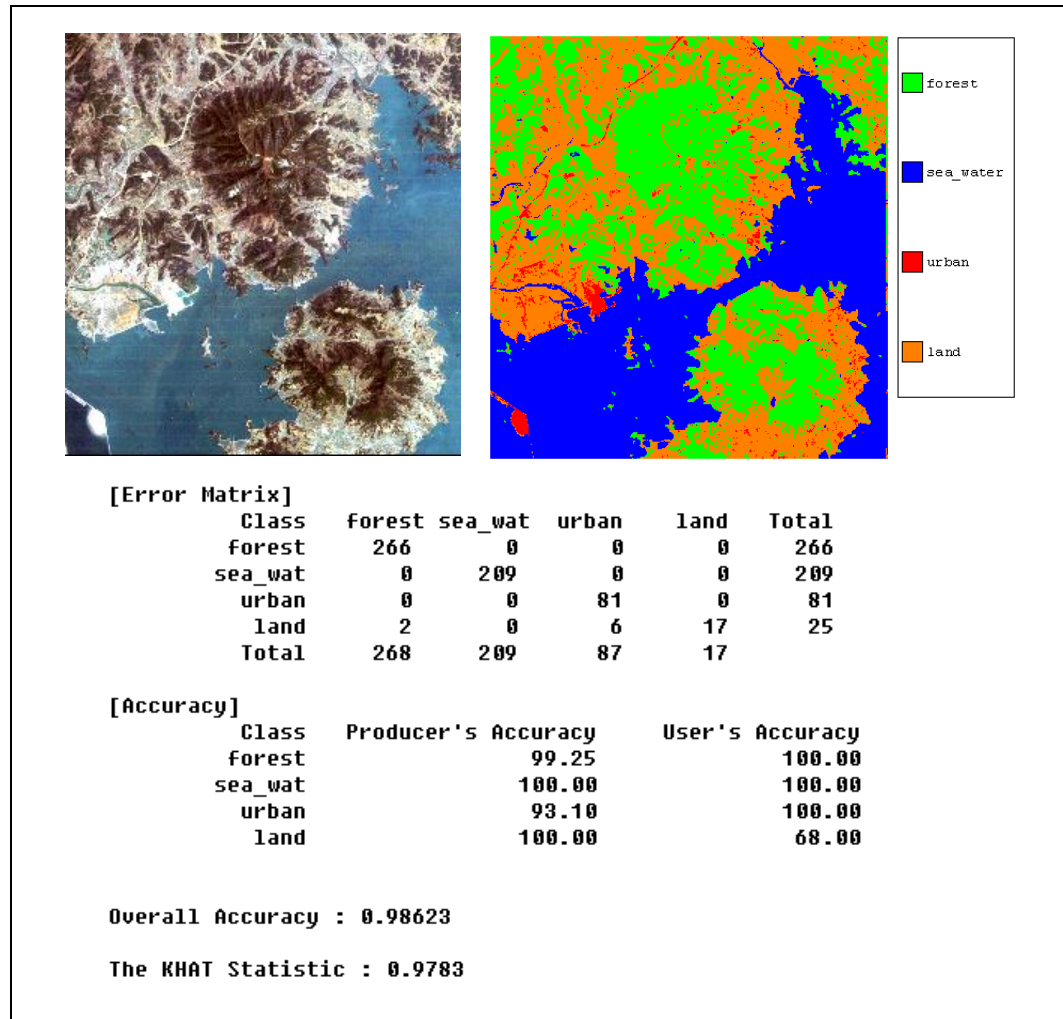


그림 15 위성 영상 자료의 분류 결과에 대한 정확도 평가의 예.

