위성전파 신호처리 기술 개발

1999

전파연구소

한국통신학회

제 출 문

본 보고서를「위성전파 신호처리 기술 개발」과제의 최종보고서로 제출합니다.

1999. 12.

총괄연구책임자 : 이 경 호(전파연구소)
연 구 책 임 자 : 이 준 환(전북대학교)
연 구 책 임 자 : 이 황 재(전파연구소)
연 구 원 : 김 준 철(서남대학교)
연 구 원 : 곽 장 호(전파연구소)
연 구 원 : 박 수 영(전파연구소)
연 구 보 조 원 : 최 종 호(전북대학교)

요 약 문

1. 목적 및 필요성

가. 위성에 탑재된 관측센서에 의해서 획득된 위성정보를 응용 및 활용하기 위해서는 신호처리 및 특성 분석과정이 필요

- o 방대한 위성 데이터의 압축 및 Channel reduction
- o 다 대역 위성정보의 잡음제거, 공간필터링 등 데이터 향상
- o 경계개선, 대비도 강조 등 데이터 강조 및 개선

나. 위성정보 추출 알고리즘 개선 및 프로그램 개발

- o 위성정보 종합처리 및 분석 소프트웨어 개발환경의 기반 구축
- o 위성전파 특성, 센서특성, 관측정보 분석 등 정보추출 및 분석

2. 연구내용 및 범위

가. 위성 영상 데이터의 잡음 모델링과 비선형 잡음제거 기법 연구

- o 다 채널 잡음 모델링 및 잡음 발생기 구현

  - 다 채널 잡음 생성 과정 : 위성 영상은 다 채널이기 때문에 다 채널 잡음 발생기를 구성 잡음의 확률 분포에 관한 개념을 고려하여 가산 잡음(additive noise)만을 고려. 만약

잡음이 원 신호와 승산 형태로 발생된다면 로그연산에 의해 가산 잡음의 형태로 구성

- 임펄스 잡음 발생기 : 다 채널 잡음 발생기를 구성하기 위해서는 다차원 랜덤 프로세스 $\boldsymbol{n}$ 을 생성시켜야 하며, 임펄스 잡음시 신호의 최소치 $s_{\min}$과 최대치 $s_{\max}$를 이용할 계획임. 임펄스 잡음은 그레이 영상에서 임펄스 잡음을 생성시키는 것과 유사한 방법으로, 동일한 확률을 가진 음과 양의 임펄스 잡음을 생성

- 실제 위성영상에서 잡음은 채널 사이에 상관관계(correlation)를 갖고 있으므로, 상관관계를 가진 잡음 모델을 고려

- 가우시안 잡음 발생기
  임의의 벡터 $\boldsymbol{X}$ 의 다변수 가우시안 분포는 다음 식으로 표현

$$f(\boldsymbol{X}) = \frac{1}{(2\pi)^{p/2}|\boldsymbol{\Sigma}|^{\frac{1}{2}}} \exp\left[-\frac{1}{2}(\boldsymbol{X}-\boldsymbol{\eta})^T\boldsymbol{\Sigma}^{-1}(\boldsymbol{X}-\boldsymbol{\eta})\right]$$

다 채널에서 채널의 개수가 3개인 경우, 3 채널이 대칭이라는 가정을 이용하여 다음과 같은 행렬 $\boldsymbol{A}$ 를 선택하여 상관관계가 있는 다 채널 가우시안 잡음을 생성

$$\boldsymbol{A} = \begin{bmatrix} a & b & b \\ b & a & b \\ b & b & a \end{bmatrix}$$

o 비선형 잡음 제거 기법에 관한 연구

- 비선형 필터링
  - M-추정기의 형태인 퍼지 클러스터 필터를 개발
  - 본 연구에서는 다 채널 위성 영상 신호의 비선형 필터링을 위해 M-추정기의 일종인 가능적 c-means 클러스터링 방법을 이용한 퍼지 클러스터 필터를 개발
  - 개발될 퍼지 클러스터 필터의 결과와 기존의 비선형 필터인 벡터 미디안 및 벡터 α- *trimmed* 평균필터의 결과 등과 비교 분석

- 퍼지 클러스터 필터
  - 영상 신호의 비선형 필터링을 위해 가능적 c-means 클러스터링 방법을 사용
  - 소속함수를 퍼지 클러스터 필터의 가중치로 이용

나. 위성 데이터의 질감 속성 연구

o 각 대역별 신호크기 값으로만 위성데이터를 분류하는 데는 한계가 있기 때문에 대역간 신호크기 관계를 고려하는 다중 대역 위성데이터의 질감 속성에 대한 연구를 수행

o 특별히 위성데이터의 질감 속성을 추출하는 여러 가지 방법중 통계적 방법이 좋은 결과를 얻을 수 있다고 보고되고 있기 때문에 다음과 같은 통계행렬을 다중대역으로 확장하고 이들 행렬들로부터 유용한 질감 속성을 추출하는 방법들을 연구

- 이계 통계치를 구하는 SGLDM의 확장
- 대역신호의 국부적인 신호크기의 변화를 표현하는 NSGLDM의 확장
- 대역 신호크기의 run-length를 표현하는 GLRLM의 확장

o 대역내의 2계 통계행렬들을 대역간의 통계행렬 범위로 확장하여 다양한 벡터 속성을 추출하는 방법을 제안

o 벡터 속성들

- 통계 행렬들을 그대로 질감 속성으로 이용할 경우 차원이 너무 크기 때문에 이를 의미 있는 방향으로 투사하여 유용한 위성 데이터의 질감 속성을 개발

o 질감 속성 벡터의 성능 측정

- 개발된 질감 속성 벡터의 성능을 측정하기 위해서는 분별력으로 판별할 수 있으나 분별력을 평가하는데는 어떤 (비)유사성 척도를 사용하는 가는 중요한 문제이므로, (비)유사성 척도는 계산량과 분별기 효율의 관점에서 비교되고 선택되어져야 함. 본 연구에서는 이들 (비)유사성 척도에 대한 조사연구가 포함됨.

o 질감 속성 평가를 위한 분별기

- 벡터 속성의 성능을 실험적으로 검토하기 위한 신경회로망 분별기 구성

다. 구역분할 관점의 Dynamic KL변환 연구

- Ohta의 방법을 다중대역에 적용하는 방법으로 확장하는 방안을 검토
- 과정은 관심 구역들의 다중대역 데이터에 대한 KL변환을 수행하고 각각의 변환속성에 대한 Histogram을 얻어내고 두드러진 구역분할을 제공하는 변환벡터들의 통계치를 구하여 두드러진 변환벡터를 찾아내는 방법으로 진행

라. 시뮬레이션을 통한 성능평가와 통합 소프트웨어 환경개발

o 시뮬레이션을 통한 성능평가

- IDL 또는 Visual C++을 이용하여 시뮬레이션 프로그램 개발
- 수집된 위성데이터를 이용하여 알고리즘 성능평가

o 통합 소프트웨어 환경개발

- Windows 98 환경 이상에서 시뮬레이션 알고리즘이 이용 가능하도록 사용자 인터페이스 개발

3. 연구결과

가. 임펄스 잡음 및 가우시안 잡음 발생기 구현

- 다채널 데이터 각각의 채널 및 채널 상호간의 상관관계를 갖는 잡은 발생가능
- 필터링 성능평가를 위한 모의실험에 사용가능

나. 비선형 필터링 구현

- 가중화된 α-trimmed 평균 및 퍼지클러스터 필터 제안
- 모의실험을 통한 성능 측정

다. 위성데이터의 질감 속성 연구

- 그레이 레벨 통계 행렬들을 대역간 통계 행렬로 확장
- 유용한 위성데이터의 질감 속성 벡터 개발
- 제안한 질감 속성 벡터를 평가하기 위한 신경망 분별기를 구성하여 영상분별시 우수성 입증

라. Dynamic KL 변환을 다중 대역에 확장 방법 구현

- 시뮬레이션 프로그램은 프로그램 개발
- Stop 및 LANSAT 위성데이터에 대한 실험
- 구역화시 성능은 양호하나 변환 Kernel을 구현하는데는 문제가 있었음

4. 연구결과 활용

o 학술발표대회 및 학술지 논문 발표

- 학술대회 발표 : 위성데이터의 압축기법, 잡음제거, 질감 속성 추출의 중간 결과는 국내 또는 국제학술대회에 논문을 발표

- 학회지 투고 : 최종 연구결과는 원격탐사 분야의 국제 학회지 및 국내 학회지에 논문을 발표

o 지적재산권 획득

- 개발된 알고리즘은 국내 방식특허를 출원

5. 기대효과

o 위성전파를 여러 응용 분야에 활용하기 위해서는 정보 추출 및 처리 과정이 필요하므로 개선된 알고리즘과 소프트웨어를 이용하여 관련분야 이용자가 손쉽게 위성신호를 이용할 수 있도록 네트웍을 통한 온라인 처리 및 분석 시스템을 구성하여 활용

o 위성전파 보정, 분류, 정합, 모델링 등의 신호처리 및 분석에 적용 가능하며, 향후 증가하는 위성신호 수요에 대비한 양질의 데이터 추출 및 활용 가능

o 위성전파 특성분석 등의 전파 품질 및 GIS 등의 분야에 활용

SUMMARY

The observation of the earth with satellite provides very important information for various areas such as environment, agriculture, geology, ocean, military, and so on. For the efficient use of the information, it is necessary to process and to analyze the electromagnetic signals. It is needed to compress the huge amount of satellite data effectively and to reduce the dimension of the data by unnecessary channel reduction. Also, the image data should be enhanced the image data with noise reduction and spatial filtering of multichannel satellite data and to emphasize edges of region boundaries and improve the contrast.

In this research, we have developed the processing and analysis algorithms that include

- nonlinear noise reduction techniques with noise modelling
- vector features induced from matrices for the texture, and a neural net classifier
- dynamic KL-transform for region segmentation

for multichannel satellite data, and the software environments to integrate the developed algorithms. In the experiment, our proposed WVα-M filter performs best in NMSE sense, the proposed vector features for texture shows pretty good classification results, and we showed the dynamic KL-transform can be efficiently used to segment the multichannel data such as SPOT and LANDSAT. The developed software can be easily

extended by adding the new methods potentially developed in the feature, because it is well structured in object-oriented fashion.

목 차

표 목 차 xiii
그림목차 xiv

제 1 장 서론 1

제 2 장 위성데이터를 이용한 영상처리 10
2.1 원격탐사의 정의 10
2.2 위성을 이용한 원격탐사에 요구되는 기술 요소 12
2.3 위성영상의 종류 및 제원 13

제 3 장 위성데이터 잡음 제거 14
3.1 다 채널 잡음 모델 14
3.2 벡터 미디안 필터(VMF: Vector Median Filter) 19
3.3 BVDF와 GVDF 23
3.3.1 BVDF(Basic Vector Directional Filter) 24
3.3.2 GVDF(Generalized Vector Directional Filters) 26
3.4 벡터 α-trimmed 평균 필터와 제안된 가중화된 벡터 α-trimmed 평균 필터 29
3.4.1 벡터 α-trimmed 평균필터 29
3.4.2 제안된 가중화된 벡터 α-trimmed 평균 필터 30
3.5 제안된 퍼지 클러스터 필터 32
3.5.1 퍼지 c-mean 클러스터링 알고리즘 32

3.5.2 가능적(possibilistic) c-mean 클러스터링 34
3.5.3 제안된 퍼지 클러스터 필터(Fuzzy Cluster Filter) 36
3.6 조건적인 필터링 39
3.6.1 다 채널 칼라영상 윤곽선 검출기 39
3.6.2 조건적인 필터링을 위한 알고리즘 42
3.7 실험 및 결과 44

제 4 장 위성데이터 질감 속성 52
4.1 질감 속성 및 방법 52
4.2 대역간 통계 행렬의 확장 56
4.2.1 행렬 속성의 정의 56
4.3 벡터 속성 추출 60
4.4 질감 속성 벡터의 성능 측정 및 분별기 63
4.4.1 (비)유사성 측도 63
4.4.2 다 채널 영상의 분별기 65
4.4.3 분류 네트웍의 구성 66
4.5 실험 및 고찰 68
4.5.1 실험 방법 및 사용 영상 68
4.5.2 위성영상의 분류 및 결과 분석 69

제 5 장 Dynamic KL 변환을 이용한 분류 73
5.1 Ohta의 방법 74
5.2 다중대역으로 확장된 Dynamic KL 변환 76
5.3 실험 및 고찰 79
5.3.1 SPOT 영상을 이용한 실험 79
5.3.2 Lansat 영상을 이용한 실험 84

제 6 장 통합 프로그래밍 개발 90
6.1 프로그램 개발 환경 90
6.2 윈도우즈 기반 프로그래밍 구성 모듈 90
6.2.1 위성 영상 입출력 모듈 91
6.2.2 구역분할 관점의 Dynamic KL변환 분류 모듈 92
6.2.3 비선형 잡음 발생기 및 제거 기법 모듈 95

제 7 장 결론 98

참고문헌 102

표 목 차

표 1. SPOT-1 영상에서의 각 필터들의 NMSE값($\times 10^{-2}$) 45
표 2. SPOT-2 영상에서의 각 필터들의 NMSE값($\times 10^{-2}$) 45
표 3. SPOT-3 영상에서의 각 필터들의 NMSE값($\times 10^{-2}$) 45
표 4. 행렬과 벡터 속성 62
표 5. SPOT 영상의 Covariance Matrix 81
표 6. SPOT 영상의 Eigen Value 81
표 7. Ohta의 Eigen Vector 82
표 8. SPOT 영상의 Eigen Vector 82
표 9. Lansat 영상의 Covariance Matrix 85
표 10. Lansat 영상의 Eigen Vector 85

그 림 목 차

그림 2.1 원격 탐사 흐름도 11
그림 3.1 잡음 생성 과정의 블록 다이어 그램 14
그림 3.2 신호원 잡음과 검출기 잡음 성분을 보여주는 시스템 모델 20
그림 3.3 스칼라 미디안 필터링에서 윤곽선 근처에 있는 임펄스 23
그림 3.4 벡터 미디안 필터링에서 윤곽선 근처에 있는 임펄스 23
그림 3.5 2차원 벡터의 집합 26
그림 3.6 (a) 1차원 벡터 값을 가진 신호
(b) n=5인 신호의 BVDF의 적용
(c) n=5, k=3인 신호의 GVDF의 적용
(d) GVDF와 후처리 과정으로 스칼라 미디안 적용 28
그림 3.7 방향성 처리와 후처리과정으로 크기 처리를 한 다 채널
영상처리 29
그림 3.8 임펄스 잡음 4%의 SPOT-1영상 필터링 결과 46
그림 3.9 임펄스 잡음 4%의 SPOT-2영상 필터링 결과 47
그림 3.10 임펄스 잡음 4%의 SPOT-3영상 필터링 결과 48
그림 3.11 σ= 15인 가우시안 잡음의 SPOT-1영상 필터링 결과 49
그림 3.12 σ= 15인 가우시안 잡음의 SPOT-2영상 필터링 결과 50
그림 3.13 σ= 15인 가우시안 잡음의 SPOT-3영상 필터링 결과 51
그림 4.1 SVDM의 예 57
그림 4.2 NSVDM의 예 58
그림 4.3 VRLM의 예 59
그림 4.4 위성영상 데이터의 영상분석 블록 다이어그램 66
그림 4.5 훈련과정 67
그림 4.6 2층 신경망 구조 68
그림 4.7 SPOT Multispectral Image captured in Sept. 29, 1997. . 69

그림 4.8 선택된 훈련집합 69
그림 4.9 제안한 속성벡터를 사용한 실험 결과 72
그림 5.1 Dynamic KL변환의 과정 75
그림 5.2 다중대역으로 확장된 Dynamic KL 변환 분류 76
그림 5.3 KL변환된 영상의 히스토그램과 Smoothing(SPOT-1) 78
그림 5.4 제안한 방법을 이용한 분류 결과(SPOT-1) 78
그림 5.5 Dynamic KL변환에 사용된 SPOT 영상 80
그림 5.6 그림 5.5의 분류 결과 83
그림 5.7 실험에 사용된 Lansat-1 영상 86
그림 5.8 실험에 사용된 Lansat-2 영상 87
그림 5.9 Lansat-2 영상의 히스토그램(KL변환 전) 87
그림 5.10 Lansat-2 영상의 히스토그램(KL변환 후) 88
그림 5.11 히스토그램 Smoothing 결과 88
그림 5.12 제안된 알고리즘을 이용한 결과 89
그림 6.1 위성 영상의 입출력 대화상자 91
그림 6.2 입력된 위성 영상 92
그림 6.3 선택된 밴드의 히스토그램 93
그림 6.4 히스토그램 Smoothing 93
그림 6.5 제안한 방법으로 분류된 영상 94
그림 6.6 Landsat 영상을 이용한 분류 94
그림 6.7 잡음이 있는 영상 입력 95
그림 6.8 필터의 종류를 선택하는 대화상자 96
그림 6.9 선택된 필터의 파라미터를 정하는 대화상자 96
그림 6.10 잡음이 제거된 영상 97

제 1 장 서론

위성전파 이용기술은 인공위성으로부터 전송되는 위성전파 신호를 수신, 처리, 분석하여 여러 응용분야에 효과적으로 활용하는 기술로서, 특히 인공 위성을 이용한 지구관측 정보는 환경, 농업, 지질, 해양, 군사 등 광범위한 분야에 활용되고 있으며 최근 새로운 응용기술의 발달로 그 활용범위가 날로 확대되고 있다. 위성을 이용한 지구관측 정보는 위성에 탑재된 광학센서와 마이크로파 센서를 통하여 우주상공에서 지구를 관측 촬영한 것으로, 짧은 시간에 넓은 지역을 동시에 관측할 수 있고 반복 측정이 가능하며 관측자료가 디지털 수치로 기록되어 판독이 용이하고 정량화가 가능하므로 지상 정보 획득에 많은 이점을 가지고 있다. 또한 관측파장 대역이 가시광선에서 적외선에 이르는 다중 파장대역으로 관측 지역 및 밴드 특성에 따라 다양하고 특색 있는 정보를 취득할 수 있으므로 목적에 따라 우주, 지상, 해양 등 광범위한 분야에서 많은 수요가 예측된다.

최근 센서의 발달로 인하여 센서의 종류도 다양해 졌으며, 획득되고 전송되는 데이터 양도 방대해짐에 따라 위성에서 전송되는 위성전파를 수신하여 필요한 정보를 추출하고 활용하기 위해서는 위성전파를 수신하여 필요한 정보를 추출하고 활용하기 위해서는 위성전파 처리 및 분석기술 개발에 관한 연구가 지속적으로 수행되어야한다. 특히 정보기술을 기반으로 하는 GIS 시스템의 구축은 지속적으로 위성데이터를 필요로 할 것이다. 이와 같이 유용성이 많은 위성영상 데이터를 다양한 분야에 효과적으로 적용하고 활용하기 위해서는 이용분야에 적합한 영상처리 및 분석과정이 선행되어야 하며 그 동안 많은 연구와 기술 개발이 이루어져 왔으나 국내연구의 경우 기존 알고리즘

의 활용으로 시스템개발 측면이 강조되어 고급요소 기술의 개발이 소외되는 경향이 있다.

모든 물체는 종류와 환경이 다르면 서로 다른 전자파를 반사 혹은 복사하는 특성을 가지고 있는 물체의 전자파 특성에 기초하여 원격탐사에 의해 지표의 대상물과 현상을 판독, 해석할 수 있다. 그러나 원격 탐사에 의해 관측되는 위성영상의 경우 영상 데이터가 수집될 때 관측기와 대상 물체 사이에 가로놓인 대기에 의한 효과나 센서 자체의 결함 또는 데이터 송수신시의 문제로 인하여 실제로 대상 물체에는 존재하지 않았던 다 채널 잡음이 생겨날 수 있다. 본 연구에서는 이러한 다 채널 잡음을 제거하기 위하여 비선형 필터의 한 형태인 퍼지 클러스터 필터를 개발하고 또한, 잡음이 발생한 위성영상에서 개발한 필터의 성능 평가를 하기 위해 다 채널 잡음을 생성하는 다 채널 잡음 발생기를 구현하고자 한다.

다 채널 위성은 잡음 센서나 채널 전송 에러에 의해 생기는 잡음에 의해 자주 오염되어진다. 이와 같은 잡음 제거를 위한 비선형 필터링 기술은 1958년 초부터 연구되어 왔으며, 비선형 필터링 기술로는 미디안(median) 필터, 순서 통계(order statistics) 필터, 스택(stack) 필터, 형상학(morphological) 필터 등이 있다. 이들 잡음 제거를 위한 비선형 필터중 비교적 단순한 필터는 미디안 필터이다. 미디안 필터는 1971년 Tukey에 의해 제안되었으며, 윤곽선(edge) 보존 능력과 잡음 제거 능력이 우수하며 화질 개선, 윤곽선 검출, 부호화(coding), 비디오 영상의 필드율 변환(filed rate up-conversion), 음성신호 처리, 위성영상 신호 처리등 많은 분야에서 응용되어 왔다.

다 채널 위성 영상들 역시 입력센서나 채널 전송시 오류가 발생하여 잡음에 오염되는 경우가 많다. 따라서, 이러한 다 채널 위성 잡음을 제거하기 위하여 벡터 미디안(vector median : VMF), 벡터 α

-trimmed 평균필터(vector α-trimmed mean filter : VαTM)등 여러 형태의 필터들이 개발되어져 왔다. 본 연구에서는 임펄스 잡음, 가우시안 잡음에서 양호한 성능을 보이고, 특히 혼합된 잡음 환경에서 우수한 성능을 보이는 퍼지 클러스터(fuzzy cluster) 필터를 제안하였으며, 혼합된 잡음에서 우수한 성능을 보이는 벡터 α-trimmed 평균필터를 개선하여 가중화된(weighted) 벡터 α-trimmed 평균필터를 제안하였다.

본 연구에서 제안된 퍼지 클러스터 필터는 가능적 c-mean 클러스터링(possibilistic c-mean clustering) 방법을 이용하였는데, 이것은 가능적 c-mean 클러스터링 방법의 경우 소속함수 값이 다른 클러스터와 무관하며, 속성과 그 클러스터 중심간의 거리에만 의존하기 때문에 퍼지 c-mean 클러스터링 방법에 비해 잡음에 오염된 환경하에서 강건한 소속함수(robust membership) 값을 얻을 수 있기 때문이다. 본 연구에서 퍼지 클러스터링은 잡음을 제거하거나 원래의 신호를 smoothing하기 위해 사용되어지고 윈도우 내의 화소들만을 이용하여 클러스터링의 목적함수(objective function)를 최소화하는 출력을 추정한다. 소속함수 값은 윈도우내의 화소와 클러스터 중심값 사이의 거리에 의해 결정되어 지고 출력은 소속함수에 의해 가중된 윈도우 내의 화소들의 평균값에 의해 결정되어진다.

원래 벡터 α-trimmed 평균필터는 임펄스 잡음의 제거에 우수한 성능을 보이는 미디안 필터 장점과 가우시안 잡음의 제거에 뛰어난 평균필터의 장점을 살린 절충 형태의 필터이다. 본 연구에서는 윈도우 내의 모든 화소에 동일한 가중치를 부여하는 벡터 α-trimmed 평균필터를 개선하여, 윈도우 내의 화소들을 벡터 정렬 방법을 이용하여 정렬한 뒤 중심에 있는 화소에는 좀 더 가중치를 부여하여 가중화된 평균 필터링을 수행하는 가중화된 벡터 α-trimmed 평균필터를

제안하였다.

또한, 기존의 필터링 방법의 경우 윈도우내의 중심 화소가 잡음이 건 아니건간에 필터링과정이 다 채널 위성 영상의 전영역에 걸쳐 균일하게 적용되어 지기 때문에 잡음에 오염되지 않은 화소를 변형시키거나 윤곽선을 왜곡 시키는 문제점이 발생하게 된다. 따라서, 본 연구에서는 이와같은 문제점을 해결하기 위해 칼라 윤곽선 검출기를 이용하여 윤곽선 영역과 smooth 영역을 구분한 뒤 각 영역에서 칼라 임펄스와 원래의 화소값을 구분한 뒤 선택적인 필터링을 하는 조건적인 필터를 제안하였다. 그리고, 이를 기존의 필터들과 성능을 비교 평가하여 보았다.

본 연구에서는 다 채널 잡음이 발생한 영상에서 제안한 필터의 성능을 평가하기 위해 다 채널 잡음 발생기를 구성하였으며, 이러한 환경 하에서 제안된 필터의 성능을 기존의 필터들과 그 결과를 비교 검토하였다. 실험 결과 NMSE(Normalized Mean Squared Error)관점에서 볼 때, 제안된 필터중에서, 임펄스 잡음에서나 가우시안 잡음이 있는 실험 영상에서 가중화된 벡터 α-trimmed 평균 필터가 가장 우수한 결과를 얻었다.

수신된 위성영상 분석에 있어서 영상내의 물체나 지역 등을 식별하는데는 밝기, 칼라 및 질감 등의 정보 추출이 필수적이다. 각 대역별 신호크기 값으로만 위성데이터를 분류하는데는 구별이 모호한 물체가 있는 영상을 처리할 때는 한계가 있기 때문에 대역간 신호크기의 관계를 고려하는 다중대역 위성데이터의 질감 속성에 대한 연구가 수행되어야한다. 위성에서 관측된 다중분광 위성영상 데이터를 이용 목적에 따라 분석하고 활용하기 위해서는 영상 자체에 내포된 밝기, 칼라, 질감 등 다양한 특징들이 중요한 정보원으로 이용되고 있다. 특히 질감이나 칼라정보를 이용한 위성영상의 분석과정에서 가장 중요

한 문제는 원 영상의 정보를 효율적으로 표현하는 속성을 추출하여 적절히 활용하는 것이다. 일반적으로 위성영상의 분석과정에서는 칼라, 크기, 형태, 질감, 패턴, 높이, 음영, 위치, 연관성 등의 기본요소들이 사용되며, 특히 위성영상을 이용하여 지상에 분포되어 있는 물체나 지역 등을 식별하고 분류하기 위해서는 밝기, 칼라, 질감 등의 특징이 중요한 정보원으로 사용되고 있다. 질감 속성을 추출하는 방법에는 구조적인 방법, 통계적 인 방법, 모델을 이용하는 방법등이 사용되고 있으며, 이들 중 통계적인 방법이 미시적인 질감 영상의 분석에 좋은 결과를 얻을 수 있다고 보고되고 있다.

영상의 통계적 성질을 표현하는 행렬로는 이계 통계치를 구하는 SGLDM(Spatial Gray Level Dependence Matrix), 영상의 국부적인 그레이 레벨의 변화를 표현하는 NSGLDM(Neighboring Spatial Gray Level Dependence Matrix), 그리고 그레이 레벨의 run-length를 표현하는 GLRLM(Gray Level Run Length Matrix)등이 있다. Haralick 등은 통계 행렬을 사용하여 질감정보를 유출해 내는 다양한 측정방법을 제안하였다. 그러나 Haralick이 제안한 스칼라 속성들은 서로 상관관계(correlation)가 많으며, 통계 행렬을 구하는데 필요한 계산량과 통계행렬이 담고 있는 다양한 정보를 제한적으로 표현하고 있어 J. Lee등은 SGLDM을 포함하여 이들 행렬을 의미있는 방향으로 투사한 벡터속성을 정의하고 이들을 질감 영상 분석에 이용하였다. 최근에는 통계 행렬등을 그레이 영상 뿐만아니라 다 채널 영상으로 확장하여 영상 분석에 이용하는 연구가 활발하게 진행되고 있다.

칼라를 이용하는 영상분석 방법에는 영상의 전반적인 색 분포를 기술하며 계산하기 쉽고 해상도의 변화에 대해 민감성이 적은 칼라 히스토그램이 많이 사용한다. 칼라 히스토그램은 영상의 전반적인 색 분포를 기술할 뿐아니라 계산하기 쉽고 관점(viewing point)에 의

한 변화 및 해상도의 변화에 덜 민감하다. 그러나 칼라들의 공간적 상관관계에 대한 정보를 포함하고 있지 않기 때문에 속성으로 사용되기에는 불충분한 점이 있다. 따라서 칼라 히스토그램과 영상의 질감 정보 및 형태 정보를 효율적으로 결합하여 이용하려는 시도들이 있었다. 이러한 연구에는 칼라 히스토그램과 별도로 웨이브렛 분석등 영상의 질감 속성등을 추출하여 결합하여 이용하려 하였다. 그레이 레벨 영상 분석에서 널리 이용되어온 이계 통계 행렬을 다 채널 칼라영상으로 확장하여 정의하고 이를 의미있는 방향으로 투사하면 영상의 히스토그램 및 영상 질감에 관한 속성 벡터를 동시에 편리하게 얻어낼 수 있다. 최근에 제안된 칼라쌍의 공간적 상관관계가 어떻게 거리에 따라 변화하는지를 기술하는 칼라 Correlogram 행렬도 이러한 부류의 속성으로 간주될 수 있다.

따라서 본 연구에서는 위성영상 분류에 유용한 속성을 선택하기 위하여 그레이 영상에서 영상의 통계적 성질을 표현하는 SGLDM (Spatial Gray Level Dependence Matrix), GLRLM (Gray Level Run Length Matrix), NSGLDM (Neighboring Spatial Gray Level Dependence Matrix) 등을 다 채널 위성영상으로 확장하여SVDM (Spatial Vector Dependence Matrix), CRLM (Vector Run Length Matrix), NSVDM (Neighboring Spatial Vector Dependence Matrix) 등의 속성을 정의하였다. 이 속성 벡터를 사용하면 기억 용량이 크고 많은 계산량이 요구되며 서로 상관관계가 많고 행렬 자체가 포함하고 있는 정보를 표현하는데 미흡한 점을 해결할 수 있으며 또한 정보의 유실을 최대한 방지한 분류시스템을 구성할 수 있다. 제안된 벡터 속성들의 분별력을 측정하기 위하여 SPOT 위성으로부터 관측된 전라남도 해안지역의 영상을 사용하여 분별력을 시험하였다. 영상분류 시스템의 구성은 신경망 분류기를 사용하였으며, 각각의 속성 벡터들을

훈련자료 영상을 이용한 유사성 측정과 전체 영상분류에 적용시켜 그 성능을 평가하였다.

또한 본 연구에서는 SPOT, Landsat등의 위성데이터의 상관관계를 분석하고, 분석된 결과를 통한 각 위성데이터의 대역 축소를 위한 최적 KL변환 커널을 제안하는 연구를 수행하였다. 일본의 Ohta 등이 칼라 영상에 대한 구역 분할 선형 속성을 개발하기 위하여 이용한 Dynamic KL 변환 기법을 다중 대역에 적용하고자 한다. 이 방법은 영상내의 관심 구역들의 다중대역 데이터에 대한 KL 변환을 수행하고 각각의 변환 속성에 대한 히스토그램을 얻어내고 두드러진 구역분할을 제공하는 변환벡터들의 통계치를 구하여 두드러진 변환 벡터를 찾아내는 방법이다.

이 방법을 다중대역 위성영상에 적용하여 실험한 결과 위성 영상은 각각의 밴드 사이에는 많은 상관관계가 있지만 Ohta의 실험에서처럼 일관된 관계를 찾을 수 없었다. 앞으로, 압축을 위한 변환 커널 구성은 추후에 더 다양한 데이터를 이용하여 실험되고 연구되어야 할 것이다. 다 채널 위성 영상을 구역 분할 관점의 Dynamic KL 변환 분류 실험에서는 시각적으로 양호한 구역분할이 수행됨을 알 수 있으나 이는 순수한 속성공간에서의 세그맨테이션이기 때문에 과구역화(oversegmentation) 현상이 나타났다. 향후 공간 영역에서의 인접한 구역의 확장등의 알고리즘을 보완 할 필요가 요구되었다.

본 연구에서 제안한 위성 전파 신호 처리 알고리즘을 Visual C++를 이용하여 PC환경에서 위성처리프로그램을 개발하고 데이터 처리 및 분석을 위한 통합 환경을 구축하였다. 또한 윈도즈 환경이상에서 시뮬레이션 알고리즘이 이용 가능하도록 사용자 인터페이스 개발을 하였다. 본 연구에서 구현된 위성 전파 신호처리 시스템은 사용자가

손쉽게 사용 할 수 있도록 하기 위해 편리한 사용자 인터페이스를 제공하고 있다.

본 연구의 추진 방향은 세가지로 다음과 같다.

- 다 채널 잡음 모델링 및 잡음 발생기의 구현과 비선형 잡음 제거 기법 연구
- 위성데이터의 질감 속성 연구
- 구역 분할 관점의 Dynamic KL 변환 연구

본 연구보고서는 이러한 연구 목적의 보고서로서 수행한 연구 결과는 다음과 같다.

- 임펄스 잡음 발생기 구현
- 가우시안 잡음 발생기 구현
- 비선형 필터링 구현
- 퍼지 클러스터 필터 구현
- 그레이 레벨 통계 행렬을 대역간 통계 행렬로 확장
- 유용한 위성데이터의 질감 속성 개발
- 제안한 질감 속성 벡터를 평가하기 위한 분별기를 구성하여 실험
- Dynamic KL 변환을 다중 대역에 확장 방법 구현
- 개발된 알고리즘을 이용할 수 있는 Graphic User 환경을 개발

본 연구보고서의 구성으로는 제 2 장에 전반적인 위성데이터를

이용한 영상처리에 대하여 기술하였으며, 제 3 장에서는 위성데이터의 잡음 제거기법에 대하여 기술하였으며, 제 4 장에서는 위성데이터의 질감속성에 대하여 설명하였고 제 5 장에서는 Dynamic KL 변환 방법에 대하여 기술하였고 제 6 장에서는 통합 프로그래밍 개발에 대하여 설명하였고 제 7장에서는 결론을 맺었다.

제 2 장 위성데이터를 이용한 영상처리

2.1 원격탐사의 정의

원격탐사란 임의의 표적물로부터 반사되거나 복사되는 에너지는 물체의 특성에 따라 달라지며 동일한 대상물이라도 파장대에 따라 반사 또는 복사되는 비율이 달라지는 특성을 이용하여 지표의 대상물과 현상을 판독, 해석하는 것이다. 이공위성을 이용한 원격탐사는 1960년 미국에서 일기예보를 위한 기상위성의 발사를 시작으로 유럽과 일본에서 기상위성을 이용한 일기예보에의 응용이 가장 활발히 진행되었다. 이후 해양관측을 위한 위성과 지표 관측을 위한 위성을 발사하여 해수온도가 기상에 미치는 영향, 산림의 변화 과정, 도시화 과정, 농산물 경작 현황 분석, 지도 작성 등에 원격 탐사 위성의 자료가 사용됨으로서 위성에 의한 원격탐사의 중요성이 부각되었다. 원격탐사 신호를 분석하는데는 파장, 공간, 시간에 따른 변수를 이용한다. 위성정보 취득의 구성 요소는 다음과 같다.

- 에너지원, 대상물체, 환경 , 대기
- 인공위성, 항공기
- 센서 : MSS, TM, VNIR, SWIR, SAR
- 지상 수신소
- 전처리 시스템
- 위성 정보처리 및 분석
- 위성정보의 응용 및 이용

그림 2.1은 위성을 이용한 원격 탐사 흐름도를 나타내었다.

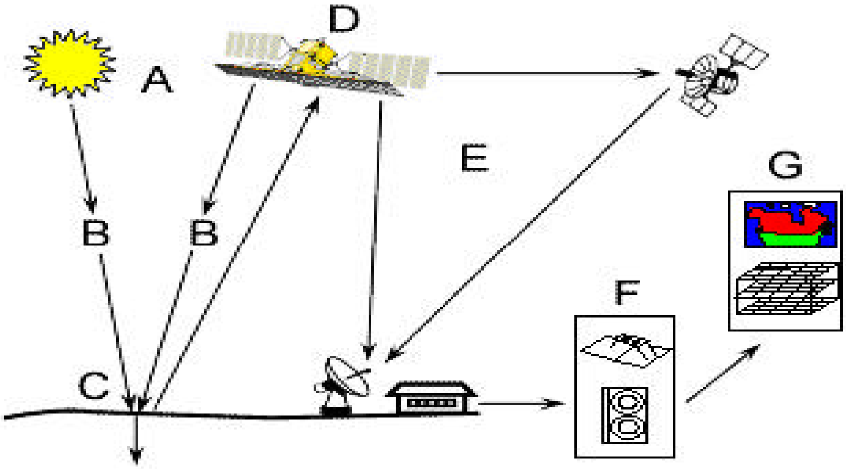

Energy Source or Illumination (A)

Radiation and the Atmosphere (B)

Interaction with the Target (C)

Recording of Energy by the Sensor (D)

Transmission, Reception, and Processing (E)

Interpretation and Analysis (F)

Application (G)

그림 2.1 원격 탐사 흐름도

그림 2.1에서 원격탐사 위성은 위성에 탑재된 광학센서 및 마이크로파 센서에서 관측한 테이터를 지상 수신소로 전송하고, 지상 수신소

에서는 계획에 따라 위성을 추적하고 위성에서 전송되는 관측데이터를 수신 및 저장하여 원시 데이터를 생산한다. 위성에서 관측된 정보는 관측시의 기기의 상태나 대기의 조건등에 의해 많은 오류나 왜곡을 포함하고 있다. 따라서 이와 같은 위성정보를 처리 및 분석하기 위해서는 전처리 과정이 수행되어야한다. 전처리 과정을 거친 데이터를 이용하여 필요로 하는 정보를 추출하고 분석하여 이용분야에 활용하고 이를 DB화하여 네트워을 통해 사용자에게 서비스한다.

2.2 위성을 이용한 원격탐사에 요구되는 기술 요소

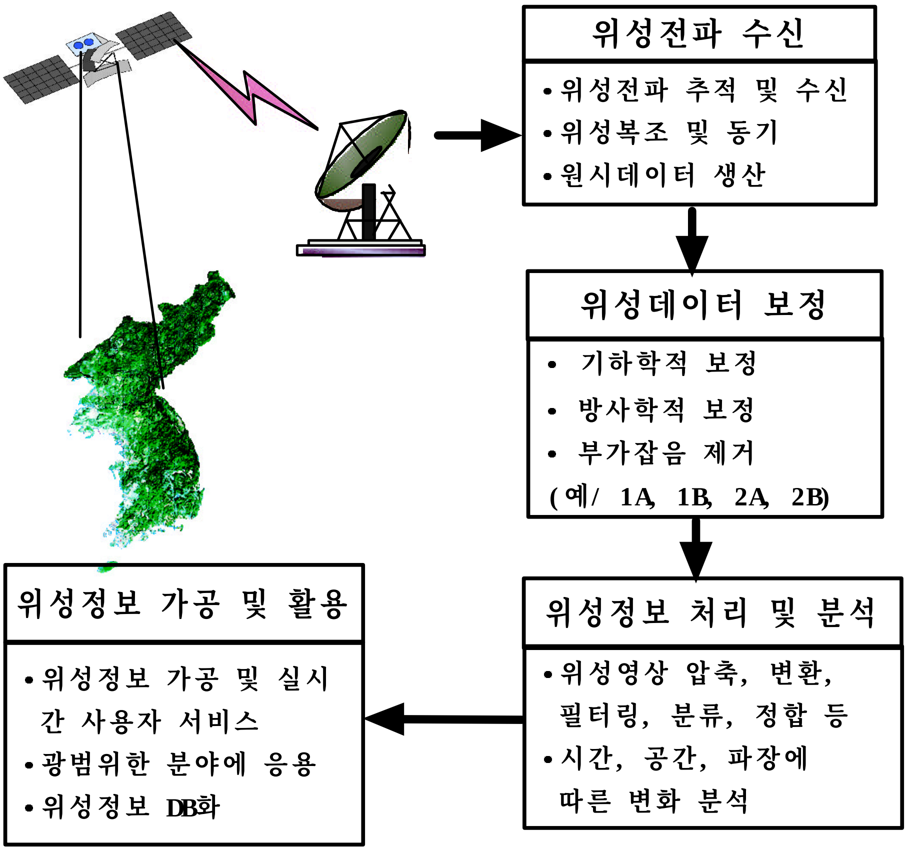

2.3 위성영상의 종류 및 제원

본 연구에서 사용하고자 하는 위성영상의 제원은 다음과 같다.

<프랑스 SPOT-1 위성 (HRV) 영상>

Altitude	832 Km			
Inclination	98.7 도			
Repeat Interval	26 일			
Swath Width	60 Km ×(60 - 85 Km)			
관측 센서 특성				
Bands	1	2	3	Pan
Sensitivity (㎛)	0.50 - 0.59	0.61 - 0.68	0.79 - 0.89	0.51 - 0.73
Resolution (m)	20	20	20	10

< 미국 LANDSAT-5 위성(TM) 영상 >

Altitude	705 Km						
Inclination	98.2 도						
Repeat Interval	16 일						
Swath Width	185 Km × 170 Km						
관측 센서 특성							
Bands	1	2	3	4	5	6	7
Sensitivity (㎛)	0.42 - 0.52	0.52 - 0.60	0.63 - 0.69	0.76 - 0.90	1.55 - 1.75	10.4 - 12.5	2.08 - 2.35
Resolution (m)	30	30	30	30	30	120	30

제 3 장 위성데이터 잡음 제거

3.1 다 채널 잡음 모델

잡음이 발생한 영상에서 알고리즘의 성능을 평가하기 위하여, 실험 영상에 잡음을 발생시킬 수 있는 방법을 정의해야 되고, 잡음 프로세스를 시뮬레이션 하는 것이 필요하다. 위성 영상은 다 채널이기 때문에, 잡음 프로세스 역시 다 채널이어야 한다. 본 연구에서는 잡음의 확률 분포에 관한 일반적인 개념만을 고려하였다. 따라서, 본 연구에서는 가산잡음(additive noise)만을 고려하였고, 잡음을 생성하기 위한 과정은 그림 3.1과 같이 세 채널인 위성 영상의 예를 본 연구에서 고려하였다.

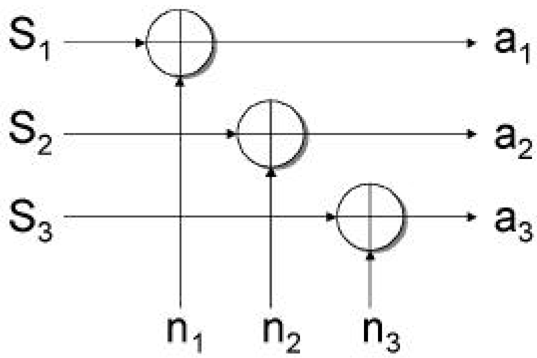

그림 3.1 잡음 생성 과정의 블록 다이어 그램

$$\mathbf{a} = \mathbf{s} + \mathbf{n}$$

여기서, $\mathbf{s}$ =[s_1, s_2, s_3]은 원 영상이고, $\mathbf{n}$ =[n_1, n_2, n_3]은 잡

음이며, $\mathbf{a}=[a_1, a_2, a_3]$은 잡음이 부가된 영상이다.

따라서, 3차원 랜덤 프로세스 **n**을 생성시켜야 한다. 그리고, 알고리즘의 성능을 평가하기 위하여, 본 연구에서는 임펄스 잡음과 가우시안 잡음을 고려하였다. 8비트 그레이 스케일 시스템을 위하여 s_{min}은 0, s_{max}는 255를 이용하였다. 임펄스 잡음은 그레이 영상에서 임펄스 잡음을 생성시키는 것과 유사한 방법을 이용하였고, 동일한 확률을 가진 음과 양의 임펄스 잡음을 생성하였다. 부가하여, 실제 다 채널 영상에서 잡음은 채널 사이에서 상관 관계를 갖고 있으므로, 본 연구에서는 상관 관계를 가진 잡음 모델을 고려하였다. 본 연구에서는 다변수의 가우시안 잡음을 고려하였고, 이것은 단일 가우시안 임의의 변수의 경우의 확장이다.

$$f(x)=\frac{1}{\sigma\sqrt{2\pi}}e^{-(x-\eta)^2/2\sigma^2} \tag{3-1}$$

여기서 $\eta=E\{x\}$는 평균값이고, σ^2은 분산이다. 임의의 벡터 X의 다변수 가우시안 분포는 다음 식과 같다.

$$f(\boldsymbol{X})=\frac{1}{(2\pi)^{p/2}|\sum|^{\frac{1}{2}}}\exp\left[-\frac{1}{2}(\boldsymbol{X}-\boldsymbol{\eta})^T\sum^{-1}(\boldsymbol{X}-\boldsymbol{\eta})\right] \tag{3-2}$$

여기서, p는 채널들의 수나 벡터의 차원이고, η는 평균값 벡터이다. $\eta_i=E\{x_i\}$이고, $\sum=E\{XX^T\}$는 공분산(covariance) 행렬이고, $\Sigma_{ij}=E\{xi, xj\}$ 공분산 행렬 $\sum$는 $p\times p$차원 symmetric positive definite 행렬이다. 만약, 분포가 평균값이 0이고, 동일한 분산값과 함께 상관 관계가 없다면

$$\boldsymbol{\eta} = [0,\ 0,\ \cdots,\ 0]^T \text{ 과 } \Sigma = \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix}$$

이 된다. 그때, 식(3-2)는 $p = 3$ 인 경우 다음과 같이 간략하게 된다.

$$f(\boldsymbol{X}) = \frac{1}{(2\pi)^{\frac{3}{2}}\sigma^3} \exp\left[-\frac{1}{2\sigma^2}\boldsymbol{X}^T\boldsymbol{X}\right] \tag{3-3}$$

또는,

$$f(x_1, x_2, x_3) = \frac{1}{(2\pi)^{\frac{3}{2}}\sigma^3} e^{-\frac{1}{2\sigma^2}\left(x_1^2 + x_2^2 + x_3^2\right)} \tag{3-4}$$

위 식으로부터 각 채널들이 서로 독립이라는 것을 알 수 있다. 그러므로, 식(3-3)을 이용하여 잡음을 생성할 때, 세 채널들이 서로 독립적이라는 것을 알 수 있고, 단 변수 분포와 함께 각각

$$f(x_i) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{x_i^2}{2\sigma^2}} \tag{3-5}$$

이 된다. 위와 같은 식을 이용할 경우는 상관 관계가 없는 잡음을 얻게 된다. 이 경우, 서로 다른 채널 사이의 상관 관계는 0이 된다. 그러나, 본 연구에서는 각 채널간에 상관 관계가 있는 잡음을 고려하였다. 그 이유는, 실제 다 채널 영상은 각 채널간에 상관 관계를 갖고 있고, 각 채널간에 상관 관계가 있는 잡음이 존재하기 때문이다. 본 연구에서는 선형 변환을 이용하여 상관 관계가 있는 분포를 구성하였다. $\boldsymbol{n} = [n1,\ n2,\ n3]T$가 상관 관계가 없는 분포와 함께 임의의 벡터라고 하면(Σ는 diagonal이다), 그때 선형 변환 A 를 이용하여 다음 식

과 같이 새로운 임의의 벡터 $\boldsymbol{s}$ = $[s1, s2, s3]T$를 만들 수 있다.

$$\boldsymbol{s} = \boldsymbol{A} \circ \boldsymbol{n}$$

변환 행렬 A는 다음과 같이 쓰여질 수 있다.

$$\boldsymbol{A} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} = \begin{bmatrix} \boldsymbol{a}_1^T \\ \boldsymbol{a}_2^T \\ \boldsymbol{a}_3^T \end{bmatrix} \tag{3-6}$$

여기서, $\boldsymbol{a}_i = [a_{i1},\ a_{i2},\ a_{i3}]^T$ 이다. 그러므로,

$$\boldsymbol{s} = [\ \boldsymbol{a}_1{}^T \circ \boldsymbol{n},\ \ \boldsymbol{a}_2{}^T \circ \boldsymbol{n},\ \ \boldsymbol{a}_3{}^T \circ \boldsymbol{n}\ ]^T$$

이다. 변환되어진 벡터의 평균 벡터 η_s와 공분산 행렬 $\sum_s$는 원래의 ηn 값과 $\sum_n$으로부터 계산되어 질 수 있다.

$$\eta_{s_i} = E[s_i] = E[\boldsymbol{a}_i^T \cdot \boldsymbol{n}] = \boldsymbol{a}_i{}^T \cdot E[\boldsymbol{n}] = \boldsymbol{a}_i{}^T \cdot \boldsymbol{\eta}_n \tag{3-7}$$

$$\begin{aligned} \Sigma_{s_{ij}} &= E[s_i s_j] = E\left[\ \boldsymbol{a}_i{}^T \boldsymbol{n}\ \boldsymbol{a}_j{}^T \boldsymbol{n}\right] = E\left[\ \boldsymbol{a}_i{}^T \boldsymbol{n}\boldsymbol{n}^T \boldsymbol{a}_j\right] \\ &= \boldsymbol{a}_i{}^T E[\boldsymbol{n}\ \boldsymbol{n}^T]\boldsymbol{a}_j = \boldsymbol{a}_i{}^T \boldsymbol{\Sigma}_n \boldsymbol{a}_j \end{aligned} \tag{3-8}$$

따라서, 적절한 변환 행렬 A를 선택함으로써 임의의 평균 벡터와, 임의의 공분산 행렬을 가진 분포를 생성시킬 수 있다. 본 연구에서는 세 채널이 대칭이라는 가정을 이용하여 다음과 같은 행렬 A를 선택

하였다.

$$\boldsymbol{A} = \begin{bmatrix} a & b & b \\ b & a & b \\ b & b & a \end{bmatrix}$$

대칭은 채널 상호간에 상관 관계가 모두 같다는 것이고, 세 채널의 분산 역시 동일하다는 것을 의미한다. 그러므로, 상관 관계가 있는 가우시안 잡음을 생성하기 위하여, 식(3-2)에서 정의되어진 바와 같이 상관 관계가 없는 세 채널 가우시안 분포와 0의 평균값을 갖는 분포를 고려하여 보면,

$$\boldsymbol{\eta}_n = [0, 0, 0]^T \text{ 와 } \quad \boldsymbol{\Sigma}_n = \sigma^2 \boldsymbol{I} = \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix}$$

이다. 이때, 이 분포를 식(3-6)에서 정의되어진 $\boldsymbol{A}$ 행렬을 가지고 변환을 해보면, 그때 $\eta_{s_i} = \boldsymbol{a}_i^T \cdot \boldsymbol{\eta}_n = 0, \quad i = 1, 2, 3$이다. 그러므로, 새로운 분포는 역시 $\boldsymbol{\eta}_s = [0, 0, 0]^T$ 의 평균값을 갖는다.

$$\boldsymbol{\Sigma}_{s_{ij}} = \boldsymbol{a}_i^T \boldsymbol{\Sigma}_n \boldsymbol{a}_j = \sigma^2 (\boldsymbol{a}_i^T \boldsymbol{a}_j) = \begin{cases} \sigma^2 (a^2 + 2b^2), & i = j \\ \sigma^2 (b^2 + 2ab), & i \neq j \end{cases} \qquad (3\text{-}9)$$

본 연구에서는 각 채널의 분산을 σ^2으로 같게 유지하였다. 따라서 위 식에 다음과 같은 제약을 두었다.

$$a^2 + 2b^2 = 1 \text{ 그때, } \quad \boldsymbol{\Sigma}_s = \sigma^2 \begin{bmatrix} 1 & \rho & \rho \\ \rho & 1 & \rho \\ \rho & \rho & 1 \end{bmatrix}$$

여기서, $\rho = b^2 + 2b\sqrt{1 - 2b^2}$은 상관 관계 상수(correlation coefficient)이다. 따라서, b의 적절한 선택에 의해 행렬 A를 구성함으로써 임의의 상관 관계 상수 ρ에 의해 가우시안 잡음 분포를 구성할 수 있다.

3.2 벡터 미디안 필터(VMF: Vector Median Filter)

미디안 연산을 벡터값을 가진 신호로 확장하였을 때, 벡터 미디안 연산을 위해 몇 가지 필요조건이 있다. 즉 스칼라 미디안 연산의 경우, 신호에서 선명한 윤곽선을 보존하는 동안 제로 임펄스 응답과 강건한 데이터 smoothing 능력의 특성을 가지는데, 벡터 미디안 연산도 이러한 스칼라 미디안 연산의 특성과 비슷한 성질을 가져야 한다. 그리고, 벡터 미디안 연산은 벡터가 1차원이었을 경우, 스칼라 미디안과 일치하여야 한다.

뛰어난 윤곽선 보존 능력과 관련된 또하나의 중요한 필요조건은 근 신호(root signal)이다. 만약, 벡터 미디안이 스칼라 미디안 연산과 같이 독립적으로 벡터 구성요소들에서 각각 연산이 행하여진다면, 벡터 미디안 필터의 결과는 근 신호를 가질 것이다. 그러나, 필터의 출력은 일반적으로 입력 벡터들중의 하나가 되지 않는다. 미디안 필터의 기본적인 성질 중의 하나는 필터의 입력값들 중에 존재하지 않는 어떠한 표본값도 출력값으로 만들지 않아야 한다는 것이다. 이는 벡터 미디안 연산의 경우도 마찬가지이다. 그래서, 벡터 미디안 필터의 출력은 입력된 벡터들 중의 하나가 되어야 한다.

그림3.2에 있는 두 개의 잡음원인 n^S와 n^D에 대하여 생각해 보자.

신호원 잡음과 검출기 잡음은 지수분포를 가정하고 maximum likelihood를 이용하면 벡터신호를 처리하기 위한 두 개의 median-like 알고리즘을 정의할 수 있다.

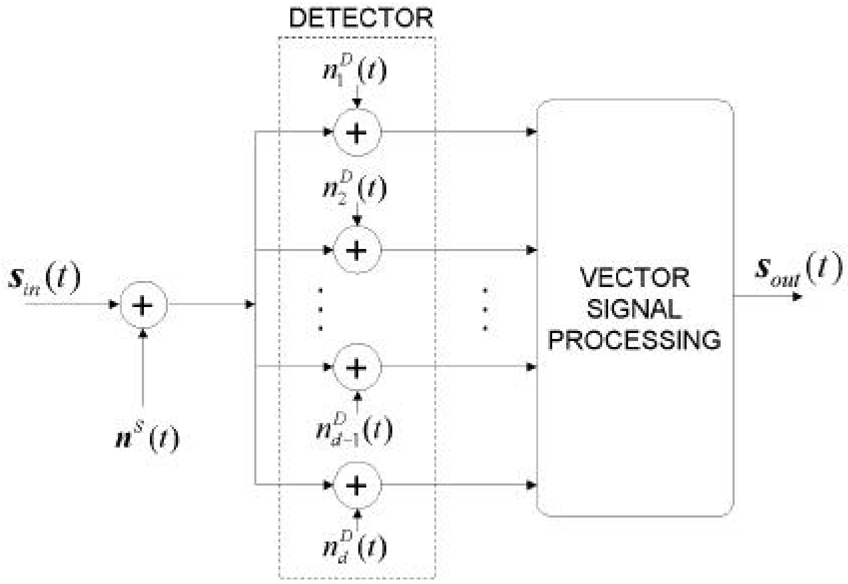

그림 3.2 신호원 잡음과 검출기 잡음 성분을 보여주는 시스템 모델

신호와 잡음은 상호 의존적이며, 잡음에 대한 선험적 정보가 주어지지 않고 대칭적 분포를 갖는다고 가정하자. 벡터 미디안 필터는 두 개의 다차원 확률 밀도함수로부터 maximum likelihood 추정방법을 이용하여 유도될 수 있다. 확률 밀도함수를 지수함수식인 식 (3-10)과 같은 형태를 갖는다고 가정하자.

$$f(x) = \gamma e^{-\alpha \| x - \beta \|_2} \qquad (3\text{-}10)$$

여기서, γ와 α는 스케일링 변수(scaling factor)들이고, $\|\ \|_2$는 L2 norm이고 β는 분포함수의 위치 변수이다. 식 (3-10)의 분포 함수로부터 임의의 표본 집합에 근거한 β의 maximum likelihood 추정값인 $\hat{\beta}$ 은 likelihood 함수를 최대화하는 β값이다.

$$L(\beta) = \prod_{i=1}^{N} \gamma e^{-\alpha \| x_i - \beta \|_2} \tag{3-11}$$

$L(\beta)$를 최대화하는 문제는 다음의 식 (3-12)을 최소화시키는 것과 동일하다.

$$\sum_{i=1}^{N} \| x_i - \beta \| \tag{3-12}$$

그러나, 이 경우 스칼라 경우에 반하여, 일반적으로 $\hat{\beta}$ 은 입력값 중의 하나가 아니다. 따라서, $\hat{\beta}$ 가 입력 벡터중의 하나가 되도록 하는 부가적인 요건을 추가할 때, 부 최적인(suboptimal) 추정값을 얻을 수 있다. 이것으로부터 L2 norm을 이용한 벡터 미디안의 정의를 다음 식과 같이 유도할 수 있다.

$$\begin{gathered} x_{vm} \in \{ x_i \mid i = 1, \cdots\cdots, N \} \\ \sum_{i=1}^{N} \| x_{vm} - x_i \|_2 \leq \sum_{i=1}^{N} \| x_j - x_i \|_2 \\ \forall j = 1, 2, \cdots\cdots, N \end{gathered} \tag{3-13}$$

만약 검출기 잡음의 경우 각 성분에 있어 독립적인 잡음 분포를 가정하고 이들이 위치 파라미터를 중심으로 양방향 지수분포를 갖는다고 가정하자. 이 경우 확률밀도함수는 식(3-14)와 같이 표현될 수 있다.

$$f(x) = \prod_{i=1}^{d} \frac{\alpha_i}{2} e^{-\alpha_i |x_i - \beta_i|} \tag{3-14}$$

여기서 α_i는 스케일링 인자들이며 β_i는 위치 파라미터 β의 성분들이다. 이 분포의 likelihood 함수 $L(\beta)$를 최대화하는 문제이다.

$$\sum_{i}^{N} (\alpha_1 |x_1^i - \beta_1| + \cdots + \alpha_d |x_d^i - \beta_d|) \tag{3-15}$$

식(3-15)에서 α1 = α2 = ⋯ = αd라 가정하고 필터출력이 입력들 중 하나라는 제약조건을 가정하면 임의의 표본집합 {*x1*, ⋯, *xN*}이 주어질 경우 위치벡터를 추정하기 위한 벡터 미디안은 식(3-16)과 같이 구해질 수 있다.

$$\sum_{i=1}^{N} \| \boldsymbol{x}_{vm} - \boldsymbol{x}_i \|_1 \le \sum_{i=1}^{N} \| \boldsymbol{x}_j - \boldsymbol{x}_i \|_1 \tag{3-16}$$

또한 식(3-13)과 식(3-16)과 같이 정의된 벡터 미디안 필터는 스케일과 바이어스에 대해 불변이고, 식(3-13)의 벡터 미디안은 회전에 대해서도 불변이며, 이들 벡터 미디안은 스칼라 미디안의 일반적인 성질을 상속시킨다.

그림3.3과 그림3.4는 식 (3-13)의 스칼라 및 벡터 미디안 필터의 예를 보여 주고 있다. 두 개의 채널을 갖는 다 채널 칼라 신호에 빨간색 채널에 임펄스 잡음이 있다고 가정하자. 만일, 그림 3.3과 같이 빨간색 채널 및 녹색 채널을 각각 독립적으로 윈도우의 길이가 5인 스칼라 미디안 필터링을 할 경우 빨간색 채널에서 윤곽선이 이동하는 윤곽선 지터(edge jitter) 현상이 발생함을 알 수 있다. 반면에 그림

3.4와 같이 윈도우길이가 5인 식(3.13)의 벡터 미디안 필터로 필터링하면, 윤곽선 지터(edge jitter)없이 임펄스가 제거되어 윤곽선을 잘 보존함을 알 수 있다.

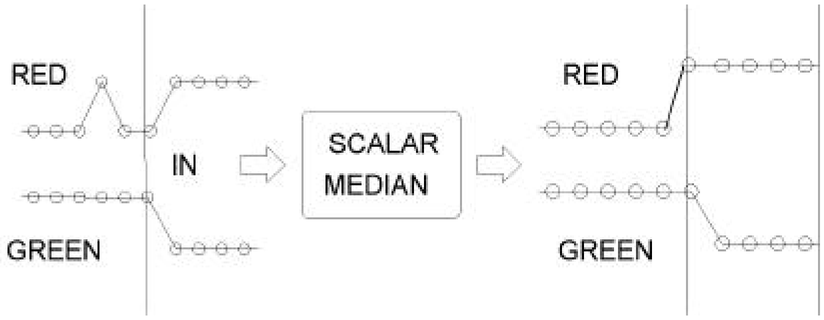

그림 3.3 스칼라 미디안 필터링에서 윤곽선 근처에 있는 임펄스

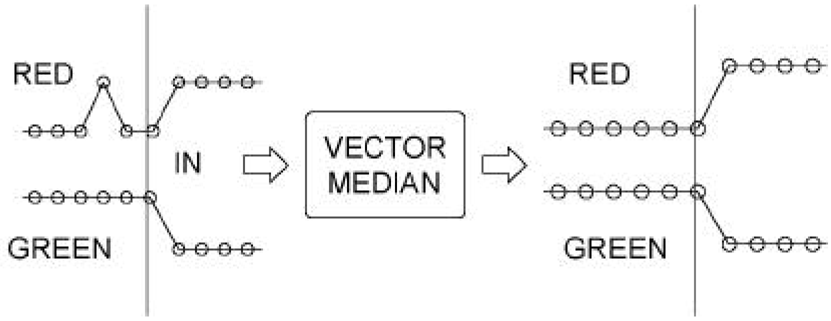

그림 3.4 벡터 미디안 필터링에서 윤곽선 근처에 있는 임펄스

본 연구에서는 잡음 분포들이 서로 의존적이라는 가정하에 식(3-13)과 같은 벡터 미디안의 정의를 채택한다.

3.3 BVDF와 GVDF

3.3.1 BVDF(Basic Vector Directional Filter)

$f(x): Z^l \rightarrow Z^m$은 다 채널 신호를 나타내고, $W \in Z^l$은 윈도우의 크기는 n이라고 하자. 여기서, l은 신호의 차원을 m은 신호의 채널의 수를 나타낸다. 윈도우 안의 화소들은 x_i, i = 1, 2, 3, ⋯, n으로 나타내고, $f(x_i)$를 f_i로 표시한다. f_i는 m개의 신호채널로 정의된 벡터 공간에서 m차원 벡터들이다.

BVDF는 VDF(Vector Directional Filter)의 특별한 경우로서 다음과 같이 정의된다.

정의) 입력 $\{f, i = 1, 2, 3, \cdots, n\}$에 대한 BVDF의 출력은 f_{BD} = BVDF[f_1, f_2, ⋯, f_n]이다. 여기서, $f_{BD} \in \{f_i, i = 1, 2, \cdots, n\}$이고,

$$\sum_{i=1}^{n} A(f_{BD}, f_i) \leq \sum_{i=1}^{n} A(f_j, f_i), \quad \forall j = 1, 2, \cdots, n$$

이 된다. 여기서, $A(f_i, f_j)$는 두 벡터 f_i와 f_j사이의 각도로서

$$0 \leq A(f_i, f_j) \leq \pi \text{ 이다.}$$

BVDF 출력은 입력 값들 중에서 다른 벡터들과의 각도 거리의 합을 가장 최소화시키는 벡터이다. 즉, 벡터의 크기는 고려하지 않고 방향 성분만을 고려하여 가장 중앙에 위치하는 벡터를 선택한다. BVDF 연산은 다른 벡터들과의 크기 거리의 합을 최소화하는 출력 값을 갖

는 벡터 미디안 연산과 비교될 수 있다. BVDF는 출력 벡터신호를 생성할 때 방향정보만을 고려한다.

2차원 벡터에서 f_{BD}는 각도 위치의 최소 오류 추정이다. 같은 크기를 가진 $\{f_i,\ i=1,2,\cdots,n\}$인 벡터들의 집합을 가정해 보면, 벡터들 $\{f_i\}$에서의 최소 오류추정은 벡터 미디안 값인 f_{VM}이다.

$$\sum_i \| f_i - f_{VM} \| \le \sum_i \| f_i - f_j \|, \quad \forall j = 1, 2, \cdots, n \tag{3-17}$$

즉, $\sum_i \| f_i - f_c \|$의 최소 값은 $f_c = f_{VM}$이 되게 된다. 같은 크기의 벡터들이라면 $l(>0)$, $\| f_i - f_{VM} \|$은 다음과 같이 표현된다.

$$\| f_i - f_{VM} \| = 2l \sin\frac{\varnothing_i}{2} \tag{3-18}$$

단, $\varnothing_i = A(f_i, f_{VM})$.

따라서, $\sum_i \| f_i - f_{VM} \|$이 최소이면 $\sum_i \sin\frac{\varnothing_i}{2}$도 최소가 된다. 가정에 의하여, 각도 $\varnothing_i$는 작고, $\sin\frac{\varnothing_i}{2}$를 각도 $\frac{\varnothing_i}{2}$(라디안값)로 대신할 수 있다.

위와 같이, 같은 크기의 벡터일 경우 벡터 미디안 필터와 BVDF의 출력 값이 일치한다는 것을 알 수 있다. 그러나, 크기가 같지 않을 경우는 같은 출력 값을 얻을 수 없다. 후자의 경우에서 BVDF 출력 값은 같은 길이의 벡터들이건 아니건 간에 아직 그 벡터가 출력 값이 된다. 그러나, 벡터 미디안 필터는 다른 결과를 갖는다. 이는 BVDF 출력 값이 벡터 f_2이고, 벡터 미디안 필터의 출력 값이 벡터 f_4로

나타나는 그림3.5에서 보는 바와 같다.

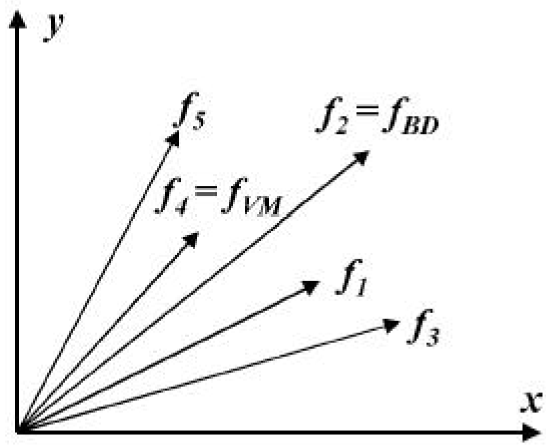

그림 3.5 2차원 벡터의 집합

3.3.2 GVDF(Generalized Vector Directional Filters)

BVDF는 벡터의 크기가 중요하지 않고, 벡터의 방향이 의미 있는 경우에 좋은 결과를 얻을수 있다. 그러나, BVDF는 몇몇 다 채널 신호처리에 응용했을 경우와 벡터의 크기가 의미가 있는 경우의 성능은 좋지 않다. 이러한 문제점은 각 화소에서의 출력 값이 벡터 $\boldsymbol{f}_j \in W$가 아닌 벡터의 집합 $\boldsymbol{f}_i \in W,\ i = 1, 2, \cdots, k,\ k < n$으로 대체하는 일반화한 BVDF에 의해 해결될 수 있다.

입력 $\{f_i,\ i = 1, 2, \cdots, n\}$에 대한 GVDF의 출력 값은 SGD = GVDF[$f1$, $f2$, ⋯, fn]이다. 여기서

$$\boldsymbol{S}_{GD} = \{\ \boldsymbol{f}^{(1)},\ \boldsymbol{f}^{(2)}, \cdots,\ \boldsymbol{f}^{(k)}\},\quad \boldsymbol{f}^{(i)} \in \{\ \boldsymbol{f}_j,\ j = 1, 2, \cdots, n\} \tag{3-19}$$

$\forall i = 1, 2, \cdots, k$

α_i가 f_i에 대응한다고 하면, 다음과 같이 정의할 수 있다.

$$\alpha_i = \sum_{j=1}^{n} A(\mathbf{f}_i, \mathbf{f}_j), \quad i = 1, 2, \cdots, n \tag{3-20}$$

α_i 들의 정렬

$$\alpha_{(1)} \le \alpha_{(2)} \le \cdots \le \alpha_{(k)} \le \cdots \le \alpha_{(n)} \tag{3-21}$$

은 f_i 에 대응하는 같은 정렬로 다음과 같이 나타낼 수 있다.

$$\mathbf{f}^{(1)} \le \mathbf{f}^{(2)} \le \cdots \le \mathbf{f}^{(k)} \le \cdots \le \mathbf{f}^{(n)} \tag{3-22}$$

정렬된 $f^{(i)}$ 의 첫 k항은 GVDF의 출력을 구성한다. 여기서 식 (3-22)의 첫 번째 항인 $f^{(1)}$ 은 BVDF의 출력 값이다. GVDF는 BVDF를 일반화한 필터이다. 다시 말하면, GVDF의 출력 값은 BVDF 출력 값의 superset이다. GVDF의 출력 값은 다른 벡터들과의 각도 차이의 합이 최소인 BVDF 출력 값과는 달리 다른 벡터들과의 각도차이가 작은 벡터의 집합이 출력 값이다. 즉, GVDF의 출력 집합은 벡터 공간에서 거의 같은 방향을 가진 집단들에서 중앙에 위치한 벡터들로 구성된다. 그림3-6의 (a) 신호로의 GVDF의 적용은 각 샘플 포인트에서의 출력 값이 벡터들의 집합인 그림3.6의 (c)에 나타나 있다.

GVDF의 적용 후에 생성된 출력 값은 대부분 같은 방향인 k벡터들의 집합이고, 크기 처리(magnitude processing)의 단계는 각 화소에서 하나의 출력 벡터가 생성되도록 적용하여야 한다.

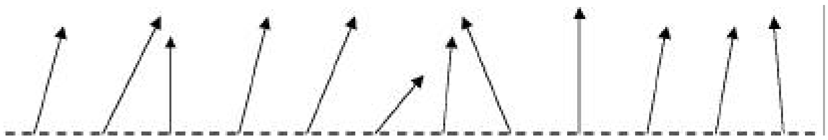

(a)

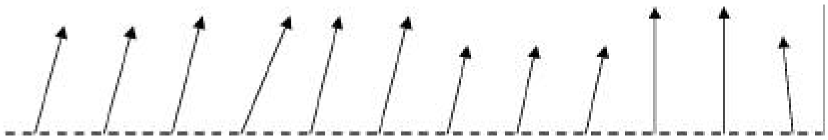

(b)

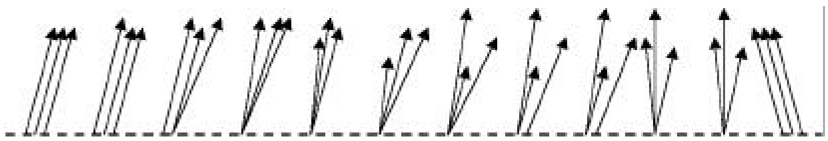

(c)

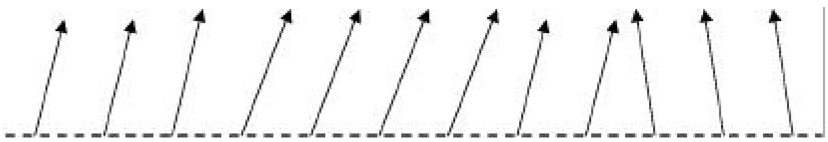

(d)

그림 3.6 (a) 1**차원 벡터 값을 가진 신호**, (b) n=5**인 신호의** BVDF**의 적용**, (c) n=5, k=3**인 신호의** GVDF**의 적용**, (d) GVDF**와 후처리 과정으로 스칼라 미디안 적용**

영상 필터링의 연산은 GVDF**가** ***F*** **모듈**(**필터**)**로 연속되는 그림**3.7**에 보여진다**. **여기서**, **방향성분은** GVDF**에 의해 처리되고**, **유사한 방향을 가진 벡터들의 크기 성분을 처리하기 위해** ***F*****를 이용하기 때문에**, ***F*** **모듈로 그레이 스케일에서 이용되어지는 여러 가지 영상처리 필터가 이용될 수 있다**. **이것은 그림**3.6**의** (c)**와** (d)**에 보여진다**. **그림**3.6**의** (c)**에 있는** GVDF **출력 값은 그림**3.6**의** (d)**에 보여진 마지막 출력 값을 생성하기 위한 그레이 스케일 미디안 필터**(***F***)**를 통과한다**.

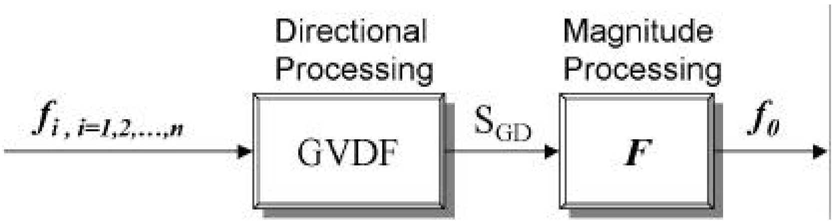

그림 3.7 방향성 처리와 후처리과정으로 크기 처리를 한 다 채널 영상처리

영상처리에 적당한 VDF를 구성하는 몇몇 특성은 여기서는 언급하지는 않는다.

3.4 벡터 α-trimmed 평균 필터와 제안된 가중화된 벡터 α-trimmed 평균 필터

3.4.1 벡터 α-trimmed 평균필터

미디안은 윤곽선을 보존하거나, 임펄스 잡음을 제거하는데는 강건하지만, 영상처리에서 자주 접하게 되는 부가적인 백색 가우시안 잡음(additive white Gaussian noise)을 제거하는데는 평균 필터나 다른 선형 필터들 보다 우수하지 못하다. 따라서, 미디안 필터와 평균 필터의 좋은 절충 형태가 α-trimmed 평균 필터이다. α-trimmed 평균 필터는 정규 분포에 대해 최적의 강건한 추정기이다. 게다가, 강건한 추정기로서 breakdown point는 $\varepsilon^* = \alpha$ 로 알려져 있다. 즉, 그레이 영상에서 α-trimmed 평균 필터는 윈도우내의 화소들을 정렬한 뒤, 상부 α%와 하부 α%를 제거한 후 남아 있는 화소들의 평균값을 필터

의 출력으로 하여 미디안 필터와 평균필터의 절충형태를 얻을 수 있다.

벡터 데이터의 경우, 벡터 정렬 방법을 이용하여 윈도우내의 화소들을 정렬한 뒤, p차원 벡터 영상의 α-trimmed 평균 필터를 다음 식과 같이 정의할 수 있다.

$$\boldsymbol{y}_{ij} = \sum_{k=1}^{n(1-2\alpha)} \boldsymbol{a}_{\boldsymbol{k}}^{T} \ \boldsymbol{x}_{(k)} \tag{3-23}$$

여기서, n은 윈도우내의 화소의 개수이다.

$$\boldsymbol{a}_{\boldsymbol{k}}^{T} = \left[\frac{1}{n(1-2\alpha)}, \frac{1}{n(1-2\alpha)}, \cdots, \frac{1}{n(1-2\alpha)} \right]^{T}.$$

위 식에서 정의되어 진 바와 같이 외곽 화소의 2α%를 제거한 뒤, 윈도우내의 화소 중 (1-2α)%의 평균을 취한다. 이 필터에서 trimming연산은 임펄스 잡음과 같은 long tailed 잡음에 대해 좋은 성능을 유지하게 하며, 날카로운 윤곽선을 보존하게 하고, 평균 연산은 가우시안 잡음과 같은 short tailed 잡음을 제거하는데 좋은 성능을 유지케 한다.

3.4.2 제안된 가중화된 벡터 α-trimmed 평균 필터

앞 절에서 언급한바와 같이 미디안 필터와 평균 필터의 좋은 절충형태가 α-trimmed 평균 필터이고, α-trimmed 평균 필터는 정규 분포에 대해 최적의 강건한 추정기이다. 역시, 앞장에서 언급한 바와 같이 벡터 α-trimmed 평균 필터는 벡터 정렬 방법을 이용하여 윈도우

내의 화소들을 정렬한 뒤 외곽 화소들 중 2α%를 제거하고 나머지 화소들을 가지고 평균 필터링을 한다. 그러나, 벡터 α-trimmed 평균 필터는 중심에 있는 화소나 중심으로부터 외곽에 있는 화소 모두 균일한 가중치로 평균 필터링을 한다. 따라서, 본 연구에서는 중심에 있는 화소에는 좀 더 가중치를 부여하여 가중된 평균 필터링을 수행하는 가중화된 벡터 α-trimmed 평균 필터를 제안하였다.

제안된 가중화된 벡터 α-trimmed 평균 필터에서 데이터 x_i 의 가중치 w_i 는 다음 식과 같다.

$$W_i = \frac{sum - s_i}{(n(1-2\alpha)-1)(s_1 + s_2 + \cdots + s_{n(1-2\alpha)})} \tag{3-24}$$

위 식에서 n은 윈도우내의 화소의 개수이고, s*i*는 *i*번째 화소와 윈도우내의 모든 화소와의 거리의 합을 나타내고, sum은 $\sum_{i=1}^{n} s_i$이다.

따라서, 가중화된 벡터 α-trimmed 평균 필터는 다음 식과 같이 정의할 수 있다.

$$y_{ij} = \sum_{k=1}^{n(1-2\alpha)} W_k \, \mathbf{x}_{(k)} \tag{3-25}$$

제안된 가중화된 벡터 α-trimmed 평균필터는 벡터 α-trimmed 평균필터의 성질을 그대로 계승하며, 벡터 미디안을 찾는데 필요한 거리정보를 이용하였기 때문에 계산량의 증가는 일반적인 벡터 α-trimmed 평균필터보다는 크게 증가하지 않는다.

반면, 윈도우 내의 데이터들의 벡터 미디안 값과의 거리정보가 가중치 결정에 이용되어 벡터 미디안 값으로부터 멀리 떨어진 데이터들은 잡음일 가능성이 높으므로 가중치를 작게 부여함으로써 보다 우수

한 필터특성을 얻을 수 있다.

3.5 제안된 퍼지 클러스터 필터

3.5.1 퍼지 c-mean 클러스터링 알고리즘

퍼지 클러스터링 알고리즘은 객체들 집합의 요소들 사이의 유사성을 찾아내는 수학적 도구이다. 하드 클러스터링(hard clustering)과 퍼지 클러스터링(fuzzy clustering)을 위한 여러 알고리즘들은 이러한 유사성을 찾아내기 위하여 발전되어지고 있다.

퍼지 c-means(FCM) 클러스터링 알고리즘은 퍼지 소속함수 값 μ_{ij}와 클러스터 중심 V_i에 관해 다음의 목적함수를 최소화시키는 nearest mean 하드 클러스터링 알고리즘의 퍼지 등가 알고리즘이다.

$$J_m = \sum_{i=1}^{c}\sum_{j=1}^{n}(\mu_{ij})^m d^2(\boldsymbol{X}_j, \boldsymbol{V}_i) \tag{3-26}$$

여기서,

$$d^2(\boldsymbol{X}_j, \boldsymbol{V}_i) = (\boldsymbol{X}_j - \boldsymbol{V}_i)^T \boldsymbol{A} (\boldsymbol{X}_j - \boldsymbol{V}_i).$$

$\boldsymbol{A}$는 $p\times p$의 positive definite 행렬이고, p는 벡터 $\boldsymbol{X}_j$ (j = 1, 2, ⋯, n)의 차원이며, c는 클러스터의 갯수, n은 벡터들의 수이고, m>1은 퍼지화 지수(fuzziness index)이다. 식 (3-26)의 목적함수를 최소화하는 FCM 알고리즘은 다음과 같은 단계로 실행된다.

1단계) 다음과 같은 조건을 만족하도록 클러스터 i에 속하는 X_j의 소속함수 값인 μ_{ij}를 초기화한다.

$$\sum_{i=1}^{c} \mu_{ij} = 1 \tag{3-27}$$

2단계) 식 (3-28)을 이용하여 i = 1, 2, ⋯, c에 대한 퍼지 중심값 (fuzzy centroid) V_i를 계산한다.

$$V_i = \frac{\sum_{j=1}^{n} (\mu_{ij})^m X_j}{\sum_{j=1}^{n} (\mu_{ij})^m} \tag{3-28}$$

3단계) 식 (3-27)을 이용하여 퍼지 소속함수 값 μ_{ij}를 갱신한다.

$$\mu_{ij} = \frac{\left(\frac{1}{d^2(X_j, V_i)} \right)^{\frac{1}{(m-1)}}}{\sum_{i=1}^{c} \left(\frac{1}{d^2(X_j, V_i)} \right)^{\frac{1}{(m-1)}}} \tag{3-29}$$

4단계) J_m값이 더 이상 감소하지 않을 때까지 2단계와 3단계를 반복한다.

FCM 알고리즘은 μ_{ij}의 초기 추정으로 부터 야기되는 J_m의 strict 국부 최소 값들로 항상 수렴한다. 즉 초기 값으로 μ_{ij}를 잘못 선택했을 경우는 국부 최소 값으로 수렴할 수도 있다.

3.5.2 가능적(possibilistic) c-mean 클러스터링

앞절에서 언급한 퍼지 c-mean은 Bezdek에 의하여 제안되어진 클러스터링 알고리즘이다. 퍼지 c-mean 알고리즘은 한 데이터가 각 클러스터에 속하는 소속함수 값이 더하여 1이 된다는 확률론적인 접근법을 이용하고 있기 때문에 한 데이터가 어떤 클러스터들에서 클러스터들로부터 멀리 떨어진 데이터나 가까운 데이터나 동일한 비율로 멀리 떨어져 있을 경우는 동일한 크기의 소속함수 값을 가질 수 있다. FCM의 이러한 성질은 “equal evidence"와 ”ignorance"를 구분할수 없기 때문에 잡음에 강건한 소속함수를 생성할수 없다.

가능적 c-mean(PCM)에서는 소속함수의 값이 다른 클러스터와 관계가 없고, 속성 데이터와 해당 클러스터 중심간의 거리에만 의존하기 때문에 FCM이 갖는 문제점을 해결할수 있어 잡음에 강건한 소속함수 값을 생성할수 있다. PCM에서 목적함수는 Raghu에 의해 제안되어졌고, 다음과 같다.

$$J_m(L, U) = \sum_{i=1}^{c}\sum_{j=1}^{N}(u_{ij})^m d_{ij}^2 + \sum_{i=1}^{c}\eta_i\sum_{j=1}^{N}(1-u_{ij})^m \qquad (3\text{-}30)$$

위 식은 식 (3-26)에서 확률적 제약조건을 완화시킬 때, 목적 함수가 모든 소속 함수 값을 0으로 최소화하여, 쓸모 없는 해를 얻는 것을 피하기 위해 우측항을 삽입하였다. 식 (3-30)에서 η_i는 적절한 양수 값이다. 위 식의 첫 번째 항은 속성 데이터로부터 클러스터 중심사이의 거리를 가능한 한 작게 유지하고, 반면에 두 번째 항은 쓸모 없는 해를 얻는 것을 피하기 위해 u_{ij}를 크게 유지하도록 한다.

정리(Theorem) 1 : $X = \{x_1, x_2, \ldots\ldots, x_n\}$을 속성 데이타의 집합이라고 하고, $L = (\beta_1, \ldots\ldots, \beta_c)$를 클러스터의 중심들의 집합이라고 하자. 또한, d_{ij}^2은 속성 데이타 x_j로부터 클러스터중심 β_i와의 거리라고 하고, $U = [u_{ij}]$는 가능성 소속함수 값들로 이루어진 C×N 행렬이라고 하자. 위와 같은 가정 하에 U는 $u_{ij} = [1 + (d_{ij}^2 / \eta_i)^{\frac{1}{m-1}}]^{-1}$이라면, $J_m(L, U)$를 위한 전역 최소치가 될 것이다. prototype을 위한 필요조건은 FCM과 동일하다.

증명) 필요조건과 소속 함수값 갱신식을 유도하기 위해, 먼저 U 의 행과 열이 서로 독립이다는 것을 주목해보자. 그러므로, U 에 관해 $J_m(L, U)$를 최소화하는 것은 u_{ij} 각각의 값에 관해 다음 목적함수를 최소화 시키는 것과 동일하다.

$$J_m^{ij}(\beta_i, u_{ij}) = u_{ij}^m d_{ij}^2 + \eta_i (1 - u_{ij})^m \tag{3-31}$$

위의 식 (3-31)을 u_{ij} 에 관해 미분하고, 미분값을 0으로 놓을 때 다음 식을 얻을 수 있다.

$$u_{ij} = \frac{1}{1 + \left(\frac{d_{ij}^2}{\eta_i}\right)^{\frac{1}{m-1}}} \tag{3-32}$$

식 (3-32)으로 부터, u_{ij} 의 값이 [0,1]사이에 놓여있다는 것을 알 수 있다. 목적함수에서 새로 더해진 두 번째 항은 prototype의 변수들이

나 거리 척도에 대해 독립이므로, 그들 변수들에 관해 위 식 (3-30)의 미분치는 FCM의 미분치와 동일하다. 그러므로, 최적화를 위한 prototype에서 필요조건은 FCM형태의 알고리즘을 위한 이론들에서 필요조건들과 같다.

각 반복에서, u_{ij}의 갱신된 값은 클러스터 중심 β_i와 x_j 사이의 거리에만 의존한다. prototype의 compatibility 관점에서 볼 때, 다른 클러스터에 관해 속성 벡터의 위치가 관계가 없어야 되고, 단지 클러스터에서 속성 벡터의 소속 함수 값은 그것이 클러스터 중심으로부터 얼마나 떨어졌는가에 의해 결정되어야 한다. 여기서, 클러스터 중심의 갱신은 선택되어진 거리척도에 의존하고, 과정은 FCM의 방법과 동일하다.

3.5.3 제안된 퍼지 클러스터 필터(Fuzzy Cluster Filter)

비선형 필터링의 목적은 잡음을 제거하거나, 윤곽선과 같은 비선형 특성을 보존하기 위한 것이다. 본 연구에서는 신호의 비선형 필터링을 위해 퍼지 클러스터링 방법을 이용하였다.

퍼지 클러스터링 방법으로는 가능적 c-mean 클러스터링(PCM) 방법을 이용하였는데, 전술한바와 같이 이것은 PCM 방법의 경우 소속함수 값이 다른 클러스터와 관계가 없고 속성데이타와 그 클러스터 중심간의 거리에만 의존하기 때문에 FCM 방법에 비해 잡음이 있는 환경에서 강건한 소속함수 값을 얻을 수 있기 때문이다. PCM 방법에서 클러스터 중심의 계산은 분산을 최소화하는 퍼지 클러스터링 방법에 의해 얻어지고, 윈도우내의 각 화소를 위한 소속함수 값은 클러스터 중심으로부터 각 화소간의 거리에 의해 얻어진다. 출력은 소속함수에 의해 가중화 된 윈도우내의 화소들의 가중화된 평균값에 의해

추정되어진다.

윈도우내의 각 표본들에서 소속함수 값은 클러스터 중심 값으로부터의 거리에 의존한다. 클러스터의 초기 중심 값은 outlier(spike noise)에 대한 강건함에서 기인한 윈도우내의 표본들의 벡터 미디안 값이다. 그 다음, 소속함수 값들이 계산되어지고, 클러스터 prototype이 다시 구해진다. 이 계산은 원하는 조건을 만족할때까지 반복적으로 수행될 수 있다.

식 (3-34)에서 $d^2(\boldsymbol{x_k}, \boldsymbol{a})$는 표본 데이타 $\boldsymbol{x}_k$와 클러스터 prototype $\boldsymbol{a}$ 사이의 유클리디안 거리이고, η는 클러스터의 분산을 정의하는 정규화 요소이다.

퍼지 클러스터링을 이용한 비선형 필터의 알고리즘은 다음과 같다.

1단계) 초기화: $\boldsymbol{a}(0) = vector\ \ median(\boldsymbol{x_k}),\ \ k = 1, 2, \ldots\ldots, K$로 표현되는 클러스터 prototype을 윈도우내의 벡터 미디안 값으로 설정한다. 클러스터 prototype의 괄호 안의 0이 뜻하는 것은 0번째 반복을 뜻한다. 여기서, 초기 η값은 식 (3-33)을 이용하여 구한다.

2단계) 반복수가 증가함에 따라 j값도 1씩 증가시킨다. ; j ← j+1

3단계) 식 (3-34)를 이용하여 윈도우내의 모든 화소들의 소속함수 값을 계산한다. 클러스터 prototype으로의 거리에 기반을 둔 $\mu_{x_k}(j)$는 전 단계 반복 때의 $\boldsymbol{a}(j-1)$로 부터 얻을 수 있다.

4단계) 식 (3-36)을 이용하여 클러스터 prototype $\boldsymbol{a}$를 포함하는 모든 클러스터 파라미터들을 갱신하고 식 (3-35)을 이용하여 정규화 요소η를 계산한다.

5단계) 원하던 모든 파라미터 값들이 수렴하면 끝내고, 아니면 2

단계로 돌아가 다시 반복한다.

6단계) 윈도우내의 출력값을 클러스터 중심값으로 대체한다.

필터링 과정을 다시 설명하면 첫 번째 과정에서는 초기 클러스터 중심값으로 윈도우내의 벡터 미디안 값을 이용하였고, 두 번째 과정에서는 소속함수 값을 계산하였으며, 세 번째 과정에서는 클러스터 중심값과 소속함수 값이 수렴할 때까지 이와 같은 과정을 반복하여 수렴된 클러스터 중심값을 출력값으로 대체하였다. 초기의 η값의 계산은 식 (3-33)을 이용하여 구했고, 소속함수의 계산은 식 (3-34)로 부터 얻어진다. 식 (3-35)은 클러스터의 중심에 가까운, 즉 잡음일 가능성이 적은 속성 데이타들만을 이용하여 η의 계산을 한 것이고, 식 (3-36)은 클러스터 중심을 계산하기 위한 식이다.

$$\eta = K \frac{\sum_{k=1}^{n} (\mu_k)^m \cdot d^2(\boldsymbol{x_k}, \boldsymbol{a})}{\sum_{k=1}^{n} (\mu_k)^m} \tag{3-33}$$

단, K는 상수이고, 대체로 K = 1이다.

$$\mu(\boldsymbol{x_k}) = \frac{1}{1 + \left(\frac{d^2(\boldsymbol{x_k}, \boldsymbol{a})}{\eta} \right)^{\frac{1}{m-1}}} \tag{3-34}$$

$$\eta = \frac{\sum_{\boldsymbol{x_k} \in \Pi_\alpha} d^2(\boldsymbol{x_k}, \boldsymbol{a})}{|(\Pi)_\alpha|} \tag{3-35}$$

단, $(\Pi)_\alpha$는 Π의 적절한 α-cut이다.

$$a = \frac{\sum_{k=1}^{n} (\mu_k)^m \cdot \mathbf{x}_k}{\sum_{k=1}^{n} (\mu_k)^m} \tag{3-36}$$

단, $m \in [1, \infty)$은 퍼지화(fuzziness)의 정도를 나타낸다.

3.6 조건적인 필터링

위성 영상은 잡음 센서나 채널 전송에러에 의해 생기는 다 채널 임펄스 잡음에 의해 자주 오염된다. 일반적으로 벡터 미디안과 순서 통계 필터들은 선형 필터들에 비해 다 채널 임펄스 잡음 제거 및 윤곽선 보존에 있어서 우수한 성능을 보여 왔다. 그러나, 벡터 미디안의 문제점은 화소가 잡음이건 아니건간에 필터링과정이 영상의 전 영역에 걸쳐 균일하게 적용되어 지기 때문에 잡음에 오염되지 않은 화소를 변형시키거나 윤곽선을 변형시켜 흐림(blurring) 현상이 나타나는 문제점이 있다. 따라서, 본 연구에서는 이와 같은 문제점을 해결하기 위해 다 채널 윤곽선 검출기를 이용하여 윤곽선 영역과 평탄한 (smooth) 영역을 구분한 뒤 각 영역에서 다 채널 임펄스와 원래의 화소 값을 구분한 뒤 선택적인 필터링을 하는 조건적인 필터링을 다 채널 위성영상에 적용하였다.

3.6.1 다 채널 칼라영상 윤곽선 검출기

다 채널 영상은 이산적인 벡터함수인 **f(x) : Z2→ Zm** 벡터필드로 볼수 있다. 여기서, Z는 정수의 집합을 나타낸다. 기호는 영상 함수 f에서 사용되어 질 것이다. W ⊂ **Z2**에서 **xi** ∈ *W* 이고 i=1,2,.....,n에서 n은 윈도우 W의 크기이다. **f(xi)**는 Xi로서 표현되어지고, X(i)는 R-정렬 방법에 의해 정렬된 윈도우 W내의 i번째로 정렬된 벡터이다. 결과적으로 **X**(1)는 윈도우내의 벡터 미디안 값이고, **X**(n)은 윈도우 W내에서 가장 외곽에 위치해있는 벡터(outlier vector)이다. 벡터 순서 통계에 근거하여 간단한 다 채널 윤곽선 검출기는 다음 식과 같이 구현되어 질 수 있을 것이다.

$$VR = \| \mathbf{X}^{(n)} - \mathbf{X}^{(1)} \| \tag{3-37}$$

윗식에서 VR은 윈도우 W에서 벡터 미디안으로부터 가장 외곽요소의 편차(deviation)를 나타낸다. 결과적으로 다 채널 칼라가 비슷한 평탄한 영역에서는 모든 벡터들은 서로 비슷하므로 VR의 출력은 작게 될 것이다. 그러나, 윤곽선에서의 VR의 출력은 크게될 것이다. 그것은 **X**(n)은 윤곽선의 한면(화소의 수가 적은 그룹)으로부터의 벡터들로부터 선택되는 반면에, **X**(i)은 윤곽선의 다른면(화소의 수가 많은 그룹)으로부터의 벡터들사이에서 선택되기 때문이다. VR의 출력 값은 문턱치값에 의해 실제적인 윤곽선이 검출될 수 있을 것이다. 그러나, VR의 출력은 임펄스 형태의 잡음에 대해 매우 민감하다. 그이유는, 윈도우 W내에서 정렬된 벡터중 가장 외곽요소는 임펄스 형태의 잡음일 가능성이 높기 때문이다. 이와같은 문제는 잡음이 있는데서 강건한 추정기인 분산척도(dispersion measure)에 의해서 해결될 수 있다. 벡터 분산 윤곽선 검출기(Vector Dispersion Edge Detector : VDED)는 정렬된 벡터들의 선형 결합에 의해 다음식과 같이 표현되어 질 수

있을 것이다.

$$\mathrm{VDED} = \mathrm{OSO}\left(\left\|\sum_{i=1}^{n}\alpha_{i1}X^{i}\right\| \cdot \left\|\sum_{i=1}^{n}\alpha_{i2}X^{i}\right\| \cdot \cdot \cdot \left\|\sum_{i=1}^{n}\alpha_{ik}X^{i}\right\|\right)$$

$$= \mathrm{OSO}\left(\left\|\sum_{i=1}^{n}\alpha_{ij}X^{i}\right\|\right), j=1,2,\ldots,k \qquad (3\text{-}38)$$

윗식에서 OSO는 순서 통계 연산자이다. 윗식에서 OSO와 상수 α_{ij} 집합의 적절한 선택에 의해 특별한 다 채널 윤곽선 검출기를 얻을 수 있을 것이다. 그러나, 불행히도 이와 같은 일을 엄격한 수학적인 방법으로 접근하는 방법은 매우 어렵다. 결과적으로 우리는 윤곽선 검출기가 이행해야 하는 몇가지 조건을 언급함으로서 대신해야 할 것이다. 다 채널 임펄스 검출기는 long-tailed(impulsive or double exponential) 잡음에 강건해야한다. 임펄스 형태의 잡음은 정렬된 벡터중 외곽요소들 일 것이므로 윤곽선 검출기는 VR과 같이 단일 차이에 의해 윤곽선을 검출하는 대신에 다음 식과 같이 차이의 k개의 집합을 취해 최소값을 취함으로써 임펄스 형태의 잡음에 강건한 윤곽선 검출기를 구현할 수 있을 것이다.

$$\min_j\left(\left\| X^{(n-j+1)} - X^{(1)} \right\|\right), \; j=1,2, \ldots, k, \qquad k<n \qquad (3\text{-}39)$$

윗식에서 min연산자의 효과는 k-1개까지의 임펄스에 강건한 윤곽선 검출기를 구현할 수 있다. 이러한 min연산자는 임펄스 잡음에 강건한 윤곽선 검출기를 구현하기 사용하였다. 윗식에서 k의 선택은 윈도우의 크기에 의존한다. 3*3윈도우의 크기에서는 k<=3 정도의 크기가 적합하다. 그러나, 최적의 k값을 얻기위한 일반적인 공식은 없다. 그러나, k값은 윤곽선에서 화소의 개수가 적은 그룹의 화소의 개수로 생

각할 수 있기 때문에 k값을 얻는일은 어려운일이 아니다. 게다가, 그 것은 윤곽선 검출기의 전반적인 성능에 크게 영향을 미치지 않는다.

3.6.2 조건적인 필터링을 위한 알고리즘

앞에서 언급한바와 같이 벡터 미디안과 순서 통계 필터들은 선형 필터들에 비해 다 채널 임펄스 잡음제거에 우수하나, 이 방법들은 필터링이 전 영상에 걸쳐 동일하게 적용되어지기 때문에 잡음에 오염되지 않은 화소를 변형시키거나 윤곽선이 왜곡되는 현상이 나타나게된다. 따라서, 본 연구에서는 이와 같은 문제점을 해결하기 위해 화소가 잡음에 오염되었는지 아닌지를 판별한 뒤 선택적인 필터링을 하는 조건적인 필터링을 수행하였다. 조건적인 필터링을 위한 알고리즘은 다음과 같다.

If the p is color edge then

If the p is the outlier of edge side consisting of small pixels and large pixels

then the corresponding pixel $\hat{p}$ be vector median

Else

make $\hat{p}$ equal p

Else

If the p is the outlier in the current window

then the corresponding pixel $\hat{p}$ be vector median

Else

make $\hat{p}$ equal p

윗 알고리즘에서 p는 원래의 화소 값이고, $\hat{p}$ 는 필터링된 값이다.
윗 알고리즘에서 먼저 윈도우내의 중심 화소가 윤곽선인지 아닌지를 판별한다. 여기서, 다 채널 윤곽선일 경우는 화소들이 두 그룹의 형태로 분리될 것이고, 중심화소가 두 그룹중의 하나의 그룹에 속하게 될 것이다. 여기서 중심화소가 각 그룹의 외곽화소일 경우는 임펄스 잡음일 가능성이 있으므로 필터링을 하고 그렇지 않을 경우는 원래의 화소 값을 유지하게 한다. 이와 마찬가지로 윈도우내의 중심화소가 윤곽선이 아닌 평탄한 영역일 경우는 중심화소로부터 벡터 미디안까지의 거리가 윈도우내의 모든 화소들과 벡터미디안과의 평균거리보다 밖에 있을 경우는 중심화소가 임펄스 잡음일 가능성이 많으므로 필터링을 하고 그렇지 않을 경우는 원래의 화소 값을 유지하도록 한다.

3.7 실험 및 결과

본 연구에서는 제안한 필터들의 성능을 평가하기 위해 다 채널 잡음 발생기를 구성하였고, 3개의 256×256 크기의 SPOT영상을 가지고 실험을 행하였다. 잡음이 발생한 각 영상들의 상관관계(correlation) 상수는 $\rho=0.5$를 주었다. 실험 결과에 대한 정량적인 평가는 정규화된 평균 자승 오차(NMSE) 관점에서 행해졌다. 그러나, NMSE 척도가 다 채널 오차를 표현하는 절대적으로 정확한 척도는 아니기 때문에 사람의 시각에 의한 평가도 해 보았다. 표 1, 2, 3은 각각의 SPOT영상에 대한 실험 결과들이다.

다 채널 임펄스 잡음이 4%인 경우, VMF가 3개의 SPOT 영상에 대하여 가장 나쁜 결과를 얻었으며, 다음으로 FCF가 VMF와 비슷한 결과를 나타내었다. 본 연구에서 제안한 방법중 벡터 α-trimmed 평균 필터가 SPOT-2영상에서 양호한 결과를 얻었으며, SPOT-1과 SPOT-2 영상에서는 가중화된 벡터 α-trimmed 평균 필터가 양호한 결과를 얻었다.

가우시안 잡음($\sigma=15$)인 경우, 본 연구에서 제안한 벡터 α-trimmed 평균 필터와 가중화된 α-trimmed 평균 필터가 가장 좋은 결과를 얻었다. 임펄스 잡음과 마찬가지로 벡터 미디언 피터의 성능이 좋지 않았다.

또한, 대부분의 영상에서 가중화된 α-trimmed 평균 필터의 성능이 벡터 α-trimmed 평균 필터의 성능보다 양호하였다.

표 1. SPOT-1영상에서의 각 필터들의 NMSE값 ($\times 10^{-2}$)

Noise Model	VMF	GVDF	FCF (α = 0.4, m = 1.3)	V α TM α = 0.1	WV α TM α = 0.1
impulsive 4 % (ρ = 0.5)	2.5752	2.2526	2.4794	2.0954	2.0850
Gaussian σ=15 (ρ = 0.5)	2.5906	2.2672	2.1547	2.0003	1.9964

표 2. SPOT-2영상에서의 각 필터들의 NMSE값 ($\times 10^{-2}$)

Noise Model	VMF	GVDF	FCF (α = 0.4, m = 1.3)	V α TM α = 0.1	WV α TM α = 0.1
impulsive 4 % (ρ = 0.5)	1.6045	1.4074	1.4957	1.2997	1.3129
Gaussian σ=15 (ρ = 0.5)	1.6272	1.4799	1.3241	1.2342	1.2315

표 3. SPOT-3영상에서의 각 필터들의 NMSE값 ($\times 10^{-2}$)

Noise Model	VMF	GVDF	FCF (α = 0.4, m = 1.3)	V α TM α = 0.1	WV α TM α = 0.1
impulsive 4 % (ρ = 0.5)	4.4431	3.8254	4.0913	3.5352	3.5229
Gaussian σ=15 (ρ = 0.5)	4.2751	3.8718	3.7331	3.3890	3.3836

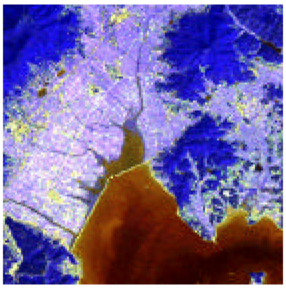 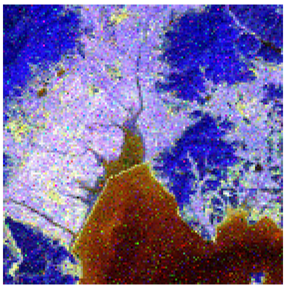

a) SPOT-1 (b) 임펄스 잡음의 SPOT-1 영상

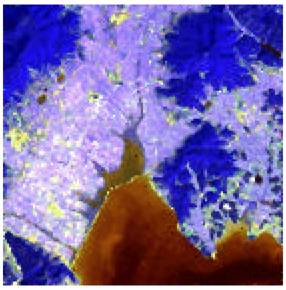 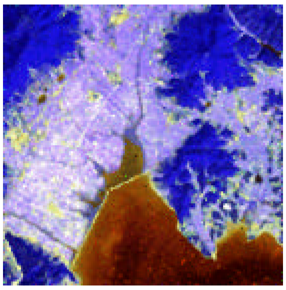

(c) VMF 결과 (d) GVDF 결과

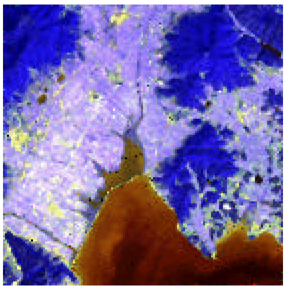 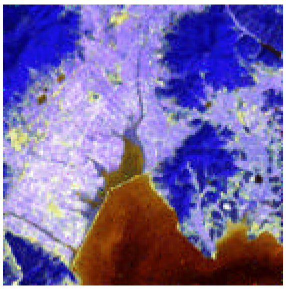

(e) α=0.4, m=1.3 FCF결과 (f) α=0.1 VαTM 결과

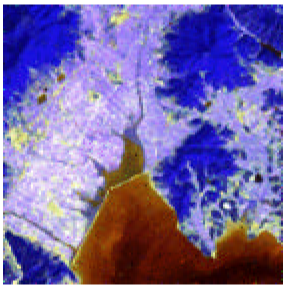

(g) α=0.1 VαTM 결과

그림 3.8 **임펄스 잡음** 4%**의** SPOT-1**영상 필터링 결과**

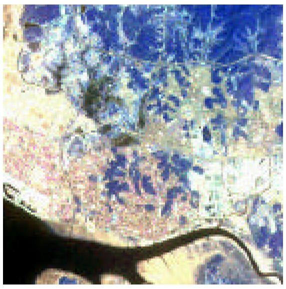

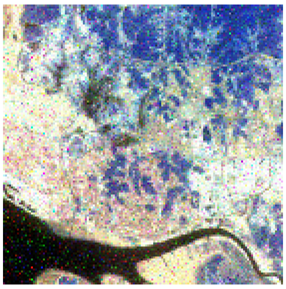

(a) SPOT-2 (b) 임펄스 잡음의 SPOT-2 영상

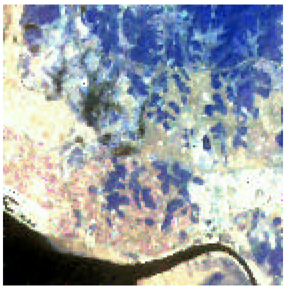

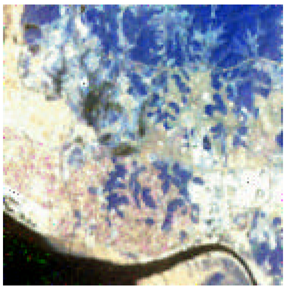

(c) VMF 결과 (d) GVDF 결과

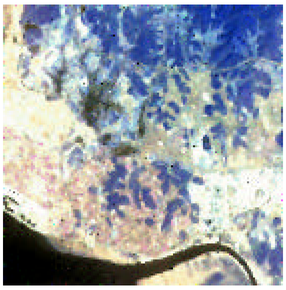

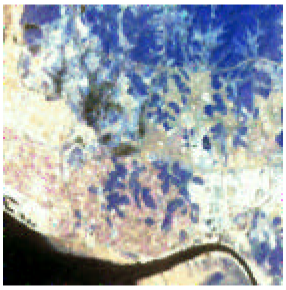

(e) α=0.4, m=1.3 FCF결과 (f) α=0.1 V α TM 결과

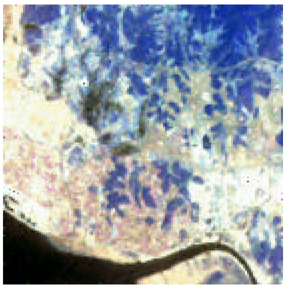

(g) α=0.1 V α TM 결과

그림 3.9 임펄스 잡음 4%의 SPOT-2영상 필터링 결과

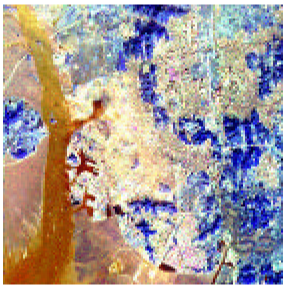

(a) SPOT-3

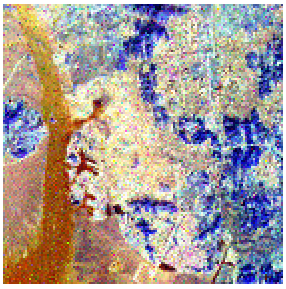

(b) 임펄스 잡음의 SPOT-3 영상

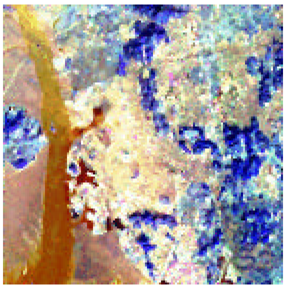

(c) VMF 결과

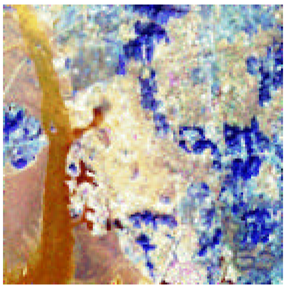

(d) GVDF 결과

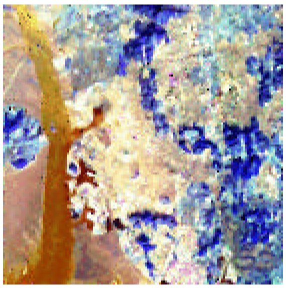

(e) α=0.4, m=1.3 FCF결과

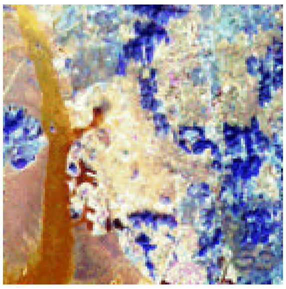

(f) α=0.1 V α TM 결과

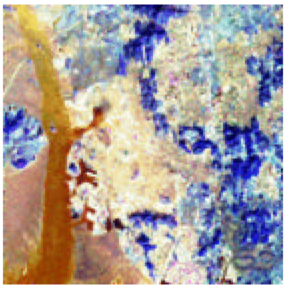

(g) α=0.0 V α TM 결과

그림 3.10 **임펄스 잡음** 4%**의** SPOT-3**영상 필터링 결과**

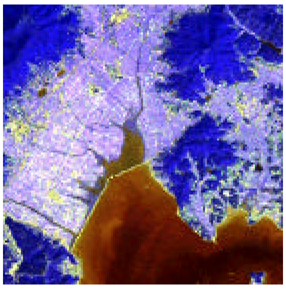

(a) SPOT-1

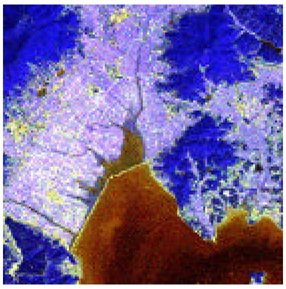

(b) σ=15인 가우시안 잡음

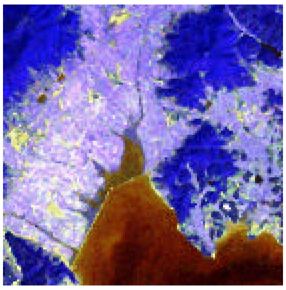

(c) VMF 결과

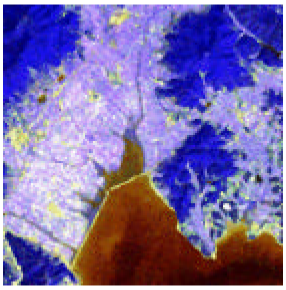

(d) GVDF 결과

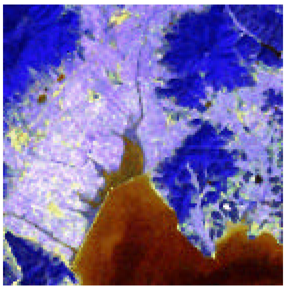

(e) α=0.4, m=1.3 FCF결과

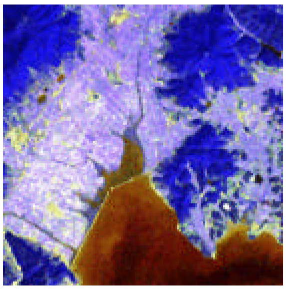

(f) α=0.1 V α TM 결과

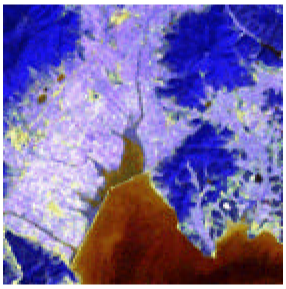

(g) α=0.1V α TM 결과

그림 3.11 σ=15인 가우시안 잡음의 SPOT-1영상 필터링 결과

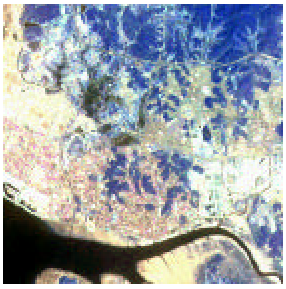

(a) SPOT-2

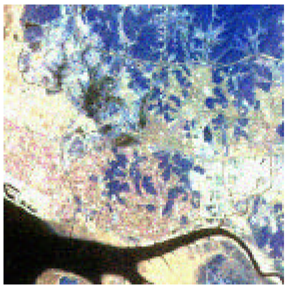

(b) σ=15인 가우시안 잡음

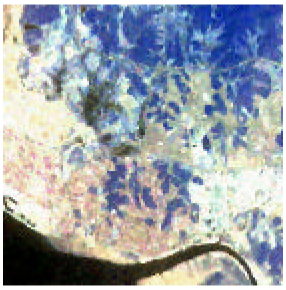

(c) VMF 결과

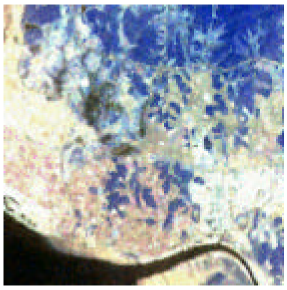

(d) GVDF 결과

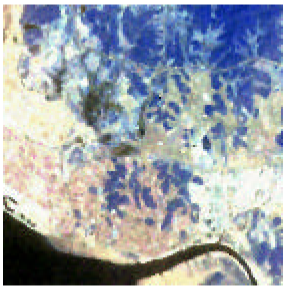

(e) α=0.4, m=1.3 FCF결과

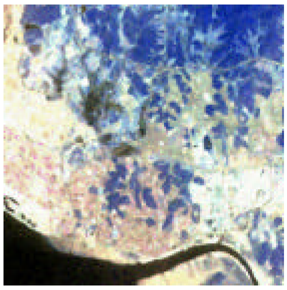

(f) α=0.1 V α TM 결과

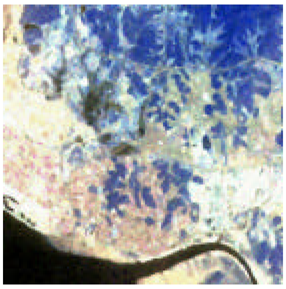

(g) α=0.1 V α TM 결과

그림 3.12 σ=15인 가우시안 잡음의 SPOT-2영상 필터링 결과

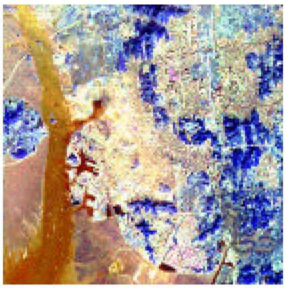

(a) SPOT-3

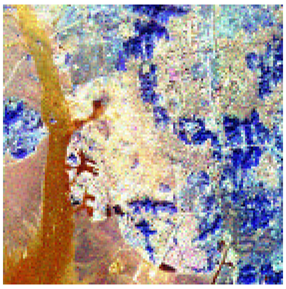

(b) σ=15인 가우시안 잡음

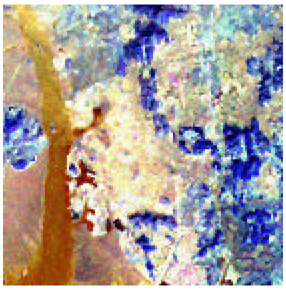

(c) VMF 결과

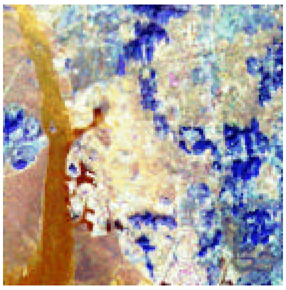

(d) GVDF 결과

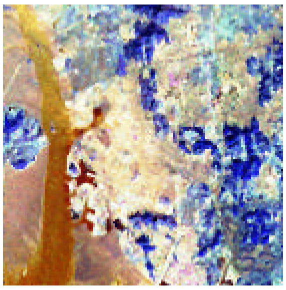

(e) α=0.4, m=1.3 FCF결과

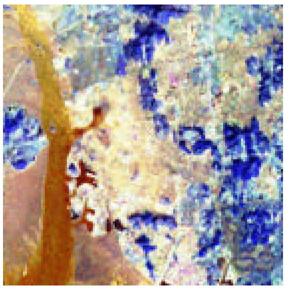

(f) α=0.1 V α TM 결과

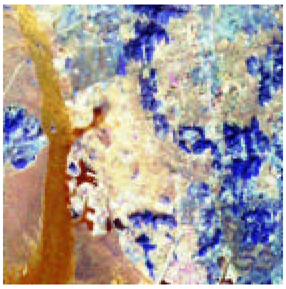

(g) α=0.1 V α TM 결과

그림 3.13 σ=15인 가우시안 잡음의 SPOT-3영상 필터링 결과

제 4 장 위성데이터 질감 속성

위성을 이용한 지구관측 정보는 위성에 탑재된 광학센서와 마이크로파 센서를 통하여 우주상공에서 지구를 관측 촬영한 것으로, 짧은 시간에 넓은 지역을 동시에 관측할 수 있고 반복 측정이 가능하며 관측자료가 디지털 수치로 기록되어 판독이 용이하고 정량화가 가능하므로 지상 정보획득에 많은 이점을 가지고 있다. 또한 관측파장 대역이 가시광선에서 적외선에 이르는 다중 파장대역으로 관측 지역 및 밴드 특성에 따라 다양하고 특색 있는 정보를 취득할 수 있으므로 목적에 따라 우주, 지상, 해양 등 광범위한 분야에서 많은 수요가 예측된다. 특히 정보기술을 기반으로 하는 GIS 시스템의 구축은 지속적으로 위성데이터를 필요로 할 것이다. 그러나 이와 같이 유용성이 많은 위성영상 데이터를 다양한 분야에 효과적으로 적용하고 활용하기 위해서는 이용분야에 적합한 영상처리 및 분석과정이 선행되어야 하며 그 동안 많은 연구와 기술 개발이 이루어져 왔다.

4.1 질감 속성 및 방법

위성에서 관측된 다중분광 위성영상 데이터를 이용목적에 따라 분석하고 활용하기 위해서는 영상 자체에 내포된 밝기, 칼라, 질감 등 다양한 특징들이 중요한 정보원으로 이용되고 있다. 특히 질감이나 칼라정보를 이용한 위성영상의 분석과정에서 가장 중요한 문제는 원영상의 정보를 효율적으로 표현하는 속성을 추출하여 적절히 활용하는 것이다. 일반적으로 위성영상의 분석과정에서는 칼라, 크기, 형태, 질감, 패턴, 높이, 음영, 위치, 연관성 등의 기본요소들이 사용되며, 특

히 위성영상을 이용하여 지상에 분포되어 있는 물체나 지역 등을 식별하고 분류하기 위해서는 밝기, 칼라, 질감 (Texture) 등의 특징이 중요한 정보원으로 사용되고 있다. 질감 속성을 추출하는 방법에는 구조적인 방법, 통계적 인 방법, 모델을 이용하는 방법등이 사용되고 있으며, 이들 중 통계적인 방법이 미시적인 질감 영상의 분석에 좋은 결과를 얻을 수 있다고 보고되고 있다. 기존의 사용되고 되는 속성 및 방법론은 다음과 같다.

- Pixel pattern
  윈도우 안의 데이터를 입력으로 직접 사용할 수 있고 평균이나 표준편차등을 속성으로 사용하는 방법
- Cooccrrence feature
  영상의 통계적 성질을 표현하는 행렬을 구하여 Haralick등이 제안한 스칼라 속성을 사용하는 방법
- Gray-level difference feature
  이웃하는 화소의 그레이 레벨 차를 이용하여 구한 속성을 사용하는 방법
- Feature derived from fourier transform
  영상을 푸리에 변환하여 전력 스펙트럼을 구하고 이것을 스칼라 속성으로 사용하는 방법
- Wavelet based feature
  영상을 wavelet 변환하여 스칼라 속성을 구하는 방법
- Feature derived by markov random field model
  분석하고자 하는 영상이 정의된 모델로부터 생성되었다고 가정하고 모델의 파라미터를 추출하는 모델을 이용한 방법이다.

영상의 통계적 성질을 표현하는 행렬로는 이계 통계치를 구하는 SGLDM(Spatial Gray Level Dependence Matrix), 영상의 국부적인 그레이 레벨의 변화를 표현하는 NSGLDM(Neighboring Spatial Gray Level Dependence Matrix), 그리고 그레이 레벨의 run-length를 표현하는 GLRLM(Gray Level Run Length Matrix)등이 있다. Haralick등은 통계 행렬을 사용하여 질감정보를 유출해 내는 다양한 측정방법을 제안하였으며 Landsat 위성영상을 이용하여 실험을 한 결과 레벨 1의 지표분류에서 정확도가 약 7% 정도 향상되었다고 보고하였고, Shin와 Showengerdt는 밝기 값에 의해 분류를 수행하였을 경우 약 73%의 평균 정확도를 보이는데 반해 밝기 값과 질감을 분류에 적용하였을 경우에는 약 96% 까지 분류 정확도가 향상되었다고 밝히고 있다. 그러나 Haralick이 제안한 스칼라 속성들은 서로 상관관계(correlation)가 많으며, 통계 행렬을 구하는데 필요한 계산량과 통계 행렬이 담고 있는 다양한 정보를 제한적으로 표현하고 있어 J. Lee등은 SGLDM을 포함하여 이들 행렬을 의미있는 방향으로 투사한 벡터 속성을 정의하고 이들을 질감 영상 분석에 이용하였다. 최근에는 통계 행렬등을 그레이 영상 뿐만아니라 다 채널 영상으로 확장하여 영상 분석에 이용하는 연구가 활발하게 진행되고 있다.

칼라를 이용하는 영상분석 방법에는 영상의 전반적인 색 분포를 기술하며 계산하기 쉽고 해상도의 변화에 대해 민감성이 적은 칼라 히스토그램이 많이 사용한다. 칼라 히스토그램은 영상의 전반적인 색 분포를 기술할 뿐아니라 계산하기 쉽고 관점(viewing point)에 의한 변화 및 해상도의 변화에 덜 민감하다. 그러나 칼라들의 공간적 상관관계에 대한 정보를 포함하고 있지 않기 때문에 속성으로 사용되기에는 불충분한 점이 있다. 따라서 칼라 히스토그램과 영상의 질감 정보 및 형태 정보를 효율적으로 결합하여 이용하려는 시도들이 있었

다. 이러한 연구에는 칼라 히스토그램과 별도로 웨이브렛 분석등 영상의 질감 속성등을 추출하여 결합하여 이용하려 하였다. 그러나, 그레이 레벨 영상 분석에서 널리 이용되어온 이계 통계 행렬을 칼라로 확장하여 정의하고 이를 의미있는 방향으로 투사하면 영상의 히스토그램 및 영상 질감에 관한 속성 벡터를 동시에 편리하게 얻어낼 수 있다. 최근에 제안된 칼라쌍의 공간적 상관관계가 어떻게 거리에 따라 변화하는지를 기술하는 칼라 Correlogram 행렬도 이러한 부류의 속성으로 간주될 수 있다.

따라서 본 연구에서는 위성영상 분류에 유용한 속성을 선택하기 위하여 그레이 영상에서 영상의 통계적 성질을 표현하는 SGLDM (Spatial Gray Level Dependence Matrix), GLRLM (Gray Level Run Length Matrix), NSGLDM (Neighboring Spatial Gray Level Dependence Matrix) 등을 다 채널 범위로 확장하여SVDM (Spatial Vector Dependence Matrix), CRLM (Vector Run Length Matrix), NSVDM (Neighboring Spatial Vector Dependence Matrix) 등의 속성을 정의하였다. 아울러 이들 다 채널 영상의 행렬 속성들로부터 유도되어 채널과 질감 속성을 동시에 검출할 수 있는 6개의 벡터 속성들을 선정하였다. 이 속성 벡터를 사용하면 기억 용량이 크고 많은 계산량이 요구되며 서로 상관관계가 많고 행렬 자체가 포함하고 있는 정보를 표현하는데 미흡한 점을 해결할 수 있으며 또한 정보의 유실을 최대한 방지한 분류시스템을 구성할 수 있다. 또한 선택된 벡터 속성들의 분별력을 측정하기 위하여 SPOT 위성으로부터 관측된 전라남도 해안지역의 영상에서 분류 클래스를 산림, 수역, 농경지 등 세 종류로 정하고 각 클래스별로 훈련자료 (Training Sites)를 추출한 다음 감독분류에 사용될 특징으로는 벡터 속성들을 적용하여 분별력을 시험하였다. 영상분류 시스템의 구성은 신경망 분류기를 사용하였으

며, 각각의 속성 벡터들을 훈련자료 영상을 이용한 유사성 측정과 전체 영상분류에 적용시켜 그 성능을 평가하였다.

4.2 대역간 통계 행렬의 확장

4.2.1 행렬 속성의 정의

일반적으로 통계행렬을 이용하는 방법에는 이계 통계치를 구하는 SGLDM과 대역신호의 국부적인 신호크기의 변화를 표현하는 NSGLDM 그리고 대역 신호크기의 Run-Length를 표현하는 GLRLM 등이 사용되고 있다. 따라서 이와 같은 속성을 다 채널 칼라로 확장하여SVDM, NSVDM, VRLM 등의 속성들을 정의할 수 있다.

(1)SVDM (Spatial Vector Dependence Matrix)

SGLDM (Spatial Gray Level Dependence Matrix)에서 확장한 것으로, $I(.,.)$를 $n \times n$ 다중 대역 위성데이터라고 가정하자. 그리고 $I(i,j) = \boldsymbol{m}$을 다중대역 위성데이터 (i,j) 위치에 있는 데이터 벡터 $\boldsymbol{m}$이라 하면, 다중 대역 데이터 벡터값 사이의 공간 변화와 공간 의존을 표현하는 행렬 $SVDM(m,n)$은 주어진 거리 d와 방향 θ를 파라미터로 하여 다음과 같이 정의할 수 있다.

$$
\begin{aligned}
&SVDM(m,n) = \\
&\quad Card\ [\{((i,j),(k,l) \in I \times I \mid \rho((i,j),(k,l)) = d, \qquad (4\text{-}1) \\
&\quad angle\ ((i,j),(k,l)) = \theta,\ I(i,j) = \boldsymbol{m},\ I(k,l) = \boldsymbol{n}\ \}]
\end{aligned}
$$

여기서, $Card()$는 집합의 원소 개수 (Cardinality)를 표현하며, $\rho(.,.)$는 화소간의 거리, $angle(.,.)$은 화소간의 각도를 표시한다. 일반적인 거리의 정의는 식 (4-2)를 사용하고 화소간의 각도는 식 (4-3)과 같이 주어진다.

$$\rho((i,j),(k,l)) = \max(|i-k|, |j-l|) \tag{4-2}$$

$$angle((i,j),(k,l)) = \tan^{-1}((l-j)/(k-i)) \tag{4-3}$$

거리 $d=1$인 경우, 방향 θ는 $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 등이 된다. 이 행렬을 표현하기 위해서 채널의 종류가 R 개라면, R^2 개의 기억 공간이 요구되며, 채널의 수의 제곱에 비례하는 형태로 많은 기억 공간이 필요하게 된다. 그림 4.1에서는 간단한 영상에 대한 $d=1$, $\theta=0^\circ$일 경우의 SVDM을 표현하였다.

m_0	m_0	m_1	m_1
m_0	m_0	m_1	m_1
m_0	m_2	m_2	m_2
m_2	m_2	m_3	m_3

(a) 위성 영상

	m_0	m_1	m_2	m_3
m_0	4	2	1	0
m_1	2	4	0	0
m_2	1	0	6	1
m_3	0	0	1	2

(b)SVDM ($d=1$, $\theta=0^\circ$)

그림 4.1 SVDM의 예

(2) NSVDM (Neighboring Spatial Vector Dependence Matrix)

NSGLDM (Neighboring Spatial Gray Level Dependence Matrix)에서 확장한 것으로 다중대역 위성데이터 $I(.,.)$의 NSVDM은 거리 d을 파라미터로 하여 다음과 같이 정의할 수 있다.

$$NSVDM(\boldsymbol{m}, n) =$$

$$Card\ [\{(i, j)\in I \mid I(i, j) = \boldsymbol{m},\ \ Card\ [\{(k, l)\in I \mid (k, l) \neq (i, j),\ \ \rho((i, j), (k, l)) = d,\ \ I(i, j) = I(k, l)\ \}] = n\ \}] \tag{4-4}$$

NSVDM이 SVDM과 다른 점은 방향성을 가지지 않기 때문에 회전에 무관하며, 거리 d 인 이웃한 (neighboring) 화소에 대해 국부적으로 계산되기 때문에SVDM에 비해 병렬 연산이 용이하고 거리 d가 적은 경우 필요한 기억 공간이SVDM 보다 적어진다. 그림 4.2는 간단한 영상에 대한 NSVDM의 예를 나타내었다.

m_1	m_1	m_2	m_3	m_1
m_0	m_1	m_1	m_2	m_2
m_0	m_0	m_2	m_2	m_1
m_3	m_3	m_2	m_2	m_1
m_0	m_0	m_2	m_0	m_1

(a) 위성 영상

	# of pixels								
	0	1	2	3	4	5	6	7	8
m_0	0	0	1	0	0	0	0	0	0
m_1	0	0	1	1	0	0	0	0	0
m_2	0	0	0	0	4	1	0	0	0
m_3	0	1	0	0	0	0	0	0	0

(b)NSVDM

그림 4.2 NSVDM의 예

(3) VRLM (Vector Run Length Matrix)

GLRLM (Gray Level Run Length Matrix)에서 확장한 것으로, 다중대역 위성데이터 $I(.,.)$의 VRLM은 영상의 방향 θ을 파라미터로 다음과 같이 정의할 수 있다.

$$VRLM(\boldsymbol{m}, n) = Card[\{(i,j) \in I \mid I(i,j) = \boldsymbol{m},\ \tau(\boldsymbol{m}, \theta) = n\}] \tag{4-5}$$

여기서 $\tau(m, \theta)$는 θ방향의 채널 값 m의 run-length에 해당된다. 따라서 VRLM은 방향성을 가지고 있으며, 방향에 무관한 VRLM을 구성하기 위해서는 각 방향의 VRLM 들을 산술 평균하여 이용할 수 있다. 그림 4.3에는 간단한 영상에 대한 VRLM의 예를 나타내었다.

m_0	m_1	m_2	m_3
m_0	m_2	m_3	m_3
m_2	m_1	m_1	m_1
m_3	m_0	m_3	m_0

(a) 위성영상

	Run Length			
	1	2	3	4
m_0	4	0	0	0
m_1	1	0	1	0
m_2	3	0	0	0
m_3	3	1	0	0

(b) VRLM ($\theta = 0^{\circ}$)

그림 4.3 VRLM의 예

(4) 히스토그램 및 Correlogrm

위성 영상 $I(.,.)$ 의 히스토그램 H는 다음과 같이 정의된다.

$$H_I(\boldsymbol{m}) = Card[\{(i,j) \in I \mid I(i,j) = \boldsymbol{m}\}] \tag{4-6}$$

다 채널 영상의 히스토그램이 안고있는 문제를 개선하기 위해 J. Haung 등이 제안한 영상 $I(.,.)$ 의 칼라 Correlogram은 다음과 같다.

$$Corr(\boldsymbol{m}, \boldsymbol{n}) =$$
$$Card[\{(i, j), (k, l) \in I \times I \mid I(i, j) = \boldsymbol{m}, \quad (4\text{-}7)$$
$$\rho((i, j), (k, l)) = d, \ I(k, l) = \boldsymbol{n}\}]$$

행렬 $Corr(\boldsymbol{m}, \boldsymbol{n})$은 영상 내의 벡터 값이 $\boldsymbol{m}$인 화소가 주어졌을 때, 주어진 화소로부터 d 만큼 떨어진 화소의 벡터 값이 $\boldsymbol{n}$일 확률을 나타낸다. $Corr(\boldsymbol{m}, \boldsymbol{n})$은 $d=1$인 경우SVDM의 4 방향에 대한 행렬을 산술 평균한 행렬과 같은 의미를 가진다. 또한 영상 $I(.,.)$의 Autocorrelogram은 $Corr(\boldsymbol{m}, \boldsymbol{n})$에서 같은 벡터쌍 사이의 공간적 상관관계를 나타낸다.

$$Autocorr(\boldsymbol{m}) = Corr(\boldsymbol{m}, \boldsymbol{m}) \quad (4\text{-}8)$$

4.3 벡터 속성 추출

통계 행렬들을 위성영상 분류에 적용되는 속성으로 사용할 경우 차원이 너무 크기 때문에SVDM, NSVDM, VRLM, Correlogram 등을 의미 있는 방향으로 투사 (projection) 하여 NSVDM_R, NSVDM_W, NSVDM_M, VRLM_R, VRLM_W, VRLM_M 등의 위성 영상 분별에 유용한 채널 및 질감 속성들을 추출할 수 있다.

다중대역 위성영상으로부터 얻어진 행렬SVDM은 대칭 행렬이다. 또한 식 (4-1)과 식 (4-7)에서 알 수 있듯이SVDM에서 각도 θ에 관한 제약을 없애면, 즉 각도 θ를 모든 방향에 대해 고려할 경우SVDM은 칼라 Correlogram과 동일함을 알 수 있다. 식 (4-9)는 이 행렬의 주 대각 요소이고, 동일한 벡터 쌍의 공간적 상호관계를 나타내는 것

이므로 Autocorrelogram과 일치한다. 또한 방향 θ의 제약을 없애고 구한SVDM_D는 식 (4-10)과 같다. 따라서 J. Huang 등이 제안한 칼라 Correlogram은 SVDM의 특별한 형태로 볼 수 있으며, Autocorrelogram은SVDM의 주 대각 요소를 벡터 형태로 추출한 속성이다. 또한 NSVDM을 가중하여 행 방향으로 합하면 Autocorrelogram이나SVDM_D와 같게 된다.

$$SVDM\_D(m) = SVDM(m, m) \tag{4-9}$$

$$SVDM\_D(m) = \sum_n n \times NSVDM(m, n) \tag{4-10}$$

NSVDM 행렬도 의미를 부여할 수 있는 방향으로 투사하여 특징있는 벡터 속성을 정의할 수 있다. NSVDM 행렬을 행 방향으로 투사하면 식 (4-11)과 같고 이것은 채널 히스토그램을 나타낸다. 또한 가중치를 주고 행 방향으로 투사하면 식 (4-12)와 같이 나타낼 수 있으며, 전술한바와 같이SVDM_D(m)와 같다. 또한 같은 벡터 쌍의 공간적 평균을 표현하고 있는 NSVDM 행렬로부터 식 (4-13)을 정의하면 이것은 영상 내에서 어떤 벡터와 이웃하는 화소 중 같은 벡터의 평균 화소 수를 나타내는 질감에 관련된 속성이다.

$$NSVDM\_R(m) = \sum_n NSVDM(m, n) \tag{4-11}$$

$$NSVDM\_W(m) = \sum_n n \times NSVDM(m, n) \tag{4-12}$$

$$NSVDM\_M(m) = NSVDM\_W(m) / NSVDM\_R(m) \tag{4-13}$$

VRLM의 경우 각 방향으로부터 얻어진 VRLM 들을 산술적으로 평균하여 얻어진 VRLM을 행 방향으로 투사하면 식 (4-14)와 같이

나타낼 수 있으며, 영상의 채널 히스토그램과 유사한 특성을 가진다. 또한 가중하여 투사한 벡터는 식 (4-15)와 같이 나타내며 영상의 히스토그램과 일치한다. 채널의 평균 run-length를 의미하는 벡터 속성은 식 (4-16) 이며, 이것은 영상의 질감을 표현하는 속성으로 간주될 수 있다. 그리고 VRLM을 각 방향에 대해 구하고 이들을 합하여 얻을 경우 식 (4-17)과 같으며 히스토그램과 일치한다.

$$VRLM\_R(m) = \sum_n VRLM(m,n) \tag{4-14}$$

$$VRLM\_W(m) = \sum_n n \times VRLM(m,n) \tag{4-15}$$

$$VRLM\_M(m) = VRLM\_W(m)/VRLM\_R(m) \tag{4-16}$$

$$VRLM\_W(m) = NSVDM\_R(m) \tag{4-17}$$

표 4. 행렬과 벡터 속성

행 렬	벡터 속성	투사 방법	의 미
SVDM	SVDM_D	주 대각 요소 추출	Autocorrelogram
	SVDM_D	행 또는 열 방향 투사	Histogram
NSVDM	NSVDM_R	행 방향 투사	Histogram
	NSVDM_W	가중화 후 행 방향 투사	Autocorrelogram
	NSVDM_M	NSVDM_W/NSVDM_R	이웃하는 평균 동일 벡터 수
VRLM	VRLM_R	행 방향 투사	Run-length 분포
	VRLM_W	가중화 후 행 방향 투사	Histogram
	VRLM_M	VRLM_W/VRLM_R	평균 Run-length 분포

따라서 상기 내용을 요약하면, SVDM에서 방향 θ에 대한 제약을 무시하고 단순히 두 화소간의 거리만을 고려하면 Color correlogram과 일치한다. 그리고 Color correlogram과SVDM의 주 대각 요소만을 추출하면 Autocorrelogram이 되며, 이것은 NSVDM을 행 방향으로 가중하여 투사한 NSVDM_W와 동일하다. 또한 방향의 제약을 무시한SVDM을 행 열 방향으로 투사하여 정규화 하거나, NSVDM을 행 방향으로 투사하여 얻은 NSVDM_R 과 VRLM을 행 방향으로 가중하여 투사한 VRLM_W는 히스토그램과 일치한다. 표 1은 이상의 벡터 속성을 정리하여 나타내고 있다.

4.4 질감 속성 벡터의 성능 측정 및 분별기

4.4.1 (비)유사성 측도

질감을 이용한 영상 분석에 있어서 가장 중요한 일은 영상의 특성에 관한 정보를 효율적으로 표현하는 질감 속성을 추출하는 방법이다. 그러나 같은 속성 벡터라도 어떻게 분별기를 구성하고 어떤 (비)유사성 측도를 사용하는가는 중요한 문제이다. (비)유사성 측도는 계산량과 분별기 효율의 관점에서 비교되고 선택되어져야 한다 본 연구에서는 두벡터 A와 B를 0과 1사이의 정규화된 퍼지소속 함수로 가정하고 다음과 같은 (비)유사성 측도들을 이용하고 평가할 것이다.

A. 평균 자승 오차(mean square error)의 비유사성 측도

$$MSE = \sum_i (A[i] - B[i])^2 \tag{4-18}$$

B. Max-Min의 유사성 측도

$$K = \max_{i} \{ \min(A(i), B(i)) \} \tag{4-19}$$

C. 퍼지 Hausdorff distance의 비유사성 측도

$$q(A, B) = \int q(A(\alpha), B(\alpha))\, d\alpha \tag{4-20}$$

여기서, $A(\alpha)$**와** $B(\alpha)$ **는 퍼지 집합** $A(i)$**와** $B(i)$**의** α-*level* **집합으로 소속함수의 값이** α **보다 큰 구간을 표현하며, 피적분함수** $q(.,.)$ **는 두 구간의** Hausdorff distance**로 만약** $A(\alpha) = [a_1, a_2]$, $B(\alpha) = [b_1, b_2]$ **라면**

$$q(A(\alpha), B(\alpha)) = \max\{|a_1 - b_1|, |a_2 - b_2|\} \tag{4-21}$$

이다.

D. Dubois 와 Prade의 유사성 측도

$$S(A, B) = |A \cap B| / |A \cup B| \tag{4-22}$$

여기서

$$A \cap B = \min[A(i), B(i)],$$
$$A \cup B = \max[A(i), B(i)]$$

이며,

$$|A| = \sum_i A(i)$$

로 퍼지 집합의 cardinarity 이다.

E. Bhattacharyya 유사성 측도

$$B(A,B) = -\ln \sum_{i=0}^{n} \sqrt{A(i) - B(i)} \qquad (4-23)$$

F. Matusima 유사성 측도

$$M(A,B) = \sqrt{\sum_{i=0}^{n} (\sqrt{A(i)} - \sqrt{B(i)})^2} \qquad (4-24)$$

4.4.2 다 채널 영상의 분별기

본 연구에서 제안된 벡터 속성의 성능을 실험적으로 검토하기 위하여 신경망 분류기를 사용하였다.

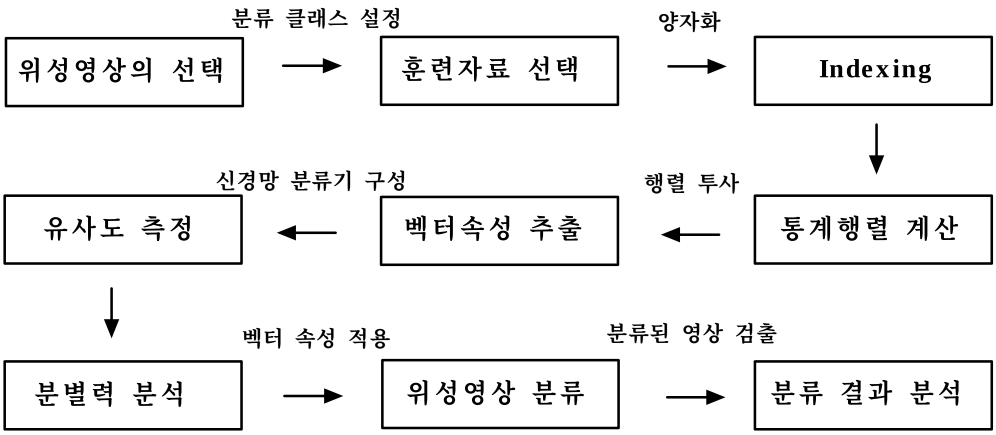

그림 4.4 위성영상 데이터의 영상분석 블록 다이어그램

4.4.3 분류 네트워크의 구성

분류를 수행하기 위한 네트워크은 그림 4.6과 같이 2층 퍼셉트론 (Two-layer perceptron) 으로 구성하였으며, 64개의 입력 노드를 갖는 입력 층과 16개의 노드를 갖는 은닉 층 (hidden layer) 그리고 출력 층은 3개의 노드를 가지고 있고 인접 층 사이에 완전 연결 구조를 가지도록 구성되었다. 1×64 벡터 입력은 16개의 은닉 노드에서 총체화 (aggregation) 되고, 16개의 은닉 노드에서의 출력은 출력 층 노드의 입력으로 연결되어 최종 출력 값을 얻게 된다. 또한 네트워의 훈련 과정은 그림 4.5에서 나타낸 것과 같이 오류 역전파 알고리즘 (Back- Propagation Algorithm)을 이용하였으며, 주어진 입력과 요구되는 출력에 대해 가장 적당한 값을 구하기 위해 Gradient Descent 방법을 사용하였다.

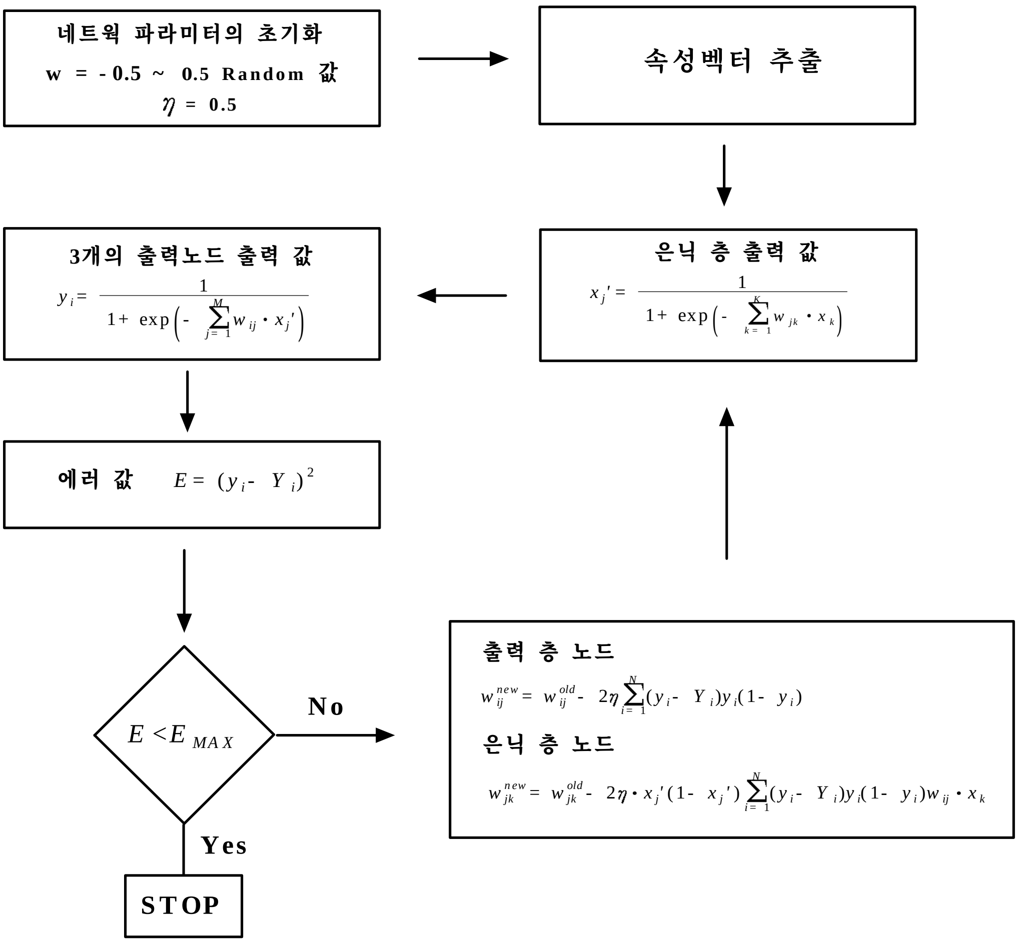
네트워 파라미터의 초기화
w = -0.5 ~ 0.5 Random 값
$\eta = 0.5$
속성벡터 추출
은닉 층 출력 값
$x_j' = \frac{1}{1+\exp\left(-\sum_{k=1}^{K} w_{jk} \cdot x_k\right)}$
3개의 출력노드 출력 값
$y_i = \frac{1}{1+\exp\left(-\sum_{j=1}^{M} w_{ij} \cdot x_j'\right)}$
에러 값 $E = (y_i - Y_i)^2$
$E < E_{MAX}$
No
Yes
STOP
출력 층 노드
$w_{ij}^{new} = w_{ij}^{old} - 2\eta \sum_{i=1}^{N} (y_i - Y_i) y_i (1 - y_i)$
은닉 층 노드
$w_{jk}^{new} = w_{jk}^{old} - 2\eta \cdot x_j'(1 - x_j') \sum_{i=1}^{N} (y_i - Y_i) y_i (1 - y_i) w_{ij} \cdot x_k$

그림 4.5 **훈련과정**

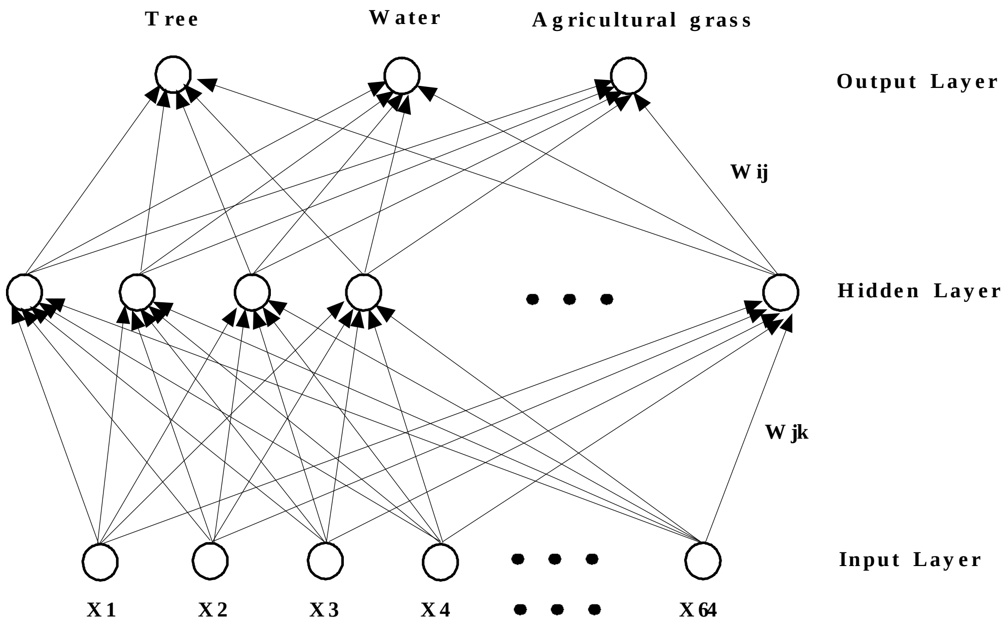

그림 4.6 2층 신경망 구조

4.5 실험 및 고찰

4.5.1 실험 방법 및 사용 영상

본 연구의 실험에서 사용된 영상은 1997년 9월 29일 촬영된 전라남도 보성군 조성면의 득량만 방조제 주변지역인 512×512 크기의 SPOT 다중분광 영상을 사용하였다. 그림 4.7의 위성영상은 밴드 1, 2, 3을 각각 Red, Green, Blue로 합성한 영상으로서, 분류하고자 하는 클래스는 영상에서 가시적으로 구분이 되는 산림, 수역, 농경지 등 세 종류로 선정하였으며, 각 클래스에 대한 훈련 데이터는 그림 4.8과 같이 선택하였다. 분류 방법은 그림 4.4와 같이 RGB 영상을 64개의 등간격 채널 값으로 양자화 하였으며, 신경망 분류기를 구성하여 6개의

64차원 속성 벡터에 대한 분별력을 실험한 다음 우수 속성을 선별하고, 전체 위성영상을 분류하여 결과를 평가하였다.

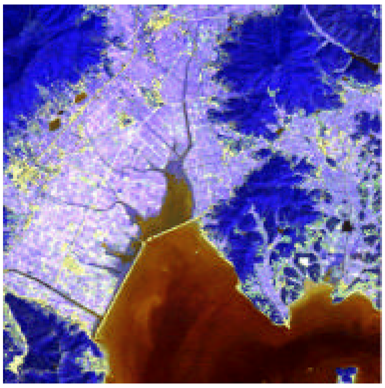

그림 4.7 SPOT Multispectral Image captured in Sept. 29, 1997.

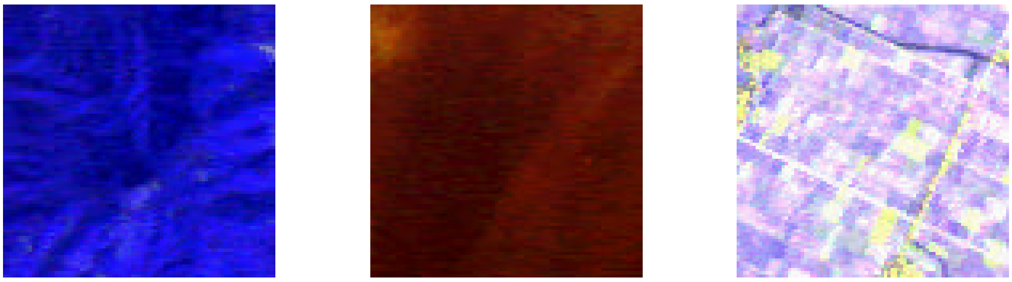

(a) Tree (b) Water (c) Agricultural grass

그림 4.8 선택된 훈련집합

4.5.2 위성영상의 분류 및 결과 분석

위성영상의 분류 실험은 훈련 (Training) 과정과 시험 (Testing) 과정으로 나누어 진행되었으며, 훈련은 이미 알고 있는 클래스의 영상 데이터를 네트워의 입력으로 사용하였을 때 출력이 원하는 클래스가 되도록 노드 파라미터를 반복적으로 조정하는 과정이며, 시험은 훈련과정에서 도출된 파리미터에 의해 영상을 분류하는 과정이다. 실

험에 사용된 SPOT 위성영상은 많은 잡음과 고주파 요소를 포함하고 있기 때문에 분류 정확도가 떨어지는 원인이 될 수도 있고, 여섯 개의 벡터 속성들은 위성영상의 밝기 정보를 포함하고 있기 때문에 전처리 과정에서 질감을 두드러지게 하는 히스토그램 평활화 (Histogram Equalization)를 시키면 속성 자체의 의미를 상실할 수 있으므로 전처리 과정은 각각의 밴드를 중요도에 따라 양자화하거나 적응 양자화 기법을 사용하여 256개의 그레이 레벨 수를 줄이는 방법을 사용할 수 있다. 따라서, 본 연구의 실험에서는 고주파 잡음요소를 제거하기 위해 메디안 필터링 (Median Filtering)을 이용하였으며, 양자화 과정은 각 밴드의 중요성이 동등하다는 가정 하에 4레벨씩 총 64개의 레벨로 인덱싱 (Indexing) 하였다.

또한 전체 영상에 대한 분류 실험을 수행하기 전에 그림 4.8의 훈련자료 영상을 이용하여 6개의 벡터 속성들에 대한 분별력을 시험하였다. 실험에 사용된 영상은 산림, 수역, 농경지에 대해 85×85 크기로 추출된 영상으로서, RGB 영상은 64개의 벡터 값으로 양자화 하였다. 속성 벡터들은 산림, 수역, 농경지 등 각각의 영상에 대하여 윈도우를 16×16 블록으로 설정하고 행과 열 방향으로 4 픽셀 간격씩 이동하며 289개의 속성 벡터를 구하였다. 이중 29개를 무작위로 선정하고 평균을 취한 다음 훈련데이터로 사용하여 나머지 260개의 벡터를 검증하는 방법을 사용하였다. 즉 실험 영상으로부터 6개의 64차원 속성 벡터를 그림 4.6에 도시된 신경망 분류기를 사용하여 분별력 시험을 수행하였으며, 분류결과 최대오류를 0.01로 설정하였을 경우 100%의 정확도를 갖는 우수한 분별력을 나타내었다. 이 결과는 훈련자료 영상의 자체 분류 결과이므로 전체 영상에는 존재하는 항목이 훈련자료 영상에는 존재하지 않을 경우와 훈련자료 영상에 존재하는 분류 항목의 샘플들은 동종이며 샘플이 쉽게 추출될 수 있기 때문에 전체

영상을 분류하는 것과는 환경이 상당히 상이하다. 따라서 전체영상 분류 정확도의 측정치가 될 수는 없지만, 사용되는 분류 방법이 훈련 자료 영상에 우수하게 작동한다는 것과 여섯 개의 속성 벡터들이 위성영상 분류에 효과적으로 사용될 수 있다는 것을 확인할 수는 있었다.

전체 영상에 대한 분류 실험은 여섯 개의 벡터 속성들 각각에 대하여 수행하였으며, 훈련데이터는 그림 4.8의 산림, 수 역, 농경지 등에 대해 윈도우를 81개씩 추출하여 사용하였고, 네트웍의 훈련에서 반복횟수는 5000회 이하가 되도록 지정하였으며 오차한계가 0.01 이하가 될 때까지 반복 수행하도록 설정하였다. 그림 4.9에서는 여섯 개의 벡터 속성들을 이용하여 그림 4.7의 영상을 세 개의 클래스로 분류한 결과를 나타낸 것으로 사용지역에 대한 정확한 분류지도 (Ground Truth Map)나 검증자료 (Reference Data)를 얻기 어려운 관계로 분류오차 표 작성 및 해석 등 정확한 분류성능 평가는 어렵지만 시각적인 판단에서 볼 때 상당히 좋은 분류 결과를 나타내고 있음을 보여준다. 참고로 그림 9의 (b)와 (d)의 결과는 채널 히스토그램과 동일한 속성으로 동일한 결과를 얻을 수 있음을 보여주고 있다. 산림의 경우 VRLM_R, VRLM_W (NSVDM_R), NSVDM_W 등이 좋은 분류결과를 나타내고 있는 반면 NSVDM_M은 일부분이 농경지 지역과 혼동되어진 것을 볼 수 있으며, 수역의 경우 VRLM_M과 NSVDM_M이 좋은 결과를 나타내고 있고 VRLM_W (NSVDM_R)도 전반적으로 양호한 편이지만 VRLM_R (NSVDM_W)은 육지에 위치하고 있는 일부 수역을 인식하지 못하고 있다. 농경지의 경우는 VRLM_W (NSVDM_R)이 양호한 결과 나타내고 있고 NSVDM_M, VRLM_R, NSVDM_W는 산림 또는 수역 지역과 약간의 오분류를 나타내고 있다. 그러나 전체적인 판단에서 볼 때 여섯 개의 벡터 속성

들은 개개의 특성에 따라 장단점을 내포하고 있으며, 전반적으로 비교적 정확한 분류결과를 나타내고 있다.

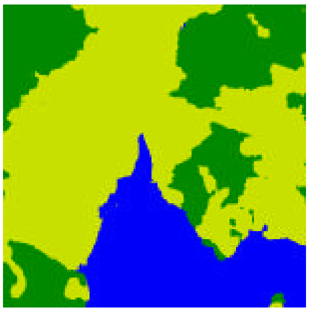

(a) Classified image using VRLM_R

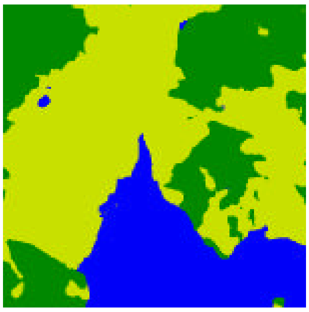

(b) Classified image using VRLM_W

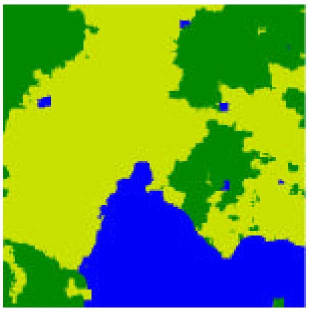

(c) Classified image using VRLM_M

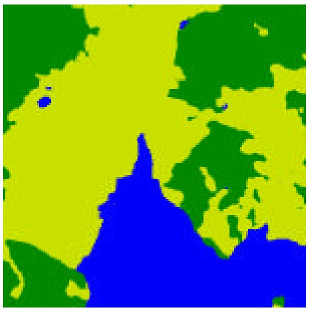

(d) Classified image using NSVDM_R

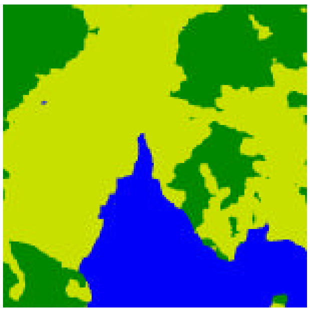

(e) Classified image using NSVDM_W

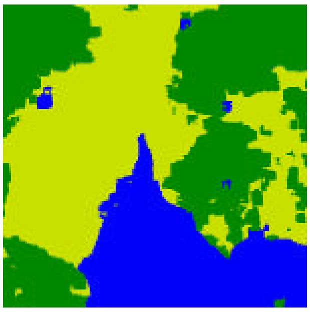

(f) Classified image using NSVDM_M

그림 4.9 제안한 속성벡터를 사용한 실험 결과

제 5 장 Dynamic KL 변환을 이용한 분류

다중 분광대를 통하여 관측되는 영상 자료는 분광대 별로 독특한 특징을 나타내지만, 인접한 분광대의 영상간에 시각적으로 서로 유사하게 보이는 특성도 동시에 나타낸다. 분광대간에 유사성이 나타나는 이유는 두 영상이 서로 상관되어 있기 때문이다. 이러한 두 영상간에 상관성을 가지는 이유는 다음과 같다.

- 자연현상 자체가 분광적으로 상관성을 가지고 있다. 즉, 가시광선에서 관측된 분광대의 영상은 식생에 의한 반사율이 대체로 낮고 근적외성의 분광대 영상은 식생에 의한 반사율이 높은 것처럼 자연현상 자체가 상관성을 가지고 있다.

- 지형의 경사각 크기와 경사방향에 의해서 상관성이 나타난다. 즉, 태양에 의한 그림자 효과는 전체 분광대에 거의 같은 정도로 영향을 미치므로 산학지형에서는 그림자 효과로 인하여 영상간의 상관성이 높아진다.

- 인접한 분광대간에 관측기기의 분광학적 중복이 일어난다. 대부분의 관측기가 분광학적 중복이 일어나지 않도록 설계되지만, 실제적인 면에서 관측기가 인접 분광데에 대하여 중복이 전혀 없도록 하는 것은 불가능하다.

따라서 관측된 원래의 다중 분광 영상은 실제 영상 전체가 가진 정보에 의해 표시될 수 있는 채널 수에 비하여 불필요한 여분의 채널 수를 가지고 있게 된다. 다중 분광 영상이 가진 여분의 채널 수를 줄여서 정보를 집약하고 불필요한 채널을 제거하기 위한 처리로서 KL 변환등이 사용된다. 본 연구에서는 SPOT, Landsat등의 위성데이터의 대역별 상관관계를 분석하고, 분석된 결과를 통한 각 위성데이터의 대역 축소를 위한 최적 KL변환을 제안하고자 한다. 또한 Ohta의 방법을 다중대역에 적용하는 방법으로 확장하고자 한다.

5.1 Ohta의 방법

일본의 Ohata등은 칼라 영상에 대한 구역 분할 선형속성을 개발하기 위해서 Dynamic KL변환 기법을 이용한바 있다. 그 과정은 관심 구역들의 다중대역 데이터에 대한 변환을 수행하고 각각의 변환속성에 대한 히스토그램을 얻어내고 두드러진 구역분할을 제공하는 변환벡터들의 통계치를 구하여 두드러진 변환벡터를 찾는 방법으로 그림5.1과 같은 과정으로 진행된다. 그림 5.1의 과정은 다음과 같은 절차를 갖는다.

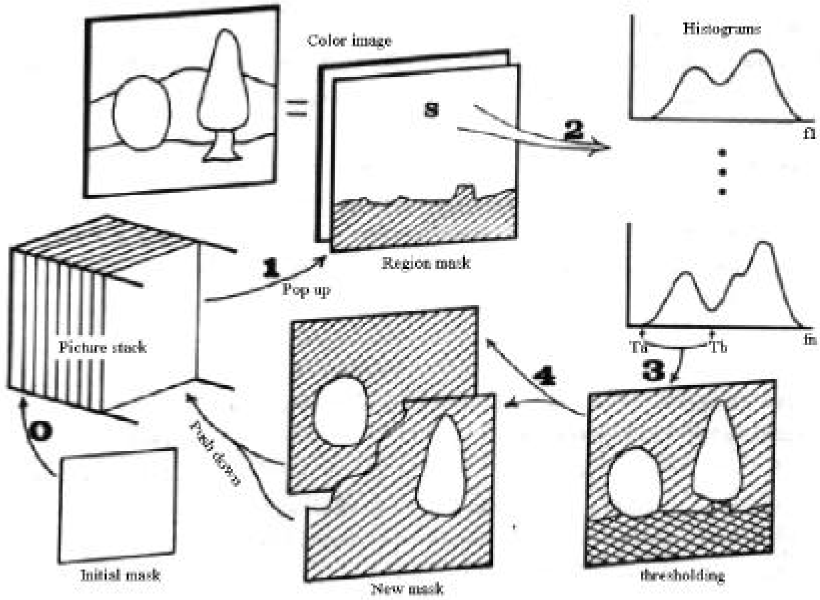

그림 5.1 Dynamic KL변환의 과정

Dynamic KL 변환의 과정

절차 1 : 초기 Picture Stack에는 영상전체를 포함하는 mask 영상을 Push

절차 2 : Picture Stack이 비어 있으면 절차 10, 아니면 mask 영상을 Pop

절차 3 : 원 영상과의 Mask후 이를 KL 변환

절차 4 : KL 변환후의 변환영역에서의 스칼라 영상의 히스토그램 획득

절차 5 : 각 변환 계수의 히스토그램에서 두드러진 피크를 제공하는 속성 발견

절차 6 : 절차 5의 속성을 기록하고 이를 이용하여 thresholding

절차 7 : 절차 6의 분리된 영역을 이용하여 mask 형성

절차 8 : 절차 7의 과정에서 얻어진 영역의 Picture Stack에 Push

절차 9 : 절차 2부터 반복

절차 10 : 기록된 변환 계수의 통계적 특성 조사

그림 5.1에서 0은 절차 1, 1은 절차 2의 과정을 나타내며, 2는 절차 3과 4를 포함하고, 3은 절차 4, 5, 6을 표현하고, 4는 절차 7을 표현하고 있다. Ohta는 위의 알고리즘을 칼라 영상에 적용하여 새로운 변환 커널을 제안하였고, 이를 칼라 영상의 분할에 적용하여 양호한 결과를 얻어내었다.

5.2 다중대역으로 확장된 Dynamic KL 변환

본 연구에서는 Ohta의 방법을 다중 대역에 적용하는 방법으로 확장하는 방법을 제시하고자 한다. 그림 5.2는 이 과정의 블록 다이어그램을 나타내었다.

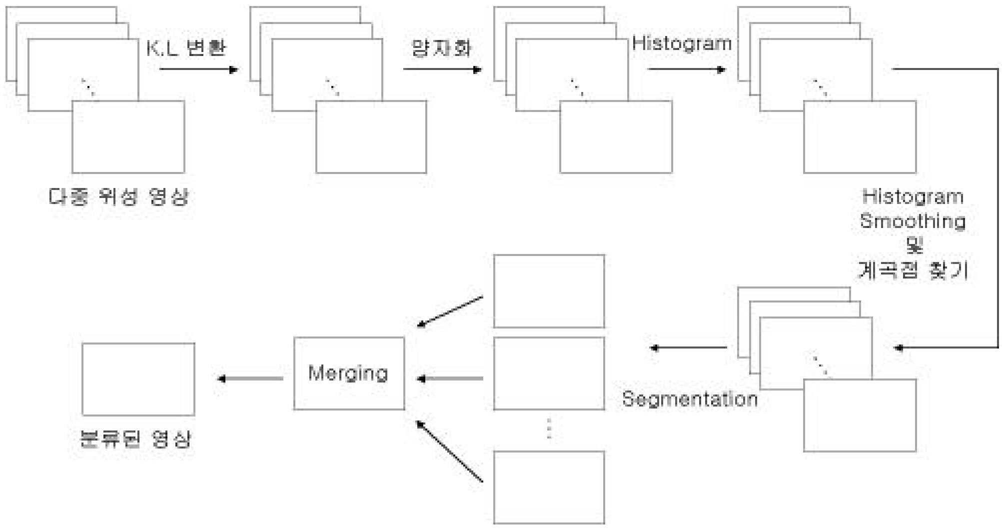

그림 5.2 다중대역으로 확장된 Dynamic KL 변환 분류

제안된 Dynamic KL 변환의 과정

절차 1 : 다중대역 위성데이터를 KL변환
절차 2 : KL변환된 영상을 양자화(0~255)
절차 3 : 양자화된 영상의 히스토그램 획득
절차 4 : 획득된 히스토그램을 Smoothing
절차 5 : Smoothing 된 히스토그램을 이용하여 두드러진 영역 발견
절차 6 : 발견된 영역을 이용하여 영상 분류
절차 7 : 분류된 영상을 Merging

그림 5.3은 그림 5-5의 SPOT-1 영상을 사용하여 위에서 기술한 방법의 예를 보였다. (a)는 절차 3을 나타냈으며, (b)는 절차 4와 5를 보이고 있다. 그림 5.3의 (b-1)에서는 23과 129, (b-2)에서는 98, (b-3)에서는 14를 찾을 수 있다. 절차 6은 절차 5에서 구한 값을 이용하여 각 밴드의 영상을 분류하고 절차 7에서는 분류된 각 밴드의 영상을 Merging 하면 그림5.4와 같은 결과를 얻을 수 있다.

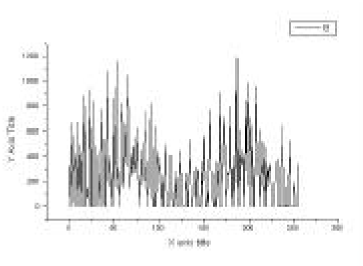

(a- 1)

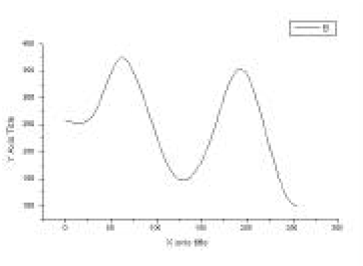

(b- 1)

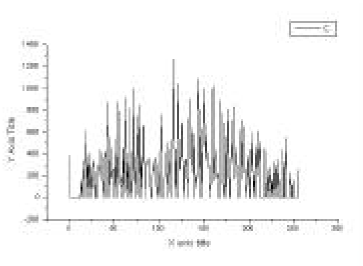

(a- 2)

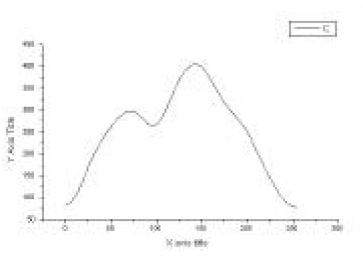

(b- 2)

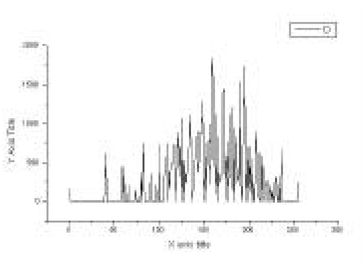

(a- 3)

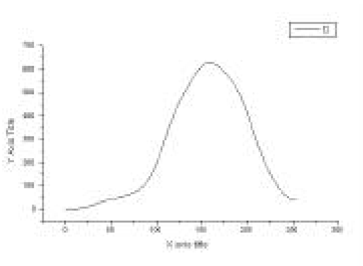

(b- 3)

그림 5.3 KL**변환된 영상의 히스토그램과** smoothing(SPOT- 1)

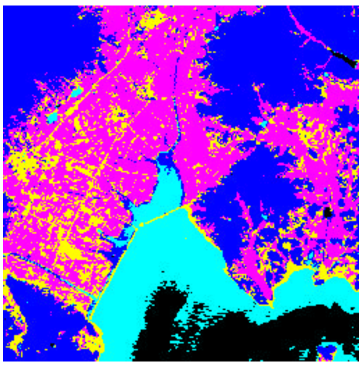

그림 5.4 **제안한 방법을 이용한 분류 결과**(SPOT- 1)

5.3 실험 및 고찰

5.3.1 SPOT 영상을 이용한 실험

본 연구에서는 제안한 방법의 성능을 평가하기 위하여 5개의 256x 256 크기의 SPOT 영상을 이용하였다. 실험을 통해 얻어진 결과를 이용하여 위성데이터의 대역별 상관관계를 분석하고, 분석된 결과를 통한 각 위성데이터의 대역 축소를 위한 최적 KL변환을 찾아 보았으며, 또한 제안된 Dynamic KL 변환을 이용한 분류 방법의 성능도 평가하였다. 그림 5.5의 위성영상은 밴드 1, 2, 3을 각각 Red, Green, Blue로 합성한 영상을 나타내었다. 표 5는 그림 5.5의 위성영상의 공분산 행렬(Covariance Matrix)로써 각 밴드 사이의 상관 관계를 나타내었다. 표 6와 7은 그림 5.5 영상의 고유값과 고유 벡터이다. 이 표들에서 알 수 있듯이 각 밴드사이에는 많은 상관관계가 있지만 표 8의 Ohta의 실험처럼 일관된 관계를 찾을 수 없었다. Ohta는 표 8을 이용하여 다음과 같은 변화커널을 정의하였다.

$$I_1 = (R + G + B)/3$$

$$I_2 = (R - B)/2 \ or \ (B - R)/2$$

$$I_3 = (2G - R - B)/4$$

따라서 향후에는 압축을 위한 변환 커널 구성은 추후 더 다양한 데이터를 이용하여 실험되고 연구되어야 할 것이다.

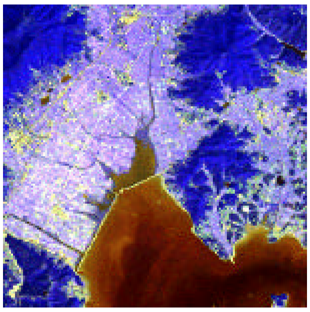

(a) SPOT-1

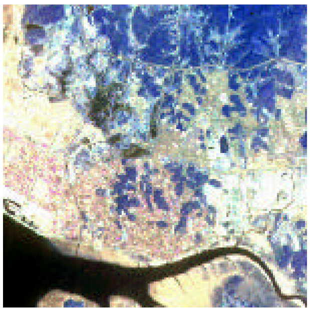

(b) SPOT-2

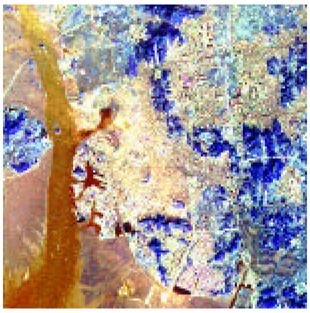

(c) SPOT-3

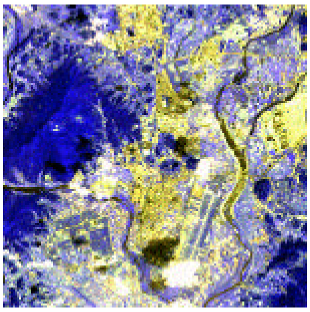

(d) SPOT-4

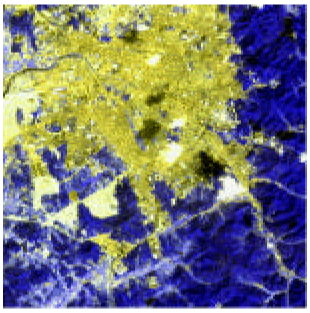

(e) SPOT-5

그림 5.5 Dynamic KL**변환에 사용된** SPOT **영상**

표 5. SPOT 영상의 Covariance Matrix

위성영상	Covariance Matrix
SPOT-1	4866.14746 4802.68520 2313.05148 4802.68520 5671.68613 3760.66006 2313.05148 3760.66006 7683.54018
SPOT-2	6108.63582 5363.88239 3456.21836 5363.88239 5239.04692 3634.76742 3456.21836 3634.76742 3729.31362
SPOT-3	4303.68965 3589.18187 1073.58133 3589.18187 4646.66119 2647.86566 1073.58133 2647.86566 4267.85834
SPOT-4	6060.27015 5909.87762 1373.43997 5909.87762 5930.22710 1322.21414 1373.43997 1322.21414 3178.01201
SPOT-5	6059.07428 6227.26829 175.19189 6227.26829 6475.43736 277.94705 175.19189 277.94705 3057.74068

표 6. SPOT 영상의 Eigen Value

위성영상	Eigen values
SPOT-1	13403.71812 4498.89420 318.76145
SPOT-2	13596.10940 1277.35505 203.53192
SPOT-3	9462.29938 3262.02007 493.88973
SPOT-4	12303.69487 2780.03883 84.77556
SPOT-5	12508.94570 3048.30025 35.00637

표 7. SPOT 영상의 Eigen Vector

위성영상	eigen vector			normalized eigen vector		
SPOT-1	0.50814	-0.52877	0.67985	0.29438	-0.32170	0.43865
	0.61091	-0.33513	-0.71727	0.35391	-0.20389	-0.46280
	0.60711	0.77980	0.15274	0.35171	0.47442	0.09855
SPOT-2	0.64786	-0.51421	-0.56202	0.37816	-0.35361	-0.34985
	0.61269	-0.08666	0.78556	0.35763	-0.05960	0.48899
	0.45264	0.85328	-0.25891	0.26421	0.58679	-0.16116
SPOT-3	0.56900	-0.57215	0.59066	0.33239	-0.39009	0.35483
	0.67909	-0.07815	-0.72989	0.39670	-0.05328	-0.43847
	0.46377	0.81642	0.34407	0.27091	0.55663	0.20670
SPOT-4	0.69627	-0.13881	-0.70423	0.43824	-0.10946	-0.49476
	0.68804	-0.15043	0.70991	0.43306	-0.11863	0.49875
	0.20448	0.97883	0.00924	0.12870	0.77191	0.00649
SPOT-5	0.69466	-0.03969	0.71824	0.48000	-0.03788	0.50017
	0.71853	-0.00892	-0.69543	0.49650	-0.00852	-0.48429
	0.03401	0.99917	0.02232	0.02350	0.95361	0.01554

표 8. Ohta의 Eigenvector

RGB영상	wR1	wG1	wB1	wR2	wG2	wB2	wR3	wG3	wB3
Cylinder	0.269	0.363	0.367	0.469	0.095	-0.437	-0.308	0.461	-0.231
Building	0.269	0.340	0.391	0.479	0.103	-0.418	-0.296	0.485	-0.219
Seaside	0.258	0.380	0.362	-0.585	0.056	0.358	-0.176	0.464	-0.360
Girl	0.336	0.354	0.309	-0.493	0.193	0.314	-0.094	0.474	-0.436
Room	0.193	0.341	0.467	0.612	0.079	-0.310	-0.209	0.507	-0.284
Home	0.197	0.328	0.476	0.492	0.180	-0.318	-0.313	0.484	-0.204
Auto	0.304	0.317	0.378	0.239	0.309	-0.452	-0.514	0.450	0.036
Face	0.175	0.411	0.414	0.523	0.128	-0.349	-0.295	0.416	-0.289

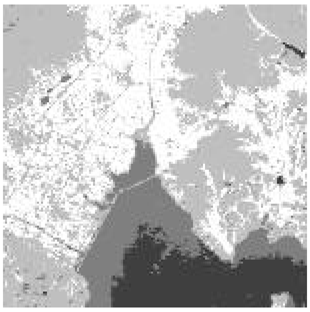

(a) SPOT-1

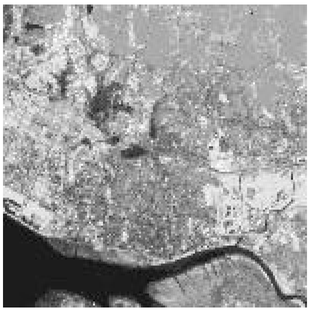

(b) SPOT-2

(c) SPOT-3

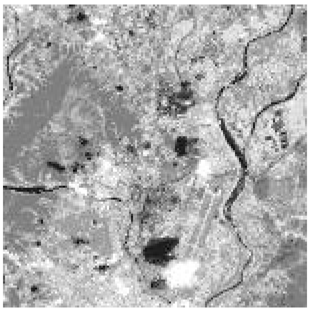

(d) SPOT-4

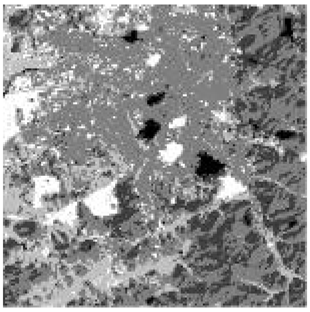

(e) SPOT-5

그림 5.6 **그림** 5.5 **의 분류 결과**

5.3.2 Landsat 영상을 이용한 실험

2개의 512 x 512 크기의 Landsat영상을 이용하여 SPOT 영상과 똑같은 실험을 수행하였다. 그림 5.7은 Landsat 영상의 7 밴드중 6 밴드를 제외한 6개의 영상을 나타내었다. 그림 5.7은 실험에 사용된 6개의 Landsat-2 영상 중 첫 번째 밴드의 영상을 보여 주고 있다. Landsat 영상의 공분산 행렬을 나타내는 표 8에서도 SPOT 영상과 마찬가지로 각 밴드 사이에는 많은 상관 관계가 있으나 공통된 관계를 찾을 수 없었다. 그림 5.8, 5.9, 5.10은 각 밴드의 히스토그램을 나타내고 있으며, 그림 5.11은 이를 이용하여 분류한 결과이다. 시각적으로는 성공적으로 구역분할이 수행됨을 알 수 있으나, 이는 순수한 속성공간에서의 세그멘테이션이기 때문에 과구역화(oversegmentati-on)현상이 나타나고 있다. 향후 공간영역에서의 인접한 구역의 확장 등의 알고리즘을 보완할 필요가 있다.

표 9. Landsat 영상의 Covariance matrix

위성영상	Covariance matrix					
Landsat-1	102.72869	60.97401	142.49942	-39.83434	52.47755	93.38970
	60.97401	40.29620	96.31617	-9.13828	53.15751	67.64375
	142.49942	96.31617	243.24302	6.44907	175.04691	184.12396
	-39.83434	-9.13828	6.44907	534.53564	720.68909	241.67865
	52.47755	53.15751	175.04691	720.68909	1754.47552	668.12989
	93.38970	67.64375	184.12396	241.67865	668.12989	508.33876
Landsat-2	82.35275	30.35067	51.05922	40.73788	149.00318	79.02383
	30.35067	40.15176	50.30067	62.55291	183.72075	97.34251
	51.05922	50.30067	245.93191	154.94927	338.58157	188.24006
	40.73788	62.55291	154.94927	668.83763	885.74093	386.24609
	149.00318	183.72075	338.58157	885.74093	1903.99404	904.51936
	79.02383	97.34251	188.24006	386.24609	904.51936	518.05077

표 10. Landsat 영상의 Eigen vector

위성영상	normalized eigen vector					
Landsat-1	0.02000	0.17972	0.01944	0.13785	0.54703	-0.15692
	0.01899	0.11128	0.03271	0.09512	0.03687	0.66317
	0.05983	0.26549	0.10142	0.23362	-0.35299	-0.17418
	0.21380	-0.19307	0.41399	0.11186	0.05206	-0.00182
	0.48121	-0.04647	-0.26877	0.06468	-0.00571	0.00200
	0.20618	0.20395	0.16367	-0.35686	0.00533	0.00191
Landsat-2	0.03339	0.10431	0.05013	-0.45110	0.23319	-0.15030
	0.04092	0.07349	0.01630	-0.08841	0.03930	0.67982
	0.08300	0.17070	0.52447	0.04796	-0.09551	-0.04151
	0.21287	-0.40794	0.17943	-0.00597	0.11621	0.04270
	0.42373	0.07346	-0.16878	-0.10768	-0.21039	-0.04958
	0.20609	0.17010	-0.06089	0.29889	0.30542	-0.03609

(a) band 1

(b) band 2

(c) band 3

(d) band 4

(e) band 5

(f) band 7

그림 5.7 **실험에 사용된** Landsat-1 **영상**

그림 5.8 **실험에 사용된** Landsat-2**의** band 1 **영상**

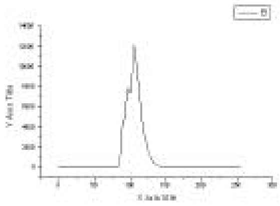

(a) band 1

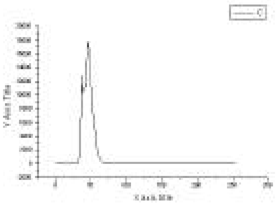

(b) band 2

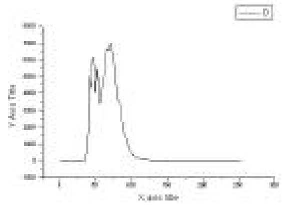

(c) band 3

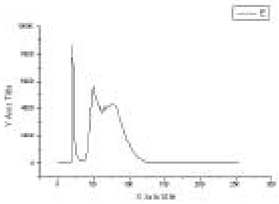

(d) band 4

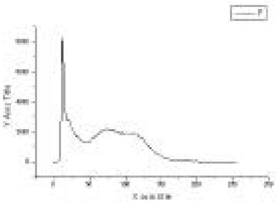

(e) band 5

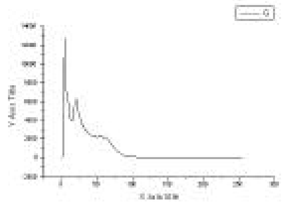

(f) band 7

그림 5.9 Landsat-2 **영상의 히스토그램**(KL**변환 전**)

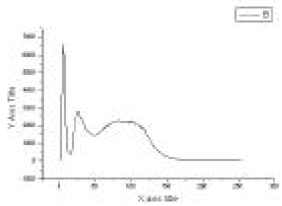

(a) band 1

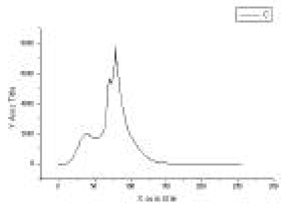

(b) band 2

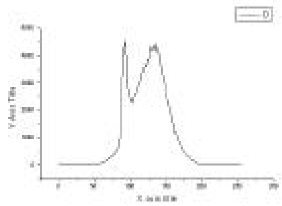

(c) band 3

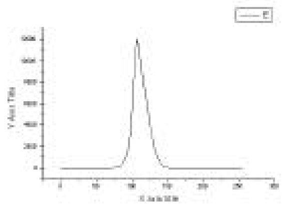

(d) band 4

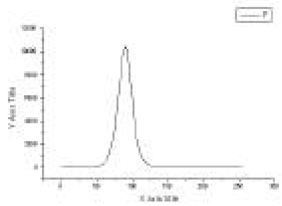

(e) band 5

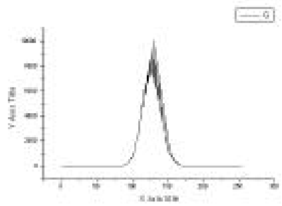

(f) band 7

그림 5.10 Landsat-2 **영상의 히스토그램**(KL**변환 후**)

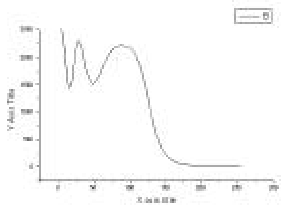

(a) band 1

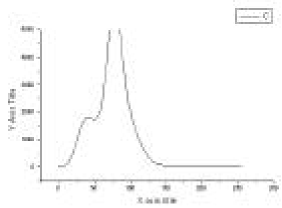

(b) band 2

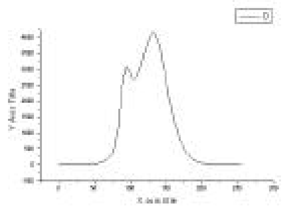

(c) band 3

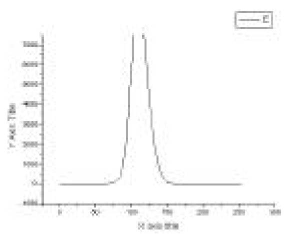

(d) band 4

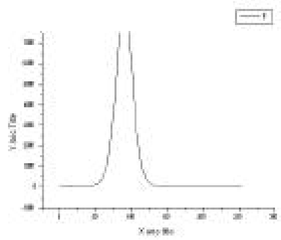

(e) band 5

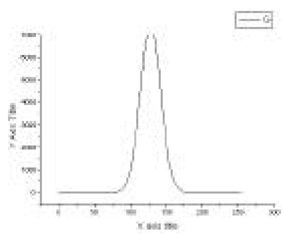

(f) band 7

그림 5.11 **히스토그램** Smoothing **결과**

(a) Landsat-1　　　　(b) Landsat-2

그림 5.12 **제안된 알고리즘을 이용한 분류 결과**

제 6 장 통합 프로그래밍 환경

본 연구에서 제안한 위성 전파 신호 처리 알고리즘을 Visual C++를 이용하여 PC환경에서 위성처리프로그램을 개발하고 데이터 처리 및 분석을 위한 통합 환경을 구축하였다. 또한 윈도즈 환경이상에서 시뮬레이션 알고리즘이 이용 가능하도록 사용자 인터페이스 개발을 하였다. 본 연구에서 구현된 위성 전파 신호처리 시스템은 사용자가 손쉽게 사용 할 수 있도록 하기 위해 편리한 사용자 인터페이스를 제공하고 있다.

6.1 프로그램 개발 환경

본 연구에서 개발된 위성전파 시스템의 개발 환경은 다음과 같다.

. 기종	: IBM PC호환 기종
. CPU	: Pentium II 330
. RAM	: 64MB
. HDD	: 8GB
. VIDEO CARD	: Graphic Blaster 4M SGRAM PCI
. 개발 언어	: Visual C++ 6.0
. OS	: MS-Windows95/98

6.2 윈도우즈 기반 프로그래밍 구성 모듈

본 프로그램은

- 위성 영상 입출력 모듈
- Dynamic KL변환 모듈
- 비선형 잡음발생기 및 제거기법 모듈

로 구성되어있다. 이러한 모듈들은 자체적으로 확장가능하고 추가 모듈을 쉽게 확장하여 활용할 수 있다.

6.2.1 위성 영상 입출력 모듈

다음 그림은 입력 영상의 종류와 크기를 정하는 대화 상자이다.

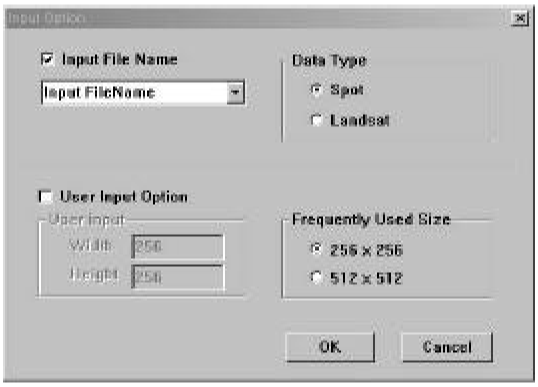

그림 6.1 위성 영상 입출력 대화 상자

다음 그림은 영상을 입력한 화면이다.

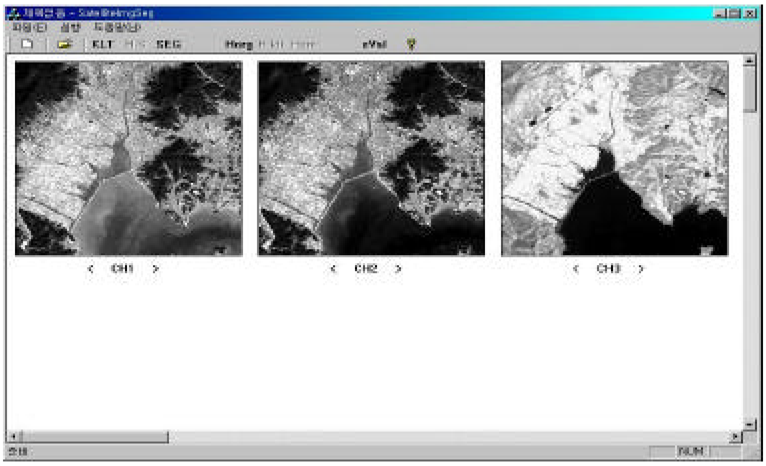

그림 6.2 입력된 위성 영상

6.2.2 구역 분할 관점의 Dynamic KL변환 분류 모듈

* 프로그램 메뉴

- KL변환 메뉴
- 양자화 메뉴
- 히스토그램 출력 메뉴
- 히스토그램 Smoothing 메뉴
- Segmentation 메뉴

다음 그림은 선택된 밴드 영상의 히스토그램을 나타낸 그림이다.

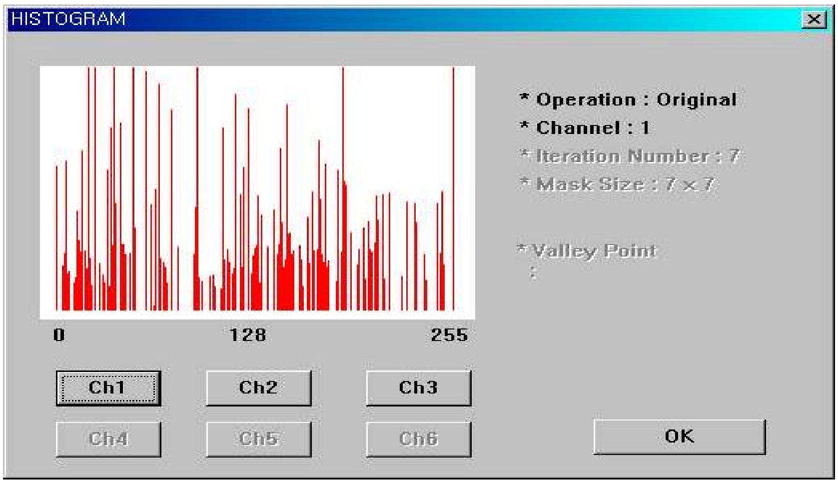

그림 6.3 선택된 밴드의 히스토그램

다음 영상은 선택된 히스토그램을 Smoothing 한 것이다.

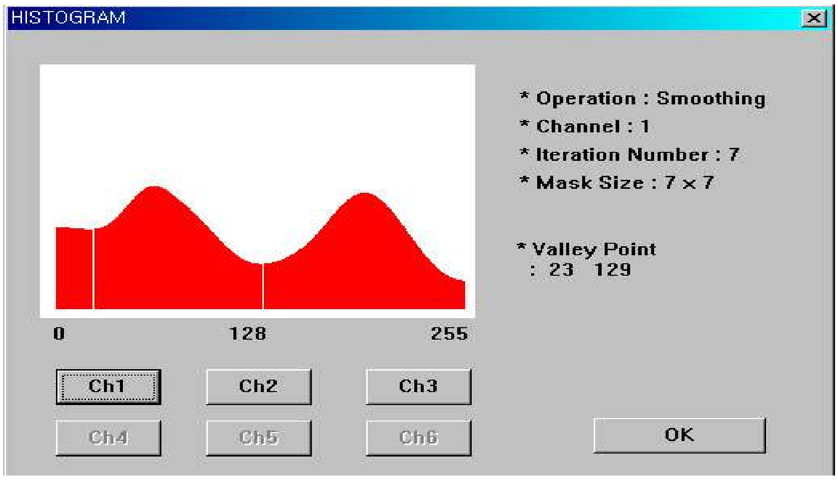

그림 6.4 히스토그램 Smoothing

다음 그림은 히스토그램을 Smoothing하여 얻은 계곡점을 이용하여 영상을 분류한 것이다.

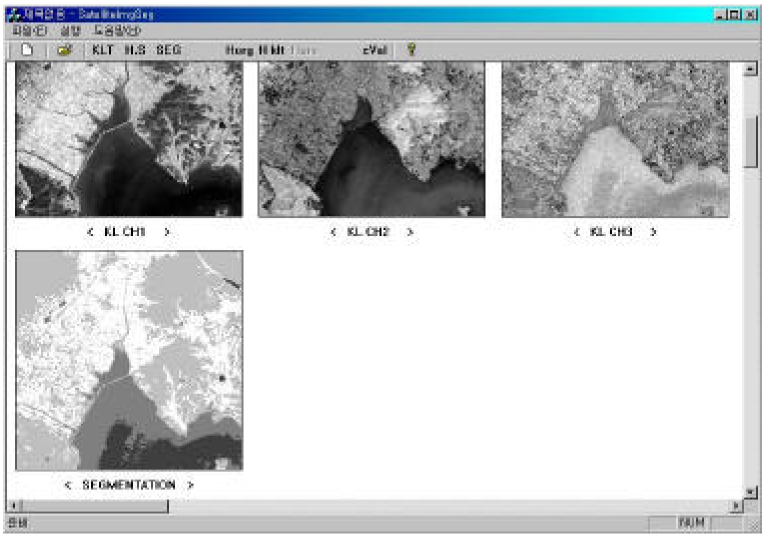

그림 6.5 제안한 방법으로 분류된 영상

다음 그림은 Landsat 영상을 입력하여 KL변환한 후 제안한 분류 방법으로 분류한 결과를 나타내었다.

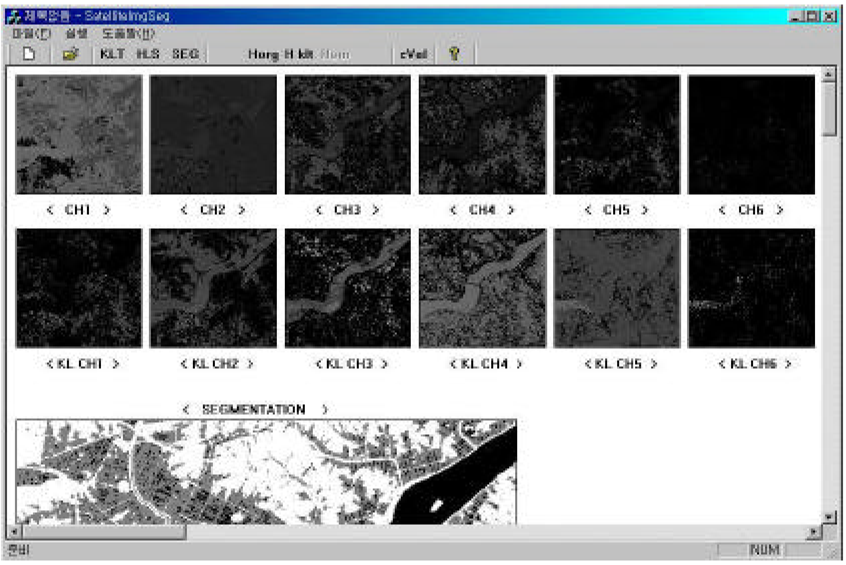

그림 6.6 Landsat 영상을 이용한 분류

6.2.3 비선형 잡음 발생기 및 제거 기법 모듈

프로그램 메뉴

* **필터의 종류**
  - VMF(Vector Median Filter)
  - GVDF(Generalized Vector Median Filter)
  - FCF(Fuzzy C-Mean Filter)
  - Vector α-trimmed Average Filter
  - Weighted Vector α-trimmed Average Filter

* Performance **평가**
  - NMSE(Normalized Mean Square Error)

다음은 잡음이 있는 영상을 입력한 그림이다.

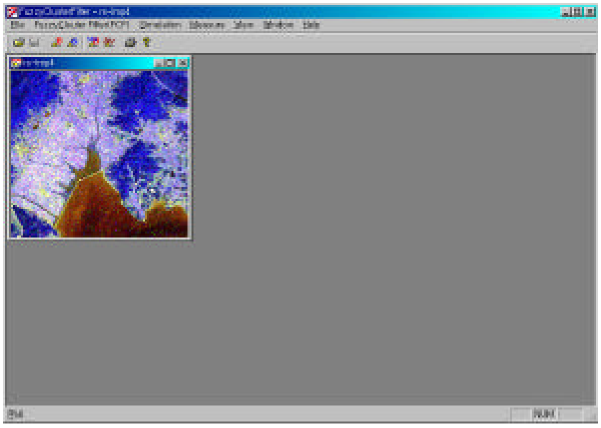

그림 6.7 잡음이 있는 영상 입력

다음 그림은 어떤 필터를 구동하여 잡음을 제거 할 것인가를 선택하는 대화 상자이다.

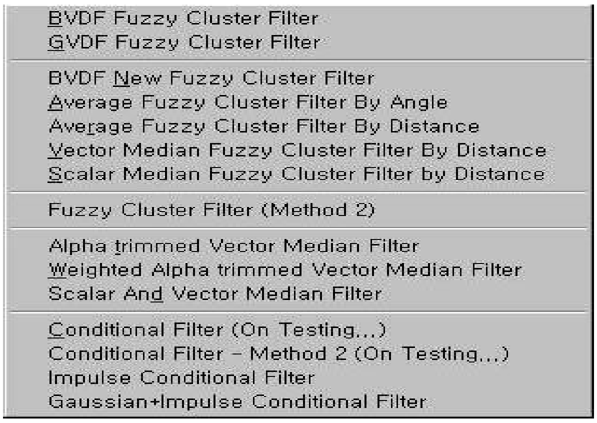

그림 6.8 필터의 종류를 선택하는 대화 상자

다음 그림은 선택된 필터의 파라메터를 정하는 대화상자를 나타내었다.

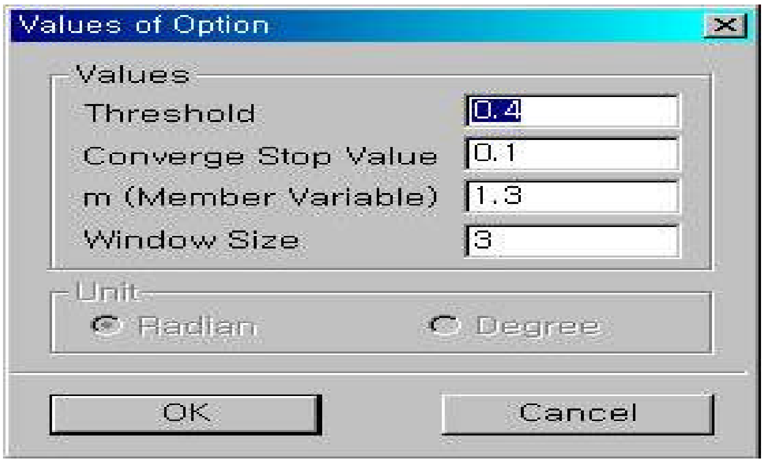

그림 6.9 선택된 필터의 파라미터를 정하는 대화상자

다음은 잡음이 제거된 영상을 보여 주는 그림이다.

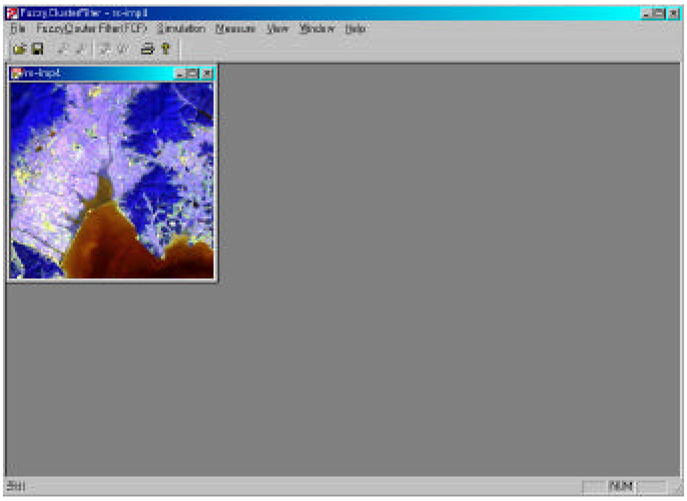

그림 6.10 잡음이 제거된 영상

제 7 장 결론

위성전파 이용기술은 인공위성으로부터 전송되는 위성전파 신호를 수신, 처리, 분석하여 여러 응용분야에 효과적으로 활용하는 기술로서, 특히 인공 위성을 이용한 지구관측 정보는 환경, 농업, 지질, 해양, 군사 등 광범위한 분야에 활용되고 있으며 최근 새로운 응용기술의 발달로 그 활용범위가 날로 확대되고 있다. 최근 센서의 발달로 인하여 센서의 종류도 다양해 졌으며, 획득되고 전송되는 데이터 양도 방대해짐에 따라 위성에서 전송되는 위성전파를 수신하여 필요한 정보를 추출하고 활용하기 위해서는 위성전파를 수신하여 필요한 정보를 추출하고 활용하기 위해서는 위성전파 처리 및 분석기술 개발에 관한 연구가 지속적으로 수행되어야한다. 특히 정보기술을 기반으로 하는 GIS 시스템의 구축은 지속적으로 위성데이터를 필요로 할 것이다. 이와 같이 유용성이 많은 위성영상 데이터를 다양한 분야에 효과적으로 적용하고 활용하기 위해서는 이용분야에 적합한 영상처리 및 분석과정이 선행되어야 하며 그 동안 많은 연구와 기술 개발이 이루어져 왔으나 국내연구의 경우 기존 알고리즘의 활용으로 시스템개발 측면이 강조되어 고급요소 기술의 개발이 소외되는 경향이 있다.

따라서 본 연구에서 위성에서 전송되는 관측데이터를 이용하여 지상에 분포된 지형 지물 등을 식별하고 분석하여 다양한 정보를 취득하는 과정인 위성영상 분류에 효과적으로 적용시킬 수 있는 위성데이터의 전처리를 위한 요소 기술 연구를 수행하였다. 본 연구의 추진방향 세가지로 다음과 같다.

- 다 채널 잡음 모델링 및 잡음 발생기의 구현 과 비선형 잡음제거 기법 연구
- 위성데이터의 질감 속성 연구
- 구역 분할 관점의 Dynamic KL 변환 연구

다 채널 잡음 모델링 및 잡음 발생기의 구현 과 비선형 잡음제거 기법 연구에서는 다 채널 잡음이 발생한 영상에서 제안한 필터의 성능을 평가하기 위해 다 채널 잡음 발생기를 구성하였으며, 이러한 환경 하에서 제안된 필터의 성능을 기존의 필터들과 그 결과를 비교 검토하였다. 실험 결과 NMSE(Normalized Mean Squared Error)관점에서 볼 때, 제안된 필터중에서, 임펄스 잡음에서나 가우시안 잡음이 있는 실험 영상에서 가중화된 벡터 α-trimmed 평균 필터가 가장 우수한 결과를 얻었다.

위성 데이터의 질감 속성 연구에서는 그레이 영상의 통계적 성질을 표현하는 SGLDM, NSGLDM, GLRLM 등을 다 채널 위성 영상으로 확장하여 SVDM, NSVDM, VRLM 등의 속성을 정의하였고, 이들 행렬 및 벡터속성들의 상호관계를 규명하였으며, 이들 행렬로부터 채널 히스토그램과 영상의 질감 속성에 해당하는 속성정보를 동시에 추출하는 방법을 제안하였다. 제안된 6개의 벡터 속성들의 분류성능 측정은 신경망을 이용한 분류기와 SPOT 위성으로부터 관측된 전남 보성만 지역의 영상을 사용하였으며, 분류 클래스를 산림, 수역, 농경지 등 세 종류로 정하고 실험을 수행한 결과, 위성 영상의 질감을 표현하는 VRLM_M 속성 벡터, 그리고 채널 히스토그램 분포와 관련된 NSVDM_R (VRLM_W)들이 가장 우수한 분별력을 나타내었으며, 같은 벡터 값을 가지는 영역을 하나로 간주하여 계수한 VRLM_R, 벡터쌍의 공간적 상관관계를 표현하는 NSVDM_W 등도 대체적으로 우수

한 결과를 얻을 수 있었다. 6개의 벡터 속성 중 임의의 벡터와 이웃하는 화소 중 같은 벡터의 평균 화소 수를 나타내는 NSVDM_M이 비교적 저조한 결과를 나타냈으나, 전반적으로 벡터 속성들을 위성영상 분류에 이용한 경우 좋은 분별력을 얻을 수 있음을 확인하였다.

따라서 본 연구에서 사용된 6개의 벡터 속성들은 채널과 질감 속성을 동시에 반영하고 있고, 실험 결과로 나타난 분별력도 우수한 상태이므로 향후 위성영상 분석에 보다 유용하게 사용될 수 있도록 본 연구의 추후 과제로 적응양자화 및 위성영상의 유사성 측도, 분류 정확도 향상 및 평가 등의 관점에서 보완연구를 수행할 계획이다.

구역 분할 관점의 Dynamic KL 변환 연구에서는 SPOT, Landsat 등의 위성데이터의 상관관계를 분석하고, 분석된 결과를 통한 각 위성데이터의 대역 축소를 위한 최적 KL변환 커널을 제안하는 연구를 수행하였다. 일본의 Ohta 등이 칼라 영상에 대한 구역 분할 선형 속성을 개발하기 위하여 이용한 Dynamic KL 변환 기법을 다중 대역에 적용하였다. 다중 대역 위성영상에 적용하여 실험한 결과 위성 영상은 각각의 밴드 사이에는 많은 상관관계가 있지만 Ohta의 실험에서처럼 일관된 관계를 찾을 수 없었다. 앞으로, 압축을 위한 변환 커널 구성은 추후에 더 다양한 데이터를 이용하여 실험되고 연구되어야 할 것이다. 다 채널 위성 영상을 구역 분할 관점의 Dynamic KL 변환 분류 실험에서는 시각적으로 양호한 구역분할이 수행됨을 알 수 있으나 이는 순수한 속성공간에서의 세그맨테이션이기 때문에 과구역화 (oversegmentation) 현상이 나타났다. 향후 공간 영역에서의 인접한 구역의 확장등의 알고리즘을 보완 할 필요가 요구되었다.

통합 소프트웨어 개발에서는 Visual C++을 이용하여 시뮬레이션

프로그램을 개발하였으며 수집된 위성데이터를 이용하여 알고리즘의 성능을 평가하였다. 또한 윈도우즈 95/98 **환경 이상에서 시뮬레이션 알고리즘이 가능하도록 사용자 인터페이스도 개발하였다.**

본 연구의 향후 과제는 위성전파를 여러 응용 분야에 활용하기 위하여 개선된 알고리즘과 소프트웨어를 이용하여 관련분야 이용자가 손쉽게 위성신호를 이용할 수 있도록 온라인 처리 및 분석시스템을 구현하는 것이다.

참 고 문 헌

[1] " **위성 전파 이용 기술의 현황과 대책** " , **전파연구소**, 1993

[2] P. M. Mather, "*Computer Processing of Remotely-Sensed Images*", John Wiley & Sons, 1987

[3] J. A. Richards, "*Remote Sensing Digital Image Analysis*", SpringVerlag, 1994

[4] R. A. Schowengerdt, "*Remote Sensing Models and Methods for Image Processing*", Academic Press, 1997

[5] I. Pitas and A. Venetsanopoulos, *Nonlinear Digital Filters: Principles and Applications*, Boston, MA:Kluwer, 1990.

[6] Y. I. Ohta and et al., "Color Information for Region Segmentation", *Computer Graphics and Image Processing* 13, pp. 222-241, 1980

[7] P. E. Trahanias and A. Venetsanopoulos, "Multichannel image processing using vector angle ranking," *SPIE Nonlinear Image Processing* ***IV***, vol. 1902, pp. 116-127, 1993.

[8] R. Krishnapuram and J. M. Keller, "A possibilistic approach to clustering," *IEEE Trans. on Fuzzy systems*, vol. 1, no. 2, pp. 98-110, 1993.

[9] N. C. Gallagher Jr., G. L. Wise, "A Theoretical Analysis of the Median Filters," *IEEE Trans. Acoustics, Speech and Signal Process.*, vol. 29, no. 6, pp. 1136-1141, Dec. 1981.

[10] E. Ataman, V. K. Aatre, K. M. Wong, "Some Statistical Properties of Median Filters," *IEEE Trans acoustics, Speech and Signal process.*, vol. ASSP-29, pp. 1073-1075, Oct. 1981.

[11] V. Barnett, "The Ordering of Multivariate Data", *J. R. Statistical Society A*, vol. 139, Part 3, pp. 318-343, 1976.

[12] J. C. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum, New York, 1981.

[13] C. A. Pomalaza-Raez and Y. Fong, "Estimation of the location parameter of a multispectral distribution by a median operation," *in Proc. 11th Int. Symp. on Machine Processing of Remotely Sensed Data, West Lafayette*, IN, pp. 41-48, 1985

[14] R. Krishnapuram, H. Frigui and O. Nasraoui, "Fuzzy and Possiblistic shell Clustering algrithms and their application to boundary detection and surface approximation," *IEEE Trans. on Fuzzy Systems.*, vol. 3, no. 1, pp. 29-60, Feb, 1995.

[15] R. O. Duda and P. E. Hart, *Pattern Classification and Scene Analysis*, New York: Wiley, 1973.

[16] P. P. Ohanian and R. C. Dubes, "Performance Evaluation for Four Classes of Textural Features," *Pattern Recognition*, vol. 25, No. 8, pp. 819-833, 1992

[17] R. M. Haralick, "Statistical and Structural Approaches to Texture," *Proceedings of IEEE*, vol. 67, No. 5 pp. 786-804, 1979.

[18] L. V. Gool,et al., "Texture Analysis Anno. 1983," *CVGIP*, vol. 29, pp. 336-357, 1985

[19] C. Sun and W.G. Wee, "Neighboring Gray Level Dependence Matrix," *CVGIP*, vol. 23, pp. 341-345, 1982

[20] M. M Galloway, "Texture Analysis Using Gray Level Run Lengths," *CVGIP*, vol. 4, pp. 172-179, 1975

[21] **김준철**, **이준환**,"**행렬 속성을 이용하는 질감 영상 분별기**," **한국전자공학회 논문집**. 31**권** B**편 제** 3**호** pp. 91-102, 1994

[22] J. Huang, et al., "Image Indexing Using Color Correlograms," *IEEE Int. Conf. on CVPR* pp. 762-768, 1997

[23] J. R. Smith and S. F. Chang, "Local Color and Texture Extraction and Spatial Query," *IEEE Int. Conf. on Image Processing*, pp. 1101-1014, 1996

[24] M. P. Dubuisson-Jolly and A. Gupta, "Color and Texture Fusion : Application to Aerial Image Segmentation and GIS Updating," *Proc. of the Workshop on Applications of Computer Vision*, pp. 2-7, 1996

[25] G. Pass and R. Zabih, "Histogram Refinement for Content-Based Image Retrieval," *IEEE Workshop on Applications of Computer Vision*, pp. 96-100, 1996

[26] J. R. Smith and S. F. Chang, "Tools and techniques for color images Retrieval," *In Symposium on Electric Imaging: Science and Technology- Storage & retrieval for Image and Viedo Database IV*, vol. 2670, San Jose, Feb. 1996, IS&T/SPIE