



### 저작자표시-동일조건변경허락 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.
- 이차적 저작물을 작성할 수 있습니다.
- 이 저작물을 영리 목적으로 이용할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



**저작자표시**. 귀하는 원저작자를 표시하여야 합니다.



**동일조건변경허락**. 귀하가 이 저작물을 개작, 변형 또는 가공했을 경우에는, 이 저작물과 동일한 이용허락조건하에서만 배포할 수 있습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공 학 석 사 학 위 논 문

유역변환기반의 마커 클러스터링을  
이용한 질감 영상 분할



2007년 2월

부 경 대 학 교 대 학 원

컴 퓨 터 공 학 과

황 진 호

공 학 석 사 학 위 논 문

유역변환기반의 마커 클러스터링을 이용한  
질감 영상 분할

지 도 교 수 송 하 주

이 논문을 공학석사 학위논문으로 제출함

2007년 2월

부 경 대 학 교 대 학 원

컴 퓨 터 공 학 과

황 진 호

# 황진호의 공학석사 학위논문을 인준함

2007년 2월 23일



주 심 공학박사 권 기 룡



위 원 공학박사 신 봉 기



위 원 공학박사 송 하 주



# 목 차

Abstract

I. 서 론 .....	1
II. 관련 연구 .....	5
2.1 클러스터링에 의한 패턴 분류 .....	6
2.1.1 영상 분할을 위한 FCM 클러스터링 .....	6
2.1.2 클러스터링의 분할 오류 .....	7
2.2 가보 웨이블릿을 이용한 질감 분석 .....	8
2.2.1 2차원 가보 필터 .....	9
2.3 유역변환 영상 분할 .....	10
2.3.1 유역변환의 개념 .....	11
2.3.2 영상의 기울기 변환 .....	12
2.3.3 마커-제어 유역변환 .....	13

Ⅲ. 질감 분할 기법의 제안 .....	15
3.1 가보 필터링 .....	17
3.2 마커 선택 .....	18
3.3 마커 클러스터링과 임계치 처리 .....	20
3.4 유역변환과 영역 병합 .....	21
3.5 후처리 .....	22
Ⅳ. 실험 결과 및 분석 .....	24
4.1 실험 환경 .....	24
4.2 단계별 실험 .....	26
4.3 기존의 FCM 연계 알고리즘과의 분할 성능 비교 .....	28
4.4 다른 클러스터링 연계 알고리즘과의 분할 성능 비교 .....	30
4.5 수행 시간 비교 .....	33
Ⅴ. 결    론 .....	35
참 고 문 헌 .....	37

*Textured Image Segmentation*  
*Using Marker Clustering in Watershed Transform*

Jin Ho Hwang

Department of Computer Engineering, The Graduate School,  
Pukyong National University

***Abstract***

Image segmentation which partitions an image into different regions each having certain properties is a principal technology for image analysis in various application fields. The higher level application demands that it partitions more complex textured regions. Generally, the solutions consist of 'Texture measurement-Segmentation method' and the main issue is how to integrate texture having multi-feature. In the point of view, clustering supplies superior segmentation performance without complex processing. But the application is restricted because of its higher computational complexity and typical errors from partition. In this thesis, marker clustering for minimizing them is considered. In marker-controlled watershed transform, it regards a marker as a marking about interest object and a start region for extending single region. Hence it can minimize the complexity with the clustering to only restricted pixels called marker. And it can reduce typical errors from partition because the marker clustering is completed by watershed transform. In proposed method, the markers are taken from Gabor texture energies and are applied to FCM(fuzzy C-means) clustering. The segmentation is completed by merging partitioned regions which were generated from all markers in watershed transform according to cluster membership between markers. In the experimental result with mosaic images mixture from Brodatz'

album, it improved typical partition errors and shows faster speed than previous FCM clustering chains in the comparison of performance time.



# I. 서론

영상 분할은 영상을 영역 단위로 처리하기 위하여 밝기, 색상, 질감 등과 같은 특성에 의해 유사한 영역들로 분리하는 작업이다. 주로 영상을 이용하는 응용에서 객체 분할 또는 추출 등의 전처리 작업으로 활용되며, 다양한 분야에 걸쳐 연구되어왔다[1]. 일반적으로 영상 분할 기술은 특정 응용에 종속적이며, 응용의 수준이 높아질수록 영상 분할 기술도 적용범위가 확대되는데, 영상의 명암도 변화가 크고 객체수가 다양해질수록 기술 연계도 복잡해진다. 이러한 문제는 주로 “질감 측정-분할 기법”의 형태로 접근하며, 질감 측정은 다양한 형태의 질감 특성을 가지기 때문에[2-3], 이러한 특성들을 어떻게 통합하느냐가 원하는 형태의 영상 분할을 얻기 위한 주요 이슈가 된다[4].

클러스터링 기법은 질감의 다양한 특성 영상들을 다차원 정보를 가지는 패턴으로 간주하여 잘 분리된 클러스터를 형성하며, 각 패턴들을 해당 클러스터로 분류한다[5]. 다차원 정보 패턴에 대한 계산이 가능한 거리함수에 기반을 두기 때문에 다른 기법에 비해 우수한 분할 결과를 제공하며, 주로 응용되는 클러스터링 알고리즘으로 k-평균(k-means), FCM, 제곱-에러(square-error) 등이 있다. Jain 등[4]은 다채널 가보 필터(Gabor filter)를 제안하여 제곱-에러 알고리즘으로 질감 분할을 구현하였으며, Tuceryan[6] 역시 모멘트 기반의 질감 분할 기법을 제안하면서 제곱-에러 알고리즘을 사용하였고, Chang 등[5]은 질감 분할 알고리즘들의 성능비교에서 분할 기법으로 FCM 알고리즘과 제곱 에러 알

고리즘을 각각 사용하였다. Clausi 등[7]은 그레이 레벨 동시정보확률(grey level co-occurrence probabilities)과 마코프 랜덤 필드(Markov random fields)의 질감 측정을 성능 평가를 위해 k-평균(k-means) 알고리즘으로 비교하였으며, Clausi 등[8]은 가보 필터와 동시정보확률을 융합한 질감 분석법을 제안하며 역시 k-평균 알고리즘을 사용하였다.

앞에서는 주로 제안한 질감 측정법을 클러스터링 기법으로 증명한 연구들로 클러스터링 적용에서 나타나는 문제를 고려하지 않았다. 클러스터링 기법은 목적함수가 수렴할 때까지 반복하기 때문에 발생하는 큰 계산 복잡도 문제와 클러스터 수의 선택, 클러스터의 중심 계산 등이 잘못될 경우 발생하는 분할 오류 때문에 응용범위가 제한된다.

클러스터링의 성능을 개선한 연구들을 살펴보면, Clausi[9]는 KIF(k-means iterative fisher) 알고리즘을 제안하여 개선된 질감 분할 성능을 보여주었지만, k-평균 알고리즘과 함께 FLD(Fisher linear discriminant)가 반복적으로 적용되기 때문에 계산 복잡도는 오히려 증가하였다.

클러스터링은 유효성 측정(validity)을 통해 성능을 분석할 수 있다는 점에 착안하여 Rhee 등[10]은 최적의 클러스터 수를 선택하기 위한 유효성 함수를 정의하였고, Bensaid 등[11]은 유효성 측정으로 분류성능을 높이기 위해 반복-클러스터링(re-clustering)을 제안하였다. 하지만, 유효성에 기반을 둔 방법은 기존 알고리즘에 추가되는 작업이므로 계산 복잡도를 줄일 수 없었다.

알고리즘 변경을 통해 개선한 연구로는 Qian 등[12]은 전체 데이터 분포와

지역 연결성 행렬을 이용하여 새로운 목적함수를 제시하여 강인한 클러스터링 기법을 제안하였다. Frigui 등[13]은 클러스터링의 주요 이슈가 되는 초기치 민감도, 클러스터 수 결정 문제, 노이즈에 대한 민감성 등을 개선하기 위해 RCA(robust competitive agglomeration) 알고리즘을 제안하였으며, 유현재 등 [14]에서는 평균내부거리를 이용한 목적함수로 성능을 개선하였다. 하지만 [10-14]에서는 기존의 목적함수를 위주로 개선하였기 때문에 계산 복잡도의 큰 향상을 기대할 수 없었다. 또, 대부분 [4-9]와는 다른 형태의 영상 분할에 대한 연구이거나 순수 클러스터링 차원의 개선 연구이므로 기존의 질감 분할 기법과 성능 비교가 어렵다.

본 논문에서는 유역변환기반의 마커를 클러스터링에 적용하여 질감 영상을 분할한다. 제안한 기법은 가보 필터를 통해 얻은 질감 에너지에서 선택된 마커만을 클러스터링으로 분류한다. 후에 수행되는 유역변환 과정에서 분류된 마커들은 각각의 영역을 형성하는데, 각 영역의 마커가 속한 클러스터 레이블 정보를 이용하여 같은 클러스터의 영역들을 서로 합친다. 제안한 기법은 Brodatz[15]의 질감 영상을 조합하여 실험하였으며, 기존의 클러스터링 연계와 달리 마커라는 특정 집합의 화소만을 클러스터링에 적용하기 때문에 영상 패턴의 복잡도가 증가할수록 빠른 분할이 가능하였고, 전체 알고리즘이 유역변환을 기반으로 이루어지기 때문에 분할 성능에서도 클러스터링 특유의 분할 오류를 상당 부분 개선할 수 있었다.

2장에서는 제안한 기법과 관련된 주요 개념들을 살펴보고, 3장에서는 제안하

는 질감 영상 분할 기법에 대해 상세히 기술한다. 4장에서는 분할 성능과 계산 복잡도를 비교·분석하며 5장에서는 본 논문의 결론을 맺는다.



## II. 관련 연구

### 2.1 클러스터링에 의한 패턴 분류

패턴 공간에 주어진 유한개의 패턴들이 서로 가깝게 모여서 무리를 이루고 있을 때, 이 무리를 이루고 있는 패턴집합을 군집 또는 클러스터(cluster)라고 하고, 패턴간의 유사성이나 근접성을 이용하여 주어진 패턴들을 무리지어 나가는 처리를 클러스터링이라고 한다. 클러스터링 과정은 그림 1의 (a)와 같이 임의의 클러스터의 중심을 주어진 클러스터의 개수만큼 할당하고, 각 클러스터와 패턴 집합과의 거리와 이를 통해 얻는 군집의 소속정도(cluster membership)를 이용한 목적함수(objective function)가 그림 1의 (b)처럼 최소가 될 때까지 반복한다.

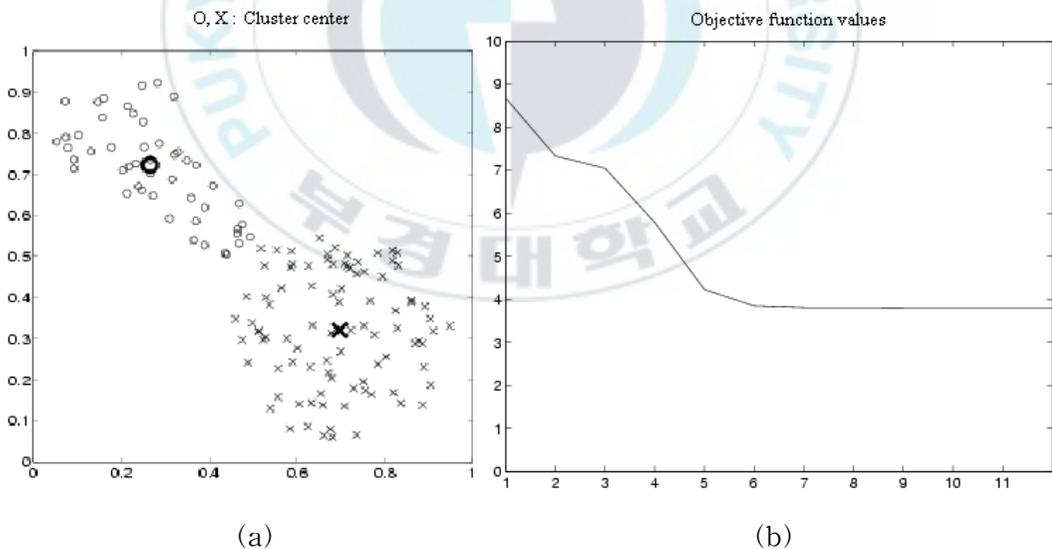


그림 1. (a) 목적함수의 수렴, (b) 패턴 분류

Figure 1. (a) Convergence of objective function, (b) Pattern classification.

### 2.1.1 영상 분할을 위한 FCM 클러스터링

앞서 기술한 클러스터링에서 거리 계산을 위한 척도로 유클리드 거리 (Euclidean distance), 마할라노비스 거리(Mahalanobis distance) 등으로 클러스터의 중심을 계산할 수 있는데[16], 이것은 다차원 정보 간 거리 계산이 가능함을 의미한다. 특히 영상의 질감 측정 결과들은 다양한 에너지로 구성되므로 분할 기법으로 클러스터링을 쉽게 응용할 수 있으며, 이것은 질감 패턴에 대한 클러스터를 형성하고 영상 내 각 영역들에 클러스터의 레이블을 할당하는 과정이 된다. 질감 분할에 자주 응용되는 클러스터링 기법에는 FCM, k-평균, 제곱-에러 알고리즘 등이 있다[14].

FCM 알고리즘은 퍼지 클러스터링 알고리즘 중 가장 폭넓게 사용되는 알고리즘이며, 분할도구로서의 성능 또한 우수하다[5]. 따라서 본 논문의 클러스터링 알고리즘은 FCM 알고리즘을 이용하며, 이것은 (8)과 같이 각각의 데이터와 클러스터 중심과의 거리를 고려한 유사도를 측정한 후 유사도에 기초한 목적함수를 최소화할 수 있도록 데이터 집합을 분할하는 알고리즘이다.

$$J_m(U, V) = \sum_{i=1}^c \sum_{j=1}^n (u_{i,j})^m \|x_j - v_i\|^2 \quad (8)$$

식 (8)에서, 모든 데이터  $j$ 에 대해  $\sum_{i=1}^c u_{ij} = 1$ 이다.  $n$ 은 데이터의 개수,  $c$ 는 클러스터의 개수 그리고  $m$ 은 퍼지 정도를 나타내는 가중치 지수이다.  $X = \{x_1, x_2, \dots, x_n\}$ 인 데이터 벡터 집합과  $V = \{v_1, v_2, \dots, v_c\}$ 인 클러스터 중심들 사이의 소속 정도를  $c \times n$ 인 행렬  $U (= u_{ij})$ 로 나타낼 수 있다.

$$u_{ij} = \left\{ \sum_{k=1}^c \left( \frac{d_{ij}}{d_{kj}} \right)^{\frac{2}{m-1}} \right\}^{-1}, \quad (9)$$

여기서,  $d_{ij} = \|v_i - x_j\|$ , ( $i = 1, 2, \dots, c$ ,  $j = 1, 2, \dots, n$ ),

$$v_i = \frac{\sum_{j=0}^n (u_{ij})^m x_j}{\sum_{j=0}^n (u_{ij})^m} \quad (10)$$

식 (9)에서  $u_{ij}$ 는  $j$ 번째 데이터가  $i$ 번째 클러스터에 속하는 소속정도를 나타내고, 식 (10)에서  $v_i$  ( $1 \leq i \leq c$ )는  $i$ 번째 클러스터 중심이다. 여기서  $m$ 이 1보다 큰 경우에 모든  $i, j$ 에 대해서  $v_i \neq x_j$ 를 만족한다면 위의 식을 만족할 때만  $(U, V)$ 가  $J_m$ 의 최소화를 가능하게 한다. 이 알고리즘은 식 (9)와 식 (10)의 과정을 반복하므로, 특정한 값으로 수렴한다[14].

### 2.1.2 클러스터링의 분할 오류

그림 2는 여러 질감 영역을 섞어놓은 영상을 Chang 등[5]의 질감 분할 알고리즘 평가에서 비교적 우수한 성능을 보여준 LAWS-FCM 연계(Laws' texture energy 질감 측정-FCM 클러스터링)를 이용하여 분할한 결과이다. 대부분의 클러스터링을 이용한 질감 분할에서는 그림 2의 (b)와 같은 특유의 분할 오류가 자주 발생하며, 본 논문에서는 다른 인접 영역과 동떨어져서 발생하는 얼룩 형태의 분할 오류를 blob segments라하고, 인접 영역 간 경계에서 얼룩이 번진 듯 발생하는 분할 오류를 blob spreads라고 한다. 이러한 오류들은 원하는 형태

의 영역 분할을 어렵게 하며, 영상 분할 도구로써 클러스터링의 실질적인 응용에 장애가 되는 주요 요인이 된다.

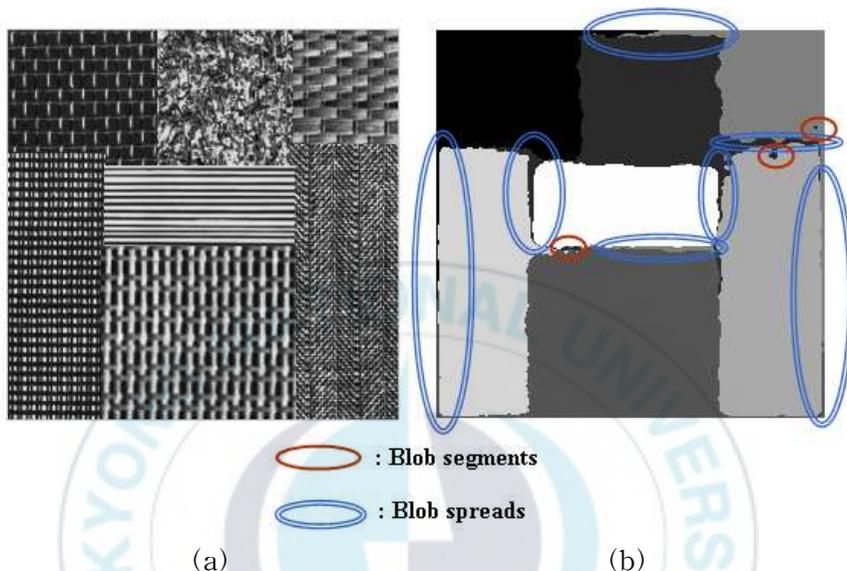


그림 2. (a) 원본 영상, (b) 클러스터링 특유의 영상 분할 오류

Figure 2. (a) Original image, (b) Frequent partition errors in clustering.

## 2.2 가보 웨이블릿(Gabor wavelet)을 이용한 질감 분석

분할 기법의 선택도 중요하지만, 기본적으로 질감 분할은 질감 측정에 근거하므로 질감 측정법의 선택이 질감 분할의 성능을 좌우한다. 질감 측정을 위한 접근으로 통계적 기법(statistical methods), 기하학적 기법(geometrical methods), 모델 기반 기법(model based methods), 신호처리 기법(signal processing methods) 등이 있는데[2], 신호처리 기법에서 공간과 주파수 도메인을 응용하는 가보 웨이블릿 모델은 영상을 공간적으로 지역화(localization)하는 특성을 지니고 있을

뿐만 아니라 주파수 영역에서도 특정 주파수와 방향에 대해서 선택적으로 반응하는 대역 통과필터의 특성을 가지며 입력 영상의 크기 변화와 회전 변화에도 강한 특성을 가진다. 특히 다양한 시각필터 중에서 공간 영역과 주파수 영역에서 동조 가능한 방향(tunable orientation)과 중심 주파수(center frequency), 반경 주파수 대역폭(radial frequency bandwidth)을 갖는 가보필터는 적절한 인수의 설정에 의해서 다양한 모양, 방향, 중심 주파수, 대역 폭 등이 변화할 수 있다. 이러한 인수 변화에 의해 타원형 모양의 특정 공간 주파수를 통과시킬 수 있는 대역 통과필터의 기능은 질감 분석에 적합하다[17-20].

### 2.2.1 2차원 가보 필터

공간 영역에서 2차원 가보필터와 그 푸리에 변환은 다음과 같다.

$$g(x, y) = \left( \frac{1}{2\pi\sigma_x\sigma_y} \right) \exp \left[ -\frac{1}{2} \left( \frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2} \right) + 2\pi j Wx \right] \quad (1)$$

$$G(u, v) = \exp \left\{ -\frac{1}{2} \left[ \frac{(u - W)^2}{\sigma_u^2} + \frac{v^2}{\sigma_v^2} \right] \right\} \quad (2)$$

여기서,  $\sigma_x, \sigma_y$ 는 표준편차,  $\sigma_u = 1/2\pi\sigma_x, \sigma_v = 1/2\pi\sigma_y$ .

식 (1)과 식 (2)에서 살펴볼 수 있듯 가보 필터는 비직교성(non-orthogonal)의 기저 집합의 형태를 가지며, 국부적인 주파수 표현을 제공한다. 가보 웨이블릿으로 참조되는 자기-유사 함수(self-similar function)를 고려하면,  $g(x, y)$ 를 모함수로

두어 식 (3)과 같은 함수 생성 과정에서 적당한 팽창(dilation)과 회전(rotation)에 의해 필터 집합(filter dictionary)을 얻을 수 있다[18].

$$g_{mn}(x, y) = a^{-m} G(x', y'), a > 1, m, n = integer \quad (3)$$

$$x' = a^{-m}(x \cos \theta + y \sin \theta), y' = a^{-m}(-x \sin \theta + y \cos \theta)$$

여기서,  $\theta = n\pi/K$ ,  $K$ 는 전체 방위수

식 (3)에서의 스케일 요소  $a^{-m}$ 는  $m$ 에 독립적인 에너지를 보장.

$$a = (U_h/U_l)^{-\frac{1}{S-1}}, \sigma_u = \frac{(a-1)U_h}{(a+1)\sqrt{2\ln 2}},$$

$$\sigma_v = \tan\left(\frac{\pi}{2k}\right) \left[ U_h - 2\ln\left(\frac{\sigma_u^2}{U_h}\right) \right] \left[ 2\ln 2 - \frac{(2\ln 2)^2 \sigma_u^2}{U_h^2} \right]^{-\frac{1}{2}}, \quad (4)$$

여기서,  $W = U_h$ ,  $m = 0, 1, \dots, S-1$ ,  $U_h$ 는 상위중앙주파수,  $U_l$ 는 하위중앙주파수.

### 2.3 유역변환 영상 분할

영상 분할은 크게 히스토그램에 의한 방법과 경계 기반 방법, 그리고 영역 기반 방법이 있는데, 영역 기반 방법은 닫힌 영역 경계를 형성하고, 중심 화소의 인접 유사성에 따라 영역을 확장해나가므로 안정적인 성능을 보여주며, 분할 및 병합(split and merge), 영역 성장(region growing)과 같은 원론적인 알고리즘이 존재한다. 특히, 영역 성장은 성장의 중심이 되는 성장점(seed)을 선택한

후, 인접 화소들을 정해진 임계치에 따라 포함시켜나가는데, 비슷한 접근으로 경계와 영역 모두에 기반을 두는 유역변환 영상 분할 기법이 있다. 이것은 수리 형태학(mathematical morphology)을 이용하며, 기울기 변환된 영상(gradient image)의 레벨 값을 높낮이(altitude)로 간주하여 지형적 구조를 형성한다. 이러한 구조에 모의 침수 과정(immersion simulation)을 적용하여 영상을 분할한다 [20].

### 2.3.1 유역변환의 개념

그레이 스케일 영상들은 그림 3과 같이 화소의 레벨에 따라 높낮이가 표현되는 지형학적 표면으로 간주되어 질 수 있다. 지형적 구조를 가지게 되는 영상에서 일정 범위의 주위 화소와 비교해서 가장 낮은 레벨을 가진 화소들을 최소지역(minima)이라 하고, 이것으로부터 물이 차오른다고 가정할 때 형성되는 지형적 구조를 담수지역(catchment basins)이라 한다. 물이 차오를 때 높이가 낮은 지역에서부터 범람하는 것과 같이 영상 화소 레벨의 최소지역으로부터 범람되는 모의 침수에 의해 유역변환이 진행된다. 범람과정에서 인접한 다른 최소지역으로부터 흘러 들어오는 물의 침범을 막는 댐(dam)을 건설하여 서로 다른 지역 간의 물이 합쳐지는 것을 막는다. 이로 인해 범람의 마지막에는 댐만이 존재하고 이것들이 분할 경계인 유역(watershed)을 형성한다[21-23].

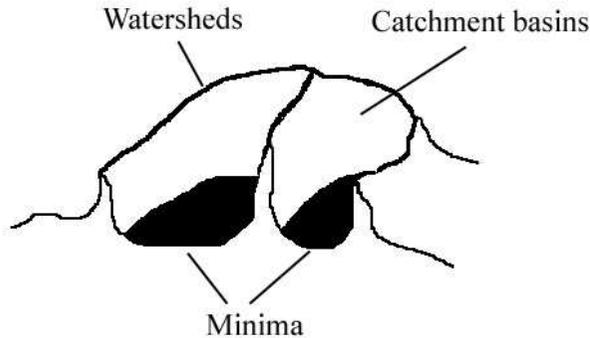


그림 3. 최소지역, 담수지역, 유역의 구조

Figure 3. Minima, catchment basins and watersheds

### 2.3.2 영상의 기울기 변환

그레이 영상에서 밝기 값에 급격한 변화를 보이는 부분들은 기울기 영상으로 변환 시 높은 고도에 위치하게 되며 결국 각각의 영역 최대점들(regional maxima)이 확장 단계에서 영역을 구분 짓는 유역경계들과 일치하게 된다. 따라서, 그레이 영상의 기울기 변환에서 유역변환 알고리즘을 적용하는 것이 일반적이며, 민감한 기울기에 의해 존재하는 잡음성의 최소지역을 억제하기 위해 전처리로 중간값 필터링(median filtering), 형태학적 열기-닫기 연산(morphological closing-opening)등의 스무딩처리를 통해 과분할을 줄일 수 있다. 하지만, 일반적인 응용에서는 영역의 명암도 변화가 복잡하므로 역시 많은 과분할이 존재하게 된다. 이를 해결하기 위해 관심 객체에 마킹을 하여 해당 객체에서만 영역 확장이 일어나도록 하는 마커-제어(marker-controlled) 유역변환을 고려할 수 있다 [23].

### 2.3.3 마커-제어 유역변환

특별한 처리 없이 유역변환을 시도하는 것은 극심한 과분할을 야기하는데, 이것은 스무딩 처리에도 없어지지 않으며, 분할하려는 영역과 관련이 없는 모조의 최소지역(spurious minima)이 원인이 된다. 관심객체를 정확히 분할하기 위해서는 관련 없는 최소지역들이 유역변환 전에 제거되어야 한다. 따라서 영상 내에 관심 객체를 마킹하는 마커-제어 기법을 고려할 수 있다. 마커는 영역 확장 시작점이자, 관심 객체에 해당하는 영역이며, 마커-제어 유역변환은 마커 영역만이 최소지역이 되도록 기울기를 수정하며, 기존의 최소지역은 모두 제거하여 유역변환을 수행하는 과정이다.

관심 객체를 마킹하는 마커 함수  $f_m$ 은 원하는 응용에 따라 다르게 설정할 수 있으며, 식 (5)와 같이 마커에 해당하는 영역을 0으로 설정하고 그 외 영역에는 영상 도메인이 가지는 최대값  $t_{max}$ 를 할당한다. 마커로 설정된 화소들은 식 (6)의 최소값 부과(minima imposition) 과정에서 가장 최저 레벨이 되도록 기울기  $f_1$ 이 수정된 후 식 (7)의 유역변환 알고리즘이 적용된다[21].

$$f_m(x) = \begin{cases} 0, & \text{if } x \text{ belongs to a marker} \\ t_{max}, & \text{otherwise} \end{cases} \quad (5)$$

$$f_2 = R_{(f_1 \wedge f_m)}^*(f_m) \quad (6)$$

$$SEG(f) = WS(f_2) \quad (7)$$

식 (6)은 형태학적 재구성(morphological reconstruction)에 해당하는 표현이며, 마커 영상  $f_m$ 으로부터 마스크 영상  $f_1 \wedge f_m (= \min[f(x), g(x)])$ 의 침식(erosion)에 의한 재구성(reconstruction)을 의미한다. 이 과정을 일차원 신호  $f$ 에 대해 도식화하면 그림 4와 같다.

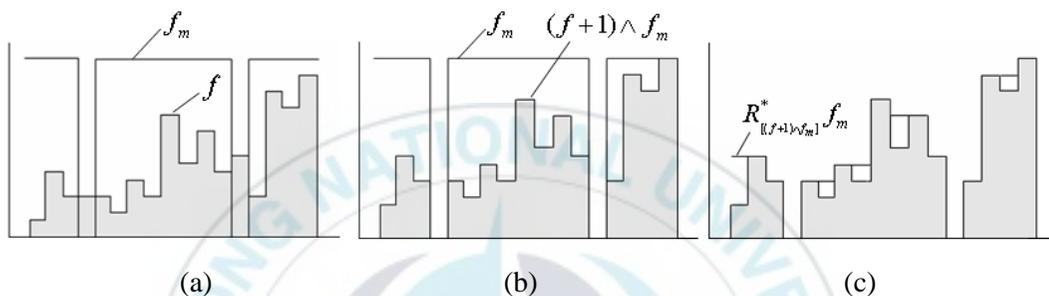


그림 4. 최소값 부과 과정 (a) 입력 신호  $f$ 와 마커 신호  $f_m$  (b)  $f+1$ 와  $f_m$ 의 점-대-점 최소 (c) 마커 함수  $f_m$ 으로부터  $(f+1) \wedge f_m$ 의 재구성

**Figure 4.** Minima imposition technique. (a) Input signal  $f$  and marker signal  $f_m$  (b) Point-wise minimum between  $f+1$  and  $f_m$  (c) Reconstruction of  $(f+1) \wedge f_m$  from the marker function  $f_m$ .

그림 4와 같이 최소값 부과 과정은 마커지역을 최소레벨로 수정하여 새로운 최소지역을 생성하고 그 외에 존재하는 최소지역은 기울기가 수정되어 없어지므로 유역변환 과정에서 영역 분할은 마킹된 영역에서만 이루어진다.

### Ⅲ. 질감 분할 기법의 제안

앞서 2장에서 거론한 클러스터링의 문제점 중 가장 응용에 장애가 되는 요인은 높은 계산 복잡도이다. 실제 응용에서는 높은 분할 성능과 낮은 계산 복잡도가 요구되는데 서론에서 살펴본 클러스터링 관련 연구들은 질감 분할에 단순히 연계하거나, 패턴의 분류 성능을 높이기 위해 더욱 계산 복잡도를 높였으므로 이러한 요건을 만족하지 못한다. 따라서 본 논문에서는 계산 복잡도를 낮추고, 클러스터링 특유의 분할 오류를 억제할 수 있는 고려한다.

FCM 클러스터링에 관한 식 (8)에서 볼 수 있듯 클러스터링의 복잡도는 클러스터의 수인  $c$ 와 영상 데이터 화소 수에 해당하는  $n$ 에 의존한다. 클러스터링의 복잡도를 낮추기 위해 본 논문에서는 클러스터링의 영상 데이터 수를 제한한다. 즉, 제한된 특정 화소만을 클러스터링의 입력 데이터로 사용하는 것이다. 제한된 특정 화소 집합으로 2장에서 살펴본 유역변환의 마커를 고려할 수 있으며 마커-제어 유역변환 과정에서 이것은 영역 확장의 시작이 되는 지점이다. 따라서 제안한 기법은 마커에 해당하는 화소만을 클러스터링에 적용한 후, 유역변환 과정에서 각 마커들이 생성한 영역을 소속 클러스터에 따라 병합하며 전체 진행과정을 블록도로 표현하면 그림 5와 같다.

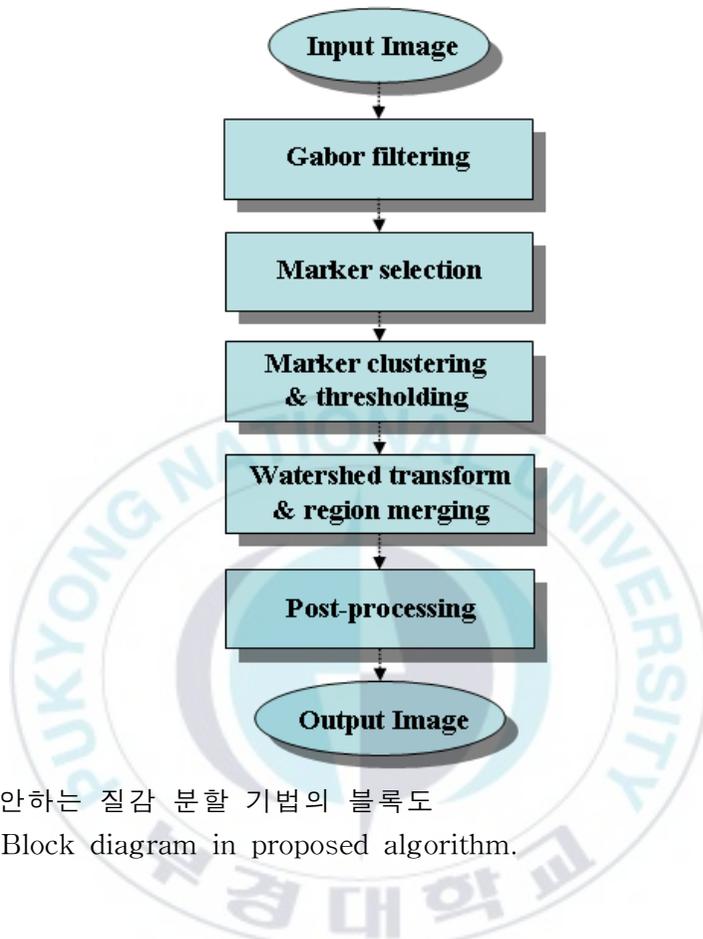


그림 5. 제안하는 질감 분할 기법의 블록도  
 Figure 5. Block diagram in proposed algorithm.

제안한 기법은 가보 필터링을 통해 질감 에너지를 얻어 유역변환에서 영역 확장의 시작점인 마커를 선택하고, 마커에 해당하는 화소만을 클러스터링에 적용하여 군집 정보를 얻는다. 그 후, 마커들은 마커-제어 유역변환 알고리즘에 적용되며, 클러스터링의 입력 데이터가 현저히 줄어들기 때문에 계산 복잡도를 절감할 수 있고, 유역변환을 기반으로 하므로 클러스터링 특유의 분할 오류도 감소한다.

### 3.1 가보 필터링(Gabor Filtering)

질감 영상은 명암도 변화가 다양하여 바로 영상 분할에 적용할 수 없으므로, 가보 필터를 이용한 질감 측정을 통해 단순화된 질감 에너지 영상으로 분할을 고려한다. 가보 필터링 과정을 식 (11)처럼 각 필터와 입력 영상 간의 연산으로 표현할 수 있으며, 각각의 결과들은 식 (12)의 형태로 얻는다. 영역 특성을 잘 구분하는 질감 에너지들로 최적의 질감 정보를 구성하기 위해 선택함수  $OPT$ 는 전체 질감 에너지  $O(x, y)$ 를 입력으로 식 (13)에 의해 최적 질감 에너지인  $e(x, y)$ 를 선택한다. 선택된 질감 정보들은 유역변환에서 단일 영상의 입력으로 변환하기 위해 식 (14)로 단일한 형태의 질감 영상인  $C(x, y)$ 를 구성할 수 있다.

$$O_i(x, y) = I(x, y) * g_i(x, y) \quad (11)$$

$O_i(x, y)$ : Gabor output,  $I(x, y)$ : original image,  $g_i(x, y)$ : Gabor filter,

$1 \leq i \leq N, N = S \cdot K, S$  : scale number,  $K$  : orientation number

$$O(x, y) = \{O_1(x, y), O_2(x, y), \dots, O_N(x, y)\} \quad (12)$$

$$OPT(O(x, y)) = \{e_1(x, y), e_2(x, y), \dots, e_k(x, y)\} \quad (13)$$

$$C(x, y) = \frac{1}{k} \sum_{i=1}^k e_i(x, y) \quad (14)$$

$k$ : number of optimal outputs

### 3.2 마커 선택(Marker Selection)

유역변환 기법의 단순 적용에서 오는 과분할 현상은 2장에서 살펴본 것과 같이 영역 확장의 시작점을 인위로 설정하는 작업으로 "관심 객체에 마킹-선택된 영역에서만 영역 확장"의 절차로 제거할 수 있다. 마커로 선택되지 않은 영역은 분할에서 제외되기 때문에 마커 선택에 있어 상당한 주의가 필요하며 마커는 영상 내 객체의 특성을 표현하여야한다[21], [23].

마커 선택 함수로 형태학적 기법인 확장 최소값 변환(extended minima transform)을 고려할 수 있는데[23], 지형적인 영상 구조에서 인접한 주위보다 특정 높이  $h$ 만큼 더 깊은 최소지역들의 집합을 계산하는 과정이며, 형태학적 개념으로 구성되는 식 (15)로 표현할 수 있다.

$$EMIN_h(f) = RMIN[HMIN_h(f)] \quad (15)$$

여기서,  $HMIN_h(f) = R_f^*(f+h)$ ,  $RMIN(f) = R_f^*(f+1) - f$ ,  $R_g^*(f) = \epsilon_g^{(i)}(f) = [R_{g^c}(f^c)]^c$

식 (15)의 표현은 형태학적 연산으로 정의되는 함수표현으로 Soille[21]의 저서에 의하면,  $HMIN_h(f)$ 는 마커  $f+h$ 로부터 마스크  $f$ 의 침식에 의한 재구성 ( $R_g^*(f)$ : the reconstruction by erosion of a mask image  $g$  from a marker image  $f$ )을 의미한다.  $RMIN$ 은 영역적 최소지역(regional minima)을 구하는 것으로 식 (15)는  $HMIN$ 의  $h$ 만큼 영역적 최소지역이 제거된  $f$ 신호를 구성하고  $RMIN$ 으로

그 신호의 영역적 최소지역을 마킹한다.

그림 6은 좌측의 원본 영상 (a)에 대해 유역변환을 바로 적용한 결과인 (b)와 확장 최소값 변환( $h=10$ )을 이용한 마커-제어 결과 (c)를 나타내었으며, 많은 수의 과분할이 제거되었음을 알 수 있다. 질감 에너지에서 선택되는 초기 마커들을 식 (15)를 통해 단순화를 고려해 볼 수 있지만, 실제로는 선택된 마커영역의 인접연결성이 같은 질감 영역뿐 아니라 다른 질감 영역의 마커들까지도 포함하게 되어, 최악의 경우에는 영역 확장의 시작점을 선택해야하는 마커가 질감 영역의 상당 부분 또는 전체를 아우르게 된다. 이럴 경우, 마커 계산과 함께 마커 화소들의 증가로 클러스터링의 계산 복잡도가 커지기 때문에 전체 화소수보다 적은 마커 화소만을 클러스터링하려는 본래의 접근에서 멀어진다.

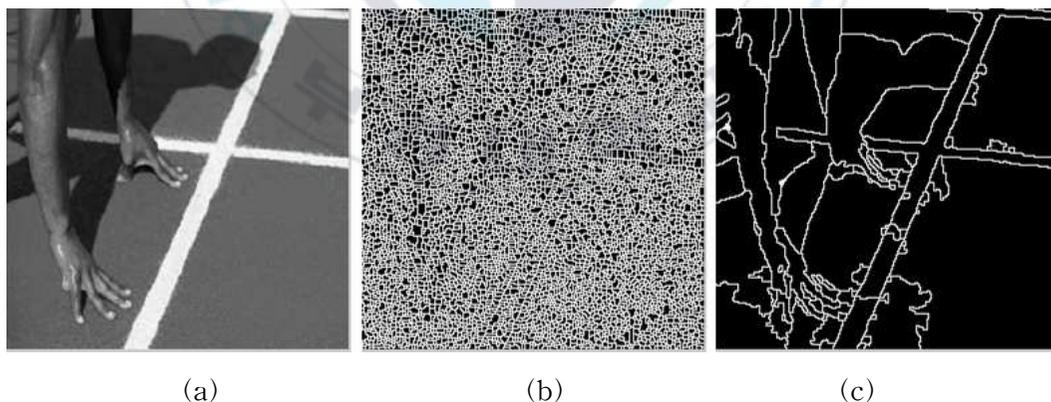


그림 6. (a) 원본영상, (b) 유역변환 결과, (c) 마커-제어 유역변환 결과

**Figure 6.** (a) Original image, (b) watershed transform, (c) marker-controlled Watershed transform.

이 가능성을 배제하기 위하여 본 논문에서의 마커 선택 함수는  $h$ 이하의 최소 지역을 제거하지 않고, 존재하는 영역적 최소지역(**regional minima**)만을 계산한다. 이것은 결국  $h=0$ 인 식 (15)의 계산을 의미하며, 다시 표현하면 식 (16)과 같다.

$$EMIN_0(f) = RMIN(f) = R_f^*(f+1) - f. \quad (16)$$

따라서 제안한 기법에서는 식 (16)으로 마커를 선택하며, 원본 영상의 기울기에서 마커를 선택하는 일반적인 유역변환과는 다르게 식 (13)의 각각의 질감 에너지 영상  $e(x, y)$ 에서 선택된 모든 마커를 클러스터링에 이용한다.

### 3.3 마커 클러스터링과 임계치 처리(**Marker Clustering & Thresholding**)

마커 영역만을 클러스터링으로 분류하고 이것을 영역 병합 조건으로 이용하면 계산량 감소가 가능하며, 이미 유역변환에 의해 분할된 영역을 합치기 때문에 개선된 분할성능을 기대할 수 있다. 따라서 본 논문에서는 마커를 클러스터링하기 위하여 Chang 등[5]의 질감 알고리즘 비교 평가에서 우수한 성능을 보여준 FCM 알고리즘을 이용한다.

하지만 FCM 알고리즘에서도 클러스터링 오류가 발생할 수 있으며, 특히 마커 클러스터링에서는 다른 질감 영역 간 경계 부근에서 오류가 많이 발생한다. 이것은 추후에 진행될 영역병합에서 오분할을 유발하므로 이를 방지하기 위한

절차가 필요하다. 경계 부근 마커들은 소속정도(cluster membership)  $u_{ij}$ 가 대체적으로 낮으므로 2단계에서 선택된 마커의 각  $p$ 에 대해 임계치  $T$ 이상인 화소만을 식 (17)과 같이 선택한다.

$$\Theta(p) = \{1 < i < c, \text{Max}(u_{ij}) > T\} \quad (17)$$

$c$ : 분류된 클러스터 수

$u_{ij}$ :  $M$ 의 모든 화소에 대한 인덱스  $j$ 의  $i$ 번째 클러스터에 대한 소속정도

제거된 마커들은 그들의 인접 마커들에 의해 확장되며, 마커가 고르게 선택되어 있을수록 제거된 마커의 공백에 대한 영역 확장이 올바르게 일어난다.

### 3.4 유역변환과 영역 병합(Watershed Transform & Region Merging)

인접으로 연결된 마커 화소들의 집합  $p_i$ 는 식 (12)의 유역변환 함수  $WS$ 에 의해 분할된 영역  $S_i$ 를 가지게 되며, 이 영역의 화소  $q_j$ 의 라벨  $lb(q_j)$ 에는 마커  $p_i$ 의 최대 소속 정도를 가지는 클러스터의 라벨  $lb_{c_{max}}(p_i)$ 를 할당하여 병합한다.

$$1 \leq i \leq l, S_i = WS(p_i) = \{q_1, q_2, \dots, q_{m-1}, q_m\} \quad (18)$$

$q_j$ :  $S_i$ 를 구성하는 화소,  $m$ :  $S_i$ 의 전체 화소수

$$lb(q_j) = lb_{c_{max}}(p_i) \quad (19)$$

### 3.5 후처리 (Post-processing)

유역변환 영상 분할 특성으로 분할 과정에서 영역간의 경계가 따로 존재하며, 해당 화소에는 분류된 클러스터에 대한 레이블이 할당되지 않는다. 완전한 분할을 위해 그레이 영상에 대한 형태학적 팽창 연산( $\oplus$ )을 이용하며, 그 처리 과정을 프로그램 코드로 표현하면 다음과 같다.

```
# define WSHED 0 /* value of the pixels belonging to the watersheds */
-input:  $im_{lb}$ , image of the labeled watersheds;
-output:  $im_{re}$ , image of the relabeled watersheds to watershed pixels;
- $SE$  /* structural elements for dilation*/
- $temp$  /* temporary memory space having same size with  $im_{lb}$  */
· initializes  $im_{re}$ :
   $im_{re} = im_{lb} \oplus SE$ ; /*first dilation*/
  /* find index still being watershed */
   $idx = find(im_{re} = WSHED)$ ;
· repeat dilation until all watersheds are removed:
   $temp = im_{re}$ ;
  while(true){
     $temp = temp \oplus SE$ 
    /* if all watersheds are removed, stop */
    if( $find(im_{re} = WSHED) = none$ ){
      break;
    }
  }/* relabels to the pixels were watershed*/
   $im_{re}(idx) = temp(idx)$ ;
```

그림 7. 형태학적 팽창을 이용한 유역 제거

**Figure 7.** Removing watershed with morphological dilation.

그림 7의 소스 코드는 레이블 영상  $im_{lb}$ 를 입력 받아 분할 경계선에 해당하는 값인 0이 모두 없어질 때까지 그레이 레벨의 팽창 연산을 반복하는 과정이며, 새로운 레이블이 할당된 영상  $im_{rc}$ 를 출력하여 모든 분할 과정이 끝난다.



## IV. 실험 결과 및 분석

### 4.1 실험 환경

본 연구에서는 질감 분할에 널리 사용되는 Brodatz[15]의 모자이크 영상을 조합하여 실험한다. 실험에 사용된 가보 필터에 관한 소스는 Manjunath 등[24]을 참고하였으며, FCM 알고리즘은 Abonyi 등[25]이 구현한 Matlab toolbox를 이용하였다. 256×256 크기로 제작된 실험 영상을 그림 8과 같이 설정하여 실험하였으며 실험 환경은 표 1을 따랐다.

표 1. 실험 환경의 설정

Table 1. Experimental environment.

실험 환경	내 용
영상 설정	2, 5, 7, 9가지 질감 조합 영상
영상 크기	256(w)×256(h)
가보필터 설정	전체 방위 수: 6, 전체 스케일 수: 4, $U_h$ : 0.4, $U_l$ : 0.05
FCM 설정	클러스터 수: 실험 영상에 조합된 질감의 수 퍼지 가중치 지수 $m$ : 2, 최대 종료 허용한계: 1e-6
기타 환경	CPU: Intel Pentium 4 3GHz RAM: 1GB OS: Window XP, Programming Tool: Matlab

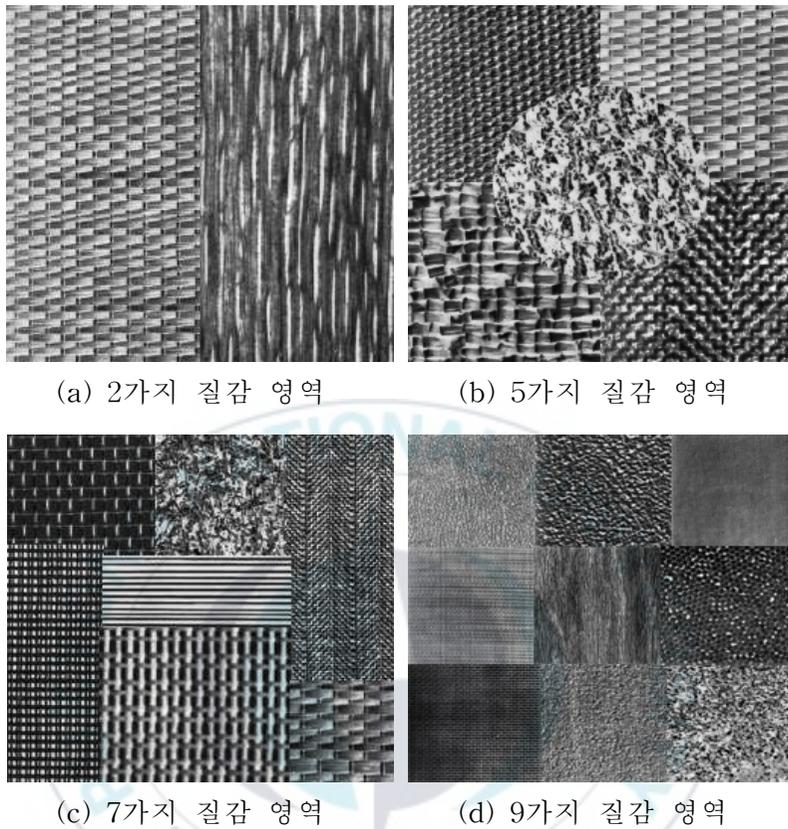
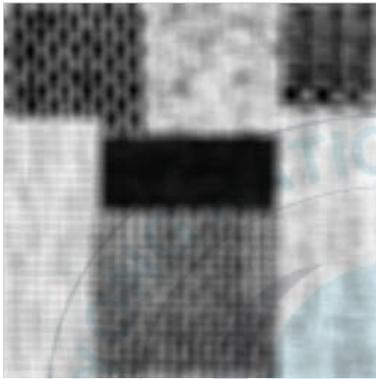


그림 8. 실험 영상의 설정  
 Figure 8. Test images.

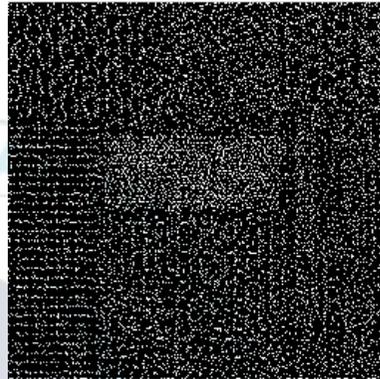
FCM 알고리즘의 사전 입력정보인 클러스터의 수는 조합된 질감 영역의 수로 설정된다. 필터링된 질감 에너지들은 blob detection이 쉽도록 쌍곡 탄젠트 (hyperbolic tangent) 연산을 적용하며, 윈도우 연산은  $C(x,y)$ 에 적용한다[4]. 기타 변수는 실험을 통해 최적화한다.

## 4.2 단계별 실험

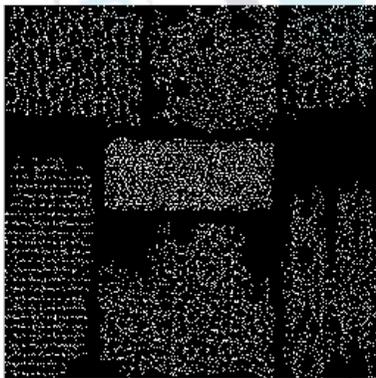
제안한 기법을 그림 8의 5가지 질감 영역을 가지는 영상에 적용한 각 단계별 결과는 그림 9와 같다.



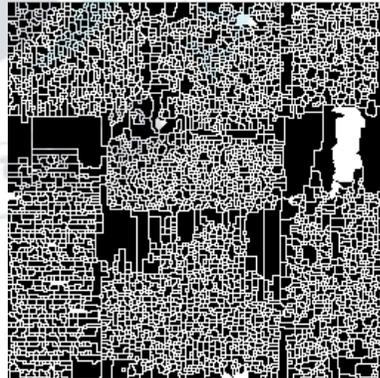
(a) Gabor filtering



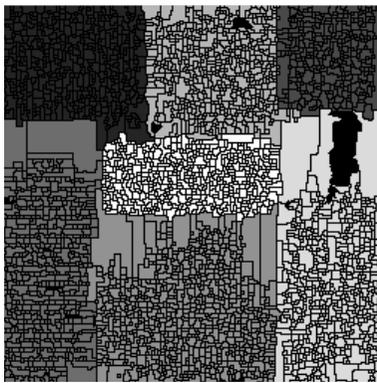
(b) Marker selection



(c) Marker clustering & thresholding



(d) Watershed transform



(e) Region merging



(f) Post-processing

그림 9. 5가지 질감 영역에 대한 각 단계별 결과

*Figure 9.* Stepwise results for the image having 5 textures.

그림 9의 (a)에서는 가보 필터링을 통한 질감 에너지를 하나로 조합하고 (b)에서는 각자의 질감 에너지에서 선택한 초기 마커를 보여준다(흰 영역). (c)에서는 마커를 FCM 클러스터링에 적용한 후,  $T=0.6$ 으로 낮은 소속정도를 가진 마커를 제거한다. (d)에서는 남아있는 마커로 유역변환한 후, (e)에서 클러스터 레이블 별로 각 마커가 생성한 영역들을 병합한다. 마지막 (f)에서는 유역 경계선을 제거하는 후처리로 영상 분할을 완료한다.

### 4.3 기존의 FCM 연계 알고리즘과의 분할 성능 비교

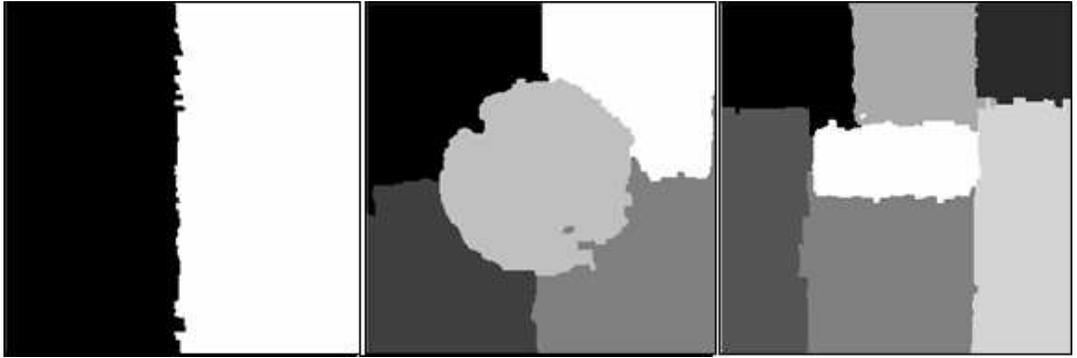
Chang 등[5]의 질감 분할 기술 평가에서 우수한 성능을 보여준 LAWS-FCM 연계와 각 구성 기술별로 우수한 가보 웨이블릿 질감 측정-FCM 알고리즘으로 구성되는 GABOR-FCM 연계를 제안한 기법과 비교하였다.



(a) Features=(LE, RR, SE, LS), 5×5 mask, 15×15 mean operation.



(b) Features=(scale=4, orientation 3-6), 11×11 mean operation.



(c) Features=(scale=4, orientation 3-6),  $11 \times 11$  mean operation,  $T=0.5$ .

그림 10. 질감 분할 결과 (a) LAWS-FCM (b) GABOR-FCM (c) 제안한 기법  
**Figure 10.** Results with (a) LAWS-FCM (b) GABOR-FCM (c) Proposed method.

그림 10의 (a)-(c)에 표기된 features는 선택된 질감 에너지에 대한 정보이며, mean operation은 각 질감 에너지를 제시된 크기로 평균 연산을 수행하였음을 의미한다. (a)의 mask는 컨볼루션 필터 크기를 의미하며 (c)의  $T$ 는 마커의 소속 정도 임계치이다. 비교적 낮은 질감 성능의 Laws' texture energy를 적용한 (a)에서는 가보 웨이블릿 측정을 이용한 다른 결과들에 비해 분할 정확도가 떨어지며, 전형적인 얼룩 현상이 두드러진다. 동일한 가보 웨이블릿 질감 측정을 이용한 (b)와 (c)를 비교해보면, 제안한 기법에서 얼룩 형태의 분할 오류가 확연히 감소하였으며, 이것은 유역변환 기법과 클러스터링의 접목을 통해 개선된 결과이다.

#### 4.4 다른 클러스터링 연계 알고리즘과의 분할 성능 비교

기존의 FCM 연계 기법 외에 표 2의 다른 클러스터링 연계 알고리즘과 질감 분할 성능을 비교한다. 비교 절차는 기존의 기술 연구에서 적용된 실험 영상을 제안한 기법에 적용하는 것으로 그림 11-13에 나타내었다.

표 2. 다른 클러스터링을 적용하는 기존 연계 기법

Table 2. Previous chain methods using another clustering.

Used method Reference	Texture measure	Clustering
[6]	Moment	Square-error
[7]	GMRF (Gaussian Markov random fields)	K-means
[9]	Gabor filter	KIF(K-means Iterative Fisher)

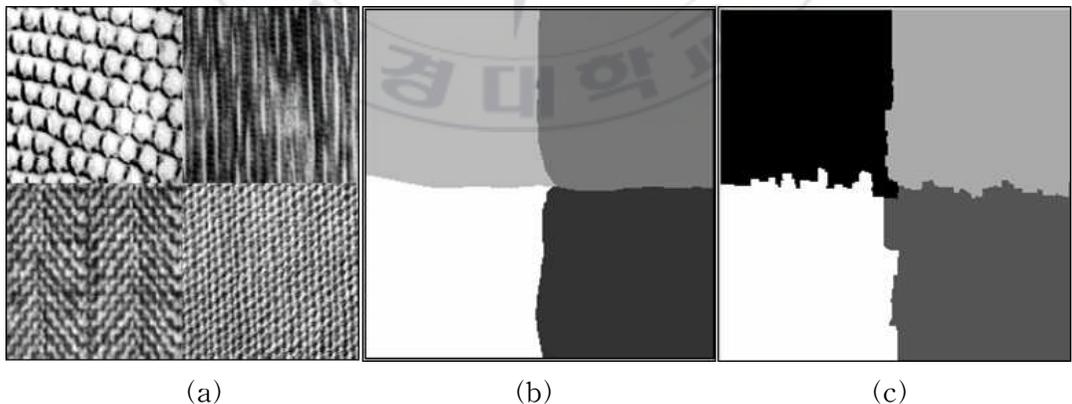


그림 11. (a) [6]의 실험 영상, (b) [6]의 실험 결과, (c) 제안한 기법의 결과  
Figure 11. (a) Sample image in [6], (b) Result image in [6], (c) Result image in proposed.

그림 11의 (a)에 대한 제안한 기법의 결과인 (c)는 모멘트에 기반을 둔 질감 분할 결과인 (b)에 비해 경계 부근에서 해상도가 떨어지는 편이나 얼룩 현상은 발견되지 않으며, 전체적으로 영역적인 측면에서 안정적인 분할을 보여준다.

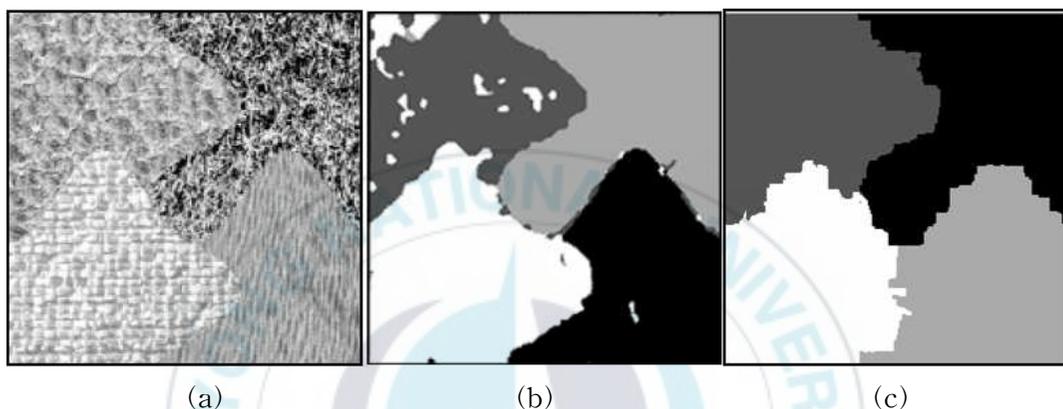
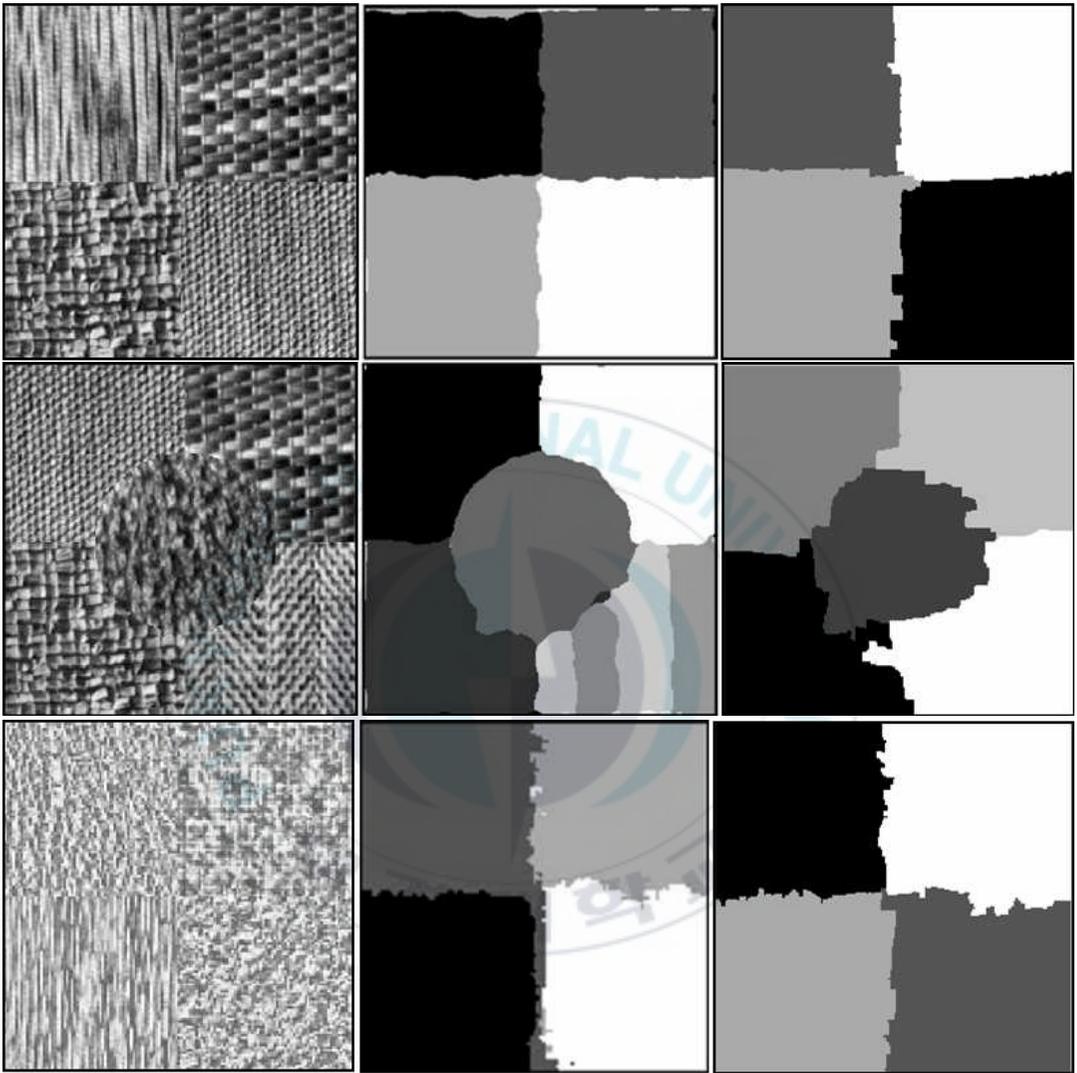


그림 12. (a) [7]의 실험 영상, (b) [7]의 실험 결과, (c) 제안한 기법의 결과  
**Figure 12.** (a) Sample image in [7] (b) Result image in [7], (c) Result image in proposed.

그림 12의 (a)는 여러 방향의 곡선의 경계로 조합되어 분할이 더욱 어려운 형태의 영상이며, GMRF에 기반을 둔 분할 결과인 (b)에서는 클러스터링 특유의 얼룩 분할 오류가 많이 발견된다. 특히 얼룩 조각 형태의 분할 오류가 두드러지며, 제안한 기법의 결과인 (c)에서는 분할 오류가 전혀 발견되지 않는다.



(a)

(b)

(c)

그림 13. (a) [9]의 실험 영상, (b) [9]에서의 결과, (c) 제안한 기법의 결과  
*Figure 13.* (a) Sample images in [9], (b) Result images in [9], (c) in proposed.

그림 13의 (a)는 3가지 타입 영상이 존재하며, 위에서 아래로 올수록 이질 영

역 간 경계가 점점 모호해지는 영상으로 구성된다. K-평균 알고리즘을 반복적으로 적용하여 성능을 개선한 KIF 알고리즘을 이용한 (b)에서는 얼룩 조각, 얼룩 번짐 형태의 분할 오류가 모두 존재한다. (c)에서 보여지는 제안한 기법의 결과에서는 클러스터링 특유의 분할 오류는 전혀 발견되지 않으며, 대신 이질 영역 간 경계 해상도가 떨어지는 문제가 여전히 발견된다. 이것은 영역 경계 부근의 클러스터링 오류를 줄이기 위해 적용한 임계치  $T$ 에 의한 결과로, 임계치 이하의 소속 정도를 가지는 마커가 제거된 후, 유역변환 과정에서 남아있는 마커들이 제거된 마커가 확장해야 할 영역까지 포함하기 때문에 발생하는 현상이다.

제안한 기법의 전체 알고리즘은 영역과 경계 기반의 유역변환 알고리즘에 기반을 두기 때문에 기존 기술들에 비해 영역적인 측면에서 안정된 결과를 보여준다. 특히 다른 클러스터링 연계 방식에서 발생하는 얼룩 조각 또는 얼룩 번짐 현상이 상당히 제거되어, 분할의 성능이 개선되었음을 알 수 있다.

#### 4.5 수행 시간 비교

제안한 기법은 클러스터링에 있어 영상 전체의 화소 집합이 아닌 마커에 해당하는 화소만을 분류하므로, 계산의 복잡도 측면에서 성능을 비교할 수 있다. 성능 비교를 위해 Chang 등[5]의 FCM 알고리즘 연계와 제안한 기법을 같은 실험 환경에서 비교한다. 표 3은 각각 10장의 2, 5, 7, 9가지 질감 영역을 가지는 실험 영상에 대해 평균 분할 시간을 기록한 자료이다. 기록된 시간은 영상입력 후, 분할완료까지의 시간을 비교기준으로 하였다.

표 3. FCM 연계 기술 간 수행 시간 비교(단위: 초)

Table 3. Time performance comparison between FCM chains.

Chain method Image Type	LAWS-FCM	GABOR-FCM	Proposed Chain
2 Texture Image	5.01	8.09	17.31
5 Texture Image	16.41	15.52	12.06
7 Texture Image	21.07	31.27	16.53
9 Texture Image	45.22	25.28	15.59
Total average time	17.54	16.03	15.37

표 3의 실험에서 기존의 기법들은 질감의 수가 늘어날수록 수행시간이 증가하는데 반하여, 제안한 기법은 전체적인 변동 폭이 일정하다. 특히 클러스터링 과정에서 5개 이상의 클러스터 설정이 필요한 영상에 대해, 제안한 기법은 빠른 수행 성능을 보여주었다. 예외로 2가지 질감 영상에 대한 제안한 기법의 수행 시간이 기존 기법들보다 느린데, 이것은 클러스터링 과정에서 복잡도가 낮은 패턴이 입력될 경우 발생하는 현상으로 제안한 기법의 마커 선택과정과, 유역 변환 과정 등에 의한 복잡도가 클러스터링의 복잡도보다 더 커지므로 발생하는 현상이다.

## V. 결론

본 논문에서는 기존의 “질감 측정-클러스터링” 연계에서 발생하는 계산 복잡도 문제와 클러스터링 특유의 분할 오류 문제에 대해 접근하였다. 높은 계산 복잡도를 가지는 클러스터링을 마커라는 특정 화소 집합에 대해 적용하여 복잡도를 최소화하였으며, 클러스터링이 가지는 특유의 분할 오류 문제를 해결하기 위해 전체 알고리즘을 유역변환에 기반을 두어 개선하였다. 클러스터링 기법이 영상 분할에 응용된 기존의 연구에서는 계산 복잡도 측면의 개선 시도가 없었으며, 특히 클러스터링을 이용한 질감 분할에서 흔히 나타나는 경계 부근의 얼룩 조각(blob segments), 얼룩 번짐(blob spreads) 등의 분할 오류를 개선하지 못하였다.

제안한 기법은 Brodatz의 영상을 조합하여 실험하였으며, 분할 성능에 있어서 클러스터링 특유의 분할 오류가 거의 발견되지 않았다. 영역 간 경계 해상도가 낮은 단점은 있었지만 영역적으로 안정된 분할 성능을 보여주었다. 또, FCM을 이용한 연계 기법들과 분할 시간 측면에서 비교하였을 때, 영상의 질감 수가 많거나, 복잡한 패턴의 영상 입력일수록, 제안한 기법은 빠른 수행 시간을 보여주었다.

향후 과제로, 영역 간 분할 경계가 고르지 못한 문제를 다른 마커 선택 함수를 고려하거나 클러스터링 측면에서 개선된 알고리즘을 적용할 수 있을 것이다. 특히, 분할 성능은 질감 측정의 성능에 의존하므로 가보 필터의 질감 구분

성능을 높이기 위한 필터 디자인 기법을 생각해볼 수 있다. 나아가 클러스터의 수에 있어 비모수적(non-parametric) 방법으로 개선한다면 응용에 최적인 영상 분할기법을 완성할 수 있다.



## 참 고 문 헌

- [1] N. R. Pal and S. K. Pal, "A Review on Image Segmentation Techniques," *Pattern Recognition*, vol. 26, no. 9, pp. 1277-1294, Mar. 1993.
- [2] C. H. Chen, L. F. Pau and P. S. P. Wang, *Handbook of Pattern Recognition and Computer Vision*, 2<sup>nd</sup> ed. World Scientific, 1999.
- [3] K. I. Laws, *Textured Image Segmentation*, Ph.D. thesis, University of Southern California, 1980.
- [4] A. K. Jain and F. Farroknia, "Unsupervised Texture Segmentation Using Gabor Filters," *Pattern Recognition*, vol. 24, no. 12, pp. 1167 - 1186, 1991.
- [5] K. I. Chang, K. W. Bowyer and M. Sivagurunath, "Evaluation of Texture Segmentation Algorithms," *Computer Vision and Pattern Recognition*, vol. 1, pp. 294-299, Jun. 1999.
- [6] M. Tuceryan, "Moment Based Texture Segmentation," *Pattern Recognition Letter*, vol. 15, issue 7, pp.659-668, Jul. 1994.
- [7] D. A. Clausi and B. Yue, "Texture Segmentation Comparison Using Grey Level Co-occurrence Probabilities and Markov Random Fields," *Pattern Recognition*, vol. 1, pp. 584-587, Aug. 2004.
- [8] D. A. Clausi and H. Deng, "Design-Based Texture Feature Fusion Using Gabor Filters and Co-Occurrence Probabilities," *IEEE Trans. Image Process.*, vol. 14, issue 7, pp. 925-936, Jul. 2005.
- [9] D. A. Clausi, "K-means Iterative Fisher (KIF) Unsupervised Clustering Algorithm Applied to Image Texture Segmentation," *Pattern Recognition*, vol. 35, issue 9, pp. 1959-1972, Sep. 2002.
- [10] H. S. Rhee and K. W. Oh, "A Validity Measure for Fuzzy Clustering and Its Use in Selecting Optimal Number of Clusters," *IEEE Proc. Fuzzy Systems.*, vol. 2, pp.

- 1020-1025, Sep. 1996.
- [11] A. M. Bensaid, L. O. Hall and J. C. Bezdek, "Validity-Guided (Re)Clustering with Applications to Image Segmentation," *IEEE Trans. Fuzzy Systems.*, vol. 4, issue 2, pp. 112-123, May. 1996.
- [12] Y. T. Qian and R. C. Zhao, "Robust Clustering Based on Global Data Distribution and Local Connectivity Matrix," *IEEE ICIPS.*, vol. 2, pp. 1629-1633, Oct. 1997.
- [13] H. Frigui and R. Krishnapuram, "A Robust Competitive Clustering Algorithm With Applications in Computer Vision," *PAMI.*, vol. 21, issue 5, pp. 450-465, May 1999.
- [14] 유현재, 안강식, 조석제, "평균내부거리를 적용한 퍼지 클러스터링 알고리즘에 의한 영상분할," 한국정보처리학회 논문지, 제7권, 제9호, pp. 3029-3036, Sep. 2000.
- [15] P. Brodatz, *Textures: A Photographic Album for Artists and Designers*, Dover Publications, New York, 1966.
- [16] 김상운, 패턴인식 입문, 홍릉과학출판사, 1997.
- [17] 장재영, Gabor 필터를 이용한 Texture Segmentation 기법, 석사학위논문, 한양 대학교, 1999.
- [18] B. S. Manjunath and W. Y. Ma, "Texture Features for Browsing and Retrieval of Image Data," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 18, pp. 837-842, Aug. 1996.
- [19] A. C. Bovic, M. Clark, and W. S. Geisler, "Multichannel Texture Analysis Using Localized Spatial Filters," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 12, pp. 55 - 73, Jan. 1990.
- [20] 박현, 다채널 가보 필터와 Log-Polar 변환을 이용한 내용기반 영상 검색, 석사학위 논문, 한양대학교, 2000.
- [21] P. Soille, *Morphological Image Analysis : Principles and Applications*, Springer, 1999.
- [22] L. Vincent and P. Soille, "Watersheds in Digital Spaces : An Efficient Algorithm based on Immersion Simulations," *PAMI.*, vol. 13, no. 6, pp. 583-589, 1991.

- [23] R. C. Gonzalez and R. E. Woods, *Digital image processing*, Pearson Education, 2003.
- [24] B. S. Manjunath and W.Y. Ma, Feature Extraction and Gabor Filtering, <http://vision.ece.ucsb.edu/texture/software>, 2006. 5.
- [25] J. Abonyi, B. Balasko and B. Feil, Fuzzy Clustering and Data Analysis Toolbox, <http://www.fmt.vein.hu/softcomp/>, 2006. 8.
- [26] X. Gong and N. K. Huang, "Texture Segmentation using Iterative Estimate of Energy States," *Pattern Recognition*, vol. 1, pp. 51-55, Nov. 1988.



## 감사의 글

먼저 지도교수이신 송하주 교수님께 깊은 감사를 드립니다. 그리고 영상처리라는 전공을 선택하게 해주시고 많은 배려와 관심을 아끼지 않으셨던 김종남 교수님께도 감사드립니다. 수많은 날을 연구실에서 지새우며 힘들기도 했지만, 그만큼 쉽게 얻기 힘든 지식과 문제 해결 능력을 키울 수 있었던 소중한 시간이었습니다.

연구실의 든든한 아버지 같은 존재이셨던 문광석 교수님, 부드러운 말투로 강의실을 이끄시던 우종호 교수님, 저의 부족한 논문을 세세하게 검토해주셨던 권기룡 교수님, 제가 부족한 게 많은데도 인자하게 대해주시던 신봉기 교수님, 항상 학생들을 배려해주시던 조우현 교수님, 중후한 멋이 일품이신 정목동 교수님 그리고 그동안 많은 가르침을 주셨던 학과의 모든 교수님들께 감사드립니다.

연구실에서 영상처리의 틀을 닦아놓으셨던 경원선배, 같이 매일 동고동락했던 태경선배와 용재선배, 졸업준비에 바빠질 영선누나, 입학 전부터 바빠진 원희, 열심히 밤새고 있을 석호, 영웅, 성연, 이 모두에게 감사의 마음을 전합니다. 그리고 동기 현동형, 승희형, 득룡형, 규희 모두 원하는바 이루길 바랍니다.

제가 하는 모든 일을 항상 믿고 지켜봐주던 어머니, 누나, 남태형에게도 감사의 말을 전합니다. 항상 지친 대학원 생활에 찾아와 활력소가 되어주었던 기훈, 호준, 노력이라는 길을 알게 해준 원정, 공부하느라 바쁜 민규, 상민, 외로울 때 힘이 되어주는 미경과 수원, 마도로스 준희, 상필 모든 친구들의 앞길에 무한한 발전이 있길 기원합니다.

2007년 2월 황진호 드림