

# 다중점 적합성 피드백방법을 이용한 영역기반 이미지 유사성 검색

김 덕 환<sup>†</sup> · 이 주 흥<sup>‡</sup> · 송 재 원<sup>\*\*\*</sup>

## 요 약

질의 이미지의 시각적 특징이 사용자의 상위 수준 개념을 잘 표현하지 못하기 때문에 이미지 검색 시스템의 성능은 보통 매우 낮다. 의미적으로 유사한 이미지들이 매우 다른 시각적 특징을 보일 수도 있으며 따라서 여러 개의 군집에 분산될 수 있다. 본 논문에서는 영역기반 이미지 검색과 군집-합병을 이용한 새로운 적합성 피드백 방법을 결합한 내용기반 이미지 검색 방법을 제안한다. 주요 목표는 의미적 차이를 줄이기 위해 의미적으로 관련된 군집들을 찾는 것이다. 제안된 방법은 영역기반 군집 과정과 군집-합병 과정으로 이루어진다. 적합한 이미지들의 모든 분할된 영역들을 의미적으로 관련된 계층적인 군집으로 구성한다. 잠재된 군집의 개수를 결정하고 근접한 군집들을 합병한 후 최종 군집의 대표점들로 다중 질의를 표현한다. 군집-합병 과정에서 군집의 개수를 찾고 고차원에서 특이점 문제를 해결하기 위하여 호텔링의  $r^2$  대신에 v개의 주성분을 이용하는  $T^2$ 를 적용하였으며  $T^2$ 의 성능과  $r^2$ 의 성능의 차이가 없음을 보인다. 실험 결과는 제안된 방법이 내용기반 이미지 검색 시스템의 성능을 개선하는 데 효율적임을 보여준다.

**키워드 :** 적합성 피드백, 이미지 데이터베이스, 군집-합병, 영역기반 이미지검색

## Region Based Image Similarity Search using Multi-point Relevance Feedback

Deok-Hwan Kim<sup>†</sup> · Ju Hong Lee<sup>‡</sup> · Jae-Won Song<sup>\*\*\*</sup>

## ABSTRACT

Performance of an image retrieval system is usually very low because of the semantic gap between the low level feature and the high level concept in a query image. Semantically relevant images may exhibit very different visual characteristics, and may be scattered in several clusters. In this paper, we propose a content based image retrieval approach which combines region based image retrieval and a new relevance feedback method using adaptive clustering together. Our main goal is finding semantically related clusters to narrow down the semantic gap. Our method consists of region based clustering processes and cluster-merging process. All segmented regions of relevant images are organized into semantically related hierarchical clusters, and clusters are merged by finding the number of the latent clusters. This method, in the cluster-merging process, applies  $T^2$  using v principal components instead of classical Hotelling's  $r^2$  [1] to find the unknown number of clusters and resolve the singularity problem in high dimensions and demonstrate that there is little difference between the performance of  $T^2$  and that of  $r^2$ . Experiments have demonstrated that the proposed approach is effective in improving the performance of an image retrieval system.

**Key Words :** Feedback, Image Database, Cluster-merging, Region-based Image

## 1. 서 론

컴퓨터 비전, 정보검색과 데이터베이스 관리 기술의 발전과 더불어 내용기반 이미지 검색(CBIR)을 위한 적합성 피드

백에 대한 상세한 연구가 진행되어 왔다. 내용기반 이미지 검색 시스템은 이미지를 특징 공간상의 벡터들로 표현하고 색인하기 위하여 색상 히스토그램, 색상 레이아웃, 질감과 같은 시각적인 속성을 사용한다. 각 이미지는 특징 공간상의 데이터 점으로 볼 수 있다. 마찬가지로, 질의 이미지는 같은 특징 공간상의 질의점으로 사상된다.  $k$ -최근접 질의는 질의점에 근접한  $k$ 개의 데이터 점에 대응하는 이미지들을 검색하는 것에 의해 수행된다. 즉, 특징 공간에서 두 벡터들이 가까울수록 대응하는 이미지들은 더욱 유사해진다.

\* 본 연구는 정보통신부 및 정보통신연구진흥원의 대학 IT 연구센터 육성·지원 사업의 연구결과로 수행되었음.

† 정 회원: 인하대학교 전자전기공학부 부교수

‡ 종신회원: 인하대학교 컴퓨터공학부 부교수

\*\*\* 준회원: 인하대학교 대학원 석사과정

논문접수: 2006년 5월 17일, 심사완료: 2006년 10월 9일

그러나, 질의 이미지에 대한 저-수준의 특징이 고-수준의 사용자의 개념을 표현하지 못하기 때문에 검색 시스템의 성능은 매우 낮은 편이다. 이러한 문제를 해결하기 위해 CBIR의 최근 연구는 세 가지 기술에 집중되고 있다: (1) 영역기반 CBIR [10, 16], (2) 적합성 피드백을 이용한 CBIR [4, 6, 11, 14], (3) 온톨로지를 이용한 감성기반 CBIR[5]. 그러나, 영역기반 CBIR과 적합성 피드백을 결합한 방법에 대한 연구[8]는 거의 없는 실정이다. 첫번째, 영역기반 이미지 검색 시스템은 객체 수준에서 이미지들을 표현하므로 색상 히스토그램과 색상 레이아웃 등의 저-수준 특징표현의 단점을 극복할 수 있다. 영역기반 검색 시스템은 이미지를 영역으로 분할하기 위하여 이미지 세그멘테이션을 적용한다. 즉, 분할이 이상적이라면 영역은 객체를 나타내며, 객체 수준의 특징 표현이 사용자의 개념에 더 근접하게 된다.

두번째, 적합성 피드백에 기초한 검색 방법은 질의 이미지에 내포된 사용자의 개념과 저-수준 특징간의 의미적 차이를 줄일 수 있다. 이 기법은 각 단계에서 사용자와 상호 작용한다. 사용자는 이전 단계에서 검색된 이미지들의 집합 안에 있는 적합한 이미지들을 확인하여 결과를 평가한다. 시스템은 현재 질의를 수정하기 위해 사용자가 평가한 피드백 정보를 이용하고 다음 단계의 검색 결과를 개선한다. 이 과정은 사용자가 결과에 만족할 때까지 반복된다.

적합성 피드백에 대한 초기 연구[6, 14]는 새로운 질의를 특정 공간상의 하나의 점으로 표현하고 최적 질의점과 최적 거리함수를 찾기 위해 특징성분의 가중치를 변화시킨다. 피드백의 매 단계마다 적합한 이미지들의 가중 평균이 다음 단계의 새로운 질의점이 된다. 반면에, 최근의 다중점 질의에 대한 연구[4, 11]는 사용자 피드백에 따른 적합한 점들을 군집으로 묶고 군집의 대표들을 새로운 질의로 사용하였다.

사용자에 의해 인식된 이미지들간의 유사도는 특정 공간에서 이미지들간의 거리와 일치하지 않을 수도 있다. 즉, 의미적으로 연관된 이미지들이 매우 다른 시각적 특성을 나타내는 경우, 이미지들은 특징공간에서 하나가 아닌 여러 개의 군집에 분산될 수도 있다. 이와 같은 관점에서 의미적 차이(semantic gap)를 줄이는 문제는 의미적으로 연관된 군집들을 찾는 문제가 된다. 본 논문에서는 영역기반 유사성 검색을 위하여 내재된 군집의 개수를 예측하고 군집-합병 알고리즘을 이용하는 적합성 피드백 방법을 제안한다.

본 논문은 다음과 같이 구성된다. 2절은 내용기반 이미지 검색에 대한 관련연구를 기술한다. 3절은 제안한 영역기반 이미지 유사성검색 알고리즘과 영역기반 유사성 측정 함수를 각각 설명한다. 상세한 군집-합병 방법을 4절에 기술한다. 5절에서 실험결과를 기술하고 6절에서 결론을 기술한다.

## 2. 관련연구

내용기반 멀티미디어 검색에 대한 초기 연구[2]는 시각적 유사성에 대한 사용자의 인식에 기초한 질의와 검색 모델을 적용시키지 않았다. 즉, 질의 이미지에 대한 저-수준의 시각

적 특징이 고-수준의 사용자의 개념을 표현하지 못하는 의미적 차이(semantic gap)문제로 인해 검색의 성능은 만족스럽지 못하였다.

이 문제를 해결하기 위하여, 다양한 적합성 피드백 방법들[4, 6, 11, 14]과 영역기반 이미지 검색 방법들[10, 16]이 제안되었다. 적합성 피드백을 이용한 방법들은 고-수준 개념들과 저-수준 특징을 연관시키고 사용자의 피드백을 이용하여 사용자의 주관적인 인식을 학습한다. 적합성 피드백에서 학습해야 할 두 가지 성분은 거리함수와 새로운 질의점이다. 거리함수는 특징 성분의 가중치를 학습함에 따라 변화되며, 새로운 질의점은 사용자가 찾고 있는 이상적인 점을 학습함으로써 얻어진다.

질의점 이동 방법은 MARS[14]와 MindReader[6]와 같은 이미지 검색 시스템들에 적용되었다. 이 시스템들은 질의를 특정 공간에서 하나의 점으로 표현하며 이점을 좋은 매치를 통해 이동되도록 하고 나쁜 결과 점들로부터는 멀어지도록 한다. 이 아이디어는 원래 문헌 검색에서 성공적으로 사용된 로치오의 공식[12]으로부터 유래된다. 이 방법에서, 질의 점의 각 차원에 가중치를 주는데, 이 값은 각 차원상의 적합한 점들의 특징값의 분산에 반비례한다. MARS는 질의를 표현하는 타원의 주축이 좌표축과 일치하는 가중치-유클리디언 거리를 사용한다. 반면에, MindReader는 축의 회전이 가능하여 임의의 방향을 갖는 타원에도 잘 적용할 수 있는 일반화된-유클리디언 거리를 이용한다.

최근에, 다중점 적합성 피드백을 이용한 질의 정제 방법이 제안되었다. MARS의 질의 확장(query expansion) 방법[11]은 적합한 점들에 대한 군집을 구성한다. 이 방법에서, 모든 군집들을 대표하는 모든 질의점들로부터 유사한 정도를 표현하는 하나의 큰 등고선을 형성한다. 다른 한편, 질의-점 이동 방법 [6, 14]은 군집들을 무시하고 모든 적합한 점들로부터 하나의 질의점을 계산한다. 이 두 방법들은 단순 질의에서 모든 질의점을 포함하기 위해 하나의 초평면-타원이나 특징공간상의 군집들을 이용한 볼록 형태를 만든다. 그러나, 두 방법들은 복잡한 질의를 위한 적절한 영역을 찾는 데 실패한다.

전역 특징들만을 사용하는 위의 전통적인 방식과 달리, 이미지 분할을 적용하여 이미지들을 객체수준으로 표현하는 영역기반 이미지 검색 방법들[6, 10, 16]에 대한 연구가 활성화되고 있다. 영역 특징들을 이용하는 목적은 이미지내용에 대한 사용자의 인식을 잘 표현하고자 함이다. 이를 위하여, 영역기반 이미지 유사성 함수들이 제안되었다 [6, 10]. WALRUS 시스템[10]은 두 이미지간의 유사한 영역들이 차지하는 면적의 비율 관점에서 두 이미지간의 유사성 측정함수를 정의한다. 한편, SIMPLIcity [16]는 영역 특징을 활용하여 검색의 정확도를 높이기 위하여, IRM(Integrated Region Matching)이란 매칭 연산을 이용하여 영역 쌍간의 유사도에 대한 가중치의 합을 구한다. 최근에는 두 가지 방법을 결합한 방법에 대한 연구가 활발해지고 있다. Jing 등[8]은 MARS의 질의점 이동 방법과 질의 확장 방법을 각각 적용한 사용자 피드백 방식과 영역기반 이미지 검색을 결합한 모델을 제시하였다.

최근에는 내용기반 이미지 검색의 의미적 차이(semantic gap)문제를 해결하기 위하여 온톨로지(ontology)를 이용한 기법들 [5]이 연구되고 있다. 기존의 저차원 시각정보 특징을 고려한 내용기반 이미지 검색 방법은 사용자의 취향이나 감성 요구에 적합한 결과를 검색하기에는 많은 어려움이 있다. Hare 등[5]은 색상으로부터 유추될 수 있는 감성 용어 시소러스(thesaurus)를 기반으로 온톨로지를 구축하여 감성 기반 이미지 검색방법을 제안하였다.

### 3. 적합성 피드백을 이용한 영역기반 이미지 유사성검색

본 논문에서는 영역에 기반하여 계층 군집과 군집-합병 방법을 사용하는 다중점 적합성 피드백 방법을 제안한다.

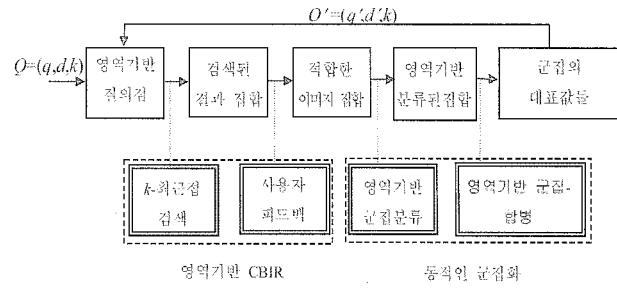
#### 3.1 영역기반 이미지 검색 알고리즘

다중점 질의를 위한 적합성 피드백 알고리즘은 다음과 같다:

```
(알고리즘 1) 영역기반 이미지 검색을 위한 k-최근접 질의
입력: 질의 예제 출력: k 검색된 이미지들
Begin
1. 초기 질의 이미지를 사용하여  $Q=(q, d, k)$ 를 정한다.
2. 다중 대표값  $Q$ 에 거리함수  $emd(Q, p)$ 를 사용하여  $k$ -최근접
질의를 수행하고 질의 결과  $Result(Q)=\{p_{l_1}, \dots, p_{l_{n_1}}, \dots, p_{k_1}, \dots, p_{k_{n_k}}\}$ 를 구한다.
3. For 이미지  $p_j \in Result(Q)$   $p_j$ 가 적합하다고 선택되는
경우..  $Relevant(Q)=Relevant_{previous}(Q) \cup \{p_j\}$ 
4. End for
5.  $Relevant(Q)$ 에 있는 이미지들에 대해 초기에는 계층적
군집방법으로 군집을 구성하며 이후 단계에서는
군집-분류 방법을 적용한다.
6. For 각 군집  $C_i$ 에 대하여,
7. 중심, 공분산과 가중치를 계산한다.
8. End for
9. For  $T^2$  함수를 적용하여 잠재적인 군집들의 개수를
찾는다.
10. 군집의 개수만큼 가까운 군집들을 합친다.
11. End for
12. 수정된  $Q'=(q', d', k)$ 를 사용하여 단계2부터 검색을
반복한다.
End
```

제안한 영역기반 이미지 유사성검색 알고리즘을 (그림 1)을 이용하여 자세히 설명한다. 전처리 단계에서 모든 이미지들은 이미지분할방법을 사용하여 다수의 영역들로 나누어지며, 각 영역들에 대한 특징 벡터를 추출하여 데이터베이스에 저장한다.

처음 단계에서, 사용자에 의해 제출된 예제 이미지는 초기 질의  $Q=(q, d, k)$ 를 생성하기 위하여 분석된다. 여기서  $q$ 는 예제이미지를 구성하는 영역들의 특징값들로 표현되므로 특징공간상의 다수의 질의점들로 구성된다.  $k$ 는 시스템에 의하여 출력되는 질의 결과에 포함된 이미지의 개수이고  $d$



(그림 1) 적합성피드백을 이용한 영역기반 이미지 유사성검색 과정

는 거리함수이다. 질의점  $q$ 는 거리함수  $d$ 를 사용하여 데이터베이스에 있는 이미지들과 비교된다.  $d$ 에 따라서  $q$ 에 근접한  $k$ 개의 이미지들로 구성된 결과 집합,  $Result(Q)=\{p_{l_1}, \dots, p_{l_{n_1}}, \dots, p_{k_1}, \dots, p_{k_{n_k}}\}$ , 이 사용자에게 제공된다. 각 이미지가 여러 개의 영역들로 구성되므로  $p_{k_{n_k}}$ 는  $k$ 번째 이미지를 구성하는  $n_k$  번째 영역이다.

다음 단계에서, 사용자는  $Result(Q)$ 에 있는 이미지들에 적합성 점수를 매겨 그들의 적합성을 평가한다. 이 점수들에 기초하여 적합한 집합,  $Relevant(Q)=\{p'_{l_1}, p'_{l_2}, \dots, p'_{l_{m_n}}\}$ , 이 얻어진다.  $p'_{l_{m_n}}$ 은  $m$ 번째 적합한 이미지의  $n$ 번째 영역이다. 즉,  $Relevant(Q)$ 는 새로이 추가된 적합한 이미지들과 이전 반복 단계의 적합한 이미지들을 포함하게 된다. 새로이 추가된 적합한 이미지들은 사용자의 질의 개념을 더 정확하게 반영 하므로, 이전의 적합한 이미지들보다 가중치를 크게 줌으로서 이 이미지들을 더 강조할 수 있다.

본 논문에서 영역기반 군집과정과 군집-합병 과정의 두 가지 과정을 구성하는 새로운 동적인 군집 방법을 제안한다. 점점 더 많은 적합한 이미지들이 추가됨에 따라 질의에 포함되는 영역들의 개수는 빠르게 증가한다. 질의와 이미지 간의 Earth Mover 거리(EMD)[13]를 계산하는 데 필요한 시간은 질의에 포함된 영역의 개수에 비례한다. 시스템의 검색 속도를 줄이기 위하여 영역기반 군집과정은 적합한 이미지들의 집합,  $Relevant(Q)$ ,에 속한 유사한 영역들을 합친다. 계층군집 알고리즘을 사용하여  $Relevant(Q)$ 에 속한 영역들을 다음 질의의 영역에 대응하는 몇 개의 군집들로 묶어준다. 그 다음에 제안된 군집-합병 과정을 이용하여 내재된 군집의 개수를 추정하고 같은 계층에 속한 근접한 군집들을 합병하여 군집의 개수를 줄인다. 즉, 제안된 군집-합병 알고리즘은 다음 반복단계를 위하여 적합한 이미지들로부터 생성된 군집들의 대표들을 이용하여 새로운 질의점을 형성한다. 새로운 질의점  $q'$ 와 수정된 가중치를 반영하는 새로운 거리함수  $d'$ 을 가지고 있는 새로운 질의  $Q'=(q', d', k)$ 가 계산되며 다음 반복단계를 위한 입력으로서 사용된다.

일정한 반복단계 후에  $Q_{opt}=(q_{opt}, d_{opt}, k)$ 가 최적 질의 일 때  $Result(Q_{opt})$ 에 근접한 최종 결과를 얻게 되면 검색이 종료된다.

본 논문에서는 정규화된 컷(normalized cuts)이미지 분할

방법[15]을 사용하여 이미지에 포함된 객체를 구별하는 영역들로 이미지를 분할한다. 즉, 이미지는 객체를 포함하는 다수의 영역들로 표현된다. 제안한 영역기반 검색은 여러 개의 객체(영역)들로 질의를 구성하는 것을 허용하며 이 것을 다중점 질의라고 한다. 사용자가  $k$ -최근접 질의 결과 이미지를 중 적합한 이미지들을 선택하면 그 이미지들을 구성하는 영역들이 적합한 점들이 된다. 그리고, 적합한 점들로 군집을 만들고 군집의 중심을 대표로 선택한다. 이 과정에서 최적의 군집의 개수를 예측하여 군집-합병과정을 거친 다음 만들어진 대표점들을 사용하여 다중점 질의를 구성한다. 영역기반 동적 군집 과정에서 계층적인 트리 구조를 구성하며 동적인 군집 방법이 검색 효율을 개선하기 위하여 사용된다. 새로이 적합한 이미지들이 추가될 때 이전의 적합한 이미지들은 변하지 않으므로 이전 단계에서 계산된 각 군집의 평균, 분산을 이용하여 현재의 군집들에 대한 통계량을 계산함으로서 소요 시간을 줄일 수 있다. 군집-합병 과정에서 호텔링의  $T^2$  [3]를 변형한  $T_v^2$  함수는 임의의 형태의 군집 쌍을 합치고 주어진 질의에 대하여 군집의 개수를 구하는 데 사용된다.

### 3.2 영역기반 이미지 유사성 측정함수

질의 이미지에 대해 유사한 이미지를 검색하기 위해, Earth Mover의 거리함수(EMD)[13]가 영역 표현에 기반한 두 이미지들간의 거리를 측정하기 위해 사용된다. 이 함수는 가변 길이를 갖는 특징 표현에 적용할 수 있기 때문에 두 이미지의 영역의 개수가 서로 다른 경우에도 거리를 측정할 수 있다. 사용자가 적합성 피드백의 각 단계에서 이미지를 중 적합한 이미지들을 표시하면, 시스템은 그들을 군집하고 군집의 중심을 대표값으로 선택한다. 유사한 영역들은 군집하는 과정에서 합쳐지며 합성된 이미지들이 다중점 질의를 형성한다. EMD의 signature는 군집들에 대응하는 영역들을 가진 합성 이미지이다. 유클리디언 거리가 두 영역 사이의 기준 거리를 측정하기 위해 사용되며 각 signature의 전체 가중치는 1이다. 영역의 크기를 signature의 가중치로 사용한다.

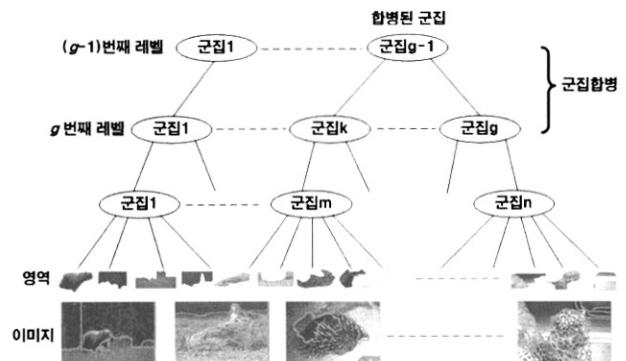
## 4. 동적인 군집을 이용한 적합성피드백

이 절에서, 질의와 의미적으로 연관된 군집들을 찾기 위한 새로운  $T_v^2$ 함수를 제안하고 군집-합병 알고리즘을 기술한다. 찾아진 군집의 대표값들은 영역기반 이미지 검색의 다음 반복 단계에서 질의점들로 사용된다.

### 4.1 영역기반 계층적 군집 과정

계층적 군집 방법이 계층적 트리 구조로 적합한 이미지들을 구성하기 위해 사용된다. 첫번째 반복단계에서 (그림 2)와 같이 적합한 이미지들의 모든 영역들에 대한 초기 군집들을 이용하여 계층 구조를 만든다. 군집의 계층구조에서  $g$  레벨에는  $g$ 개의 군집이 대응된다.

군집 알고리즘은 데이터를 초평면 구형 영역들로 데이터를 묶어준다. 일단 초기 군집이 만들어지면, 평균벡터  $\bar{x}$ , 가중치 공분산 행렬  $S$ 를 계산한다. 평균 벡터는 초평면 타원의 위치를 결정한다. 반면에 공분산 행렬은 형태와 방향을 나타낸다. 반복단계의 피드백 과정에서 사용자는 각 이미지  $x$ 에 대해 점수값  $v$ 를 표시한다. 현 반복단계의 군집-합병 과정 뒤에  $x$ 가  $i$ 번째 군집  $C_i$ 의  $k$ 번째 점이 되면  $v$ 는  $v_{ik}$ 가 된다. 각 군집  $C_i$ 의 상대적인 가중치  $m_i$ 는 각 군집에 있는 점들의 적합성 점수들의 합,  $m_i = \sum_{k=1}^{n_i} v_{ik}$  으로 정해진다.



(그림 2) 적합한 이미지들의 영역에 대한 계층적 군집 구성

### 4.2 군집-합병을 위한 $T_v^2$

두 군집의 근접 여부를 검사하기 위하여 널리 알려진 호텔링의  $T^2$  통계량 [3]을 이용할 수 있다.  $T^2$ 함수는 두 평균 벡터  $\bar{x}_i, \bar{x}_j$ 의 근접 정도로부터 통계적으로 두 군집의 합병 여부를 추론한다. 통계적 가설검정을 위하여, 다음과 같이 정의한다:

$i$ 번째 군집의 점들  $x_{i1}, x_{i2}, \dots, x_{in_i}$ 을 평균벡터  $\mu_i$ , 공분산 행렬  $S_i$ 인 모집단으로부터 크기  $n_i$  인 확률 표본이라고 한다.  $j$ 번째 군집의 점들  $x_{j1}, x_{j2}, \dots, x_{jn_j}$ 을 평균벡터  $\mu_j$ , 공분산 행렬  $S_j$ 인 모집단으로부터 크기  $n_j$  인 확률 표본이라고 한다.  $x_{i1}, x_{i2}, \dots, x_{in_i}$  와  $x_{j1}, x_{j2}, \dots, x_{jn_j}$ 는 서로 독립이다.

두 군집의 모집단의 공분산이 거의 같다고 가정하기 때문에 공통 분산을 추정하기 위하여 표본의 공분산을 사용한다. 대상이 되는 두 군집이 평균 벡터  $\bar{x}_i, \bar{x}_j \in \mathbb{R}^p$ , 공분산 행렬  $S_i, S_j$ , 군집의 원소의 개수  $n_i, n_j$ , 군집의 가중치  $m_i, m_j$ 를 각각 갖고 있을 때, 호텔링의  $T^2$  통계량은 다음과 같이 정의된다 [3]:

### (정의 1) 호텔링의 $T^2$ 함수

$$T^2(\bar{x}_i, \bar{x}_j) = \frac{m_i m_j}{m_i + m_j} (\bar{x}_i - \bar{x}_j)' S_{pooled}^{-1} (\bar{x}_i - \bar{x}_j) \quad (1)$$

$$S_{pooled} = \frac{1}{m_i + m_j} \left( \sum_{k=1}^{n_i} v_{ik} (x_{ik} - \bar{x}_i)' (x_{ik} - \bar{x}_i) + \sum_{k=1}^{n_j} v_{jk} (x_{jk} - \bar{x}_j)' (x_{jk} - \bar{x}_j) \right)' \quad (2)$$

대용량 이미지 데이터베이스에서는 이미지의 시각적 특징을 고차원 벡터로 표현한다. 따라서 데이터의 차원이 데이터의 개수보다 클 경우  $T^2$  함수에서 사용되는 공분산의 특이 점(singularity) 문제가 발생할 수 있다. 따라서 원래 데이터 대신에 차원 축소한 데이터를 사용하기 위해 주성분 분석[8]을 적용하여,  $v$ 개의 주성분을 이용한  $T_v^2$  함수를 제안한다.

#### 4.2.1 주성분 분석

$x$ 가 평균  $\mu$ , 분산  $\Sigma$ ,  $\Gamma$ 가  $\Sigma$ 의 eigenvector인  $p$ 차원 확률 벡터일 때 주성분 변환은  $z = (x - \mu)\Gamma$ 에 의해 주어진다.  $\Gamma$ 는 직교하며,  $\Gamma'\Sigma\Gamma = \Lambda$ 인 대각선에 주성분  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$ 을 갖는다.  $X = (x_1, \dots, x_n)'$  일 때,  $S$ 는  $X$ 의 표본공분산 행렬일 때,  $G$ 는  $S$ 의  $p \times p$  고유벡터 행렬이고  $L$ 은  $S$ 의 고유값 행렬이 된다.  $x_i$ 가  $R^p$  인 컬럼 벡터이고  $g_{(i)}$ 가  $G$ 의 컬럼 벡터일 때 표본 주성분은  $z_{(i)} = (X - \bar{x})'g_{(i)}$ 과 같이 정의된다. 표본공분산 행렬  $S$ 의 spectral 분해를  $S = GLG'$ 로 표현할 수 있다. 여기서, 표본 주성분을 함께 모으면  $Z = (X - \bar{x})G$ 가 된다.  $G$ 는  $(n \times p)$ 행렬을 같은 차수의 다른 행렬로 변환시킨다.  $L$ 은  $Z$ 의 공분산 행렬이다.

$$T^2(\bar{x}, \bar{y}) = C(\bar{x} - \bar{y})' S_{pooled}^{-1} (\bar{x} - \bar{y}) \text{이라고 하자.}$$

여기서,  $C$ 는 상수이고  $\bar{x}$ 와  $\bar{y}$ 는 각각  $\bar{x}_1$ 와  $\bar{x}_2$  대신에 사용된다.  $COV_{pooled}(x, y)$ 는  $x, y$ 의 공통 공분산이며, 식(3)과 같이  $L$ 로 나타낼 수 있다.

$$COV_{pooled}(G'x, G'y) = G'S_{pooled}(G')' = G'S_{pooled}G = G'(GLG')G = L. \quad (3)$$

따라서, 고유벡터를 적용한 경우의  $T^2$  함수값은 원래 벡터의  $T^2$  함수값과 같게 된다.

$$\begin{aligned} T^2(G'\bar{x}, G'\bar{y}) &= C(G'\bar{x} - G'\bar{y})'(G'S_{pooled}^{-1}G)^{-1}(G'\bar{x} - G'\bar{y}) \\ &= C(\bar{x} - \bar{y})'G(G'S_{pooled}G)^{-1}G'(\bar{x} - \bar{y}) = T^2(\bar{x}, \bar{y}) \end{aligned} \quad (4)$$

그 이유는  $T^2$ 함수가 선형변환에 불변이라는 사실을 증명하여 보일 수 있다.

(정리 1)  $\bar{x} = (x_1, \dots, x_p) \in R^p$  일 때  $T^2$ 은 선형변환에 불변이다.

(증명)

$$\begin{aligned} T^2(A\bar{x}) &= \frac{m_i m_j}{m_i + m_j} (A\bar{x}_i - A\bar{x}_j)' S_{pooled}^{-1} (A\bar{x})(A\bar{x}_i - A\bar{x}_j) \\ &= \frac{m_i m_j}{m_i + m_j} (\bar{x}_i - \bar{x}_j)' A' (AS_{pooled}A')^{-1} A (\bar{x}_i - \bar{x}_j) \\ &= \frac{m_i m_j}{m_i + m_j} (\bar{x}_i - \bar{x}_j)' A' (A')^{-1} S_{pooled}^{-1} A^{-1} A (\bar{x}_i - \bar{x}_j) \\ &= T^2(\bar{x}) \end{aligned}$$

즉, (정리 1)에 의하여 식(4)의  $T^2(G'\bar{x}, G'\bar{y}) = T^2(\bar{x}, \bar{y})$  이 성립한다.

#### 4.2.2 차원축소 데이터를 위한 호텔링의 $T_v^2$

식(1)과 같이 제안된 호텔링의  $T^2$  함수는 표본공분산 행렬과 이의 역행렬을 사용한다. 고차원에서의 특이점 문제를 해결하기 위하여 4.2.1절에서 설명한 주성분 분석을 이용하여 역행렬 대신에 대각선행렬을 사용하는 새로운  $T_v^2$  함수를 제안한다.  $\bar{z}_x = G'\bar{x}$ 이고  $\bar{z}_y = G'\bar{y}$ 이라고 하자.  $p$ 개의 주성분을 갖는  $T_v^2$ 의 단순한 형태는 다음과 같다:

$$\begin{aligned} T_v^2(G'\bar{x}, G'\bar{y}) &= C(\bar{z}_x - \bar{z}_y)'(G'S_{pooled}^{-1}G)^{-1}(\bar{z}_x - \bar{z}_y) = C(\bar{z}_x - \bar{z}_y)'(G'GLG'G)^{-1}(\bar{z}_x - \bar{z}_y) \\ &= C \sum_{j=1}^p (\bar{z}_{xj} - \bar{z}_{yj})^2 / \lambda_j \end{aligned} \quad (5)$$

주성분의 수를 결정하기 위하여 전체 변이에 대한 선택할 주성분들이 설명하는 변이의 비율을 이용한다 [7].

$$\frac{\lambda_1 + \dots + \lambda_v}{\lambda_1 + \dots + \lambda_k + \dots + \lambda_p} \geq 1 - \varepsilon \quad (6)$$

각  $\varepsilon \leq 0.15$ 일 때, 처음  $v \leq p$  개의 주성분을 취하였다.  $1 - \varepsilon$ 은 처음  $v$ 개의 주성분에 의해 커버되는 전체 변동의 비율이다. 여러 번의 실험 결과를 통하여 전체변이의 85% 이상을  $v$ 개의 주성분으로 설명하는 것이 타당하여 이를 임계값으로 정하였다.  $G_v$ 를 컬럼들이  $G$ 의 첫번째  $v$ 컬럼들인  $(p \times v)$  행렬이라고 하자.

(정의 2)  $\bar{z}_{xv} = G'_v \bar{x}$ 이고  $\bar{z}_{yv} = G'_v \bar{y}$  일 때  $v$ 개의 주성분을 이용한  $T_v^2$  함수

$$\begin{aligned} T_v^2(G'_v \bar{x}, G'_v \bar{y}) &= C(\bar{z}_{xv} - \bar{z}_{yv})'(G'_v S_{pooled} G_v)^{-1}(\bar{z}_{xv} - \bar{z}_{yv}) \\ &= C(\bar{z}_{xv} - \bar{z}_{yv})'(G'_v G L G'_v)^{-1}(\bar{z}_{xv} - \bar{z}_{yv}) \\ &= \sum_{j=1}^v (\bar{z}_{xvj} - \bar{z}_{yvj})^2 / l_j \end{aligned} \quad (7)$$

이 경우에,  $v$ 개의 주성분을 이용한 호텔링의  $T_v^2$ 는 계산량을 줄이는 간단한 이차식의 형태가 된다.

#### 4.3 군집-합병 과정

영역기반 군집과정 후에 군집들은 더 큰 군집들로 합병될 수 있다. (그림 2)와 같이  $g$ 개의 군집들이 주어질 때, 제안된 군집-합병 알고리즘은 합쳐질 군집의 후보 쌍을 찾는다. 알고리즘은 내재된 군집의 개수를 찾을 때까지 계속해서 합쳐질 군집 쌍을 선택한다. 합쳐질 가능성이 큰 두 군집들은 충분히 가까이 있어야 한다. 이 목적을 위하여, 그들의 평균 벡터들을 비교한다. 위치 차이를 검사하기 위한 통계적 가설검정은 다음과 같다:

$$H_0 : \mu_i = \mu_j \text{ and } H_1 : \mu_i \neq \mu_j \quad (8)$$

$\mu_i$ 는  $C_i$ 의 알려지지 않은 중심이다.  $T^2$ 함수는 두 군집의

중심  $\bar{x}_i$  와  $\bar{x}_j$  가 충분히 가까울 때 작은 값을 가지며 귀무 가설  $H_0$ 가 선택된다. 즉,  $H_0$ 가 참이면

$$T_v^2 \approx \frac{p(m_i + m_j - 2)}{m_i + m_j - p - 1} F_{p, m_i + m_j - p - 1}(\alpha) = c^2 \quad (9)$$

이 된다. 여기서,  $F_{p, m_i + m_j - p - 1}(\alpha)$ 는 자유도가  $p$ 와  $m_i + m_j - p - 1$ 인  $F$ -분포의 상위  $100(1-\alpha)$  백분율이다. 두 군집이 떨어져 있을 때는  $T^2$ 함수는 큰 값을 가지며  $T_v^2(\bar{x}_i, \bar{x}_j) > c^2$  이다. 즉,  $H_0$ 가 기각되고 두 군집은 서로 다르다고 판단하게 된다. 제안된 군집-합병 함수가 표본 공분산과 이의 역행렬을 이용하는 경우, 데이터가 다변량 정규분포를 따를 때,  $(m_i + m_j - p - 1)/p(m_i + m_j + p - 2)r^2$  은  $F(p, m_i + m_j - p - 1)$ 를 따른다. 이 통계량은 두 군집의 중심간의 마하나노비스 거리(Mahalanobis distance)로 알려져 있다.

효율적인 군집-합병을 위해, 기존 군집에 있는 점들의 매개변수 대신에 기존 군집들의 매개변수들로부터 합쳐진 군집의 매개변수를 결정한다. 군집들이 평균 벡터  $\bar{x}_i$ , 공분산 행렬  $S_i$ , 군집의 원소의 개수  $n_i$ , 군집의 가중치  $m_i$ 를 갖고 있을 때, 다음과 같은 통계량을 이용하여 군집  $i$ 와  $j$ 를 합쳐 새로운 군집을 만들 수 있다 [7]:

$$m_{new} = m_i + m_j \quad (10)$$

$$\bar{x}_{new} = \frac{m_i}{m_{new}} \bar{x}_i + \frac{m_j}{m_{new}} \bar{x}_j \quad (11)$$

$$S_{new} = \frac{m_i - 1}{m_{new}} S_i + \frac{m_j - 1}{m_{new}} S_j + \frac{m_i m_j}{m_{new}(m_{new} - 1)} [(\bar{x}_i - \bar{x}_j)(\bar{x}_i - \bar{x}_j)'] \quad (12)$$

#### (알고리즘 2) 군집 합병

입력:  $g$ 개의 군집들      출력: 합병된 군집들

Begin

1.  $\binom{g}{2}$  개의 군집 쌍에 대하여  $T_v^2$  값과  $c^2$ 값을 계산한다.
  2.  $T_v^2$ 값들 중 최소값을 갖는 군집의 쌍을 선택한다.
  3. While 최소  $T_v^2$  값  $\leq$  선택된 군집쌍의  $c^2$ 값
  4. 후보 군집 쌍을 합친다.
  5. 식(10)-(12)을 사용하여  $m_{new}$ ,  $\bar{x}_{new}$ ,  $S_{new}$ 을 계산한다.
  6. 군집의 다음 후보쌍을 선택한다.
  7. End While
- End

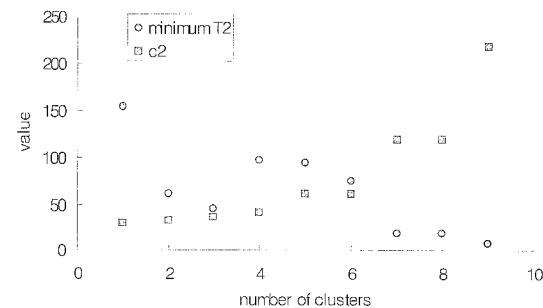
군집의 개수를 찾는 과정을 시작하기 위하여,  $(g-1)$  군집을 갖는 레벨과  $g$  군집을 갖는 레벨을 고려하자. 어떤 레벨이 더욱 최적인지 결정해야 한다.  $g$ 번째 군집 레벨에서, 어떤 군집 쌍을 합칠지 결정하기 위하여  $\binom{g}{2}$ 개의  $T^2$ 함수값을 이용한다. 임의의 군집 합병이 발생하지 않으면 군집개수  $g$ 가 군집 개수  $(g-1)$ 보다 최적값에 근접한다. 그렇지 않으면, 군집개수  $(g-1)$ 이 최적값에 더 근접하게 된다.

(정의 3)  $\vec{x} = (x_1, \dots, x_p) \in \mathbb{R}^p$  일 때 통계량  $U(\vec{x})$ 가 선형변환에 불변이라면 알고리즘은 선형 변환에 불변이다. 즉,  $A$ 가 역행렬 연산이 가능한  $p \times p$  행렬일 때  $U(A\vec{x}) = U(\vec{x})$  가 성립한다.

(정리 2) 알고리즘 2는 선형변환에 불변이다.

증명)  $T_v^2$  가 선형변환에 불변이라는 것을 증명하면 된다. 따라서 (정리 1)의 증명으로 대체할 수 있다. 이 성질 때문에, 제안된 알고리즘의 효율성이 원 또는 타원 등의 임의의 선형변환에 대해 거의 같다.

(예제 1) (그림 3)은 9개의 군집들에 대한 군집-합병 과정을 보여준다. 임의의 군집 쌍의 근접 여부를 검사하기 위하여 신뢰수준  $\alpha$ 의 초기값이 0.01로 주어질 때, 모든 군집쌍들의  $T_v^2$ 값과 대응하는 군집쌍의  $c^2$ 값들을 계산한다.  $T_v^2$ 값들 중의 최소값이 대응하는  $c^2$ 값보다 작으면 두 군집은 매우 근접하다고 보고 그들을 합친다. 반복과정에서 9개의 군집이 주어질 때 가능한 모든 군집 쌍에 대해  $T_v^2$ 값들 중의 최소값을 갖는 군집쌍을 찾는다.  $T_v^2$ 값들 중의 최소값을 갖는 군집쌍이 합쳐질 후보이며 주어진  $\alpha$ 에 대하여 그들의  $c^2$ 값을 계산한다.  $T_v^2$ 값이  $c^2$ 값보다 작으면 그들은 하나로 합쳐진다. 그러면 군집의 개수는 하나가 줄게 된다. 이 과정은  $T_v^2$ 값들 중의 최소값이  $c^2$ 값보다 클 때까지 반복된다. (그림 3)에서 조정된 군집의 개수는 6이 된다. 즉, 적절한 신뢰수준  $\alpha$ 를 선택하여 합쳐질 군집의 개수를 조정할 수 있다.



(그림 3) 군집 합병과정

## 5. 실험 및 결과

본 논문에서 제안한 방법을 실험하기 위한 시스템 구현환경으로 하드웨어 시스템은 펜티엄 3.20Ghz PC를 사용하며, 운영체제는 윈도우 2003 환경에서 C언어로 프로그램을 구현하였다.

### 5.1 실험 환경

실험은 영역기반 이미지 데이터베이스에서 다중점  $k$ -최근접 질의를 위하여 군집-합병을 이용하는 새로운 적합성 피드백 방법을 평가하는 데 초점을 두었다. 세부적인 실험은 두 가지 목표에 대해 수행된다. 첫째, 시스템의 성능을 비

교하기 위하여 제안한 방법(Adaptive Cluster)과 기존의 영역기반 이미지 검색 방법들 중 잘 알려진 질의점 이동(Query Point Movement)[8]과 점진적인 군집 방법(Incremental Cluster)[8]를 비교한다. 점진적 군집 방법의 경우, 초기에 군집의 개수를 2로 주고 반복단계에서 하나씩 증가하였다. 둘째, 잠재적 군집의 개수를 추정하기 위해 제안된  $T_v^2$  함수와 주성분을 이용하는  $T_v^2$  함수의 성능을 비교한다.

실험을 위하여 합성 데이터와 Corel 이미지 컬렉션이 시험 데이터로 사용되었다. 이미지 컬렉션은 10,000 컬러 이미지들을 포함한다. 이미지들은 전문가들에 의해 분류되어 있으며 각 카테고리(비행기, 꽃, 산, 파라미드, 석양 등)마다 10 0개의 이미지가 존재한다. 실험에서, 사용자가 하위 수준 특정 표현이 아닌 상위 수준 개념에 기초하여 이미지를 검색하기 원하기 때문에 상위 수준 카테고리 정보를 적합성 피드백을 얻기 위한 정답으로 사용한다[11]. 즉, 같은 카테고리로부터 온 이미지들을 적합하다고 생각한다.

이 실험에서 사용한 이미지 분할 방법은 정규화된 컷(normalized cuts) [15] 방법이다. 이미지의 분할은 이미지를 서로 다른 영역들로 구분한다. 각 이미지의 모든 영역을 사용하였다. 각 영역이 의미하는 객체들을 표현하기 위해 특징들을 개별적인 영역들로부터 추출하였다. 영역을 표현하기 위해 색상과 모양 그리고 가중치 정보를 특징으로 사용한다. 색상 특징으로 평균, 표준편차의 두 가지 색상 모멘트값들이  $L*a*b$  색상 공간의 각 채널로부터 추출되며, 모양 특징은 밀집도(compactness), 굴곡도(convexity), 영역의 크기, 영역의 중심 위치, 영역의 분산을 추출한 후에 주성분 분석을 사용하여 3차원으로 특징 벡터의 차원을 축소하였다. 즉, 3차원 특징 벡터를 사용하므로  $T_v^2$  함수에서  $v$ 는 3이 된다. 영역의 크기는 전체 이미지의 크기로 나누어 정규화하였으며 영역의 중심위치는 이미지 내에서의 영역의 상대적인 위치로 표현된다. 영역의 중요성을 판단하는 기준으로 영역의 크기와 중심위치를 사용하였다. 크기가 클수록, 이미지의 중앙에 가까울수록 중요한 객체라고 가정하여 영역의 가중치를 높여 준다.

실험에서, 100개의 초기 질의를 임의로 생성하였으며 초기 질의로 시작된 반복 단계를 통해 검색 성능을 평가하였다. 초기 질의 외에 5 피드백 반복 단계를 수행하며 100번의 질의 결과를 평균하였다. 유사성 검색을 위하여  $k$ -최근접 질의를 사용하였으며,  $k$ 는 100으로 정했다.

## 5.2 실제 이미지 데이터를 이용한 실험 및 분석

(그림 4)는 색상 모멘트를 특징으로 사용할 때 군집-합병 과정에서  $T_v^2$  함수를 사용하는 역행렬 방법과  $T_v^2$  함수를 사용하는 대각선 행렬 방법의 CPU 비용을 비교한다.  $T_v^2$  함수를 사용하는 대각선 행렬 방법이 CPU 시간 측면에서 역행렬 방법보다 상당히 좋은 성능을 보였다. 따라서, 기존의 적합성 피드백 방법들과 비교를 위해  $T_v^2$  함수를 사용하는 대각선 행렬 방법을 사용한다.

(그림 5)는 반복 단계마다  $T_v^2$  함수를 사용하는 대각선 행렬 방법(Adaptive Cluster), 질의점 이동(Query Point Movement)과 점진적인 군집(Incremental Cluster) 방법들의 평균 검색시간을 비교한다. 초기 질의시에 비슷한 검색시간을 보이나, 점진적으로 검색시간이 증가함을 보이며, 다섯번째 반복단계에선 질의점 이동방법이 제안한 방법보다 5배의 시간이 더 걸린다. 그 이유는 질의점 이동 방법의 경우 반복단계마다 점차적으로 적합성 피드백에 사용되는 영역의 개수가 증가하여 EMD 거리함수에 사용되는 질의점의 개수가 많아지는 데 비해, 제안한 방법은 적합한 이미지들의 영역들을 군집하고, 군집합병 과정을 거쳐 EMD 거리함수에 사용되는 질의점들을 줄이기 때문이다.

(그림 6, 7, 8)은 제안된 방법(Adaptive Cluster), 질의점 이동 (Query Point Movement)과 점진적인 군집(Incremental Cluster)방법의 precision-recall 그래프를 각각 보여준다. 이 그래프들에서, 반복 단계마다 한줄씩 나타내며, 각 줄은 100개의 검색된 이미지들에 대한 정확율(precision)과 재현율(recall)을 보이기 위해 100개의 점들로 그려진다. 이 그림들에 기초하여, 다음과 같이 두 가지 관찰을 하였다:

검색 성능은 각 단계마다 증가한다. 검색 성능은 대부분 첫번째 단계에서 가장 많이 증가하고, 그 다음 단계부터는 미미하게 증가하였다. 이 결과는 제안된 방법이 사용자의 목표에 빠르게 수렴하고 있음을 보여준다.

(그림 9)는 반복 단계마다  $T_v^2$  함수를 사용하는 대각선 행렬 방법(Adaptive Cluster), 질의점 이동(Query Point Movement)과 점진적인 군집(Incremental Cluster) 방법들의 재현율을 비교한다. 초기 질의시에 같은 재현율 (0.312)을 보인다. 제안된 방법은 첫번째 단계부터 좋은 성능을 보이며, 다섯 단계 이후의 평균 재현율은 질의점 이동 방법보다 19% 그리고 점진적인 군집 방법보다 10%의 성능 이득을 보인다. (그림 9)는 또한 첫번째 단계의 평균 재현율과 비교할 때 다섯 단계 후의 평균 재현율의 증가비율이 제안한 방법은 63%, 질의점 이동 방법의 경우 37%, 점진적인 군집 방법의 경우는 50%임을 보여준다. 이 결과는 제안한 방법이 가장 좋은 재현율을 보일 뿐만 아니라 가장 빠른 성능 향상을 제공함을 나타낸다.

(그림 10)과 (그림 11)은 비행기 카테고리에 속한 표본 질의에 대한 첫번째, 다섯번째 반복단계에서의 질의 결과를 각각 보여준다. 질의 이미지는 원쪽상단에 보여진다. 지면의 제약 때문에,  $k$ -최근접 질의( $k=100$ )의 결과중 질의 이미지와 10개의 결과 이미지만을 보인다. 다섯 번째 반복된 결과가 더 좋은 성능을 보여준다.

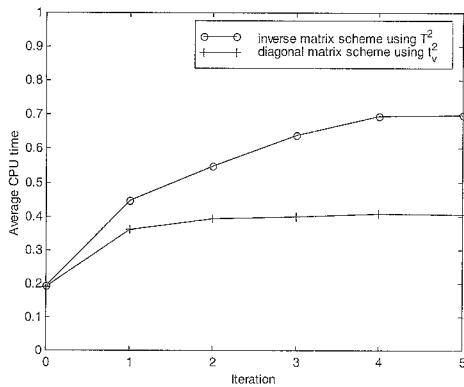
## 5.3 합성 데이터를 이용한 실험 및 분석

두번째로 합성 데이터를 이용하여 군집-합병 알고리즘의 정확성을 측정하기 위해 세부적인 실험을 수행하였다.  $z=(z_1, \dots, z_p) \in \mathbb{R}^p$ 이고 정규분포  $N(0,1)$ 라고 하자.  $z$ 는 평균 0과 공분산 행렬  $I$ 를 갖는 다변량 정규분포를 따르며  $z$ 의 데이터 형태는 구형이다.  $y = Az$ 이라고 하자. 그러면  $Cov(y) = AA'$

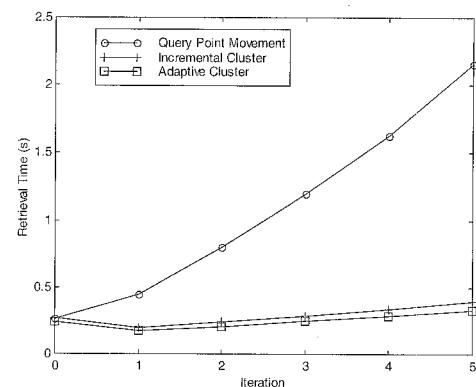
'이고  $y$ 의 데이터 형태는 타원이다.  $\mathbb{M}^{16}$ 에서 합성 데이터가 생성된다. 데이터는 3개의 군집을 구성하며 군집간 거리는 0.5에서 2.5로 변화된다. 주성분 분석을 사용하여 16차원에서 12, 9, 6, 3차원으로 축소할 수 있다.

다음에, 12, 9, 6, 3차원 데이터에 대하여 군집-합병 알고리즘의 정확성을 측정하기 위하여 역행렬을 사용한  $T^2$  함수의 오류비율과 대각선 행렬을 사용하는  $T_v^2$  함수의 오류비율을 계산한다. 크기 30인 100쌍의 군집이 주어질 때, 100  $T^2$

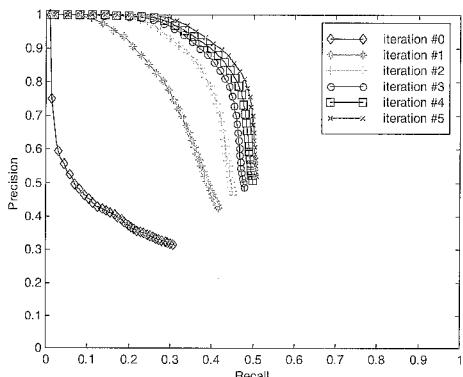
값과 대응하는 임계 거리값 ( $c^2$ )이 계산된다. <표 1>과 <표 2>의 quantile-F값들은  $p$ 가 차원이고  $n$ 이 개체의 수일 때 95% 확률로 주어지는 임계 거리값이다.  $T^2$ 값이 대응하는  $c^2$  값보다 클 때  $H_0$ 를 기각한다. 즉, 두 군집이 분리되어야 한다고 결정하게 된다. 두 군집이 가까운 경우에 그들을 분리한다면 오류율은 증가한다. <표 1>과 <표 2>는 역행렬을 사용한  $T^2$ 와 대각선 행렬을 사용한  $T_v^2$ 에 대하여 12, 9, 6, 3 차원 데이터의 평균값과 평균 오류비율(%)를 보여준다.



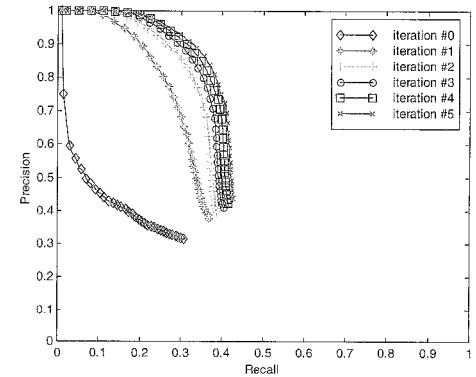
(그림 4) 제안된 방법에서 역행렬 및 대각선행렬 사용시 CPU 시간



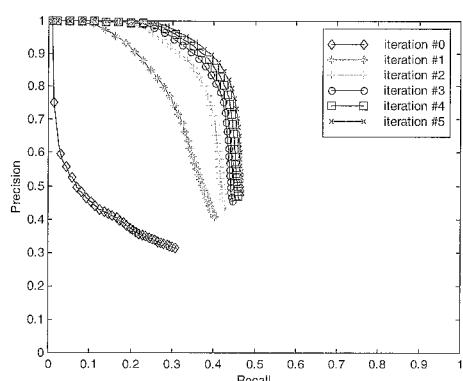
(그림 5) 검색시간 비교



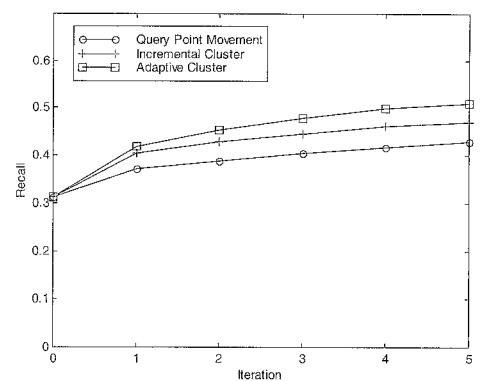
(그림 6) 제안된 방법(adaptive Cluster)의 정확률과 재현율



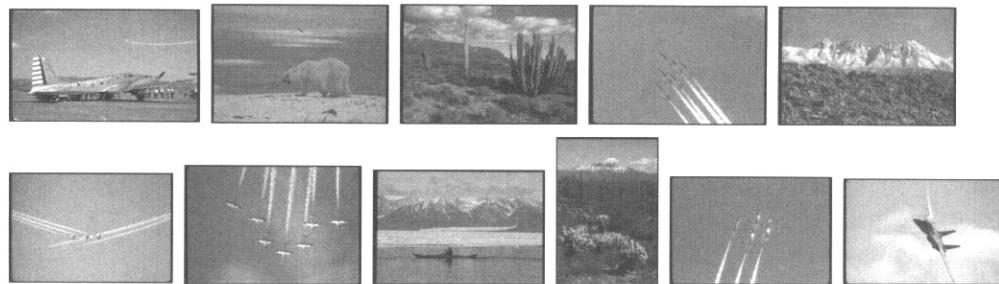
(그림 7) 단일 점 이동 (Query Point Movement)의 정확률과 재현율



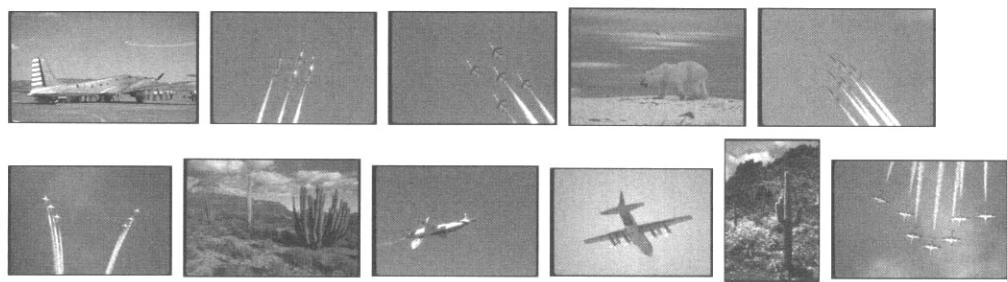
(그림 8) 점진적인 군집 (Incremental Cluster)의 정확률과 재현율



(그림 9) 반복단계에 따른 재현율의 비교



(그림 10) 첫번째 반복단계후의 10 결과 이미지들



(그림 11) 다섯번째 반복단계후의 10 결과 이미지들

<표 1> 군집의 쌍이 같은 평균을 가질 때 역행렬을 이용한  $T^2$ 과 대각선행렬을 이용한  $T_v^2$ 의 비교

차원	변동 비율	T2	Quantile-F	오류-비율(%)
역행렬을 갖는 $T^2$				
12	0.996	0.77	1.96	0
9	0.97	1.02	2.07	1
6	0.96	0.79	2.28	2
3	0.94	0.44	2.77	2
대각선행렬을 갖는 $T_v^2$				
12	0.996	0.70	1.96	2
9	0.97	0.87	2.07	4
6	0.96	0.68	2.28	6
3	0.94	0.44	2.77	6

<표 2> 군집의 쌍이 다른 평균을 가질 때 역행렬을 이용한  $T^2$ 과 대각선행렬을 이용한  $T_v^2$ 의 비교

차원	변동 비율	T2	Quantile-F	오류-비율(%)
역행렬을 갖는 $T^2$				
12	0.996	20.54	1.96	0
9	0.97	24.17	2.07	0
6	0.96	31.01	2.28	0
3	0.94	38.29	2.77	6
대각선행렬을 갖는 $T_v^2$				
12	0.996	28.37	1.96	0
9	0.97	25.03	2.07	1
6	0.96	31.27	2.28	2
3	0.94	41.20	2.77	8

## 6. 결 론

적합성 피드백 과정에서 사용자가 생각하고 있는 거리함수와 이상적인 질의점을 예측하기 위하여 질의의 다중 군집

을 찾는 문제에 집중하였다. 제안된 방법은 (1) 전단계의 적합한 이미지들과 현단계에서 적합하다고 표시된 이미지들을 묶는 군집-분류 단계와, (2) 다음 반복단계에서 질의점들의 개수를 줄이기 위하여 군집들을 합쳐 군집의 개수를 줄이는 군집-합병의 두 가지 과정으로 구성된다.

주요 공현도는 이미지분할을 이용하여 객체 수준에서 이미지를 표현하므로 저-수준 특징표현의 단점을 극복하고 질의와 의미적으로 관련된 군집들을 찾아 다중점 적합성 피드백 방법을 통해 의미적 차이를 줄일 수 있었다는 것이다. 또한 특이점 문제를 해결하기 위해 대각선행렬을 사용하는  $T_v^2$  함수를 이용한 실험은 제안된 방법이 질의점 이동과 점진적인 군집 방법보다 상당히 우수한 검색 성능을 보여주고 있다.

## 참 고 문 헌

- [1] R. D. Duda, P. E. Hart, D. G. Stork. Pattern Classification. John Wiley & Sons, Inc., New York, 2001.
- [2] M. Flickner, H. S. Sawhney, J. Ashley, Q. Huang, B. Dom, M. Gorkani, J. Hafner, D. Lee, D. Petkovic, D. Steele, and P. Yanker. Query by image and Video content: The qbic system. IEEE Computer, 28(9), 23-32, 1995.
- [3] H. Hotelling. Multivariate Quality Control. In C. Eisenhart, M. W. Hastay, and W. A. Wallis, eds. Techniques of Statistical Analysis. N.Y., McGraw-Hill, 1947.
- [4] K.A. Hua, N. Yu, D. Liu. Query Decomposition: A Multiple Neighborhood Approach to Relevance Feedback Processing in Content-based Image Retrieval. Proceedings of IEEE Int. Conference on Data Engineering, 2005.

- [5] J. S. Hare, P.A.S. Sinclair, P. H. Lewis, K. Martinez, P. G. B. Enser, C. J. Sandom. Bridging the Semantic Gap in Multimedia Information Retrieval: Top down and Bottom-up approaches. Proceedings of 3rd European Semantic Web Conference, 2006.
- [6] Y. Ishikawa, R. Subramanya, C. Faloutsos. MindReader: Querying databases through multiple examples. Proceedings of the 24th VLDB Conference, 218–227, New York, USA, 1998.
- [7] R.A. Johnson, D.W. Wichern. Applied Multivariate Statistical Analysis. Prentice-Hall, N.J., 1998.
- [8] F. Jing, M. Li, H. J. Zhang, B. Zhang. Relevance feedback in region-based image retrieval. IEEE Transactions on Circuits and Systems for Video Technology, 14(5), 672–681, May 2004.
- [9] Q. Lv, M. Charikar, K. Li. Image Similarity Search with Compact Data Structures. Proceedings of CIKM'04, 208–217, Washington DC, Nov., 2004.
- [10] A. Natsev, R. Rastogi, K. Shim. WALRUS: A similarity retrieval algorithm for image databases. Proceedings of SIGMOD'99, Philadelphia, PA, 395–406, 1999.
- [11] K. Porkaew, K. Chakrabarti. Query Refinement for Multimedia Similarity Retrieval in MARS. Proceedings of the 7th ACM Multimedia Conference, 235–238, Orlando, Florida, 1999.
- [12] J. J. Rocchio. Relevance feedback in information retrieval. In Salton, G. (Ed), The SMART Retrieval system - Experiments in Automatic Document Processing. Prentice Hall, Englewood Cliffs, NJ, 313–323.
- [13] Y. Rubner, L.J. Guibas, C. Tomasi. The earth mover's distance, Shimutil-dimensional scaling, and color-based image retrieval. Proc. ARPA Image Understanding Workshop, 661–668, New Orelans, LA, May 1997.
- [14] Y. Rui, T. Huang, S. Mehrotra. Content-based image retrieval with relevance feedback in MARS. Proceedings of IEEE International Conference on Image Processing '97, Santa Barbara, CA, October 1997.
- [15] J. Shi and J. Malik. Normalized Cuts and Image Segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence, 22(8), 888–905, August 2000.
- [16] J. Z. Wang, J. Lie, G. Wiederhold. SIMPLIcity: Semantics-Sensitive Integrated Matching for Picture Libraries. IEEE Transactions on Pattern Analysis and Machine Intelligence, 23(9), 947–963, 2001.



### 김 덕 환

e-mail : deokhwan@inha.ac.kr

2003년 2월 한국 과학 기술원 컴퓨터  
공학 박사

2006년 ~ 현재 인하대학교 전자전기공학부  
부교수

관심분야 : 멀티미디어, 데이터마이닝,  
정보검색, 임베디드시스템



### 이 주 흥

e-mail : juhong@inha.ac.kr

2001년 2월 한국 과학 기술원 컴퓨터공학  
박사

2002년 ~ 현재 인하대학교 컴퓨터공학부  
부교수

관심분야 : 데이터마이닝, 데이터베이스,  
정보검색, 신경망, 기계학습



### 송재원

e-mail : sjw@datamining.inha.ac.kr

2005년 2월 성공회대학교 전산정보학과  
학사

2006년 ~ 현재 인하대학교 대학원 석사과정  
관심분야 : 데이터베이스, 데이터마이닝,  
정보검색