

영상 검색을 위한 적응적 컴포넌트 분석 시스템 설계

최 철 *, 박 장 춘 **

The Design of Adaptive Component Analysis System for Image Retrieval

Chul Choi *, Chang-Choon Park **

요 약

본 논문에서는 내용 기반 영상 검색 시스템(Content Based Image Retrieval System)의 특징 추출(feature extraction)과 분석(analysis)을 위한 방법으로 적응적 컴포넌트 분석(ACA : Adaptive Component Analysis)을 제안하고 있다. 검색을 위해서 영상에서 추출된 특징들은 영상의 도메인(domain)에 따라 적절하게 적용해야만 좋은 검색 결과를 얻을 수 있다. 이러한 조건을 만족시키기 위한 방법으로 본 논문에서는 검색 측정도(retrieval measurement)를 제안하고 있다. ACA는 알고리즘과 시스템적인 관점에서 볼 때, 기존의 내용 기반 영상 검색을 위한 중간 단계라고 할 수 있으며, 검색 속도 향상 및 성능 개선에 목표를 두고 있다.

Abstract

This paper proposes ACA (Adaptive Component Analysis) as a method for feature extraction and analysis of the content-based image retrieval system. For satisfactory retrieval, the features extracted from images should be appropriately applied according to the image domains and for this, retrieval measurement is proposed in this study. Retrieval measurement is a standard indicating how important the value of a relevant feature is to image retrieval. ACA is a middle stage for content-based image retrieval and it purposes to improve the retrieval speed and performance.

▶ KEY WORDS : 영상 분석(Image Analysis), 영상 검색(Image Retrieval)

* 건국대학교 컴퓨터 공학과 박사과정수료, ** 건국대학교 컴퓨터 공학과 교수

I. 서론

영상 검색 기법은 크게 텍스트 기반 영상 검색(Text-Based Image Retrieval)과 내용 기반 영상 검색으로 분류된다. 텍스트 기반 영상 검색 기법은 주석이나 키워드에 의존하는 검색 방법으로 그 방법상에서는 관련이 없는 영상이 검색될 수도 있지만 고속 검색의 장점을 가진다. 이에 반해 내용 기반 영상 검색은 영상 내의 특징들을 이용한 검색 방법을 이용한다. 이러한 특징들에는 컬러, 필터링, 신호 처리(signal processing), 통계(statistics), 텍스처(texture) 등을 이용한 방법이 있다[1]. 단순한 분석법들은 영상을 검색하는 데 있어서 사용자에게 성능적인 면에서 큰 만족을 주지 못하고 있다[2]. 이러한 특징들은 독립적으로 사용하는 것보다는 복합적으로 유지 및 관리할 필요가 있다. 간단한 예로 많은 수의 특징 값들을 관리하기 위해서 [3]의 논문에서는 특징, 모델, 그리고 구조적으로 텍스처 특징 추출 기법을 분류하고 있다. 이러한 측면에서 본 논문에서는 특징 값들을 분석하여 그 가치를 측정하는 방법을 제시하였으며, 알고리즘과 시스템적인 측면에서 개선점을 제안하고자 한다.

II. 관련 연구

1. 영상의 특징 추출 방법

영상의 특징 추출을 위한 방법으로는 영상 필터링, 신호 처리 관련 변환 알고리즘, 통계적 기법, 색상 기법 및 텍스처를 이용한 방법 등이 있다[2]. 영상의 필터링과 신호 처리 같은 영상의 전 처리 알고리즘들은 그 자체로 이용하기 보다는 복합적으로 이용되는 경우가 많으며 일반적으로 통계적, 텍스처 분석을 위한 전 처리 과정에 해당하는 경우가 많다[4].

2. 정형화할 수 없는 영상의 검색

모양 기반(shape-based)의 정형화 할 수 있는 것은 영상의 형태적인 구조를 활용하여 정형화 할 수 없는 것은 형태적인 구조를 이용할 수 없다. 이 문제를 해결하기 위해서는 텍스처나 통계적인 방식을 사용한다.

텍스처 정보를 추출하기 위해서 GLCM(Gray Level Co-occurrences Matrix)[3]이 이용하고 있다. GLCM은 단순한 통계적인 분석이라기보다는 영상 내의 거칠고 부드러움을 측정하는 수단이 되기 때문에 정형화 할 수 없는 영상 검색을 위한 방법으로 이용되고 있다[4].

3. 영상 도메인

알고리즘적인 측면에서 특정 알고리즘을 수행하기 위해서는 도메인을 축소해야 한다. 이것은 영상 검색을 위한 한계가 되며 이러한 한계는 검색의 효율성을 감소시킨다. 게다가 현재에는 많은 특징 추출의 방법들이 존재하고 있으며, 이러한 특징들은 영상의 상태, 빛의 강도(intensity), 복잡도(complexity), 배경(background), 그리고

잡음(noise) 등에 영향을 미치게 된다[1].

III. 전형적인 영상 검색 방법의 문제점

전형적인 영상 검색에서의 일반적인 문제점은 다음과 같이 두 가지로 정리된다. 우선 정형화 할 수 없는 영상의 검색이다. 가령 얼굴 검색의 경우 얼굴 자체의 특징이나 형태적인 것을 이용할 수 있다. 이 방법은 현재 주로 사용되는 검색 기법이다. 하지만 정형화 할 수 없는 산, 하늘, 물과 같은 것을 검색하고자 한다면 다른 방법을 이용할 수밖에 없다[2]. 또 한 가지는 영상에서 추출된 정보가 영상의 도메인에 독립적일 수도 있지만, 대부분 종속적인 경우가 더 많다. 이러한 문제점은 알고리즘 그 자체만으로는 쉽게 해결하기 힘든 문제점이다.

IV. 적응적 컴포넌트 분석 시스템의 설계 및 구현

영상 특징 추출을 위한 여러 가지 방법들이 있지만 이러한 특징들은 모든 영상에 적용하는데 한계가 있기 마련이다. 하나의 특징 값이 모든 영상에 독립적으로 적용될 수는 없다. 가령 영상을 검색할 때 도메인이 전혀 다른 환경에서 검색하기 위해서는 임계치(threshold)를 재설정하거나 검색 자체를 포기해야 하는 문제가 발생한다. 이러한 문제에 대해 본 논문에서는 다양한 특징들 중에서 환경에 따라서 가장 적합한 특징들을 선별하는 방법을 제안하고 있다.

1. 제안된 알고리즘

가장 적합한 특징을 선별하는 과정(즉, 특징 값이 어느 정도 가치가 있는지 알아내는 것을 말한다)을 검색 측정도(Retrieval Measurement)라고 하며 검색 측정도에 따라서 영상에서 추출된 특징들의 중요도와 검색기준을 마련하게 된다. 제안된 ACA 기반의 시스템에서는 검색 측정도의 측정 수치에 따라 그 중요도가 결정되며 이러한 특징들은 영상의 검색과 분류의 기준이 된다. 시스템은 기존에 존재하던 특징 추출과 검색 기법을 유지해야만 한다. 반면에 새로운 특징 추출 방법은 시스템에 추가로 적용시키게 된다. (그림1)에서 영상 특징 어댑터(Image Feature Adapter)가 이러한 역할을 담당하게 된다. ACA시스템에서는 이 두 가지를 모두 충족시키는 방법으로 적응적인 방식으로 특징 값을 처리 및 관리하고 있다.

1-1 전 처리 과정과 특징 추출 과정

ACA시스템에서는 특징을 추출하는 방법에 대해 제한을 두지 않고 있다는 것을 전제로 하고 있다. 특징 추출에 필요한 전 처리 기법을 사용하게 되며, 특징 추출 역시 사용자에 의해서 선별적으로 선택할 수 있다.

1-2 검색 측정도 측정

CBIR(Content-Based Information Retrieval) 시스템에도 현재 영상의 특징 값이 포함되고 있다[5][6]. 본 시스템에서 사용하는 특징 추출 기법은 가장 일반적으로 널리 알려져 있는 영상 처리를 위한 특징 추출 기법으로 30여 가지 방법을 실험하고 있다.

그 중 질감의 풍부한 정보를 주는 동시발생률(co-occurrences)[7], 일반화된 동시 발생률[8]과 같은 기법을 주로 이용하고 있으며, 그 외에도 통계적인 정보, 모멘트(moment)[9]등 여러 가지 특징 추출 방법을 이용하고 있다. 따라서 검색 측정도 측정에서 추출된 적응적 컴포넌트(Adaptive Component)를 이용하여 영상을 분석하고, 분석된 결과를 영상의 검색이나 인식에 활용할 수 있다.




그림 1. 전체 ACA시스템 구조
Fig. 1 Whole Structure of ACA System

1-3 검색 측정도 측정과정

(1) 최적 구간의 검출

검색 측정도의 검출은 두 단계로 나누어진다. 먼저, 검색에 필요한 최적의 구간을 찾기 위해서 유전자 알고리즘(Genetic Algorithm)을 이용하고 있다. 유전자 알고리즘의 공적은 적자생존(survival of the fittest)의 개념과 새로운 것을 생성해내기 위한 전체 교배(interbreeding), 그리고 혁신적인 검색 기법이라 할 수 있다[6].




그림 2. 적응적 컴포넌트의 획득
Fig. 2 Acquisition of Adaptive component

유전자 알고리즘을 사용자 측면에서 본다면 적합도 함수(fitness function)를 어떻게 사용하는지가 핵심이 된다. 특정 값을 전체 구간이라고 할 때 전체 데이터의 범위 내에서 어느 구간이 가장 적합한 블록인지[5] 찾아내는 것을 주 목표로 하며 이 때 엔트로피(entropy)의 계산법을 이용한다. 특정 블록이 적합한지 아닌지를 밝히는 것은 연속적인 구간을 이산적으로 분리시키는 기법이기 때문에 간단한 문제가 아니다[3]. 유전자 알고리즘을 이용하여 구간 자체를 알고리즘 처리를 위한 입력 값으로 사용해서 최적의 구간을 찾고자 하는 것이다.

(2) 검색 측정도의 계산 및 처리

검색에 필요한 특징 값의 블록 설정이 끝나면, 해당 블록의 검색 측정도를 계산할 수 있다. 블록의 검색 측정도는 엔트로피(Entropy)를 이용해서 측정하고 있다. 목표 영상과 일반 영상을 구분하기 위해서 해당 특징 값이 얼마나 큰 엔트로피를 가지느냐에 따라서 해당 특징 값이 얼마나 큰 영향력이 있는지를 측정할 수 있다. 엔트로피를 계산하는 방법은 (식 1,2,3)과 같이 나타낼 수 있다[2][3][4].

$$H(z) = - \sum_{k=1}^c P(s_k) \log P(s_k) \quad \text{식 1. 엔트로피}$$

(식 1)은 전체 집합에서 s_k 가 발생할 확률을 이용한 엔트로피를 의미한다.

$$H(z/s_k) = - \sum_{i=1}^c P(a_i/s_k) \log P(a_i/s_k) \quad \text{식 2. 조건부 확률 엔트로피}$$

(식 2)에서 s_k 가 발생했을 때 a_i 가 발생할 조건부 확률을 이용한 엔트로피를 의미한다.

$$H(z/v) = - \sum_{i=1}^c \sum_{k=1}^t P(a_i, b_k) \log P(a_i | b_k) \quad \text{식 3. 전체 엔트로피}$$

(식 3)에서 a_i 와 b_k 는 조건부 확률을 이용한 전체 엔트로피를 의미한다. 이러한 엔트로피들은 정보가 어느 정도 유효한지를 측정하는 정보이익(Gain)의 척도로 계산될 수 있다. 정보이익의 표현은 (식4)와 같이 나타낼 수 있다.

$$I(z/v) = H(z) - H(z/v) \quad \text{식 4. 정보이익}$$

(3) 검색 측정도의 중요도

이렇게 측정된 검색 측정도는 의미가 있는 특징 값과 의미가 없는 특징 값으로 나누어 생각해 볼 수 있다. 특정 영상에 반응하는 특징 값을 해당 영상의 적응적 컴포넌트라고 하며, 이 적응적 컴포넌트는 검색, 인식, 학습의 기준으로 활용될 수 있다. 검색 측정도에서 사용하는 엔트로피 계산은 통계적인 확률 기법이기 때문에 이산적인 데이터에 더 좋은 반응을 보인다[3]. 하지만 본 논문에서 적용하려는 자료는 대부분 연속적인 형태이며 이것은 엔트로피 계산에 상당한 장애 요인이 된다. 엔트로피는 열전도에서 사용하는 무질서도 개념이지만 이것이 학습에 적용되면서 학습 결정 트리(decision tree)를 만드는 방법으로 사용되기도 한다. 학습 결정 트리의 문제점은 연속적인 데이터, 학습의 깊이, 데이터의 수에 따라서 결정 트리가 무의미해 질 수도 있다는 것이다[3]. 본 시스템에서와 같이 연속적이며 데이터의 수가 많을 때는 학습의 깊이가 커질 수도 있으며 전혀 의미 없는 결정 트리가 생성될 수도 있다. 하지만 본 논문에서, 깊이를 결정하는 순서는 특징 값의 가치를 결정하는 수단이 된다는 측면에서 어느 정도 의미가 있는 특징 값만 분류해서 사용하겠다는 방안을 도출하고 있다.




그림 3. 최적의 블록
fig. 3 Optimized Block

최적의 블록은 (그림 3)에서 d로 표현되며 일반적인 방법으로 임의의 구간을 선택하고자 할 때는 히스토그램의 임계치 설정과 같은 방법으로 특정 구간을 선택할 수밖에 없다. 하지만 임의의 구간에 나타나는 정보이익(Gain)을 측정하여 그 측정치에 따라서 최적의 구간을 검색한다면 보다 효율적인 방법으로 해당 구간을 추출해낼 수 있다. (식 5)는 해당 구간을 선택하기 위한 정보이익을 계산하는 방법을 보여주고 있다.

$$F(x_1, x_2) = \max\left(-\sum_{k=1}^c P(s_k) \log P(s_k) - \sum_{i=1}^c \sum_{k=1}^l P(a_i, b_k) \log P(a_i | b_k)\right)$$

selected block z: $x_1 < z < x_2$

unselected block z': $x_1 > z' \parallel z > x_2$

식 5. 정보이익의 계산

정보이익은 해당 데이터가 학습에 얼마나 많은 영향을 미치는지 기를 나타내며 최적의 구간은 (그림 4)와 같이 적합도 함수로 제공된다.

적합도 함수는 유전자 알고리즘에서 학습 데이터를 판단하는 기준이 되며 최적의 구간을 구하기 위해 새로운 유전자를 재생산하고 선택하기 위한 기준이 된다.




그림 4. 최적의 검색 블록을 찾기 위한 구조도
fig. 4 Structure for finding out optimized block

앞의 과정에서 최적의 검색 블록을 찾았다면 이제 남은 것은 각각의 특징 값의 블록 엔트로피를 측정하는 것이다. 많은 특징 값 중에서 검색에 영향을 미치는 우선순위 별로 정렬한다면 검색 측정도 측정은 마무리된다.

1-4 시스템적인 특성

특징 추출 과정은 (그림 5)에서와 같이 입력 영상과 입력 알고리즘이 이미지 저장 공간과 특징 함수 저장 공간에 등록되면 등록된 이미지와 특징 추출 알고리즘을 이용해서 추출 프로세서(extraction processor)가 특징 값을 추출하게 된다. 이러한 시스템 구조상의 장점은 고정된 특징 값을만을 이용하는 것이 아니라 보다 동적으로 특징 값을 유지 관리할 수 있다는 것이다.




그림 5. 특징 추출 시스템 구조도
Fig. 5 Structure of feature extraction system

V. 실험 결과

(그림 6)은 6가지 종류의 학습 이미지 샘플을 각각 5개씩 보이고 있으며, 실제 실험에서는 종류 별로 10개의 이미지가 사용되었다. 6종류의 이미지는 각각 특징 추출 과정을 거치게 된다.




그림 6. 입력 샘플 이미지
Fig. 6 sample image for Input

표1. 추출된 특징 값들
Table. 1 Extracted feature values

	bear	plane	elephant1	elephant2	sunrise1	sunset2
1	0.011667	0.039329	0.006349	0.007256	0.010512	0.011997
2	9.952838	6.953416	14.14066	15.10043	4.114359	9.598219
3	394.897	340.1106	740.5048	1033.768	102.413	671.1883
4	31083.74	24312.82	80316.17	135899	4784.825	86265.66
5	0.328676	0.551223	0.234536	0.266783	0.486662	0.393538
6	0.262639	0.514417	0.162503	0.197341	0.425388	0.326644
7	0.241578	0.500383	0.142506	0.175924	0.399114	0.301631
8	7.632492	5.795243	8.305728	8.303061	6.538828	7.190078
9	0.001697	0.00986	0.000521	0.00066	0.002663	0.001818
10	98.62105	113.026	141.1869	155.8916	63.36117	128.7607
11	1316.122	1395.72	2220.035	3545.511	838.2135	2636.845
12	-0.85365	-1.60724	-1.26661	-0.89025	-0.73357	-1.01866
13	1.218892	2.546381	1.322461	-0.07291	-0.01369	-0.28252
14	6.599119	5.599109	7.002664	7.154242	6.179106	6.540205
15	115.2812	106.4303	134.5993	157.415	75.06527	161.5775
16	1747.058	1326.358	1901.885	3505.844	1144.876	5568.192
17	-1.17015	-1.43932	-1.46825	-0.95021	-1.08508	-0.8101
18	0.807423	2.749683	2.164897	0.171621	0.238632	-0.89846
19	6.08816	5.206094	6.243372	6.488817	5.751626	5.822311
20	109.0983	83.9858	166.9861	147.974	110.5874	180.0759
21	1883.805	912.0326	2914.266	3133.742	2983.527	5094.638
22	-0.4011	-0.28088	-1.29727	-0.93713	-0.36479	-1.11494
23	1.211156	5.268593	1.598472	0.284006	-0.11799	-0.33356
24	6.105464	5.306955	6.42613	6.603996	6.652801	4.380464
25	72.50407	149.6561	122.9626	163.2378	5.424357	45.6864
26	822.5183	2555.017	2831.508	4509.369	27.27821	627.5718
27	-0.41821	-1.87386	-0.14804	-0.74744	1.361749	0.718468
28	1.074619	2.024221	-0.02451	-0.61803	2.695332	0.924858
29	6.134785	5.468434	6.823505	6.14866	3.852498	6.0538

〈표 1〉은 6개의 학습 영상에 대한 29개의 특징 값으로 이루어져 있으며, 이들 특징 값들은 기본적인 영상 학습을 위한 기준이 된다. 실제 실험에서는 각 종류별로 10개의 영상이 사용되었고, 〈표 1〉에서는 종류별로 1개의 영상에 대한 특징 값을 보인 것이다.

본 논문에서 제안하는 시스템에서 특징 값들의 중요도를 측정하는 것에 주 목적이 있기 때문에 〈표 1〉에서 제시된 특징 값들의 의미는 현 시점에서는 중요하지 않다. 하지만 특정 영상에 어떤 특징 값이 더 중요한 가는 본 논문에서 제시하는 주 개념이 된다. 즉, 각각의 특징 값의 의미보다는 특정 영상에 어떠한 특징 값들이 더 많은 영향을 주는가에 초점을 맞추고 있는 것이다.

1. 엔트로피 결과 값

ACA 시스템을 통해서 추출된 최적의 블록을 선택하는 과정은 유전자 알고리즘의 유전자가 담당하게 된다. (그림 7)의 (a)는 임의로 초기 유전자가 만들어진 것을 보여주고 있으며 (b)그림은 유전자가 우성 형질로 세대변환을 했을 때 최적의 구간으로 집중되는 현상을 보여주고 있다.

단계별로 각각 (a)는 2번, (b)는 4번, (c)는 6번, (d)는 8번, (e)는 10번, (f)는 15번의 진화를 거쳐서 나온 결과를 보여주고 있다. (그림7)에서 최적의 구간은 (0.368627, 0.631373)이며, 대각으로 유전자의 형질이 분포하고 있는 것은 (식6)를 만족하기 위해서이다.

$$X \subseteq \{x_1, x_2, x_3 \wedge x_a \wedge x_b \wedge x_i\}$$

$$x_a < x_b$$

식 6. 구간(x)의 조건식




그림 7. 엔트로피 계산을 위한 랜덤 유전자의 분포와 세대교체 후의 우성 형질 유전자의 분포
(세로축은 찾고자 하는 영역의 최소값, 가로축은 최대값)

fig. 7 Distribution of random genes for calculation of entropy and distribution of genes of dominant traits after alternation of generation

만약 이러한 조건이 없을 때에는 유전자의 세대교체 후에도 임의로 결과값이 도출되거나 우성 형질로의 변환이 느리게 이루어진다. 다음의 〈표 2〉는 최적의 블록 검색의 결과를 수치로 보여주고 있다.

위의 〈표 2〉에서 보는 바와 같이 최적의 구간은 어느 한 지점에 집중되어 있으며 이 구간은 학습 데이터를 평가하기 위한 최적의 구간이 되는 것이다.

표 2. 검색된 최적의 블록 예 data-iris.dat
Table. 2 Searched optimize block

진화수	최대빈도	시작점	끝점	엔트로피
1	5	0.223529	0.823529	0.164473
	5	0.349020	0.894118	0.211042
	5	0.462745	0.749020	0.423156
2	6	0.274510	0.713725	0.274147
	6	0.423529	0.752941	0.379427
	6	0.474510	0.709804	0.529612
3	6	0.509804	0.835294	0.295193
	9	0.435294	0.713725	0.462018
	9	0.447059	0.768627	0.37306
4	9	0.498039	0.701961	0.625293
	14	0.474510	0.705882	0.529612
	17	0.400000	0.737255	0.399493
5	17	0.486275	0.721569	0.495451
	25	0.498039	0.717647	0.570593
	56	0.498039	0.713725	0.586614
6	99	0.494118	0.698039	0.633343
	211	0.494118	0.698039	0.633343
	336	0.498039	0.698039	0.633343
7	3888	0.498039	0.698039	0.633343
	4722	0.498039	0.698039	0.633343
	4958	0.498039	0.698039	0.633343
8	4605	0.498039	0.698039	0.633343
	50	0.498039	0.698039	0.633343

2. 최종 특징 값 및 평가




그림 8. 테스트 영상
Fig. 8 Test image

표 3. 테스트 영상의 특징값
Table. 3 Feature Value of Test image

No.	sample1	sample2	No.	sample1	sample2
1	0.330385	0.101820	16	0.049207	0.239264
2	0.128104	0.757758	17	0.048849	0.333607
3	0.200723	0.717963	18	0.807240	0.233827
4	0.148378	0.424531	19	0.501959	0.881412
5	0.888742	0.136107	20	0.248525	0.755349
6	0.892158	0.119897	21	0.024365	0.353387
7	0.885375	0.112715	22	0.162525	0.245687
8	0.297577	0.861229	23	0.526070	0.198794
9	0.174549	0.010848	24	0.399297	0.753450
10	0.669617	0.865151	25	0.973109	0.744200
11	0.170524	0.643342	26	0.281123	0.644189
12	0.004765	0.391895	27	0.000000	0.347912
13	0.830790	0.180550	28	0.225398	0.018648
14	0.462020	0.876707	29	0.663451	0.944448
15	0.613411	0.822846			

결과를 검증하기 위해 (그림 8)과 같이 2개의 테스트 영상에 대해 특징 추출 기법을 적용시켜 보았다. (그림 8)의 Sample1의 영상은 2번 plane의 영상 특징 추출 기법 들 중 13,14,28,29,3번 기법과 같은 기법의 엔트로피가 우선 순위를 나타냈으며, Sample2의 영상은 3번 elephant1의 영상 특징 추출 기법 중에서 27,22,4,20,16 번 기법과 같은 기법이 선택되는 것을 <표 3>를 통해 확인할 수 있다.

VI. 결론

우리가 자주 사용하는 영상들은 정지 영상과 동영상으로 나눌 수 있지만, 두 방식 모두 검색에서는 텍스트 기반 검색 방식 외에는 명백한 해결 방법을 찾지 못하고 있다. 또한 텍스트 기반의 검색 방식을 지원하도록 손질된 영상은 전체 영상들의 극히 일부에 지나지 않고, 이런 영상들을 모두 텍스트 기반의 영상들로 변환하는 것은 거의 불가능하기 때문에 내용 기반 검색 방식의 발전이 시급한 실정이다. 그렇지만, 이러한 문제점을 해결해 나가기 위해서, 한두 가지 알고리즘으로 획일적인 특징 값을 사용하는 시스템으로는 좋은 결과를 획득할 수 없기 때문에, 여러 가지 효율적인 특징 분류기를 제안하고, 시스템적인 측면에서 어댑티 방식을 이용한 동적 특징 값 추출 기법을 이용하게 되었다. 그리고 영상의 특징 값의 독립성을 위해서 최적의 특징 값을 추출하는 기법을 사용하고 있으며, 본 논문에서 제안한 ACA 는 현재 사용하고 있는 대부분의 영상 검색 방법에 비해 보다 비용을 절감하고, 기존의 검색 시스템을 그대로 유지할 수 있다는 장점을 제공하고 있다. 이러한 기법은 영상의 특징 값만이 아니라 특징 값 분류를 해야 하는 다른 연구 및 응용 분야에도 충분히 사용될 수 있을 것이다.

참고문헌

- [1] Maria Petrou and Panagiota Bosdogianni, *Image Processing*, John Wiley & Sons, Ltd, 2000
- [2] Q. Iqbal and J. K. Aggarwal, CIRES: A System for Content -based Retrieval in Digital Image Libraries, Invited session on Content Based Image Retrieval: Techniques and Applications International Conference on Control, Automation, Robotics and Vision (ICARCV), Singapore, pp.205-210, December 2-5, 2002.
- [3] T.R Reed, J.M Hans Du Buf. A review of recent texture segmentation and feature extraction techniques, *CVGIP: Image Understanding*, 57(3)(1993), pp. 359372.
- [4] Gonzalez, Woods : *Digital Image Processing*, Addison Wesley Longman, 1992.
- [5] Bernd Jhne, *Digital Image Processing*, Springer -Verlag Berlin Heidelberg, 1995
- [6] R. M. Haralick, I. Dinstein, Textural features for image classification, *IEEE Trans. on System, Man, and Cyber*, vol 3, pp. 610-621, November
- [7] Quinlan, J.R. C4.5: *Programs for Machine Learning*, Morgan Kaufmann Publisher, 1993.
- [8] Jiawei Han, Micheline Kamber : *Data Mining Concepts and Techniques*, Morgan Kaufmann

- Publisher. 2001.
- [9] Gregory J.E. Rawlins : Foundation of Genetic Algorithms, Morgan Kaufmann Publisher. 1991.
 - [10] Bauer, R.: Genetic algorithms and investment strategies, New York: John Wiley & Sons, 1994.
 - [11] A. Ralescu and R. Jain (Eds), Special issue on advances in visual information management system, Journal of Intelligent Information Systems, vol. 3, July 1994.
 - [12] W. E. L. Grimson, On the recognition of parametrized 2D objects, International Journal on Computer Vision, vol. 3, pp. 353-372, 1988
 - [13] F. Stein and G. Medioni, Structural indexing: efficient 2-D object recognition, IEEE Trans. Pattern Anal. Mach. Intel, vol. 14, pp. 1198-1204, December 1992.
 - [14] S. O. Belkasim, M. Shridhar and M. Ahmadi, Pattern recognition with moment invariants a comparative study and new results, Pattern Recognition, vol. 24 no. 12, pp. 1117-1138, 1991.