

하이브리드 기법을 이용한 영상 식별 연구

박 상 성*, 정 귀 임**, 장 동 식***

A Study on Image Classification using Hybrid Method

Sang-Sung Park *, Gwi-Im Jung **, Dong-Sik Jang ***

요 약

영상 식별 기술은 대용량의 멀티미디어 데이터베이스 환경 하에서 고속의 검색을 위해서 필수적이다. 본 논문은 이러한 고속 검색을 위하여 GA(Genetic Algorithm)과 SVM(Support Vector Machine)을 결합한 모델을 제안한다. 특징벡터로는 색상 정보와 질감 정보를 사용하였다. 이렇게 추출된 특징벡터의 집합을 제안한 모델을 통해 최적의 유효 특징벡터의 집합을 찾아 영상을 식별하여 정확도를 높였다. 성능평가는 색상, 질감, 색상과 질감의 연합 특징벡터를 각각 사용한 성능 비교, SVM과 제안된 알고리즘과의 성능을 비교하였다. 실험 결과 색상과 질감을 연합한 특징벡터를 사용한 것이 단일 특징벡터를 사용한 것 보다 좋은 결과를 보였으며 하이브리드 기법을 이용한 제안된 알고리즘이 SVM알고리즘만을 이용한 것 보다 좋은 결과를 보였다.

Abstract

Classification technology is essential for fast retrieval in large multi-media database. This paper proposes a combining GA(Genetic Algorithm) and SVM(Support Vector Machine) model to fast retrieval. We used color and texture as feature vectors. We improved the retrieval accuracy by using proposed model which retrieves an optimal feature vector set in extracted feature vector sets. The first performance test was executed for the performance of color, texture and the feature vector combined with color and texture. The second performance test, was executed for performance of SVM and proposed algorithm. The results of the experiment, using the feature vector combined color and texture showed a good performance than a single feature vector and the proposed algorithm using hybrid method also showed a good performance than SVM algorithm.

▶ Keyword : Hybrid method, Data mining, GA(Genetic Algorithm), SVM(Support Vector Machine), Image, Classification

• 제1저자 : 박상성

• 접수일 : 2006.11.15, 심사일 : 2006.12.07, 심사완료일 : 2006. 12.25.

* 고려대학교 BK21 유비쿼터스 정보보호사업단, ** 고려대학교 정보경영공학부,

*** 고려대학교 정보경영공학부

※ 본 연구는 2006년도 교육부 BK21 사업의 지원으로 수행됨.

I. 서론

IT 기술의 발전으로 e-Business 환경에서 멀티미디어 정보의 생성과 유통이 폭발적으로 증가하고 있다. 이러한 추세에 의해 대량의 멀티미디어 데이터에 대한 검색에 관한 연구가 필요하다. 기존의 정보 검색에는 단순한 쿼리 매칭에 의한 비지능형 키워드 검색이 있으나 이러한 키워드 검색은 사용자의 의미론적 관점을 고려하지 않기 때문에 원하는 검색 결과를 얻기 힘든 실정이다. 이러한 문제점을 해결하기 위해 사용자의 의미론적 관점을 고려한 지능형 정보 검색에 관한 연구가 활발히 진행 중이다. 특히, 멀티미디어 정보 중 다른 매체에 비해 정보 전달의 효과가 큰 영상검색(image retrieval)이 활발히 연구되고 있다. 논문에서는 색상[1], 질감[2], 모양[3]과 같은 시각적 정보를 기반으로 하는 기술인 내용기반 영상검색을 다룬다. 이러한 내용기반 영상검색을 다루는 시스템은 이미 많이 연구되어졌다.[4, 5] 하지만 이러한 시스템들은 다차원 색인 구조를 가지고 있다. 다차원 색인 기법들은 특징 데이터의 수가 증가함에 따라 검색시간이나 기억공간에 대한 요구가 지수적으로 증가되어 고차원 데이터에 대해서는 순차적으로 탐색하는 것에 미치지 못하는 결과를 초래하여 색인구조로서의 기능을 상실하게 된다. 따라서 기존에 제시된 다차원 색인 기법들은 고차원의 이미지 데이터를 색인하기에는 적합한 색인구조라고 할 수 없다. 이러한 문제점을 해결하기 위하여 본 논문에서는 데이터 마이닝 기법인 SVM(support vector machine)과 GA(genetic algorithm)을 이용하였다. 먼저, SVM(support vector machine) 알고리즘의 파라메터를 최적으로 세팅한 후 GA와 SVM 알고리즘을 결합하여 유효 특징벡터의 집합을 구하여 식별 정확도를 향상하였다. 이때, 특징벡터는 색상과 질감 정보를 사용하였다. 색상정보는 영상의 시각 능력에 유사한 색상 모델인 HSV, 질감정보는 영상의 혼잡도를 나타내는 엔트로피를 사용하였다.

II. 데이터 마이닝

데이터 마이닝은 관계, 패턴, 규칙 등을 발견하기 위해서 대용량의 데이터를 자동 또는 반자동의 수단을 통해서 탐색하고 분석하는 일련의 과정이다. 본 논문에서는 이러한 데이터 마이닝 기법 중 유전 알고리즘과 SVM 알고리즘을 이용하여 영상을 식별한다.

2.1 유전 알고리즘(Genetic Algorithm : GA)

유전 알고리즘은 자연선택과 진화의 개념에 기본을 두고 있는 탐색과 최적화 문제를 해결하기 위한 방법이다. 유전자 알고리즘이 수행되는 동안 하나의 가능한 해집단이 선택되고 이 해의 집합은 적합도 함수의 선택적 제약을 받으면서 최적의 해로 진화해 간다. 유전 알고리즘의 기본 원리는 아래의 의사코드와 같다. 변수 자체를 표현하는 것이 아니라 변수를 코드화하여 유전자를 만든 다음 단일해가 아닌 여러 해들의 집단인 첫 세대를 무작위 발생시키고 이를 중에서 다음 세대를 만들기 위한 부모해들을 선택한다. 우수한 해는 부모해로 선택될 확률이 높다. 일단 선택된 부모해는 유전 알고리즘의 연산자인 재생과 교차와 돌연변이를 통해 다음 세대인 자손 세대를 만든다. 이 과정을 유전 집단이 수렴할 때까지 반복한다.[6]

```

begin GA
g:=0 generation counter
Initialize population P(g)
Evaluation population P(g)
while not done do
    g:=g+1
    Select P(g) from P(g-1)
    Crossover P(g)
    Mutation P(g)
    Evaluation P(g)
end
end GA

```

1) 재생(Reproduction)

부모 세대는 현재의 세대로부터 무작위 선택되고, 차세대는 선택된 부모 세대의 유전자 재결합, 교차, 돌연변이를 거쳐 만들어진다. 일반적으로 적합도에 따른 비례 배분으로 부모해 집단의 개체를 복사하여 자손해 집단을 형성한다. 따라서 적합도가 높은 개체는 몇 대를 거쳐도 살아남을 확률이 높다.

2) 교차(Crossover)

두 부모해의 유전 정보를 임의의 위치에서 부분적으로 교환함으로써 새로운 자손해를 생성하도록 하는 조작법이다. 이것은 현재까지 탐색되지 않은 새로운 해 공간을 탐색하는 것을 의미한다.

3) 돌연변이(Mutation)

부모로부터 자손으로 전달된 측정한 정보에 대하여 무작위적인 변형을 시도함으로써, 전체 해집단에서 배제된 새로운 개체를 발생시키거나 진화과정에서 상실된 특정 유전 정보의 재현을 시도하는 조작 방법이다.

2.2 SVM(Support Vector Machine : SVM)

SVM은 1998년 Vapnik [7]에 의해 개발된 학습기법으로, 데이터를 고차원 공간으로 투사시켜 분리경계가 단순한 문제로 변환시키기 때문에 수학적으로 분석하는 것이 수월하다. 또한 SVM은 조정해야 할 모수(parameter)의 수가 많지 않아 비교적 간단하게 학습에 영향을 미치는 요소들을 규명할 수 있다. 그리고 구조적 위험을 최소화함으로써 과대적합문제에서 벗어날 수 있으며, 볼록함수를 최소화하는 학습을 진행하기 때문에 전역적 최적해를 구할 수 있다는 점에서 인공신경망보다 성능이 우수한 기계학습기법으로 주목 받고 있다.[7-8]

그림 1에서 보는 바와 같이 SVM 알고리즘은 Support Vector라고 불리는 training set point들에 의해 결정되는 결정 경계(decision boundary)를 결정함으로써 2개의 서로 다른 문제에 주로 많이 사용되고 있다.

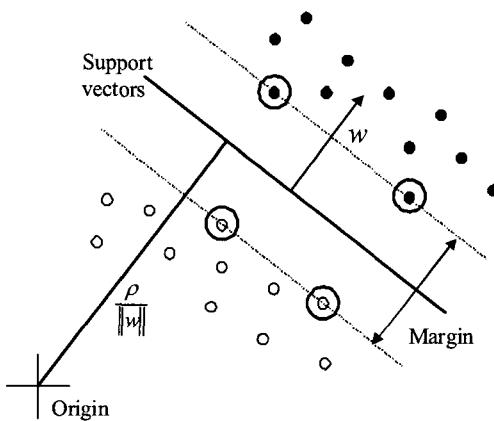


그림 1. 2차원 공간에서의 SVM의 결정경계영역
Fig 1. SVM decision boundary region of two dimensions

이때, 결정 경계는 두 클래스간의 최대 거리를 유지하도록 결정된다. SVM의 기본 아이디어는 구조적 리스크 최소화를 통해 벡터공간에서의 최적의 결정경계영역을 찾아내는 것으로, 이진분류문제를 푸는 방법으로 이용되고 있다. SV

M은 두 집단으로 구분된 입력벡터를 가지는 훈련용 자료에 대해 집단을 분류할 때 기준이 되는 분리 초평면(separating hyperplane)을 특수한 학습 알고리즘을 이용하여 찾는다. 고차원 문제를 주로 다루는 SVM에서는 이론적으로는 가능하나 실제로는 풀기 힘든 매핑함수를 대신하여 원자료를 고차원 공간으로 사상시켜 특징공간 내에 선형으로 분리 가능한 입력자료 집합을 만들어 주는 커널함수를 도입하여 분리 초평면을 찾게 되는데, 대표적인 커널함수는 아래의 식 (1-3)과 같다

$$\text{RBF 커널} : k(x, y) = \exp\left(-\frac{\|x-y\|^2}{\sigma^2}\right) \quad \dots \dots \dots (1)$$

Sigmoid 커널 :

$$k(x, y) = \tanh(\gamma \langle x, y \rangle + \theta), \text{ where } \gamma, \theta > 0 \quad \dots \dots \dots (2)$$

$$\text{Polynomial 커널} : k(x, y) = (\langle x, y \rangle + c)^d \quad \dots \dots \dots (3)$$

III. 제안된 알고리즘

SVM을 이용한 학습을 위하여 본 논문에서는 k-fold Cross Validation 기법을 써서 파라메타를 구한 후 SVM 환경을 설정한다. SVM을 실행하기 위해서는 먼저 어떤 커널함수를 사용할 것인가를 결정해야 한다. 다음으로 SVM 모형의 모수인 C와 커널함수 모수를 선택해야 하는데 선형 커널함수는 상한값 C이외에 별도로 선택해야 할 모수가 없다는 장점은 있으나 선형으로 분리가 불가능한 문제에서는 효과적이지 못하다는 단점이 있다. SVM에서 선형으로 분리가 불가능한 문제를 해결하는데 사용되는 커널함수로는 RBF커널과 다항식 커널 그리고 Sigmoid 커널이 대표적인데, 이 경우 커널함수의 모수가 존재하기 때문에 추가적으로 모수의 값을 선택해야 한다. 구체적으로, RBF 커널은 고차원의 특징공간으로 입력 벡터를 비선형적으로 이동시키기 때문에 선형 분리가 불가능한 문제를 해결하는데 매우 유용하다. 그러나 다항식 커널은 차수 d라는 추가적인 모수의 선택이 필요하고 학습에 걸리는 시간도 RBF 커널에 비해 많이 소요되는 단점이 있으며 Sigmoid 커널의 경우 예

측 정확도가 떨어진다고 보고되고 있다. 따라서 본 연구에서는 RBF 커널을 이용한 SVM 모형을 기본 모형으로 사용하였다. RBF 커널함수는 SVM 모형의 허용오차 상한값 C와 γ 에 따라 예측성과가 달라지기 때문에 최적의 C와 γ 의 값을 선정해야 하는 사전 작업이 필요하다. 본 연구에서는 5-fold cross validation을 이용한 격자탐색 기법을 도입하여 최적의 C와 γ 의 값을 도출하고, 이를 이용하였다. 특징벡터에는 클러스터링에 영향을 미치는 요소와 그렇지 못한 요소가 있다. 불필요한 특징벡터들은 오랜 학습시간과 잘못된 분류를 발생시킨다. 본 논문에서는 불필요한 특징벡터들을 없애고 최적의 입력변수를 선택하기 위하여 GA와 SVM 알고리즘을 결합하여 사용하였다. GA를 이용한 특징선택은 클러스터링을 할 때 벡터들 중에서 불필요한 벡터를 제거함으로써 최적의 특징들의 집합을 찾아내어 GA와 SVM 알고리즘을 결합한 모델의 성능을 높이기 위한 것이다. 정확도와 특징 집합의 크기는 이러한 조건을 만족시켜주기 위한 요소들이다. 본 논문에서는 이러한 요소들을 고려하여 Fitness Function을 설정함으로써 최적의 특징벡터 집합을 찾아 SVM 분석을 하였다.

3.1 Cross Validation

어떤 모델을 학습시키는 이유는 새로운 미래의 데이터들에 대해서 좋은 성능을 내기 위해서이다. 좋은 성능을 가진 SVM 모델은 일반화의 에러를 줄여야 한다. 논문에서는 k-fold cross-validation을 이용하여 일반화의 에러를 줄여주는 최적의 파라메터를 구하였다.

데이터 중 학습을 위한 데이터로 80%를 사용하고 나머지 20%는 검증용 데이터로 사용한다. 보다 일반화된 연구 결과를 얻기 위해서 본 연구에서는 5-cross validation 방법을 썼다. 따라서 본 연구에서는 전체 데이터를 5개의 데이터 세트으로 나누어 4개의 데이터 세트으로 모델을 구성하고, 나머지 하나의 데이터 세트으로 검증하는 과정을 5번 반복하였다. 아래의 표 1에 보듯이 C와 γ 의 값이 2¹¹과 2⁻³일 때 cross validation의 예측성과가 가장 우수한 것으로 나타났으며 이때의 성과는 95.9%이다.

최적의 C와 γ 의 값을 구한 후 이를 이용하여 학습용 데이터 전체에 대하여 학습을 다시 수행하고, 최종적으로 SVM 분류기를 생성한 후 검증용 데이터를 대상으로 예측정확도를 분석하였다. 다항식 커널의 모수도 RBF 커널함수에서 사용된 C와 γ 의 값을 동일하게 적용하고 차수는 1, 2, 3 차로 하여 결과를 분석하였다. 이 중 가장 좋은 결과를 보

인 3차를 다항식 커널의 차수로 사용하여 세팅을 하였다. 또, Sigmoid 커널도 RBF와 동일한 γ 의 값을 사용하였다. 커널에 따른 파라메타의 세팅을 정리하면 표 2와 같다.

표 1. 5-fold cross validation을 이용한 grid 탐색 결과
Table 1. A retrieval result of grid using 5-fold cross validation

γ	2^3	2^1	2^{-1}	2^{-3}	2^{-5}	2^{-7}	2^{-9}	2^{-11}	2^{-13}	2^{-15}
C	2^{-5}	61.3	61.1	68.5	68.8	67.7	66.2	66.2	66.2	66.2
2^{-3}	70.8	72.9	72.9	69.1	69.1	67.7	66.2	66.2	66.2	66.2
2^{-1}	78.2	80.2	79.6	77.7	75.4	69.2	66.2	66.2	66.2	66.2
2^1	78.2	82.6	80.0	79.9	75.4	69.2	66.2	66.2	66.2	66.2
2^3	78.2	85.7	85.9	83.4	82.1	71.1	67.8	66.2	66.2	66.2
2^5	78.2	86.6	87.4	88.2	85.5	71.1	71.1	71.1	67.8	67.8
2^7	82.4	84.1	87.4	90.3	89.1	76.9	71.1	71.1	71.1	72.4
2^9	82.4	85.4	90.3	92.7	91.4	84.7	84.7	80.2	80.2	79.4
2^{11}	82.4	85.4	94.2	95.9	93.4	87.8	87.2	80.7	80.7	80.4
2^{13}	82.4	85.4	93.6	94.6	94.3	89.4	86.0	79.6	80.4	80.6
2^{15}	82.4	85.4	88.9	91.1	91.0	88.4	85.3	80.7	80.4	80.4

표 2. SVM에서의 커널에 따른 파라메타 세팅
Table 2. Parameter setting for each SVM kernel

Kernel	C	γ	d
Linear	2^{11}	-	-
Polynomial	2^{11}	2^{-3}	3
RBF	2^{11}	2^{-3}	-
Sigmoid	2^{11}	2^{-3}	-

(이때, r은 1로 고정하였음.)

3.2 최적의 유효 특징벡터 집합 선택

아래의 그림 2는 GA와 SVM을 결합하여 최적의 유효 특징벡터 집합을 구성하고 식별하는 제안된 알고리즘의 흐름도이다.

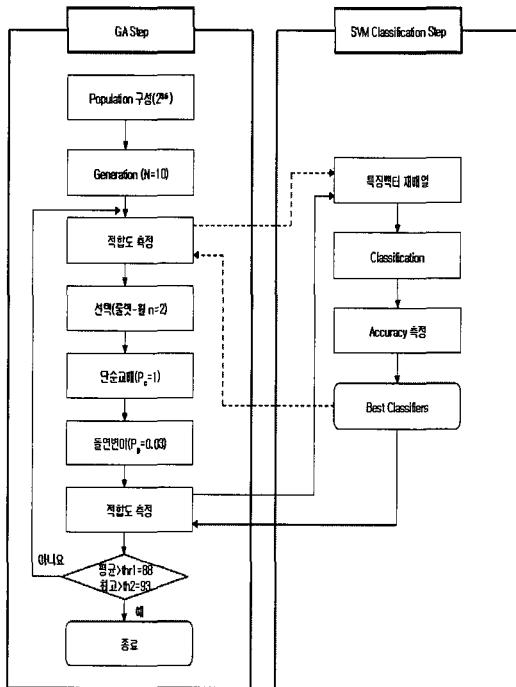


그림 2. 제안된 알고리즘의 흐름도
Fig 2. A flow diagram of proposed algorithm

1) 특징선택 인코딩

본 논문에서는 36개(h, s, v, entropy 각각 9개씩)의 비트열로 염색체를 만든다. 이때, i번째 비트가 1일 경우 i 번째 고유벡터는 선택되고 그렇지 않으면 무시한다.

2) Fitness Function

각 특징의 부분집합들은 많은 수의 핵심 고유벡터를 포함하다. 만약 각기 다른 수의 고유벡터를 가진 두 개의 부분집합들이 똑같은 정확도를 가질 경우 더 적은 수의 고유 벡터들의 부분집합들이 보다 적은 부하와 보다 빠른 식별을 가져올 것이다.

따라서 본 논문에서는 fitness function으로 다음과 같이 제안한다.

$$F = \lambda_1 Q_1 + \lambda_2 \frac{1}{Q_2} \quad (4)$$

여기서 Q_1 은 특징벡터의 부분집합으로 클래스를 식별하여 나온 정확도이고 Q_2 는 선택되어진 고유벡터의 개수이다. 아래의 식 (5-6)은 각각의 식을 나타낸다.

$$Q_1 = \frac{\text{클래스터링된 영상의 수}}{\text{클래스 내 전체 영상의 수}} \quad (5)$$

$$Q_2 = '1' \text{비트의 개수} \quad (6)$$

본 논문에서는 λ_1 은 100으로 λ_2 는 10으로 하였다. 많은 특징수를 포함한 집합이라도 정확도가 높은 것이 적은 수의 특징을 포함하고 정확도가 낮은 집합 보다 중요하다. 이러한 이유에 근거하여 실험을 통하여 λ_1 , λ_2 값을 위와 같이 설정하였다. 만약 보다 신속한 식별 결과를 우선조건으로 가진다면 fitness function에서 특징벡터의 수에 가중치를 더해주어야 할 것이다.

3) 초기 집단

개체군은 36비트의 염색체로 구성된 236개가 있다. 이러한 개체군 중 랜덤하게 10개를 뽑아 제 1세대의 염색체로 구성한다.

4) 선택

SVM classification 시스템을 이용하여 뽑혀진 1세대의 특징벡터 부분집합으로 카테고리를 재구성하여 accuracy를 측정한 후 적합도 측정을 한다. 이렇게 측정된 적합도는 전통적인 염색체 선택 방법인 룰렛 휠 방법을 써서 생존확률이 높은 것이 선택되도록 한다. 여기에선 2개의 염색체를 선택한다.

5) 교배

선택과정에 의해 추출된 두 개의 염색체는 하나의 포인트를 임의로 선택하고 이를 기준으로 두 염색체를 포인트를 기준으로 서로 교환하여 진화를 유도한다. 이때, 교배확률은 1로 하였다.

6) 돌연변이

돌연변이 확률을 0.03로 하여 one-point 돌연변이를 실시하였다.

7) 매개변수 선언과 학습 중지

- ▶ 교배학률 = 1.0
- ▶ 돌연변이 확률 = 0.03

GA을 통하여 1세대가 만들어지고 이렇게 만들어진 세대는 적합도 측정을 통하여 선택, 교배, 돌연변이를 하게 된다. 과정을 모두 거친 후 1세대의 개체군의 평균 적합도가 threshold1=88보다 크고 최고 적합도가 threshold2=93보다 크다면 이 알고리즘은 학습을 중지하고 최고값을 가지는 염색체를 선택하게 된다. 만약 위의 조건을 만족하지 못하면 적합도 측정, 선택, 교배, 돌연변이를 다시 수행하게 된다.

IV. 실험 및 결과

본 연구에서 제안된 알고리즘은 인텔 펜티엄4 1.8G와 512M 메모리 등의 하드웨어와 VC++ S/W를 이용하여 구현되었다. 실험 대상으로는 10개의 카테고리 200개의 일반 스틸 영상을 이용하여 영상을 클러스터링 하였다. 표 3에는 본 논문의 실험을 위한 영상 데이터의 종류와 개수를 나타내고 있다.

표 3. 영상 class
Table 3. Image Class

image class	learning	Training	Testing
Airplane	200	160	40
Eagle	200	160	40
Horse	200	160	40
Rose	200	160	40
Polar Bear	200	160	40
Sunset	200	160	40
Valley	200	160	40
Dolphin	200	160	40
Tiger	200	160	40
Bear	200	160	40
Sum		2000	

본 논문에서는 classification의 성능 평가의 척도로써 정확도를 식 7과 같이 나타내었다.

$$\text{정확도} = \frac{\text{클러스터링된 영상의 수}}{\text{클래스 내 전체 영상의 수}} \dots\dots\dots (7)$$

4.1 입력벡터 변화에 따른 성능 비교

각 입력벡터에 따른 성능 비교를 위하여 색상, 질감, 색상+질감 특징치를 각각 사용하였다. 표 4는 색상, 질감, 색상과 질감의 연합의 학습 결과를 전체적으로 보여주는 것이다.

표 4. 전체 성능 비교
Table 4. Total performance comparison

image features	Type of kernel	Number of classes	Training (%)	Testing(%)
색상	Linear	10	90.00	88.09
	Polynomial	10	92.82	90.36
	RBF	10	94.06	91.96
	Sigmoid	10	92.76	90.64
질감	Linear	10	83.36	80.34
	Polynomial	10	85.33	82.65
	RBF	10	86.91	83.68
	Sigmoid	10	86.76	83.43
색상과 질감의 연합	Linear	10	92.49	90.83
	Polynomial	10	95.84	93.21
	RBF	10	97.11	95.87
	Sigmoid	10	95.90	94.06

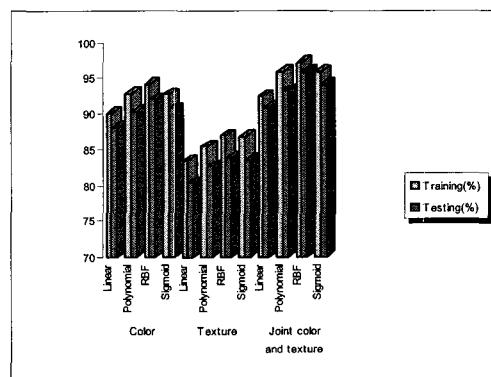


그림 3. 실험 결과
Fig 3. Experimental result

그림 3은 특징의 종류에 따른 커널별 식별 결과를 나타내는 그래프이다. 특징치에 의한 실험 결과 성능은 연합 특징치, 색상, 질감 특징치 순이었고 전체적으로 RBF 커널을 사용하였을 때 가장 좋은 성능인 95.87%를 보여주었다. 실험 결과에서 보듯이 영상의 식별은 색상과 질감 정보를 함께 고려하여야 오인식률을 줄일 수가 있다.

4.2 SVM과 제안된 알고리즘의 성능 비교

실험은 SVM만으로 식별한 것과 GA를 이용한 유효 특징치 추출에 의해 추출된 특징벡터를 SVM 입력벡터로 식별한 것과의 성능 비교이다. 이때 각각의 특징벡터는 색상과 질감의 연합 그리고, SVM은 RBF커널을 사용하였다. 표 5는 SVM과 제안된 알고리즘의 성능 비교의 결과이다. 그림 4는 표 5를 도시화 한 결과이다.

표 5. SVM과 제안된 알고리즘과의 성능 비교
Table 5. Performance Comparison to SVM and proposed algorithm

image class	SVM(%)	GA+SVM(%)
Airplane	92.7	94.2
Eagle	94.1	96.2
Horse	92.7	99.5
Rose	94.1	95.9
Polar Bear	99.0	99.0
Sunset	96.6	99.4
Valley	81.9	87.0
Dolphin	93.2	96.2
Tiger	92.7	94.5
Bear	94.7	96.8
Average	93.27	95.87

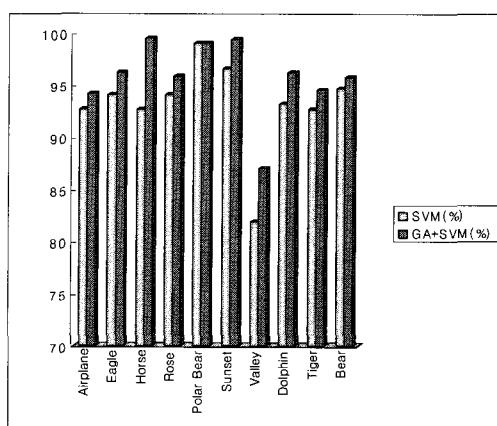


그림 4 SVM과 제안된 알고리즘의 성능 비교
Fig 4. Performance Comparison to SVM and propose algorithm

V. 결론

본 논문에서는 내용기반 영상검색 시스템을 구현하고자 데이터마이닝 기법을 이용하여 알고리즘을 제안하였다. 대용량의 데이터를 다루는 멀티미디어 정보검색에서는 데이터 처리량 감소와 정확도 향상을 요구한다. 이를 위해 GA와 SVM을 혼합하여 최적 유효 특징 벡터 집합을 추출 한 후, 식별을 실시함으로써 높은 정확도와 데이터 처리량의 감소를 가져왔다.

실험을 통하여 영상의 식별 정확도는 색상 또는 질감을 단독으로 쓰는 것 보다 두 가지 특징치를 모두 고려한 연합 특징치를 쓰는 것과 SVM 알고리즘의 RBF 커널을 적용하는 것이 좋은 성능을 보임을 알 수 있었다. 또, SVM 식별보다는 GA와 SVM을 혼합한 알고리즘으로 식별한 것이 더 높은 정확도를 보임을 알 수 있었다.

향후 과제는 다음과 같다.

첫째, 본 논문에서는 자연영상을 위주로 연구를 하였으나 향후에는 상업성이 강한 상품 검색을 위주로 한 연구가 필요하다. 온라인상에서는 데이터 저장 공간과 처리 속도 등을 고려하여야 하기 때문에 상품 검색 시 최소의 데이터 처리량을 가져야 한다. 그러므로 영상 전체를 특징으로 쓰기보다는 상품만을 객체 분할하여 데이터양을 줄임과 동시에 검색의 효율을 높일 필요가 있다.

둘째, 영상을 온라인상에서 입력 받아 실시간으로 학습 할 수 있는 연구가 필요하다. 이러한 연구를 하기 위하여 학습된 패턴을 기억하면서 새로운 패턴을 실시간으로 계속 학습하는 적응성-안정성(Plasticity-Stability)을 동시에 유지할 수 있는 모델을 구현하여야 한다.

참고문헌

- (1) Smith, J.R., Chang, S.F., Tools and techniques for color image retrieval, In Proc. SPIE: Storage and Retrieval for Image and Video Databases IV, Vol. 2670, 1996, pp.426-437.
- (2) Manjunath, B.S., Ma, W.Y., Texture features for browsing and retrieval of image data, Tech. Rep. CIPR TR, 95-06, 1995.

- [3] Jain, A.K., Vailaya, A., Shape-based retrieval:
A case study with trademark image databases.
Pattern Recognition, Vol. 31, No. 9, 1998, pp.
1369-1390.
- [4] Flickner, M., Sawhney, H., Niblack, W., Ashley,
J., Huang, Q., Dom, B., Gorkani, M., Hafer, J.,
Lee, D., Petkovic, D., Steele, D., Yanker, P..
Query by image content: The QBIC system, IEEE
Computer, Vol. 28, No. 9., 1995, pp.23-31.
- [5] Smith, J.R., Chang, S.E., VisualSEEK: A fully
automated content-based image query system.
In Proc. ACM Multimedia, 1996, pp.87-98
- [6] 박상성, 안동규, "유전자 알고리즘을 이용한 영상 특징 추
출", 한국컴퓨터정보학회논문지, 11권3호, pp.
133-139, 2006.
- [7] V. Vapnik., Statistical Learning Theory.
Springer, New York, 1998.
- [8] H. Drucker, D. Wu, and V.N. Vapnik., "Support
vector machines for spam categori-zation",
IEEE Transactions on Neural Networks, Vol. 10,
No. 5, pp. 1048-1054, 1994.

저자 소개



박상성

2006년 2월 : 고려대학교 산업시스템정보
공학과 박사

2006년~현재 : 고려대학교 BK21 사업단
연구진임강사

관심분야: 패턴인식, 컴퓨터비전



정귀임

2006년 2월 충주대학교 산업경영학과 졸업

2006년~현재: 고려대학교 정보경영공학부
석사과정

관심분야: 전문가시스템, 패턴인식



장동식

1988년 2월 텍사스 A&M 산업공학 박사

1989년~현재 : 고려대학교 정보경영공학부
교수

관심분야: 패턴인식, PM, 컴퓨터비전