

논문 2011-48CI-1-6

다중 클래스 아다부스트 알고리즘

(Multiclass-based AdaBoost Algorithm)

김 태 현*, 박 동 철**

(Tae-Hyun Kim and Dong-Chul Park)

요 약

본 논문은 다중 클래스 데이터의 효율적 분류를 위한 새로운 아다부스트 알고리즘을 제안한다. 기존의 아다부스트 알고리즘은 기본적으로 이진 분류기이므로 다중 클래스 데이터 분류의 적용에는 매우 제한적이었다. 이를 극복하기 위하여 제안된 알고리즘은 여러 개의 이진 분류기 대신 하나의 다중 분류기를 약 분류기로 사용함으로써 학습시간을 단축시키고 안정적인 정확도를 얻을 수 있는 장점이 있다. 제안하는 알고리즘의 성능을 평가하기 위하여 Caltech 영상 데이터베이스에서 4가지 클래스의 영상 데이터를 총 800개 수집하여 영상 분류 실험을 진행하였다. 실험의 결과 제안된 다중 클래스 아다부스트 알고리즘은 Adaboost.M2 알고리즘에 비해 분류정확도는 대등한 결과를 얻었지만, 학습시간을 학습단계에 따라 83.1%까지 감소시킬 수 있었다.

Abstract

We propose a multi-class AdaBoost algorithm for an efficient classification of multi-class data in this paper. Traditional AdaBoost algorithm is basically a binary classifier and it has limitations when applied to multi-class data problems even though multi-class versions are available. In order to overcome the problems on the AdaBoost algorithm for multi-class classification problems, we devise an AdaBoost architecture with a training algorithm that utilizes multi-class classifiers for its weak classifiers instead of series of binary classifiers. Experiments on a image classification problem using collected Caltech Image Database are performed. The results show that the proposed AdaBoost architecture can reduce its training time while maintaining its classification accuracy competitive when compared to Adaboost.M2.

Keywords : Image Classification, Data retrieval, Adaboost.

I. 서 론

멀티미디어 데이터는 데이터의 특징을 간단하면서 정확하게 표현할 수 없는 특성 때문에 정보 검색에 많은 어려움이 있다. 특히 영상 데이터의 경우 검색을 위한 데이터의 구축에 사람이 주석을 붙이는 주석 기반 검색 기법을 이용할 경우 많은 기회비용과 시간이 요구된다. 또 주석기반 검색 기법은 사람이 의미정보를 기술하는 것으로 제한된 범위 내에서 효율적인 검색이

가능하지만 대용량의 데이터에 대해 주석을 붙이는 사람과 검색하는 사용자의 관점의 불일치 때문에 검색의 비효율성이 나타난다. 그에 반해 특정 데이터를 자동으로 추출하여 이를 기반으로 검색하는 내용기반 검색 기법은 데이터 간 특징을 수치화하여 사용함으로써 보다 객관적이고 효율적인 검색을 제공할 수 있다. 하지만 영상 데이터의 경우 대부분 용량이 크거나 데이터의 수가 방대하여 얼마나 효과적이며 정확하게 찾을 수 있는가 하는 문제에 대해 특정 추출 기법과 분류기법에 대한 많은 연구가 이루어지고 있다^[1~5].

Freund와 Schapire에 의해 소개된 아다부스트 알고리즘은 여러 개의 약 분류기를 직렬로 연결하여 성능이 좋은 강 분류기를 생성하는 부스팅 기법 중 하나이다. 아다부스트는 얼굴탐색, 물체탐색, 얼굴인식, 음성인식,

* 학생회원, ** 정회원, 명지대학교 전자공학과

(Dept. of Electronic Eng., Myong Ji University)

※ 본 연구는 2010년 정부(교육과학기술부)의 재원으로
한국연구재단의 지원을 받아 수행된 연구임
(2010-0009655).

접수일자: 2010년12월5일, 수정완료일: 2011년1월7일

특징선택 등 많은 분류, 인식 문제에 대해 적용되어 성공적인 성능을 보여주었다.^[7~9] 하지만 이진분류문제를 해결하기 위해 설계된 아다부스트 알고리즘은 (1) 여러 클래스에 대해 단순 추측보다 좋은 약 분류기를 얻기 힘들고, (2) 클래스의 증가와 전체 학습단계(T)의 증가에 따라 학습시간이 매우 길어지는 문제가 발생한다. 이런 문제를 해결하기 위해 본 논문에서는 무감독 경쟁 분류 알고리즘^[6, 10~12]과 약 분류기들을 이용하여 하나의 강 분류기를 생성하는 부스팅(Boosting) 기법^[7]을 결합하여 효과적으로 영상을 분류하는 새로운 다중 분류기 기반 아다부스트(AdaBoost) 알고리즘을 제안한다.

본 논문의 II장에서는 대표적인 부스팅 알고리즘인 아다부스트 알고리즘과 기존의 다중 클래스(multi-class)아다부스트 알고리즘에 대해 살펴보고, III장에서는 기존의 다중 클래스 아다부스트 알고리즘의 문제를 개선한 새로운 다중 클래스 아다부스트 알고리즘을 제안한다. IV장에서는 약 분류기로 사용될 Self Organizing Map(SOM)^[10]과 중심 신경망 알고리즘(Centroid Neural Network: CNN)^[11~12]에 대해 간단하게 알아보며, V장에서는 실험을 통해 제안된 알고리즘의 성능을 살펴본다. VI장은 본 논문의 결론이다.

II. 아다부스트 알고리즘

아다부스트 알고리즘은 약 분류기(Weak Classifier)를 이용하여 강 분류기(Strong Classifier)를 생성하는 방법으로 얼굴영역의 검출이나 물체검출 같이 목적물 검출과 각각의 단계에서 약 분류기를 통해 하나의 특정 차원을 선택하는 특징 선택에 성공적으로 적용되었다.^[13~14] 기본적인 아다부스트 알고리즘은 두 개의 클래스를 가지는 문제에 대해 약 분류기를 선형적으로 클래스 영역을 표현함으로써 이진 분류 문제에 최적화 되어있다. 그 중 Freund와 Schapire에 의해 소개된 아다부스트 알고리즘은 대표적인 부스팅 알고리즘으로 약 분류기의 수가 증가할수록 오류가 지속적으로 감소함이 증명되었다^[7]. 학습단계에서 우리가 목표로 하는 데이터를 긍정 데이터(positive data)라고 하여 1의 라벨을 할당하고 그에 반하는 부정 데이터(negative data)에는 0의 라벨을 할당한다. 처음 단계에서 긍정 데이터와 부정 데이터의 전체적인 분포에 기초하여 모든 데이터에 대한 가중치를 초기화한다. 그 후 각 데이터의 가중치에 연관된 오류를 최소화 시키는 약 분류기를 선택하고 가중치

를 갱신한다. 이 동작은 미리 정해진 횟수(T)만큼 반복되며, 최종적인 강 분류기는 각 갱신단계(t)에서 선택된 약 분류기와 그에 따른 신뢰도(α)의 결합에 의해 생성된다. 보다 자세한 아다부스트 알고리즘은 참고문헌을 참고할 수 있다^[13~14].

III. 다중 분류기 기반 아다부스트 알고리즘

다양한 환경에서의 2개 이상의 클래스를 가지는 다중 분류 문제를 해결하고, 응용시스템을 구축하기 위해서는 다중 클래스 분류기법이 필요하다. 기존의 아다부스트 알고리즘은 기본적으로 2개의 클래스에 대해 동작하는 것으로, 다중 클래스 분류 문제에 적용하기 위한 기법들로는 다중 클래스 분류 문제를 여러 개의 이진 분류 문제로 분할하고, 이들을 다시 종합하여 최종 결정을 내리는 출력코딩 기법들이 있다.^[13~14] 이를 기반으로 하는 대표적인 기법들로 One-Vs-All 분류기법과 Pair-Wise 분류 기법이 있다. One-Vs-All 분류기법은 각 이진 분류기를 하나의 클래스와 나머지 다른 클래스들을 구분하도록 학습되며, Pair-Wise 기법은 각 이진 분류기를 클래스 A와 클래스 B로 구분하도록 학습되고, 이러한 이진 분류기는 가능한 클래스 조합의 쌍 만큼 생성된다.

이진분류기 기반의 아다부스트 알고리즘은 기본적으로 다중 클래스 문제에 많은 학습시간을 포함하는 문제점을 가지고 있다. 이러한 문제를 해결하기 위해서, 본 논문에서는 대표적인 다중 분류기법인 무감독 군집화 알고리즘을 아다부스트 알고리즘에 적용하였다. 제안된 다중 클래스 아다부스트 알고리즘은 클래스의 수와 관계없이 각 학습단계(t)의 약 분류기를 단일의 군집화 알고리즘을 사용함으로써 학습시간을 줄이고 안정적인 결과를 가지는 강 분류기를 얻을 수 있다. 여기서, N 개의 모든 학습 데이터는 모든 클래스 M 에 관한 가중치(weight)를 가지며, 각 데이터 $\vec{x}_i, i=1,...,N$ 에 대해 $(N \times M)$ 가중치 행렬로 표현될 수 있다. 즉,

$$\begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1M} \\ w_{21} & w_{22} & \cdots & w_{2M} \\ \vdots & & \ddots & \\ w_{N1} & \cdots & w_{NM} \end{bmatrix} \quad (1)$$

또한 각 데이터, i 에 대해 클래스, j 에 속하는가를 나타

내는 목표값, $y_{i,j}$,은 다음과 같이 정의된다.

$$y_{i,j} = \begin{cases} 1, & \text{if } j \in \text{Class}(i) \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

여기서 $\text{Class}(i)$ 는 데이터, i 가 속한 클래스를 나타낸다.

초기의 가중치는 $w_{i,j} = 1/N$ 로 설정한다. 가중치를 정해준 후 약 분류기의 학습은 여러 개의 이진 분류 알고리즘 대신 하나의 다중 분류 알고리즘으로 대체된다. 분류 결과에 대한 오류는 AdaBoostM2에서와 같이 pseudo-loss 오류로 계산되고, 각 학습단계 t 에서 각 클래스 k 에 해당하는 오류, ϵ_k 는 다음과 같이 정의된다.

$$\epsilon_k^t = \frac{1}{2} \sum_i^N w_{i,k}^t |1 - h_k(\vec{x}_i)| + w_{i,k}^t \sum_{j \neq k}^J w_{i,j}^t h_j(\vec{x}_i), \quad j \in J - k \quad (3)$$

여기서 t 는 학습단계를 나타내며, $h_k(\vec{x}_i)$ 는 데이터 i 에 대한 분류기의 출력이다.

원래의 pseudo-loss 오류는 식(3)과 같이 다른 클래스를 목표값으로 하는 이진 분류기의 결과를 포함하지만, 본 논문에서 제안하는 다중 분류 알고리즘은 어떤 클래스에 가장 가까운가를 하나의 출력을 보여주므로, 가장 가까운 클래스를 제외한 다른 클래스에 대한 출력은 자동으로 0이 되므로 식 (3)은 다시 식(4)와 같이 표현될 수 있다.

$$\epsilon_k = \frac{1}{2} \sum_{i=1}^N w_{i,k}^t |1 - h_k(\vec{x}_i)| \quad (4)$$

이를 이용하여, 클래스 k 에 해당하는 약 분류기의 신뢰도를 다음과 같이 각각 구할 수 있다.

$$\beta_k^t = \frac{\epsilon_k^t}{1 - \epsilon_k^t} \quad (5)$$

따라서, 클래스 k 의 가중치 갱신식은 다음과 같이 구할 수 있다.

$$w_k^{t+1} = w_k^t (\beta_k^t)^Q, \quad Q = \frac{1}{2} (1 - h_k^t(\vec{x})) \quad (6)$$

이제 미리 정해진 약 분류기의 학습 단계 T 만큼의 학습이 끝나고 ($t = T$), 모든 약 분류기와 관련된 가중치가 정해지면, 데이터 \vec{x} 에 대한 최종의 강 분류기 $H(\cdot)$ 는 다음과 같이 얻어진다.

$$H(\vec{x}) = \arg\max_k \sum_{t=1}^T \alpha_k^t h_k^t(\vec{x}), \quad \alpha_k^t = \log \frac{1}{\beta_k^t} \quad (7)$$

IV. 실험에 사용된 군집화 알고리즘

현재까지 많은 군집화 알고리즘이 개발되어 왔으며 영상 분류를 포함한 많은 분야에 쓰이고 있다.^[5~6, 11] 그 중 Self-Organization Map(SOM)^[10]과 Centroid Neural Network(CNN)^[11~12]을 본 실험에 사용하여, 제안된 알고리즘의 성능을 검증하고자 한다. Kohonen에 의해 개발된 SOM은 수많은 논문에서 소개되었으므로, CNN 알고리즘에 대해 간단히 살펴본다.

중심 신경망(CNN)은 k-means와 SOM 같은 기존의 알고리즘이 매 학습마다 연결 강도(weight)를 수정하는 것과 달리, 승자와 패자의 연결 강도를 각각 설정하여 현재와 이전 학습에서 뉴런의 상태에 대한 정보를 이용하여, 가중치를 변화시킨다. 즉, 이전 학습에서 승자였지만 현재의 학습에서 입력데이터에 가장 가깝지 않다면 현재 학습에서는 패자라고 정의한다. SOM은 매 반복 갱신에서 모든 연결강도를 수정하지만, 중심신경망은 각 뉴런이 승자 또는 패자의 상태가 변할 경우에만 연결 강도를 수정하므로, 학습시간을 안정적으로 감소시킬 수 있는 장점이 있다.

중심 신경망은 k-means 알고리즘과 SOM같은 기존의 알고리즘들과 비교하여 사전 학습 계수나 전체 학습 반복수(epoch)등의 변수를 설정할 필요가 없고, 기존의 군집화 알고리즘에서 문제점으로 지적되었던 초기 연결강도 설정의 문제를 효과적으로 해결함으로써 준 최적의 군집화 결과를 안정적으로 도출하는 장점이 있다. 중심신경망에 대한 보다 자세한 내용을 참고문헌을 참고할 수 있다.^[11~12]

IV. 실험 및 결과

우리는 기존의 알고리즘들과 제안된 알고리즘의 성능 비교를 위해 Airplane, Cars, Faces, Leopards의 4가지 클래스의 영상 데이터를 분류하는 실험을 진행하였다. 실험에 사용된 데이터는 Caltech 데이터베이스에서 각 클래스에 200개의 영상을 추출하여, 총 800개의 데이터를 실험에 사용하였다. 그럼 1은 데이터의 예이다.

기존의 다중 분류 아다부스트 알고리즘들의 하나인 Adaboost.M2와 제안된 알고리즘의 학습시간과 정확도를 비교하고, 제안된 알고리즘에서 약 분류기로 사용된 군집화 알고리즘인 SOM과 CNN의 단일 분류기에 관한 정확도와 제안된 알고리즘의 정확도를 비교 분석 하였

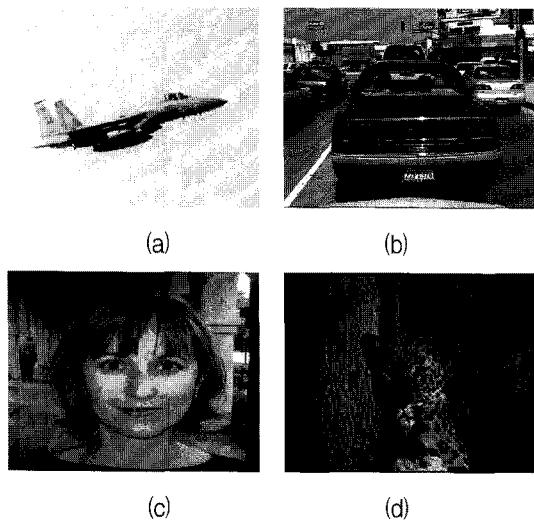


그림 1. Caltech 데이터의 예
 (a) 비행기 (b) 자동차 (c) 얼굴 (d) 표범
 Fig. 1. Examples of Caltech Database.
 (a) airplane (b) car (c) face (d) leopard

다. 각 클래스의 데이터 200개는 다시 170개의 무작위로 추출된 학습데이터 부분과 나머지 30개의 검증데이터 부분으로 나뉘어 사용된다. 실험은 10개의 서로 다른 학습 데이터/검증데이터 쌍으로 진행되었다. 즉, 각 클래스에서 무작위로 추출된 680개의 학습데이터와 나머지 120개의 검증데이터 쌍을 만들어 실험을 진행하고, 다시 각 클래스에서 무작위로 680개의 학습데이터를 추출하고, 나머지 120개의 검증데이터 쌍에 대해 실험을 진행하는 방법으로 10번의 실험을 진행하였다. 본 논문에서 보고되는 각 알고리즘의 정확도는 이러한 10번의 실험의 결과에서 보인 각각의 정확도에 대한 평균과 표준편차로 표현된다. 각 데이터의 특징추출 과정에서 색상, 주파수, 형태, 패턴의 영역을 각각 표현해 줄 수 있는 다음 4가지의 특징추출방법을 사용하였다.

- 1) HSV (Hue, Saturation, Value)^[1] - 200 차원
- 2) DCT(Discrete Cosine Transform)^[2] - 64 차원
- 3) Hough Transform^[3] - 54차원
- 4) Wavelet Transform^[4] - 68차원

하지만, 위의 차원을 가지는 데이터의 학습은 대부분 알고리즘에 사용된 기본 분류기에 사용하기에는 매우 부적절하며, 학습에서 대부분 발산하는 상황이 발생했다. 이에 대처하기 위하여, 데이터의 차원을 줄이는 방법으로, 우리는 3차원의 SOFM (Self-Organizing Feature Map)을 사용하였는데, 이를 통해 전체적인 테

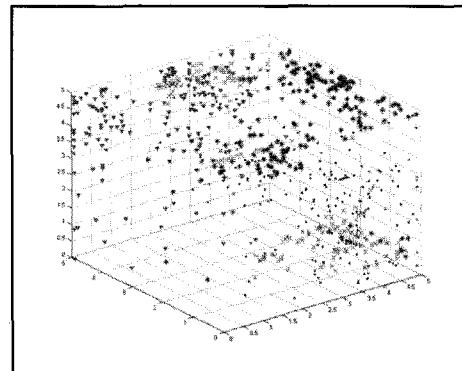


그림 2. HSV에 대한 Self-Organizing Feature Map
 Fig. 2. Self-Organizing Feature Map of HSV feature.

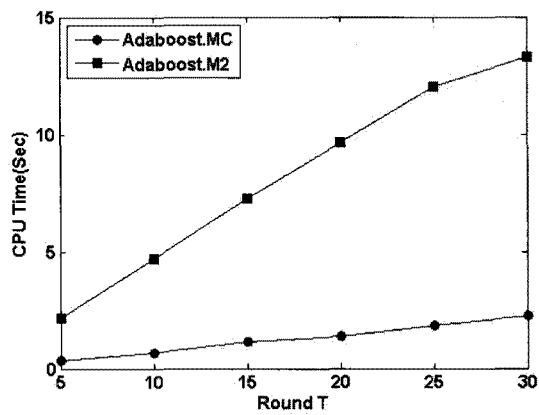


그림 3. 학습단계(T)에 따른 학습시간(sec)
 Fig. 3. CPU time for different algorithms vs. Training rounds.

이터의 차원 수를 각 특징별로 3차원씩 총 12차원의 단일 특징 벡터로 생성하였다. 그림 2는 SOFM에서 나타난 데이터의 한 예이다.

1. 학습단계 수에 따른 학습 시간 비교

기존의 알고리즘과 제안된 알고리즘의 학습시간을 비교하기 위해 전체 분류기의 학습단계(T)의 증가에 따른 학습 시간(sec)을 비교하였다. 그림 3과 같이 제안된 알고리즘이 비교적 점진적인 학습시간의 증가를 보여주는 것에 반해 기존의 Adaboost.M2 알고리즘은 학습단계(T)의 증가에 따라 높은 증가율을 보여주고 있다. 학습 시간이 30단계의 경우 제안된 다중분류기 기반의 아다부스트 알고리즘은 기존의 AdaboostM2에 비해 약 16.9%의 정도의 학습시간만을 요구함을 알 수 있으며, 학습단계수의 증가에 따라 그 학습시간의 감소는 더욱 커질 것임을 알 수 있다. 실험에 사용한 PC의 제원은 다음과 같다. CPU : Pentium R core2Duo E6300

2.80GHz, RAM : 2 GByte , HDD : 7200rpm WD500G,
운영체제 : 32bit Window 7.

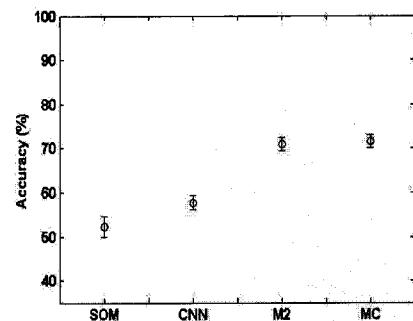
2. 알고리즘에 따른 정확도 비교

Caltech 데이터베이스를 사용하는 실험을 통해 CNN, SOM, Adaboost.M2 그리고 제안된 다중 분류기 기반 아다부스트(MC) 알고리즘의 정확도를 비교하였다. 실험에서는 학습단계(T)를 변화시켜, 그 정확도를 측정하였는데, 학습단계(T)가 10을 초과하면, 그 정확도가 포화상태가 되어 더 이상 학습단계(T)가 성능에 영향을 미치지 않게 됨을 알 수 있었다. 표 1과 그림 4~5의 경과는 학습단계(T)가 10인 경우의 정확도를 나타낸다. HSV, DCT, Hough, Wavelet에 대한 실험 결과는 그림 4에서 주어지는데, 이 4가지 특징에 대한 실험 결과는 80%의 정확도를 넘지 못함을 알 수 있다. 이는 각 특징들이 종합적인 정보를 가지고 있는 것이 아니므로 어떤 클래스에 대한 간접성이 최종 클래스 결정에 영향을 주기 때문이다. 그러나 SOFM을 이용하여 앞의 4가지 특징을 모두 합친 데이터의 경우, 약 분류기로 사용된 SOM과 CNN에서도 어느 정도 좋은 성능을 보여주고 Adaboost.M2나 제안된 알고리즘에 실험 결과는 다른 어떤 특징 개별적인 것보다는 좋은 성능을 보여준다. 기존의 Adaboost.M2와 본 논문에서 제안하는 MC의 성능은 오차범위 이내에서 대등한 분류 정확도를 보여준다. 이는 만일 두 알고리즘의 학습시간이 같다면 제안된 알고리즘은 더욱 많은 학습단계를 가질 수 있으므로 보다 향상된 정확도를 기대할 수 있다.

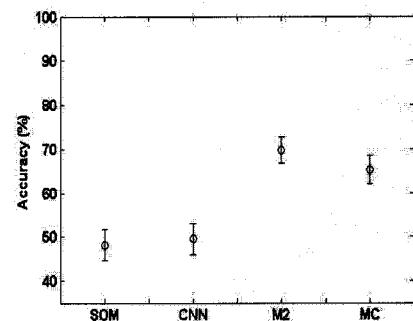
표 1. Cal-tech 데이터에 대한 실험결과 (T=10)
Table 1. Classification accuracy on different algorithms.

feature	SOM	CNN	M2	MC
HSV	52.30	57.67	70.89	71.56
DCT	48.21	49.60	69.80	65.33
Hough	42.00	47.22	68.52	68.12
Wavelet	54.83	57.30	79.52	77.04
Conc	64.47	67.18	90.18	89.20

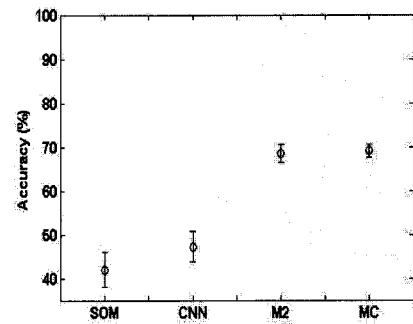
※주 : SOM(Self Organizing Map), CNN(Centroid Neural Network), M2(Adaboost.M2), MC(Multiclass-based Adaboost)



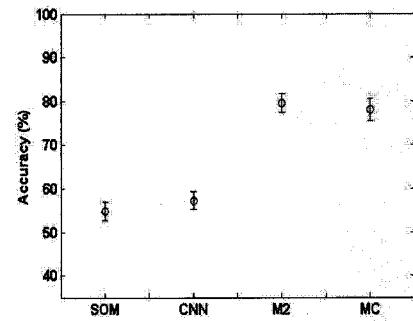
(a) HSV



(b) DCT



(c) Hough



(d) Wavelet

그림 4. 특징벡터에 따른 알고리즘 정확도

Fig. 4. Classification accuracy on individual feature vector.

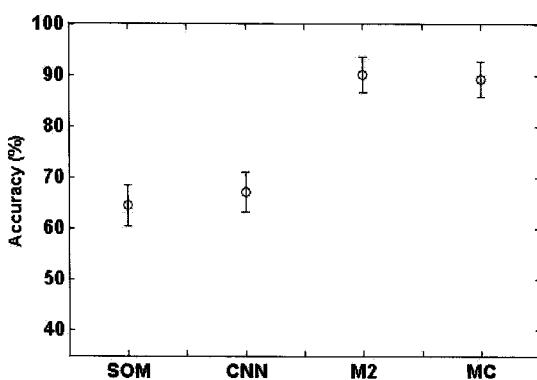


그림 5. SOFM에 의해 특징벡터의 차원을 줄인 후의 실험에 의한 정확도 비교

Fig. 5. Classification accuracy comparison after reducing feature dimensions by SOFM.

V. 결 론

본 논문에서는 다중 분류기를 기반으로 하는 아다부스트 알고리즘을 제안하였으며, SOM과 CNN 알고리즘, 그리고 기존의 분류모델인 Adaboost.M2와 제안된 알고리즘에 다중 클래스의 영상 데이터를 사용하는 영상 분류 문제에 대한 실험을 통해 그 성능을 비교하였다. 제안된 다중 분류기 기반 아다부스트 알고리즘은 학습시간에 관한 실험에서 기존의 Adaboost.M2 알고리즘보다 월등히 빠른 학습속도를 보여주었다. 데이터에 존재하는 클래스의 수와 학습단계의 수에 따라 상대적으로 더욱 빠른 속도를 보일 수 있는데, 이는 학습할 데이터의 양이 증가하거나 전체 약 분류기의 수가 증가함에 따라 더욱 큰 차이를 보여주었다. 전체적인 성능은 거의 대등한 성능을 보여주었다. 하지만 그 같은 학습시간에 더욱 많은 약 분류기를 학습할 수 있다는 사실을 감안하면 사실상 제안하는 다중 분류기를 기반으로 하는 아다부스트 구조의 분류기는 더욱 유용성이 높은 것을 알 수 있다.

참 고 문 헌

- [1] G. Paschos, "Perceptually uniform color spaces for color texture analysis: an empirical evaluation", IEEE Transactions on Image Processing, V.10, No.6, pp.932-937, 2001
- [2] E.Y. Lam and J.W. Goodman, "A mathematical analysis of the DCT coefficient distributions for images", IEEE Trans. on Image Processing, V.9,

- No.10, pp.1661-1666, 2000
- [3] Zhi-Zhong Wang and Jun-Hai Yong, "Texture Analysis and Classification With Linear Regression Model Based on Wavelet Transform", IEEE Trans. on Image Processing, V.17, No.8, pp.1421-1430, 2008
- [4] Masi. S and Malik. J, "Object detection using a max-margin Hough transform", IEEE Computer Vision and Pattern Recognition, 2009
- [5] 김재영, 박동철, "진보된 다단계 특징벡터 기반의 분류기 모델", 전자공학회논문지, 제47권 CI편, 제3호, 2010년 5월.
- [6] Ying Shan, et al. "Unsupervised Learning of Discriminative Edge Measures for Vehicle Matching between Nonoverlapping Cameras", IEEE, Trans, Pattern Analysis and Machine Intelligence, V.30, pp. 700-711, 2008
- [7] P. Viola, M. Jones, "Rapid object detection using a boosted cascade of simple features," Proc. of IEEE ICCVPR, V.1, pp. 511-518, 2001.
- [8] 윤창용, 장석윤, 박민용, "수직면과 아다부스트를 사용한 실시간 교통 표지판 검출", 전자공학회논문지, 제46권 SC편, 제5호, 29-37쪽, 2009년 9월.
- [9] 김재협, 장경현, 이준행, 문영식, "아이다부스트와 원형기반합수를 이용한 다중표적 분류 기법", 전자공학회논문지, 제47권 CI편, 제3호, 2010년 5월.
- [10] T. Kohonen, "The Self-Organizing Map", Proc. IEEE, V.78, pp 1464-1480. 1990
- [11] D.C Park, "Centroid Neural Network for Unsupervised Competitive Learning", IEEE Trans. Neural Networks, V.11, pp 520-528. 2000
- [12] D.C Park et al., "Centroid Neural Network with a Divergence Measure for GPDF Data Clustering", IEEE Trans. Neural Networks, V.19, NO. 6, pp 948-957. 2008
- [13] Y. Freund and R.E. Schapire, "A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting", LNCS, V.904, pp. 23-37, 1995
- [14] R. Schapire, "Using output codes to boost multiclass learning problems", Proc. ICML, 1997.

저자소개



김 태 현(학생회원)
2010년 명지대학교 정보공학과
학사 졸업.
2012년 명지대학교 전자공학과
석사 졸업 예정.
<주관심분야 : 신경망, 인공지능,
신호처리, 영상처리, 반도체>



박 동 철(정회원)
1980년 서강대학교 전자공학과
학사 졸업.
1982년 한국과학기술원 전기 및
전자공학과 석사 졸업.
1990년 Univ. of Washington,
Seattle, Dept. of
Electrical Eng. 박사 졸업
2010년 현재 명지대학교 전자공학과 교수.
<주관심분야 : 지능컴퓨팅, 신호처리>