

논문 2010-47CI-3-3

# 아이다부스트(Adaboost)와 원형기반함수를 이용한 다중표적 분류 기법

( Multi-target Classification Method Based on Adaboost and Radial  
Basis Function )

김 재 협\*, 장 경 현\*\*, 이 준 행\*, 문 영 식\*\*\*

( Jae Hyup Kim, Kyung Hyun Jang, Jun Haeng Lee, and Young Shik Moon )

## 요 약

최근 기계학습 분야에서 커널머신을 이용한 대표적 분류기로 Adaboost가 주목받고 있다. Adaboost는 통계적 학습이론에 기반하여 뛰어난 일반화 성능을 보여주며, 다양한 패턴인식 문제에 적용되고 있다. 그러나, Adaboost는 이진 분류기이므로 다중 표적 분류 문제에 곧바로 적용할 수 없다. 일반적으로 다중 분류 문제를 해결하는 기법으로 One-Vs-All 기법과 Pair-Wise 기법이 대표적이다. 이러한 두 기법은 다중 분류 문제를 여러 개의 이진 분류 문제로 분할하고, 이들을 다시 종합하여 최종 결정을 내리는 출력코딩이라는 일반적인 기법으로 실제 시스템 구성에 적합할만한 분류 성능을 보여주지 못하는 경우가 대부분이다. 본 논문에서는 이진 분류기인 Adaboost의 다중 분류 확장 방안으로 원형 기반 함수를 약한 분류기로 이용하는 Adaboost 기반 다중표적 분류 기법을 제안한다.

## Abstract

Adaboost is well known for a representative learner as one of the kernel methods. Adaboost which is based on the statistical learning theory shows good generalization performance and has been applied to various pattern recognition problems. However, Adaboost is basically to deal with a two-class classification problem, so we cannot solve directly a multi-class problem with Adaboost. One-Vs-All and Pair-Wise have been applied to solve the multi-class classification problem, which is one of the multi-class problems. The two methods above are ones of the output coding methods, a general approach for solving multi-class problem with multiple binary classifiers, which decomposes a complex multi-class problem into a set of binary problems and then reconstructs the outputs of binary classifiers for each binary problem. However, two methods cannot show good performance. In this paper, we propose the method to solve a multi-target classification problem by using radial basis function of Adaboost weak classifier.

**Keywords :** Adaboost, Radial basis function, Multi-class classification, target classification

## I. 서 론

\* 정회원, 삼성탈레스

(Samsung Thales Co.)

\*\* 학생회원, \*\*\* 평생회원-교신저자, 한양대학교 컴퓨터 공학과

(Dept. of C.S.E., Hanyang University)

※ 이 논문은 2009년 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (2009-0077434, 한양대학교)

접수일자: 2010년4월5일, 수정완료일: 2010년4월30일

자연 환경에서 임의의 형태로 움직이는 이동 표적을 실시간으로 식별하고 추적하기 위한 알고리즘 및 시스템에 대한 연구는 미사일 유도, 항공기 추적, 레이더 등과 같은 전략 방위 분야에서 뿐만 아니라 컴퓨터 비전, 자동 감시, 항공 관제 등 산업 분야에서 첨단 기술

술로서 그 연구 개발이 절실히 요구되고 있다. 특히, 전략 방위 분야에서 미사일 등 급속한 무기 체계의 발전에 의해 적의 공격에 효율적으로 대처할 수 있는 시간이 수분 이내로 제한되고, 최근의 고도화된 전자전의 경우 그 시간은 더욱 짧아질 수 밖에 없다. 따라서 영상 인식 및 이해를 위한 컴퓨터 시각장치의 대부분이 공통적으로 갖고 있는 문제점인 시각정보에 의한 인간의 판단능력과 유사한 기능을 가지고 다양한 환경에 적응할 수 있는 시스템을 구현하기 위해서는 인간을 대신하여 많은 정보를 엄밀히 분석하여 정확한 판단 및 대응책을 강구할 수 있는 지능형 자동 인식 체계가 절실히 요구되며, 빠르고 정확한 인식 및 분류 시스템의 연구가 필요하다.

본 논문에서는 최근 기계학습 분야에서 통계적 학습이론에 기반하여 뛰어난 일반화 성능을 보여주고 있는 Adaboost를 기반으로 다중 클래스, 즉 다중 표적 분류 기법을 제안한다.

대부분의 분류 기법은 이진 클래스 분류를 위한 알고리즘이 우선 고안되었다. SVM(Support Vector Machine)<sup>[1]</sup>, Adaboost<sup>[2~8]</sup> 등의 기법들이 우수한 성능과 장점을 가지는 대표적인 기법이다. 이러한 이진 클래스 분류 기법들은 이진 클래스 문제에 국한되어 있기 때문에 일반적인 다중 클래스 문제를 해결할 수가 없다. 다중 클래스 분류 문제를 해결하는 대표적인 기법으로는 One-Vs-All 기법<sup>[9]</sup>과 Pair-Wise 기법<sup>[10]</sup>이 있다. 상기 두 기법은 다중 클래스 분류 문제를 여러 개의 이진 클래스 분류 문제로 분할하고, 이들을 다시 종합하여 최종 결정을 내리는 출력코딩<sup>[11]</sup>이라는 일반적인 기법에 속한다. One-Vs-All 기법은 각 이진 분류기를 하나의 클래스와 나머지 클래스들을 구분하고, Pair-Wise 기법은 하나의 클래스를 또 다른 하나의 클래스와 구분하는 방식이다. 이러한 기법들은 실제 응용분야에서는 활용 가능 수준의 충분한 성능을 보여주지 못하고 있다.

본 논문에서는 뛰어난 성능을 보이고 있는 이진 클래스 분류기 Adaboost의 약한 분류기를 개선한 다중 클래스 분류 기법을 제안한다. 본 논문에서 제안하고자 하는 분류 모델은 기본적으로 아래의 요구조건을 충족시키기 위한 모델이다.

- 다중 표적 분류 시스템
- 동일 표적간의 패턴 공간내 영역 구축
- 분류 표적 패턴의 각 표적에 대한 유사도 도출

- 분류 판단이 불가능한 패턴 공간 영역 설정

기존의 단순 선형 약한 분류기를 대체할 새롭게 정의된 약한 분류기는 원형 기준 함수(Radial Basis Function, RBF)로써 방사형 영역에 대해 클래스의 분류 성능을 계산하여 가중치를 갱신해 나감으로써 각각의 클래스 자체의 분류 영역을 확보한다. 원형 기준 함수의 특징은 중심으로부터 거리가 멀어질수록 함수 값들이 단조 증가 또는 단조 감소한다는 것이다. 이러한 특징으로 인해 원형 기준 함수는 지역성의 특징이 존재하며 따라서 클래스 자체의 영역 표현이 가능해진다.

본 논문은 II장에서 이진 분류 기법을 이용한 다중 분류 기법에 대해 살펴본다. III장에서는 본 연구의 기반이 되는 Adaboost 알고리즘에 대한 내용과 이를 확장한 다중 클래스 분류 기법에 대해 설명한다. IV장에서는 실험 결과를 통하여 제안하는 기법을 분석하고, V장에서는 결론 및 향후 과제에 대해 기술한다.

## II. 다중 분류 기법

다양한 환경에서의 분류 문제를 해결하고, 응용 시스템을 구축하기 위해서는 다중 분류 기법이 필요하다. 이러한 기법들로는 다중 분류 문제를 여러 개의 이진 분류 문제로 분할하고, 이들을 다시 종합하여 최종 결정을 내리는 출력코딩 기법들<sup>[11]</sup>이 있다. 이를 기반으로 하는 대표적인 기법들로 One-Vs-All 분류 기법<sup>[9]</sup>과 Pair-Wise 분류 기법<sup>[10]</sup>을 들 수 있다. One-Vs-All 기법은 각 이진 분류기를 하나의 클래스와 나머지 다른 클래스들을 구분하도록 학습되며, 따라서, K개의 클래스가 있는 경우, 양의 클래스를 하나씩만 가지는 K개의 이진 분류기가 생성된다. 복원은 주로 각 이진 분류기의 출력값이 가장 큰 분류기에 학습된 양의 클래스로 결정하는 방식을 따른다. 이러한 방식에 의해 생성되는 이진 클래스 문제는 학습에 사용되는 음의 클래스는 이질적인 다양한 클래스들로 구성되기 때문에 성능에 대한 신뢰도가 저하된다. Pair-Wise 기법은 각 이진 분류기를 클래스 A와 클래스 B로 구분하도록 학습되고 이러한 이진 분류기는 가능한 클래스 조합쌍만큼 생성한다. 따라서, 풀어야 할 이진 클래스 문제는 단지 두 개의 클래스에 속한 샘플들을 구분하는 비교적 적은 학습샘플로 가능하며, 이렇게 학습된 이진 분류기에 대해 높은 신뢰도의 출력값을 기대할 수 있다.

Pair-Wise 기법은 분할과정에서 이러한 장점이 있는 반면, 디코딩 과정에서는 넌센스 출력의 문제가 발생한다. 넌센스 출력은, 예를들어, 클래스 A와 B에 속하지 않는 입력샘플 X가 A와 B를 분류하는 이진 분류기에 주어지면 이진 분류기는 의미 없는 출력을 하게 되는 현상을 의미한다.

### III. Adaboost를 이용한 다중 표적 분류 기법

부스팅(boosting) 알고리즘이란 이미 주어진 성능이 약한 분류기의 선형 조합을 통해 성능이 강력한 분류기로 만드는 과정을 의미하며, 단순 추측하는 것보다 약간 성능이 좋은 약한 분류기(weak classifier)가 강한 분류기(strong classifier)로 부스팅 될 수 있음이 이미 증명되어있다. 부스팅 아이디어를 실제 자료 분석에 적용할 수 있도록 개량한 기법이 1995년 Freund<sup>[2]</sup> 등에 의해 소개되었으며, 약한 분류기의 수가 증가할수록 부스팅 알고리즘의 에러율은 0에 지수적으로 근접한다는 것을 증명하였다. 부스팅 학습법의 장점으로는 다른 학습법에 비해 예측해야할 파라미터의 수가 적다는 것이다. 또한, 양성 오류(false positive)의 측면에서 부스팅 학습을 진행할 경우 일정 기준 이하의 양성 오류 비율을 가지는 단계별로 쉽게 계층형(cascade) 분류 모델을 구성할 수 있다. 그리고 각각의 단계에서 약한 분류기를 통해 하나의 특정 차원을 선택함으로써 특징 선택의 측면으로 응용이 가능하다.

이러한 부스팅 모델에서 가장 기본적인 기법으로는 Adaboost를 들 수 있다<sup>[2-8]</sup>. Adaboost는 두 클래스의 샘플을 이용하여 매우 약한 분류기를 반복적으로 학습 시킴으로써 최종적으로 강한 분류기를 생성해내는 학습 기법으로써, 초기에는 모든 샘플에 대하여 동일한 가중치를 주고 약한 분류기를 학습시킨 후, 단계가 진행될수록 기초 분류기에서 오분류로 판정된 샘플의 가중치를 증가시킴으로써 약한 분류기의 성능을 높여가는 기법이다. 그림 1에서는 이진 분류형의 Adaboost의 의사 코드를 보여주고 있다<sup>[8]</sup>.

표 1의 약한 분류기는 선형적으로 클래스 영역을 표현하기 때문에 학습된 클래스 이외의 영역에서도 클래스를 분류하게 된다. 이는 각 클래스 이외의 영역부분은 어떤 클래스가 해당하게 되는지 알 수 없는 부분이기 때문에 클래스 분류에 있어 잘못된 결과를 초래하게 되며, 추가적인 클래스에 대한 적응과 주어진 클래스

표 1. 이진 분류 기반 Adaboost  
Table 1. Adaboost based on binary classification.

<p>[1] 학습 샘플 선언  <math>(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)</math>, <math>x_i</math>: 학습 샘플, <math>y_i = \begin{cases} 1 \\ 0 \end{cases}</math>  <math>n = m + l</math>, <math>m</math>: 클래스 1 샘플 개수, <math>n</math>: 클래스 0 샘플 개수</p>	
<p>[2] 초기 가중치  <math>w_{1,i} = \begin{cases} \frac{1}{2m} \\ \frac{1}{2l} \end{cases}</math>, <math>w</math>(단계번호, 샘플번호)  <math>t = 0</math></p>	
<p>[3] 약한 분류기 학습( T 회 반복 )                  - <math>t = t + 1</math>                  - 가중치 일반화 <math>w_{t,i} = \frac{w_{t,i}}{\sum_{j=1}^n w_{t,j}}</math>                  - 모든 특징 <math>j</math>에 대하여 최소 에러(<math>\epsilon_j</math>)를 가지는 약한 분류기 <math>h_j</math>를 선택  <math>\epsilon_j = \sum_i w_i  h_j(x_i) - y_i </math>                  - 가중치 업데이트  <math>w_{t+1,i} = w_{t,i} \beta_i^{1-\epsilon_i}</math>  <math>\epsilon_i = \begin{cases} 1 &amp; \text{if } x_i \text{ is correct} \\ 0 &amp; \text{otherwise} \end{cases}</math>, <math>\beta_i = \frac{\epsilon_i}{1-\epsilon_i}</math></p>	
<p>IF <math>t == T</math> THEN GOTO 4                  ELSE AND GOTO 3</p>	
<p>4. 최종 분류 모델 생성  <math display="block">h(x) = \begin{cases} 1 &amp; \sum_{i=1}^T \alpha_i h_i(x) \geq \frac{1}{2} \sum_{i=1}^T \alpha_i \\ 0 &amp; \text{otherwise} \end{cases}</math>, <math>\alpha_i = \log \frac{1}{\beta_i}</math></p>	

이외에 불분명한 패턴 공간(unknown pattern space)에 대한 정의가 어렵다. 본 논문에서는, 이러한 단순 선형 약한 분류기를 대체하여 원형 기반 함수(Radial Basis Function, RBF)를 이용하여 방사형 영역으로의 분류 모델을 제안하며, 이를 통하여 효과적인 다중 클래스 분류를 위한 Adaboost 모델을 생성한다.

원형 함수의 특징은 중심을 기준으로 퍼진 형태를 가지고 있고, 중심에서 멀어질수록 낮은 출력값을 도출한다. 이런 특징으로 인해 원형 기준 함수는 지역성의 특징이 존재하며 따라서 클래스 자체의 영역의 표현이 가능해진다. 원형 기준 함수는 방사형 기저함수로 다음 식 1과 같이 가우시안 형태로 근사화하여 사용한다.

$$h(x_p, \sigma_q, x_i) = \begin{cases} 1 & \frac{1}{2} \exp\left\{-\frac{\|x_i - x_p\|^2}{2\sigma_q^2}\right\} \geq 0.5 \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

여기에서  $x_i$ 는 입력 특징값을 나타내고,  $x_p$ 와  $\sigma_q$ 는 클래스의 평균과 분산을 나타낸다. 식 1은 1차원 가우

표 2. 원형 함수 기반 Adaboost  
Table 2. Adaboost based on radial basis function.

<p>[1] 학습 샘플 선언  <math>(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)</math>, <math>x_i</math>: 학습 샘플, <math>y_i = \begin{cases} 1 \\ 0 \end{cases}</math>  <math>n = m + l</math>, <math>m</math>: 클래스 1 샘플 개수, <math>n</math>: 클래스 0 샘플 개수</p> <p>[2] 초기 가중치  <math>w_{1,i} = \begin{cases} \frac{1}{2m} \\ \frac{1}{2l} \end{cases}</math>, <math>w_i</math>(단제번호, 샘플번호)  <math>t = 0</math></p> <p>[3] 약한 분류기 학습( T 회 반복 )                  - <math>t = t + 1</math>                  - 가중치 일반화 <math>w_{t,i} = \frac{w_{t,i}}{\sum_{j=1}^n w_{t,j}}</math>                  - 모든 샘플 <math>x_i</math>를 평균으로하는 약한 분류기(원형 기반 함수)에 대하여 최소 에러 확률(<math>\rho_{x_p, \sigma_q}</math>)을 가지는 약한 분류기 <math>h(x_p, \sigma_q, x_i)</math>를 선택  <math display="block">\rho_{x_p, \sigma_q} = \sum_i h(x_p, \sigma_q, x_i)  h(x_p, \sigma_q, x_i) - y_i </math> <math display="block">h(x_p, \sigma_q, x_i) = \begin{cases} \frac{1}{2} \exp\left\{-\frac{\ x_i - x_p\ ^2}{2\sigma_q^2}\right\} \geq 0.5 \\ 0 \text{ otherwise} \end{cases}</math> <math display="block">x_p \in x_1, \dots, x_n, \sigma_q \in \sigma_1, \dots, \sigma_N   1 \leq N \leq 100</math>                 - 가중치 업데이트  <math>w_{t+1,i} = w_{t,i} \beta_i^{1-\epsilon_i}</math>  <math display="block">\epsilon_i = \begin{cases} 1 &amp; \text{if } x_i \text{ is correct} \\ 0 &amp; \text{otherwise} \end{cases}, \beta_i = \frac{\rho_{x_p, \sigma_q}}{1 - \rho_{x_p, \sigma_q}}</math> <p>IF t == T THEN GOTO 4                  ELSE AND GOTO 3</p> <p>4. 최종 분류 모델 생성  <math display="block">h(x) = \begin{cases} 1 &amp; \sum_{i=1}^T \alpha_i h_i(x) \geq \frac{1}{2} \sum_{i=1}^T \alpha_i \\ 0 &amp; \text{otherwise} \end{cases}, \alpha_i = \log \frac{1}{\beta_i}</math></p> </p>
--

시안 함수를 보여주고 있으며, 2차원 이상의 다차원 가우시안 함수의 경우 분산은 공분산행렬로 대체된다. 제안하는 알고리즘에서는 각 특징벡터를 평균으로 하고 100 레벨의 분산 값을 이용하여 약한 분류기를 구성하였다. 또한, 주어진 약한 분류기에 대하여 0.5 이상의 값을 가지는 영역 내에서만 분류 여부를 판단하도록 하였다. 이를 위하여 가우시안 함수를 평균의 위치에서 1의 값을 가지도록 일반화 하였다. 제안하는 알고리즘에서의 Adaboost 모델은 표 2와 같다

IV. 실험 결과

본 논문에서는 원형 함수 기반의 아이다부스트 알고

리즘을 이용한 다중 표적 분류 기법을 제안하였으며, 제안하는 알고리즘을 이용하여 다양한 환경의 다중 표적 분류 시스템을 구성하여 실험을 통해 성능을 검증하였다.

1. 실험 데이터

본 논문에서는 적외선 촬영 기기로 획득된 동영상으로 3클래스로 구성된 총 6종류의 동영상을 이용하여 실험하였다. 실험 데이터에 대한 자세한 내용은 표 3에서 볼 수 있다. 표 3의 동영상 명칭은 저장 동영상의 명칭이며, 각 동영상에 촬영된 표적 영상은 보안 사유로 인하여 본 논문에서는 공개를 하지 않는다.

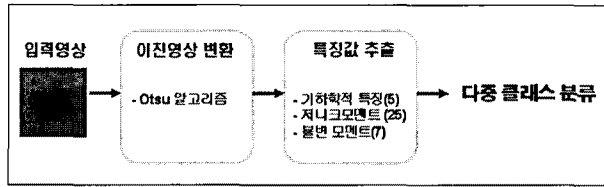
각 동영상의 프레임 으로부터 추출한 영상에서 배경 정보를 제거하고 객체 정보만을 이용하기 위해서 Otsu 알고리즘<sup>[12]</sup>을 이용하여 이진 영상으로 변환한다. 획득된 이진 영상에서 다양한 각도와 크기의 객체(전투기, 헬기, 배)들을 정방형으로 잘라낸 후 특징값을 추출하였다. 특징값은 영상에서의 객체 비율, 영상에서의 객체 외곽선의 비율, 객체의 장축 및 단축 길이, 장축 길이와 단축 길이의 비율을 계산한 기하학적 특징값 5개, 저니크 모멘트(zernike moment)<sup>[13]</sup> 25개, 불변 모멘트(invariant moment)<sup>[14]</sup> 7개로 총 37개의 특징값을 사용하였다. 각 영상에서 추출된 특징값을 기반으로 일부 데이터는 학습에 사용하고 나머지 데이터는 분류 실험에 사용하였다. 그림 1에서는 실험환경에 대한 구성도를 보여주고 있다.

표 3. 실험 데이터  
Table 3. Test data.

클래스	적외선 동영상	영상 개수
전투기	PKX_15527	500장
	성남1D_2_21	500장
헬기	비냉각논산	500장
	PKX_04	500장
전함	2D부양정_ship2D	500장
	대전1D_5_1	500장

그림 1. 실험환경 구성도

Fig. 1. The diagram of testing system.




2. 실험 결과

각 객체 영상의 형태가 비슷한 PKX 동영상에서 추출된 전투기 영상 1500장, 비냉각 검출기 동영상에서 추출된 헬기 영상 500장, 부양정 동영상에서 추출된 배 영상 300장에서 각 객체 영상의 50%를 학습하고, 나머지 50%를 분류 실험하였다.

그림 2는 기존 분류 방법들과 제안하는 방법들과의 성능비교를 나타내고 있다. 실험결과를 살펴보면 학습된 데이터와 분류 실험에 사용된 데이터의 형태가 비슷함에도 불구하고 One-Vs-All 방법과 Pair-Wise 방법은 80%이하의 좋지 못한 분류 결과를 보여주고 있지만 제안하는 방법은 80%이상의 좋은 분류 결과를 보여주고 있다는 것을 볼 수 있다.


그림 2에서 나타난 제안하는 방법의 분류 결과는 각 클래스 영역이 겹치는 부분을 포함한 결과이다. 이 때 각 클래스에만 해당하는 영역과 각 클래스 영역이 겹치는 부분을 고려하여 그림 3과 같이 실험을 하였다. 실험결과에서 확정 부분은 각 클래스에만 해당하는 영역을 사용한 분류 결과이고, 불확실포함 부분은 각 클레



클래스	테스트 영상	인식률		
		One-Vs-All 방법	Pair-Wise 방법	제안하는 방법
전투기	PKX_155217	75.47% (566/750)	79.87% (599/750)	87.47% (656/750)
헬기	비냉각논산	68.80% (172/250)	73.60% (184/250)	80.40% (201/250)
배	2D부양정_ship2D	71.33% (107/150)	80.40% (201/250)	83.33% (125/150)

그림 2. 분류 성능 비교

Fig. 2. The comparison of classification rate.



클래스	테스트영상	인식률	
		확정	불확실포함
전투기	PKX_155217	96.53% (724/750)	87.47% (656/750)
헬기	비냉각논산	98.00% (245/250)	80.40% (201/250)
배	2D부양정_ship2D	95.33% (143/150)	83.33% (125/150)


그림 3. 제안하는 알고리즘 분류 성능 분석

Fig. 3. The classification performance of proposed algorithm.

스 영역이 겹치는 부분을 포함하여 실험한 결과이다. 다중 클래스가 존재할 때 각 클래스간의 겹치는 영역을 배제하고 각 클래스에만 해당하는 영역을 고려하였을 때 95%이상의 좋은 결과를 보이고 있으며, 각 클래스 영역이 겹치는 부분까지 포함한 불확실 포함 결과도 80%이상의 결과를 볼 수 있다.


각 객체 영상의 형태가 상이한 경우 제안하는 방법의 성능을 평가하기 위해서 각기 객체 영상의 형태가 상이한 성남1D\_2\_21 동영상에서 추출된 전투기 영상 300장, PKX\_04 동영상에서 추출된 헬기 영상 500장, 대전 1D\_5\_1 동영상에서 추출된 배 영상 500장에서 각 객체 영상의 50%를 학습하고, 나머지 50%를 분류 실험하였다. 그림 4에서는는 학습된 데이터와 분류 데이터의 형태가 상이한 경우 기존 분류 방법들과 제안하는 방법들과의 성능비교를 나타내고 있다. 실험결과를 살펴보면 학습된 데이터와 분류 실험에 사용된 데이터의 형태가 상이하기 때문에 One-Vs-All 방법은 저조한 분류 결과를 보이고 Pair-Wise 방법은 어느 정도 좋은 분류 결과를 보여주고 있지만 제안하는 방법은 80%이상의 좋은 분류 결과를 보여주고 있다.

형태가 상이한 각 객체 영상이 주어졌을 경우에도 각 클래스에만 해당하는 영역과 각 클래스 영역이 겹치는 부분을 고려하여 그림 5와 같이 실험을 하였다. 각 클래스에만 해당하는 영역을 고려하였을 때 역시 92~94%정도의 좋은 결과를 나타내고, 각 클래스 영역이 겹



클래스	테스트 명상	인식률		
		One-Vs-All 방법	Pair-Wise 방법	제안하는 방법
전투기	성남1D_2_21	66.00% (99/150)	72.67% (109/150)	79.33% (119/150)
헬기	PKX_04	70.40% (116/250)	78.80% (197/250)	80.80% (202/250)
배	대전1D_5_1	72.40% (181/250)	77.60% (194/250)	80.40% (201/250)

그림 4. 분류 성능 비교  
Fig. 4. The comparison of classification rate.



클래스	테스트 명상	인식률	
		확정	불확실 포함
전투기	성남1D_2_21	92.67% (139/150)	79.33% (119/150)
헬기	PKX_04	92.80% (232/250)	80.80% (202/250)
배	대전1D_5_1	94.40% (236/250)	80.40% (201/250)

그림 5. 제안하는 알고리즘 분류 성능 분석  
Fig. 5. The classification performance of proposed algorithm.

치는 부분까지 포함한 불확실 포함 결과도 80%정도의 결과를 볼 수 있다.

#### IV. 결 론

본 논문에서는 최근 기계학습 분야에서 통계적 학습 이론에 기반하여 뛰어난 분류 성능을 보여주고 있는 Adaboost에서 원형 기반 함수를 약한 분류기로 이용함으로써 다중 클래스 문제를 해결하는 방법을 제안하였다. 제안한 방법은 방사형 영역에 대해 각 클래스의 분류 성능을 계산하여 가중치를 갱신해 나감으로써 각 클래스 자체의 분류 영역을 확보하고 클래스 자체 영역의

표현이 가능하였다. 이는 실험결과를 통해서 다중 클래스 분류에 있어서 좋은 결과를 보여준다는 것을 확인하였다. 향후 과제로 다중 클래스 분류 문제에 있어 각 클래스가 겹치는 영역이 크게 존재하는 경우 분류 성능을 향상시킬 수 있도록 추가적인 연구가 진행되어야 할 것이다.

#### 참 고 문 헌

- [1] N. Cristianini, J. Shawe-Taylor, "An introduction to support vector machines and other kernel-based learning methods," Cambridge University Press, 2000.
- [2] Y. Freund, R.E. Schapire, "Experiments with a new boosting algorithm," In Proceedings of the IEEE International Conference of Machine Learning, pp. 148-156, 1996.
- [3] Y. Freund, R.E. Schapire, "A decision-theoretic generalization of on-line learning and application to boosting," Journal of Computer and System Sciences 55, pp. 119-139, 1997.
- [4] 이기현, 권한준, 김용득, "Windows CE 5.0 기반의 AdaBoost 얼굴검출 알고리즘을 이용한 감시카메라 시스템 설계," 대한전자공학회 하계종합학술대회 논문지, 743-744쪽, 2008년 6월
- [5] 박성호, 조달호, 박강령, "Adaboost를 이용한 모바일 환경에서의 홍채인식을 위한 눈 검출에 관한 연구," 대한전자공학회논문지, 제45권 CI편, 제 4호, 1-11쪽, 2008년 7월
- [6] 윤창용, 장석윤, 박민용, "수직면과 아다부스트를 사용한 실시간 교통 표지판 검출," 대한전자공학회 논문지, 제46권 SC편, 제5호, 29-37쪽, 2009년 9월
- [7] 박찬우, 김용민, 박기태, 문영식, "질감 필터를 이용한 눈 검출," 대한전자공학회논문지, 제46권 CI 편, 제6호, 70-78쪽, 2009년 11월
- [8] P. Viola, M. Jones, "Rapid object detection using a boosted cascade of simple features," In Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition, vol. 1, pp. 511-518, 2001.
- [9] J. Ghosh, "Multiclassifier systems : back to the future," In Proceedings of the Int'l Workshop on Multiple Classifier Systems, Lecture Note on Computer Science, vol. 2364, pp. 1-15, 2002.
- [10] T. Hastie, R. Tibshirani, "Classification by pairwise coupling," Advances in Neural Information Processing Systems, vol. 10, pp. 507-513, 1998.
- [11] T.G. Dietterich, G. Bakiri, "Solving multiclass

learning problems via error-correcting output codes,” Journal of AI Research, vol. 2, pp. 263-286, 1995.

[12] N. Otsu, “A threshold selection method from gray-level histogram,” In IEEE Transactions on System, Man and Cybernetic, vol.9, pp. 62-66, 1979.

[13] A. Khotanzard, Y. H. Hong, “Invariant image recognition by Zernike moments,” In IEEE Transactions on Pattern Analysis and Machine Intelligence. vol. 12, pp. 489-497, 1990.

[14] A. Mamistvalov, “N-dimensional moment invariants and conceptual mathematical theory of recognition of n-dimensional solids,” In IEEE Transactions of Pattern Analysis and Machine Intelligence, vol. 20, pp. 819-831, 1998.

저 자 소 개



김 재 협(정회원)  
 2001년 한양대학교 전자계산학과  
 학사 졸업  
 2003년 한양대학교 컴퓨터공학과  
 석사 졸업  
 2008년 한양대학교 컴퓨터공학과  
 박사 졸업

2008년~2009년 한양대학교 엠비언트인텔리전스  
 S/W연구팀 박사후 연구원  
 2009년~현재 삼성탈레스 책임연구원  
 <주관심분야 : 컴퓨터비전, 패턴인식>



장 경 현(학생회원)  
 2005년 한양대학교 전자컴퓨터  
 공학부 학사 졸업  
 2007년 한양대학교 컴퓨터공학과  
 석사 졸업  
 2007년~현재 한양대학교 컴퓨터  
 공학과 박사 과정

<주관심분야 : 객체추적, 패턴인식, 영상처리>



이 준 행(정회원)  
 2004년 중앙대학교 전자전기  
 공학부 학사 졸업  
 2006년 중앙대학교 첨단영상  
 대학원 석사 졸업  
 2006년~현재 삼성탈레스 선임  
 연구원

<주관심분야 : 영상추적, 패턴인식>



문 영 식(평생회원)  
 1980년 서울대학교 공과대학 전자  
 공학과 학사 졸업  
 1982년 한국과학기술원 전기 및  
 전자공학과 석사 졸업  
 1990년 University of California  
 at Irvine Dept. of  
 Electrical and Computer  
 Engineering. 박사 졸업

1982년~1985년 한국전자통신연구소 연구원  
 1989년~1990년 Inno Vision Medical 선임연구원  
 1990년~1992년 생산기술연구원 선임연구원  
 1992년~현재 한양대학교 컴퓨터공학과 정교수  
 <주관심분야: 영상보안, 영상검색, 패턴인식>