

# Kernel Classification Using Data Distribution and Soft Decision MCT-Adaboost

Kisang Kim<sup>†</sup> · Hyung-II Choi<sup>\*\*</sup>

## ABSTRACT

The MCT-Adaboost algorithm chooses an optimal set of features in each rounds. On each round, it chooses the best feature by calculate minimizing error rate using feature index and MCT kernel distribution. The involved process of weak classification executed by a hard decision. This decision occurs some problems when it chooses ambiguous kernel feature. In this paper, we propose the modified MCT-Adaboost classification using soft decision. The typical MCT-Adaboost assigns a same initial weights to each datum. This is because, they assume that all information of database is blind. We assign different initial weights with our propose new algorithm using some statistical properties of involved features. In experimental results, we confirm that our method shows better performance than the traditional one.

**Keywords :** Adaboost, MCT, Soft Decision, Kernel Classification, Data Distribution

## 데이터 분포와 연관정을 이용한 MCT-Adaboost 커널 분류기

김기상<sup>†</sup> · 최형일<sup>\*\*</sup>

## 요 약

MCT-Adaboost 학습 알고리즘은 각 학습 단계에서 배경과 객체를 구분하는 가장 좋은 특징을 찾는 학습 알고리즘이다. 각 학습 단계에서는 최적의 특징을 검출하기 위해 학습 데이터에서 각 특징의 각 커널에서 모든 오차율을 산정하고, 각 특징에서 모든 커널들의 합을 하였을 경우 최소 오차율을 가지는 특징을 선택하도록 되어 있다. 이를 선택하고 다음 학습때 영향을 주는 약분류기에서 기존의 MCT-Adaboost 방법은 경관정 방법으로 사용하였다. 이 방법은 특정 커널에서 객체 데이터와 배경 데이터의 오류율이 유사할 경우, 한쪽으로 판정하기 때문에, 제대로 된 결과값을 산정할 수 없는 문제가 있다. 이를 유연하게 하기 위해 본 연구에서는 연관정을 이용한 약분류기 방법을 제안한다. 기존의 MCT-Adaboost는 초기 가중치를 동일하게 산정한다. 하지만, 이는 데이터의 특성을 모른다는 가정하에 설계된 초기 가중치 설정이다. 본 논문에서는 데이터 분포를 이용하여 가중치를 확률적으로 다르게 할당함으로써, 적은 학습에도 좋은 결과를 보이는 방법을 제안한다. 실험 결과에는 기존의 MCT-Adaboost가 제안하는 성능평가를 통해, 본 연구가 제안하는 방법이 기존 방법에 비해 좋은 결과를 보였다.

**키워드 :** Adaboost, MCT, 연관정, 커널 분류기, 데이터 분포

## 1. 서 론

최근 정보 보안 및 자동화 시스템 및 서비스에 대한 요구가 증대되고 있어, 이와 관련된 핵심 분야인 인공지능, 그 중 특히 인식에 대한 연구가 대두되고 있다[1]. 인식 기술은 주어진 데이터에서 내재된 정보를 부호화를 통해 데이터를

분류 및 군집화 하는 방법이다[2]. 이러한 패턴 인식에 대해 최근에는 다양한 방면으로 연구가 진행되고 있다. 특히 이 분야의 기존 알고리즘들 중 SVM (Support Vector Machine) [3], PCA (Principal Component Analysis)[4], 신경회로망[5], Boosting [6] 등과 같은 알고리즘들이 자주 사용될 뿐만 아니라, 인식률을 높이기 위해 다양한 다른 알고리즘들과 융합하는 방법에 대한 다방면의 연구가 진행되고 있다. 특히, Boosting 방법은 다른 여러 분류기들과 조합하기 쉬워 많은 관심을 받고 있다. 그 중 Viola가 제안한 Adaboost 알고리즘이 가장 널리 사용되고 있으며, 이를 확장한 다양한 연구들이 진행되고 있다[7].

본 논문에서는 MCT-Adaboost를 확장한 방법을 제안한

※ 본 논문은 중소기업청에서 지원하는 2015년도 산학연협력 기술개발사업 (기업부설연구소 신규설치)(No. C0342479)의 연구수행으로 인한 결과물임.

† 준 회 원 : 숭실대학교 미디어학과 박사과정

\*\* 종신회원 : 숭실대학교 미디어학부 교수

Manuscript Received : August 12, 2016

Accepted : September 8, 2016

\* Corresponding Author : Hyung-II Choi(hic@ssu.ac.kr)

다. MCT-Adaboost는 Viola가 제안한 Haar-like를 이용한 Adaboost에 비해 일반적으로 조명에 강건하기 때문에 객체 인식률이 더 좋으며, 학습 시간도 많이 단축하는 장점이 있어 많이 사용된다. 하지만, 기존의 MCT-Adaboost는 경관정(Hard decision)으로 결정되기 때문에, 경계부분에 검출되는 특징의 경우 오류를 일으키는 문제가 있다. 이러한 문제를 해결하기 위해 본 논문에서는 연관정(Soft decision)을 이용하는 방법을 제안한다. 또한, 보다 효율적인 학습을 위해, Adaboost의 초기 가중치를 동일 가중치가 아닌 유용한 특징은 가중치를 높이고, 유용하지 않은 특징은 가중치를 낮추는 방법도 제안한다. 초기 가중치는 전반적인 학습 알고리즘에 많은 영향을 미치는 만큼, 좋은 초기 가중치는 좋은 학습 결과를 나타낼 수 있기 때문이다[8].

## 2. 기존 연구

Adaboost 알고리즘은 물체 검출, 분류, 인식 등 다양한 분야에 많이 사용된 알고리즘이다. 특히, Viola와 Jones가 제안한 Adaboost는 Haar-like 특징과 함께 사용하여 높은 얼굴 검출률을 보이는 알고리즘을 제안하였다. 하지만, 이 방법의 경우 Haar-like의 특징은 너무 경우의 수가 많아 학습하는데 오랜 시간이 걸리며, 학습데이터에 따라 조명이 달라질 경우, 검출이 실패하는 문제가 있다. 이를 보완한 방법이 Froba와 Ernst가 제안한 MCT Adaboost이다.

MCT Adaboost 알고리즘은 Haar-like 특징 대신, MCT (Modified Census Transform) 특징을 사용하고, 이에 맞는 Adaboost를 접목시키는 방법이다. MCT 특징은 CT (Census Transform)의 방법을 확장한 방법이다. 기존 CT는 Fig. 1에서와 같이 특정 패턴에서 원하는 커널을 추출하지 못하는 문제가 있다.

Input			Result of CT		
1	5	1	0	0	0
1	5	1	0	0	0
1	5	1	0	0	0

Fig. 1. CT Feature Problem

Fig. 1과 같은 문제가 발생하는 이유는 CT의 원리에 대해 문제가 있기 때문이다. CT는 중심점을 기준으로 중심값과 주변값을 바로 비교하기 때문에, 중심값보다 똑같거나 작으면 0으로 인식하며, 크면 1로 인식하는 구조적 문제가 있다. 이러한 CT의 문제를 해결하는 방법이 MCT 방법이다. MCT 특징 추출방법은 Fig. 2에서와 같이 3x3 커널안에 포함되는 밝기값들의 평균을 계산한 후, 평균값과 커널안의 각각의 밝기값을 비교, 밝기값이 평균값보다 작으면 0, 크면 1로 할당한다. 마지막으로 이렇게 계산된 결과를 2진수로 표현하고, 이를 다시 10진수로 표현하여 커널값을 추출하는 방법이다.

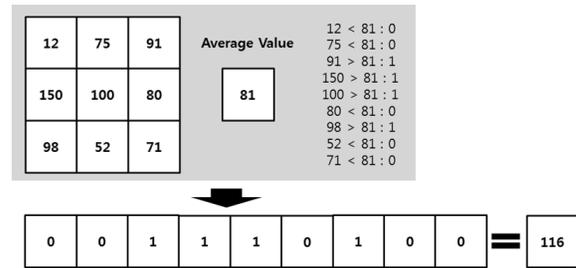


Fig. 2. Example of MCT Feature Extraction

MCT 특징을 이용하여 추출하면 Fig. 1에서 문제되었던 부분이 Fig. 3에서와 같이 CT에서는 검출하지 못한 커널을 MCT에서는 원하는 커널을 추출하는 결과를 나타낸다.

Input			Result of MCT		
1	5	1	0	1	0
1	5	1	0	1	0
1	5	1	0	1	0

Fig. 3. Result of MCT Feature Extraction

MCT는 주위 픽셀과의 비교를 이용하여 만든 특징이기 때문에 조명 변화에 강건하며, 유용한 특징들로 구성되기 때문에, Haar-like 특징에 비해 더 각광받고 있다.

MCT-Adaboost의 Adaboost는 기존의 Haar-like 특징과 접목한 Adaboost와 비교하여 Hypothesis 부분이 다르게 설정되어 있다. 이러한 이유는 기존의 Haar-like 특징의 경우 그 값이 연속성이 있는 값이다. 연속성이라고 하면 일반적으로 픽셀 밝기 값이 0~255로 구성되는데, 10이라는 값을 가지는 픽셀은 20이라는 값을 가지는 픽셀에 비해 어두운 것을 알 수 있다. 하지만 커널로 구성되는 MCT 특징의 경우 연속성이 존재하지 않는다. MCT 커널 값이 1인 것과 MCT 커널 값이 10인 것은 둘 사이에 연관성이 없는 전혀 별개의 다른 것이다. 따라서 연속성을 이용하여 비교하는 기존의 Adaboost의 Hypothesis는 MCT 특징에 적합하지 않다. 이를 해결 하기 위해 Froba와 Ernst는 MCT-Adaboost을 제안하였다.

MCT-Adaboost는 기존 Adaboost와 달리, Equation (1)과 Equation (2)와 같이 긍정데이터와 부정데이터의 Lookup table을 생성한다. 이 Lookup table은 해당 위치의 특정 커널값이 주어졌을 때, 학습데이터와 가중치의 곱들의 합으로 이루어진 결과이다. 이는 즉, 해당 위치의 커널이 주어지면 긍정일 확률과 부정일 확률을 계산하게 되는 것이다.  $W_k(i)$ 는 I번째 데이터의 k단계에서 가중치를 나타내며,  $E(\cdot)$ 은 안에 있는 항목이 만족하면 1을, 만족하지 않다면 0값을 리턴하는 함수를 나타낸다.  $g_k(x, \gamma)$ 는 k번째 단계에서 학습데이터들이 x에 위치하며 커널값이  $\gamma$ 를 갖는 데이터의 개수를 나타낸다.

$$g_k^p(x, \gamma) = \sum_i W_k^p(d) E(M(I_i^p(x))) = \gamma \quad (1)$$

$$g_k^n(x, \gamma) = \sum_i W_k^n(d) E(M(I_i^n(x))) = \gamma \quad (2)$$

Lookup table을 생성하였으면, 최소의 오류율을 갖는 위치를 찾기 위해 Equation (3)과 같이 각 위치에서 커널들의 오류율들의 합을 계산하게 된다. Equation (3)에서  $\epsilon_k(x)$ 는 k번째 단계에서 x위치의 최소오류율을 나타낸다.

$$\epsilon_k(x) = \sum_{\gamma} \min(g_k^p(x, \gamma), g_k^n(x, \gamma)) \quad (3)$$

Equation (4)를 이용하여, 위치에서 각 라운드에서 결정된 최적의 위치를 저장하는 집합을 만들게 된다. Equation (4)에서 n은 위치의 최대 개수이며  $S_k$ 는 각 단계에서 이미 검출된 위치들이 저장된 집합을 나타낸다.

$$x_k = \begin{cases} x \mid \epsilon_k(x) = \min_x(\epsilon_k(x)) & \text{if } |S_k| < n \\ x \mid \epsilon_k(x) = \min_{x \in S}(\epsilon_k(x)) & \text{otherwise} \end{cases} \quad (4)$$

위치가 결정되면, 약분류기는 Equation (5)와 같이 입력 데이터의 해당 위치의 커널값을 이용하여 결정하게 된다.  $w_k(\gamma)$ 는 약분류기를 말하며, 미리 학습된 데이터에 대해 정해진 위치와 이에 해당하는  $\gamma$  값이 있을 때, 긍정이 가까운지 부정에 가까운지 결정하는 단계이다. 하지만 여기서 분류기를 구성하는  $w_i(\gamma)$ 는 0과 1로 구분되는 경판정을 이용하였다.

$$w_k(\gamma) = \begin{cases} 0 & \text{if } g_k^p(x_k, \gamma) > g_k^n(x_k, \gamma), \\ 1 & \text{otherwise,} \end{cases} \quad (5)$$

다음 라운드를 위해 최소 오차율이 계산된 값을 이용하여 Equation (6)의 가중치를 계산하고, 이를 이용하여 다음 학습데이터의 가중치를 Equation (7)과 Equation (8)과 같이 업데이트한다. Equation (6)에서  $\alpha$ 는 학습 라운드에서 계산된 약분류기의 가중치를 나타낸다. Equation (7)과 Equation (8)에서  $Z_t$ 는 정규화를 위한 인자값이다.

$$\alpha_t = \frac{1}{2} \ln\left(\frac{1 - \epsilon_k}{\epsilon_k}\right) \quad (6)$$

$$W_{k+1}^p(i) = \frac{W_t^p(i)}{Z_t} \cdot \begin{cases} e^{-\alpha_t} & \text{if } w_k(I_i^p(x)) = 0, \\ e^{\alpha_t} & \text{otherwise,} \end{cases} \quad (7)$$

$$W_{k+1}^n(i) = \frac{W_t^n(i)}{Z_t} \cdot \begin{cases} e^{-\alpha_t} & \text{if } w_k(I_i^n(x)) = 1, \\ e^{\alpha_t} & \text{otherwise,} \end{cases} \quad (8)$$

최종적으로 인식하는 강분류기는 Equation (9)와 같이 각 라운드에서 계산된 가중치와 약분류기들의 합으로 계산하게 된다.  $M(I(x_k))$ 는 I 영상에서  $x_k$  위치에서의 MCT 커널값을 나타낸다.

$$h(I) = \sum_{k=1}^K \alpha_k \cdot w_k(M(I(x_k))) \quad (9)$$

Table 1. MCT-Adaboost Algorithm

Input	
Positive Train data	- $I_1^p, I_2^p, \dots, I_t^p$
Negative Train data	- $I_1^n, I_2^n, \dots, I_t^n$
Boosting	
Initial weight	
Set initial weights for each train data	
Positive data weight	- $W_1^p(d) = \frac{1}{2t}$
Negative data weight	- $W_1^n(d) = \frac{1}{2f}$
Learning	
For k = 1, ..., K	
Create lookup table for each Positive and Negative data using Equation (1,2)	
Extract minimum error rate in position x using Equation (3)	
Find optimal position x using Equation (4) in each stage	
Weak Classifier - Equation (5)	
$\alpha$ value update using Equation (6)	
Weight update using Equation (7,8)	
Classification : Strong Classifier - Equation (9)	

Table 1에서 I는 입력 데이터로, 본 논문에서 실험을 위해 사용된 데이터는 영상데이터로 구성되었다. Equation (5)에서 알 수 있듯이, 본 방법은 경판정을 이용하여 학습하였다. 일반적으로 경판정의 경우 분류가 모호한 것일수록 오류율을 높이는 문제가 된다. 또한 MCT-Adaboost의 경우 초기 가중치를 동일하게 할당하였다. 이러한 부분은 연판정 및 초기 가중치 설정에 따라 개선할 수 있다. 이러한 부분에 있어 3장과 4장에서 개선 방법을 제안한다.

### 3. 효율적인 학습을 위한 초기 가중치 설정

초기 가중치는 학습 알고리즘을 수행하는데 있어 학습 결과에 큰 영향력을 행사한다[9]. 따라서, 대부분의 학습 알고리즘을 설계하는데 있어 초기 가중치에 대해 많은 연구가 이루어지고 있다[10]. 학습 알고리즘의 초기 가중치를 설정하는데 있어 가장 보편적인 방법은 초기 가중치를 동등하게 주는 방법이다. Viola가 제안한 Adaboost도 초기 가중치를 동등하게 주었을 뿐만 아니라 기존의 MCT-Adaboost 알고리즘도 초기 가중치를 동등하게 설정하였다. 초기 가중치를 동일하게 주는 이유는 학습 데이터의 특징을 모를 경우, 특정 학습 데이터의 비중이 커져 잘못된 결과 추출을 방지하기 위함이다. 하지만, 학습 데이터의 특징을 추출할 수 있다면, 초기 가중치를 동등하게 주는 것은 학습하는데 있어 최선의 선택은 될 수가 없다[8]. 이에, 본 논문에서는 학습 데이터의 특징을 추출, 이를 이용한 초기 가중치 설정에 대해 제안한다.

일반적으로 Adaboost 학습 데이터의 긍정 데이터는 비스

한 형태의 데이터로 구성되어 있다. 예를 들어, 얼굴 검출을 위해 학습할 경우, 긍정 데이터는 사람의 얼굴들만으로 구성되어 있으며, 보행자 데이터의 경우 보행자 영상들만으로 구성되어 있다. Fig. 4A는 긍정 데이터 중 특징1과 특징2로 구성된 분포도를 나타낸다. Fig. 4A에서 볼 수 있듯이 긍정 데이터는 데이터들 간의 유사성이 존재한다. 반대로, 부정 데이터의 경우 다양한 객체, 배경 등으로 이루어져 있기 때문에, 데이터들 간의 유사성이 존재하기 힘들다. Fig. 4B의 경우 부정 데이터 중 특징1과 특징2로 구성된 분포도다. 이 Fig. 4B에서 볼 수 있듯이, 부정 데이터는 데이터들 간의 연결성이 존재하지 않는다.

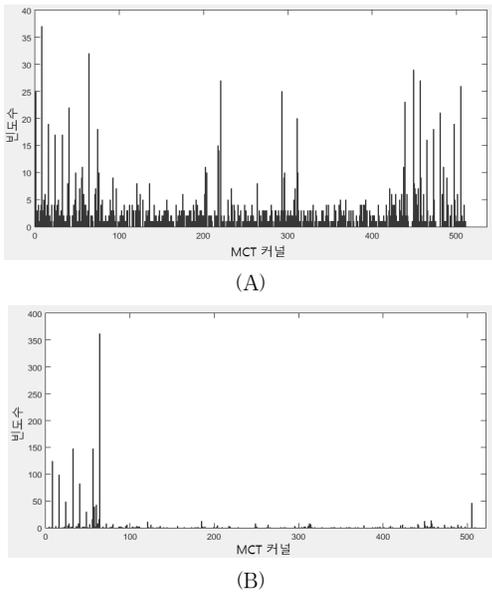


Fig. 4. MCT Feature Distribution  
(A) Positive Data, (B) Negative Data

이러한 특성을 이용하여 각 긍정 데이터와 부정데이터의 초기 가중치를 다르게 할당하는 방법을 제안한다. 연결성이 존재하는 긍정데이터의 경우 Fig. 4A에서와 같이 모여 있는 데이터의 경우 가중치를 높게 할당하며, 이와 반대되는 부분은 가중치를 낮게 할당한다. 이를 계산하기 위해 특징마다 MCT 커널에 대해 히스토그램을 생성하여 커널마다의 분포도를 계산한다. Equation (10)에서는 MCT 커널에 대해 히스토그램을 설정하기 위한 수식이다.

$$Kh(x, \Gamma) = \sum_{d=1}^N E(M(I_d(x)) = \Gamma) \quad (10)$$

Equation (10)에서  $Kh(x, \Gamma)$ 는  $x$  위치에서 커널 값  $\Gamma$ 에서의 누적 빈도수를 나타낸다.  $d$ 는 긍정데이터의 인덱스를 나타내며  $N$ 은 긍정 데이터의 총 개수를 나타낸다.  $E(\cdot)$ 는 안에 수식이 참일 경우 1을 리턴하며, 거짓일 경우 0을 리턴하는 함수이다. 마지막으로  $M(x, y, d)$ 는  $d$  번째 데이터에서  $(x, y)$  위치에 있는 MCT 커널값을 나타낸다. Equation (11)에서는 Equation (10)에서 계산된 히스토그램을 이용하여 각 데이터의 중요도를 계산한다.

$$S(d) = \sum_{x=1}^W \sum_{y=1}^H Kh(x, M(I(x_d))) \quad (11)$$

Equation (11)에서  $S(d)$ 는  $d$  번째 데이터에서의 MCT값에 해당하는 히스토그램 빈도수를 합한 결과이다. 마지막으로 Equation (12)에서는 Equation (11)에서 구해진 값을 가중치로 표현하기 위해 정규화하는 과정을 나타낸다.

$$W_1(d) = \frac{S(d)}{2 \cdot \sum_{i=1}^N S(i)} \quad (12)$$

Equation (12)에서  $W_1(d)$ 는  $d$  번째 데이터에서 초기 가중치를 나타낸다. 분모에 2를 곱한 이유는 긍정 데이터의 가중치의 총 합과 부정 데이터의 가중치의 총합이 동일한 0.5로 맞추기 위함이다.

#### 4. MCT 특징을 이용한 연관정 방법

MCT Adaboost는 학습 할 때마다 해당 라운드에서 분류가 가장 잘되는 특징과 특징에 대한 분류기를 추출하는 알고리즘이다. 분류가 잘되는 특징을 찾기 위해 긍정 및 부정 데이터를 분류할 때 최소 오류율을 이용하여 특징을 추출한다[11]. 특징을 추출하는데 있어 일반적으로 경관정(hard decision)을 이용하여, 해당 커널의 누적값 중 큰쪽을 선택하게 된다. 일반적으로 경관정은 계산 복잡도가 낮고 구현이 쉬운 장점이 있다. 하지만, 이 방법은 이분법으로 구분하게 되며, 분류의 기준이 되는 긍정 데이터와 부정데이터의 커널 누적값이 비슷할 경우 오차를 발생하는 문제가 있다. 따라서, 본 논문에서는 연관정을 사용한다. 연관정은 경관정에 비해 일반적으로 높은 계산 복잡도를 가지게 되지만, 본 논문에서는 약분류기를 변형하여 제한하기 때문에, 높은 계산 복잡도를 요구하지 않으며, 연관정의 특유인 유연성을 제공하기 때문에, 기존의 방법에 비해 더 좋은 결과 값을 추출하는 장점이 있다.

Fig. 5은 연관정을 이용한 결정에 대한 전반적인 내용을 나타낸다. Fig. 5에서 수평축은 특정 특징의 커널에서 전체 데이터 중 긍정데이터의 비율을 나타내며 수직축은 멤버십을 나타낸다.

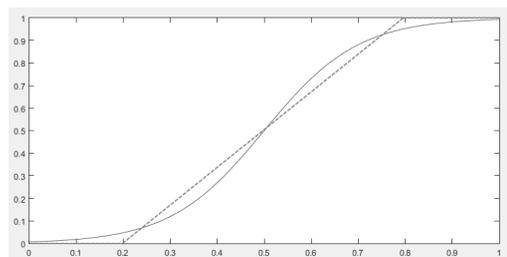


Fig. 5. Soft Decision  
Dash Line : Proposed Method, Line : Sigmoid Function

Fig. 5에서 점선은 Equation (13)과 Equation (14)로 이루어진 결정 경계이다. 이와 같이 하게 된 이유는 시그모이드 함수와 유사하며, 계산 복잡도가 단순하기 때문에 이와 같이 사용되었다. 결정 경계를 나타내는 Equation (13)과 Equation

(14)는 각 특징에서 해당 커널이 객체 그룹에 속하는 정도를 결정하는 멤버십에 관한 수식으로, 부정데이터에 가까울수록 0에 가까워지며, 긍정데이터에 가까울수록 1에 가까워진다. Equation (12)와 Equation (13)은 Fig. 5에서 표현한 결정 경계를 나타낸다.

$$R_k(\gamma) = \frac{g_k^p(x_k, \gamma)}{g_k^p(x_k, \gamma) + g_k^n(x_k, \gamma)} \quad (13)$$

$$wm_k(\gamma) = \begin{cases} 0, & \text{if } R_k(\gamma) < Th \\ Th + (1 - 2 \cdot Th) \cdot R_k(\gamma) & \text{if } Th \leq R_k(\gamma) \leq 1 - Th \\ 1, & \text{if } 1 - Th \end{cases} \quad (14)$$

Equation (13)에서 k는 Adaboost의 학습할 때 라운드를 나타낸다. Equation (14)에서 임계값  $Th$ 는 긍정데이터와 부정데이터를 확정하는 임계값으로 보통 0.2로 할당한다. 이러한 결정 경계를 이용하여 Adaboost의 업데이트 시, Equation (15), Equation (16)과 같은 방법으로 멤버십 함수를 이용한 업데이트를 수행한다.

$$W_{k+1}^p(i) = \frac{1}{Z_k} \exp(-\alpha_k \cdot (wm_k(M(I_i^p(x_k))) - 0.5) \times 2) \quad (15)$$

$$W_{k+1}^n(i) = \frac{1}{Z_k} \exp(\alpha_k \cdot (wm_k(M(I_i^n(x_k))) - 0.5) \times 2) \quad (16)$$

$$h(I) = \sum_{k=1}^K \alpha_k \cdot wm_k(M(I(x_k))) \quad (17)$$

마지막으로, 강분류기는 Equation (17)의 함수를 이용하여 계산하게 된다. Table 2는 제안하는 방법의 알고리즘을 나타낸다.

Table 2. Proposed Algorithm

Input	
Positive Train data	- $I_1^p, I_2^p, \dots, I_t^p$
Negative Train data	- $I_1^n, I_2^n, \dots, I_f^n$
Boosting	
Initial weight	
Set initial weights for each train data	
Positive data weight -	
Create Histogram of MCT kernel (Equation (10))	
Calculate data importance in each train data (Equation (11))	
Extract data weights from weight equalization (Equation (12))	
Negative data weight - same as Table 1	
Learning	
For k = 1, ..., K	
Create lookup table for each Positive and Negative data using Equation (1,2)	
Extract minimum error rate in position $x$ using Equation (3)	
Find optimal position $x$ using Equation (4) in each stage	
Weak Classifier - Equation (13,14)	
$\alpha$ value update using Equation (6)	
Weight update	
Positive data - Equation (15)	
Negative data - Equation (16)	
Classification : Strong classifier - Equation (17)	

### 5. 실험 결과

본 시스템을 개발 및 실험하기 위한 컴퓨터 환경으로는 Intel(R) Core™ i7-4790 3.60 GHz CPU와 8GByte 메모리를 사용하였다. 운영체제는 Windows 8 Enterprise K 64bit를 사용하였으며, 개발툴은 Visual Studio 2013의 MFC환경과 OpenCV 2.4.9를 사용하였다. 객체 검출을 위해 학습에 사용된 데이터는 얼굴 데이터, 보행자 데이터, 그리고 그 외의 배경 데이터를 사용하였다. 얼굴에 대해 학습하기 위해 총 400장의 얼굴 이미지와 800장의 랜덤 이미지를 학습데이터로 사용하였으며, 보행자를 검출하기 위한 학습 데이터는 400장의 보행자 이미지와 800장의 랜덤 이미지를 사용하였다. 얼굴 데이터는 뉴욕 대학에서 제공하는 얼굴데이터베이스[12]를 사용하였으며, 보행자 데이터는 MIT에서 제공하는 데이터베이스[13]를 사용하였다. 배경 데이터는 인터넷에 있는 임의의 데이터를 사용하였다.

데이터 분포를 계산하고 초기 가중치를 설정하는데 걸리는 시간은 대략 0.2초의 계산 시간이 걸리며, 리소스는 특징의 수를 저장할 수 있는 만큼 메모리를 필요로 한다. 또한, 기존의 학습하는데 걸리는 시간은 대략 6.5초의 시간이 걸렸으며, 제안하는 방법은 약 7초의 시간이 걸렸다. 이 말은 연판정으로 인해 필요한 시간이 약 0.3초정도 증가한 것으로 판단된다. 얼굴 학습을 위해 영상을 25x25로 영상 크기를 변환하였으며, 보행자는 20x40으로 영상 크기를 변환하였다. 따라서 특징의 개수는 얼굴의 경우 625개의 특징이 나오며, 보행자는 800개의 특징이 추출된다. 각 MCT특징은 2Byte로 구성되기 때문에 2KByte보다 못한 메모리를 할당하게 되므로, 메모리에 부담이 되지 않는다. 또한 학습하는데 걸리는 총 시간은 약 10초가 소요된다. 이는 초기가중치를 계산하는데 걸리는 시간에 비해 매우 큰 시간이 소요되므로, 초기 가중치를 설정하는데 시간 복잡도는 무시되어도 무방한 것으로 판단된다.

Fig. 6은 보행자에 대한 데이터로 측정하였을 경우, 인식률을 나타낸다. Fig. 6에서 X축은 Adaboost 특징 추출의 개수를 나타내며, Y축은 해당 특징 개수에서 인식률을 나타낸다. 특히 특징이 적은 전반부에서는 초기 가중치를 제안한 방법으로 했을 경우, 기존의 방법보다 좋은 것을 확인된다.

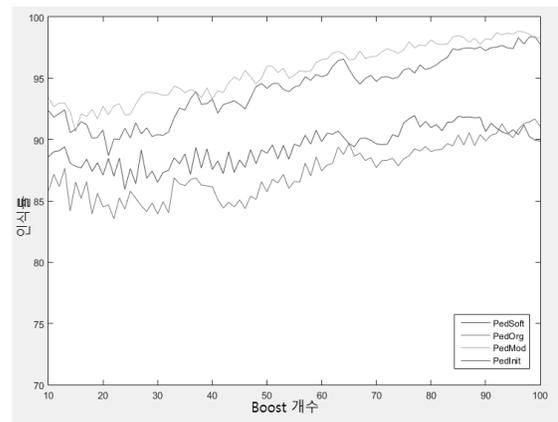


Fig. 6. Comparison of Pedestrian Detection

하지만, 검출된 특징이 많아지는 후반부로 갈수록 초기 가중치의 유무의 차이는 줄어드는 것을 알 수 있다. 또한, 제안하는 방법을 사용한 연판정은 기존의 경판정에 비해 인식률이 좋은 것을 확인 할 수 있다.

Fig. 7는 얼굴 데이터베이스를 이용한 얼굴 검출 인식률을 나타낸다. 얼굴 검출의 경우 Boost의 개수가 많아질수록 보행자에 비해 인식률이 좋아지는 것을 확연히 볼 수 있다. 또한, 초기 가중치의 영향은 25개 이하의 특징에서 영향이 있으며, 그 이후는 영향이 있다고 판단하기는 어렵다. 하지만, 연판정의 경우 경판정에 비해 현저히 좋은 결과를 가지는 것을 확인 할 수 있으며, 연판정과 초기 가중치가 같이 적용될 경우 더욱 좋은 검출 결과를 가져오는 것을 확인 할 수 있다.

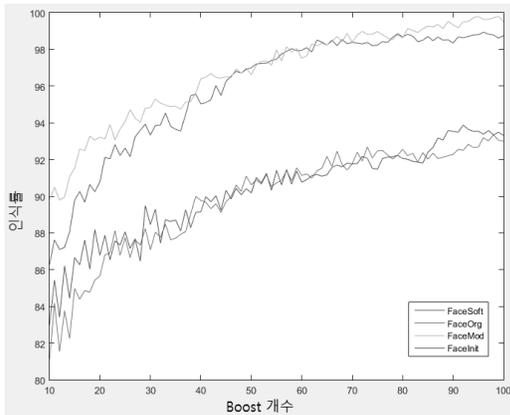


Fig. 7. Comparison of Face Detection

## 6. 결 론

본 논문은 MCT-Adaboost를 확장한 데이터 분포도를 이용한 가중치와 연판정을 이용한 새로운 Boosting 알고리즘을 제안하였다. 데이터 분포도를 이용한 초기 가중치는 특징을 적게 추출했을 때 효율적인 분류 결과를 보였다. 연판정의 경우 기존의 경판정에 비해 더 좋은 분류 결과를 보였다. 이러한 결과를 토대로 확률 기반 초기 가중치와 연판정은 다양한 Boosting 분야에 적용 시켰을 경우 더 좋은 결과를 보일 것으로 예상된다.

## References

[1] Y. Kim and B. Ryu, "Future social change from development of AI technology," KISTEP R&D InI, 2016.  
 [2] S. Kulkarni, L. Gabor, and S. Venkatesh, "Learning pattern classification—a survey," *IEEE Transactions on Information Theory*, Vol.44, No.6, pp.2178-2206, 1998.  
 [3] S. Tong and D. Koller, "Support vector machine active learning with applications to text classification," *The Journal of Machine Learning Research*, pp.45-66, 2001.

[4] J. Friedman, T. Hastie, and R. Tibshirani, "Additive logistic regression: a statistical view of boosting," *The Annals of Statistics* Vol.28, No.2, pp.337-407, 2000.  
 [5] M. Hagan, H. Demuth, M. Beale, and O. Jesus, "Neural Network Design," Boston : Pws Pub., 1996.  
 [6] Y. Freund and R. Schapire, "A decision-theoretic generalization of on-line learning and an application to boosting," *Journal of computer and system sciences*, Vol.55, No.1, pp.119-139, 1997.  
 [7] P. Viola and M. Jones, "Rapid object detection using a boosted cascade of simple features," *Computer Vision and Pattern Recognition*, 2001.  
 [8] K. Kim and H. Choi, "Object detection using Fuzzy Adaboost," *Journal of the Korea Contents Association*, Vol.16, No.5, pp.104-112, 2016.  
 [9] S. Lomax, and S. Vadera, "A survey of cost-sensitive decision tree induction algorithms," *ACM Computing Surveys (CSUR)*, Vol.45, No.2, 2013.  
 [10] G. Hinton, S. Osindero, and Y. Teh, "A fast learning algorithm for deep belief nets," *Neural Computation*, Vol.18, No.7, pp.1527-1554, 2006.  
 [11] B. Froba and A. Ernst, "Face detection with the modified census transform." *Automatic Face and Gesture Recognition*, 2004.  
 [12] Face dataset from Newyork University [Internet], <http://www.cs.nyu.edu/roweis/data.html>.  
 [13] Pedestrian dataset from MIT [Internet], <http://cbcl.mit.edu/software-datasets/PedestrianData.html>.



### 김기상

e-mail : kimkisang@ssu.ac.kr  
 2007년 숭실대학교 컴퓨터학부(학사)  
 2009년 숭실대학교 미디어학과(공학석사)  
 2014년~현 재 숭실대학교 미디어학과 박사과정  
 관심분야 : 컴퓨터 비전, 영상처리, 기계학습 등



### 최형일

e-mail : hic@ssu.ac.kr  
 1979년 연세대학교 전자공학과(공학사)  
 1983년 미시간대학교 전기전산학과 (공학석사)  
 1987년 미시간대학교 전기전산학과 (공학박사)  
 1987년~1999년 숭실대학교 컴퓨터학부 교수  
 2000년~현 재 숭실대학교 미디어학부 교수  
 관심분야 : 컴퓨터 비전, 패턴인식, 증강현실 등