

판별 함수를 이용한 문턱치 선정에 의한 약분류기 개선

Improving Weak Classifiers by Using Discriminant Function in Selecting Threshold Values

삼 아디카리*, 유현중**, 김형석*

전북대학교 전자정보공학부*, 상명대학교 정보통신공학과**

Shyam Adhikari(shyam.rvision@hotmail.com)*, Hyeon-Joong Yoo(yoohj@smu.ac.kr)**,
Hyongsuk Kim(hskim@jbnu.ac.kr)*

요약

Viola와 Jones가 사용한 Haar-like 특징 기반 약분류기의 분별력을 개선하기 위하여, 2차 판별식에 기반한 판정 경계(decision boundary) 결정 방법을 제안한다. Viola와 Jones가 부스팅된 약분류기 앙상블을 사용해서 강분류기를 만들 때 사용한 단일 판정 경계 기반 약분류기는 특징 공간을 지나치게 단순하게 해석한 산물이어서 대부분의 경우 최적이지 않으며, 객체 클래스와 배경 클래스 간을 효율적으로 분별하기에 흔히 너무 약하다. 이 논문에서 제안하는 2차 판별식 분석에 기반한 방법은 객체 클래스와 배경 클래스 사이에 다중 판정 경계를 사용하는 약분류기를 만들어준다. 1000개의 positive 샘플과 3000개의 negative 샘플을 훈련에 사용하고, 500개의 positive와 500개의 negative를 테스트에 사용한 차량 검출 실험을 통해서, 기존의 단일 문턱치 기반 약분류기 방식에 비해, 제안 기법이 더 적은 수의 분류기를 사용하면서도 더 우수한 분류 성능을 제공하는 것을 확인하였다.

■ 중심어 : | 약분류기 | Haar-like 특징 | AdaBoost | 판별함수 | 문턱치 |

Abstract

In this paper, we propose a quadratic discriminant analysis based approach for improving the discriminating strength of weak classifiers based on simple Haar-like features that were used in the Viola-Jones object detection framework. Viola and Jones built a strong classifier using a boosted ensemble of weak classifiers. However, their single threshold (or decision boundary) based weak classifier is sub-optimal and too weak for efficient discrimination between object class and background. A quadratic discriminant analysis based approach is presented which leads to hyper-quadric boundary between the object class and background class, thus realizing multiple thresholds based weak classifiers. Experiments carried out for car detection using 1000 positive and 3000 negative images for training, and 500 positive and 500 negative images for testing show that our method yields higher classification performance with fewer classifiers than single threshold based weak classifiers.

■ keyword : | Weak Classifiers | Haar-like Features | Adaboost | Discriminant Function | Threshold |

I. 서론

패턴인식에서 객체 검출은 (1) 특징 선정과 (2) 선정된 특징에 기반한 분류기 설계 이슈를 갖는, 일반적으로 두 클래스 분류 문제이다. Viola와 Jones[1, 2]는 이 이슈들에 대한 해법을 제공하기 위해서, 선형적인 판정 경계를 사용하는 단순한 Haar-like 특징들을 선택하고 AdaBoost[3]를 사용해서 분류기들을 훈련시키는 프레임워크를 제안하였다. 이 방법은 기존 방법들의 속도와 성능 문제를 동시에 개선하여 큰 관심을 끌어 왔으며, 객체 검출을 위한 범용 프레임워크로 확고하게 자리 잡은 상태이다.

이 프레임워크를 개선하기 위하여 다양한 각도에서 여러 방법이 제안되었다. 즉, 부스팅을 개선하려는 Real AdaBoost, KLBoosting, FloatBoost 같은 AdaBoost의 수정 버전들이 제안되었으며[4-6], 기본 Haar-like 특징 집합을 확장해서 다른 패턴을 이용하는 방법들도 제안되었다[7-9]. 그 외, Mita 등[10]은 효율적인 분류기를 만들기 위해 여러 개의 선형적 약분류기(weak classifier)를 융합시키는 방법을 제안하였다. 그리고, Zhang 등[11]은 부스팅의 뒷단에서 PCA로부터 도출된 전역적 특징에 의해 지역적 Haar-like 특징들을 대체하는, 계층적 특징 공간에서의 부스팅 방법을 소개하였다.

이 논문에서는 약한 분류기 또는 약분류기들의 문턱치(또는 판정 경계(decision boundary)) 결정이 성능에 끼치는 영향을 탐구한다. 단일 문턱치에 기반하는 약분류기에서 문턱치는 보통 분포 모드들의 평균의 평균을 취해서 구해지는데[1], 이 문턱치에 기반하는 약분류기는 복잡한 실제 문제들의 근원적 분포를 효율적으로 분별하기에 충분치 않으며, 따라서 특징 집합(feature set)의 대다수 특징들이 분별력이 없다. 더욱이 Zhang 등[11]이 언급했듯이, 이들 특징은 캐스케이드의 뒷단으로 갈수록 문제 난이도가 증가하는 데 비해 상대적으로 훨씬 더 약해서 부스팅 효과가 없을 정도가 된다. 이런 문제를 해결하기 위해서, 이 논문에서는 2차 판별 함수를 사용해서 부스팅에 효율적인 약분류기를 구현하는 방법을 제안한다.

이 논문의 구성은 다음과 같다: 2장은 Haar-like 특징

들에 대한 AdaBoost 학습을 설명하고, 3장에서는 효율적인 약분류기의 구현을 위한 방법을 소개하며, 4장에서는 실험 결과를 제시하며, 5장에서 결론을 맺는다.

II. 약분류기 부스팅

1. AdaBoost

AdaBoost는 약분류기들을 결합해서 강분류기(strong classifier)를 만드는 기계 학습용 적응적 부스팅 알고리즘이다. 강분류기의 판정은 약분류기들의 가중된 다수결에 의해 만들어진다. 약분류기는 다음의 식으로 표현된다.

$$h(x, f, p, \theta) = \begin{cases} 1 & \text{if } pf(x) > p\theta \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

여기서, x 는 입력, f 는 특징, θ 는 문턱치, p 는 부등호의 방향을 결정하는 극성을 나타낸다. 이들의 양상불인 강분류기는 다음의 식으로 나타낼 수 있다:

$$H(x) = \begin{cases} 1 & (\text{객체}) \quad \sum_{i=1}^k \alpha^{(i)} h^{(i)}(x) \geq \Theta \\ 0 & (\text{클러터}) \quad \text{otherwise} \end{cases} \quad (2)$$

여기서 $h^{(i)}(x)$ 는 부스팅에 의해 i 번째로 선정된 약분류기이며, $\alpha^{(i)}$ 는 i 번째 약분류기의 가중치, Θ 는 강분류기의 문턱치이다. 계수들과 약분류기들을 선택하기 위하여 Viola와 Jones는 아래와 같은 수정된 AdaBoost 알고리즘을 사용하였다(이 알고리즘에 관한 자세한 설명은 [1]과 [2]를 참고):

샘플 영상 $(x_1, y_1), \dots, (x_n, y_n)$ 이 주어졌다고 하자. 여기서 positive 샘플과 negative 샘플 각각에 대해 $y_i = 0, 1$ 이다.

$y_i = 0, 1$ 각각에 대해 가중치를 초기화한다: $w_{1,i} = \frac{1}{2m}, \frac{1}{2l}$.

여기서 m 과 l 은 각각 positives와 negatives의 수를 나타낸다.

For $t = 1, \dots, T$.

1) 가중치를 정규화시킨다: $w_{t,i} \leftarrow \frac{w_{t,i}}{\sum_{j=1}^n w_{t,j}}$

2) 다음의 가중 오차 합을 비교해서 가장 성능이 좋은 약분류기를 선정한다.

$$\epsilon_t = \min_{f,p,\theta} \sum_i w_i |h(x_i, f, p, \theta) - y_i|$$

3) ϵ_t 를 최소화시키는 f, p, θ 로, 선정된 $h_t(x) = h(x, f, p, \theta)$ 를 정의한다.

4) 가중치를 갱신한다: $w_{t+1,i} = w_{t,i} \beta_t^{1 - e_i}$

여기서 x_i 가 옳게 분류되면 $e_i = 0$ 이며, 아니면 $e_i =$

1 이다. $\beta_t = \frac{\epsilon_t}{1 - \epsilon_t}$ 이다.

최종 강분류기는 다음과 같다:

$$C(x) = \begin{cases} 1 & \sum_{t=1}^T \alpha_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \\ 0 & \text{otherwise} \end{cases}$$

여기서 $\alpha_t = \log \frac{1}{\beta_t}$ 이다.

알고리즘 1. AdaBoost 학습 알고리즘

2. 약분류기

약분류기들은 [그림 1]의 다섯 가지 기본형 Haar-like 특징들에서 파생된다.



(a) 에지 특징 (b) 선 특징 (c) 대각선 특징

그림 1. 기본형 Haar-like 특징 집합

최종 강분류기는 일련의 가중된 Haar-like 특징들의 조합을 사용하며, 강분류기는 목표 훈련 어려움을 갖는다. 실제 객체 검출을 위해서 [그림 2]에서와 같은 강분류기 캐스케이드가 만들어지는데, 뒷단으로 갈수록 복잡해진다.




그림 2. 검출 캐스케이드의 개략도


캐스케이드 검출기의 전반적 형태는 첫 분류기의 positive 결과가 두 번째 분류기에 입력으로 들어가고, 그 결과가 세 번째 분류기에 입력되는 등등의 축퇴 판정 트리(degenerate decision tree)에 해당한다[1]. 각 단에서의 negative 출력은 그 샘플이 배제되게 하며, 따라서 캐스케이드의 각 단은 앞의 모든 단을 통과한 샘플들로 훈련된다. 각 단은 약분류기들로 구성되는데 그 크기는 훈련 단계에서 결정된다.

III. 최적 문턱치


분류를 위한 Bayes 판정 룰(decision rule)은 훈련 데이터에 대한 분류 오차를 최소화하는 문턱치 또는 판정 경계(decision boundary)를 제공한다. 자연 상태가 ω_1 과 ω_2 인 두 클래스 문제에서, x 를 관찰이라고 할 때, 분류 오차를 최소화하는 문턱치는 $P(\omega_1|x) = P(\omega_2|x)$ 인 조건부 확률 식에 의해 주어지며, 이때의 판정 룰은 만일 $P(\omega_1|x) > P(\omega_2|x)$ 이면 ω_1 , 아니면 ω_2 로 판정하는 것이다. 약분류기는 단 두 클래스만을 구분하나, 최적의 해당 Haar-like 특징을 선정하는 것은 일반적으로 많은 계산량을 필요로 한다.

[그림 3]은 실험에서 얻은 Haar-like 특징 값들의 분포 예를 보여준다. 단일 문턱치에 기반하는 약분류기는 일반적으로 모드의 평균의 평균을 사용하는데, 이런 문턱치로는 이 그림을 통해 알 수 있듯이 대부분의 Haar-like 특징들이 분별력을 갖지 못 한다. 더욱이, 훈련이 진행되면서 뒷단으로 갈수록 객체 클래스와 배경 클래스 간의 구분이 어려워지며, 그에 따라 각각의 약


분류기의 오차율이 50%에 가깝게 되어[11] 부스팅의 효율이 현저히 낮아진다. 이렇게 약분류기의 부스팅이 너무 약하게 되는 단(stage)들에서는 특히 특징의 수가 급증하여 낭비가 심해지고 훈련 시간도 급증하게 된다. 그에 따라 일반 PC에서 훈련 시간이 1주일이 넘는 일도 흔하다.



(a)



(b)



(c)

그림 3. Haar-like 특징 값 분포 예

따라서 단일 문턱치에 기반하는 약분류기 대신에, [그림 3]의 실제 분포를 감안하여 근원적 분포 간 차이를 더 잘 반영하도록 다중 문턱치를 사용한다면 약분류기의 효율성을 높일 수 있을 것이고, 그림으로써 더 적은 수의 약분류기로 더 나은 분류 성능을 기대할 수도 있을 것이다.

이를 위해 이 논문에서는 일련의 판별 함수

$g_i(X), i = 1, 2, \dots, c$ 를 사용하는 방법을 제안한다. 여기서 c 는 분별할 클래스 수이다. 특징 벡터 X 가 주어졌을 때 판별함수에 의한 판정률은 다음과 같이 기술된다: 모든 $i \neq j$ 에 대해 $g_i(X) > g_j(X)$ 이면 ω_i 로 판정하며, 이때 문턱치는 최대 판별 함수들 간에 값이 같아지는 곳이다. 다변량 노멀(normal) 밀도의 경우, 식 (3)에 주어진 판별 함수를 사용해서 오차율이 최소인 분류를 달성할 수 있다[12]:

$$g_i(X) = -\frac{1}{2}(X - \mu_i)^t \Sigma_i^{-1}(X - \mu_i) - \frac{d}{2} \ln 2\pi - \frac{1}{2} \ln |\Sigma_i| + \ln P(\omega_i) \quad (3)$$

부류마다 서로 다른 분산 행렬을 갖는 일반적인 다변량 노멀 분포의 경우, 판별 함수는 식 (4)로 주어진다 [12].

$$g_i(X) = X^t W_i X + w_i X + w_{i0} \quad (4)$$

여기서

$$W_i = -\frac{1}{2} \Sigma_i^{-1}$$

$$w_i = \Sigma_i^{-1} \mu_i$$

$$w_{i0} = -\frac{1}{2} \mu_i^t \Sigma_i^{-1} \mu_i - \frac{1}{2} \ln |\Sigma_i| + \ln P(\omega_i)$$

이 판별 함수에 의한 판정 표면은, 1차원에서 그려보면 [그림 3]을 통해서 알 수 있듯이 흔히 단순 연결되지 않는다. 즉, 단변량 Haar-like 특징의 경우에 두 분포가 분산이 서로 다른 노멀 분포라면, 판별 함수에 의해 같은 클래스의 영역이 분리된 상태로 구해지므로, 다중 문턱치 기반 약분류기를 사용하는 것이 적합하다는 것을 알 수 있다.

[그림 4]는 [그림 3](b)에 대해 두 접근법에 의해 결정된 문턱치들을 보여준다. 점선은 두 분포의 평균의 평균을 문턱치로 사용하는 기존 방법에 의해 결정되는 문턱치이며, 실선은 판별함수에 의해 결정되는 문턱치들을 보여준다. 이 그래프에 해당하는 feature는 기존 기법에 의한 문턱치를 사용할 경우 분류 성능이 나쁠 것이므로 약분류기로서 채택되지 못 할 것이나, 제안 방법에 의해서는 좋은 분류 성능을 제공하기 때문에 약분류기로 선정될 수 있다. 마찬가지로, [그림 4](c)의 경우

에 대해서도 제안 기법이 더 적절한 문턱치를 제공할 것이다. 제안 기법의 알고리즘에서는 식 (1)이 다음과 같이 바뀐다.

$$h(x, f, p, \theta) = \begin{cases} 1 & \text{if } g_p(f(x)) > g_n(f(x)) \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

이 식에서 아래 첨자 p와 n은 각각 positive와 negative를 나타낸다.




그림 4. Haar-like 특징 값 분포 예(점선: 기존 기법에 의한 문턱치; 실선: 제안 기법에 의한 문턱치)

IV. 단일 및 다중 문턱치 기반 약분류기들을 이용한 차량 검출

다양한 조건에서 촬영된 비디오 클립들을 사용해서 차량 검출을 수행하였다. [그림 5]는 실험에 사용한 동영상의 한 프레임에 대한 검출 결과를 참고로 보여준다.




그림 5. 실험 동영상 및 차량 검출 결과

Haar-like 특징 분류기의 훈련에 사용한 positive와 negative 샘플 수는 각각 1000개와 3000개이었다. 이 훈

련 데이터에 대해 100%의 적중률과 0%의 false positives를 목표로 두 문턱치 선정 방법을 사용해서 분류기들을 훈련시켰다. 실험 결과, 훈련 데이터에 대한 요구 성능을 달성하는데 단일 문턱치 기반 약분류기를 사용한 강분류기에는 225개의 Haar-like 특징이 소요되었으나, 판별 함수에 기반한 약분류기를 사용한 강분류기는 69개만 필요했다. [그림 6]이 두 방법에 의한 약분류기 수 대 훈련 오차를 비교해서 보여준다. 제안한 약분류기들이 단일 문턱치 기반 약분류기들보다 더 효율적으로 훈련됨을 알 수 있다.




그림 6. 단일 및 다중 문턱치 방법들의 약분류기 수 대 훈련 오차

각각 500개의 positives와 negatives로 구성된 validation dataset에 대한 적중률 대 허위 경보율을 [그림 7]이 보여준다. 강분류기의 문턱치는 0.25 스텝으로 -10부터 +10 사이에서 조정되었다. [그림 7]의 ROC 곡선으로부터 판별 함수 기반 약분류기가 단일 문턱치 기반 약분류기 보다 분류 성능이 좋음을 알 수 있다.




그림 7. 단일 및 다중 문턱치 기반 약분류기들을 사용해서 훈련된 강분류기들의 ROC 곡선

또 다른 실험에서는 훈련 집합으로부터의 500개의 positive 샘플과, 단일 문턱치 기반 약분류기로 훈련된 10단 캐스케이드로부터 얻은 false positive들로 구성된 2000개의 negative 샘플을 사용했다. 두 방법을 사용해서 이 dataset에 대해 강분류기들을 훈련시켰다. 훈련 데이터에 대한 성능 기준(performance criteria)은 위의 실험들과서와 같다. 문턱 난이도가 높은 이 실험에서는 단일 문턱치 기반 약분류기들은 너무 약해서 최종 분류기의 Haar-like 특징 수가 236개에 달했고, 그 반면에 제안 기법으로 똑 같은 성능을 달성하는 데는 26개의 Haar-like 특징만 필요했다. [그림 8]이 시험 dataset에 대한 ROC 곡선을 보여주는데, 어려운 샘플들로 구성된 이 데이터 집합에 대해서 제안 기법이 단일 문턱치 기반 방법 보다 현저히 성능이 좋음을 알 수 있다.




그림 8. 제안 방법과 기존 방법의 ROC 곡선. 단일 문턱치 기반 약분류기들로 훈련된 10단 캐스케이드의 false positive들을 negative 샘플로 사용해서 훈련시켰다.

V. 결론

다중 문턱치를 사용하는, 부스팅에 효율적인 약분류기를 구현하기 위하여 판별 함수에 의한 약분류기 문턱치 선정 방법을 제안하였다. Viola와 Jones가 사용한 단일 문턱치 기반 약분류기들은 객체 클래스와 클러터 클래스 간 판정 경계가 지나치게 단순화되어, 근원적 분포를 효율적으로 분리하기에 적합하지 않다. 더욱이 캐스케이드의 뒷단으로 갈수록 이런 약분류기들은 문턱 난이도에 비해 상대적으로 뚜렷하게 약해져서 부스팅

효과를 내지 못 한다. 이 논문에서는 이러한 단점을 지닌 기존의 약분류기 대신에, 근원적 분포를 분산이 다른 두 개의 노멀 분포로 모델링하고, 이들에 대해 판별 함수 기반 방법을 사용함으로써 부스팅 효과가 좋은 다중 문턱치 기반 약분류기를 구현할 수 있었다. 실험을 통해 제안 기법이 feature 수를 더 적게 필요로 하는 등 기존 방법에 비해 더 효율적으로 훈련되는 동시에 분류 성능도 좋음을 확인할 수 있었다.

참고 문헌

- [1] P. Viola and M. Jones, "Rapid object detection using a boosted cascade of simple features," Conf. Computer Vision and Pattern Recognition (CVPR), 2001.
- [2] P. Viola and M. Jones, "Robust Real-Time Face Detection," International Journal of Computer Vision, Vol.57, No.2, pp.137-154, 2004.
- [3] Y. Freund and R. Schapire, "A decision-theoretic generalization of on-line learning and an application to boosting," Journal of Computer and System Sciences, 1997(8).
- [4] R. E. Schapire and Y. Singer, "Improved Boosting Algorithms Using Confidence-Rated Predictions," Machine Learning, Vol.37, pp.297-336, 1999.
- [5] S. Z. Li and Z. Q. Zhang, "FloatBoost Learning and Statistical Face Detection," IEEE Trans. Pattern Analysis and Machine Intelligence, Vol.26, No.9, pp.1112-1123, 2004(9).
- [6] C. Liu and H. Y. Shum, "Kullback-Leibler Boosting," Proc. Computer Vision and Pattern Recognition, pp.587-594, 2003.
- [7] R. Lienhart and J. Maydt, "An Extended Set of Haar-Like Features for Rapid Object Detection," Proc. IEEE Int'l Conf. Image Processing, Vol.1, pp.900-903, 2002.

[8] B. Wu, H. Ai, C. Huang, and S. Lao, "Fast Rotation Invariant Multi-View Face Detection Based on Real AdaBoost," Proc. IEEE Conf. Automatic Face and Gesture Recognition, pp.79-84, 2004.

[9] M. Kořlsch and M. Turk, "Robust Hand Detection," Proc. IEEE Conf. Automatic Face and Gesture Recognition, pp.614-619, 2004.

[10] T. Mita, T. Kaneko, B. Stenger and O. Hori, "Discriminative feature co-occurrence selection for object detection," IEEE Trans. Pattern Analysis and Machine Intelligence, Vol.30, No.7, pp.1257-1269, 2008.

[11] D. Zhang, S. Z. Li, and D. G. Perez, "Real-Time Face Detection Using Boosting in Hierarchical Feature Spaces," Proc. Int'l Conf. Pattern Recognition, pp.411-414, 2004.

[12] R. Duda, P. Hart, and D. Stork, *Pattern Classification*, Wiley- Interscience, 2000.

유 현 중(Hyeon-Joong Yoo)

정회원



- 1982년 2월 : 서강대학교 전자공학과(공학사)
 - 1991년 7월 : 미조리대학교 전기 및컴퓨터공학과(공학석사)
 - 1996년 5월 : 미조리대학교 전기 및컴퓨터공학과(공학박사)
 - 1996년 10월 ~ 현재 : 상명대학교 정보통신학과 교수
- <관심분야> : 패턴인식, 컴퓨터비전

김 형 석(Hyongsuk Kim)

정회원



- 1980년 2월 : 한양대학교 전자공학과(공학사)
 - 1982년 2월 : 전북대학교 전기공학과(공학석사)
 - 1988년 5월 : 미조리대학교 전기 및컴퓨터공학과(공학박사)
 - 1993년 9월 ~ 현재 : 전북대학교 전자정보공학부 교수
- <관심분야> : 로봇비전, 패턴인식, 병렬회로망

저자 소개

삼 아디카리(Shyam Adhikari)

정회원



- 2005년 6월 : National Institute of Technology, Silchar, India B. Tech(공학사)
 - 2008년 8월 : Malaviya National Institute of Technology, Jaipur, India M. Tech(공학석사)
 - 2009년 8월 ~ 현재 : 전북대학교 전자정보공학부 박사과정
- <관심분야> : 영상처리, 패턴인식