

실시간 물체 검출을 위한 고효율 Viola-Jones 검출 프레임워크

High Efficient Viola-Jones Detection Framework for Real-Time Object Detection

박 병 주*, 이 재 흥**

Byeong-Ju Park*, Jae-Heung Lee**

Abstract

In this paper, we suggest an improved Viola-Jones detection framework for the efficient feature selection and the fast rejection method of the sub-window. Our object detector has low computational complexity because it rejects sub-windows until specific threshold. Owing to using same framework, detection performance is same with the existing Viola-Jones detector. We measure the number of average feature calculation about MIT-CMU test set. As a result of the experiment, the number of average feature calculation is reduced to 45.5% and the detection speed is improved about 58.5% compared with the previous algorithm.

요 약

본 연구에서는 기존의 Viola-Jones 검출 프레임워크를 개선하여 하나의 특징 당 더 높은 효율을 가지며 검출대상이 아닌 서브 윈도우들을 더 빠르게 제거하는 개선된 학습 알고리즘을 제안한다. 학습의 결과로 생성된 물체 검출기는 서브 윈도우를 특정 임계값까지 빠르게 제거하기 때문에 서브 윈도우당 계산수가 줄어든다. 기존의 Viola-Jones 물체 검출기와 동일한 프레임워크이므로 검출 성능에는 영향을 주지 않는다. MIT-CMU 테스트 집합에 대해서 서브 윈도우당 특징 계산 횟수를 측정하였으며 기존 계산 횟수의 45.5%로 줄어들어 검출 속도가 약 58.5% 향상됨을 확인하였다.

Key words : High Efficient Feature, Fast Rejection, Object Detection, Machine Learning, Viola-Jones

1. 서론

일반적으로 물체인식이란 실세계의 장면을 제약이 없는 상태로 촬영된 영상 안에서 어떤 물체가 영상 내에 존재하는지, 혹은 어떤 장면인지를 특정 명칭으로 컴퓨터가 인식하는 것이다. 물체의 인식은 보통 물체 검출 단계를 포함하는 개념으로 알려져 있다. 최근 들어 물체 검출의 중요성이 커지면서 검출과 인식이 서로 독립적인 분야로 연구되고 있다.

PC의 발전에 의해 대량의 데이터를 고속으로 처

* Dept. of Computer Engineering, Hanbat University
010-4447-5267, dinobei89@gmail.com

★ Corresponding author 042-821-1208 jhlee@hanbat.ac.kr

※ Acknowledgment

This research was financially supported by the Ministry of Education (MOE) and National Research Foundation of Korea(NRF) through the Human Resource Training Project for Regional Innovation (No. 2012H1B8A2026119).

Manuscript received Dec. 10, 2013; revised Jan. 13, 2014; accepted Jan. 15, 2014

리하는 것이 가능해 졌으며, 또한 기계 학습 분야에서 연구된 학습방법이 물체인식에 적용될 수 있게 되었기 때문에 많은 물체인식 방법이 제안되었다. 일반적인 기술을 예로 들면, 특징 부분에서 에지 검출, 코너 검출, Haar-like feature, HoG, LBP 등이 있고 학습 방법으로는 PCA, 인공 신경망(ANN), 서포트 벡터 머신(SVM), Adaboost, 액티브 러닝 등으로 다양하다.

이 중 Viola-Jones 물체 검출 프레임워크는 실시간으로 높은 물체 검출률을 달성하기 위해 제안된 최초의 물체 검출 프레임워크이다. 보행자나 얼굴, 차량, 번호판, 손 등을 검출하기 위한 응용 사례가 있으며 적용 결과 이 프레임워크는 다른 검출 알고리즘에 비해 검출 속도도 빠르면서 검출률도 비슷하거나 우수한 것으로 알려졌다. Viola-Jones 알고리즘의 핵심은 초기에 정한 수천 개에서 수만 개 정도의 포지티브 샘플들의 패턴과 그 외의 모든 패턴을 구분하는 것으로 볼 수 있다. 그 외의 모든 패턴의 개수는 그레이스케일 영상의 서브윈도우에서 가로, 세로의 길이에 따라 2^{SHW} 개가 존재하므로 가능한 모든 패턴을 학습 시 모두 고려한다면 천문학적인 계산량이 필요하다. 따라서 가능한 모든 패턴 대신 네거티브 샘플 집합을 사용하여 학습하고, 실제 테스트하는 환경에서 오검출하는 패턴들을 추가하여 재학습하는 방식으로 검출기를 개선한다. 즉 일정 검출률(Detection rate, 이하 DR)을 달성한 상태에서 오검출률(False Positive Rate, 이하 FPR)을 최대한 낮게 학습하는 것이 관건이다.

기존의 Viola-Jones 물체 검출 프레임워크는 직분 이미지를 사용하여 Haar-like feature를 빠르게 계산할 수 있고 빠른 리젝션을 위해 cascade 형태로 학습한다. 다만, Haar-like feature set은 경계선의 명암차이만을 특징으로 사용하므로 다양한 패턴의 영상에서는 오인식할 확률이 높아지는 단점이 있다. 따라서 검출성능을 더욱 높이려는 연구를 하면서 불가피하게 연산량이 늘어나게 되었고 이를 적용하면서도 속도를 향상시킬 수 있는 연구가 필요하게 되었다.

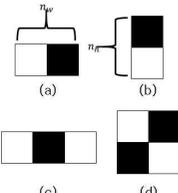
본 연구에서는 Viola-Jones 물체 검출 프레임워크를 개선하여 동일한 학습 데이터로 더 빠른 검출기를 학습하는 알고리즘을 제안한다.

II. Viola-Jones 검출기 관련 연구

1. 기존 물체 검출기의 한계점

Viola-Jones 알고리즘에서 사용하는 Haar-like

feature의 overcomplete set은 임의의 비율로 정교하게 샘플링된 위치를 가진 특징들을 제공[1]하기 때문에 풍부한 특징 표현법이며, 특징 계산 속도가 굉장히 빠른 특징을 갖고 있다.



$$\sum_{h=1}^{H_{lim}} \sum_{w=1}^{W_{lim}} (W - n_w w + 1)(H - n_h h + 1)$$

$$H_{lim} = \frac{H - (H/n_h)}{n_h}$$

$$W_{lim} = \frac{W - (W/n_w)}{n_w}$$

Fig 1. The number of overcomplete set of Haar-like features

그림 1. Haar-like feature와 overcomplete set의 수

서브윈도우 크기에 따른 Haar-like feature의 overcomplete set의 수는 그림 1의 수식으로 계산할 수 있다. 그러나 Haar-like feature는 경계선 정보만을 이용하기 때문에 성능 향상에 한계가 있다.

또 다른 한계점은 정규화이다. Haar-like feature는 정규화가 필수적인데, 기존의 분산정규화를 이용하면 영상의 밝기 변화가 작은 영역에서 오검출이 증가[2]하게 되며, 정규화를 위해 별도의 적분영상을 더 생성해야하기 때문에 처리 속도에 적지 않은 영향을 미치게 된다. 이를 개선하기 위해 현재까지 연구된 Viola-Jones 물체 검출기 관련 연구 주제는 크게 속도 또는 검출성능 향상의 두 가지로 볼 수 있다.

2. 검출성능 향상을 위한 기존 연구

Lienhart와 Maydt [3]는 Viola와 Jones가 제안한 4가지 종류의 Haar-like feature를 확장하여 회전된 특징 등이 추가된 14개의 Haar-like feature 집합을 소개하였다. 이 새로운 특징 집합은 기존의 간단한 4개의 특징에 비해 표현이 훨씬 풍부하다. 적용 결과 이 특징들로 학습된 검출기는 동일한 DR일 때 10% 낮아진 FPR을 보였다.

Takeshi Mita et al. [4]는 Joint Haar-like feature를 제안하였다. 이 논문에서 제안하는 특징은 여러 Haar-like feature들의 동시발생을 기반으로 하며 구조적으로 유사한 것으로 판명된 동시발생은 효율적인 분류기를 만드는 것을 가능하게 해준다고 밝히고 있다. 얼굴 검출기는 기존의 Adaboost 알고리즘을 기반으로 Joint Haar-like feature의 stagewise selection에 의해 학습된다. 이 특징을 적용한 실험 결과 Joint Haar-like feature는 매우 빠르게 계산될 수 있으며

잡음이나 조명의 변화에도 강인하다고 밝혔다.

다음으로 Ramirez와 Fuentes [5]는 Asymmetric Totally Corrective Boosting이라는 알고리즘을 제안하였다. 이 boosting 알고리즘은 Viola와 Jones의 검출 프레임워크와 두 가지 방면에서 다른 알고리즘인데, 첫 번째는 대칭적인 loss가 아닌 비대칭적인 loss에 대해 최적화한 것이고, 두 번째는 일반적인 boosting 알고리즘에서 사용하는 stagewise 최적화와 대조해서 totally corrective 방식으로 업데이트되도록 보다 효율적인 boosting을 설계한 것이다. 또한 제안하는 부스팅 알고리즘은 기존의 boosting과는 다르게 캐스케이드를 학습하는 동안 분류에 무관한 약분류기를 제거하는 de-select가 가능하다. 이 연구의 실험은 얼굴과 보행자 검출을 통해 입증하였으며, 실험 결과 개선된 검출 성능과 학습된 강분류기에 있는 약분류기의 개수가 더욱 적어진 것을 보였다.

일반적으로 검출성능 향상을 위한 기존의 연구들은 보통 학습이나 분류 시 연산량이 많아져 기존보다는 느린 속도로 동작하는 결과를 얻었다. 이를 개선하기 위해 속도 향상을 위한 연구나 속도와 검출성능 향상 모두를 고려한 연구를 다음 절에서 보여준다.

3. 속도 향상을 위한 기존 연구

속도 향상을 위한 기존의 연구는 크게 학습과 분류 시 속도를 개선하기 위한 연구로 나뉜다. 분류 시 속도 향상을 위해서는 일반적으로 스캔 방식을 변경하거나 계산 방식을 바꾸어 연산량을 줄이는 방법이 연구되었다.

Park와 Hwang [2]이 제안한 Haar-like feature 정규화는 기존의 분산 정규화 대신 수식 (1)과 같이 평균 정규화를 사용하여 픽셀 제곱의 적분 이미지를 생성하는 연산을 제거하여 계산량을 줄이고 속도를 개선하였다. 평균 정규화는 영상의 밝기 변화에 대해서 강건한 성능을 보여 속도뿐만 아니라 검출 성능도 개선되었다.

$$HF_u = \frac{1}{u} HF = \frac{\sum_i r_i w_i}{\sum_{x,y \in window} i(x,y)} \quad (1)$$

다음으로 학습 시 속도 개선을 위해 PSO기반의 Adaboost (PSOAdaboost)가 Mohemmed et al. [6]에 의해 제안되었다. ExAdaboost로 학습할 때보다 PSOAdaboost가 약 19배 빠른 연구결과를 얻었으며 평균 DR과 평균 FPR에서도 더 좋은 결과를 얻었다.

An과 Kim [7]은 연속적인 비디오 프레임에서 사람

을 검출 및 추적하기 위해 스캔 방식을 가우시안 군집 최적화(GPSO)를 사용하여 변경하였다. [7]은 [6]과는 다르게 학습 시 속도 개선이 아니라 분류 시 속도 개선을 위해 PSO를 적용한 점이 다른데, 슬라이딩 윈도우 스캔에 비해 서브윈도우의 수를 극적으로 감소시켰다.

Kim과 Lee [8]는 얼굴검출기의 성능을 높이기 위해 멀티코어의 이점과 색상 정보를 활용하였다. 스캔 영역을 줄이기 위해 피부색 이외의 영역은 배경으로 가정하였고, 병렬처리를 위해 알고리즘을 기능별로 분할하여 독립적으로 동작되도록 설계하였다. Cortex-A9 멀티코어가 내장된 SoC에서 실험 결과 알고리즘을 분할하기 전에 비해 약 1.8배 빠른 검출 결과를 나타내었다.

III 본 논문의 개선된 Viola-Jones 물체 검출기

그림 2는 각각의 방법으로 학습한 검출기이다. 그림 2 (a)는 Adaboost 학습 방법으로 학습한 결과이며 검출기가 하나의 스테이지로 구성되어있다. 그림 2 (b)는 기존의 Viola-Jones 검출기 학습 알고리즘으로 학습한 결과이며 cascade형태로 구성되어있다. 그림 2 (c)는 제안하는 방법으로 학습한 검출기의 예인데, 그림 2 (b)와 마찬가지로 cascade로 구성되어있지만 하나의 스테이지가 더 적은 약분류기로 구성되어있어서 리젝션 횟수가 더 많다는 특징이 있다. 본 논문에서는 그림 2 (c)와 같은 검출기를 학습하기 위한 알고리즘을 제안한다.

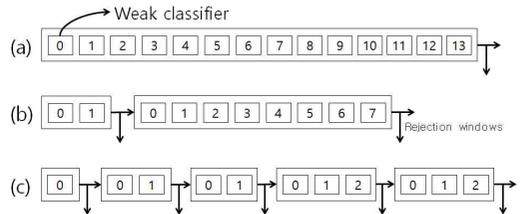


Fig 2. Learned detector of each methods
그림 2. 각각의 방법으로 학습한 검출기

본 논문에서 제안하는 방법은 네거티브 샘플의 평가 기준 변경, 빠른 리젝션을 위한 Adaboost의 종료 조건 변경과 학습 시 발견된 가장 높은 효율의 스테이지를 선택하기 위한 세대수 학습 구조의 세 가지로 나눌 수 있다.

1. 네거티브 샘플의 평가 기준 변경

기존의 Viola-Jones 물체 검출 알고리즘에서는 네거티브 샘플을 random하게 선택하여 이에 종속된 Adaboost 학습을 한다. Random하게 선택된 네거티브 샘플들이기 때문에 만약 현재 남아있는 서브윈도우 중에서 분류에 특징이 많이 필요한 샘플이 다수 선택되면 최종적으로 만들어진 검출기의 연산량이 많아져 비효율적일 수 있다. 또한 각 스테이지의 FPR을 계산하는데 있어서 random하게 선택된 네거티브 샘플들로 평가하게 되면, 선택된 샘플에 종속적으로 FPR이 결정되기 때문에 전체를 대상으로 평가했을 때와 비교해서 편이하게 다른 결과를 얻을 수도 있다. 실제로 본 연구에서는 기존 학습 결과를 테스트해보았고, 표 1과 같이 초기 스테이지의 성능에 따라 평균 계산횟수가 2.20배 차이나고 검출기의 속도는 최대 2.09배까지 차이나는 것을 확인하였다.

Table 1. The result of test for Viola-Jones detector about MIT-CMU test set.

표 1. MIT-CMU 테스트 집합에 대한 Viola-Jones 검출기 테스트 결과

학습 횟수	1	2	3
FPR	5.60e-07	1.85e-06	2.84e-06
평균 계산 횟수	3.85	6.29	8.48
평균 계산 속도	83.54ms	121.47ms	174.98ms

따라서 random하게 네거티브 샘플을 선택하되, 검출할 물체가 포함되지 않은 영상 집합에 대해 각 스테이지의 FPR과 효율을 측정하도록 변경하였다.

2. Adaboost 종료조건 변경

기존의 학습 알고리즘에서는 스테이지당 목표 FPR인 f 가 입력 파라미터로 들어가서 수식 (2)와 같이 이전 스테이지보다 f 만큼 더 filter out 능력이 좋아져야만 하나의 스테이지 학습이 종료되었다. 이렇게 되면 빠른 리젝션을 하지 못해 비효율적인 분류기가 생성될 여지가 있다.

$$F[n-1]*f > F[n] \tag{2}$$

$$F[n-1] > F[n] \tag{3}$$

따라서 선택된 약분류기의 수와 상관없이 효율이 가장 좋을 때 빠르게 리젝션 할 수 있도록 수식 (3)을 사용하였다. 조건을 수식 (3)으로 변경하여 학습하면 스테이지가 매우 많아지게 되는데, cascade 구조에서는 스테이지가 많아질수록 최종 DR이 떨어지게

된다. 따라서 filter out 임계값($threshold_{filterout}$)을 정의해서 그 임계값 전까지만 (3)의 조건을 사용하도록 설계하였다. 최종적으로 변경된 Adaboost 종료조건은 그림 3과 같다.

```

F[n] = (Evaluate FPR for NFIS)
if(1.0 - F[n - 1] ≥ thresholdfilterout && F[n] < f * F[n - 1])
    break;
else if(F[n] < F[n - 1]) break;
    
```

Fig 3. Adaboost stopping criteria for fast rejection
 그림 3. 빠른 리젝션을 위한 Adaboost 종료조건

3. 세대수 학습 구조

각 스테이지 학습 중 random하게 선택된 네거티브 샘플에 따라 초기 스테이지의 학습 결과가 달라질 수 있다. 초기 스테이지에서 가장 많은 FPR의 감소를 보이기 때문에 이 부분의 결과가 전체적인 학습 속도에 큰 영향을 미치게 된다.

$$\frac{1 - FPR}{\text{Number of Weak classifier}} \tag{4}$$

따라서 학습 중 발견한 가장 좋은 효율의 스테이지를 선택하기 위해 퍼셉트론의 포켓 알고리즘과 같이 세대(epoch)를 두었다. 즉, 각 세대 중 최고의 효율을 발휘하는 스테이지를 선택하고 몇 번의 세대가 진행되는 동안 변화가 없으면 현재 스테이지의 학습을 마치도록 변경하였다. 효율 계산을 위해 수식 (4)를 사용하였으며 변경된 학습 구조는 그림 4과 같다.

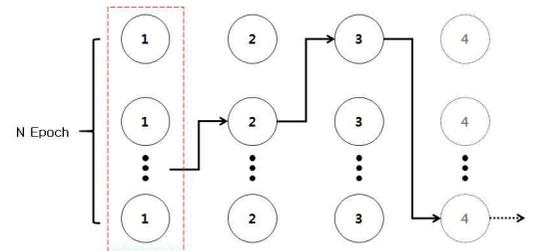


Fig 4. Modified learning structure for the high efficient stage selection
 그림 4. 가장 높은 효율의 스테이지를 선택하기 위해 변경된 학습 구조

IV 실험 및 고찰

기존의 다양한 응용 중 얼굴 검출을 바탕으로 실험

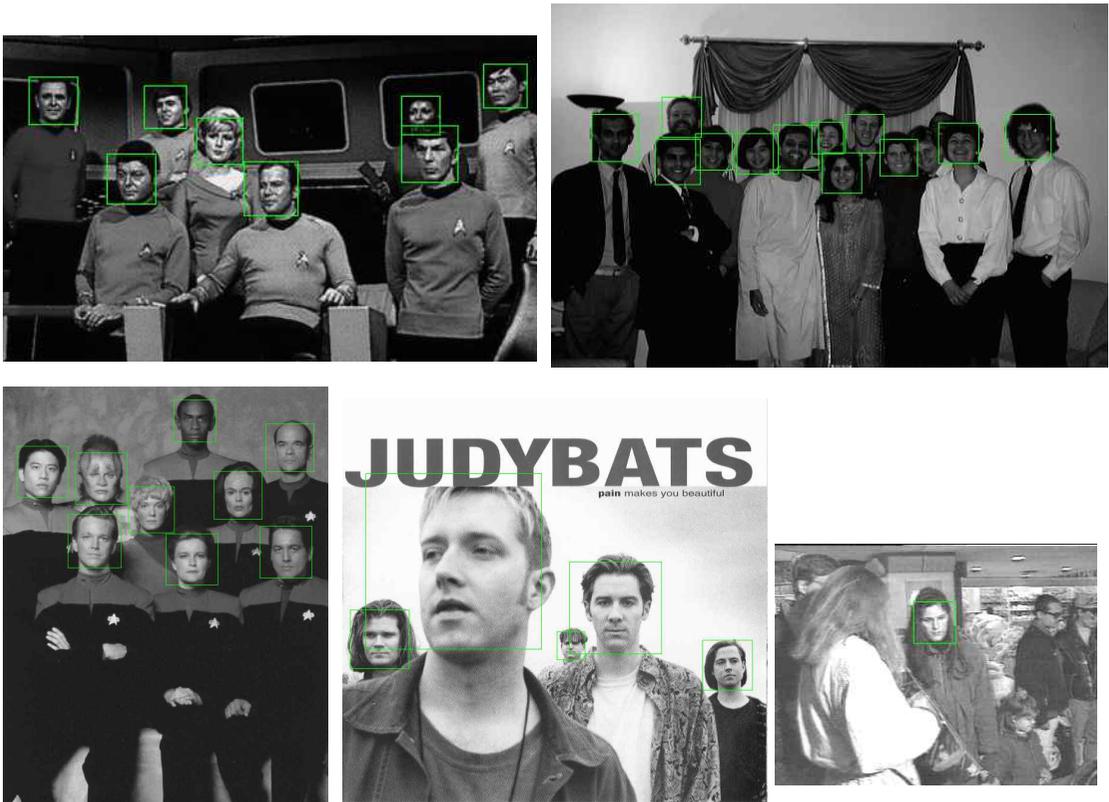


Fig 5. Result of our face detector on a number of test images from the MIT-CMU test set
 그림 5. MIT-CMU test set에 대해 제안하는 방법으로 학습한 얼굴검출기의 결과

하였다. LFW (Labeled Faces in the Wild) 얼굴 데이터베이스에서 정렬된 데이터를 이용하여 직접 제작한 10,806개의 얼굴 샘플과 random하게 촬영된 2,050장의 NFIS (Non-face image set)를 학습 데이터로 사용하였다. 기존의 Viola-Jones 얼굴 검출기[1]의 연구 결과를 토대로 scale factor와 d, f는 각각 1.25, 0.99, 0.3으로 두고 학습하였고, 특징의 정규화는 [2]의 방법을 사용하였다. 기존의 방법과 본 논문에서 제안한 방법을 적용하여 학습한 결과 ROC curves는 그림 6과 같았으며, 본 논문에서 제안하는 검출기로 검출한 결과는 그림 5와 같다. 검출 성능에는 거의 영향을 주지 않았지만 고효율의 스테이지를 선택하였기 때문에 더 낮은 FPR에서 약간 더 좋은 DR을 보인 것을 알 수 있다.

그림 7을 보면 스테이지별 수렴 속도가 기존보다 느린데, 이는 본 논문의 방법에서 각 스테이지별 조건을 충족하기 쉽게 했기 때문이다. 표 2를 보면 본 연구의 방법으로 학습한 검출기의 스테이지별 약분류

기 수가 더 적다는 것을 알 수 있다.

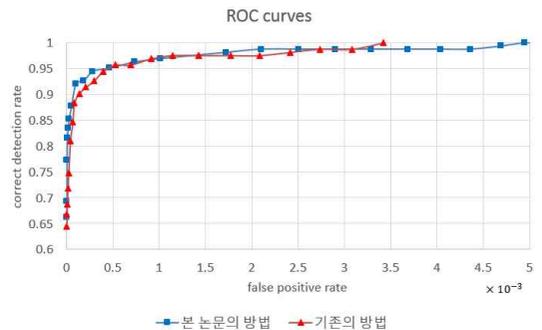


Fig 6. ROC curves for comparison of performance of Viola-Jones detector and our method

그림 6. Viola-Jones 검출기와 본 논문의 검출기의 성능 비교를 위한 ROC 커브

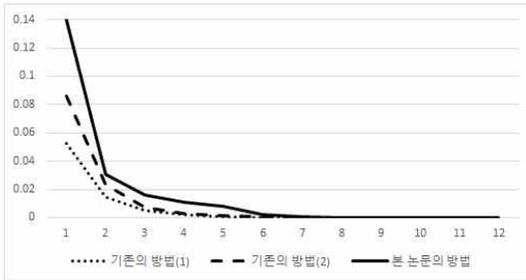


Fig 7. FPR reduction trend for each stage
그림 7. 스테이지별 FPR 감소 추이

두 검출기 사이의 성능 비교를 위해 약분류기별로 FPR을 살펴보면 평균적으로 서브윈도우당 특징 계산 횟수가 줄어든 것을 알 수 있다. 그림 8은 약분류기별 FPR을 보여주는 그래프인데 기존의 방법에 비해 더 적은 특징만 계산하고 빠르게 리젝션하는 것을 알 수 있다. 한편, 검출기는 평균 계산횟수(nc_m)를 수식으로 계산할 수 있다. 즉, n_x 가 스테이지 x 의 약분류기 수이고 f_{x-1} 이 스테이지 $x-1$ 에서의 FPR이라면 수식 (5)와 같이 표현된다.

$$nc_m = \sum_{x=1}^N n_x f_{x-1}, f_0 = 1 \quad (5)$$

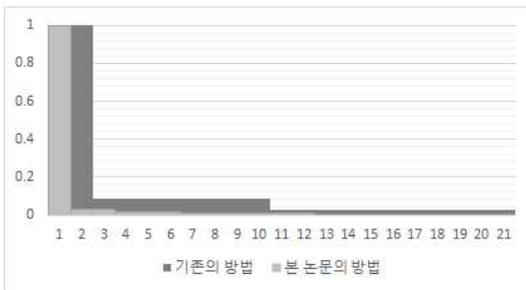


Fig 8. Weak classifier-FPR graph
그림 8. 약분류기-FPR 그래프

따라서 그림 8의 그래프 면적을 수식 (5)를 통해 계산하면 평균 계산 횟수를 구할 수 있게 되므로 줄어든 계산 횟수를 수치적으로 계산할 수 있는데, 기존 방법의 평균 계산횟수는 3.85였으며 본 논문의 방법은 1.75로 기존에 비해 45.5%로 줄어 들었다.

MIT-CMU 테스트 집합을 기준으로 이전의 검출 성능과 이후의 검출 성능을 85% 전후로 거의 동일하게 맞춘 뒤 결과를 측정하였다. 표 1과 표 3에서 얻은

Table 2. Comparison of traditional and our methods
표 2. 기존의 방법과 본 논문의 학습 결과 비교

	기존의 방법		본 논문의 방법	
	FPR	N_{wc}	FPR	N_{wc}
stage1	0.086021	2	0.0139901	1
stage2	0.023486	8	0.030257	2
stage3	0.007253	14	0.015886	3
stage4	0.002726	21	0.010729	3
stage5	0.001114	29	0.008003	3
stage6	0.000403	36	0.002392	22
stage7	0.000150	37	0.000635	34
...

데이터를 바탕으로 각각 가장 좋은 결과일 때를 비교했을 때 약 58.5% 검출 속도가 향상된 것을 알 수 있다. 검출 속도의 개선 정도는 사용하는 특징의 계산량과 테스트 영상에 따라 다르게 측정되었지만, 기본적으로 계산량이 증가하면 실제 검출 속도 향상 폭은 더욱 증가할 것이다.

Table 3. The result of test for our detector about MIT-CMU test set.

표 3. MIT-CMU 테스트 집합에 대한 제안하는 검출기 테스트 결과

학습 횟수	1	2	3
FPR	9.91e-08	3.30e-08	6.70e-08
평균 계산 횟수	1.76	1.75	1.75
평균 계산 속도	49.85ms	49.43ms	48.83ms

본 연구의 결과는 기존의 연구와 독립적이기 때문에 다른 연구결과를 접목하면 보다 큰 성능향상이 가능할 것으로 보인다. 예를 들어 다른 특징을 사용하여 인식 성능을 높이거나 스캔 방식을 변경해서 속도를 더욱 향상시킬 수 있다.

V 결론

본 논문에서는 빠른 리젝션과 고효율 특징 선택을 이용한 빠른 Viola-Jones 물체 검출기를 제안하였다. 네거티브 샘플을 random하게 선택하여 각 스테이지를 학습할 때 생기는 문제점을 해결하기 위해 FPR을 평가하는 기준을 변경하였고 세대수 개념을 도입한 학습 구조를 제시하였다. 그리고 가장 좋은 효율의 스테이지를 선택하도록 Adaboost 종료 조건을 변경하였다.

성능 비교를 위해 기존의 방법과 본 논문에서 제안하는 방법에 대해 각각 얼굴 데이터로 학습하였고,

MIT-CMU 테스트 집합을 기준으로 학습 결과를 얻었다. 본 논문에서 제안하는 방법을 적용한 결과 검출 성능에는 영향을 주지 않았으며, 가장 좋은 결과를 기준으로 비교했을 때 서버윈도우당 평균 계산 횟수가 45.5%로 감소하였고 검출 속도는 약 58.5% 향상되었다.

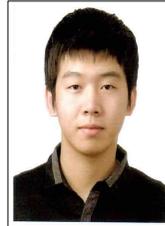
References

- [1] Paul Viola, Michael J. Jones "Robust Real-Time Face Detection" *International Journal of Computer Vision*, vol.57, no.2, pp.137-154, May. 2004
- [2] Ki-Yeong Park, Sun-Young Hwang "An Improved Normalization Method for Haar-like Features for Real-time Object Detection" *The Korean Institute of Communications and Information Sciences*, vol.36, no.8, pp.505-515, Aug. 2011
- [3] Lienhart, R., Maydt, J. "An Extended Set of Haar-like Features for Rapid Object Detection" *Image Processing. 2002. Proceedings. 2002 International Conference on*, vol.1, no., pp.900-903, 2002
- [4] Takeshi Mita, Toshimitsu Kaneko, Osamu Hori "Joint Haar-like Features for Face Detection" *Tenth IEEE International Conference on*, vol.2, no., pp.1619-1626, Oct. 2005
- [5] Geovany A. Ramirez, Olac Fuentes "Multi-Pose Face Detection with Asymmetric Haar Features" *Applications of Computer Vision, 2008. WACV 2008. IEEE Workshop on*, vol., no., pp.1-6, Jan. 2008
- [6] Ammar W Mohemmed, Mengjie Zhang, Mark Johnston "Particle Swarm Optimization Based Adaboost for Face Detection" *Evolutionary Computation, 2009. CEC '09. IEEE Congress on*, vol., no., pp.2494-2501, May. 2009
- [7] Sung-Tae An, Jeong-Jung Kim and Ju-Jang Lee "SDAT: Simultaneous Detection and Tracking of Humans using Particle Swarm Optimization" *Mechatronics and Automation (ICMA), International Conference on*, vol., no., pp.483-488, Aug. 2011
- [8] Hong-Hee Kim, Jae-Heung Lee "An Efficient Face Detection Method Using Skin Color Information and Parallel Processing in Multi-Core

SoC" Journal of IKEEE, vol.16, no.4, pp.375-381, Dec. 2012

BIOGRAPHY

Park Byeong-Ju (Student Member)



2012 : BS degree in Computer Engineering, Hanbat National University.

2012 ~ Present : MS Course in Computer Engineering, Hanbat National University.

Lee Jae-Heung (Member)



1983 : BS degree in Electronic Engineering, Hanyang University.
1985 : MS degree in Electronic Engineering, Hanyang University.
1994 : PhD degree in Electronic Engineering, Hanyang University.

1989 ~ Present : Professor in Dept. of Computer Engineering, Hanbat National University