

JointBoost 알고리즘을 이용한 기울어진 얼굴 검출

정운호[†], 송영모^{**}, 고운호^{***}

요 약

AdaBoost 알고리즘을 이용한 얼굴 검출 방법은 가장 빠르고 신뢰성 있는 얼굴 검출 알고리즘의 하나로 이를 향상하거나 확장한 많은 알고리즘들이 제안되었다. 그러나 이전의 접근들은 대부분 정면 얼굴만을 다루고 있고 AdaBoost 알고리즘을 정면과 기울어진 얼굴에 동일한 특징으로 적용함으로써 기울어진 얼굴에 대한 분별 성능이 제한적이었다. 또한 회전된 얼굴을 검출하기 위하여 입력된 영상을 회전하여 정면 얼굴 검출 방법을 적용하거나 회전된 각도에 따라 다른 검출기를 적용하는 기존 기법들은 연산량이 많고 검출률이 저하되는 문제를 가지고 있다. 본 논문에서는 이러한 문제를 극복하기 위해 JointBoost를 이용한 기울어진 얼굴 검출 방법을 제안한다. JointBoost를 통해 클래스간의 공유된 feature들을 찾음으로써 연산량과 샘플 복잡도를 감소시켰다. 실험 결과를 통해 제안된 방법의 검출률이 동일한 반복 횟수를 가지는 학습에서 기존의 AdaBoost 기법에 비해 2% 이상 우수함을 보인다. 또한 제안된 방법은 얼굴의 존재를 검출할 뿐만 아니라 기울어진 방향에 대한 정보도 제공할 수 있다.

Inclined Face Detection using JointBoost algorithm

Youn-Ho Jung[†], Young-Mo Song^{**}, Yun-Ho Ko^{***}

ABSTRACT

Face detection using AdaBoost algorithm is one of the fastest and the most robust face detection algorithm so many improvements or extensions of this method have been proposed. However, almost all previous approaches deal with only frontal face and suffer from limited discriminant capability for inclined face because these methods apply the same features for both frontal and inclined face. Also conventional approaches for detecting inclined face which apply frontal face detecting method to inclined input image or make different detectors for each angle require heavy computational complexity and show low detection rate. In order to overcome this problem, a method for detecting inclined face using JointBoost is proposed in this paper. The computational and sample complexity is reduced by finding common features that can be shared across the classes. Simulation results show that the detection rate of the proposed method is at least 2% higher than that of the conventional AdaBoost method under the learning condition with the same iteration number. Also the proposed method not only detects the existence of a face but also gives information about the inclined direction of the detected face.

Key words: face detection(얼굴검출), JointBoost(조인트부스트), AdaBoost(에이다부스트), shared feature(특징 공유), inclined face(얼굴 회전)

※ 교신저자(Corresponding Author): 고운호, 주소: 대전광역시 유성구 궁동 충남대학교 공대4호관 514호(305-764), 전화: 042)821-6860, FAX: 042)823-4919, E-mail: koyh@cnu.ac.kr

접수일: 2011년 11월 19일, 수정일: 2012년 2월 19일
완료일: 2012년 3월 14일

[†] 정회원, 충남대학교 메카트로닉스공학과
(E-mail: lordnegaro@cnu.ac.kr)

^{**} 정회원, LG전자
(E-mail: thegrimja@nate.com)

^{***} 중신회원, 충남대학교 메카트로닉스공학과

※ 이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 기초연구사업 지원을 받아 수행된 것임 (2009-0073947).

1. 서 론

생체 인식(biometric recognition)은 인간의 생리적 또는 행동적 특성을 자동화된 장치로 측정하여 개인을 식별하는 기술로 얼굴, 홍채, 손 모양, 지문, 음성, 걸음걸이 등이 특징으로 사용된다[1]. 생체인식의 한 분야인 얼굴 인식(face recognition)은 시스템이 사용자에게 특별한 접촉이나 요구를 하지 않으므로 자연스럽게 사람을 인식할 수 있어 이용이 편리하고, 영상 보안, 감시와 같이 다른 생체 인식으로는 구현할 수 없는 기능을 수행할 수 있다. 이러한 얼굴 인식 과정은 다시 얼굴 검출과 얼굴인식의 두 단계로 나눌 수 있다. 얼굴 인식의 개발 초기에는 얼굴 검출이 단순히 얼굴 인식의 전처리 과정으로 여겨져 간과되었던 면이 있었지만, 얼굴 검출의 성능이 얼굴 인식 성능에 결정적인 영향을 준다는 것이 알려지면서 별도의 연구 분야로서 활발히 연구되고 있다.

지금까지 연구되고 있는 얼굴 검출 방법으로는 얼굴에 대한 사람의 지식을 규칙으로 만들어 검출(눈, 코, 입 등의 얼굴 특징들 사이에 존재하는 상대적인 위치와 거리를 규칙으로 만들)하는 지식기반 방법[2], 얼굴의 변하지 않는 특징들을 찾아 얼굴을 검출하는 특징불변 방법[3,4], 미리 준비된 표준 얼굴 패턴을 템플릿으로 하여 입력영상과 비교하여 얼굴을 검출하는 템플릿 정합 방법[5,6], 미리 준비된 템플릿을 사용하지 않고 학습 영상들로부터 훈련 과정을 통해 얼굴을 검출하는 외양 기반 방법 등이 있다. 현재 가장 많이 쓰이고 있는 방법은 외양 기반 방법으로 그 종류는 신경회로망(Neural Network)[7,8], SVM(Support Vector Machine)[9,10], LDA(Linear Discriminant), AdaBoost 등이 있다[11][12].

얼굴 검출 기능이 단독으로 사용되어지는 중요한 응용 분야중의 하나는 디지털 카메라이다. 현재 출시되고 있는 다수의 디지털 카메라에는 얼굴 검출 기능이 구현되어 있으며 사용자들은 이를 친숙하게 활용되고 있다. 하지만 정면 얼굴에 대하여만 검출이 되고 있는 상황이며 기울어진 얼굴 검출을 하기 위해서는 입력 영상을 회전하거나 기울어진 각도에 따라 독립된 검출기를 사용하여 이를 검출하고 있다. 하지만 이 방법은 정면 얼굴 검출의 중복된 연산으로 인해 비효율적인 방법이다.

얼굴 검출이 사용되는 대부분의 분야는 실시간 검

출을 필요로 하고 있어 입력된 영상으로부터 빠르게 얼굴을 검출할 수 있어야 사용자의 불편을 최소화할 수 있으며 그 기능의 효과를 볼 수 있다. 따라서 본 논문에서는 중복된 연산을 줄이고, 검출률을 높이기 위해 JointBoost 알고리즘을 사용하였다. 정면 얼굴 검출은 주로 단일 특징을 사용하는 AdaBoost 알고리즘을 사용한다. 이를 공통된 특징을 사용하는 JointBoost 알고리즘을 사용함으로써 중복된 연산을 줄이고, 검출률을 높일 수 있는 것이다.

본 논문의 2장에서는 AdaBoost 알고리즘을 이용한 얼굴 검출에 대하여 알아보고, 3장에서는 JointBoost 알고리즘을 이용한 얼굴 검출에 대하여 알아본다. 4장에서는 각 알고리즘의 실험 결과를 비교해 보기로 한다.

2. AdaBoost 알고리즘을 이용한 얼굴 검출

2.1 AdaBoost 알고리즘

AdaBoost 알고리즘은 Freund와 Schapire(1996)에 의해 2분류(2-class) 문제를 해결하기 위해 설계되었으며, Viola와 Jones(2001)는 AdaBoost에 Haar-like feature와 적분 영상을 적용한 얼굴 검출 방법을 제안하였다[11]. AdaBoost에서 각 훈련 패턴은 약한 분류기(Weak classifier)를 위한 훈련 집합에 선택될 확률을 결정하는 가중치를 받는다. 만일 어떤 훈련 패턴이 정확하게 분류된다면, 다음 요소 분류기에 다시 사용될 기회는 줄어든다. 역으로, 만일 어떤 패턴이 정확하게 분류되지 않으면, 다시 사용될 기회는 증가된다. 이러한 방식으로, AdaBoost는 정보제곱적 또는 어려운 패턴들에 집중한다. 최종적으로 각 반복마다 선택된 약한 분류기의 선형 결합에 의해 강한 분류기가 생성된다.

2.2 AdaBoost 알고리즘의 한계

AdaBoost를 적용한 얼굴 검출 시스템은 정면 얼굴에는 우수한 검출률을 보이나, 회전된 얼굴에는 제한적인 성능을 보이기 때문에 이를 해결하기 위해 여러 가지 방법이 제시되고 있다. 검출 시 입력 영상을 여러 각도로 회전하여 검출하는 방법은 많은 연산량으로 인해 검출 속도의 저하를 가져오며, 영상 회전 시 발생하는 손실된 픽셀로 인해 검출률의 저하를

가져올 수 있다[13]. 입력 영상을 회전하지 않고 검출기를 회전하는 방법도 있지만[14], 이는 입력 영상을 회전하는 것과 연산량의 차이가 없다. 이들은 모두 검출 영상에 대하여 검출에 사용될 적분 영상을 구해야하고, 이를 다시 강한 분류기에 적용해야 되기 때문에 회전된 횟수만큼의 중복 연산이 필요하다. 이들과는 다른 방법으로 훈련 과정에 정면 얼굴과 회전된 얼굴을 같이 입력하여 이들을 모두 얼굴로 검출할 수도 있지만, 이는 입력된 영상들의 특징을 찾아 분류하기에는 너무 많은 약한 분류기들이 필요하게 되므로, 강한 분류기를 얻기 위해서는 많은 수의 훈련 반복이 필요할 것이며 그렇지 않을 경우에는 매우 낮은 검출률을 가져올 수 있다.

또 다른 방법으로는 다분류가 가능한 AdaBoost.M.H 알고리즘을 이용하는 방법이 있다[15]. 이 방법은 각각의 대상체에 대하여 독립된 검출기를 학습시킨 후 이들에 대한 각각의 검출기를 생성하는 것이다. 결과적으로 검출률에 있어서는 좋은 결과를 보일 수 있겠지만, 얼굴 각도에 따라 다른 검출기를 만들어 검출하는 것과 별반 차이가 없다. 이 방법 역시 앞서의 방법들과 같이 연산량의 증가를 요구한다. 즉, 서로 전혀 다른 물체를 검출하기 위해 이 방법을 사용한다면 좋은 효과를 볼 수 있겠지만, 기울어진 얼굴을 검출하기 위해 AdaBoost.M.H를 사용하는 것은 비효율적이다. 왜냐하면 정면 얼굴과 기울어진 얼굴은 유사한 특징을 많이 갖고 있기 때문에, 이 특징을 잘 이용할 수 있어야 한다.

본 연구에서는 정면 얼굴과 기울어진 얼굴들이 유사한 특징을 갖고 있다는 점을 이용하여, 검출 시 입력 영상이나 검출기의 회전 없이 단일의 검출로 이들을 분류하는 검출방법을 제안한다.

3. JointBoost를 이용한 기울어진 얼굴 검출

3.1 JointBoost 알고리즘

JointBoost는 다분류, 다각도의 대상에 대한 분류기를 만들기 위해 고안되었다[16]. 여러 대상체를 분류할 때, 각각의 독립된 특징으로 검출기를 만드는 것이 아니라 서로 공통된 특징으로부터 대상체를 분류하는 것이 가장 핵심이 되는 개념이다.

구체적으로, “R”, “b”, “3”을 분류하고자 할 때 그림 1의 (a)처럼 기존의 분류기는 이들의 각각에 대한




그림 1. 독립적인 특징과 공통된 특징에 의한 분류

독립적인 특징으로 분류했다. 즉, 각각 2개씩 가지고 있는 특징으로 분류하기에 총 6개의 특징이 필요하다. 하지만 JointBoost는 그림 1의 (b)처럼 “R, b”에 대한 공통된 특징으로 “3”을 분류하고, “b, 3”의 공통된 특징으로 “R”을 분류하고, “R, 3”의 공통된 특징으로 “b”를 분류한다. 따라서 3개의 특징으로 이들을 분류할 수 있는 것이다.

JointBoost는 AdaBoost의 확장된 연구인 Gentle AdaBoost[17]와 다분류가 가능한 AdaBoost.M.H [15]를 기본 배경으로 하여 연구된 알고리즘이다. 두 알고리즘을 접목시킨 후, 서브셋(subset)이라는 특징들의 공유를 추가한 것이다. 만약 3개의 클래스를 가진 분류 문제의 경우 서브셋은 각각의 클래스 {(1), (2), (3)}와 공유된 클래스 {(1,2), (1,3), (2,3), (1,2,3)}를 가지게 되는 것이다. JointBoost도 약한 분류기들의 선형 결합에 의해 강한 분류기가 생성되며, 이는 식 (1)과 같다.

$$H(v,c) = \sum_{m=1}^M h_m(v,c) \tag{1}$$

$H(v,c)$ 는 입력 데이터 v 와 분류 c 에 대한 강한 분류기를 의미하며, M 은 전체 반복횟수, h_m 은 m 번째 반복에서 선택된 약한 분류기를 의미한다. 즉, 위의 식이 의미하는 것은 입력 데이터 v 가 있을 때 이것이 c 번째 분류에 대한 약한 분류기의 선형 결합에 의해 나타낸다는 것이다. 만약 전체 클래스의 개수 c 가 3 이라면 새로운 입력 데이터 v 에 대하여 $H(v,1)$, $H(v,2)$, $H(v,3)$ 로 검사하여 이들에 대한 응답 값 중에서 가장 큰 값을 가지는 클래스로 분류하는 원리이다.

세부적으로 JointBoost는 강한 분류기를 만들기 위해 각 반복마다 식(1)에서 나타난 약한 분류기(h_m)를 선택해야 된다. 이 때 선택되는 약한 분류기는 가장 작은 오차를 가지는 분류기이다. 오차는 식 (2)의 J_{wse} (weighted squared error)로 구하게 된다.

$$J_{wsc}(n) = \sum_{c=1}^C \sum_{i=1}^N w_i^c (z_i^c - h_m^n(v_i, c))^2 \quad (2)$$

$$\text{where } w_i^c = e^{-z_i^c H(v_i, c)}$$

여기에서 w_i^c 는 i 번째 훈련 데이터의 c 분류에 대한 가중치로서 각각의 훈련 데이터 i 는 C 개의 가중치 (w_i^c)를 갖고 있다. z_i^c 는 i 번째 데이터가 분류 c 에 속하는지를 나타내는 것으로 분류 c 에 속하면 +1의 값을 속하지 않으면 -1의 값을 갖게 된다. 여기서 n 은 서브셋 인덱스로 C 개의 클래스가 존재하는 경우 $n=1, 2, \dots, 2^C - 1$ 이다.

$h_m^n(v_i, c)$ 는 regression stump로 식(3)과 같이 정의된다.

$$h_m^n(v_i, c) = \begin{cases} a_s & \text{if } v_i^f > \theta \text{ and } c \in S(n) \\ b_s & \text{if } v_i^f \leq \theta \text{ and } c \in S(n) \\ k^c & \text{if } c \notin S(n) \end{cases} \quad (3)$$

데이터의 클래스가 선택된 서브셋에 포함될 경우 ($c \in S(n)$), i 번째 데이터의 f -차원(dimension) 데이터 값인 v_i^f 가 θ 보다 크면 a_s 값을 θ 보다 작으면 b_s 의 값을 갖게 된다. 만약 클래스가 선택된 서브셋에 포함되지 않을 경우 ($c \notin S(n)$), k^c 값을 부여하여 클래스 상수로 처리한다. 이 값은 클래스 간에 positive와 negative를 공유하기에 명확하지 않을 경우 특징이 공유되는 것을 예방하는 것이 목적이다. $S(n)$ 은 n 번째 서브셋을 의미한다.

a_s , b_s , k^c 의 값은 각각 식(4), (5), (6)을 통해 구할 수 있다. 식(4)에서 $\delta(v_i^f > \theta)$ 는 v_i^f 데이터 값이 θ 보다 크면 1을 갖고 작으면 0을 갖는다는 의미이다. n 번째 서브셋 $S(n)$ 에 포함된 클래스들에 대하여 θ 보다 큰 값들이 많이 존재한다면 식(4)의 a_s 값은 positive 값을 갖게 되고 식(5)의 b_s 값은 negative 값을 갖게 될 것이며, 그렇지 않다면 반대의 경향을 갖게 되는 것이다. 식(6)은 k^c 값을 나타낸 것으로 v_i 에 대한 θ 의 크기와 상관없이 일정한 값을 갖게 된다.

$$a_s(f, \theta) = \frac{\sum_{c \in S(n)} \sum_i w_i^c z_i^c \delta(v_i^f > \theta)}{\sum_{c \in S(n)} \sum_i w_i^c \delta(v_i^f > \theta)} \quad (4)$$

$$b_s(f, \theta) = \frac{\sum_{c \in S(n)} \sum_i w_i^c z_i^c \delta(v_i^f \leq \theta)}{\sum_{c \in S(n)} \sum_i w_i^c \delta(v_i^f \leq \theta)} \quad (5)$$

$$k^c = \frac{\sum_i w_i^c z_i^c}{\sum_i w_i^c} \quad (6)$$

각 반복마다 서브셋에 대한 결과가 나오면 이들에 대한 에러 값인 J_{wsc} 값이 가장 작은 약한 분류기를 선택하고, 이때 선택된 약한 분류기의 파라미터 값으로 모든 가중치를 업데이트한다. 이 과정을 M 번 반복하면 결과적으로 각 분류에 대한 강한 분류기 $H(v, c)$ 가 생성되는 것이다.

JointBoost의 전체적인 알고리즘은 그림 2와 같다.

- 1) Initialize the weights $w_i^c = 1$ and set $H(v_i, c) = 0$, $i = 1, \dots, N$, $c = 1, \dots, C$.
- 2) Repeat for $m = 1, 2, \dots, M$
 - a) Repeat for $n = 1, 2, \dots, 2^C - 1$
 - i) Fit shared stump:

$$h_m^n(v_i, c) = \begin{cases} a_s & \text{if } v_i^f > \theta \text{ and } c \in S(n) \\ b_s & \text{if } v_i^f \leq \theta \text{ and } c \in S(n) \\ k^c & \text{if } c \notin S(n) \end{cases}$$
 - ii) Evaluate error

$$J_{wsc}(n) = \sum_{c=1}^C \sum_{i=1}^N w_i^c (z_i^c - h_m^n(v_i, c))^2$$
 - b) Find best subset: $n^* = \arg \min_n J_{wsc}(n)$.
 - c) Update the class estimates

$$H(v_i, c) := H(v_i, c) + h_m^{n^*}(v_i, c)$$
 - d) Update the weights

$$w_i^c := w_i^c e^{-z_i^c h_m^{n^*}(v_i, c)}$$

그림 2. JointBoost 알고리즘

우선적으로 N 개의 훈련 데이터 중 i 번째인 v_i 와 각 데이터의 클래스 c_i 를 입력으로 받는다. 그리고 각 훈련 데이터 v_i 에는 전체 클래스 개수인 C 개의 가중치 w_i^c 를 각각 부여받는다. 즉, 하나의 훈련 데이터에는 C 개의 가중치를 부여받아 전체 $N \times C$ 개의 가중치가 존재하는 것이다. 훈련을 시작할 경우 전체 가중치는 1로 초기화한다. 그리고 각 훈련 반복 m 마다 가능한 모든 서브셋 n 에 대하여 모든 약한 분류기에 대한 $h_m(v_i, c)$ 값을 구하여 J_{wsc} 값을 구한다. 이들 중 J_{wsc} 값이 가장 작은 서브셋과 약한 분류기를 선택하여 이들의 파라미터 값으로 강한 분류기를 업데이트 한다. 이때 선택된 약한 분류기로 가중치를 업데이트 하는데, 분류가 잘된 데이터의 가중치는 감소시키고 분류가 잘못된 데이터의 가중치는 증가시켜 다음 훈련 반복에서는 이들의 분류에 집중을 하는 것이

다. 이와 같은 과정이 끝나면 한 번의 훈련 반복이 끝나는 것이다. 이를 총 M 번 반복하면 최종적으로 강한 분류기 $H(v,c)$ 가 생성이 된다.

3.2 얼굴 영상의 클래스 분류

기울어진 얼굴을 검출하기 위해 실제 사진을 촬영할 때 검출 가능한 얼굴의 각도를 구분지어 3개의 클래스로 분류하였다. 주로 많이 유지하는 자세로 -30° 부터 30° 까지의 얼굴 각도가 목격이 되었기에 $-10^\circ \sim 10^\circ$ 를 클래스 1, $10^\circ \sim 30^\circ$ 를 클래스 2, $-30^\circ \sim -10^\circ$ 를 클래스 3으로 분류하였으며 배경은 클래스 4로 분류하였다. 사용된 영상은 32×32 크기의 얼굴 영상을 각도별로 분류하여 사용하였으며, 클래스 4는 배경 영상을 사용하였다. 그림 3은 학습 훈련에 참여한 데이터의 유형을 보여준다.




그림 3. 훈련 참여 영상

3.3 기울어진 얼굴의 특징 집합

Viola와 Jones에 의해 제안된 Haar-like feature는 정면 얼굴 검출에 적합한 특징으로 기울어진 얼굴의 특징을 찾기에는 부족한 부분이 있다. 따라서 기울어진 얼굴의 특징을 잘 표현할 수 있는 특징이 필요하기에 기존의 특징에 새로운 형태의 모형을 추가하였다. 그림 4는 기존의 정면 얼굴을 검출하기 위해 설계된 특징이며, 그림 5는 기울어진 얼굴을 검출하기 위




그림 4. 정면 얼굴 검출을 위한 Haar-like features




그림 5. 기울어진 얼굴 검출을 위한 Haar-like features

해 새롭게 추가된 특징이다. 이들 각각의 높이와 폭에 변화를 주어 다양한 형태의 크기로 서브 윈도우에서 위치를 변화하며 특징 집합을 구성하였다.

총 14가지 유형의 특징에 대하여 서브 윈도우 안에서 크기를 변화시키며 특징을 얻기에는 그 경우의 수가 방대하여 위치에 제한을 두어 특징 집합의 크기를 줄였다. 그림 4의 a와 b는 눈과 코, c와 d는 눈과 입, e는 입, f는 코의 위치로 제한하였다. 그리고 그림 5의 a, b, c, d는 눈과 코, e와 f는 눈, g와 h는 입의 위치에서 검출하도록 제한하여 전체 2,215개의 특징 집합을 구성하였다.

3.4 약한 분류기(weak classifier)

AdaBoost를 사용하여 약한 분류기를 학습할 경우 θ 를 기준으로 분류하였다. 여기에서 θ 는 얼굴의 Haar-like feature 특징값의 평균과 비얼굴의 Haar-like feature 특징값의 평균을 $1/2$ 로 하는 값을 사용하였다. 이는 2개 클래스의 평균을 사용하였기에 적어도 50%의 검출 성능을 낼 수 있다. 하지만 본 논문에서는 총 4개의 클래스에 대한 분류를 해야 하기 때문에 이에 대한 변형이 필요하다. 본 논문에서 접근한 방법은 각 클래스의 표준편차 값을 이용하는 것이다.

표준편차 값을 이용하는 방법은 표준편차를 이용하여 θ 의 범위를 만들어 약한 분류기로 사용하는 것이다. 데이터가 가우시안 분포를 따른다고 가정하였을 경우 평균(μ)에서 표준편차(σ)의 범위($\mu - \sigma, \mu + \sigma$) 안에 약 68% 정도의 데이터가 분포하고 있다. 이와 같은 가정하에 클래스 1의 약한 분류기를 클래스 1의 평균 μ_1 과 표준편차 σ_1 을 통해($\mu_1 - \sigma_1, \mu_1 + \sigma_1$)으로 설정한다. 이와 같은 방법으로 클래스 2와 클래스 3의 분류기를 설정한다. 만약 클래스 1과 클래스 2의 분포가 유사할 경우 이들은 공유할 수 있는 특징을 갖게 되어 서브셋 (1,2)로 분류되는 것이다. 표준편차 값을 이용하는 방법은 범위를 생성해야 하므로 전체 2,215개의 특징 집합에 대하여 6,645개의 약한

분류기가 생성이 되며 각각의 약분류기는 $(\theta_{\min}, \theta_{\max})$ 두 가지 값을 지니게 된다. 따라서 JointBoost의 약한 분류기는 그림 6과 같이 표현되며, 식 (7)로 표현된다.




그림 6. 표준편차를 이용한 약한 분류기

$$h_m^n = \begin{cases} a_s & \text{if } \theta_{\min} < v_i^f \text{ and } v_i^f < \theta_{\max} \text{ and } c \in S(n) \\ b_s & \text{if } v_i^f < \theta_{\min} \text{ and } \theta_{\max} < v_i^f \text{ and } c \in S(n) \\ k^c & \text{if } c \notin S(n) \end{cases} \quad (7)$$

3.5 강한 분류기(Strong classifier)

매 훈련 반복마다 선택된 약한 분류기의 선형 결합으로 강한 분류기가 생성된다. 새로운 입력 영상에서 얼굴을 검출하고자 하는 경우 32×32 크기의 서브 윈도우(sub-window)가 이동하며 이 강한 분류기를 통해 얼굴을 검출하게 된다. 강한 분류기의 파라미터 값으로는 강한분류기를 구성하는 m 번째 반복에 의한 약한 분류기의 θ, a, b, k 그리고 선택된 서브셋 종류를 지니고 있으며, 서브윈도우 안에서 약한 분류기들의 응답값을 반복 수 만큼 누적하여 클래스 1, 2, 3에 대한 강한 분류기 값이 생성된다. 따라서 이들에 대한 임계치(threshold)를 설정하여 이 값보다 작은 것들은 클래스 4로 분류하고, 이 값보다 큰 값들 중에서 가장 큰 값을 검출 결과로 나타낸다. 즉, 비얼굴인 클래스 4는 따로 검출하지 않고, 각 클래스에 대한 강한 분류기 응답값에서 임계치보다 작은 값은 클래스 4로 분류한다.

4. 실험 및 결과

먼저 기존의 AdaBoost를 이용한 정면 얼굴 검출 방법을 구현하고 이에 대한 성능 검증 후, 본 논문에서 제안한 방법의 결과를 검증하고 이를 AdaBoost 방법과 비교해보았다.

4.1 AdaBoost를 이용한 얼굴 검출

기존의 Viola와 Jones가 제안한 AdaBoost를 이용한 얼굴 검출 방법을 사용하여 정면 얼굴에 대한 검출 성능을 평가하였다. 훈련에 사용한 Haar-like feature는 그림 4의 6가지 유형을 사용하였으며 약한 분류기는 얼굴 영상과 비얼굴 영상의 Haar-like feature값에서 평균을 구하고, 구한 평균의 중간 값을 사용하였다. 훈련에 참여한 데이터는 32×32 크기의 얼굴과 비얼굴 영상을 사용하였으며, 얼굴은 700장, 비얼굴은 1200장의 영상을 사용하였다. 전체 훈련 반복수는 150번을 수행하였다.

그림 7은 학습에 참여한 데이터와 참여하지 않은 데이터에 대한 검출 성능을 나타낸 그래프로 파란색 선은 검출률을 나타내며, 붉은색 선은 오검출률을 나타낸다. 그리고 실선은 학습에 참여한 데이터에 대한 결과이며 점선은 학습에 참여하지 않은 데이터에 대한 결과이다.

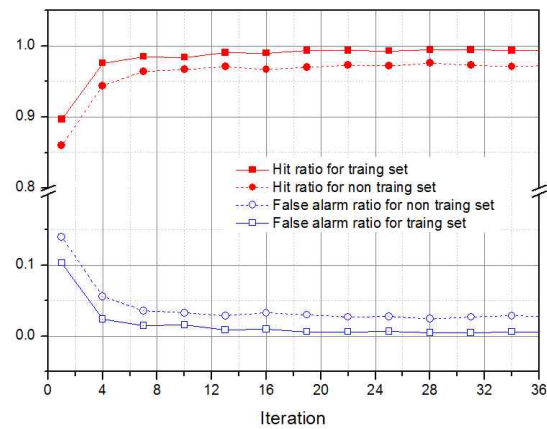


그림 7. AdaBoost의 검출률

4.2 JointBoost를 이용한 얼굴검출

훈련에 사용된 Haar-like feature는 그림 4와 그림 5의 14가지 유형을 사용하였으며, 표준편차를 이용한 약한 분류기를 사용하였다. 학습 데이터는 32×32 크기의 영상으로 자체 제작하여 정면 얼굴과 각도별로 기울어진 얼굴을 사용하였다. 그림 8은 훈련에 참여한 데이터의 일부를 보여준다. 클래스 1, 2, 3는 각각 200장씩 훈련에 참여시켰고, 클래스 4는 400장으로 총 1000장의 영상을 훈련에 참여시켰다. 최종 훈련 반복수는 150번으로 제한하였다. 그림 9는 그림



그림 8. 기술어진 얼굴 검출을 위한 훈련 영상




그림 9. 얼굴 검출 결과




그림 10. JointBoost의 검출률

8에 대한 검출결과이다.

JointBoost를 이용한 기법의 얼굴 검출 성능을 분석하기 위해 훈련에 참여한 데이터 1000개와 참여하지 않은 데이터 1000개를 사용하여 그 검출률을 평가하였는데 이에 대한 결과는 그림 10과 같다. 훈련에 참여한 데이터의 경우 검출률은 100% 정도로 나왔다. 훈련에 참여하지 않은 데이터에 대해서는 96.4%의 검출률을 보였으며, 오검출률은 3.6% 정도로 나

왔다. 오검출률은 4개의 클래스 간에 서로 잘못된 분류를 한 경우를 의미한다.

4.3 AdaBoost와의 비교

본 논문에서 제안된 방법과 AdaBoost를 이용한 얼굴 검출 방법의 비교를 위해 동일한 조건하에서 훈련을 하고 성능을 평가하였다. 이를 위해 JointBoost와 AdaBoost의 입력 영상은 동일한 학습 데이터를 사용하였고, 얼굴 검출에 사용된 Haar-like feature는 14가지 유형의 2,215개의 특징 집합을 사용하였으며 훈련 반복수는 150번으로 동일하게 하였다. 이를 통해 각 방법이 얼굴 검출 시 사용하는 약분류기의 수를 동일하게 하여 얼굴 검출 시 속도가 대등하도록 하였다. 표 1은 각각의 시스템에서 검출 성능에 대한 실험 결과를 보여준다.

표 1에서 JointBoost는 본 논문에서 제안된 방법으로 구현한 시스템을 의미하며, AdaBoost I은 정면 얼굴 영상과 비얼굴 영상을 훈련 입력으로 받은 AdaBoost 시스템을 의미한다. AdaBoost II는 클래스 1(정면 얼굴), 2(오른쪽으로 회전된 얼굴), 3(왼쪽으로 회전된 얼굴)를 얼굴 영상으로 통합하여 받고 이를 비얼굴과 분류하는 AdaBoost 시스템을 의미한다. 그리고 TR은 훈련 반복수가 150회로 제한되었을 때 훈련에 참여한 영상에 대한 검출률을 의미하며, NTR은 훈련에 참여하지 않은 영상에 대한 검출률을 의미한다. AdaBoost I의 경우 NTR I는 훈련에 참여하지 않은 정면 얼굴 테스트 영상에 대한 검출률을 의미하며, NTR II는 훈련에 참여하지 않은 정면 얼굴을 포함한 회전된 얼굴 테스트 영상에 대한 검출률을 의미한다.

JointBoost를 사용하였을 경우, 본 논문에서 제안된 방법은 훈련에 참여한 영상과 참여하지 않은 영상에 대해 각각 100%, 96.4%의 검출률을 나타냈으며, AdaBoost I의 경우에는 훈련에 참여한 영상과 참여하지 않은 영상에 대해 각각 100%, 96.3%의 검출률을 나타내 두 경우가 비슷한 성능을 보였다. 하지만

표 1. 각 방법의 검출률

	JointBoost		AdaBoost I			AdaBoost II	
	TR	NTR	TR	NTR I	NTR II	TR	NTR
검출률	100%	96.4%	100%	96.3%	73.3%	94.5%	92.2%

AdaBoost I은 정면 얼굴만을 검출할 때 이러한 검출률을 보인 것이며, 본 논문의 시스템은 정면 얼굴과 기울어진 얼굴을 검출할 때 보인 검출률인 것이다. 그리고 AdaBoost I을 이용하여 정면 얼굴과 기울어진 얼굴에 대해 실험해 본 결과 73.3%의 낮은 검출률을 보였다. AdaBoost II는 정면 얼굴과 기울어진 얼굴을 입력으로 받아 성능을 실험해 본 결과 92.2%의 검출률을 나타내었다. 실험 결과를 통해 제안된 시스템이 동일한 반복수에서 검출률에서 우수할 뿐 아니라, 기울어진 방향에 대한 정보도 제공할 수 있다는 장점이 있음을 알 수 있다.

5. 결론 및 향후 연구 과제


본 논문에서는 정면 얼굴과 기울어진 얼굴들의 공유할 수 있는 특징을 이용하는 JointBoost 알고리즘에 기반한 얼굴 검출 방법을 제안하였다. 정면 얼굴, 위로 회전된 얼굴, 좌로 회전된 얼굴, 비얼굴 4개의 클래스를 설정하고 각 클래스의 표준편차를 이용하는 약한 분류기를 적용하였다. 제안된 방법은 동일한 개수의 약분류기를 사용하여 검출 속도의 수준이 유사하게 맞추어진 경우 기존 AdaBoost 기법에 비해 약 2% 우수한 검출률을 보인다. 또한 제안된 방법은 얼굴의 존재를 검출할 뿐만 아니라 기울어진 방향에 대한 정보도 추가로 제공할 수 있다. 만약 기울어진 얼굴 검출을 위해 입력 영상의 정면뿐만 아니라 왼쪽과 오른쪽으로 기울여서 기존 AdaBoost 기법을 적용하는 경우에 비해 제안 기법은 약 3배 빠른 얼굴 검출이 가능하다. 하지만 제안된 방법에 걸린 훈련 시간은 기존 AdaBoost를 이용한 훈련 방법보다 수 배 이상의 시간이 요구 되었다. 이는 학습 알고리즘의 계산 복잡도와 기울어진 얼굴의 고차원 특징으로 인해 나타나는 현상으로 이러한 계산 복잡도를 감소시키기 위한 효과적 훈련 방안에 대한 향후 연구가 필요하다.

참 고 문 헌

- [1] 문기영, "생체인식 기술현황 및 전망," TTA 저널, 통권 제98호, pp. 38-47, 2005.
- [2] G. Yang and T.S. Huang, "Human Face Detection in a Complex Background," *Pattern Recognition*, Vol.27, No.1, pp. 53-63, 1994.
- [3] K.C. Yow and R. Cipolla, "Feature-Based Human Face Detection," *Image and Vision Computing*, Vol.15, No.9, pp. 713-735, 1997.
- [4] 백영현, "피부색 모델 기반의 효과적인 얼굴 검출 연구," 전자공학회논문지, 제45권 SP편, 제6호, pp. 38-43, 2008.
- [5] 이철한, 정민이, 김종선, 최정윤, 김재희, "통계적 형상 기반의 얼굴인식을 위한 가변얼굴템플릿 생성방법," 전자공학회논문지, 제44권 SP편, 제2호, pp. 27-35, 2007.
- [6] A. Lanitis, C.J. Taylor, and T.F. Cootes, "Automatic Interpretation and Coding of Face Images using Flexible Models," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.19, pp. 743-756, 1997.
- [7] C. Garcia and M. Delakis, "A Neural Architecture for Fast and Robust Face Detection," *International Conference on Pattern Recognition*, pp. 44-47, 2002.
- [8] H. Rowley, S. Baluja, and T. Kanade, "Rotation Invariant Neural Network-Based Face Detection," *IEEE Conf. Computer Vision and Pattern Recognition*, pp.38-44, 1998.
- [9] B. Heisele, T. Serre, S. Prentice, and T. Poggio, "Hierarchical Classification and Feature Reduction for Fast Face Detection with Support Vector Machines," *Pattern Recognition*, Vol.36, No.9, pp. 2007-2017, 2003.
- [10] 박승환, 광조준, "SVM과 PCA를 이용한 국부 외형 기반 얼굴 인식 방법," 전자공학회논문지, 제47권 SP편, 제3호, pp. 54-60, 2010년 5월.
- [11] P. Viola and M. Jones, "Robust Real-Time Face Detection," *Proc. IEEE International Conference on Computer Vision 2001*, Vol.20, pp.1254-1259, 2001.
- [12] 이우주, 김진철, 이배호, "AdaBoost 알고리즘을 이용한 실시간 얼굴 검출 및 추적," 멀티미디어학회논문지, Vol.9, No.10, pp. 1266-1275, 2006.
- [13] C. Liu, "A Bayesian Discriminating Features Method for Face Detection," *IEEE Trans. Pattern Analysis and Machine Intelligence*,

Vol.25, No.6, pp. 725-740, 2003.

- [14] R. Lienhart and J. Maydt, "An Extended Set of Haar-like Features for Rapid Object Detection," *IEEE Conference Image Processing*, Vol.1, pp. I-900, 2002.
- [15] R. Schapire and Y. Singer, "BoosTexter: A Boosting-Based System for Text Categorization," *Machine Learning*, Vol.39, No.2, pp. 135-168, 2000.
- [16] A. Torralba, K.P. Murphy, and W. T. Freeman, "Sharing Visual Features for Multiclass and Multiview Object Detection," *IEEE Trans. Pattern Analysis and Machine Intelligence*. Vol.29, No.5, pp. 854-869, 2007.
- [17] J. Friedman, T. Hastie, and R. Tibshirani, "Additive Logistic Regression: A Statistical View of Boosting," *Annals of statistics*, Vol.28, No.2, pp. 337-374, 2000.



정 은 호

2003년 3월 ~ 2010년 2월 충남대학교 메카트로닉스 공학과 공학사
 2010년 3월 ~ 2012년 2월 충남대학교 지능로봇시스템 공학석사

관심분야 : 영상/비디오 신호처리, 영상인식 및 패턴인식



송 영 모

2000년 3월 ~ 2007년 2월 충남대학교 메카트로닉스 공학과 공학사
 2007년 3월 ~ 2009년 8월 충남대학교 지능로봇시스템 공학석사

2009년 ~ 현재 LG전자 MC사업본부 주임연구원
관심분야 : 영상/비디오 신호처리, 영상인식 및 패턴인식



고 윤 호

1991년 3월 ~ 1995년 2월 부산대학교 전자공학과 학사
 1995년 3월 ~ 1997년 2월 한국과학기술원 전기 및 전자공학과 석사
 1997년 2월 ~ 2002년 8월 한국과학기술원 전기 및 전자공학과 박사

2004년 10월 ~ 현재 충남대학교 메카트로닉스공학과 부교수

관심분야 : 영상처리, 컴퓨터비전, 로봇비전, 영상인식, 영상압축