미러영상 특징을 이용한 Joint Bayesian 개선 방법론

한성휴*, 안정호**

요 약

Joint Bayesian 방법론[1]은 2012년 발표된 이후 최근까지 최고 성능을 보이는 거의 모든 얼굴인식 알고리즘에서 이진 분류를 위해 사용되고 있지만, 지금까지 이를 개선한 알고리즘은 2D-JB[2] 외에 거의 발표되지 않았다. 우리는 본 논문에서 주어진 얼굴 영상과 이를 좌우 반전시킨 미러 영상을 함께 고려함으로써 Joint Bayesian 방법론의 성능을 향상시킬 수 있는 방법론을 제안한다. 일반적인 패턴인식에서결정함수 값이 결정경계 또는 임계치에 가까운 경우 오류가 발생할 확률이 높다. 제안한 방법론은 미러영상의 특징을 이용하여 결정함수 값을 결정경계로부터 덜어지게 함으로써 오류를 줄이는 방법이다.

우리는 LFW DB를 이용한 실험을 통해 제안한 JB 개선 방법론이 기존 JB 방법론보다 1%이상 높은 인식률을 보임을 입증하였다. LFW DB를 이용한 기존 연구들에서 성능을 1% 높이기 위해 많은 학습데 이터가 필요했음을 감안할 때, 제안한 방법론은 큰 의미가 있다고 볼 수 있다.

키워드: 얼굴인식, JB 방법론, 2차원 JB 방법론, 미러영상, LFW 데이터베이스

An Improved Joint Bayesian Method using Mirror Image's Features

Sunghyu Han*, Jung-Ho Ahn**

Abstract

The Joint Bayesian[1] method was published in 2012. Since then, it has been used for binary classification in almost all state-of-the-art face recognition methods. However, no improved methods have been published so far except 2D-JB[2]. In this paper we propose an improved version of the JB method that considers the features of both the given face image and its mirror image. In pattern classification, it is very likely to make a mistake when the value of the decision function is close to the decision boundary or the threshold. By making the value of the decision function far from the decision boundary, the proposed method reduces the errors.

The experimental results show that the proposed method outperforms the JB and 2D-JB methods by more than 1% in the challenging LFW DB. Many state-of-the-art methods required tons of training data to improve 1% in the LFW DB, but the proposed method can make it in an easy way.

Keywords: Face recognition, Joint Bayesian method, 2D-JB method, mirror image, LFW DB

1. 서론

Corresponding Author: Jung-Ho Ahn

Received: June 22, 2015
Revised: August 29, 2015
Accepted: October 10, 2015

Tel: +82-31-280-3661, Fax: +82-31-280-3979

email: jungho@kangnam.ac.kr

* School of Liberal Arts, Korea University of Technology and Education.

** Division of Computer Media Information Engineering, Kangnam University.

■ 이 논문은 2015년도 한국기술교육대학교 연구제

최근 얼굴인식 분야는 LFW DB[3] 발표이후 연구 방향이 다소 선회하였다. 전통적인 얼굴인 식문제는 여러 사람의 영상들을 학습하고, 테스트 시 주어진 얼굴 영상이 학습된 사람들 중 어느 사람의 얼굴인지 또는 학습된 사람의 얼굴이 아닌지를 판단하는 것이었다. 이와 달리, 2007년 출시된 LFW 얼굴 DB는 두 장의 얼굴 영상이

파견연구비 지원에 의하여 연구되었음

주어지고 이 두 영상의 얼굴이 같은 사람의 것인지 다른 사람의 것인지를 판단하는 실험 규약을 채택하고 있다. 최근 제안된 얼굴인식 알고리 즘들은 이 규약을 따라 LFW DB의 실험결과를 제시하고 있다[1, 2, 4, 5, 6, 7, 8, 9].

LFW 실험 규약은 최근 얼굴인식 응용분야의 추세를 따른다고 볼 수 있다. 특히, 최근 얼굴인식이 응용되는 사례에서는 많은 데이터를 학습하기 어려운 경우가 많다. 스마트폰에서 얼굴인식을 할 경우 일반 사용자가 학습데이터와 레이블을 할당해야 하는데, 이 때 한 사람당 여러 장의 사진을 할당하는 것을 기대하기 어렵다. 한클래스 당 많은 학습데이터를 사용하여 개발되었던 전통적인 얼굴인식 알고리즘들은 이런 어플리케이션에서 높은 성능을 보이기 어렵다. LFW의 실험 규약에 따라 개발된 알고리즘은 이러한 상황에 적용 가능하다.

최근 얼굴인식 방법론들은 대부분 다음과 같은 구조로 되어 있다. 주어진 얼굴영상에서 얼굴특징점(facial landmark)들을 찾아내어 배열 (alignment)한 후, 상당히 높은 차원의 특징벡터를 추출한다. 그리고 이를 PCA(Principal Component Analysis)를 이용하여 저차원 특징벡터로 차원을 축소한다. 주어진 두 영상에서 추출된 두 저차원 특징벡터를 이용하여 두 영상의 얼굴이 같은 사람의 것인지 여부를 판단하는 이진 분류를 수행한다.

최고 성능을 보이는 대부분의 방법론들은 이 진 분류를 위해 Joint Bayesian(JB) 방법론[1]을 사용한다. JB는 두 특징벡터가 같은 클래스에 속하는 지 여부를 판단하는 알고리즘으로 2012년에 발표되었지만 이를 개선한 알고리즘이나이보다 더 좋은 성능을 보이는 알고리즘에 대한연구 발표는 미비하다. 2015년에 발표된 2차원 JB 방법론(2D-JB)[2]은 JB 방법론의 유사도 식을일반화한 것으로 기존 JB 방법론을 개선한유일한 알고리즘이다. 2D-JB는 JB 유사도 식의세 항을 두 부분으로 나누어 2차원 특징벡터를추출한후,에러를 최소화할수 있도록 파라미터를한번더 학습하였다.

우리는 본 논문에서 JB 방법론과 2D-JB 방법 론을 개선한 효과적인 방법론을 제안한다. 이는 주어진 두 영상과 더불어 두 영상을 좌우 반전 (horizontally flipped)시킨 미러 영상도 함께 사 용하여 두 영상이 같은 클래스에 속하는지 여부 를 이중으로 판단하는 방법이다.

우리는 2장에서 기존의 JB 방법론과 2D-JB 방법론을 설명하고, 3장에서 이 두 방법을 개선 시킬 수 있는 방법을 제안한다. 4장에서 실험결 과를 제시하고 5장에서 토의를 통해 결론을 맺 는다.

2. Joint Bayesian 방법론

본 장에서는 난해한 JB 방법론[1]과 이를 확장한 2차원 JB 방법론[2]을 이해하기 쉽게 재구성하여 기술한다.

2.1 Joint Bayesian 방법론

JB 방법론은 임의의 한 얼굴 영상으로부터 추출한 특징 벡터를 확률변수 x라 할 때, 다음과 같은 관계가 있다는 가정에서 출발한다.

$$x = \mu + \epsilon \tag{1}$$

이 때, μ 는 x가 표현하는 인물의 얼굴 영상들의 평균 특징 벡터이고, ϵ 은 변위 또는 에러를 나타내는 확률변수(즉, 조명, 자세, 표정과 같은 것들에 따라 발생하는 영상 변형)이다.

우리는 x의 평균은 0으로 가정할 수 있다. 이 가정은 x에서 x의 평균값을 빼서 다시 x에 대입하면 가능하다. JB 방법론은 추가적으로 μ 와 ϵ 가 서로 독립이고, 다음과 같은 확률분포를 따른다고 가정한다.

$$\mu \sim N(0, S_{\mu}), \ \epsilon \sim N(0, S_{\epsilon}),$$
 (2)

여기서 N은 다변량 정규분포를 의미하고, S_{μ} 와 S_{ϵ} 은 미지의 공분산 행렬들이다. 이 가정들로 부터 특징벡터 x는 다음의 정규분포를 따른다.

$$x \sim N(0, S_{\mu} + S_{\epsilon}) . \tag{3}$$

이 때, 두 확률변수 $\{x_1, x_2\}$ 의 결합 확률분포 (Joint distribution)는 다음과 같다.

$$(x_1, x_2) \sim N(0, \Sigma)$$
 (4)

공분산 행렬 Σ 는 x_1 , x_2 가 같은 사람인가(가정 H_I) 다른 사람인가(가정 H_E)에 따라 다르게 주어진다. 다음 식(5)는 이 두 가정 하에서 Σ 식을 유도하기 위해 필요하다.

$$cov(x_i, x_j) = cov(\mu_i, \mu_j) + cov(\epsilon_i, \epsilon_j)$$
 (5)

이 식(5)는 식(3)과 μ 와 ϵ 이 서로 독립이라는 가정으로부터 $i,\ j$ \in $\{1,2\}$ 인 모든 $i,\ j$ 에 대하여성립한다.

 H_I 라는 가정에서는 $\mu_1=\mu_2$ 이고 ϵ_1 과 ϵ_2 는 서로 독립이기 때문에 두 특징벡터 $x_1,\ x_2$ 가 발생할 확률 $P(x_1,x_2|H_I)$ 의 공분산 행렬 Σ 은 다음과 같다.

$$\Sigma_{I} = \begin{pmatrix} S_{\mu} + S_{\epsilon} & S_{\mu} \\ S_{\mu} & S_{\mu} + S_{\epsilon} \end{pmatrix}. \tag{6}$$

 H_E 라는 가정에서는 μ_1 과 μ_2 는 서로 독립이고, ϵ_1 과 ϵ_2 도 서로 독립이다. 따라서 $P(x_1,x_2|H_E)$ 의 공분산 해렬 Σ 은 다음과 같다.

$$\Sigma_E = \begin{pmatrix} S_{\mu} + S_{\epsilon} & 0\\ 0 & S_{\mu} + S_{\epsilon} \end{pmatrix}. \tag{7}$$

이제 JB 방법의 결정함수인 x_1 과 x_2 의 유사도 $r(x_1, x_2)$ 를 다음과 같이 정의한다.

$$r(x_1, x_2) = \log \frac{P(x_1, x_2 | H_I)}{P(x_1, x_2 | H_E)}.$$
 (8)

다변량 정규분포의 정의를 이용하면 다음과 같 은 확률함수식을 얻을 수 있다.

$$P(x_1, x_2 | H_i) = \frac{1}{(2\pi)^{n/2} \sqrt{|\Sigma_i|}} e^{-\frac{1}{2} (x_1^T x_2^T) \Sigma_i^{-1} \binom{x_1}{x_2}} (9)$$

여기서 첨자 i는 I 또는 E이다. 식(7)로부터 Σ_E 의 역행렬은 다음과 같다.

$$\Sigma_{E}^{-1} = \begin{pmatrix} (S_{\mu} + S_{\epsilon})^{-1} & 0\\ 0 & (S_{\mu} + S_{\epsilon})^{-1} \end{pmatrix}. \quad (10)$$

또한, 식(6)의 Σ_I 역행렬에 대해서는 다음을 만족하는 행렬 F, G가 존재한다.

$$\sum_{I}^{-1} = \begin{pmatrix} F + G & G \\ G & F + G \end{pmatrix}. \tag{11}$$

 $A = \left(S_{\mu} + S_{\epsilon}\right)^{-1} - \left(F + G\right) \text{ 라 하면, } 4(9), (10),$ (11)로부터 유사도 4(8)은 다음과 같다.

$$r(x_1, x_2) = \frac{1}{2} \begin{pmatrix} x_1^T & x_2^T \end{pmatrix} \begin{pmatrix} A & -G \\ -G & A \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} + \frac{1}{2} \log \left(\frac{|\Sigma_E|}{|\Sigma_I|} \right). \tag{12}$$

여기서 G가 대칭행렬이기 때문에 식(12)의 첫 번째 항은 $1/2(x_1^TAx_1+x_2^TAx_2-2x_1^TGx_2)$ 과 같다. 첫 번째 항의 계수 1/2과 두 번째 항은 모든 x_1 , x_2 에 대하여 동일하므로, 이를 생략하면, 최종적으로 다음과 같은 JB 유사도 식을 얻을 수 있다.

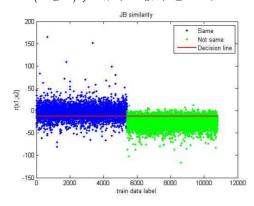
$$r(x_1, x_2) = x_1^T A x_1 + x_2^T A x_2 - 2 x_1^T G x_2.$$
 (13)

이 유사도 값에 따라 분류하기 위해, 학습 데이터의 유사도 값 분포로 부터 학습데이터의 에러가 최소화되는 임계값 T를 구한다. 테스트 시에는 주어진 두 영상의 특징 x_1, x_2 에 대하여 다음 식 (14)를 만족하면 같은 사람으로 결정하고, 그렇지 않으면 다른 사람으로 결정한다.

$$r(x_1, x_2) \ge T \tag{14}$$

본 논문에서는 이 방법론을 1차원 Joint Bayesian(1D-JB) 방법론이라 부르기로 한다.

(그림 1) JB 유사도 값의 분포 예



(Figure 1) An example of JB similarity values

(그림 1)은 유사도 $r(x_1, x_2)$ 값 분포의 예를 보여준다. 파란색 점은 5400개의 같은 인물의 영상 쌍(pair)의 유사도 값이고, 녹색점은 5400개의다른 인물의 영상 쌍의 유사도 값이다. 이 학습데이터에 대해 에러를 최소화하는 임계값은 빨간색 실선으로 표시하였다. 그림에서 임계값은 -12.2830이고 이때의 인식률은 82.44%이다.

2.2. 2차원 Joint Bayesian 방법

본 절에서는 앞 절의 JB 모델을 발전시킨 2차 원 IB(2D-IB) 모델[2]에 대하여 설명한다.

2.1절 1D-JB의 임계치를 결정하는 과정은 1차 원 파라미터의 학습과정(learning process)으로 생각할 수 있다. 즉, 결정 함수 $r_{1D}(x_1,x_2)$ 을 다음과 같이 정의한다.

$$r_{1D}(x_1, x_2) = \theta_0 + r(x_1, x_2)$$
 (15)

그리고, 학습데이터를 이용하여 $r_{1D}(x_1,x_2)$ 가 양수이면 같은 사람, 음수이면 다른 사람으로 결정하도록 θ_0 값을 학습한다. 이 때, θ_0 는 위에서 언급한 임계값 T의 마이너스 값이 된다. 즉,

$$\theta_0 = -T. \tag{16}$$

이것은 매우 단순한 학습과정이다. 2D-JB 모델은 이를 2차원 학습과정으로 발전시킨 것이다. 먼저 다음 확률변수를 정의한다.

$$X_1(x_1, x_2) = x_1^T A x_1 + x_2^T A x_2, \tag{17}$$

$$X_2(x_1, x_2) = -2x_1^T G x_2. (18)$$

위의 값 X_1 과 X_2 는 식 (13)에 있는 $r(x_1, x_2)$ 의 세 항을 두 부분으로 나눈 것이다. 그리고 결정함수 $r_{2D}(x_1, x_2)$ 를 다음과 같이 정의한다.

$$r_{2D}(x_1, x_2) = \theta_0 + \theta_1 X_1(x_1, x_2) + \theta_2 X_2(x_1, x_2)$$
 (19)

그리고, 학습 데이터의 쌍 x_1 , x_2 이 같은 사람인 경우 $r_{2D}(x_1,x_2)\geq 0$, 다른 사람인 경우 $r_{2D}(x_1,x_2)<0$ 이 되도록 $\theta=(\theta_0,\theta_1,\theta_2)$ 값을 학습한다. 로지스틱 회귀분석(logistic regression; LR)[10]이나 서포트 벡터머신(support vector machine; SVM)[11]을 이용하면 이 파라미터 θ 를 학습할 수 있다.

본 논문에 적용한 LR의 학습방법은 다음과 같다. 먼저 다음과 같은 가설(hypothesis)을 정의 한다.

$$h_{\theta}(x) = g(\theta^T x) = P(y = 1 | x; \theta)$$
 (20)

위의 식에서 $\theta = (\theta_0, \theta_1, \theta_2), x = (1, X_1, X_2)$ 이고 q(z)는 다음과 같은 시그모이드 함수이다.

$$g(z) = \frac{1}{1 + e^{-z}} \tag{21}$$

우리는 다음과 같은 비용함수(cost function) $J(\theta)$ 에 대해 기울기 하강(gradient descent) 방법을 적용하여 θ 를 결정한다.

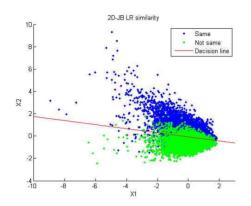
$$J(\theta) = \frac{1}{m} \sum_{i=1}^{m} C(h_{\theta}(x^{(i)}), y^{(i)})$$
 (22)

여기서 $y^{(i)}$ 는 i 번째 학습 데이터 쌍의 레이블로서 같은 사람이면 1, 다른 사람이면 0의 값을 갖는다. 그리고 개별 비용함수 C는 다음과 같이 정의한다.

$$C(h_{\theta}(x), y) = \begin{cases} -\log(h_{\theta}(x)) & \text{if } y = 1\\ -\log(1 - h_{\theta}(x)) & \text{if } y = 0 \end{cases}$$
(23)

이와 같은 방법으로 θ 가 결정되면, 테스트 시 $\theta^T x \geq 0$ 이면 같은 사람, 그렇지 않으면 다른 사람이라고 결정한다.

(그림 2) LR을 이용한 2D-JB 결정경계



(Figure 2) 2D-JB decision boundary via LR

(그림 2)는 로지스틱 회귀분석을 이용한 2D-JB의 결정경계의 예를 보여준다. 파란색 점은 5400개의 같은 사람 쌍의 (X_1,X_2) 이고, 녹색점은 5400개의 다른 사람 쌍의 (X_1,X_2) 이다. 빨간색 직선은 로지스틱 회귀분석을 이용한 결정경계(decision line)이다. 이 직선의 방정식은 $\theta^Tx=0$ 에서 $\theta^T=(0.1832,\ 0.4860,\ 2.6556)$ 이고, 이 학습데이터에 대한 인식률은 84.12%이다.

3. 미러영상의 특징을 이용한 Joint Bayesian 방법론

이 장에서는 미러영상의 특징을 이용하여 JB 방법론의 성능을 개선하는 방법론을 제안한다. 1D-JB 또는 2D-JB 방법론은, 두 개의 얼굴 영상 x_1, x_2 에 대하여 유사도 $r(x_1, x_2)$ 을 계산하고이 값이 임계치 T보다 크거나 같으면 같은 사람으로, 작으면 다른 사람으로 결정하였다.

제안하는 방법론은 $r(x_1,x_2)$ 뿐만 아니라, $r(\overline{x_1},\overline{x_2})$ 도 함께 고려하여 판단한다. 여기서 $\overline{x_1}$ 와 $\overline{x_2}$ 은 각각 주어진 두 영상 x_1 과 x_2 를 좌우 반전시킨 미러영상이다. $r(x_1,x_2)$ 과 $r(\overline{x_1},\overline{x_2})$ 의

값에 대하여 다음의 네 가지 경우가 발생한다.

(i)
$$r(x_1, x_2) \ge T$$
, $r(\overline{x_1}, \overline{x_2}) \ge T$

(ii)
$$r(x_1, x_2) < T$$
, $r(\overline{x_1}, \overline{x_2}) < T$

(iii)
$$r(x_1, x_2) \ge T$$
, $r(\overline{x_1}, \overline{x_2}) < T$

(iv)
$$r(x_1, x_2) < T, \ r(\overline{x_1}, \overline{x_2}) \ge T$$

(i)과 (ii)의 경우는 $r(x_1,x_2)$ 에 의한 판단과 $r(\overline{x_1},\overline{x_2})$ 에 의한 판단이 일치하기 때문에 자명하지만, (iii)과 (iv)는 $r(x_1,x_2)$ 와 $r(\overline{x_1},\overline{x_2})$ 의 판단이 다르기 때문에 주어진 값만으로 판단할수 없다. 이 경우, 임계값(경계)으로부터 얼마나 멀리 떨어져 있는가에 의해 판단한다. 즉, (iii)의 경우, 두 유사도 값으로 부터 경계 T까지 거리를 계산한다. 이 경우에 다음과 같이 두 가지 경우를 생각할 수 있다.

(iii-1)
$$r(x_1, x_2) - T \ge T - r(\overline{x_1}, \overline{x_2})$$

(iii-2)
$$r(x_1,x_2) - T < T - r(\overline{x_1},\overline{x_2})$$

(iii-1)의 경우 $r(x_1,x_2)$ 의 판단을 따라 같은 사람으로 판단하고, (iii-2)의 경우 $r(\overline{x_1},\overline{x_2})$ 의 판단을 따라 다른 사람으로 판단한다.

(iv)의 경우도 유사하다. 즉, 다음과 같은 두 가지 경우가 발생할 수 있는데, (iv-1)의 경우에 는 같은 사람으로 판단하고, (iv-2)의 경우에는 다른 사람으로 판단한다.

$$(\mathrm{iv}\text{-}1) \ r(\overline{x_1},\overline{x_2}) - T \ \geq T - r(x_1,x_2)$$

(iv-2)
$$r(\overline{x_1}, \overline{x_2}) - T < T - r(x_1, x_2)$$

(그림 3) 미러영상 특징을 이용한 1D-JB 개선 방법론



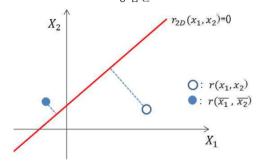
(Figure 3) An improved 1D-JB method using mirror image's features

(그림 3)은 제안하는 미러영상 특징을 고려한 JB 방법론을 도식화한 예이다. 이 경우 $r(\overline{x_1},\overline{x_2})$ 가 $r(x_1,x_2)$ 보다 임계치 T로 부터 더 멀리 있으므로, $r(\overline{x_1},\overline{x_2})$ 의 결정에 따라 x_1 과 x_2 는 같은 사람이라 결정한다.

이 방법은 주어진 두 영상에 대하여 두 개의 유사도를 계산하여 결정 경계(임계치)로부터 멀 리 떨어져 있는 유사도의 결정을 따르는 방법이 다. 이는 결정경계 근처에서 오류가 많이 발생하 는 것에 착안하여, 결정경계로부터 멀리 떨어져 있는 유사도 값을 얻을 수 있는 방법을 고안한 것이다.

지금까지 미러영상의 특징을 이용한 JB 분류 방법을 1D-JB 방법론에 적용하여 설명하였다. 이 방법은 위에서 설명한 2차원 JB 방법에도 적 용할 수 있다. 2D-JB에서는 임계치 대신 결정경 계에서 멀리 떨어져 있는 값의 결정을 따른다.

(그림 4) 미러영상 특징을 이용한 2D-JB 개선 방법론



(Figure 4) An improved 2D-JB method using mirror image's features

(그림 4)는 미러영상의 특징을 이용한 2D-JB 분류 방법론을 도식화한 예를 보여준다. 이 경우 $r(x_1,x_2)$ 가 $r\left(\frac{x_1}{x_1},\frac{x_2}{x_2}\right)$ 보다 결정경계 직선으로 부터 더 멀리 떨어져 있으므로, $r(x_1,x_2)$ 의 결정에 따라 x_1 과 x_2 이 동일인인지 판단한다.

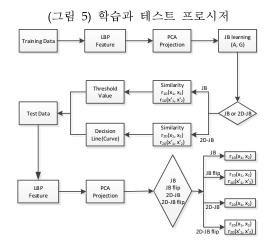
식(19)의 유사도 함수 r_{2D} 의 절댓값이 2차원 특징에서 결정경계까지 거리에 비례하므로 다음과 같은 의사코드를 얻을 수 있다.

```
\begin{array}{l} \text{if } |r_{2D}(x_1,x_2)| \geq \left|r_{2D}(\overline{x_1},\overline{x_2})\right| & \{\\ \text{if } r_{2D}(x_1,x_2) \geq 0 \\ & x_1 \text{ and } x_2 \text{ are same.} \\ \text{else} \\ & x_1 \text{ and } x_2 \text{ are different.} \\ \} \\ \text{else } \{ \\ \text{if } r_{2D}(\overline{x_1},\overline{x_2}) \geq 0 \\ & x_1 \text{ and } x_2 \text{ are same.} \\ \text{else} \\ & x_1 \text{ and } x_2 \text{ are different.} \\ \} \\ \end{array}
```

4. 실험결과

우리는 이 장에서 기존 1D-JB, 2D-JB 방법론과 제안하는 미러영상 특징을 이용한 JB 방법론을 실험을 통하여 비교한다. 미러영상 특징을 이용한 1D-JB 개선 방법론을 1D-JP-flip, 미러영상 특징을 이용한 2D-JB 개선 방법론을 2D-JB-flip이라 부르기로 하자.

우리는 실험에서 최근 큰 이슈가 되고 있는 LFW(Labeled Faces in the Wild)[3]와 LFW-a[9] DB를 사용하였다. LFW DB는 5,749 인물에 대해 13,233개의 영상을 포함하고 있다. LFW-a DB는 LFW DB의 영상들을 상업용 소프트웨어를 이용하여 얼굴 배열을 한 영상들의 모음이다. (그림 5)는 LFW DB를 이용한 비교실험 과정을 보여준다.



(Figure 5) Training and test procedure

학습 과정에서, 우리는 두 가지 종류의 데이터 (영상)를 사용한다. 첫 번째는 LFW 실험 규약 (protocol)을 따를 때 사용할 수 있는 LFW 데 이터이다. 우리는 이것을 뷰2(View 2) 데이터라 고 부르겠다. LFW 실험 규약에는 10개의 폴드 (fold)가 있다. 이 중 한 폴드를 테스트 폴드로 지정하고, 나머지 9개 폴드를 학습 폴드로 지정 한다. 학습 폴드에 속하는 모든 영상을 학습 과 정에서 이용할 수 있다. 이 과정을 테스트 폴드 를 바꿔가며 10회 반복하고 평균 인식률을 제시 한다. 두 번째는 각 테스트 폴드마다, 테스트 폴 드에 속하지 않는 모든 LFW 데이터를 학습에 이용하였다. 우리는 이것을 확장된 뷰 2 데이터 라고 부르겠다. 모든 실험에서 우리는 원본 얼굴 영상들과 이를 좌우 반전시킨 얼굴영상들을 학 습과정에서 사용하였다.

우리는 영상으로부터 다음과 같이 전체적 (global) LBP(local binary pattern)[12] 특징과 국부적(local) LBP 특징을 추출하여 하나의 벡터로 연결(concatenate)한다[14]. 전체적 LBP 특징을 추출하기 위해 LFW-a DB 영상에서 중앙의 120×80 크기의 영상을 추출하여 10×10 크기의 12×8개의 셀(cell) 영역으로 분할한다. 각 셀의 100개의 픽셀에 대해 $LBP_{8,1}^{u2}$ 특징들을 추출한 후 59개의 빈(bin)을 가지는 히스토그램을 구한다. 또 각 셀에서 $LBP_{8,2}^{u2}$ 특징들을 추출해 히스토그램을 구하여 모두 연결시킨다. 그리고 4개의 구석에 속한 16개의 셀은 제외시킨다. 이 과정을

통해 한 장의 영상에서 $(12\times8-16)\times59\times2=9,440$ 차원의 특징벡터를 얻을 수 있다. 또, 좀 더 전체적인 특징을 얻기 위해 이 120×80 영상을 60×60 영상으로 축소하여 36개의 셀에 대해 같은 방법으로 $LBP_{8,1}^{u^2}$ 과 $LBP_{8,2}^{u^2}$ 히스토그램 특징벡터를 구한다.

국부적 특징추출을 위해 LFW DB 영상에서 SDM 방식[13]을 이용하여 49개의 얼굴 특징점을 추출하고, 각 특징점을 중심으로 한 10×10 크기의 영상영역에서 $LBP_{8,1}^{u2}$ 과 $LBP_{8,2}^{u2}$ 히스토그램을 추출하여 연결하였다. 이렇게 구한 모든 LBP 히스토그램을 연결하여 36,344 차원의 특징벡터를 구하였다.

특정 벡터의 차원을 줄이기 위하여 주성분 분석(PCA)을 이용하였다. 원본 영상과 좌우 반전시킨 영상을 모두 이용하여 PCA 축을 구하였다. 우리의 실험에서 100부터 700까지 PCA 차원을 변경하며 인식률을 측정하였다. 원본 데이터를 그대로 이용하는 것 보다 PCA를 이용하여 차원을 축소할 때 테스트 성능이 향상된다는 것은 주목할 만한 사실이다.

JB 학습으로 구해지는 행렬 A, G는 각 사람의 평균과 평균으로부터 변화량(variation)을 고려한다. 이 변화량을 잘 구하기 위해서는 한 사람당 학습할 수 있는 영상의 개수가 충분해야한다[1]. 이러한 이유로 우리는 실험에서 nDepth라는 파라미터를 고려하였다. nDepth는 클래스(인물)당 데이터의 수로 실험 전에 미리 설정한다. JB의 행렬 A와 G는 LFW DB의 영상 중에서 nDepth 이상의 영상을 포함하고 있는 사람들의 영상들만을 이용하여 구했다. 실험에서 nDepth는 2에서 10까지 변화시켰다.

<표 1> 뷰2 학습데이터를 이용한 인식률

PCA dim	1D-JB	1D-JB-fl ip	2D-JB	2D-JB-fl ip
100	85.70	86.90	85.87	87.15
200	87.88	88.98	88.50	89.43
300	88.55	89.43	89.37	90.03
400	88.63	89.82	89.60	90.58

<Table 1> Recognition rate using view 2 training data

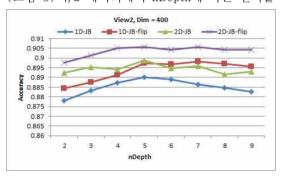
<표 2> 확장된 뷰2 학습데이터를 이용한 인식률

PCA dim	1D-JB	1D-JB-fl ip	2D-JB	2D-JB-fl ip
500	91.07	91.88	91.82	92.67
600	91.18	92.22	91.87	92.90
700	91.35	92.28	92.08	93.12

<Table 2> Recognition rate using augmented view 2 training data

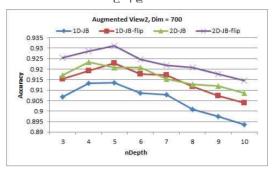
<표 1>은 뷰2 학습데이터를 이용한 실험결과이고 <표 2>는 확장된 뷰2 학습데이터를 이용한 실험결과를 보여준다. nDepth의 값은 5로 고정하였다. 같은 조건일 때, 기존 방법 1D-JB, 2D-JB 방법보다 제안한 1D-JB-flip, 2D-JB flip) 방법의 성능이 1% 정도 인식률이 향상되었음을 알 수 있다. 최고의 인식률은 PCA 차원이 700이고 2D-JB-flip 알고리즘을 이용할 때, 93.12%임을 알 수 있다.

(그림 6) 뷰2 데이터에서 nDepth에 따른 인식률



(Figure 6) Comparison of performances with nDepth using view 2 data

(그림 7) 확장된 뷰2 데이터에서 nDepth에 따른 인식률



(Figure 7) Comparison of performances with nDepth using augmented view 2 data

우리는 학습데이터의 보유량(depth)[1]에 따른 인식률의 변화를 실험을 통해 알아보았다. (그림 6)과 (그림 7)은 nDepth의 변화에 따른 인식률 을 보여준다. (그림 6)은 PCA에 의해 400차원으 로 축소된 뷰2 데이터의 특징을 이용한 인식 결과이고. (그림 7)은 700 차원으로 축소된 확장 된 뷰2 데이터의 특징을 이용한 결과이다. 두 그 림 모두에서 제안한 미러영상 특징을 이용한 IB 방법론(1D-JB-flip, 2D-JB-flip)들이 기존의 JB(JB, 2D-JB) 방법론들의 성능을 향상시키고 있음을 볼 수 있다. 네 가지 방법론들은 모두 nDepth가 5 근방일 때 최고 인식률을 보였다. nDepth가 작을수록 더 많은 학습데이터를 이용 하여 JB 학습을 수행할 수 있지만, 얼굴의 변화 를 표현하는 공분산 행렬을 잘 추정할 수 없어 인식률이 오히려 떨어지는 것을 볼 수 있다. nDepth가 큰 경우 인식률이 저하되는 것은 학습 데이터가 부족하기 때문에 발생한 현상으로 보 인다.

5. 결론 및 토의

LFW DB 발표 이후 훌륭한 얼굴인식 알고리즘들이 많이 제안되었다. 2012년 JB 방법론이제안된 후 제안된 거의 모든 얼굴 인식 방법론들은 특징추출 방법만 바뀌었을 뿐, 특징추출 후분류는 JB 방법론을 이용하고 있다. 하지만 JB 방법론보다 뛰어난 분류 방법론이나 이를 개선한 방법론은 Han 등[2]이 제안한 2D-JB가 유일

하다. 우리는 본 논문에서 JB와 2D-JB 방법론을 개선한 알고리즘을 제안하였다. 우리는 실험을 통해 제안한 미러영상 특징을 이용한 JB 방법론이 기존 JB 알고리즘 보다 1.6% 이상, 기존 2D-JB 알고리즘보다 약 1%의 높은 인식률을 보임을 보였다.

우리는 최근 깊이학습(Deep Learning) 특징을 이용한 연구를 수행중이다. 수행중인 연구에서도 LFW DB를 이용한 모든 실험에서 제안한 JB 개선 방법론이 기존 JB 알고리즘 보다 1%이상 높은 인식률을 보이는 것을 확인할 수 있었다.

많은 연구자들은 최신 연구[1, 4, 5, 6. 7, 8]에서 보듯이 성능을 1% 향상시키기 위해 엄청난양의 학습데이터가 추가로 필요하다. 하지만 제안한 JB 개선 방법론은 학습데이터를 늘리지 않고도 성능을 1%이상 향상시킬 수 있는 매우 효과적인 방법론이다.

References

- [1] D. Chen, X. Cao, L. Wang, F. Wen, and J. Sun, "Baye sian Face Revisited: A Joint Formulation," Proc. EC CV, pp.566 - 579, 2012.
- [2] S. Han, I.-Y. Lee, J.-H. Ahn, "Two-dimensional Joi nt Bayesian method for face verification", Journal of Information Processing Systems, in press, 2015.
- [3] G. Huang, M. Ramesh, T. Berg, and E. Learned-Mill er, "Labeled Faces in the Wild: A Database for Stud ying Face Recognition in Unconstrained Environme nts", University of Massachusetts, Amherst, Techni cal Report 07–49, Oct. 2007.
- [4] X. Cao, D. Wipf, F. Wen, and G. Duan, "A practical Transfer Learning Algorithm for Face Verification", Proc. ICCV, pp.3208–3215, Dec. 2013.
- [5] D. Chen, X. Cao, F. Wen, and J. Sun, "Blessing of Dimensionality: High-dimensional Feature and Its Efficient Compression for Face Verification", Proc. CVPR, pp.3025–3032, June. 2013.
- [6] Y. Sun, Y. Chen, X. Wang and X. Tang, "Deep Learning Face Representation by Joint Identity-Verification

- n", Proc. NIPS, Dec. 2014.
- [7] Y. Sun, X. Wang, and X. Tang, "Deep Learning Face Representation from Predicting 10,000 Classes", Pro c. CVPR, pp.1891–1898, June, 2014.
- [8] Y. Sun, X. Wang, and X. Tang, "Deeply learned face representations are sparse, selective, and robust", A rXiv:1412.1265, Dec. 2014.
- [9] L. Wolf, T. Hassner, and Y. Taigman, "Effective Fac e Recognition by Combining Multiple Descriptors an d Learned Background Statistics", IEEE TPAMI, V ol.33, No.10, 2011.
- [10] C.M. Bishop, Pattern Recognition and Machine Lear ning, 1st ed., Springer, 2006.
- [11] C. Cortes and V. Vapnik, "Support-Vector Network s", Machine Learning, Vol.20, No.3, pp.273-297, 1995
- [12] T. Ahonen, A. Hadid, and M. Pietikainen, "Face des cription with local binary patterns: Application to face recognition", IEEE TPAMI, Vol.28, No.12, pp.20 37–2041, 2006.
- [13] X. Xiong and F.D. Torre, "Supervised Descent Meth od and its Application to Face Alignment", Proc. CV PR, pp.532–539, June, 2013.
- [14] J.-H. Ahn, "An Improved RSR Method to Obtain the Sparse Projection Matrix", Journal of Digital Contents Society, Vol.16, No.4, pp.605-613, 2015.



한 성 휴

1999년 : 연세대학교 대학원 (이학

석사)

2007년 : 연세대학교 대학원 (이학

박사-부호이론)

2000년~2005년: 삼성전자 선임 연구원

2007년~2008년: University of Louisville 수학과 박

사후 연구원

2008년~2009년: 이화여자대학교 수리과학 연구소 박

사후 연구원

2009년~현 재: 한국기술교육대학교 교양학부 조교수

관심분야: 얼굴인식, 이미지 인식, 부호론 등



안 정 호

1998년 : 연세대학교 대학원 (공학

석사-수학)

2001년 : Texas A&M University

대학원 (이학석사-통계학)

2006년 : 연세대학교 대학원 (공학

박사-컴퓨터과학)

2006년~2007년: 연세대학교 BK21 지능형모바일서비 스를 위한 차세대 단말소프트웨어 사업단, 박사후 연구원

2006년~현재: 강남대학교 컴퓨터미디어정보공학부, 부교수

관심분야: 얼굴인식, 패턴인식, 기계학습, 딥러닝, 영 상처리, 컴퓨터비전 등