

더미 클래스를 가지는 열린 집합 얼굴 인식 방법의 유효성 검증에 대한 연구

안정호·최권택

강남대학교 소프트웨어응용학부 가상현실전공

A Study on the Validation Test for Open Set Face Recognition Method with a Dummy Class

Jung-Ho Ahn · KwonTaeg Choi

Division of Software Application, Kangnam University, YongIn-si 16979, Korea

[요 약]

열린 집합 인식 방법론은 테스트 데이터의 클래스를 학습 시에 모두 파악할 수 없는 경우에 대한 인식 방법론이다. 따라서 열린 집합 인식 방법론은 분류와 유효성 검증의 절차를 필요로 한다. 이러한 연구는 얼굴 인식 모듈의 상용화를 위해 필수적이지만 지금까지 국내에서 연구 결과들이 거의 발표되지 않았다. 우리는 두 개의 검증 단계를 가지는 열린 집합 얼굴 인식 방법론을 제안한다. 첫 번째 단계에서는 학습 클래스 외에 더미 클래스들을 설정하고 희소표현 기반 분류를 수행한다. 이 때 테스트 데이터가 더미 클래스로 분류되면 무효 데이터로 판별하고, 유효한 클래스로 분류되면 다음 유효성 검증 단계로 넘어간다. 두 번째 단계에서 제안하는 네 가지 특징을 추출하고, 확률분포에 기반을 둔 판별함수를 통해 유효성 검증을 수행한다. 우리는 실험을 통해 열린 집합 인식 방법론의 시뮬레이션 방법을 제안하였고 제안하는 방법론의 성능을 제시하고, 희소기반 분류 방식에서 널리 사용되는 SCI 지표를 이용한 유효성 테스트보다 높은 성능을 보임을 입증할 수 있었다.

[Abstract]

The open set recognition method should be used for the cases that the classes of test data are not known completely in the training phase. So it is required to include two processes of classification and the validation test. This kind of research is very necessary for commercialization of face recognition modules, but few domestic researches results about it have been published. In this paper, we propose an open set face recognition method that includes two sequential validation phases. In the first phase, with dummy classes we perform classification based on sparse representation. Here, when the test data is classified into a dummy class, we conclude that the data is invalid. If the data is classified into one of the regular training classes, for second validation test we extract four features and apply them for the proposed decision function. In experiments, we proposed a simulation method for open set recognition and showed that the proposed validation test outperform SCI of the well-known validation method

색인어 : 얼굴 인식, 열린 집합 인식, 더미 클래스, 희소 표현, 커널 밀도 추정

Key word : Face recognition, Open set recognition, Dummy class, Sparse representation, Kernel density estimation

<http://dx.doi.org/10.9728/dcs.2017.18.3.525>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 10 May 2017; **Revised** 21 May 2017

Accepted 25 June 2017

***Corresponding Author; KwonTaeg Choi**

Tel: +82-031-280-3660

E-mail: kwontaeg.choi@kangnam.ac.kr

I. 서론

지금까지 패턴인식 분야의 연구는 학습단계부터 테스트 데이터가 속하는 모든 클래스들을 안다는 가정 하에 이루어진 닫힌 집합 인식(closed set recognition)에 대한 연구들이 주를 이루었다. 하지만, 테스트 데이터 중 일부는 학습된 클래스 중 어느 것에도 속하지 않을 수 있다고 가정하는 것이 보다 현실적이라 여겨진다. 이러한 가정 하에 인식하는 방법을 열린 집합 인식(open set recognition)이라 부른다[1].

얼굴인식을 상용화하기 위해서는 열린 집합 얼굴인식에 대한 연구가 수반되어야 한다. 즉, 테스트 데이터가 학습된 클래스 중 가장 유사한 클래스로 잘 분류될 수 있는 방법론을 개발하는 것 외에, 테스트 데이터가 학습된 클래스 중 어느 하나에 속하는지의 여부를 판단할 수 있어야 한다. 이러한 판단을 유효성 검증(validation test)라 부른다. 테스트 데이터가 정상적인 학습 클래스에 속한다고 판단되면 유효(valid), 그렇지 않으면 무효(invalid)라 판별한다.

지문 인식이 등 상용화된 대부분의 생체인식 제품들은 생체 영상과 더불어 식별 번호를 입력한다. 이때 입력하는 식별 번호는 클래스 아이디로, 입력된 영상이 이 클래스로 분류되는지의 여부를 판단하는 방식으로 유효성 검증(테스트)을 수행한다. 유효성 검증을 위해 사용자가 부가 정보를 입력해야 하는 것이다. 하지만, 사용자 편의를 중시하는 기술 발전의 경향으로 볼 때, 입력 영상만으로 분류와 유효성 테스트가 모두 가능해야 할 것이다. 즉, 이제는 열린 집합 인식에 대한 연구가 필요한 시점이라 말할 수 있다. 국외에서는 열린 집합 인식에 대한 연구가 꾸준히 수행되어 왔으나[1]-[5], 아직 국내에서는 열린 집합 인식에 관한 연구가 활발히 이루어지지 않고 있다.

최근 얼굴인식에 대한 연구는 LFW(Labeled Faces in the Wild) 얼굴 데이터베이스(DB)[6] 발표 이후, 주어진 두 장의 얼굴 영상이 같은 사람(match)인가, 다른 사람(mismatch)인가를 판단하는 이진 분류 문제에 대한 연구가 활발하다. 이런 얼굴 인식을 얼굴 검증(face verification)이라 부른다. 만약 얼굴 검증이 성공적으로 이루어진다면 모든 클래스의 학습 영상과 비교를 통해 데이터의 유효성 문제는 자연스럽게 해결될 수 있을 것으로 기대할 수 있다.

우리는 본 논문에서 분류에 기반을 둔 새로운 열린 집합 얼굴 인식 방법론을 제안한다. 제안하는 방법론은 두 단계의 유효성 테스트를 수행한다. 첫 번째 단계는 더미 클래스(dummy class)를 추가하여 분류와 유효성 테스트를 동시에 수행한다. 두 번째 단계에서는 테스트 데이터와 분류된 클래스의 데이터들을 이용하여 유효성 테스트를 위한 특징들을 추출하고 이 특징 값들을 확률적으로 결합하는 방식으로 유효성 테스트를 수행한다.

우리는 다음 절에서 희소 표현기반 얼굴인식 방법론을 간략히 살펴본다. 이는 본 논문에서 얼굴영상을 분류할 때 사용하는 방법론으로 대상의 가려짐이나 변장, 영상의 잡음, 손상에 대해

서 강한 특성을 가지는 것으로 알려져 있다. 그리고 희소기반 얼굴인식 방법론에서 유효성 테스트를 위해 사용되는 SCI(Sparsity Concentration Index) 지표를 소개한다. 3절에서는 제안하는 유효성 테스트 방법론을 기술하고, 4절에서는 다양한 DB에서 실험을 통해 제안한 방법론의 우수성과 분석 결과를 소개한다. 그리고 5절에서 결론을 맺는다.

II. 배경

희소 표현기반 얼굴인식은 다음 식 (1)과 같이 테스트 데이터 y 를 학습데이터 행렬 A 의 선형조합으로 표현할 수 있다고 가정한다[7].

$$y = Ax \tag{1}$$

여기서 x 는 희소해(sparse solution)로 0이 아닌 요소(entry)가 차원에 비해 크게 적어야 하는 제약을 둔다. 이때, 이 희소해 x 를 찾는 것이 중요한 문제가 된다. 이는 다음 식 (2)와 같이 l^0 최적화 문제로 정형화 할 수 있다.

$$x_0 = \operatorname{argmin} \|x\|_0 \quad \text{subject to } Ax = y \tag{2}$$

하지만 이 문제의 해를 직접 구하는 것은 NP 하드 문제이기 때문에 l^1 최적화 문제의 해로 복원(recovery)하는 것이 일반적이다. 또는, 탐욕적인 ROMP(Regularized Orthogonal Matching Pursuit) 방법[8]을 이용하여 l^2 최적화 문제를 통해 효율적으로 복원할 수 있다[9].

추정된 해는 자신이 속한 클래스의 학습 데이터에 대해서만 0이 아닌 요소를 갖고, 다른 클래스의 학습 데이터에 대해서는 0에 가까운 값을 갖는 것이 이상적이다. 이러한 이유로, 분류기를 미리 학습하지 않고, 희소해 x 의 분포를 이용하거나 x 를 통해 복원한 데이터와 테스트 데이터의 잔차(residual)가 최소인 클래스로 분류한다[7], [9].

그러나 분류가 유효성(validity)을 보장하지 못 하기에 때문에, 식 (3)과 같이 희소해의 분포를 이용해 테스트 데이터의 유효성(validity)을 테스트할 수 있는 SCI 지표가 처음으로 제안되었다[7].

$$SCI(x) = \frac{k \max_i \|\delta_i(x)\|_1 / \|x\|_1 - 1}{k - 1} \tag{3}$$

여기서 k 는 클래스 수이고, $\delta_i(x)$ 는 희소해 벡터 x 에서 i 번째 클래스에 속하지 않는 학습데이터에 해당하는 값들을 모두 0으로 설정하는 함수이다. SCI 값이 특정 임계값보다 높을 경우 유효성 테스트 데이터가 유효하다고 판단하고, 그렇지 않을 경우 유효하지 않다고 판단할 수 있다.

III. 제안 방법

3-1 제안하는 열린 집합 얼굴 인식 개요

열린 집합 얼굴 인식은 유효성 검증과 분류 작업으로 구성된다. 우리는 유효성 검증을 통해 주어진 테스트 데이터가 학습된 클래스들 중 어느 하나에 속하는 경우 유효(valid), 그렇지 않은 경우 무효(invalid)라 판별한다.

제안하는 유효성 검증 방법론은 ‘분류 후 검증’ 방식으로, 테스트 데이터에 대해 분류 작업을 먼저 수행한다. 분류를 위한 학습 단계에서 학습 대상을 위한 클래스 외에 학습 대상이 아닌 인물들에 대한 클래스들을 추가하여 학습한다. 여기서, 덤으로 추가된 클래스를 더미 클래스라 부른다. 만약 테스트 영상이 더미 클래스로 분류되면 무효 데이터로 판별한다.

만약 테스트 영상이 더미 클래스가 아닌 정상적인 학습 클래스 중 하나로 분류되면, 테스트 영상(또는 특징)으로부터 유효성 검증을 위한 특징들을 추출하여 제안하는 판별함수로 유효성 테스트를 수행한다. 여기서 유효로 판별되면 테스트 데이터는 처음에 분류된 클래스에 속하는 것으로 확정하고, 무효로 판별되면 학습 대상이 아닌 인물로 판단한다. 다음 그림 1은 제안하는 열린 집합 얼굴 인식 방법론을 도식화한 것이다.

우리는 분류를 위해 ROMP를 이용한 희소 표현 기반 얼굴 인식 방법론[9]을 사용하였다. 다음 절에서 유효성 검증을 위한 특징 추출 방법을 제안하고, 3-3절에서는 유효성 특징 값들의 확률 분포 추정을 통한 유효성 판별함수를 제안한다.

3-2 유효성 검증을 위한 특징 추출

우리는 얼굴 유효성 검증을 위해 다음과 같이 4가지 특징을 연구하였다. 2개의 특징은 희소 표현 기반의 얼굴 인식에서 사용하는 특징이고, 2개는 확률 분포를 고려해 유효성 검증을 위해 제안된 특징이다.

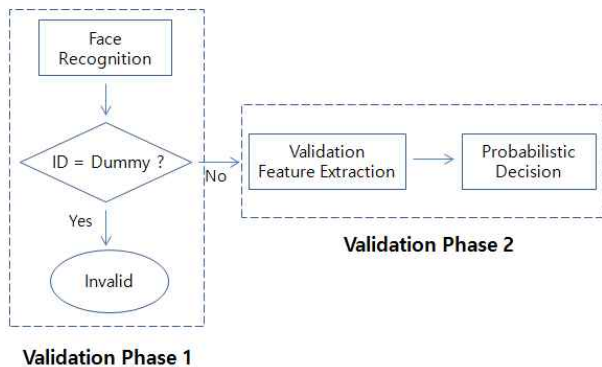


그림 1. 제안하는 열린 집합 얼굴 인식 방법론 개요
 Fig. 1. The overview of the proposed open set face recognition method

1) 잔차 특징
 다음 식 (4)와 같이 정의하는 잔차 특징 값은 주어진 테스트 데이터를 희소해를 이용해 복원시킬 때 에러로 이 값이 작을수록 유효한 데이터로 볼 수 있다. 여기서 최솟값이 발생하는 인덱스 i 는 1 단계 분류에서 추정된 클래스의 레이블과 같다.

$$\min_i (\|y - A\delta_i(x)\|) \quad (4)$$

2) SCI 특징
 희소표현기반 인식에서 널리 사용되는 식 (3)의 SCI 값은 유효성 검증을 위해 사용할 수 있다. 희소해의 0 아닌 값의 분포가 특정 클래스로 집중될 경우 SCI 값이 커지고, 그렇지 않은 경우 작아지게 된다. 희소해의 0 아닌 값들이 특정 클래스에 집중된다는 것은 특정 클래스의 학습데이터의 선형조합으로 테스트 데이터가 복원 가능하다는 것을 의미한다. 따라서 SCI 값이 크면 데이터는 유효하다고 볼 수 있고 작으면 무효라 할 수 있다.

3) 거리-비 특징
 학습데이터를 이용하여 각 클래스 별로 경계를 정확히 추정할 수 있다면 검증 문제는 손쉽게 해결될 수 있다. 하지만 클래스 경계를 설정하는 것은 어려운 문제이다. 따라서 우리는 클래스의 경계를 결정하는 대신, 주어진 테스트 데이터와 이와 가장 가까이 있는 학습 데이터를 경쟁시키는 방식으로 테스트 데이터가 분류된 클래스에 속하는 정도를 유효성 검증을 위한 특징으로 새롭게 제안한다.

테스트 데이터 y 에 대해 1 단계 분류를 통해 y 의 예상 클래스가 레이블 c 로 예측되었다고 하고, 클래스 레이블이 c 가 아닌 학습데이터 중 y 와 가장 가까운 데이터를 y'_{NN} 이라 하자. 우리는 두 데이터 y, y'_{NN} 와 클래스 c 사이의 거리의 비를 거리-비 특징으로 정의한다.

그림 2에서 보듯이 클래스 c 의 클래스 경계는 y'_{NN} 과 클래스 c 의 데이터들 사이에 있을 가능성이 있다. 만약 테스트 데이터 y 보다 y'_{NN} 이 클래스 c 에 더 가까이 있다면 이 테스트 데이터 y 는 무효일 가능성이 높다. 여기서 데이터 y, y'_{NN} 와 클래스 c 사이의 거리를 구하기 위해, 클래스 c 의 학습 데이터 중 y 와 유사한 데이터를 찾는다.




그림 2. 이웃 데이터의 관계를 고려한 거리-비 특징
 Fig. 2. Distance ratio feature using the nearest neighbor data

유사 데이터가 한 개인 경우 이를 x_1 이라 할 때, 다음 식(5)와 같이 특징 공간의 원점 O 와 x_1 을 잇는 직선 $\overrightarrow{Ox_1}$ 과 데이터 y, y'_{NN} 사이의 거리 비율을 거리-비 특징으로 정의한다.

$$\frac{d(y, \overrightarrow{Ox_1})}{d(y'_{NN}, \overrightarrow{Ox_1})} \tag{5}$$

이는 원점과 x_1 을 잇는 직선상의 점들은 x_1 과 동일한 클래스 레이블을 가질 확률이 높다는 가설에 의해 고안되었다. 왜냐하면, x_1 이 영상의 각 행을 연결한 벡터인 경우 직선 $\overrightarrow{Ox_1}$ 상의 점들은 x_1 영상의 밝기를 달리한 영상에 해당하므로 이 직선 상의 점들은 모두 같은 인물에 해당되기 때문이다. 이 거리는 데이터의 노름이 1로 정규화되어 있을 때, 다음과 같이 구할 수 있다.

$$d(y, \overrightarrow{Ox_1}) = \|y - (y \cdot x_1)x_1\|_2 \tag{6}$$

마찬가지로, 유사 데이터가 두 개인 경우 이를 각각 x_1, x_2 라 하자. 이 두 데이터가 모두 클래스 c 에 속하므로 직선 $\alpha x_1 + \beta x_2$ 상의 데이터들도 모두 클래스 c 에 속할 확률이 높다는 가설하에 다음 거리의 비를 거리-비 특징으로 정의하였다.

$$\frac{d(y, \overrightarrow{x_1x_2})}{d(y'_{NN}, \overrightarrow{x_1x_2})} \tag{7}$$

이 경우의 거리는 모든 데이터의 노름(norm)이 1로 정규화 되어 있을 때, 다음과 같이 구할 수 있다.

$$d(y, \overrightarrow{x_1x_2}) = \left\| y - x_1 - \frac{(x_2 - x_1) \cdot (y - x_1)}{\|x_2 - x_1\|_2^2} (x_2 - x_1) \right\|_2 \tag{8}$$

그림 3은 유사 데이터가 두 개인 경우의 예를 보여 준다. 유사 데이터는 클래스 c 의 학습데이터 중 최소해가 0보다 큰 데이터로 y 와 가까운 두 개의 데이터를 선택하였다. 0보다 큰 데이터가 한 개인 경우는 유사 데이터가 한 개인 경우로 계산하였다.




그림 3. 유사데이터가 2개인 경우의 거리-비
Fig. 3. Distance ratio when there are two similar points

4) MkNN 유사도 특징

MkNN(Marginalized kNN)[10] 유사도 특징은 주어진 두 (영상) 데이터 x_i 와 x_j 가 같은 클래스에 속할 확률을 계산하기 위해 사용하는 방법이다. 하나의 데이터 x_i 에 대하여 클래스 c 에 속할 확률은 다음과 같다.

$$p(y_i = c|x_i) = n_c^i/k \tag{9}$$

여기서 k 는 x_i 의 NN 개수이고, n_c^i 는 k-NN 중 레이블이 c 인 데이터의 개수이다. 이를 이용하여 두 데이터가 같은 레이블을 가질 확률은 다음과 같이 계산할 수 있다.

$$p(y_i = y_j|x_i, x_j) = \sum_c p(y_i = c|x_i)p(y_j = c|x_j) = \sum_c n_c^i n_c^j / k^2 \tag{10}$$

이 식 (10)의 값을 $MkNN(x_i, x_j)$ 라 할 때, 테스트 데이터 y 에 대해 다음과 같이 MkNN 유사도 특징 추출 방식을 제안한다.

$$\max_{x \in C} MkNN(y, x) \tag{11}$$

여기서 C 는 클래스 c 의 모든 학습 데이터들의 집합이다. 본 논문의 실험에서 사용할 4 가지 유효성 검증 특징의 의미에 대해서 표 1에 정리하였다.

3-3 유효성 검증

3-2 절에서 검증을 위한 4가지 특징을 제시하였다. 우리는 본 절에서는 이 4개의 특징 값을 적절히 조합하여 유효성 검증을 수행하는 방법을 설명한다.

n 차원 특징 벡터 $f = (f_1, \dots, f_n)$ 의 특징 값들을 조합하는 효과적인 방법 중 하나는 적절한 가중치 w_1, \dots, w_n 을 이용하여 선형 조합한 후 적절한 임계값 T 를 설정하는 방식으로 다음 식 (12)을 만족하면 유효, 그렇지 않으면 무효로 판별하는 방식을 고려할 수 있다.

$$w_1 f_1 + w_2 f_2 + \dots + w_n f_n > T \tag{12}$$

표 1. 유효성 검증을 위한 특징 요약

Table. 1. Summary of the proposed features for validation

약자	특징	유효한 경우
Residual Error	reconstruction 유사도	낮을때
C-SCI	최소 솔루션의 특성 이용	높을때
Distance-ratio	결정 경계를 고려	낮을때
MkNN	같은 클래스에 속할 확률	낮을때

이는 선형 SVM[11]을 이용하여 구현가능하다. 하지만 이 방법은 n 차원 특징의 분포가 선형분리 가능한 경우 효과적이며 DB에 의존성이 높다. 따라서 우리는 다음 식 (13)과 같은 확률적 접근을 제안한다.

$$y = \begin{cases} \text{valid} & \text{if } P(\text{valid}|y) > P(\text{invalid}|y) \\ \text{invalid} & \text{otherwise} \end{cases} \quad (13)$$

여기서 $P(\text{valid}|y)$ 와 $P(\text{invalid}|y)$ 는 테스트 데이터 y 가 유효 또는 무효일 확률로 다음 식 (14)와 같이 각 특징 값의 우도(likelihood)의 합과 비례관계가 있다고 가정하자.

$$\begin{aligned} P(\text{valid}|y) &\propto L(\text{valid}|f_1) + \dots + L(\text{valid}|f_n) \\ P(\text{invalid}|y) &\propto L(\text{invalid}|f_1) + \dots + L(\text{invalid}|f_n) \end{aligned} \quad (14)$$

우리는 이를 이용하여 다음 식 (15)과 같은 형태의 유효성 판별함수(decision function)를 제안한다.

$$D(f) = \sum_{i=1}^n (L(\text{valid}|f_i) - L(\text{invalid}|f_i)) \quad (15)$$

우리는 확률밀도함수(pdf; probability density function)의 함수 값으로 우도 값 $L(\cdot | f_i)$ 를 계산한다.

연속확률분포에서 확률밀도함수의 함수 값은 확률은 아니지만 확률과 비례관계가 있는 우도로 볼 수 있다[12]. 예를 들어, 어느 특징에 대한 유효, 무효 확률밀도함수 그래프가 다음 그림 4와 같이 주어졌을 때, 이 특징 값이 0.9인 데이터가 유효할 우도는 초록 점선과 빨간 pdf 그래프, 초록 점선과 파란색 pdf 그래프의 두 교차점의 높이 차로 구할 수 있다.

우리는 이런 방식으로 우도를 계산하기 위해 커널(kernel) 함수를 이용한 비모수통계(nonparametric statistics) 방법론[13]을 이용하여 각 검증 특징에 대해 유효 확률분포와 무효 확률분포를 각각 추정한다.

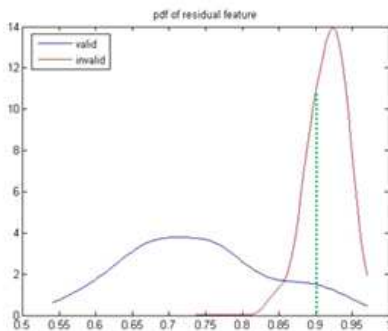


그림 4. 유효, 무효에 대한 연속 확률 분포
Fig. 4. probability density functions of valid and invalid cases




그림 5. 커널함수를 이용한 확률밀도함수 추정의 예[13]
Fig. 5. an example of kernel density estimation

우리는 주어진 특징 값들 x_1, \dots, x_n 과 커널함수 K 와 평활모수(bandwidth) h 에 대해서 식 (16)과 같이 확률밀도 함수 \hat{f}_h 를 추정한다.

$$\hat{f}_h(x) = \frac{1}{n} \sum_{i=1}^n K_h(x - x_i) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) \quad (16)$$

그림 5는 6개의 데이터와 표준정규분포함수인 $N(0, 1)$ 커널 함수를 이용한 확률분포함수 추정의 예를 보여준다[13].

우리는 다음 절에서 각 특징에 대해 DB 별로 추정된 확률밀도함수의 그래프를 소개하고 분석한다. 우리는 각 특징의 유효, 무효 확률밀도함수를 이용하여 우도를 추정하고, 성능향상을 위해 각 특징별 가중치 w_i 를 식 (15)에 추가하여 합으로써 식 (18)과 같이 결정함수를 정의한다.

$$D(f) = \sum_{i=1}^n w_i (L(\text{valid}|f_i) - L(\text{invalid}|f_i)) \quad (18)$$

이 결정함수를 이용하여 식 (18)과 같이 유효성 검증을 위한 결정 규칙을 정의한다.

$$y = \begin{cases} \text{valid} & \text{if } D(f) > 0 \\ \text{invalid} & \text{otherwise} \end{cases} \quad (18)$$

i 번째 특징에 대한 가중치 w_i 는 식 (19)와 같이 결정한다.

$$w_i = \frac{n_i^V + n_i^I}{N} \quad (19)$$

여기서 N 은 교차 타당화(cross validation) 데이터의 개수이고, n_i^V 는 유효 데이터 중 $L(\text{valid}|f_i) - L(\text{invalid}|f_i)$ 값이 0보다 큰 데이터의 개수이고, n_i^I 는 무효 데이터 중 $L(\text{valid}|f_i) - L(\text{invalid}|f_i)$ 값이 0보다 작은 데이터의 개수이다. 우리는 가중치의 효과를 입증하기 위해 가중치를 적용한 검증률(w)과 적용하지 않은 검증률(w/o)에 대한 실험을 수행하였다. 실험 결과는 다음 절에서 소개한다.

IV. 실험

우리는 본문에서 제안하는 열린 집합 얼굴 인식 알고리즘의 성능을 평가를 위해 각기 다른 환경에서 촬영된 8개의 얼굴 DB를 이용하여 비교 실험을 수행하였다. 실험에 사용한 DB의 데이터 개수와 클래스 개수에 대한 정보는 표 2와 같다.

얼굴 인식을 위한 특징을 추출하기 위해 각각의 DB의 얼굴 영상을 40x40 사이즈로 정규화한 후, 각 블록마다 LBP(local binary pattern) 히스토그램[15]을 구하고 독립적으로 학습된 LDA(linear discriminant analysis)[16] 축을 이용하여 300차원으로 축소하였다[9].

유효성 검증을 위한 특징으로는 잔차, 거리-비, MkNN 유사도, SCI, C-SCI특징으로 실험하였다. ROMP 알고리즘에서 희소레벨은 $\min(10, \#trainData/3)$ 로 10개 이하로 설정하였고, MkNN 유사도의 k 값은 5로 설정하였다.

우리는 학습데이터가 적을 때 인식에 관심을 가지고 있기에 클래스 당 학습데이터의 개수는 2 또는 5개로 제한하여 실험하였다.

첫 번째 실험으로 커널 함수를 이용한 비모수 통계 방법을 이용해 각 특징의 연속 확률분포 측정에 관한 실험을 수행하였다. 우리는 8개의 DB중에서 임의로 IF DB와 CF DB를 사용해 5개의 특징에 대한 확률 분포를 추정하고 이를 각각 그림 6, 7, 8, 9, 10에 표현하였다.

각각의 그림에서 첫 번째 행은 IF DB에서의 분포이고, 두 번째 행은 CF DB에서의 임의로 추정된 2개의 분포로 + 부분은 유효 데이터 분포를 -부분은 무효 데이터 분포를 의미한다.

표 2. 실험을 위한 얼굴 DB 요약

Table 2. Summary of face database for experiments

약자	DB	데이터수	클래스수
CT	CalTec99	440	26
Yale	Extended Yale B	9332	28
CF	Color FERET	1535	264
GF1	Gary FERET1	2164	489
GF2	Gary FERET2	3961	506
IF	Indian Face	546	61
JFF	JAFFE	213	10
ORL	ORL	382	40

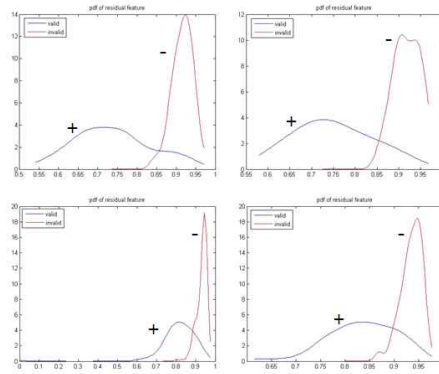


그림 6. IF, CF DB에서 잔차 특징 분포

Fig. 6. The pdf estimation for the residual feature under IF and CF database

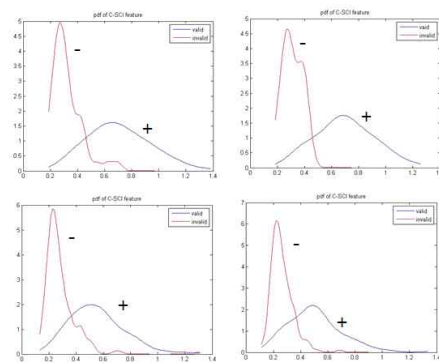


그림 7. IF, CF DB에서 제안된 C-SCI 특징 분포

Fig. 7. The pdf estimation for the C-SCI feature under IF and CF database

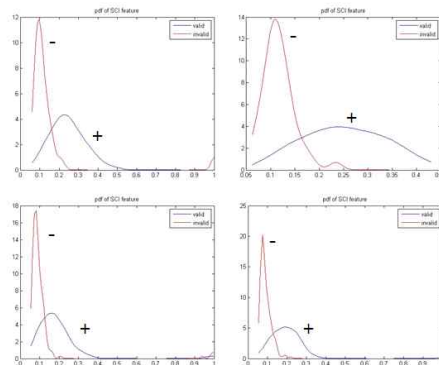


그림 8. IF, CF DB에서 SCI 특징 분포

Fig. 8. The pdf estimation of the SCI feature under IF and CF database

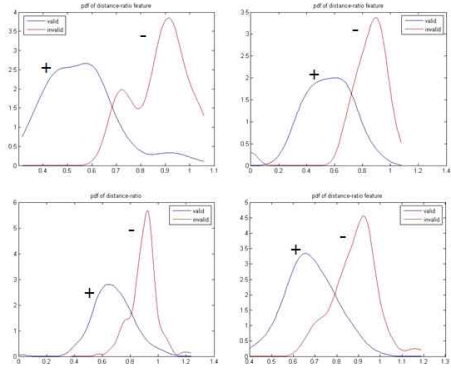


그림 9. IF, CF DB에서 거리-비 특징 분포
 Fig. 9. The pdf estimation of the distance-ratio feature under IF and CF database

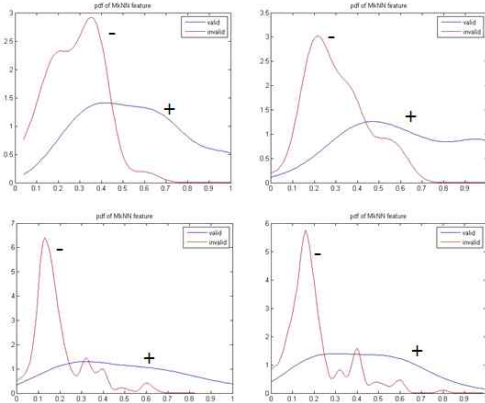


그림 10. IF, CF DB에서 MkNN 유사도 특징 분포
 Fig. 10. The pdf estimation for the MkNN similarity feature under IF and CF database

위 다섯 개의 특징 분포 그래프로부터 알 수 있는 사항은 다음과 같다. 1) DB와 특징에 따라 확률 분포는 다양해 보이지만 각각의 특징은 DB에 상관없이 어느 정도 유사해 보이는 것으로 보아 DB에 의존성이 크지는 않아 보인다. 2) 유효분포와 무효분포에서 겹치는 영역이 매우 크다. 겹치는 부분은 오류를 의미하기 때문에 단일 특징만으로 유효, 무효 분포를 구분하기는 어려움을 의미한다. 3) 대부분의 그래프에서 무효분포는 단일 봉우리 형태를 보이지만 유효한 분포는 넓게 퍼져 있다. 원래 이상적인 분포는 유효/무효 분포가 단일 봉우리 모양이고, 폭이 좁을수록 오류가 줄어든다.

표 3. SCI 특징을 이용한 유효성 성능 실험
 Table 3. Face validation performance using SCI

DB	CT	CF	GF1	GF2	IF	JFF	ORL
n=2	52.88	61.24	66.73	59.38	59.74	57.61	61.89
n=5	67.33	82.42	80.69	78.73	77.72	53.19	93.89

표 3은 SCI 특징을 이용한 유효성 검증 결과를 보여준다. 이 유효성 검증률은 50%~60%로 매우 낮음을 알 수 있다. 다음으로, 제안한 다섯 개의 특징을 결합한 유효성 검증을 수행하였다. 그리고 이러한 특징을 결합할 때 가중치를 적용한 검증률(w)과 적용하지 않은 검증률(w/o)을 비교하였다. 6개의 DB에서 30회 반복 실험해 실험결과를 표 3에 정리하였다.

유효성 인식률이 특징 하나만을 이용할 때 50%~60% 이었지만, 표 4에서 보듯이 5개의 특징을 결합한 경우 80%~90%까지 성능 향상이 있다. 그리고 각각의 특징에 가중치를 부여했을 때와 부여하지 않았을 때 약 1% 정도의 인식률 상승을 확인할 수 있었다. 이 수치는 5개의 특징 중 어느 하나가 큰 역할을 하기 보다는 각각이 비슷한 정도의 가중치를 갖기 때문으로 보인다.

특징에 대한 결합 가중치가 크게 영향을 미치는 않는 정확한 이유를 파악하기 위해 5개 DB에서 5개의 특징에 대한 식 (20)으로 추정된 가중치 값을 표 5에 나타내었다.

표 5를 보면 각각의 특징은 평균적으로 0.18~0.22 정도의 가중치를 갖는다. 다섯 개의 특징이 서로 우선순위가 없이 균등할 경우 각각 가중치 0.2라고 볼 수 있기 때문에 학습을 통해 얻어진 가중치는(0.18~0.22) 특정 특징 하나가 다른 특징에 비해 우선 하지도 크게 떨어지지도 않음을 의미한다. 그리고 가중치에 대한 차이가 크지는 않지만 실험에서 사용한 다섯 개의 DB에서는 잔차, 거리비, C-SCI, SCI, MkNN 유사도의 순으로 변별력이 있다고 판단되어 진다.

표 4. 가중치를 이용한 특징 결합 효용성 실험 결과
 Table 4. Experimental results for utility of weight

DB	n=2			n=5		
	w/o	w/	diff	w/o	w/	diff
CT	86.50	86.93	+0.43	89.78	89.94	+0.16
CF	68.64	68.95	+0.31	86.62	86.71	+0.09
GF2	65.40	65.54	+0.14	83.68	83.97	+0.29
IF	73.08	73.87	+0.79	86.23	86.30	+0.07
JFF	83.75	85.37	+1.62	88.32	88.64	+0.32
ORL	81.56	82.11	+0.55	92.36	92.36	+0.0

표 5. 개별 특징에 대한 가중치
 Table 5. The weights for each feature

DB	Residual	C-SCI	d-ratio	MkNN	SCI
IF	0.2262	0.1642	0.2182	0.1923	0.1990
CT	0.2223	0.1928	0.2068	0.1976	0.1805
JF	0.2247	0.2183	0.2122	0.1771	0.1677
ORL	0.2147	0.1954	0.2072	0.1827	0.1999
CF	0.2119	0.1978	0.2002	0.1854	0.2048
평균	0.2199	0.1937	0.2089	0.1870	0.1903

마지막 실험은 그림 1에서 제안한 전체 유효성 검증에 대한 성능을 측정하였다. 교차 타당화 방법을 사용하여 테스트 데이터 중 랜덤하게 선택된 반을 유효성 검증 특징 분포 학습을 위해 사용하고, 나머지 반을 이용하여 인식률을 측정하였다.

더미 클래스의 개수는 총 클래스의 개수의 20%로 더미 클래스의 데이터는 모두 학습에 사용하였고, 무효 클래스는 총 클래스 개수의 30%로 무효 클래스의 데이터는 모두 테스트 데이터로 사용하였다.

SCI와 C-SCI는 유사한 특성을 반영하기 때문에 이번 실험에서는 5개의 특징이 아닌 4개의 특징을 가중치를 학습해 결합하였다. 그리고 제안하는 방법의 효과성을 검증하기 위해 기존에 잘 알려진 SCI만을 이용한 검증 방법과 비교하였다. 표 6, 표 7은 이 실험 결과를 보여 준다.

표 6, 7에서 Phase 1은 무효 데이터는 더미 클래스로 분류되고, 유효 데이터는 유효 클래스로 분류된 비율을 의미하고, Phase 2는 1단계에서 더미클래스로 분류되지 않은 데이터 중, 유효 데이터는 유효라 판단하고, 무효 데이터는 무효라 판단한 비율을 의미하고, Total은 무효 데이터는 더미클래스로 분류되거나 2단계 검증에서 무효로 판단되는 경우, 유효 데이터는 2단계에서 유효로 판단된 경우의 비율을 의미한다.

(검증+분류)는 유효 데이터는 올바른 클래스로 분류되고 무효 데이터는 무효라 판단된 비율을, (분류) 컬럼은 유효 데이터는 올바른 클래스로 분류되고 무효 데이터는 더미 클래스로 분류된 비율을 의미한다. 마지막 SCI 컬럼은 SCI 특징만으로 유효성 판정을 하여 참인 데이터의 비율을 의미한다.

실험결과를 보면 기존 방법인 SCI 만을 이용할 경우 검증률이 매우 낮으며, 제안하는 방법은 모든 경우에 가장 높은 검증률을 보이고 있다.

표 6. 클래스당 두 개의 학습데이터를 사용하고 잔차, 거리-비, MkNN, C-SCI 특징을 사용한 경우의 실험 결과

Table. 6. Experimental results with two training data per class using four features of residual, distance-ratio, MkNN and C-SCI

DB	Phase1	Phase2	Total	(검증+분류)	(분류)	SCI (비교방법)
CT	84.01	86.93	85.40	85.35	94.91	52.88
CF	68.81	68.93	68.86	68.29	69.37	61.24
GF1	71.25	71.09	71.18	70.82	71.08	66.73
GF1	62.90	65.54	63.90	63.31	65.33	59.38
IF	71.76	75.95	73.51	73.26	77.42	59.74
JFF	77.54	85.37	80.44	80.10	92.15	57.61
ORL	85.51	82.11	83.77	83.70	92.54	61.89

표 7. 클래스당 다섯 개의 학습데이터를 사용하고 잔차, 거리-비, MkNN, C-SCI 특징을 사용한 경우의 실험 결과

Table. 7. Experimental results with five training data per class using four features of residual, distance-ratio, MkNN and C-SCI

DB	Phase1	Phase2	Total	(검증+분류)	(분류)	SCI (비교방법)
CT	93.06	90.04	91.21	91.21	97.97	67.33
CF	92.70	86.96	89.47	84.25	84.61	82.42
GF1	92.80	85.56	88.80	88.74	76.37	80.69
GF1	84.77	83.97	84.30	84.14	80.11	78.63
IF	88.53	86.30	87.27	86.98	86.17	77.72
JFF	94.82	88.64	91.40	91.40	97.24	53.19
ORL	98.61	92.36	95.05	95.05	98.69	83.89

V. 결 론

우리는 본 논문에서 새로운 열린 집합 얼굴인식 방법을 제안하였다. 더미 클래스를 이용한 분류를 통한 1 단계 유효성 검증과 유효성 검증을 위한 특징 추출을 통한 2 단계 유효성 검증을 수행하는 ‘분류 후 검증’ 방식을 제안하였다. 이를 위해 4 개의 유효성 검증을 위한 특징을 제안하였고, 이 특징들을 확률적으로 모델링하여 조합하는 결정함수를 제안하였다. 제안한 검증 특징은 희소 표현의 복원 정확성을 의미하는 최소 잔차, 희소해의 분포를 이용한 SCI, 클래스 경계 설정을 의미하는 거리-비, 테스트 데이터가 예측된 클래스에 속할 확률을 의미하는 MkNN 유사도 등 4 개이다. 이 특징들은 각 특징별로 커널을 이용한 사후 확률분포를 추정하여 우도를 구한 후, 가중 합을 하는 방식으로 조합하였다. 우리는 실험을 통해 열린 집합 얼굴 인식의 성능을 측정하였고, 제안한 방법이 희소기반 얼굴인식에서 널리 사용되는 유효성 검증 방법인 SCI 지표에 비해 높은 유효성 검증 성능을 보임을 입증하였다.

우리는 열린 집합 얼굴 인식에 대한 연구를 지속하기 위해 더미 클래스 구성 방식과 학습 클래스의 경계 설정 방법 등 두 가지 향후 연구를 계획하고 있다.

감사의 글

본 연구는 제 1 저자가 수주한 2016년도 강남대학교 교내 연구비 지원 사업에 의하여 이루어진 연구로서, 관계 부처에 감사드립니다.

참고문헌

- [1] W. J. Scheirer, A. Rocha, A. Sapkota and T. E. Boulton, "Toward Open Set Recognition", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 35, No. 7, pp. 1757-1772, July 2013.
- [2] F. Li and H. Wechsler, "Open Set Face Recognition using Transduction", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 27, No. 11, pp. 1686-1697, September 2005.
- [3] P. Li, Y. Fu, U. Mohammed, J. H. Elder and S. J. D. Prince, "Probabilistic Models for Inference about Identity", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 34, No. 1, pp. 144-157, January 2012.
- [4] W. J. Scheirer, L. P. Jain and T. E. Boulton, "Probability Models for Open Set Recognition", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 36, No. 11, pp. 2317-2324, November 2014.
- [5] A. Bendale and T. E. Boulton, "Toward Open Set Deep Networks", Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016.
- [6] G. B. Huang, M. Ramesh, T. Berg and E. Learned-Miller, "Labeled faces in the wild: A database for studying face recognition in unconstrained environments", University of Massachusetts, Amherst, Technical Report 08-49, October, 2007.
- [7] J. Wright, A. Y. Yang, A. Ganesh, S. S. Sastry and Y. Ma, "Robust face recognition via sparse representation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 31, No. 2, pp. 210-227, February 2009.
- [8] D. Needell and R. Vershynin, "Uniform uncertainty principle and signal recovery via regularized orthogonal matching pursuit", *Foundations of Computational Mathematics*, Vol. 9, No. 3, pp. 317-334, June 2009.
- [9] K. Choi and J.-H. Ahn, "Face Recognition via Sparse Representation using the ROMP Method", *Journal of Digital Contents Society*, Vol. 18, No. 2, pp. 151-159, April 2017.
- [10] M. Guillaumin, V. Verbeek and C. Schmid, "Is that you? Metric Learning Approaches for Face Identification", in *Proceeding of 2009 IEEE 12th International Conference on Computer Vision*, pp. 498-505, September 2009.
- [11] C. Cortes and V. Vapnik, "Support-Vector Networks", *Machine Learning*, Vol. 20, No. 3, pp. 273-297, September 1995.
- [12] J. Shao, *Mathematical Statistics*, 2nd ed. Springer, 1994.
- [13] E. Parzen, "On Estimation of a Probability Density Function and Mode", *Annals of Mathematical Statistics*, Vol. 33, No. 3, pp. 1065-1076, 1962.
- [14] Wikipedia. Kernel density estimation. Available: https://en.wikipedia.org/wiki/Kernel_density_estimation
- [15] T. Ahonen, A. Hadid and M. Pietikainen, "Face description with local binary patterns: Application to face recognition", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 28, No. 12, pp. 2037-2041, December 2006.
- [16] P. N. Belhumeur, J.P. Hespanha and D. J. Kriegman, "Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 19, No. 7, pp. 711-720, July 1997.



안정호(Jung-Ho Ahn)

1996년 : 연세대학교 수학과 (이학학사)
1998년 : 연세대학교 수학과 (이학석사)
2001년 : Texas A&M University 통계학과 (이학석사)
2006년 : 연세대학교 컴퓨터과학과 (공학박사-컴퓨터비전, 패턴인식)

2007년~현 재: 강남대학교 컴퓨터미디어정보공학부 교수
2017년~현 재: 강남대학교 소프트웨어응용학부 교수
※ 관심분야 : 패턴인식, 기계학습, 컴퓨터비전, 영상처리 등



최권택(KwonTaeg Choi)

2001년 : 한림대학교 컴퓨터공학과(이학학사)
2006년 : 연세대학교 컴퓨터과학과(이학석사)
2011년 : 연세대학교 컴퓨터과학과(공학박사-패턴인식)

2011년~2015년: LG전자
2016년~현 재: 강남대학교 컴퓨터미디어정보공학부 교수
2017년~현 재: 강남대학교 소프트웨어응용학부 교수
※ 관심분야 : 가상현실, 모바일컴퓨팅, 기계학습, HCI