

ROMP를 이용한 희소 표현 방식 얼굴 인식 방법론

안정호¹ · 최권택^{1*}¹강남대학교 소프트웨어응용학부 가상현실전공

Face Recognition via Sparse Representation using the ROMP Method

Jung-Ho Ahn¹ · KwonTaeg Choi^{2*}¹Division of Software Application, Kangnam University, YongIn-si 16979, Korea

[요 약]

희소 표현을 이용한 얼굴 인식 방법론은 강인성이 입증된 우수한 얼굴 인식 방법으로 알려져 있다. 이 방법론의 단점은 L_1 -노름 최적화 문제를 통해 희소해를 구하는 과정에서 많은 시간이 소요되어 실시간 응용 분야에 적합하지 않다는 것이다. 통상적인 L_2 -노름 최적화 문제를 통해 얻어진 희소해는 희소성이 결여되고 정확도가 떨어져서 희소 표현을 이용한 인식 방법론에는 사용되고 있지 않다. 우리는 본 논문에서는 탐욕적인 방식으로 L_2 -노름 최적화 문제를 푸는 ROMP 방식을 도입해 희소해를 구하는 방법을 제안하고, 실험을 통해 제안한 방식이 정확도에서 기존 방식과 유사하며 속도는 60배 이상 빠름을 보였다. 또한, 희소 표현기반 인식 방법론으로 희소해의 분포만을 고려하여 분류하는 단순한 방식인 C-SCI 방법론을 제안하였다. 이 방법론은 테스트 데이터를 복원하는 기존 방식과 성능 면에서는 유사하나 속도 면에서는 약 5배 빠름을 실험적으로 입증하였고, 이론적인 복잡도 분석 결과도 제시하였다.

[Abstract]

It is well-known that the face recognition method via sparse representation has been proved very robust and showed good performance. Its weakness is, however, that its time complexity is very high because it should solve L_1 -minimization problem to find the sparse solution. In this paper, we propose to use the ROMP(Regularized Orthogonal Matching Pursuit) method for the sparse solution, which solves the L_2 -minimization problem with regularization condition using the greed strategy. In experiments, we shows that the proposed method is comparable to the existing best L_1 -minimization solver, Homotopy, but is 60 times faster than Homotopy. Also, we proposed C-SCI method for classification. The C-SCI method is very effective since it considers the sparse solution only without reconstructing the test data. It is shown that the C-SCI method is comparable to, but is 5 times faster than the existing best classification method.

색인어 : 얼굴인식, 희소 표현, ROMP, C-SCI, LBP

Key word : Face recognition, Sparse representation, ROMP, C-SCI, LBP

<http://dx.doi.org/10.9728/dcs.2017.18.2.347>

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 13 March 2017; Revised 20 April 2017

Accepted 25 April 2017

*Corresponding Author; KwonTaeg Choi

Tel: +82-031-280-3660

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

1. 서론

일상생활에서 상대방의 얼굴을 기억하고 알아보는 것은 인간관계의 기본이다. 마찬가지로 인간-기계 상호 작용에서도 기계가 인간의 얼굴을 인식하는 것은 기본이 되어야 할 것이다. 이러한 이유로 컴퓨터 비전, 패턴인식, 기계학습 등 관련 분야에서는 오래 전부터 얼굴인식(face recognition)에 대한 연구가 꾸준히 이루어졌다.

많은 전문가들이 추후 스마트폰에서 얼굴인식 기술이 기본 기술로 자리 잡을 것이라는 예상을 하고 있다. 이를 증명하듯 최근 출시된 삼성전자와 LG전자의 스마트폰에서 얼굴인식을 이용한 간단한 잠금 해제 기능이 추가되었고, 애플은 이스라엘의 얼굴인식 기술 보유 스타트업인 리얼페이스(RealFace)를 인수하였다.

제약이 없는 환경에서 얼굴은 다양한 포즈와 조명조건에 대한 민감함 등으로 인해, 제약된 환경에서 수행하는 지문인식이나 홍채인식과 같은 생체인식(biometrics) 기술에 비해 얼굴인식 성능은 다소 떨어진다. 하지만 꾸준한 기술 개발로 상용화에 근접하고 있다.

딥러닝(deep learning)에 기반을 둔 방법론들이 최근 인식(recognition) 또는 분류(classification) 관련 연구에서 주목받고 있다. 얼굴 인식 분야에서도 딥러닝에 기반을 둔 방법론들이 좋은 성과를 보였다[1]-[3]. 하지만 딥러닝 모델의 복잡도(complexity)로 인해 수반되는 문제점들이 있다. 딥러닝 모델은 복잡도가 매우 높기 때문에 매우 많은 학습 데이터를 필요로 한다. 이에 학습시간도 길고 효과적으로 학습시키기 위한 숙련된 경험과 기술이 요구된다. 또한, 테스트 시 많은 시간이 소요되기 때문에 즉각적인 처리를 요하는 실시간 처리에 적합하지 않다.

우리는 본 논문에서 희소 표현(sparse representation; SR)에 기반을 둔 얼굴 인식 방법론에 대한 연구결과를 소개한다. 그동안 희소 표현을 이용한 얼굴 또는 영상 인식 방법론은 꾸준히 연구되어 왔다[4]-[10]. 희소표현 기반 방법론은 통계적 신호처리 분야에서 처음 고안되었다[11]. 이는 매우 적은 수의 표본 추출로 신호를 표현, 압축하기 위해 연구되었으나 통계적 추론과 분류 분야에 적용되어 다양하게 응용되고 있다.

희소 표현 방법론은 테스트 데이터가 주어지면 이 데이터를 학습데이터들의 선형조합으로 표현함으로써 복원하는 방법이다. 여기서 선형조합의 계수(coefficient)는 희소성(sparsity; 대부분 0) 제약을 가진다. 학습데이터들의 모음을 사전(dictionary)이라 부른다. 희소 표현은 본질적으로 데이터 복원을 위한 방법론이지만, 어떤 클래스의 데이터들이 복원에 가장 크게 기여하는가를 판단함으로써 분류를 수행할 수 있다. 이러한 이유로 희소 표현에 기반을 둔 분류 방법론들은 단순한 결정 함수(decision function)를 가진다[4].

희소 표현을 이용한 인식 방법론은 얼굴 인식과 같은 영상 분류에 있어서 매우 강인한 성질을 가진다. 영상의 손상이나 잡

음, 대상의 가려짐이나 변장에 대해서도 인식을 저하가 크지 않다. 또한 인식을 위한 특징추출 방법론의 종류에 따라 인식률의 차이가 크지 않은 장점이 있다[4], [6], [10].

희소 분류를 위해 선형 조합의 계수를 구하는 방법에 대해서도 꾸준히 연구되었다. 이는 이론적으로 최소화 문제(minimization problem)로 귀결되는데, 선형 조합의 계수는 이 최소화 문제의 해가 된다. 우리는 이러한 이유로 희소 분류를 위해 선형 조합의 계수를 희소해(sparse solution)라 부른다.

희소 표현 기반 방법론의 단점은 희소해를 구하기 어렵다는 것이다. 정확한 희소해를 구하기는 어렵기 때문에 L_1 또는 L_2 노름기반 방법론으로 희소해를 복원(recovery)한다. 이때 복원은 근사(approximation)와 유사한 의미이다[4], [5].

다음 절에서 희소해의 개념과 관련된 논의를 자세히 소개한다. 우리는 3절에서 L_2 노름기반 방법론인 ROMP(Regularized Orthogonal Matching Pursuit)[13], [14]를 소개하고, C-SCI 분류 방법을 제안한다. 4절에서는 실험을 통해 ROMP 기반 희소해 복원이 기존의 L_1 희소해보다 우월함을 보이고, 제안한 C-SCI 분류 방법이 기존의 최소 잔차 에러를 이용한 분류 방법보다 우월함을 보인다. 그리고 5절에서 결론을 맺는다.

II. 배경

희소 표현(SR)기반 얼굴인식은 다음 식(1)과 같이 테스트 데이터 y 를 학습데이터 행렬 A 의 선형조합으로 표현할 수 있다는 가정 하에 출발한다[4].

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

여기서 x 는 희소해(sparse solution)로 0이 아닌 요소(entry)가 차원에 비해 적어야 하는 제약이 있다. 이러한 인식 프레임에서는 이 희소해 x 를 찾는 것이 중요한 문제가 된다.

위에서 기술된 문제는 다음 식(2)와 같은 l^0 최적화 문제로 정형화 할 수 있다.

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

하지만 이 문제의 해를 직접 구하는 것은 매우 어렵다. 이는 NP 하드 문제이다. 식 (2)는 희소해 x 가 충분히 희소하다는 가정 하에 다음 식(3)과 같은 l^1 최적화 문제의 해로 복원 가능하다.

$$x_1 = \operatorname{argmin} \|x\|_1 \text{ subject to } Ax = y \tag{3}$$

식 (2)는 희소해 x_0 가 충분히 희소하다는 가정 하에 다음 식 (3)과 같은 l^1 최적화 문제의 해 x_1 으로 복원 가능하다. 하지만 일반적으로 다음 식(4)와 같은 l^2 최적화 문제의 해 x_2 는 희소

성을 갖기 어려운 점에서 희소해 x_0 를 복원하기 어려운 것으로 알려져 있다. 우리는 다음 절에서 이에 대한 실험 결과를 제시한다.

$$x_2 = \operatorname{argmin} \|x\|_2 \text{ subject to } Ax = y \tag{4}$$

식 (2), (3)의 제약조건 $Ax = y$ 는 $\|Ax - y\|_2 < \epsilon$ 과 같은 타원으로 대치하여 근사 해를 구한 것과 큰 차이가 없다. 여기서 큰 차이가 없다는 것은 복원의 관점에서 차이가 없음을 의미한다.

희소 표현을 이용한 얼굴 인식 알고리즘에 대한 많은 연구가 이루어지면서, 효율적으로 l^1 최적화 문제를 해결하는 방법들도 함께 연구되었다. 예를 들어, 다음 식(5)와 같이 정규화 항(regularization term)을 추가한 최적화 문제의 해를 구하는 시도도 있었다[5].

$$x_1 = \operatorname{argmin}_x \left(\|Wx\|_1 + \frac{1}{2} \|Ax - y\|_2^2 \right) \tag{5}$$

추정된 해 x 는 이상적으로 자신이 속한 클래스의 학습 데이터에 대해서만 0이 아닌 요소를 갖고, 다른 클래스의 학습 데이터에 대해서는 0에 가까운 값을 갖는다. 이러한 특성을 이용해 분류기를 학습하지 않고, 해 x 의 0이 아닌 요소의 분포를 사용해 인식을 수행한다.

이러한 방법은 전통적인 분류기 기반 학습방법과는 다른 접근방법이다. 전형적인 얼굴 인식 알고리즘은 특징 추출 후 분류기를 사용해 특징 공간에서 분포를 최대한 고려해 클래스 레이블을 결정한다. 학습과정에서 이를 위해 모델 파라미터가 결정되고, 테스트 데이터와 모델 파라미터만을 사용해 빠르게 클래스 레이블을 결정한다. 즉, 학습 단계는 느리고 테스트 단계는 매우 빠른 비대칭 학습 방법이다.

따라서 희소 표현 기반의 얼굴 인식 알고리즘은 테스트 단계에서 알고리즘에 대한 계산 복잡도가 매우 높기 때문에 다양한 응용 분야에 활용되기 위해서는 고속의 희소해 추정 알고리즘이 필요하다.

III. 제안 방법

제안하는 얼굴 인식 알고리즘은 크게 세 부분으로 이루어져 있다. 우선 학습 데이터와 테스트 데이터 모두 특징 추출 알고리즘을 사용해 차원을 축소한다. 다음으로 ROMP 알고리즘을 사용해 희소 솔루션 벡터를 구한다. 마지막으로 희소 솔루션 벡터의 계수 중 특정 클래스에 해당하는 계수의 합이 최대가 되도록 클래스를 결정한다. 특징 추출 방법은 널리 사용되는 알고리즘이기 때문에 본문에서는 ROMP를 이용한 희소 표현과 희소해를 이용한 얼굴 인식 방법에 대해서 설명하고자 한다.

3-1 L2기반 ROMP를 이용한 희소 표현

일반적으로 식 (4)의 L_2 해는 희소성을 갖기 어려워 L_2 해가 L_0 해를 복원할 수 없기 때문에, 우리는 탐욕적인(greedy) 알고리즘인 ROMP 방법에 의해 희소해를 구함으로써 L_0 해를 복원하였다. 그림 1. (a)는 150차원에서 10개 차원에 대해서만 값을 갖는 희소해의 예이다. L_2 기반 알고리즘인 최소자승법(least square method)을 이용해 희소해를 복원하면 그림 1. (b)와 같다. 이와 같이, 일반적으로 L_2 해는 희소성이 없다. 반면, L_1 기반으로 신호를 복원하면 그림 1.(c)처럼 희소성을 갖는다.

일반적으로 L_2 보다는 L_1 최적화 문제의 해가 희소성과 정확성 면에서 모두 우수하다. 하지만 L_1 최적화 문제의 해는 계산 복잡도가 매우 높은 단점이 있다. 희소해의 정확도를 높이면서 계산 복잡도를 낮추기 위한 대표적인 방법으로 OMP (Orthogonal Matching Pursuit) 알고리즘이 있다[12]. 이는 계산 복잡도가 낮은 L_2 방법을 이용하면서 희소성과 정확도를 높이기 위해 탐욕적인 방법을 사용한 알고리즘들 중 하나이다.

OMP 알고리즘은 반복(iteration)할 때 마다 서포트(support; 벡터의 0이 아닌 요소)들을 하나씩 추가하면서 잔차(residual error) $Ax - y$ 를 최소화하는 방향으로 신호를 복원한다. 표 1은 OMP에 안정적인 해를 구하기 위해 정규화(Regularization) 과정을 추가한 ROMP 방법의 의사코드를 보여준다[13], [14].

다시 말해, ROMP는 반복 계산 과정 중 선택된 서포트 개수 만큼 최소자승 해를 구해 점진적으로 잔차를 줄여가는 방식으로 서포트의 개수를 미리 정한 개수, 예를 들어, k 개까지 늘려가는 방법이다. 이 총 서포트 개수 k 를 희소 레벨이라 부른다.

3-2 희소해를 이용한 C-SCI 기반 얼굴 인식

본 논문에서 제안하는 얼굴 인식 방법론은 블록기반 LBP(Local Binary Pattern) [15] 히스토그램을 이용하여 특징을 추출하고, 이 특징벡터를 ROMP를 이용한 L_2 기반 희소 표현 방법으로 희소해를 구하여 새로운 결정함수를 통해 클래스를 추정한다.

표 1. ROMP 의사 코드[14]
Table 1. Pseudo code of ROMP

REGULARIZED ORTHOGONAL MATCHING PURSUIT (ROMP)	
INPUT:	Measurement vector $x \in \mathbb{R}^N$ and sparsity level n
OUTPUT:	Index set $I \subset \{1, \dots, d\}$
Initialize:	Let the index set $I = \emptyset$ and the residual $r = x$. Repeat the following steps until $r = 0$:
Identify:	Choose a set J of the n biggest coordinates in magnitude of the observation vector $u = \Phi^*r$, or all of its nonzero coordinates, whichever set is smaller.
Regularize:	Among all subsets $J_0 \subset J$ with comparable coordinates: $ u(i) \leq 2 u(j) $ for all $i, j \in J_0$, choose J_0 with the maximal energy $\ u_{J_0}\ _2$.
Update:	Add the set J_0 to the index set: $I \leftarrow I \cup J_0$, and update the residual: $y = \operatorname{argmin}_{z \in \mathbb{R}^I} \ x - \Phi z\ _2; \quad r = x - \Phi y$.

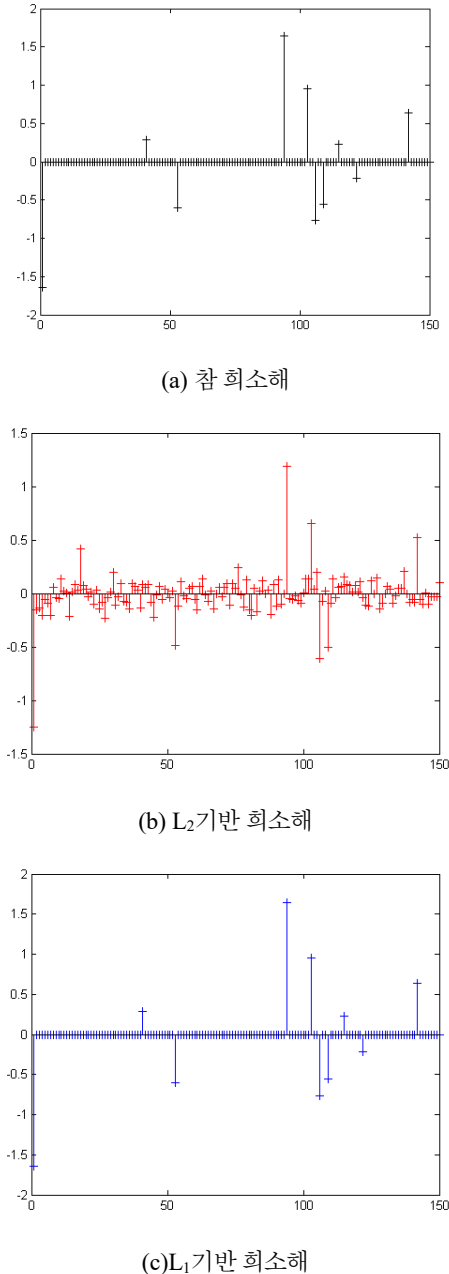


그림 1. L₁, L₂기반 희소해 복원 비교
 Fig. 1. Comparison of sparse solutions by L₁ and L₂ based algorithms

LBP는 텍스처 분류를 위한 기술어(descriptor)로 처음 제안된 후[15] 얼굴인식을 위한 분별력있는 특징으로 입증되어 많은 얼굴인식 연구에서 사용되고 있다[16].

우리는 전처리 작업으로 얼굴영상에서 눈 검출을 수행한 후, 검출된 눈간 간격이 일정하도록 40x40으로 영상 크기를 정규화하고 히스토그램 평활화를 수행하였다. 그리고 정규화된 영상을 25(5x5)개 블록으로 나눈 후, 각 블록마다 LBP 히스토그램을 구하였다.




그림 2. LBP 히스토그램을 이용한 특징 추출
 Fig. 2. Feature extraction using LBP histogram

LBP는 일정한 패턴(uniform pattern)만 취하고 일정하지 않은 패턴은 모두 하나의 레이블로 할당하는 개선된 LBP 특징추출 방식을 사용하였다. 이 방식은 노이즈에 강인하고 코드북 크기가 작아 효율적인 계산이 가능한 특징이 있다[16]. 실험에서 반경이 1이고 8개의 픽셀을 샘플링 하는 방식으로 총 59개의 코드북을 사용하였다.

또한 얼굴의 좌, 우측 하단 블록은 얼굴인식 성능향상에 도움이 되지 않아, LBP 히스토그램 추출을 하지 않았다. 그림 2는 나뉜진 블록과 추출된 LBP 히스토그램들을 보여준다. 이 히스토그램 빈(bin) 값들을 순서대로 연결하여 1357(=59x23)차원의 벡터를 추출한 후, 300개의 LDA(Linear Discriminant Analysis)[17] 축을 이용하여 차원을 축소함으로써 효과적인 계산이 가능하도록 하였다. 이 LDA 축은 301명에 사람에 대해 각 10장씩의 데이터를 학습하여 추출하였다.

희소 표현 기반의 얼굴 인식 알고리즘은 별도의 학습과정 없이 테스트 데이터를 학습데이터의 선형 조합으로 표현할 수 있는 희소해를 찾는다. 따라서 테스트 데이터와 희소해를 이용해 얼굴 인식을 수행한다.

가장 일반적인 알고리즘은 아래 식 (6)과 같은 잔차 오류(residual error)를 최소화하는 방법[4]이다.

$$class = \operatorname{argmin}_i (\|y - A\delta_i(x)\|) \tag{6}$$

식 (6)에서 $\delta_i(x)$ 는 전체 학습데이터에 대한 희소해 벡터 x 에서 i 번째 클래스에 해당하는 값을 제외하고 모두 0으로 출력하는 함수이다. 테스트 데이터 y 와 복구된 신호사이의 에러를 최소화하는 i 를 클래스로 결정한다.

그러나 이 방법은 매번 전체 학습데이터와 희소해를 사용한 많은 곱셈연산이 필요하기 때문에 학습데이터가 많을 경우 계산 비용이 매우 높다.

식 (6)은 행렬 $A \in R^{m \times n}$ 와, 벡터 $\delta_i(x) \in R^{n \times 1}$ 간 곱셈과 m 차원 데이터에 대한 n 번의 잔차 에러 계산, 그리고 n 개 데이터에서 최솟값 탐색이 필요하다. 따라서 식(6)의 계산 복잡도는 대략 $o(mn^2 + mn + n)$ 이 된다.

우리는 이 속도 문제를 해결하기 위해 희소해만을 사용해 효율적으로 클래스를 결정하는 방법을 제안한다. 제안하는 C-SCI(Class Sparsity Concentration Index) 방법론에서는 다음과 같이 클래스를 추정한다.

$$class = \operatorname{argmax}_i (\sum \delta_i(x) / \sum x) \quad (7)$$

$\delta_i(x)$ 함수를 통해 자신의 클래스에 해당하는 희소해의 합이 최대인 i 번째 클래스를 결정한다. 이상적으로는 희소 표현 방법이 자신의 클래스에서는 0이 아닌 계수 값을 갖고 자신의 클래스가 아닌 데이터에 대해서는 0에 가까운 계수가 되는 특성을 이용한 방법이다.

원래 SCI는 테스트데이터의 유효성(validity)을 평가하기 위해 식(8)로 정의되었다[4].

$$sci(x) = \frac{k \max_i \|\delta_i(x)\|_1 / \|x\|_1 - 1}{k-1} \quad (8)$$

여기서 k 는 클래스 수이다. 테스트데이터의 클래스를 결정하는데 k 는 비례상수 역할만을 하기 때문에 제안하는 C-SCI에서는 식(8)에서 k 를 제거해 식(7)로 단순화시켰다.

희소해 벡터에서 클래스별 합연산과 k 클래스에 대해서 최댓값만 찾으면 되기 때문에 계산 복잡도는 $o(n+k)$ 가 된다. 일반적으로 n 이 k 에 비해 매우 크기 때문에 C-SCI 방법의 계산 복잡도는 $o(n)$ 이라 할 수 있다.

희소해만을 사용한다면 단순한 방법은 희소해 벡터 x 에서 최대 요소 값에 해당하는 학습데이터의 클래스로 테스트 데이터의 클래스를 결정하는 방법이다. 최대치(Peak Point)만을 고려한 이 결정 방법은 아래 식(9)와 같이 계산 가능하다.

$$class = \operatorname{Label}(\operatorname{argmax}(x)) \quad (9)$$

단순히 희소해 중 최댓값에 해당하는 학습데이터의 클래스로 결정하기 때문에 특정 데이터 하나에 의존적일 확률이 높다. 희소해 벡터에서 최댓값만 찾으면 되기 때문에 계산 복잡도는 $o(n)$ 이다.

우리는 다음 절에서 최소 잔차를 이용하는 기존 방법(Min-Res), 희소해만을 사용한 C-SCI 값을 이용한 방법, 희소해 중 최댓값만 고려하는 방법(Peak) 등 세 가지 분류 방법에 대한 비교 실험 결과를 제시한다.

IV. 실험

본 절에서 제안하는 방법의 우수성을 검증하기 위해 ROMP를 이용한 희소해 복구 성능에 대한 실험과 3-2에서 기술한 세 가지 희소해 기반 얼굴 인식 방법에 대한 비교 실험 결과를 제시한다. 우리는 두 실험에서 정확도와 처리 시간을 측정하였다.

4-1 희소해 복원 비교 실험

표 2. ROMP와 호모토피 방법을 이용한 희소해 복원 성능 비교
Table 2. Accuracy of sparse solution recovery by ROMP and Homotopy algorithms

	Error	Standard deviation
ROMP	0.0089	0.2806
Homotopy	0.0122	0.3871

이번 실험에서는 ROMP 방법을 현재 가장 우수한 L_1 희소해 탐색 방법인 호모토피(Homotopy) 방법론[5]과 비교하였다. 이를 위해 데이터의 차원이 100이고 100개의 학습데이터(dictionary)를 가진 데이터에 대해 다음과 같은 실험을 수행하였다. 각 학습데이터는 표준정규분포 $N(0,1)$ 에서 랜덤하게 생성하였고, 참 희소해 x 는 임의로 10개의 위치를 선정하여 다음 식(10)과 같이 생성하였다.

$$x \sim 10 \times (U(0,1) - 0.5) \quad (10)$$

여기서 $U(0,1)$ 는 구간 $(0,1)$ 에서 정의된 균일분포(uniform distribution)이다. 이 참 희소해를 계수로 사용하여 학습데이터의 선형조합을 구한 후 백색잡음을 첨가하여, 다음 식(11)과 같이 테스트 데이터 y 를 생성하였다.

$$y = Ax + N(0,1) \quad (11)$$

학습데이터를 $N(0,1)$ 으로부터 생성하였기 때문에, 이 잡음의 양은 과하다고 볼 수 있다. 우리는 이러한 방식으로 테스트 데이터와 참 희소해를 생성하여 1000번 반복 실험을 수행하였다. 표 2는 이 실험의 결과를 보여 준다.

여기서 에러는 참 희소해 x 와 각각의 방법으로 구해진 희소해의 차의 L_2 거리이다. 실험결과를 보면 L_2 기반의 ROMP 방법을 이용하여 구한 희소해가 L_1 기반인 호모토피 알고리즘으로 구한 희소해보다 에러가 작음을 알 수 있다. 1000번의 실험에 대한 표준편차도 ROMP 알고리즘이 작은 것으로 보아 호모토피 알고리즘 대비 더 안정적인 희소해 계산이 가능함을 알 수 있다.

그림 3을 통해 희소성과 정확도면에서 모두 L_2 기반 ROMP 알고리즘이 L_1 기반 호모토피 알고리즘에 비해 희소해를 효과적으로 복구함을 알 수 있다.

다음으로 우리는 ROMP와 호모토피에 대한 계산 복잡도를 측정하였다. 이전 실험과 동일하게 1000번 반복 실험을 수행하여 표 3의 실험 결과를 얻었다.

표 3에서 확인할 수 있듯 ROMP 알고리즘이 호모토피 알고리즘에 비해 60배 이상 빠름을 알 수 있다. 수행 시간에 대한 표준 편차도 상대적으로 작은 것으로 보아 탐욕적 알고리즘이 잘 동작하고 있음을 알 수 있다.

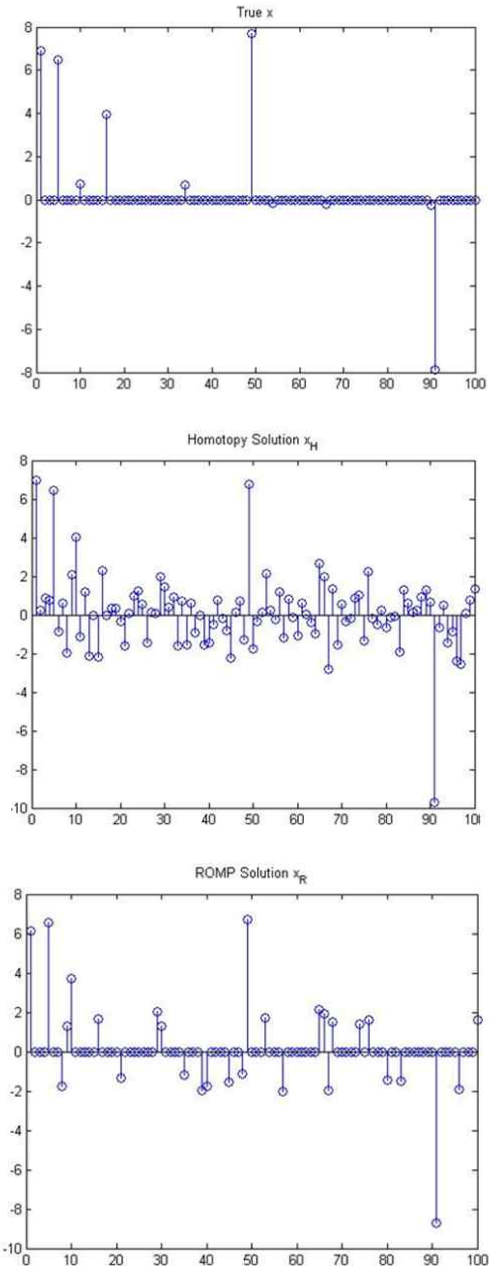


그림 3. ROMP와 호모토피에 의한 희소해 비교
 Fig. 3. Sparse solutions by Homotopy and ROMP algorithms

표 3. ROMP와 호모토피 수행 시간 비교
 Table 3. Comparison of processing time of ROMP and Homotopy algorithms

	Speed	Standard deviation
ROMP	1.4	0.0431
Homotopy	93.1	2.9438




그림 4. ROMP 계산 복잡도 분석(빨간색(+): 학습데이터수변화, 녹색(-): 특징차원변화, 파란색(△): 희소레벨변화)
 Fig. 4. Time complexity analysis of ROMP algorithm (Red(+): change on the number of samples, Green(-): change on the feature dimension, Blue(△): change on the sparse level)

ROMP 알고리즘은 데이터의 차원수, 학습데이터수, 희소레벨에 따라 계산 복잡도가 결정된다. 여기서 희소레벨은 서포트 개수를 말하며 nROMP로 표시한다. 우리는 ROMP의 계산 복잡도 특성을 분석하기 위해 학습데이터수를 1000에서 3000, 특징차원을 100에서 1000, 희소레벨을 10에서 100으로 다양하게 변경해 가며 수행 시간을 측정하였다. 그림 4는 이 실험 결과를 그래프로 나타낸 것이다. 기울기 변화가 가장 크고 비선형적으로 보이는 파란색(△)이 희소레벨의 변화에 따른 계산 시간이고, 기울기 변화가 가장 완만한 빨간색(+)이 학습데이터수 변화에 따른 계산 시간을 나타낸다.

그림 4를 통해 ROMP 알고리즘은 희소레벨이 증가함에 따라 시간 복잡도가 가장 크게 증가함을 알 수 있다. 반면, 학습데이터수와 특징차원수의 증가에 따라 ROMP 알고리즘의 복잡도는 다소 완만하게 증가함을 알 수 있다. 따라서 ROMP 알고리즘의 수행 속도를 줄이기 위해서는 학습데이터 개수와 특징벡터의 차원을 줄이기보다는 소수의 학습데이터로 테스트 데이터들이 표현될 수 있는 특징추출 방법을 이용하거나 학습데이터의 중복성(redundancy)을 줄이는 것이 효과적일 것이다.

4-2 희소 표현을 이용한 얼굴 인식 실험

우리는 3-2에서 제안한 세 인식 방법론의 성능을 평가를 위해 각기 다른 환경에서 촬영된 8개의 얼굴 데이터베이스(DB)를 이용하여 비교 실험을 수행하였다. 이 실험에서 우리는 세 인식 방법론의 인식률과 처리 속도를 측정하여 비교하였다. 실험에 사용한 DB에 대해 데이터수와 클래스 수에 대한 정보는 표 4와 같다.

표 4. 얼굴 인식을 위한 실험 DB 요약

Table 4. Summary of face databases for face recognition performance evaluation

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

얼굴 인식을 위한 특징을 추출하기 위해 각각의 DB의 원본 얼굴 40x40으로 정규화한 후, 각 블록마다 LBP 히스토그램을 구한 후, 독립적으로 학습된 LDA 축을 이용하여 300차원으로 축소하였다. 이러한 방법은 간단한 차원 축소 알고리즘인 PCA 방법[18]에 비해 지역적 변화에 강인하면서도 분별력 있는 특징을 추출한다.

우리는 실험에서 ROMP 알고리즘을 이용하여 희소해를 구하였으며, ROMP의 희소 레벨은 30으로 설정하였다. nROMP의 수 30은 실험적으로 가장 인식률이 높은 값으로 설정하였다. 인식률은 30번의 반복 실험으로 측정하였다. 그리고 적은 학습 데이터를 사용하는 응용분야를 가정하여 클래스 당 학습데이터의 개수를 2, 3, 절반 등 세 가지 경우에 대해 실험하였다.

표 5는 8개 DB에 대해 클래스 당 학습데이터 수가 두 개인 경우의 실험 결과이다. 표에서 세 개의 비교 알고리즘 중 최댓값을 굵은 글씨로 표시하였다.

실험 결과를 보면 두 장의 학습데이터만을 사용하더라도 CT, JFF, ORL 등 세 개의 얼굴 DB에서는 92% 이상의 높은 인식률을 보였으며 나머지 다섯 개 DB에서는 70% 수준의 낮은 인식률을 보였다.

인식률이 높은 세 개의 얼굴 DB는 얼굴 영상의 변화(variation)가 적기 때문에 적은 수의 학습데이터로 테스트 데이터의 복원이 가능하기 때문으로 보인다. 반면, 그 외의 DB는 다양한 환경에서 촬영된 영상이 많기 때문에 복구를 위해 많은 학습데이터가 필요하다고 볼 수 있다.

표 5의 실험 결과를 보면 Min_Res 방법이 5개의 DB에서, C-SCI 방법이 3개의 DB에서 가장 좋은 성능을 나타내었다. Peak 방법은 모든 DB에서 가장 성능이 좋지 않을 뿐만 아니라 두 가지 방법의 인식률에 비해 대략 10% 정도 떨어지는 것으로 나타났다. 이 실험을 통해 희소해만을 사용한 C-SCI 방법과 모든 학습데이터를 사용하는 Min_Res 방법이 큰 성능 차이가 없음을 알 수 있다.

표 5. 얼굴 인식 실험결과(학습 데이터 수 2개)

Table 5. Face recognition results (two training data for each class)

DB	Min_Res	C-SCI	Peak
CT	94.91±1.57	95.27±1.53	91.86±1.91
Yale	57.07±2.37	57.66±2.25	50.48±2.17
CF	69.37±1.07	67.95±1.20	61.89±1.64
GF1	71.08±1.05	68.95±0.85	64.06±1.22
GF2	65.33±0.67	63.04±0.55	56.86±0.58
IF	77.42±1.60	75.92±4.94	72.21±4.74
JFF	92.15±2.44	92.99±2.33	87.08±3.27
ORL	92.54±1.49	91.87±1.51	81.88±1.79

다음으로 클래스 당 다섯 개의 데이터를 사용해 실험하였다. 표 6의 실험결과를 보면 클래스 당 두 장의 학습데이터를 사용했을 때 보다 전체적으로 인식률이 향상됨을 알 수 있다. Min_Res 방법이 4개의 DB, C-SCI 방법이 4개의 DB에서 가장 좋은 성능을 나타내었다. 역시 Peak 방법은 모든 DB에서 가장 성능이 좋지 않았다. C-SCI 방법은 CT, Yale, JFF 등 4개의 DB에서는 학습데이터 수가 2, 5일 때 모두 Min_Res 방법보다 높은 성능을 보였다. 전반적으로 두 개의 인식 방법 Min_Res 와 C-SCI는 인식률에서 큰 성능차가 없는 것을 확인할 수 있었다.

우리는 세 번째 실험으로 절반을 학습데이터로 사용하고 나머지 데이터를 테스트하는 일반적인 방식으로 세 알고리즘을 비교하였다. 이전 실험에서 다섯 장의 학습 데이터를 사용한 실험을 했기 때문에 8 개의 DB 중 클래스당 10개 이상의 데이터를 가지고 있는 CT, Yale, JFF, ORL 얼굴 DB만 사용해 인식률을 비교하였다. 예를 들어, CF 얼굴 DB의 경우 클래스수가 264개이고, 전체 학습데이터수가 1535이기 때문에 평균 6장의 학습데이터만 존재한다. 이러한 이유로 CF 얼굴 DB는 이 실험에서 제외하였다.

표 6. 얼굴 인식 실험결과(학습 데이터 수 5 개)

Table 6. Face recognition results(five training data for each class)

DB	Min_Res	C-SCI	Peak
CT	97.97±0.96	98.51±0.76	90.32±1.40
Yale	72.94±1.59	75.59±1.55	61.86±1.32
CF	84.61±1.14	84.46±1.03	70.08±1.84
GF1	76.37±1.84	75.35±1.03	57.54±2.11
GF2	80.11±0.80	80.21±1.04	67.60±0.91
IF	86.17±1.28	82.20±4.10	75.94±3.81
JFF	97.24±1.76	98.65±1.25	88.88±2.43
ORL	98.69±0.83	98.51±0.81	94.34±1.40

표 7. 얼굴 인식 실험결과(학습 데이터 수 50%)

Table 7. Face recognition results (the half of training data for each class)

DB	Min_Res	C-SCI	Peak
CT	96.89±0.58	97.81±0.78	85.68±2.10
Yale	99.06±0.18	99.36±0.12	94.42±0.29
JFF	99.48±0.79	99.94±0.23	93.43±2.73
ORL	98.63±0.63	98.04±1.00	92.80±1.34

표 8. Min_Res, C-SCI, Peak 알고리즘의 실행 속도 비교

Table 8. Processing time of Min_Res, C-SCI and Peak algorithms

	Min_Res	C-SCI	Peak
2	4.59ms	1.01ms	0.2ms
5	14.16ms	2.47ms	0.5ms

표 7의 실험결과를 보면 50%를 학습 데이터로 사용하면 모든 DB에서 96% 이상의 좋은 인식률을 보였다. 특히 Yale DB에서 많은 성능 향상이 있었다. 이는 Yale DB의 얼굴 변화가 크기 때문으로 보인다. C-SCI 방법이 3개, Min_Res 방법이 1개의 DB에서 우수한 성능을 보이긴 했지만 인식률상의 큰 차이는 없다고 할 수 있다.

위 세 실험을 통해 제안하는 C-SCI 인식 방법이 잔차를 이용한 Min_Res 인식 방법과 유사한 성능을 보여줌을 확인할 수 있었다.

표 8은 본문 3-2에서 살펴본 세 가지 방법에 대해 수행 속도를 보여 준다. 50% 학습데이터를 이용하는 실험의 경우 DB마다 전체 학습데이터 크기가 다르기 때문에 정확한 비교를 위해 배제하였고, 2개 또는 5개를 학습데이터로 사용하는 경우에 대해서 수행 속도를 비교하였다.

표 8을 보면 2개의 학습 데이터 사용시 C-SCI방법이 Min_Res방법에 비해 4배정도 빠르지만 5개의 학습 데이터를 사용할 때는 6배 정도 빠름을 확인할 수 있다. 학습데이터 수에 대해 계산 복잡도 $o(n)$ 인 C-SCI 방법이 계산 복잡도 $o(n^2)$ 인 Min_Res 방법보다 더 빠르게 얼굴 인식을 수행함을 실험적으로도 알 수 있다.

최소 잔차 에러를 이용한 인식방법은 학습데이터를 모두 이용하여 복원하는 방법론으로 인식 성능은 가장 우수한 것으로 평가되었으나 제안한 C-SCI 방법과 큰 차이가 없었으며, 계산 속도는 제안한 다른 두 방법론에 비해 많이 떨어짐을 알 수 있다. 최대치를 이용한 인식 방법(Peak)은 속도는 가장 우수하나 성능이 가장 떨어지는 것을 볼 수 있다.

제안한 C-SCI 방법은 성능 면에서 최소 잔차 에러를 이용한 인식방법과 비교해 큰 차이가 없으며 빠른 계산 속도를 보여 주고 있어, 매우 효율적인 희소 표현 방식을 이용한 인식 방법론이라 할 수 있다.

V. 결 론

희소 표현을 이용한 얼굴 인식 방법론은 영상의 잡음, 손상, 얼굴의 가려짐, 변장 등에 대해 강인한 성질이 있음이 입증된 우수한 방법론이다. 우리는 본 논문에서는 희소 표현을 이용한 얼굴인식에 대해 기존에 연구되지 않았던 새로운 방식을 적용한 연구 결과를 소개하였다. 얼굴 특징의 희소 표현을 위해 기존의 L_1 회소해가 아닌, ROMP를 이용한 L_2 회소해를 구하였다. 우리는 실험을 통해 이 방법론은 기존의 우수한 방법론보다 계산 속도가 빠를 뿐 아니라 정확도가 높음을 확인할 수 있었다.

또한, 희소 표현을 이용한 인식 방법론으로 C-SCI라는 새로운 결정 함수를 제안하였다. C-SCI는 기존 분류 방법과 유사한 성능을 보였으나 계산 복잡도가 월등히 낮음을 실험을 통해 입증하였다.


감사의 글

본 연구는 2015년도 강남대학교 교내 연구비 지원 사업에 의하여 이루어진 연구로서, 관계 부처에 감사드립니다.

참고문헌

- [1] Y. Sun, X. Wang and X. Tang, "Deep learning face representation from predicting 10,000 classes", in *Proceeding of 2015 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1891-1898, June 2014.
- [2] Y. Sun, X. Wang and X. Tang, "Robust face recognition via multimodal deep face representation", *IEEE transactions on Multimedia*, Vol. 17, No. 11, pp. 2049-2058, September 2015.
- [3] A. T. Tran, R. Hassner, I. Masi and G. Medioni, "Regressing robust and discriminative 3D morphable models with a very deep neural network", arXiv preprint arXiv:1612.04904, 15, December, 2016.
- [4] 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.
- [5] A. Yang, S. Sastry, A. Ganesh and Y. Ma, "Fast L_1 -minimization algorithms and an application in robust face recognition: A review", in *Proceeding of International Conference on Image Processing*, pp. 471-478, October 2010.
- [6] L. Zhang, M. Yang and X. Feng, "Sparse representation or collaborative representation: Which helps face recognition?",

- in *Proceeding of ICCV'11 International Conference on Computer Vision*, pp. 471-478, November 2011.
- [7] T. Guha and R. W. Ward, "Learning Sparse Representations for Human Action Recognition", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 34, No. 8, pp. 1576-1588, August 2012.
- [8] J. Wang, C. Lu and M. Wang, "Robust face recognition via adaptive sparse representation", *IEEE Transactions on Cybernetics*, Vol. 44, No. 12, pp. 2368-2378, December 2014.
- [9] Z. Fan, M. Ni, Q. Zhu and E. Liu, "Weighted sparse representation for face recognition", *Neurocomputing*, Vol. 151, No. 1, pp. 304-309, March 2015.
- [10] Z. Zhang, Y. Liang, L. Bai and E. R. Hancock, "Discriminative sparse representation for face recognition", *Multimedia Tools and Applications*, Vol. 75, No. 7, pp. 3973-3992, April 2016.
- [11] E. J. Candes and M. B. Wakin, "An Introduction to compressive sampling", *IEEE Signal Processing Magazine*, Vol. 25, No. 2, pp. 21-30, March 2009.
- [12] V. Temlyakov, "Nonlinear methods of approximation", *Foundations of Computational Mathematics*, Vol. 3, No. 1, pp. 33-107, January 2003.
- [13] T. Blumensath and M. E. Davies, "Gradient Pursuits", *IEEE Transactions on Signal Processing*, Vol. 56, No. 6, pp. 2370-2382, May 2008.
- [14] 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.
- [15] T. Ojala, M. Pietikainen and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 24, No. 7, pp. 971-987, July 2002.
- [16] 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.
- [17] 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.
- [18] J.-M. Kim and K.-J. Lee, "Real Time Face Detection and Recognition using Rectangular Feature Based Classifier and PCA-based MLNN", *Journal of Digital Contents Society*, Vol. 11, No. 4, pp. 417-424, December 2010.



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