

논문 2017-54-3-7

## 비음수 행렬 분해와 학습 벡터 양자화를 이용한 얼굴 인식

## ( Face Recognition using Non-negative Matrix Factorization and Learning Vector Quantization )

진 동 한\*, 강 현 철\*\*

( Donghan Jin and Hyunchul Kang<sup>Ⓢ</sup> )

## 요 약

비음수 행렬 분해 기법(non-negative matrix factorization)은 대표적인 부분 영역 기반 표현 기법의 하나로 영상의 부분적인 특징을 나타내는 기저 벡터의 선형 조합으로 영상을 표현하는 기법이다. 본 논문에서는 여러 가지 비음수 행렬 분해 기법을 이용하여 얼굴 영상을 표현하고, 추출된 특징을 기반으로 학습 벡터 양자화를 이용하여 얼굴 인식을 수행하였다. 추출된 각 기법의 기저 벡터를 비교하여 각 기법의 특징을 분석하였다. 또한 NMF 기법들의 인식을 검증을 통해 비음수 행렬 기법의 얼굴 인식에 대한 활용 가능성을 확인하였다.

## Abstract

Non-negative matrix factorization (NMF) is one of the typical parts-based representation in which images are expressed as a linear combination of basis vectors that show the local features or objects in the images. In this paper, we represent face images using various NMF methods and recognize their face identities based on extracted features using a learning vector quantization. We analyzed the various NMF methods by comparing extracted basis vectors. Also we confirmed the availability of NMF to the face recognition by verification of recognition rate of the various NMF methods.

Keywords : face recognition, NMF, parts-based representation, local feature, learning vector quantization

## I. 서 론

컴퓨터 시각(computer vision)은 기계에 시각적 인지 능력을 부여하는 것으로 입력 영상 데이터로부터 유용한 정보를 추출하고 이를 분석, 이해하는 수준을 인간과 동등한 수준까지 구현하는 것을 목표로 한다. 얼굴 인식은 컴퓨터 시각의 주요한 연구 분야 중 하나로 얼굴 인식은 정지영상이나 동영상에 포함된 사람의 얼굴을 추출하고 얼굴 데이터베이스에 저장된 인물 중에서 어떤 인물에 해당하는지를 판별하는 일련의 과정을 의미한다.

얼굴 인식은 생체 인식 기법 중 하나로 개인 및 특정 집단의 정보 보호를 위한 컴퓨터 접근 제한, 출입문 통제, 공공장소에서의 감시 장치, 범죄자 검색 등 다양한 응용 가능성으로 주목 받고 있으며 활발히 연구되고 있는 분야이다<sup>[1~3]</sup>. 그러나 얼굴 인식은 얼굴 표정, 조명, 헤어스타일, 안경의 착용여부 등에 따라 인식을 변화가 심하기 때문에 상대적으로 실용화가 어려운 분야이다. 이와 같은 문제를 해결하기 위하여 다양한 불변적 인식 파라미터 설정과 인식을 향상에 대한 연구가 진행되었으며, 다양한 얼굴 인식 기법과 체계적인 평가 방법들이 제시되었다<sup>[4]</sup>.

기존의 얼굴 인식 기법은 고차원 데이터를 저차원으로 줄이는 선형 변환 방식을 많이 사용하는데, 대표적인 방식으로는 데이터의 상관행렬(covariance matrix)에서 변동이 심한 방향을 찾는 주성분 분석(principal component analysis)<sup>[5]</sup>, 학습 단계에서 클래스의 구분에

\* 학생회원, \*\* 정회원, 인천대학교 정보통신공학과  
(Dept. of Information and Telecommunication Eng.,  
Incheon National University)

Ⓢ Corresponding Author(E-mail : hckang@inu.ac.kr)

Received ; November 10, 2016 Revised ; February 7, 2017

Accepted ; February 16, 2017

중점을 두는 선형 판별식 분석(linear discriminant analysis)<sup>[6]</sup>, 통계적 독립성을 이용하여 독립적인 성분만을 추출하는 독립성분 분석(independent component analysis)<sup>[7]</sup> 등이 있다. 그러나 이러한 선형 변환 방식들은 영상에서 전역적인 특징(holistic feature)을 추출하기 때문에 표정이나 조명의 변화에 의한 얼굴 영상의 부분적인 변형에 잘 적응하지 못한다. 본 논문에서는 영상의 지역적인 특징(local feature)을 기저 벡터로 하는 비음수 행렬 분해를 이용하여 얼굴 영상을 표현하고 인식하는 방법을 제안한다. 비음수 행렬 분해는 다른 비지도 학습(unsupervised learning) 기법들과 마찬가지로 데이터 행렬에 제약을 가지고 분해하는 알고리즘이다. 비음수 행렬 분해는 비음수성 제약(non-negativity constraint)을 가지며 이 제약을 통해 데이터의 부분 표현을 학습하기에 유용하다고 알려져 있으며, 오디오 인식<sup>[8]</sup>, 차량 인식<sup>[9~10]</sup>에 적용되는 등 여러 응용 분야에서 사용되고 있다.

II. 비음수 행렬 분해

선형 변환(linear transformation)은 컴퓨터 시각이나 기계 학습과 같은 분야에서 고차원 데이터의 분석 문제를 해결하는데 유용하게 사용되어 왔다. 선형 변환 기반의 방법들은 입력 영상 데이터를 표현하는 기저 벡터(basis vector)의 집합을 구하며 입력 영상을 기저 벡터들에 투영하여 구해진 계수를 특징 및 데이터 표현에 이용한다. 이러한 방법을 이용한 인식은 입력 영상 데이터의 특성에 의존적이며, 영상 데이터의 부분적인 변형은 인식 성능에 큰 영향을 주게 된다. 또한 기존의 대표적인 선형 변환 방식들은 데이터의 전역적인 특성을 사용함으로써 데이터 내에 존재하는 지역적인 정보에 대한 표현이 불가능하다는 단점을 가지고 있다.

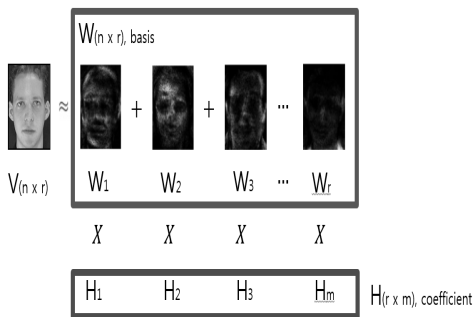


그림 1. NMF 선형 조합의 예  
Fig. 1. Example of linear combination in NMF.

전체적인 특성을 표현하는 이전의 선형 변환 방식이 가진 문제점을 해결하기 위하여 비음수 행렬 분해가 연구되었다.

비음수 행렬 분해(non-negative matrix factorization, NMF)<sup>[11]</sup>는 다변량 분석기법으로 다른 비지도 학습 알고리즘들과 마찬가지로 데이터 행렬에 제약을 가지고 분해하는 알고리즘이며 입력 데이터가 양의 값을 가지고 있는 경우 유용하게 사용될 수 있는 비음수 제약을 가지며, 데이터의 지역적인 특징을 찾아 의미 있는 특징의 학습이 가능하다. NMF는 사람의 두뇌가 입력되는 영상의 부분적 특징에 근거한 인식을 수행한다는 것에 착안하여 이를 알고리즘으로 구현한 것이다.

NMF를 제안한 Lee와 Seung<sup>[12]</sup>은 NMF를 얼굴 영상에 적용하여 얼굴을 눈, 코, 입 등의 직관적으로 인식 가능한 부분들을 표현하는 기저 벡터의 선형 조합으로 표현할 수 있다는 것을 증명하였다<sup>[13]</sup>.

1. 표준 NMF(Standard NMF, S-NMF)

S-NMF는 고차원의 영상 데이터 행렬을 저차원의 기저 벡터와 계수 벡터로 분해하고 각 벡터들이 최소 특성을 가지기 때문에 부분 영역 기반 표현<sup>[14]</sup>이 가능하다는 장점이 있다. S-NMF는 영상 데이터베이스 행렬  $V$ 를 생성하기 위하여 2차원의 영상을 1차원의 벡터로 변환하여 각 열(column)에 저장한다. 생성된 행렬  $V$ 를 S-NMF를 통하여  $W$ 와  $H$ 로 분해한 후 재구성 행렬(reconstruction matrix)  $WH$ 가 영상 데이터베이스 행렬에 근사하게 수렴하도록 반복적인 갱신 규칙을 수행한다. 영상 데이터베이스 행렬  $V$ 는 식 (1)과 같이 기저 행렬과 계수 행렬로 분해된다.

$$V \approx WH \tag{1}$$

$n \times m$  크기의 영상 데이터베이스 행렬  $V$ 는 S-NMF를 이용하여  $n \times r$  크기의 기저 행렬  $W$ 와  $r \times m$  크기의 계수 행렬  $H$ 로 분해된다.  $n$ 은 영상 데이터베이스를 구성하는 영상 한 장에 대한 차원을 나타내고,  $m$ 은 영상 데이터베이스 행렬에 저장된 영상의 개수를 나타낸다.  $r$ 은 기저 행렬  $W$ 를 구성하는 기저 벡터의 개수나 각 계수 벡터의 차원과 같고 일반적으로  $(n+m)r < nm$ 을 만족해야 하는 제약 조건이 존재한다<sup>[5]</sup>.  $V$ 와 근사하도록 만드는  $W$ 와  $H$ 를 생성하기 위해 NMF에서는  $V$ 와  $WH$ 의 차이인 목적함수  $F$ 를 식 (2)와 같이 정의하고 이를 최소화함으로써 반복적인 갱신을 멈추게 된다.

$$F = \sum_{i=1}^n \sum_{\mu=1}^m [V_{i\mu} \log(WH)_{i\mu} - (WH)_{i\mu}] \quad (2)$$

W와 H의 계산은 반복적인 갱신을 통해 이루어지는데 갱신 규칙에 따라 계산 복잡도와 갱신 속도 그리고 기저 형태가 조금씩 다르게 나타난다. S-NMF는 목적 함수 F의 수렴을 위하여 KL divergence를 이용하기 때문에 갱신 규칙은 식(3)과 (4)와 같이 나타낼 수 있다.

$$W_{nr}^{k+1} \leftarrow W_{nr}^k \frac{(V(H^{k+1})^T)_{r,m}}{(W^k H^{k+1} (H^{k+1})^T)_{nr}} \quad (3)$$

$$H_{rm}^{k+1} \leftarrow H_{rm}^k \frac{((W^k)^T V)_{r,m}}{((W^k)^T W^k H^k)_{nm}} \quad (4)$$

갱신 규칙은 곱셈 갱신 규칙(multiplicative update rule)으로, 기울기 하강(gradient descent)방법과 유사하게 동작하며 현재의 W와 H의 값에 예측값을 곱하여 목적함수 F를 최소화 할 수 있는 방향으로 갱신된다. 갱신된 W와 H는 부분적인 편차를 갖게 되고 행렬 상호간, 내부적으로 직교하는 방향으로 변화하게 된다. 따라서 부분 영역 기반 표현에서 요구하는 희소성(sparseness) [15~16]을 만족할 수 있게 된다.

## 2. Projected Gradient NMF(P-NMF)

S-NMF 기법은 얼굴 영상에 대해서 눈, 코, 입 등 공통된 특징을 갖는 기저를 추출하였으나 해상도가 낮은 영상으로부터 공통된 특징을 나타내는 기저를 얻지 못한다. S-NMF 기법은 구현 과정이 간단하지만 V와 WH 사이의 거리를 근사화하는 방법은 국부 최소점(local minimum)으로의 수렴을 보장하지 못한다. 이는 학습과정에서 기저의 희소성에 대한 제약 조건의 설정에 따라 달라지는 NMF의 특성에 기인하기 때문이다. 이와 같은 문제점을 보완하기 위하여, Lin은 Projected Gradient NMF를 제안하여 주어진 얼굴 데이터 영상으로부터 W와 H의 값을 학습하였다[17].

$$(\tilde{W}; \tilde{H}) \equiv P[(\bar{W}; \bar{H}) - \alpha(\nabla_{Wf}(\bar{W}; \bar{H}), \nabla_{Hf}(\bar{W}; \bar{H}))] \quad (5)$$

이 때,  $\alpha$ 는 학습 속도를 결정하는 파라미터이며,  $\nabla_{Wf}()$ 와  $\nabla_{Hf}()$ 는 각 W와 H에 대한 f의 도함수를 나타낸다. 이 방법은 빠른 속도로 국부 최소점으로의 수렴이 보장된다. S-NMF의 방법은 학습 영상에 대해 뚜렷하지 않은 형태의 기저를 얻는 반면 P-NMF 방법은 보다 뚜렷한 형태의 기저를 얻을 수 있다.

## 3. 직교 NMF(orthogonal NMF, O-NMF)

O-NMF<sup>[18]</sup>는 NMF의 기저 벡터들이 서로 직교하지 않는다는 것에 착안하여 제안된 알고리즘<sup>[18-19]</sup>이다. 식 (1) 형태의 분해를 찾으나, 행렬 W 또는 행렬 H가 직교 제한( $W^T W = I$  또는  $H^T H = I$ )을 만족하도록 하는 것이다<sup>[11]</sup>.

$W^T W = I$ 인 경우에 기저에 직교 제약을 적용한 방법으로 라그랑지안  $\tilde{\varepsilon}$ 를 고려한다.

$$\tilde{\varepsilon} = \frac{1}{2} \|X - WH\|^2 + \frac{1}{2} \text{tr} \Omega(W^T W - I) \quad (6)$$

$\Omega \in R^{n \times n}$ 은 라그랑지안 곱셈 매트릭스를 나타내며  $\Omega$ 는 최적값(optimal value)을 포함한다. 또한 Ding et al.<sup>[19]</sup>은 식 (7)과 (8)의 알고리즘을 제안하였다.

$$H \leftarrow H \odot \frac{W^T X}{W^T W H} \quad (7)$$

$$W \leftarrow W \odot \left( \frac{X H^T}{W W^T X H^T} \right)^{\cdot \frac{1}{2}} \quad (8)$$

$(\cdot)^{\cdot \frac{1}{2}}$ 는 요소별 제곱근(element-wise square root)을 나타낸다. Stiefel 다양체[20]에서는 변화율 값을 식 (9)를 이용하여 계산한다.

$$\begin{aligned} \widetilde{\nabla_{W\varepsilon}} &= \nabla_{W\varepsilon} - W[\nabla_{W\varepsilon}]^T W \\ &= [\widetilde{\nabla_{W\varepsilon}}]^+ - [\widetilde{\nabla_{W\varepsilon}}]^- \\ &= [W H X^T W] - [X H^T] \end{aligned} \quad (9)$$

그러므로 O-NMF의 곱셈 갱신 규칙 형태는 다음과 같다.

$$H \leftarrow H \odot \frac{W^T X}{W^T W H} \quad (10)$$

$$W \leftarrow W \odot \frac{X H^T}{W H X^T H} \quad (11)$$

H에 대한 곱셈 갱신 규칙은 S-NMF와 같은 방법을 사용한다.  $H^T H = I$ 인 경우에 O-NMF는 쉽게 유도될 수 있다.  $H^T H = I$ 를 만족하는 Stiefel 다양체의 변화율 값은 식 (12)와 같이 계산할 수 있다.

$$\begin{aligned} \widetilde{\nabla_{H\varepsilon}} &= \nabla_{H\varepsilon} - H[\nabla_{H\varepsilon}]^T H \\ &= [\widetilde{\nabla_{H\varepsilon}}]^+ - [\widetilde{\nabla_{H\varepsilon}}]^- \\ &= [H X^T W H] - [W^T X] \end{aligned} \quad (12)$$

$H$ 에 대한 곱셈 갱신 규칙은 식 (13)처럼 구할 수 있으며  $W$ 에 대한 갱신 규칙은 S-NMF와 같다.

$$H \leftarrow H \odot \frac{W^T X}{H X^T W H} \quad (13)$$

### III. 얼굴 인식

#### 1. NMF를 이용한 얼굴 인식 시스템

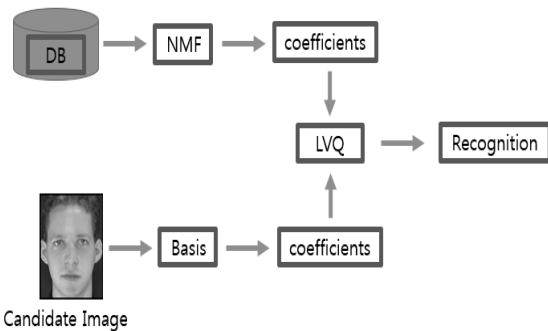


그림 2. 제안하는 얼굴 인식 시스템  
Fig. 2. Proposed face recognition system.

NMF를 이용한 얼굴 인식 시스템은 그림 2와 같다. NMF는 신경망의 구조와 유사하다는 특징을 갖고 있다. NMF에 의해 분해된 두 행렬은 신경망의 가중치 행렬과 입력 행렬과 유사하게 동작하기 때문에 자체적인 분류 능력이 뛰어나며, 추가적인 연산 없이 기저 행렬을 사용하여 결정 경계를 설정할 수 있다.

제안하는 얼굴 인식 시스템에서는 먼저 얼굴 영상을 NMF를 적용하여 계수 행렬을 추출한다. 다음 얼굴 영상을 데이터베이스 영상과 비교하여 인식한다.

본 논문에서는 분류기로 신경망 중의 하나인 학습 벡터 양자화(learning vector quantization, LVQ)를 사용하는데, 지도 학습과 분산 처리가 가능하다는 특징을 갖고 있다.

#### 2. 학습 벡터 양자화

신경망 모델 중 학습 벡터 양자화는 Kohonen<sup>[21]</sup>이 제안한 통계적 패턴 인식 방법의 하나로, Self Organization Feature Map(SOFM)과 밀접한 관계를 가지고 있다. 최근의 물체 인식 연구에서 분류기로 신경망을 많이 사용하고 있는 데, 신경망 중에는 다층 신경망(multi-layer neural network) 방식이 많이 사용되고 있다. 그러나 다층 신경망의 경우 네트워크의 크기에 따라 인식 성능이 결정되고 학습 시간이 오래 걸리게 되는 문제점이 있다. 이러한 단점을 개선할 수 있는 신경망 모델 중 하나

가 LVQ이다. LVQ 알고리즘은 클러스터(참조 벡터)의 수, 학습율과 같은 알고리즘 인자들을 설정하고 각 클러스터 중심(centroid)을 임의의 값으로 초기화한다. 그 다음 유클리드 거리 기반의 경쟁 학습을 통해 클러스터의 중심을 수정하면서 학습을 진행하는 알고리즘이다.

#### 가. LVQ1

LVQ1은 입력 벡터와 유사한 클러스터의 중심은 입력 벡터와 가깝도록 수정하고 다른 부류의 클러스터 중심은 입력 벡터와 멀어지도록 수정한다. 따라서 LVQ1에서는 식 (14)를 이용하며, 여기서  $W$ 는 승자로 선택된 클러스터의 번호이다.

$$V_{ij}(t+1) = \begin{cases} V_{ij}(t) + \eta(X_{kj} - V_{ij}), & i = W \\ V_{ij}(t) - \eta(X_{kj} - V_{ij}), & i \neq W \end{cases} \quad (14)$$

#### 나. LVQ2

LVQ2는 LVQ1과 같은 구조를 갖는데, 승자로 선택되지 않은 모든 클러스터를 입력 벡터와 멀어지도록 학습하는 것이 아니라 유클리드 거리가 두 번째로 짧은 클러스터만 입력 벡터와 멀어지도록 학습하는 것이 다른 점이다. 즉, 승자로 선택된 클러스터의 중심  $V_W$ 는 식 (15)와 같이 수정되고 유클리드 거리가 두 번째로 짧은 클러스터의 중심  $V_Q$ 는 식 (16)과 같이 수정된다.

$$V_W(t+1) = V_W(t) + \eta(X_k - V_W) \quad (15)$$

$$V_Q(t+1) = V_Q(t) - \eta(X_k - V_Q) \quad (16)$$

### IV. 실험 결과 및 분석

#### 1. 실험 환경

ORL 얼굴 데이터베이스와 YALE 얼굴 데이터베이스를 사용하여 학습과 인식 실험을 하였고 그 중 일부를 각각 그림 3과 그림 4에 나타내었다.

ORL 데이터베이스와 YALE 데이터베이스를 구성하는 영상 한 장의 크기는 92×112이다.



그림 3. ORL 얼굴 이미지 일부  
Fig. 3. Selected ORL face images.



그림 4. YALE 얼굴 이미지 일부  
Fig. 4. Selected YALE face images.

## 2. 기저 형태의 비교

ORL 얼굴 데이터베이스는 40명의 얼굴, 사람 당 10장, 총 400장의 이미지로 구성되어 있으며 그 중 360장은 학습에 사용하고 나머지 40장은 인식 실험에 사용하였다. YALE 얼굴 데이터베이스는 15명의 얼굴, 사람 당 11장, 총 165장의 이미지로 구성되어 있으며 그 중 150장은 학습에 사용하고 나머지 15장은 인식 실험에 사용하였다. 학습 이미지 행렬  $V$ 는 각각  $10,304(92 \times 112) \times 360$ (영상 개수)와  $10,304(92 \times 112) \times 150$ (영상 개수)로 구성되며 각각의 NMF에 적용하여 추출한 기저 벡터의 일부를 그림 5에서 그림 10에 나타내었다.

Number of basis	S-NMF Feature
50	
75	
100	
125	
150	

그림 5. S-NMF 기저 벡터의 일부 (ORL)  
Fig. 5. Selected S-NMF basis vectors. (ORL)

number of basis	S-NMF Feature
50	
75	
100	
125	
150	

그림 6. S-NMF 기저 벡터의 일부 (YALE)  
Fig. 6. Selected S-NMF basis vectors. (YALE)

Number of Basis	P-NMF Feature
50	
75	
100	
125	
150	

그림 7. P-NMF 기저 벡터의 일부 (ORL)  
Fig. 7. Selected P-NMF basis vectors. (ORL)

number of basis	P-NMF Feature
50	
75	
100	
125	
150	

그림 8. P-NMF 기저 벡터의 일부 (YALE)  
Fig. 8. Selected P-NMF basis vectors. (YALE)

Number of Basis	O-NMF Feature
50	
75	
100	
125	
150	

그림 9. O-NMF 기저 벡터의 일부 (ORL)  
Fig. 9. Selected O-NMF basis vectors. (ORL)

number of basis	O-NMF Feature
50	
75	
100	
125	
150	

그림 10. O-NMF 기저 벡터의 일부 (YALE)  
Fig. 10. Selected O-NMF basis vectors. (YALE)

그림에서 기저 벡터의 개수에 따라 추출되는 기저 벡터의 모습이 다름을 확인할 수 있다.

그림 5와 6의 S-NMF 기저 벡터는 전체적인 윤곽이 잘 보이는 이미지의 형태를 가지고 있다. 때때로 수렴에 실패하는 경우에는 기저들이 직교하지 않게 되기 때문에 얼굴 이미지의 부분적인 모습보다는 얼굴 전체를 표현하는 것을 확인할 수 있다.

그림 7과 8의 P-NMF 기저 벡터는 공통적으로 나타나는 부분을 특징으로 잘 표현함을 알 수 있다<sup>[23]</sup>. S-NMF에 비하여 얼굴의 부분적인 모습을 나타내는 기저 벡터가 많으나 여전히 얼굴의 전체적인 모습을 나타내는 기저 벡터가 존재함을 확인할 수 있다.

그림 9와 10은 W 행렬에 직교 제약을 추가한 O-NMF의 기저 벡터의 모습이다. 기저 행렬의 중복성을 제거하였기 때문에 S-NMF와 P-NMF와는 다르게 직관적으로 얼굴의 각 부분(눈, 코, 입, 귀 등)들이 도드라지게 나타남을 알 수 있다<sup>[22]</sup>.

각각의 NMF 알고리즘은 기저 벡터의 수가 적을수록 얼굴의 전체적인 모습을 표현하는 경우가 많았으며 S-NMF, P-NMF에 비해 O-NMF가 얼굴의 부분적인 특징을 보다 잘 표현함을 확인할 수 있다.

3. 실험 결과

기저 벡터의 개수에 따른 각 NMF 알고리즘의 인식률을 표 1과 그림 11과 12에 각각 나타내었다.

표 1. 기저 벡터의 수에 따른 NMF 알고리즘 인식률 Table1. Recognition rate of the various NMF methods according to number of basis.

number of basis \ NMF		25	50	75	100	125	150
		S-NMF	ORL 79.7	83	85.6	86.1	86.8
	YALE 78.3	80.1	82	83.1	85.5	85	
P-NMF	ORL 86.1	88.7	89.3	90	89.3	88.3	
	YALE 83.6	85.7	87	89.3	90.7	90.1	
O-NMF	ORL 76.3	77.7	80.1	82.3	82.7	82.6	
	YALE 78	79.3	80.3	81.3	82	82.3	
PCA	ORL 73	87.8	88	88.3	88.3	88.2	
	YALE 75.1	82.3	85.1	85.3	86.7	86.7	

기저 벡터의 개수가 많을수록 인식률은 높아지다가 125개 이후로 낮아지는 데, 이는 특징의 개수가 불필요하게 많아져 발생하는 차원의 저주(curse of dimensionality)로 생각할 수 있다. 차원의 저주란 패턴인식 시스템에서 특징의 개수가 많아지면 인식 성능이 향상될 것으로

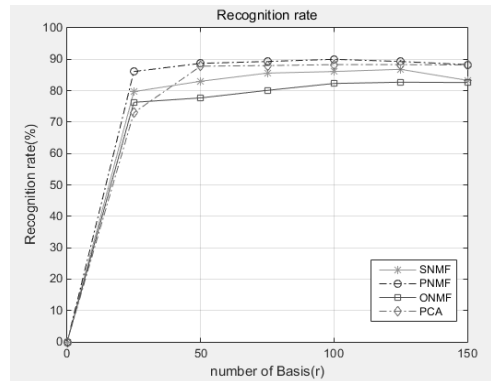


그림 11. 인식률 비교 (ORL)

Fig. 11. Comparison of recognition rate of the various NMF methods. (ORL)

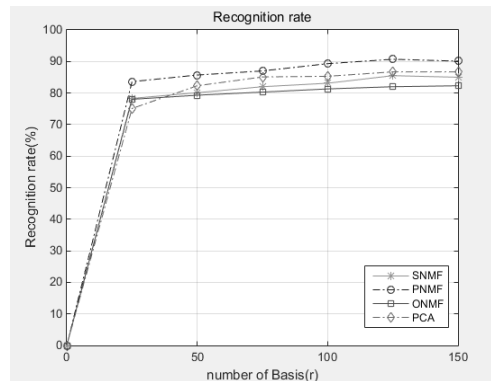


그림 12. 인식률 비교 (YALE)

Fig. 12. Comparison of recognition rate of the various NMF methods. (YALE)

기대되지만 오히려 패턴 인식기의 성능이 떨어지고 인식률도 떨어지는 현상을 말한다. 즉, 중요도가 낮은 특징이 많을수록 성능에 나쁜 영향을 미친다는 것이다. 각 알고리즘의 인식률을 확인하면 P-NMF가 S-NMF와 O-NMF, PCA에 비해 더 높은 인식률을 얻을 수 있었다.

V. 결론

전역적인 특징을 나타내는 선형 변환 기법에 비하여 부분 영역 기반 표현 기법은 눈, 코, 입 등의 얼굴의 부분적인 특징을 표현할 수 있기 때문에 가려진 얼굴 또는 부분적인 훼손이 있는 경우에도 강인한 특성을 갖는다. 본 논문은 부분 영역 기반 표현인 비음수 행렬 분해 기법을 이용하여 효과적으로 얼굴의 지역적인 특징을 추출하고, 이를 학습 벡터 양자화를 이용하여 얼굴을 인식하는 시스템을 제안하였으며, 여러 가지 비음수 행렬 기법의 성능을 비교, 분석하였다.

S-NMF의 경우, 학습 영상에 대하여 전체적인 모습

을 나타내는 기저 벡터를 얻는 반면 O-NMF는 직교 제약을 부여함으로써 희소성(sparseness)이 높은 기저 벡터를 획득할 수 있었으며 결과적으로 얼굴의 부분적인 모습을 잘 나타내는 기저 벡터를 얻을 수 있었다. P-NMF의 기저 벡터는 S-NMF와 O-NMF의 기저 벡터의 중간 정도의 모습을 보였다.

S-NMF, P-NMF, O-NMF의 인식률은 ORL 얼굴 데이터베이스를 대상으로 하였을 경우, 86.8%, 89.3%, 82.7%이고, YALE 얼굴 데이터베이스를 대상으로 하였을 경우, 85.5%, 90.7%, 82.0%를 보였으며, 이는 각각 88.3% (ORL), 86.7%(YALE)를 보인 PCA 기법보다 우수한 성능을 보임을 확인할 수 있다. 인식에 사용하는 기저 벡터의 개수는 125개 정도가 적당함을 확인할 수 있었다.

NMF를 이용한 부분 영역 기반 표현 기법은 많은 연산을 필요로 하므로 기저 벡터를 추출할 때 데이터 량에 따라 많은 시간이 소요되며, 수렴속도가 느리다는 단점이 있기 때문에 속도가 빠른 갱신 규칙과 다양한 목적 함수에 대한 연구가 필요하다.

또한 부분 영역 표현을 잘 활용할 수 있을 것으로 기대되는 가려진 영상의 인식이나 부분적인 영상의 조합으로 표현되는 3차원 물체 인식을 위하여서는 부분적인 정합 정도를 나타내는 지역 유사도(local similarity)를 측정할 수 있는 거리 척도(distance metric)에 대한 연구가 필요하다.

### 감사의 글

이 논문은 2013년도 정부(교육부)의 재원으로 한국연구재단 기초연구사업의 지원을 받아 수행된 연구임(NRF-2013R1A1A2010720)

### REFERENCES

[1] A. Samil and P. Iyengar, "Automatic Recognition and Analysis of Human Face and Facial Expression: A Survey," *Pattern Recognition*, vol. 25, pp. 65-77, 1992.  
[2] R. Chellappa, C. Wilson, and S. Sirohey, "Human and Machine Recognition of Face: A Survey," *Proc. of IEEE*, vol. 83, no. 5, pp. 705-740, 1995.  
[3] A. Pentland, "Looking at People : Sensing for Ubiquitous and Wearable Computing," *IEEE Trans. PAMI*, vol. 22, no. 1, pp. 107-119, Jan. 2000.

[4] M. H. Yang, D. J. Kriegman, and N. Ahuja, "Detecting Faces in Image: A Survey," *IEEE Trans. PAMI*, vol. 24, no. 1, pp. 34-58, Jan. 2002.  
[5] A. Pentland and M. Turk, "Eigenfaces for recognition," *Journal of Cognitive Neuroscience*, vol. 3, pp. 71-86, 1993.  
[6] Mika, S. et al. "Fisher Discriminant Analysis with Kernels", *IEEE Conf. on Neural Networks for Signal Processing IX*: 41-48, 1999.  
[7] P. Comon and C. Jutten, *Handbook of Blind Source Separation, Independent Component Analysis and Applications*, Academic Press, Oxford UK, 2010.  
[8] Y. C. Cho and S. Choi, "Nonnegative features of spectro-temporal sounds for classification," *Pattern Recognition Letters*, vol. 26, no. 9, pp. 1327-1336, 2005.  
[9] Jae Min Ban, Byeong Rae Lee and Hyunchul Kang, "Moving Vehicle Recognition using NMF in Urban Scene," *Journal of Korean Institute of Communication and Information Sciences*, Vol. 37C, No. 7, pp.554-564, 2012. 7.  
[10] Jae Min Ban and Hyunchul Kang, "Vehicle Recognition using Non-negative Tensor Factorization," *Journal of the Institute of Electronics Engineers of Korea*, Vol. 52, No. 5, pp.136-146, 2015. 5.  
[11] S. Z. Li, X. W. Hou, H. J. Zhang and Q. S. Cheng, "Learning spatially localized part-based representation," *IEEE Int. Conf. on Computer Vision Pattern Recognition*, Kauai, Hawaii, pp. 207-212, 2001.  
[12] D. D. Lee, H. S. Seung, "Algorithms for Non-Negative Matrix Factorization," *Advances in Neural Information Processing Systems*, vol. 13, pp. 556-562. 2001.  
[13] Donghan Jin and Hyunchul Kang, "Face Recognition using Non-negative Matrix Factorization," *Korean Institute of Information Scientists and Engineers*, 2016 Workshop on Image Processing and Image Understanding, Jeju, 2016. 2  
[14] D. D. Lee, H. S. Seung, "Learning the Parts of Objects by Non-Negative Matrix Factorization," *Nature*, vol. 401, no. 6755, pp. 788-791, 1999.  
[15] S. Agarwal, A. Awan, Roth, "Learning to detect objects in images via a sparse, part-based representation," *IEEE Trans. PAMI*, vol. 26, no. 11, pp. 1475-1490, 2004.  
[16] P. Hoyer, "Non-negative Matrix Factorization with Sparseness Constraints," *Journal of Machine Learning Research*, vol. 5, pp. 1457-1469, 2004.  
[17] C. Lin, "Projected Gradient Methods for

- Nonnegative Matrix Factorization,” *Neural Computation*, vol. 19, no. 10, pp. 2756–2779, 2007.
- [18] J. H. Yoo and S. J. Choi,, “Orthogonal nonnegative matrix factorization: Multiplicative updates on stiefel manifolds,” In Fyfe, C., Kim, D., Lee, S.-Y., Yin, H. (eds.) *IDEAL 2008*. LNCS, vol. 5326, pp. 140–147. 2008.
- [19] C. Ding, T. Li, W. Peng, and H. Park, “Orthogonal nonnegative matrix tri-factorizations for clustering,” *Proc. of the ACM SIGKDD*, Philadelphia, 2006.
- [20] A. Edelman, T. Arias, and S. T. Smith, “The geometry of algorithms with orthogonality constraints,” *SIAM Journal of Matrix Analysis. Application.*, vol. 20, no. 2, pp. 303–353, 1998.
- [21] T. Kohonen, J. Hunninen, J. Kangas, J. Kaaaksonen, and K. Torkkola, “LVQ\_Pak : The Learning Vector Quantization Program Package,” Technical Report A30, Helsinki Univ. 1996.
- [22] D. Donoho and V. Stodden, “When does non-negative matrix factorization give a correct decomposition into parts?,” *Advances in Neural Information Processing Systems 16*, MIT Press, 2003.

---

 저 자 소 개
 

---



진 동 한(학생회원)  
 2015년 인천대학교 정보통신공학과  
 학사 졸업.  
 2017년 인천대학교 정보통신공학과  
 석사 졸업.  
 <주관심분야: 영상처리, 컴퓨터 비  
 전, 화상통신>



강 현 철(정회원)  
 1982년 연세대학교 전자공학과 학사  
 졸업.  
 1984년 연세대학교 전자공학과 석사  
 졸업.  
 1989년 연세대학교 전자공학과 박사  
 졸업.  
 1990년~현재 인천대학교 정보통신공학과 교수  
 <주관심분야: 영상처리, 컴퓨터 비전, 화상통신>