

부분 최소제곱법 기반한 차원 축소 특징을 이용한 얼굴 인식

이창범*, 김도향**, 박혁로*, 백장선**

*전남대학교 전산학과

**전남대학교 통계학과

{chblee1225, dodo_hyang}@hanmail.net,

{hyukro, jbaek}@chonnam.ac.kr

Face Recognition using Dimension Reduction Features based on Partial Least Squares

Chang-Beom Lee*, Do-Hyang Kim**, Hyuk-Ro Park*,
Jangsun Baek**

*Dept. of Computer Science, Chonnam National University

**Dept. of Statistics, Chonnam National University

요 약

얼굴 이미지의 대부분은 표본의 수보다 특징 변수의 수가 많기 때문에 이러한 점을 고려한 특징 추출 방법이 필요하다. 본 논문에서는 부분 최소제곱법을 이용하여 특징 벡터의 차원을 축소하는 방법을 제안한다. 전통적인 차원 축소 방법인 주성분 분석은 클래스의 정보를 고려하지 않고 최대 변이를 가지는 성분을 추출하기 때문에, 클래스의 구분에 필요한 특징을 필수적으로 추출하지 못한다. 이에 비해, 부분 최소제곱법은 클래스 변수에 대한 정보를 포함하여 성분을 추출한다. 그러므로, 분류를 하는데 있어서는 주성분 분석에 의해 추출된 성분보다는 부분 최소제곱법에 의해 추출된 성분이 보다 더 예측적이다. 맨체스터와 ORL 얼굴 데이터베이스를 이용하여 실험한 결과, 분류와 차원 축소 측면에서 주성분 분석 방법보다는 부분 최소제곱법을 이용한 방법이 그 성능이 우수함을 알 수 있었다.

1. 서론

대부분의 통계적 패턴 인식 방법들은 표본의 수가 적은 경우 문제점을 가지고 있다[1]. 이러한 문제는 특징 벡터의 차원과 비교하여 표본 수가 적기 때문에 발생하는데, 얼굴 인식 분야에서는 대부분 발생한다.

일반적으로 분류기를 훈련시키는 표본의 수에는 제한이 있기 때문에, 특징 벡터의 차원을 줄이고자 한다. 얼굴 인식에서, 가장 성공적인 특징 변수의 차원을 줄이는 한 가지 방법은 주성분 분석(PCA: Principal Component Analysis)이다[2]. 주성분 분석은 다변량 자료의 총변이를 주성분이라는 축소 요약된 양을 통하여 해석함으로써 다차원 변수들에 대한 단순화를 도모하고, 서로 상관되어 있는 변수들간의 내적 구조를 분석하는 데 그 목적을 두고 있다. 하

지만, 주성분 분석은 각 집단(class or group)간의 관계를 고려하지 않고, 전체 데이터의 분산을 최대 로 하는 방향으로만 선형 투사하기 때문에 집단간의 겹침이 발생하는 단점이 있다. 즉, 결과 주성분이 얼굴 전체 영상에 대한 표현으로서, 눈, 코, 입 등과 같은 세부적인 표현이 아니므로, 다양한 변형을 표현할 수 있는 국부적 특징을 추출하지 못한다는 문제점을 가지고 있다. 이에 비해, 부분 최소제곱법(PLS: Partial Least Squares)은 집단과 원래의 특징 벡터 사이의 표본 공분산을 최대 로 하는 성분을 선택한다. 부분 최소제곱법은 많은 예측 변수를 가지고 있는 회귀 모형을 예측하는데 적합하다[3]. 이 변수 예측 방법은 사회과학분야에서 발생했으나 화학 분야에 응용되면서 널리 쓰이고 있다. 최근에는 생체자료(biometric data) 분류에도 적용되고 있다[4].

본 논문의 구성은 다음과 같다. 2장에서는 PLS를 설명하고 또한 PCA와 비교한다. 3장에서는 실험 및 평가에 대해 기술하고, 4장에서는 결론을 맺는다.

2. PLS를 이용한 차원 축소

차원 축소 방법들의 목적은 높은 p 차원의 원래 얼굴 특징 공간을 보다 낮은 K 차원의 성분 공간으로 줄이는 것이다 ($K \ll p$). 이것은 특징 공간에서 정해진 목표를 극대화하는 방향으로 K 개의 성분을 추출함으로써 이루어 질 수 있다. 이제 PLS와 PCA를 서로 비교하여 설명하고자 한다.

X 를 표준화 $n \times p$ 행렬이라고 하자. 여기서, n 은 얼굴 이미지의 개수이고, p 는 원래의 얼굴 특징수이다. 또한, 특징들은 표준화(평균=0, 표준편차=1)되었다.

PCA는 특징들의 직교 선형 결합이며, 순차적으로 변이(variance)를 최대화한다. PCA는 다음과 같은 가중치 벡터 a_k 를 찾는 과정이다.

$$a_k = \arg \max Var(Xa) \quad \text{for } k=1, 2, \dots, K$$

$$\text{제약 조건} \begin{cases} a' a = 1 \\ a' S a_j = 0 \quad \text{for all } 1 \leq j < k \end{cases}$$

단, $S = X' X$

또한, a_k 는 공분산행렬 $S/(n-1)$ 의 k 번째 고유값(eigenvalue)와 관련된 고유벡터(eigenvector)이다. 그리고, k 번째 주성분(principal component)은 특징들의 선형결합, Xa_k 이다.

PCA는 구축된 성분이 클래스를 잘 예측하는지 관계없이, 전체적인 특징 변이를 최대화하는 성분을 추출하기 때문에 클래스 예측적이지 못하다. 이러한 이유로, 본 논문에서는 PLS를 이용한 차원 축소 방법을 제안한다.

성분을 구성함에 있어서, PLS는 클래스 변수와 특징들의 선형 결합 사이의 공분산을 순서적으로 최대화하는 방법을 사용한다. 인식되어야 할 $G+1$ 개의 클래스($0, 1, \dots, G$)가 있다고 가정하자. 그러면, G 차원의 확률벡터(random vector)

$y = (y_1, y_2, \dots, y_G)'$ 를 정의할 수 있다. 여기서, 얼굴 이미지가 클래스 $i-1$ ($i=1, 2, \dots, G$)에 속할 경우에는 모든 $j \neq i$ 에 대하여 $y_i=1, y_j=0$ 로, 이미지가 클래스 G 에 속한다면 $y_i=1$ ($i=1, 2, \dots, G$)로 처리한다. 그러면, 훈련

샘플 이미지로부터 클래스 관측 벡터들, $\{y_1, y_2, \dots, y_n\}$ 를 구할 수 있으며, $n \times G$ 클래스 행렬, $Y = [y_1, y_2, \dots, y_n]'$ 을 구축할 수 있다. PLS는 다음과 같은 가중치 벡터 b_k 를 찾는 것이다.

$$b_k = \arg \max Cov^2(Xb, Yc) \quad \text{for } k=1, 2, \dots, K$$

$$\text{제약 조건} \begin{cases} b' b = 1, c' c = 1 \\ b' S b_j = 0 \quad \text{for all } 1 \leq j < k \end{cases}$$

단, $\begin{cases} b, c : \text{unit vector} \\ S = X' X \end{cases}$

위와 같은 절차를 다변량 PLS (multivariate PLS)라 부른다. k 번째 PLS 성분은 원래 특성들의 선형 결합, Xb_k 이다. PLS는 성분과 클래스 변수들 간의 상관 관계(correlation)를 최대로 하는 성분을 추출하기 때문에, PLS는 PCA보다는 더 클래스 예측적이라 볼 수 있다.

3. 실험 및 평가

이번 장에서는 PCA와 PLS로 차원 축소하여 얼굴 인식 실험한 결과에 대해 기술한다.

실험 자료는 맨체스터와 ORL 얼굴 데이터베이스를 사용하였다. 여기서, 맨체스터의 경우 30명의 사람에게 대해 각각 10장씩 300장의 영상을 사용하였고, ORL의 경우 40명의 사람에게 대해 각각 10장씩 400장의 영상을 사용하였다. 맨체스터 이미지의 해상도는 512×512 이지만 16×16 으로 축소하여 실험하였고, ORL 이미지의 경우에는 112×92 해상도이지만 28×23 으로 축소하여 실험하였다. 그리고, 모든 이미지는 256 그레이 스케일로 표현되었다. 결국, 맨체스터의 경우 256차원의 특징 벡터를, ORL의 경우 644차원의 특징 벡터를 사용하였다.

PCA와 PLS로 차원 축소된 각각의 결과는 선형 판별분석(LDA: Linear Discriminant Analysis), 이차판별분석(QDA: Quadratic Discriminant Analysis), 신경망(NN : Neural Network) [5], SVM(Support Vector Machine) [6]와 같은 분류기를 이용하여 얼굴 인식 실험을 하였다. 그리고, 각 데이터베이스에서 70%는 학습 자료로, 30%는 실험 자료로 사용하였다. 또한, 이러한 표본 추출을 무작위로 10번 반복 시행하여 각각 10개의 학습자료 셋과 실험자료 셋을 사용하여 실험하였다.

3.1 맨체스터 자료의 실험 결과

축소된 PCA 와 PLS 성분수를 30 개부터 100 개까지 10 개씩 증가시켜가면서 각 분류기 별로 10 개의 실험자료 셋들에 대하여 각각 인식률을 계산한 다음, 그들의 평균을 구하여 평균인식률을 측정하였다. <표 1>에서는 맨체스터 자료의 분류기별 PCA 와 PLS 인식률의 차이에 대한 대응표본 t-검정 결과를 나타내고 있다. LDA를 제외한 QDA, NN, SVM에서 PLS가 PCA에 비하여 더 우수한 인식률의 유의적인 차이가 있음을 알 수 있다. 그리고, <표 2>는 성능이 우수하다고 판정된 PLS변환 자료에 대한 각 방법별 인식률의 차이에 대한 분산분석 결과를 나타내고 있다. Tukey의 다중비교 결과, NN 과 SVM, LDA, QDA 방법별로 집단군이 형성됨을 알 수 있다. (그림 1)은 실험에 사용된 성분수별 각 방법들의 평균 인식률을 나타내고 있다.

<표 1> 맨체스터 자료의 방법별 PCA와 PLS 인식률의 차이에 대한 검정 (유의수준 $\alpha=0.05$)

** 유의적 차이

방법	t 값	p 값
LDA	0.583	0.578
QDA	-3.236	0.014 **
NN	-14.821	0.0001 **
SVM	-4.411	0.003 **

<표 2> 맨체스터 자료의 PLS를 이용한 방법별 인식률의 차이에 대한 검정 (유의수준 $\alpha=0.05$)

개체-간 효과 검정

종속변수: 정분류율

소스	제 III 유형 제곱합	자유도	평균제곱	F	유의확률
수정 모형	.317 ^a	10	3.174E-02	31.064	.000
절편	19.611	1	19.611	19194.009	.000
방법	.308	3	.103	100.399	.000
성분	9.653E-03	7	1.379E-03	1.350	.277
오차	2.146E-02	21	1.022E-03		
합계	19.950	32			
수정 합계	.339	31			

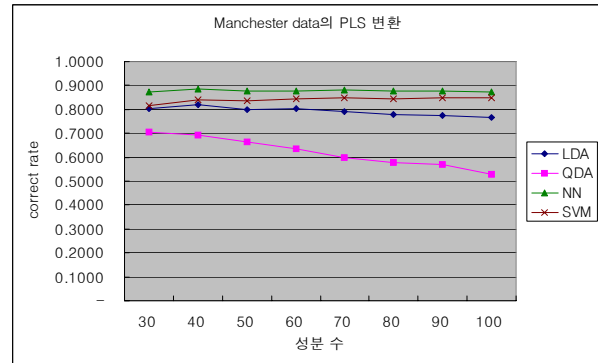
a. R 제곱 = .937 (수정된 R 제곱 = .907)

정분류율

Tukey HSD^{a,b}

방법	N	집단군		
		1	2	3
QDA	8	*****		
LDA	8		*****	
SVM	8			*****
NN	8			*****
유의확률		1.000	1.000	.136

동일집단군의 그룹에 대한 평균이 표시됩니다.
 유형 III 제곱합에 기초합니다
 오차항은 평균제곱(오차) = 1.022E-03입니다.
 a. 조화평균 표본 크기 8.000을(를) 사용합니다.
 b. 유의수준 = .05.



(그림 1) 맨체스터 자료의 PLS 변환 인식률

3.2 ORL 자료의 실험 결과

축소된 PCA 와 PLS 성분수를 25 개부터 50 개까지 5 개씩 증가시켜가면서 각 분류기 별로 10 개의 실험자료 셋들에 대하여 각각 인식률을 계산한 다음, 그들의 평균을 구하여 평균인식률을 측정하였다. <표 3>에서는 ORL 자료의 분류기별 PCA와 PLS 인식률의 차이에 대한 대응표본 t-검정 결과를 나타내고 있다. QDA를 제외한 LDA, NN, SVM에서 PLS가 PCA에 비하여 더 우수한 인식률의 유의적인 차이가 있음을 알 수 있다. 그리고, <표 4>는 성능이 우수하다고 판정된 PLS변환 자료에 대한 각 방법별 인식률의 차이에 대한 분산분석 결과를 나타내고 있다. Tukey의 다중비교 결과, SVM과 LDA, NN, QDA 방법별로 집단군이 형성됨을 알 수 있다. (그림 2)는 실험에 사용된 성분수별 각 방법들의 평균 인식률을 나타내고 있다.

<표 3> ORL 자료의 방법별 PCA와 PLS 인식률의 차이에 대한 검정 (유의수준 $\alpha=0.05$)
 ** 유의적 차이

방법	t 값	p 값
LDA	-3.737	0.013 **
QDA	-1.267	0.261
NN	-13.023	0.0001 **
SVM	-6.519	0.001 **

<표 4> ORL 자료의 PLS를 이용한 방법별 인식률의 차이에 대한 검정 (유의수준 $\alpha=0.05$)

개체-간 효과 검정

종속변수: 정분류율

소스	제 III 유형 제공함	자유도	평균제곱	F	유의확률
수정 모형	1.713E-02 ^a	8	2.142E-03	33.287	.000
절편	21.288	1	21.288	30869.995	.000
방법	1.706E-02	3	5.687E-03	88.390	.000
성분	7.238E-05	5	1.448E-05	.225	.946
오차	9.651E-04	15	6.434E-05		
합계	21.306	24			
수정 합계	1.810E-02	23			

a. R 제곱 = .947 (수정된 R 제곱 = .918)

정분류율

Tukey HSD^{a,b}

방법	N	집단군		
		1	2	3
QDA	6	*****		
NN	6		*****	
LDA	6			*****
SVM	6			*****
유의확률		1.000	1.000	.999

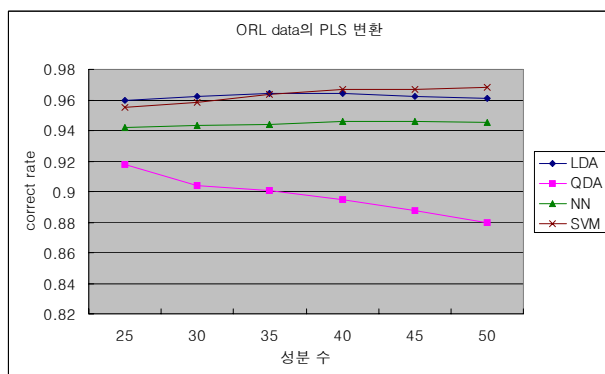
동일집단군의 그룹에 대한 평균이 표시됩니다.

유형 III 제공함에 기초합니다.

오차항은 평균제곱(오차) = 6.434E-05입니다.

a. 조화평균 표본 크기 6.000을(를) 사용합니다.

b. 유의수준 = .05.



(그림 2) ORL data의 PLS 변환 인식률

4. 결론

본 논문에서는 얼굴 이미지의 부분 최소 제곱법과 주성분 분석법을 이용하여 4가지 분류방법(LDA, QDA, NN, SVM)을 통해 얼굴 이미지 자료를 분류하였다. 실험 결과를 통해 효과적인 얼굴 이미지 추

출 방법을 제안하였고 각 분류기에 따른 비교를 통해 각 이미지 데이터베이스에서 보다 나은 분류 방법을 선택할 수 있도록 하였다.

맨체스터 자료와 ORL 자료에 대한 두 가지 변환 방법을 비교하여 실시한 결과 PLS 변환 방법이 PCA 변환 방법 보다 우수한 성능을 보임을 알 수 있었다. 또한 제한된 얼굴인식 실험자료에 의존한 결과이지만 PLS 특징을 이용했을 때 SVM, NN, LDA 는 그 성능 면에서 비슷한 인식 성능을 가지고 있다고 할 수 있겠다.

참고문헌

[1] K. Fukunaga, "Introduction to Statistical Pattern Recognition", Academic Press, Boston, 1990.
 [2] M. Turk, A. Pentland, "Eigen faces for recognition", J. Cognitive Neurosci. 3, pp. 71-86, 1991.
 [3] P. M. Garthwaite, "An interpretation of partial least squares", J. Am. Stat. Assoc. 89, pp. 122-127, 1994
 [4] D. V. Nguyen, D. M. Rocke, "Tumor classification of partial least squares using microarray gene expression data", Bioinformatics 18, pp. 39-50, 2002.
 [5] B. D. Ripley, "Pattern Recognition and Neural Networks", CAMBRIDGE UNIVERSITY PRESS, 1996.
 [6] Guoding Guo, Stan Z. Li, Kap Luk Chan, "Support vector machines for face recognition", Image and Vision Computing. 19, pp.631-638, 2001.