

부분 최소제곱법을 이용한 얼굴 인식에 관한 연구

이 창 범^{*} · 김 도 향^{††} · 백 장 선^{†††} · 박 혁 로^{††††}

요 약

얼굴 인식에서 얼굴 이미지의 특징 추출 방법에는 여러 가지가 있다. 그러나, 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.

키워드 : 부분 최소제곱법, 주성분 분석, 얼굴인식

A Study on Face Recognition based on Partial Least Squares

Lee, Changbeom^{*} · Kim, Dohyang^{††} · Baek, Jangsun^{†††} · Park, Hyukro^{††††}

ABSTRACT

There are many feature extraction methods for face recognition. We need a new method to overcome the small sample problem that the number of feature variables is larger than the sample size for face image data.

The paper considers partial least squares(PLS) as a new dimension reduction technique for feature vector. Principal Component Analysis(PCA), a conventional dimension reduction method, selects the components with maximum variability, irrespective of the class information. So, PCA does not necessarily extract features that are important for the discrimination of classes. PLS, on the other hand, constructs the components so that the correlation between the class variable and themselves is maximized. Therefore PLS components are more predictive than PCA components in classification.

The experimental results on Manchester and ORL databases shows that PLS is to be preferred over PCA when classification is the goal and dimension reduction is needed.

Key Words : Partial Least Squares, Principal Component Analysis, Face Recognition

1. 서 론

최근 몇 년 사이에 정보 통신의 발전이 급속하게 진행되고 있는 가운데 통신망의 발전은 우리 개인의 생활 영역까지 확대되고 있다. 현실 세계에서만 이루어지던 경제적, 사회적 활동들이 인터넷을 통해 가상 공간으로 급속하게 퍼져나가고 있다. 개방적인 가상 공간에서는 기업의 정보 유출

이나 개인의 사생활 침해 등의 우려가 높아가고 있다. 이에 관련된 단말기, 출입통제시스템, 인증 시스템 등에 대한 보안을 위해서 개인 신분 확인 기술이 이용되고 있다. 이에 따라 최근 각광을 받고 있는 것이 사람의 고유한 신체적 특징을 이용한 생체 인식 시스템이다.

생체 인식 기술은 크게 생리적 특징을 이용한 지문, 얼굴, 망막, 혈관 패턴, 홍채, 손목 또는 손등의 정맥 분포 패턴, DNA를 식별하는 방식과 사람의 행위나 형태적 특징을 이용한 서명, 음성 등의 방법이 있다. 이 중에서 얼굴 인식 기술은 주변 환경이나 얼굴 모양의 다양한 변화 같은 요소들에 민감한 문제점이 있지만, 사용자의 편의성 면에서 여러 가지의 장점을 가지고 있다. 홍채, 지문 등과 같이 별도로

* 본 연구는 정보통신부 및 정보통신연구진흥원의 대학 IT연구센터 유흥·지원사업의 연구결과로 수행되었음.

† 정 회 원 : 울산대학교 컴퓨터정보통신공학부 DMUTRC 연구교수

†† 정 회 원 : University of Minnesota, School of Statistics 박사과정

††† 정 회 원 : 전남대학교 통계학과 교수

†††† 종신회원 : 전남대학교 전자컴퓨터정보통신공학부 교수

논문접수 : 2005년 7월 20일, 심사완료 : 2006년 7월 4일

제작된 센서가 아닌, 이미 설치되어 있는 카메라를 이용할 수 있으며, 또한 대부분의 신분증이 사진 데이터를 가지고 있으므로 대량의 데이터를 쉽게 이용 가능하다. 그리고, 얼굴은 사람이 사람을 식별하는 수단이므로, 추후에 관리자가 결과를 확인할 수 있으며, 접촉식이 아니므로 대규모 공공 시설에서 감시 수단으로 쉽게 적용될 수 있는 기술이다.

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 특징 변수의 차원을 줄이는 가장 성공적인 한 가지 방법은 주성분 분석(Principal Component Analysis: PCA)이다[2, 7, 10]. 주성분 분석은 고차원의 특징을 총 변이의 가능한 많은 부분을 보유하는 몇 개의 특징 성분으로 축소한다. 하지만, 주성분 분석은 각 집단(class or group)간의 관계를 고려하지 않는다. 이에 비해, 부분 최소제곱법(Partial Least Squares: PLS)은 집단과 원래의 특징 벡터 사이의 표본 공분산을 최대로 하는 성분을 선택한다. 부분 최소제곱법은 많은 예측 변수를 가지고 있는 회귀 모형을 예측하는데 적합하다[3, 9]. 이 변수 예측 방법은 사회과학분야에서 발생했으나 화학분야에 응용되면서 널리 쓰이고 있다. 최근에는 생체자료(biometric data) 분류에도 적용되고 있다[4, 11].

본 논문의 구성은 다음과 같다. 2장에서는 특징 추출에 이용된 주성분 분석과 부분 최소제곱법에 대하여 기술한다. 3장에서는 각 특징 추출 방법에 따른 분류 실험 및 평가에 대해 다루고, 4장에서는 결론을 맺는다.

2. 특징 추출(Feature Extraction)

2.1 주성분 분석(Principal Component Analysis: PCA)

주성분 분석은 신호 처리 분야, 통계학 그리고 신경망 관련 연구에서 주로 쓰인다. 이는 Karhunen-Loeve 변환 또는 Hotelling 변환이라고 불리기도 한다.

주성분 분석은 다변량 자료의 총 변이를 주요 성분이라는 축소 요약된 양을 통하여 해석함으로써 다차원 변수들에 대한 단순화를 도모하고, 서로 상관되어 있는 변수들 간의 내적 구조를 분석하는 데에 그 목적을 두고 있다. 이를 위하여 주성분 분석은 원래 변수들을 선형 결합의 형식으로 변화시켜 주성분(Principal Component)이라고 부르는 서로 상관되어 있지 않은(독립적인) 인공적 변수를 유도한다. 여기서 각 주성분이 가지는 변이의 크기(주성분의 분산)를 기준으로 그 중요도의 순서를 생각할 때, 첫 몇 개의 주성분이 원래 자료에 내재하는 총 변이의 가능한 많은 부분을 보유하도록 함으로써 차원의 축약을 기할 수 있다. 즉, 전체 영상의 데이터를 가지고 그것들의 분산이 큰 몇 개의 고유 방향에 대한 축으로 선형 투사시켜서 차원을 줄이는 방법을 말한다. 주성분 분석을 통해 입력 벡터의 차원을 감소하는

것은 데이터 분포에 대한 정보는 그대로 유지하지만, 계산상의 부하를 감소할 수 있고, 노이즈를 제거하며, 데이터 압축과 같은 효과를 가질 수 있다. 하지만, 각 집단 간의 관계를 고려하지 않고, 전체 데이터의 분산을 최대로 하는 방향으로만 선형 투사하기 때문에 집단 간의 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.

2.1.1 주성분 분석의 정의 및 성질

얼굴 이미지의 경우, 얼굴의 각 이미지는 픽셀(pixel) 단위로 처리된다. 이 픽셀은 얼굴에 대한 벡터로 표현할 수 있는데, 가로 픽셀 × 세로 픽셀 개의 픽셀(성분)으로 구성된다. 여기서 성분들은 변량으로 설명될 수 있다.

따라서, p -변량 원 얼굴 이미지에서 얻은 크기 n 개의 랜덤 표본벡터를 X_1, X_2, \dots, X_p 라 할 때 이로 계산한 Σ 의 추정량인 S 가 구체적인 분석 대상이 된다. 크기 $p \times p$ 행렬 S 의 고유값(eigen value)을 l , 그리고, 이 고유값에 대응되는 고유벡터(eigen vector)를 g 라 하자. S 의 최대 p 개의 고유값과 고유벡터의 쌍 (l, g) 를 l 의 내림차순으로 배열한 것을 $(l_1, g_1), (l_2, g_2), \dots, (l_k, g_k), \dots, (l_p, g_p)$ 로 표기할 때, 이들은 다음 관계를 만족한다.

$$Sg_k = l_k g_k, \quad k = 1, 2, \dots, p \quad (1)$$

$$l_1 \geq l_2 \geq \dots \geq l_k \geq \dots \geq l_p$$

$$g_k = (g_{1k}, g_{2k}, \dots, g_{jk}, \dots, g_{pk})'$$

이 때 k 번째 표본주성분 Y_k , $k = 1, 2, \dots, p$ 는 S 의 k 번째 고유값 l_k 의 짹이 되는 고유벡터 g_k 의 p 개의 원소를 가중계수로 하는 원래 변수들과의 선형 결합으로 다음과 같이 정의된다.

$$Y_k = g_k' X = g_{1k}X_1 + g_{2k}X_2 + \dots + g_{jk}X_j + \dots + g_{pk}X_p = \sum_{j=1}^p g_{jk}X_j \quad (2)$$

이런 p 개의 주성분들로 이루어진 주성분벡터 $Y = (Y_1, Y_2, \dots, Y_k, Y_p)'$ 는 각각 원래 변수벡터와 S 의 고유벡터와의 선형 결합이다. 또한, 각 표본주성분은 서로 독립적(무상관)이며, 각 표본주성분의 분산은 S 의 고유값이 된다.

일반적으로 k 번째 주성분 Y_k 가 총변이를 설명하는 비중은 $l_k / \sum_{u=1}^p l_u$, $k = 1, 2, \dots, p$ 가 되며, 첫 m 개의 주성분들 (Y_1, Y_2, \dots, Y_m) , $m \leq p$ 에 설명되는 부분은 $(l_1 + l_2 + \dots + l_m) / \sum_{u=1}^p l_u$ 가 된다.

따라서, 만약 첫 m 개의 주성분들에 설명되는 부분이, 예를 들어 80~90%를 차지한다면 p 보다 작은 m 개의 주성분들을 이용하더라고 변이에 대한 정보의 손실은 크지 않을 것이며 p -차원의 원래 변수벡터 대신 m -차원 주성분 (Y_1, Y_2, \dots, Y_m) 으로의 차원 축소를 기할 수 있게 된다.

i 번째 관찰개체($i=1,2,\dots,n$)로부터 얻은 p -차원 관찰벡터를 $X_i = (X_{i1}, X_{i2}, \dots, X_{ij}, \dots, X_{ip})'$ 라 하자. 이 때, i 번째 관찰벡터에 대한 첫 번째 주성분점수는

$$Y_{i1} = g_1' X_i = g_{11} X_{i1} + g_{21} X_{i2} + \dots + g_{j1} X_{ij} + \dots + g_{p1} X_{ip} \quad (3)$$

이다. 이와 같이 i 번째 관찰 벡터에 대한 k 번째 주성분 점수($i=1,2,\dots,n; k=1,2,\dots,p$)를 얻게 된다. 각 개체에 대해 주성분 점수는 변수의 개수만큼 생성되고, 이 중에서 설명력이 높은 몇 개의 주성분 점수는 다른 분석의 입력 자료로 사용될 수 있다. 특히 주성분 점수간에는 서로 상관관계가 존재하지 않으므로, 회귀분석이나 판별분석의 좋은 입력 자료가 될 수 있다.

2.2 부분 최소제곱법(Partial Least Squares: PLS)

부분 최소제곱법은 종속변수 Y 와 설명변수 X 에 대한 회귀방정식을 세우는 새로운 방법이다. 특히, 매우 많은 설명 변수로부터 종속변수들을 예측할 때 유용하다.

부분 최소제곱법은 종속변수 Y 와 설명변수 X_1, X_2, \dots, X_m 사이의 관계를 형성하기 위해서 각 설명변수 X_1, X_2, \dots, X_m 의 선형결합이고 서로 상관되어 있지 않은 열들로 구성된 행렬을 이용하는 방법으로 인자(성분, 잠재적 변수)라는 새로운 설명변수를 만든다. 이 인자들은 주성분 분석의 주성분과 유사하나 인자들이 X 와 y 의 정보를 모두 포함하도록 유도되고 추정된다는 점에서 주성분과 다르다. 즉, 부분 최소제곱법은 $y = X\beta + \epsilon$ 과 같은 회귀식에서 X 대신 인자를 사용한다.

부분 최소제곱법의 목적은 X 변수의 수보다 더 적은 성분을 사용하여 회귀 문제의 차원을 줄이면서 X 변수의 정보 대부분을 설명하고, 또 Y_1, Y_2, \dots, Y_l 을 예측함에 있다.

2.2.1 부분 최소제곱법의 정의와 성질

먼저 p 개의 변수에 대해 측정된 n 개의 표본의 관측값들로 구성된 $(n \times p)$ 자료 행렬을 X 라 하자. 일반적으로 자료 행렬 X 의 열 벡터들이 서로 상관되어 있고 자료 고유의 정보이외에 다른 잡음이 포함되어 있는 경우 자료 축약 과정을 통하여 자료의 분석 및 해석을 용이하게 할 수 있다. X 의 성분행렬을 T 라 하면 부분 최소제곱법을 통하여 다음과 같이 X 를 점수행렬(score matrix) T 로 표현할 수 있다.

$$T = XV \quad (4)$$

X 와 관련 종속변수 y 의 회귀관계식을 T 를 이용하여 다음과 같은 모형으로 생각할 수 있다.

$$y = Tq + f \quad (5)$$

그러면 q 를 추정한 후 y 는 다음과 같이 예측할 수 있다.

$$\hat{y} = X V \hat{q} \quad (6)$$

위에서 T 의 열 벡터(인자)들이 서로 독립이 되도록 그리고

X 의 계수(rank)보다 적은 수의 인자들만을 분석에 이용하여 행렬 T 에 대한 y 의 회귀식을 추정한다. 그러면, 자료의 공선성 문제로 야기될 수 있는 변수의 선택 문제와 자료에 불필요한 잡음의 제거 문제를 동시에 해결할 수 있다.

그러나, X 와 y 모두가 행렬 T 의 회귀식으로 표현될 경우 다음과 같은 보정 모형을 생각할 수 있다.

$$\begin{aligned} X &= TP' + E \\ y &= Tq + f \end{aligned} \quad (7)$$

식(5)의 모형과는 달리 식(7)의 보정 모형에서는 관계식 $T = XV$ 의 V 가 자료 X 와 y 로부터 추정된다.

적재행렬/loading matrix) P 와 적재벡터/loading vector) q 는 각각 T 에 대한 X 와 y 의 회귀계수행렬과 회귀계수벡터로 생각할 수 있으며, E 와 f 는 모형에 의해 설명되지 않는 오차항이다. 여기서, V 와 적절한 인자의 수는 보정 과정으로부터 추정되고 결정되며, 추정된 \hat{V} 에 따라 \hat{T} 가 구해진다. 그러면, P 와 q 그리고 오차항 E 와 f 는 다음과 같이 계산된다.

$$\begin{aligned} \hat{P}' &= (\hat{T}' \hat{T})^{-1} \hat{T}' X \\ \hat{q} &= (\hat{T}' \hat{T})^{-1} \hat{T}' y \\ E &= X - \hat{T} \hat{P}' \\ f &= y - \hat{T} \hat{q} \end{aligned} \quad (8)$$

보정 모형에서 인자의 수의 최대 값은 X 의 계수(rank)이며 인자의 수가 X 의 계수와 같으면 X 의 오차항 E 는 0이 된다.

자료행렬 X 에서 y 와 관련된 정보들 중 많은 부분이 몇 개의 인자들로 표현될 수 있다. 부분 최소제곱법은 식(7)과 같은 모형의 한 형태로, 두 자료 행렬 X 와 y 를 모두 사용하여 V 를 추정하는 방법이다. 따라서, X 에 관한 주성분 분석에서와 같이 $P'X$ 의 분산을 최대로 하는 X 의 적재행렬 P 를 구하는 대신, 선형 결합 Xw 와 y 간의 공분산을 최대화하는 가중적재벡터/loading weight vector), w 를 먼저 유도한다. 그러면 $V = W(P'W)^{-1}$ 과 같이 된다. 보정과정에서는 자료의 변이를 많이 설명하는 몇 개의 인자들만을 구하는 것으로 충분하기 때문에, 자료의 변이를 가장 많이 설명하는 인자부터 시작하여 더 이상 자료의 유용한 정보를 포함하는 인자를 구할 수 없을 때까지 한 번에 한 개의 인자를 구하는 알고리즘이 유용하다. <표 1>은 부분 최소제곱법 보정을 위한 알고리즘을 나타낸다. 이 알고리즘에서는 각 인자에 대해 먼저 구해진 인자들을 추정한 후 계산된 오차항으로부터 다시 적재벡터와 점수벡터를 구하는 반복 절차가 수행된다.

<표 1>의 알고리즘에서는 적절한 인자의 수만큼 위의 과정을 수행하는 데 매번 구해지는 \hat{w}_a 는 서로 직교하게 된다. step 5에서 구해진, 점수벡터 \hat{t}_a 와 적재벡터 \hat{p}_a 의 곱 $\hat{t}_a \hat{p}_a$ 와 점수벡터 \hat{t}_a 와 \hat{q}_a 의 곱 $\hat{t}_a \hat{q}_a$ 는 각각 자료행렬 X 와 y 에 대하여 모형으로부터 추정된 부분 최소제곱법 근사치로 인자의 수 a 가 X 의 계수일 때 E 의 원소들은 모두 0이 된다.

〈표 1〉 부분 최소제곱법의 보정 알고리즘

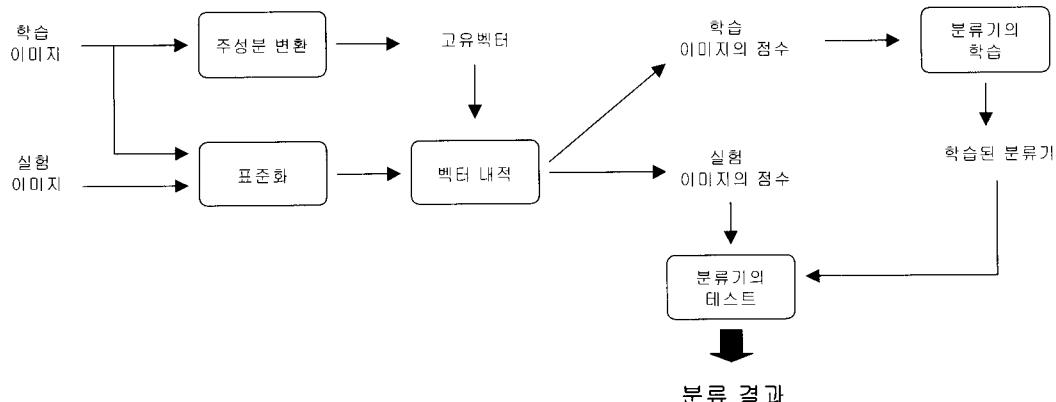
step 0. 보정자료 X 와 y 에서 평균을 빼준다.(centering) 필요하다면 X 를 표준편차로 나누어준다.(scaling) 인자의 수 a 를 1로 놓는다.
step 1. $w_a' w_a = 1$ 의 조건 하에서 선형결합 Xw_a 와 y 간의 공분산을 최대화하는 가중직제벡터 w_a 를 구한다. $\hat{w}_a = X'y / y'y$
step 2. 구해진 \hat{w}_a 에 대한 X 의 사영(projection)인 점수벡터 \hat{t}_a 를 구한다. $\hat{t}_a = X \hat{w}_a$
step 3. 적재벡터 \hat{p}_a 를 구하기 위하여 \hat{t}_a 에 X 를 회귀시키면 \hat{p}_a 는 다음과 같다 $\hat{p}_a = X' \hat{t}_a / \hat{t}_a' \hat{t}_a$
step 4. \hat{q}_a 를 구하기 위하여 \hat{t}_a 에 y 를 회귀시키면 \hat{q}_a 는 다음과 같다 $\hat{q}_a = y' \hat{t}_a / \hat{t}_a' \hat{t}_a$
step 5. X 와 y 의 오차항을 계산한다. $E = X - \hat{t}_a \hat{p}_a$ $f = y - \hat{t}_a \hat{q}_a$
step 6. a 를 하나 증가시키고 step 5에서 구해진 X 의 오차항 E 와 y 의 오차항 f 를 각각 X 와 y 로 대치한 후 step 1로 돌아간다.

3. 분류 실험 및 평가

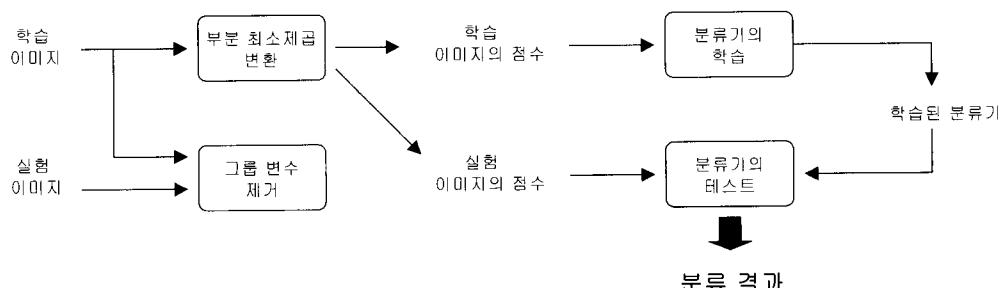
(그림 1)과(그림 2)는 각각 주성분 분석 변환과 부분 최소제곱법 변환에 따른 얼굴 영상 분류 개략도를 보이고 있다.

3.1 실험 방법

실험 자료는 맨체스터와 ORL 얼굴 데이터베이스를 사용



(그림 1) 주성분 분석 변환에 따른 얼굴 영상 분류 개략도



(그림 2) 부분 최소제곱법 변환에 따른 얼굴 영상 분류 개략도

하였다. 여기서, 맨체스터의 경우 30명의 사람에 대해 각각 10장씩 300장의 영상을 사용하였고, ORL의 경우 40명의 사람에 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.

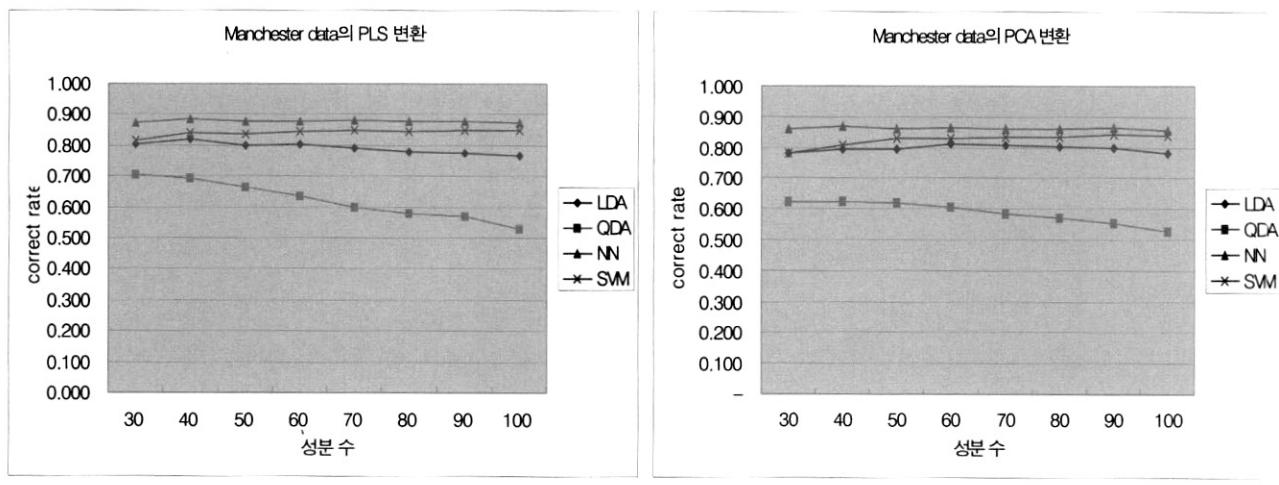
각 데이터베이스에서 70%는 학습 자료로, 30%는 실험 자료로 사용하였다. 또한, 이러한 표본 추출을 무작위로 10번 반복 시행하여 각각 10개의 학습자료 세트와 실험자료 세트를 사용하여 실험하였다.

주성분 변환의 경우 그레이 스케일로 구성된 얼굴 데이터를 주성분 분석을 위해 학습자료에 대한 분산-공분산 행렬을 구하여 고유벡터와 고유값을 구한다. 이로부터 구해진 고유벡터를 사용하여 학습자료에 대한 주성분 점수와 실험자료에 대한 주성분 점수를 구하여 그것을 분석 대상으로 하였다.

부분 최소제곱의 경우 학습자료로부터 부분 최소제곱법을 시행하여 학습자료의 점수를 구할 수 있었을 뿐만 아니라 실험자료의 점수도 추정할 수 있었다. 부분 최소제곱법의 경우도 구해진 점수를 분석의 대상으로 하였다.

주성분 분석과 부분 최소제곱법으로 차원 축소된 각각의 결과는 선형판별분석(Linear Discriminant Analysis: LDA)[7, 10], 이차판별분석(Quadratic Discriminant Analysis: QDA)[8], 신경망(Neural Network: NN)[5, 13, 14], SVM(Support Vector Machine)[6]과 같은 분류기를 이용하여 얼굴 인식 실험을 하여

		※ 부분 최소제곱법 변환 인식률(주성분 분석 변환 인식률)							
방법 \ 성분수	30	40	50	60	70	80	90	100	
LDA	0.804 (0.781)	0.820 (0.792)	0.801 (0.796)	0.804 (0.813)	0.790 (0.806)	0.778 (0.801)	0.773 (0.800)	0.766 (0.782)	
QDA	0.707 (0.623)	0.691 (0.624)	0.662 (0.620)	0.637 (0.604)	0.597 (0.582)	0.579 (0.571)	0.568 (0.553)	0.530 (0.526)	
NN	0.871 (0.860)	0.884 (0.869)	0.878 (0.861)	0.878 (0.863)	0.880 (0.861)	0.879 (0.859)	0.876 (0.863)	0.871 (0.857)	
SVM	0.816 (0.780)	0.839 (0.809)	0.838 (0.830)	0.843 (0.829)	0.848 (0.833)	0.844 (0.832)	0.849 (0.843)	0.850 (0.838)	



(그림 3) 맨체스터 자료의 변환 인식률

<표 2> 맨체스터 자료의 방법별 주성분 분석과 부분 최소제곱법 인식률의 차이에 대한 검정

(유의수준 $\alpha = 0.05$) ** 유의적 차이

방법	t 값	유의확률
LDA	0.583	0.578
QDA	-3.236	0.014 **
NN	-14.821	0.0000**
SVM	4.411	0.003 **

그 성능을 측정하였다. 성능 측정을 위해 MATLAB과 SAS 및 SPSS[12]를 사용하였다.

3.2 맨체스터 자료의 실험 결과

축소된 주성분 분석과 부분 최소제곱법 성분수를 30 개부터 100 개까지 10 개씩 증가시켜면서 각 분류기 별로 10 개의 실험자료 셋들에 대하여 각각 인식률을 계산한 다음, 그들의 평균을 구하여 평균인식률을 측정하였다. (그림 3)은 부분 최소제곱법과 주성분 분석에 의한 성분을 사용하여 여러 가지 분류기별로 적용시켰을 때 성분수의 증가에 따른 각 분류방법들의 평균 인식률을 나타내고 있다. (그림 3)의 (a)와(b)를 비교해 보면 LDA 방법을 제외한 나머지 방법들

에서 부분 최소제곱법을 이용하는 경우가 더 우수한 인식률을 보이고 있다. 각 분류방법별로 두 가지 성분추출 방법 간에 유의적인 차이가 존재하는지, 즉 최소제곱추출 성분이 주성분분석 성분보다 유의적으로 더 인식률이 높은지 검정하기 위하여 두 방법의 인식률 차이에 대하여 대응표본 t-검정을 실시하였다. <표 2>에서는 맨체스터 자료의 분류기별 주성분 분석과 부분 최소제곱법 인식률의 차이에 대한 대응표본 t-검정 결과를 나타내고 있다. <표 2>의 각 방법에 대한 t-값과 유의확률을 통하여 유의수준 0.05 하에서 LDA를 제외한 QDA, NN, SVM에서 부분 최소제곱법이 주성분 분석에 비하여 유의적으로 더 우수한 인식률을 가지고 있음을 알 수 있다. 왜냐하면, QDA, NN, SVM의 유의확률이 유의수준 0.05보다 작기 때문이다. 다음으로는 성능이 우수하다고 판정된 부분 최소제곱법 변환 자료를 이용하여 인식을 할 때 각 분류방법 간에는 과연 인식률에 있어서 차이가 있는지 검정하기 위하여 분산분석을 실시하였다. <표 3>(a)에서 ‘방법’에 대한 유의확률이 0.000 이므로 분류방법들 간에 유의한 차이가 있음을 알 수 있다. 또한 <표 3>(b)와 같이 Tukey의 다중비교 결과, NN과 SVM 그룹이 LDA나 QDA 방법보다 유의적으로 더 높은 인식률을 가지고 있음을 확인할 수 있다.

〈표 3〉 맨체스터 자료의 부분 최소제곱법을 이용한 방법별 인식률의 차이에 대한 검정 (유의수준 $\alpha = 0.05$)

(a) 방법별 인식률의 차이에 대한 F값 및 유의확률

개체-간 효과 검정

종속변수: 정분류율

소스	제III 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. R제곱=.937(수정된 R제곱=.907)

(b) 방법별 인식률의 차이에 의한 집단군 형성

정분류율

Tukey HSD ^{a,b}

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

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.

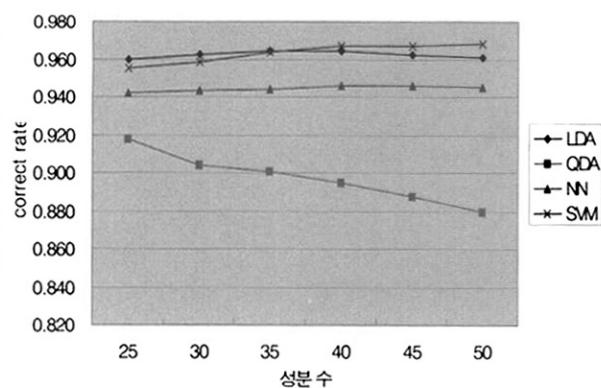
3.3 ORL 자료의 실험 결과

축소된 주성분 분석과 부분 최소제곱법 성분수를 25 개부터 50 개까지 5 개씩 증가시켜면서 각 분류기 별로 10 개의 실험자료 셋들에 대하여 각각 인식률을 계산한 다음, 그들의 평균을 구하여 평균인식률을 측정하였다.(그림 4)는 실험에 사용된 성분수별 각 분류방법들의 평균 인식률을 부분 최소제곱법과 주성분 분석 방법을 비교하여 보여주고 있는데, QDA를 제외한 나머지 모든 방법에서 부분 최소제곱법을 이용하는 것이 더 높은 인식률을 달성한다는 것을 확인할 수 있다. 〈표 4〉에서는 ORL 자료의 분류기별 주성분 분석과 부분 최소제곱법 인식률의 차이가 통계적으로 유의한지 검정하기 위해 실시한 대응표본 t-검정의 결과를 나타내고 있다. QDA를 제외한 LDA, NN, SVM에서 유의수준 0.05보다 유의확률이 더 작으므로 부분 최소제곱법이 주성분 분석에 비하여 더 우수한 인식률을 갖고 있음을 알 수 있다. 그리고 〈표 5〉는 성능이 우수하다고 판정된 부분 최소제곱법 변환 자료에 대한 각 분류방법별 인식률의 차이에 대한 분산분석 결과를 나타내고 있다. 〈표 5〉(a)에서 '방법'에 대한 유의확률이 역시 0 이므로 분류방법들 간에는 그 인식률에 있어 유의한 차이가 있음을 확인할 수 있다. 또한 어느 분류방법이 다른 방법에 비하여 더 우수한 인식률을 보이는지 검정하기 위해 〈표 5〉(b)와 같이 Tukey의 다중비교를 실시한 결과, SVM과 LDA 그룹이 NN과 QDA 방법보다 유의적으로 높은 인식률을 가지고 있음을 알 수 있다.

※ 부분 최소제곱법 변환 인식률(주성분 분석 변환 인식률)

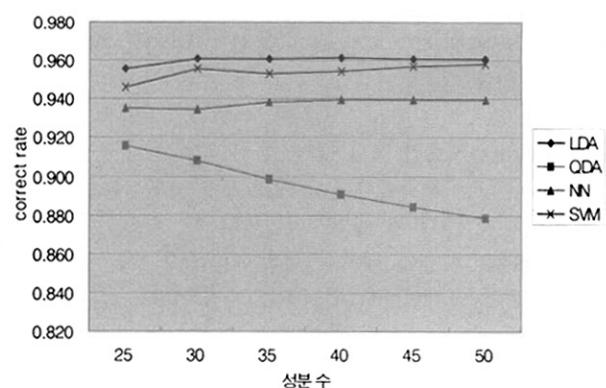
방법 \ 성분수	25	30	35	40	45	50
LDA	0.960 (0.956)	0.963 (0.961)	0.964 (0.961)	0.964 (0.962)	0.963 (0.961)	0.961 (0.961)
QDA	0.918 (0.916)	0.904 (0.908)	0.901 (0.898)	0.895 (0.891)	0.888 (0.884)	0.880 (0.878)
NN	0.942 (0.935)	0.943 (0.934)	0.944 (0.938)	0.946 (0.939)	0.946 (0.940)	0.945 (0.940)
SVM	0.955 (0.946)	0.958 (0.956)	0.963 (0.953)	0.967 (0.954)	0.967 (0.957)	0.968 (0.958)

ORL data의 PLS 변환



(a) 부분 최소제곱법 변환 인식률

ORL data의 PCA 변환



(b) 주성분 분석 변환 인식률

(그림 4) ORL 자료의 변환 인식률

〈표 4〉 ORL 자료의 방법별 주성분 분석과 부분 최소제곱법 인식률의 차이에 대한 검정
(유의수준 $\alpha = 0.05$) ** 유의적 차이

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

〈표 5〉 ORL 자료의 부분 최소제곱법을 이용한 방법별 인식률의 차이에 대한 검정
(유의수준 $\alpha = 0.05$)

(a) 방법별 인식률의 차이에 대한 F값 및 유의확률

개체-간 효과 검정

종속변수: 정분류율

소스	제III유형 제곱합	자유도	평균제곱	F	유의 확률
수정 모형	1.713E-02 ^a	8	2.142E-03	33.287	.000
점편	21.288	1	21.288	330869.995	.000
방법	1.706E-02	3	5.687E-03	88.390	.000
상분	7.238E-05	5	1.448E-05	.225	.943
오차	9.651E-04	15	6.434E-05		
합계	21.306	24			
수정 합계	1.810E-02	23			

a. R제곱=.947(수정된 R제곱=.918)

(b) 방법별 인식률의 차이에 의한 집단군 형성

정분류율

Tukey HSD^{ab}

방법	N	집 단 군		
		1	2	3
QDA	6	*****		
LDA	6		*****	
SVM	6			*****
NN	6			*****
유의확률		1.000	1.000	.999

동일집단군의 그룹에 대한 평균이 표시됩니다.

유형 III 제곱합에 기초합니다.

오차항은 평균제곱(오차) = 6.434E-03입니다.

a. 조화평균 표본 크기 6.000을(를) 사용합니다.

b. 유의수준 = .05.

4. 결 론

본 논문에서는 얼굴 이미지의 부분 최소제곱법과 주성분 분석법을 이용하여 4가지 분류방법(LDA, QDA, NN, SVM)을 통해 얼굴 이미지 자료를 분류하였다. 실험 결과를 통해 효과적인 얼굴 이미지 추출 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 부분 최소제곱법 변환 방법이 주성분 분석 변환 방법 보다 우수한 성능을 보임을 알 수 있었다. 또한 제한된 얼굴인식 실험 자료에 의존한 결과이지만 부분 최소제곱법 특징을 이용했을 때 SVM, NN, LDA 는 그 성능 면에서 비슷한 인식 성능을 가지고 있다고 할 수 있겠다.

참 고 문 헌

- [1] K. Fukunaga, "Introducion 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", Bioinfomatics 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.
- [7] 김기영, 전명식, "다면량 통계자료분석", 자유아카데미, 1999
- [8] 김도향, "차원 축소 특징을 이용한 얼굴 인식 방법의 성능 비교", 석사학위논문, 2004.
- [9] 김선우, 김연주, 김종원, 윤길원, "부분 최소제곱회귀(Partial Least Squares Regression) 이론과 분광학학적 혈중 혈액글로빈 진단에의 응용", 응용통계연구, 제10권, 2호, pp.227-239, 1997.
- [10] 노형진, "다면량분석 이론과 실제", 형설출판사, 2005.
- [11] 문지현, 김학일, 류춘우, 이응봉, 전성욱, "생체 인식 시스템 성능 평가를 위한 연구", 정보과학회지, 제19권, 제7호, pp.60-71, 2001.
- [12] 박성현, 조신섭, 김성수, "한글 SPSS", SPSS 아카데미, 2002.
- [13] 이재훈, 전인자, 이정훈, 이필규, "오류-역전파 신경망 기반의 얼굴 검출 및 포즈 추정", 정보처리학회, 제9-B권, 제6호, pp.853-862, 2002.
- [14] 장명탁, "나충신경망 은닉뉴런수의 효율적인 최적화", 정보과학회, 제25권, 제9호, pp.1333-1341, 1998.



이 창 범

e-mail : chblee@empal.com

1995년 전남대학교 전산학과(학사)

2001년 전남대학교 전산학과(이학석사)

2005년 전남대학교 전산학과(이학박사)

1995년~1999년 대우정보시스템(주)

2005년~현재 울산대학교 컴퓨터정보통신

공학부/DMITRC 연구교수

관심분야: 정보검색, 자연어처리, 문서요약 등



김 도 향

e-mail : kissingdh@hanmail.net

2002년 전남대학교 통계학과(학사)

2004년 전남대학교 통계학과(이학석사)

2005년~현재 University of Minnesota,

School of Statistics 박사과정

관심분야: 생물통계, 의학통계, 패턴인식 등

백 장 선



e-mail : jbaek@chonnam.ac.kr
1981년 연세대학교 응용통계학과(학사)
1984년 연세대학교 대학원
응용통계학과(이학석사)
1991년 미국 Texas A&M 대학교 대학원
통계학과(이학박사)

1993년 ~ 1995년 전남대학교 통계학과 전임강사

1995년 ~ 현재 전남대학교 통계학과 교수

관심분야 : Nonparametric Function Estimation, Multivariate Analysis 등



박 혁 로

e-mail : hyukro@chonnam.ac.kr
1987년 서울대학교 전산학과(학사)
1989년 한국과학기술원 전산학과
(공학석사)
1997년 한국과학기술원 전산학과
(공학박사)

1994년 ~ 1998년 한국과학기술정보연구원 연구원

2002년 ~ 2002년 University of Maryland UMIACS Post Doc.

1999년 ~ 현재 전남대학교 전자컴퓨터정보통신공학부 교수

관심분야 : 정보검색, 자연어처리, 데이터베이스 등