

논문 2004-41SP-6-6

다중 클래스 SVMs를 이용한 얼굴 인식의 성능 개선

(The Performance Improvement of Face Recognition Using Multi-Class SVMs)

박 성 욱*, 박 중 욱*

(Sung-Wook Park and Jong-Wook Park)

요 약

기존의 다중 클래스 SVMs은 클래스의 개수가 증가되면, 이진 클래스 SVMs의 수도 증가되어 분류를 위해 많은 시간이 요구된다. 본 논문에서는 분류 시간을 줄이기 위하여, PCA+LDA 특징 부 공간에서 NNR을 적용하여 클래스의 개수를 줄이는 방법을 제안한다. 제안된 방법은 PCA+LDA 특징 부 공간에서 간단한 NNR을 사용하여, 입력된 테스트 특징 데이터와 근접된 얼굴 클래스들을 추출함으로써 얼굴 클래스의 개수를 줄이는 방법이다. 클래스 개수를 줄임으로, 본 방법은 기존의 다중 클래스 SVMs에 비하여 훈련 횟수와 비교 횟수를 줄일 수 있고, 결과적으로 하나의 테스트 영상을 위한 분류 시간을 크게 줄일 수 있다. 또한 실험 결과, 제안된 방법은 NNC 기법보다 낮은 에러율을 가지며, 기존의 다중 클래스 SVMs보다 동일한 에러율을 갖지만, 보다 빠른 분류시간을 가짐을 확인할 수 있었다.

Abstract

The classification time required by conventional multi-class SVMs(Support Vector Machines) greatly increases as the number of pattern classes increases. This is due to the fact that the needed set of binary class SVMs gets quite large. In this paper, we propose a method to reduce the number of classes by using nearest neighbor rule (NNR) in the principle component analysis and linear discriminant analysis (PCA+LDA) feature subspace. The proposed method reduces the number of face classes by selecting a few classes closest to the test data projected in the PCA+LDA feature subspace. Results of experiment show that our proposed method has a lower error rate than nearest neighbor classification (NNC) method. Though our error rate is comparable to the conventional multi-class SVMs, the classification process of our method is much faster.

Keywords : Multi-Class SVMs, PCS, LDA, Face Recognition

I. 서 론

얼굴 인식을 위한 중요한 단계로서 얼굴 특징 추출단계와 추출된 특징 표현을 기반으로 하는 얼굴 특징 분류 단계가 있다. 얼굴 특징 추출 단계에서 PCA(Principal Component Analysis)또는 LDA(Linear Discriminant Analysis)를 이용한 방법이 가장 효과적인 방법으로 알려져 있다^[1,2]. Eigenface와 Fisherface로 잘 알려진 이들 방법들은 일반적으로 얼굴 외형에 대해 직접적

으로 적용된다. 얼굴인식을 위해 2차원 얼굴 크기 영역은 크기의 1차원 벡터로 표현할 수 있으며, 크기의 1차원 벡터는 얼굴 영상을 eigenface 성분으로 사상시킴으로서 저 차원의 새로운 벡터로 재구성될 수 있다.

PCA에 기반한 얼굴 특징 추출 방법은 클래스 정보를 사용하지 않고, 특징 공간에서의 데이터 분포의 특성을 유지하면서 영상의 차원을 줄이는데 목적을 둔다. 따라서 PCA 방법은 인식을 위한 분류의 목적으로 사용하기에는 적합하지 않다^[3]. LDA에 기반한 방법은 특징 추출을 위해 FLD(Fisher's Linear Discriminant) 기법을 사용하며, 클래스들 사이의 거리는 최대화하고 클래스에 속한 데이터들의 거리는 최소화시키는 분류 방법이다^[4]. 성능적으로 LDA에 기반한 얼굴 특징 분류가

* 정희원, 인천대학교 전자공학과

(Dept. of Electronic Engineering, Univ. of Incheon)

※ 본 연구는 한국과학재단 지정 인천대학교 멀티미디어 연구센터의 지원에 의한 것입니다.

접수일자: 2004년 1월13일, 수정완료일: 2004년11월4일

PCA에 기반한 얼굴 특징 분류보다 우수하다^[5]. 그러나 LDA 기반한 알고리즘은 시스템의 분류 바이어스가 필연적으로 커지고 훈련영상 개수가 충분하지 않을 경우 fisherface의 계산이 어려워지는 단점을 가지고 있다. 이 문제를 해결하기 위해 fisherface를 위한 LDA에서 PCA개념을 적용하는 PCA+LDA 방법을 사용한다^[6].

얼굴 특징들을 분류하기 위한 분류기로서, 특징 공간상의 특징 벡터들과 테스트 얼굴 영상의 특징 벡터와의 유클리디안 거리를 이용하여 제일 가까운 거리에 해당하는 특징벡터의 클래스를 인식 클래스로 선정하는 NNC(Nearest Neighbor Classifier), BPN(Back Propagation Networks)이 있다. 그리고 최근에는 얼굴 특징 분류 기법으로 기존의 방법들에 비해 명확한 이론적 근거에 기반하고 간단한 알고리즘을 가지는 다중 클래스 SVMs가 많이 사용되고 있으며, SVMs는 각 특징들 사이의 최적의 경계 분리 면을 제시하여 뛰어난 특징 분류 성능을 나타낸다^[7]. 그러나 얼굴 인식에 사용되는 얼굴 클래스들이 증가하게 되면, 다중 클래스 SVMs를 구성하는 이진 클래스 SVMs의 훈련 횟수와 비교 횟수가 증가하여 분류 시간이 크게 증가하는 단점이 있다.

본 논문에서는 얼굴 특징 분류를 위해 Nearest Neighbour Rule(NNR)을 사용하여 기존의 다중 클래스 SVMs에 대해 에러율을 유지하면서 보다 더 빠른 분류 시간을 가지는 방법을 제안한다. 제안된 방법은 PCA+LDA 특징 공간으로 투영된 테스트 특징과 가장 가까운 거리의 얼굴 클래스들을 순서대로 추출하여, 이들 중 몇 개만을 사용함으로써, 기존의 다중 클래스 SVMs에서 사용되는 얼굴 클래스 수를 크게 줄이는 방법이다. 제안된 방법은 NNR을 사용하여 얼굴 클래스의 수를 줄인 후 다중 클래스 SVMs를 사용한다. 각 클래스에 속한 훈련 영상들에 대하여 PCA+LDA 각 클래스 중심 특징 벡터들과 테스트 특징벡터와 가장 가까운 거리 순서대로 몇 개의 클래스 중심 특징 벡터들을 추출하여 사용함으로써 하나의 테스트 특징에 대한 분류 시간을 크게 줄일 수 있는 방법이다.

제안된 방법을 위해 표정, 포즈와 얼굴의 세부요소에서 변화가 심한 40클래스로 구성된 ORL(Olivetti Research Laboratory) 얼굴 영상 데이터베이스를 이용하여 실험하고 leave-one-out 검증 방법으로 에러율과 분류 시간을 측정하였다. 그 결과 제안된 다중 클래스 SVMs는 클래스 수가 증가 될수록 NNC, BPN 보다 낮은 에러율을 가지며, 기존의 다중 클래스 SVMs보다 빠른 분류 시간을 가지면서 동일한 에러율을 유지함을 확

인하였다.

본 논문의 구성은 다음과 같다. II장에서 이진 클래스 SVMs와 다중 클래스 SVMs에 대해 설명한다. III장에서 제안된 방법의 다중 클래스 SVMs를 대표적 분류기인 NNC, BPN 그리고 기존의 다중 클래스 SVMs과 비교하여 성능을 분석하고 IV장에서 결론을 내린다.

II. 본 론

1. 이진 클래스 SVMs

SVMs는 두 클래스를 효율적으로 분류하는 학습 머신의 한 방법으로 분류 성능이 뛰어나 패턴 인식 분야에서 각광을 받고 있다. 만일 $x_i \in R^n$ 인 데이터들이 x_1, x_2, \dots, x_l 의 집합을 갖는다면, 각 데이터들은 $y_i \in \{-1, 1\}$ 인 라벨 y_1, y_2, \dots, y_l 에 대응된다. x_i 는 n 차원의 벡터에 의해 표현되어진 i 번째 영상 데이터의 특징 벡터이고, y_i 는 i 번째 특징 데이터의 +1 또는 -1 클래스 레이블이다. l 은 주어진 훈련 데이터들의 수이다. 이진 클래스 SVMs 구조에서 $(w \cdot x) + b = 0$ (여기서 $w \in R^n, b \in R$)로서 표현되는 하나의 최적 분리 영역에 의해 +1 그리고 -1 로서 특징 데이터들을 분리한다. 그리고, 훈련 특징 데이터들을 두 클래스로 분리하기 위해 최적 분리 영역(선형 분리를 위해 두 클래스 데이터들을 분리할 어떤 w 와 b)을 찾아야 한다. "최적"을 정의하기 위해, 두 클래스들 사이의 마진을 고려해야한다. 이것을 그림으로 나타내면 그림 1과 같다.

그림 1에서 실선은 두개의 가능한 결정 경계 영역들을 가리키고, 각각은 훈련 데이터들을 두 클래스들로 분리시킨다. 하이퍼플랜에 대한 조건은 $(w \cdot x + b)y_i \geq 1$ 로 나타낼 수 있다. 두 점선들에 놓인 훈련 벡터 데이터들을 서포트 벡터(support vector)라 하며, 이것은 추출된 서포트 벡터를 제외한 모든 훈련 데이터들을 제거할 지라도 같은 결정 경계 영역을 얻을 수 있음을 의미한다.

서포트 벡터들로부터 분리 결정 경계 영역의 거리,




그림 1. 최적 분리 하이퍼플랜

Fig. 1. Optimal separating hyperplane.

즉 마진은 $1/|w|$ 로 주어진다. 따라서 두 클래스들 사이의 전체 마진은 $2/|w|$ 로 주어질 것이다. 여기서 마진을 최대화하기 위해 $(w \cdot x + b)y_i \geq 1$ 을 조건으로 하는 함수 $|w|^2/2$ 을 최소화해야한다. 즉, SVMs 학습은 $|w|$ 를 최소화하도록 w 와 b 를 찾는 것이다. 이러한 문제는 라그랑제 승수(lagrange multipliers)를 사용하여 해결할 수 있으며, 라그랑제 승수를 이용한 최적화 문제는 식 (1)과 같은 라그랑제 함수의 안장점(saddle point)을 이용하여 해결할 수 있다.

$$L(w, b, \alpha) = \frac{1}{2} w \cdot w - \sum_{i=1}^l \alpha_i [y_i (w \cdot x_i + b) - 1] \quad (1)$$

여기서 α_i 는 라그랑제 승수이다. 식 (1)은 w, b 에 대해 최소화되어야 하고, 음이 아닌 α 에 대해 최대화되어야 한다. 이를 위해 식 (2)와 같은 두개의 최적 조건을 이끌어낼 수 있다.

$$\frac{\partial}{\partial w} L(w, b, \alpha) = 0, \frac{\partial}{\partial b} L(w, b, \alpha) = 0 \quad (2)$$

따라서 식 (2)를 식 (1)에 적용하면 식 (3)을 산출할 수 있다.

$$w = \sum_{i=1}^l \alpha_i y_i x_i, \sum_{i=1}^l \alpha_i y_i = 0 \quad (3)$$

또한, 안장점에서 라그랑제 승수값은 식 (4)와 같이 0이 된다.

$$\alpha_i [y_i (w \cdot x_i + b) - 1] = 0 \quad (4)$$

식 (4)는 서포트 벡터를 제외한 모든 벡터들에서 $\alpha_i = 0$ 을 의미한다. 그리고 식 (1)을 보다 쉽게 해결하기 위해, 라그랑제의 쌍대 문제(dual problem)로 변형될 수 있다. 쌍대 문제는 식 (5)와 같다.

$$\max_{\alpha} W(\alpha) = \max_{\alpha} \left\{ \min_{w, b} L(w, b, \alpha) \right\} \quad (5)$$

식 (1), 식 (5) 그리고 식 (3)을 이용하면 쌍대 문제의 해법은 식 (6)과 같다.

$$\alpha^* = \arg \min_{\alpha} \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j x_i \cdot x_j - \sum_{k=1}^l \alpha_k \quad (6)$$

여기서 $\alpha_i \geq 0$ ($i=1, \dots, l$)이며 $\sum_{j=1}^l \alpha_j y_j = 0$ 이다. 식 (6)은 라그랑제 승수를 결정하며, 최적 하이퍼 플랜은 식 (7)로 나타낼 수 있다.

$$w^* = \sum_{i=1}^l \alpha_i y_i x_i, b^* = -\frac{1}{2} w^* \cdot [x_r + x_s] \quad (7)$$

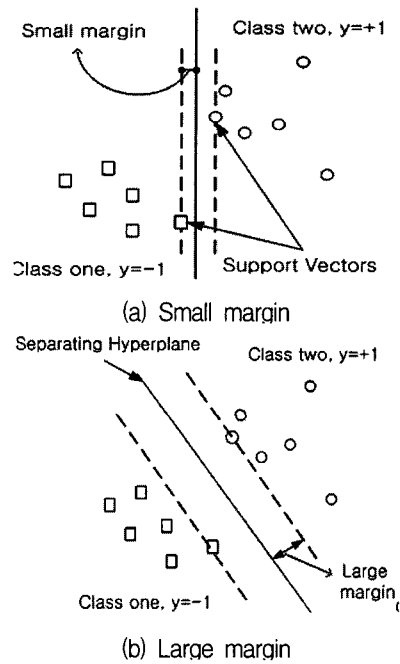


그림 2. 두 개의 분리가능한 하이퍼플랜
Fig. 2. Two possible separating hyperplanes.

여기서 x_r 과 x_s 는 $\alpha_r, \alpha_s > 0$ 그리고 $y_r = 1, y_s = -1$ 을 만족하는 support vector들이다. 따라서 임의의 테스트 데이터 x 는 식(8)을 이용하여 분류될 수 있다.

$$f(x) = \text{sign}(w^* \cdot x + b^*) \quad (8)$$

만일 훈련 데이터가 어떤 노이즈 때문에 선형적으로 분리될 수 없는 경우, 음이 아닌 여유 변수(slack variables) ξ_i 를 이용하여 약간의 오분류를 허용함으로써 최적 하이퍼 플랜을 선형적으로 만들 수 있다.

2. 다중 클래스 SVMs

얼굴 인식에서는 두 얼굴 클래스들보다 더 많은 얼굴 클래스들을 사용한다. SVMs은 기본적으로 이진 클래스 분류기이기 때문에, 셋 이상의 클래스들을 분류하기 위해서 이진 클래스 SVMs를 다중 클래스 SVMs로 확장해야한다. 클래스 개수가 k 개 일 때, 그림 2와 같이 분리 가능한 영역들 중에서 최적 분리 영역을 구하기 위해서 $k(k-1)/2$ 개의 이진 클래스 SVMs이 훈련된다.

일대일 설계에서 각각의 이진 클래스 SVMs은 다음 식과 같이 최적화 문제를 계산하게 된다^[8].

$$\text{Minimize } \frac{1}{2} |w_{ij}|^2 \quad (9)$$

$$\text{subject to } w_{ij} \cdot x_k + b_{ij} \geq 1, \text{ if } y_k = j$$

$$w_{ij} \cdot x_k + b_{ij} \leq -1, \text{ if } y_k \neq j$$





그림 3. 상향식 트리 구조
Fig. 3. Bottom-up tree structure.


그리고 분류 단계에서 그림 3과 같이 “Max Wins” 선정 방법을 사용한다^[9]. 즉, 클래스 i 와 j 를 분류하는 분리 경계면인 $w_{ij} \cdot x_k + b_{ij}$ 에 의해서 입력 데이터 x_k 가 클래스 i 로 분류되면 클래스 i 의 투표 값을 1증가시키고, 클래스 j 로 분류되면 클래스 j 의 투표 값을 1증가시킨다. 입력 데이터 x_k 는 최종적으로 투표 값이 가장 높은 클래스로 분류되게 된다. 클래스 개수가 k 개일 때, $k-1$ 번의 비교 횟수가 이루어지게 된다. 그러나 얼굴 인식에 사용되는 얼굴 클래스 개수가 증가하게 되면, 다중 클래스 SVMs를 구성하는 이진 클래스 SVMs의 훈련 횟수와 비교 횟수도 크게 증가되므로 분류 시간이 크게 증가하는 단점이 있다.

3. 개선된 다중 클래스 기법 SVMs 기법

얼굴 인식에서 데이터베이스가 커지게 되면, SVMs의 훈련 횟수와 SVMs간의 비교 횟수도 크게 증가되므로 분류 시간이 크게 증가하는 단점이 있다. 본 논문에서는 이러한 단점을 개선하기 위하여, 기존의 모든 얼굴 클래스 개수를 사용하는 다중 클래스 SVMs보다 정확도는 유지하면서 분류 시간을 줄일 수 있는 방법을 제안한다. PCA+LDA 특징 공간에서 훈련 클래스들의 분포 제안된 방법은 PCA+LDA 특징 추출 기법을 사용하여 모든 훈련 얼굴 클래스들의 특징 벡터를 구하고, 특징 공간에서 NNR을 사용하여 클래스의 수를 줄인 후 선택된 클래스만을 사용하여 분류에 소요되는 시간을 줄이는 방법이다. 그러나 선택되지 못하고 버려지는 클래스들 중에 테스트 영상이 분류되어야 할 클래스가 포함되어 있다면 애러가 되기 때문에, 테스트 특징 데이터와 모든 클래스들의 중심 특징 벡터와 유클리디안 거리를 측정하여 그 중 가장 가까운 거리 순서대로 몇 개만을 선택하고 나머지 클래스는 제외시킨다. 이것은 특징 공간에서 테스트 특징 벡터와 가장 가까운 거리를 갖는 클래스 특징 벡터가 분류되어야 할 클래스가 될 확률이 높기 때문에 직관적으로 거리가 너무 먼 클래스들을 제외시켜도 애러률에 영향을 미치지 않는



(a) First and second principal axes




(b) Third and fourth principal axes

그림 4. PCA+LDA 특징 공간에서 훈련 클래스들의 분포
Fig. 4. Distribution of training classes in PCA+LDA feature space.


다. 따라서, NNR을 사용하여 애러률에는 영향이 없으면서 기존의 다중 클래스 SVMs의 클래스 수를 줄일 수 있게 되어 결과적으로 분류 시간이 줄어들게 된다. 그림 4에 훈련 클래스들의 PCA+LDA 특징 공간을 보였다.

그림 4(a)에 기저벡터 중에서 첫 번째와 두 번째의 주요 특징 축(principal axis)으로 투영한 결과를 보였고, 세 번째와 네 번째의 특징 축으로 투영한 결과를 그림 4(b)에 나타내었다. 그림 4(b)에서 일부 특징 벡터들이 인접한 다른 얼굴 클래스 특징 벡터와 겹쳐 보이지만 첫 번째, 두 번째 축으로 투영된 그림 4(a)에서 뚜렷이 분리됨을 알 수 있다.

그림 5에 테스트 벡터와 NNR을 사용하여 클래스들을 추출하는 과정을 보였다. 각 클래스 중심 특징 벡터와 테스트 영상 특징 벡터와의 NNR을 사용하여 가까운 거리 순서대로 클래스들에 번호를 붙인다. 그리고 번호가 붙여진 클래스만을 사용함으로써 기존의 클래스 개수를 줄인다. 그림 5(a)에서 테스트 영상 특징 벡터는 사각형 모양으로 표시되었다.



(a) First and second principal axes



(b) Third and fourth principal axes

그림 5. NNR을 이용한 얼굴 클래스의 선택
Fig. 5. Choosing face class by NNR.

그림 5에 테스트 벡터와 NNR을 사용하여 클래스들을 추출하는 과정을 보였다. 각 클래스 중심 특징 벡터와 테스트 영상 특징 벡터와의 NNR을 사용하여 가까운 거리 순서대로 클래스들에 번호를 붙인다. 그리고 번호가 붙여진 클래스만을 사용함으로써 기존의 클래스 개수를 줄인다. 그림 5(a)에서 테스트 영상 특징 벡터는 사각형 모양으로 표시되었다. 테스트 영상 특징 벡터에서 NNR을 수행한 결과, 그림 4(a)에서 추출된 (1)~(4) 클래스 중 첫 번째로 7번 클래스가 추출되었고, 그림 4(b)에서는 추출된 (1)~(4) 클래스 중 두 번째로 7번 클래스가 가깝게 추출되었음을 보여준다. 또한, 테스트 특징 벡터가 옳은 분류가 되기 위해서는 테스트 특징 벡터로부터 NNR에 의해 소속된 7번 클래스 중심 특징 벡터가 반드시 추출되어야 하기 때문에, 기존의 클래스 개수(7개)의 절반에 해당하는 클래스 개수(4개) 만큼을 추출하였다. 따라서 제안된 방법에 의해 7개의 얼굴 클래스 개수를 4개의 얼굴 클래스의 개수로 줄일 수 있게 되고, 줄어든 얼굴 클래스의 개수를 이용하여 다중 클래스 SVMs를 구성할 수 있다. 그림 6과 그림 7에 기

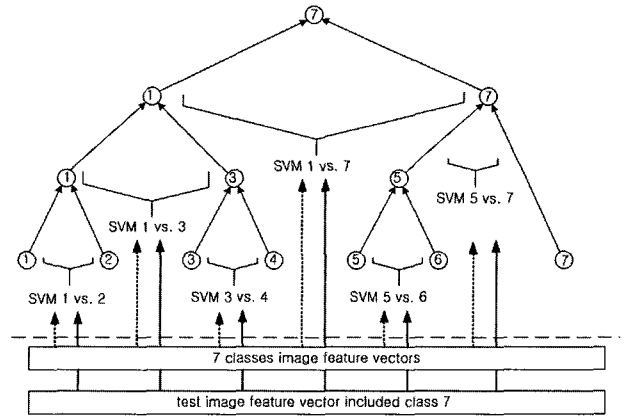


그림 6. 7개의 얼굴 클래스로 구성된 기존 다중 클래스 SVMs 구조
Fig. 6. Multi-class SVMs composed by 7 face class.

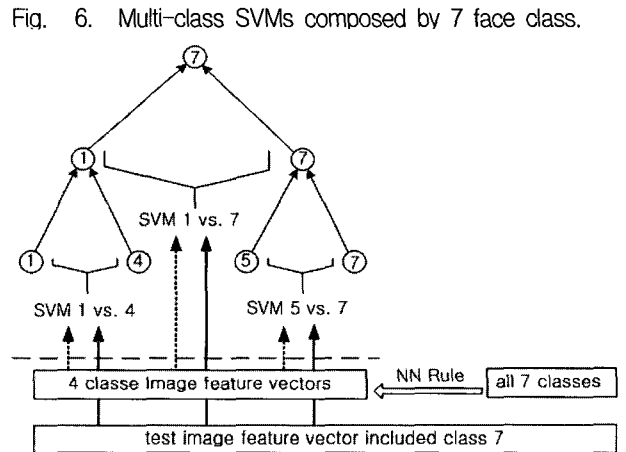


그림 7. 제안된 방법에 의한 다중 클래스 SVMs 구조
Fig. 7. Multi-class SVMs composed by the proposed method.

존 방법의 다중 클래스 SVMs의 구조와 개선된 방법에 의한 다중 클래스 SVMs의 구조를 나타내었다.

그림 6에서 하나의 테스트 영상 특징 벡터를 위해 훈련되는 이진 클래스 SVMs 개수는 21이고, 비교 회수는 6이다. 그리고 그림 7에서 제안한 방법에 의해 훈련되어지는 이진 클래스 SVMs 개수는 6이고, 비교 회수는 3이다. 따라서 개선된 다중 클래스 SVMs로서 이진 클래스 SVMs의 훈련 회수는 1/3.5, 비교 회수는 1/2로 줄어들게 되므로 하나의 테스트 영상 특징 벡터를 위한 분류 시간을 줄일 수 있다.

III. 실험 및 결과

제안된 방법의 성능을 분석하기 위해 ORL 얼굴 데이터베이스를 사용하여 실험하였다. 이 데이터베이스는 40클래스(각 10개 영상)의 얼굴에 대해 총 400개의 112x92 크기의 영상으로 구성되어 있고 표정, 포즈, 그



그림 8. ORL 얼굴 이미지들중 2명의 얼굴 클래스
Fig. 8. Two face classes on the ORL Database.

표 1. NNC, BPN, 기존의 SVMs 그리고 제안된 SVMs 방법의 leave-one-out 에러율 (N_c =얼굴 클래스의 수, N_t =전체 얼굴 클래스 데이터, N_f =특징 수)

Table 1. NNC, BPN, SVMs, SVMs of proposed method leave-one-out error rates (N_c = Number of face classes, N_t = Total number of face class data, N_f = Number of features).

N_c	N_t	N_f	NNC	BPN		SVMs	SVMs of proposed method
				200회반복	500회반복		
5	50	4	6% (3/50)	0% (0/50)	0% (0/50)	6% (3/50)	6% (3/50)
10	100	9	5% (5/100)	0% (0/100)	0% (0/100)	5% (5/100)	5% (5/100)
15	150	14	2.66% (4/150)	6.7% (10/150)	2.1% (3/150)	3.33% (5/150)	3.33% (5/150)
20	200	19	4% (8/200)	8% (16/200)	5% (10/200)	4% (8/200)	4% (8/200)
25	250	24	4% (10/250)	4% (10/250)	2.51% (6/250)	5.2% (13/250)	5.2% (13/250)
30	300	29	8% (24/300)	6.5% (19/300)	3.2% (9/300)	6% (18/300)	6% (18/300)
35	350	34	9.43% (33/350)	11.2% (39/350)	8.3% (29/350)	6.57% (23/350)	6.57% (23/350)
40	400	39	11% (44/400)	9.8% (39/400)	7.5% (30/400)	6.75% (27/400)	6.75% (27/400)

리고 얼굴의 세부요소에서 변화의 정도를 매우 크게 가진다. 그리고 메모리 사용량을 줄이고, 알고리즘을 구현할 때 행렬 계산의 편리함을 위해 112x92의 영상을 30x30 크기로 정규화하여 실험에 사용하였다. 그림 8에 실험에 사용된 정규화된 ORL 얼굴 데이터베이스의 일부를 나타내었다.

분류 에러율 측정을 위해 제안된 방법의 다중 클래스 SVMs와 NNC, BPN 그리고 기존의 다중 클래스 SVMs와 leave-one-out 방법을 사용하여 분석하였다. 먼저 1개의 영상을 제외하고 나머지 영상들을 학습 데이터로 사용하여 다중 클래스 SVMs를 훈련한다. 그리고 제외된 1개의 영상을 테스트 데이터로 다중 클래스 SVMs에 입력하여 분류 실험을 한 후 에러 유무를 측정하고, 이 방법을 전체 클래스 얼굴 데이터 개수만큼 반복하여 전체 에러율을 계산하였다.

실험 환경은 Windows 2000과 384Mbyte를 가지는 Pentium3 800MHz 에서 실행되었고, 선형 SVMs를 사




그림 9. 제안된 SVMs 방법과 NNC, BPN, 기존의 SVMs 과의 에러율 비교

Fig. 9. Comparison of error rates between NNC, BPN, SVMs and SVMs of proposed method.

표 2. 분류 시간 비교 (N_c =얼굴 클래스의 수, N_t =전체 얼굴 클래스 데이터, N_f =특징 수)

Table 2. Comparison of classification time (N_c = Number of face classes, N_t = Total number of face class data, N_f = Number of features).

N_c	N_t	N_f	NNC	BPN		SVMs	SVMs of proposed method
				200회반복	500회반복		
5	50	4	0.11	3.36	3.42	2.44	0.5
10	100	9	0.16	3.53	3.55	16.58	1.43
15	150	14	0.26	13.79	34.48	45.35	4.14
20	200	19	0.32	19.68	44.22	112.97	16.51
25	250	24	0.38	29.12	72.8	231.33	40.37
30	300	29	0.46	46.35	110.49	462.03	56.33
35	350	34	0.55	61.97	150.06	690.61	83.10
40	400	39	0.66	87.41	212.36	1088.28	112.85

용하였다. 표 1과 그림 9에 그 결과를 나타내었다.

표 1, 그림 9에서와 같이 에러율은 NNC에서 11%, 200회와 500회 반복 학습한 BPN에서 각각 9.8%, 7.5%의 에러율을 보였으며, 기존의 모든 얼굴 클래스들을 사용한 다중 클래스 SVMs에서는 6.75%로 제안한 방법의 다중 클래스 SVMs에서의 6.75%의 에러율과 동일하였다. 또한 클래스가 많아 졌을 때 다중 클래스 SVMs의 에러율이 가장 낮음을 보였다. 그러나 NNC의 에러율은 클래스의 개수가 증가됨에 따라 급격히 증가된다. 이는 많은 얼굴 클래스에 대해서 NNC 분류가 다중 클래스 SVMs에 비해 매우 민감함을 알 수 있다. BPN은 실험에 사용되는 클래스 개수에 따라 최적의 가중치가 변하므로 에러율의 굴곡 현상이 보인다. 클래스 개수가 적을 경우 최적의 가중치를 찾기가 쉬워 에러율이 낮지만, 클래스 개수가 커질수록 최적의 가중치를

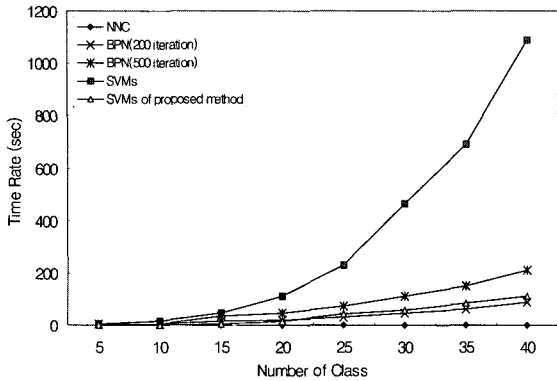


그림 10. 분류시간 비교

Fig. 10. Comparison of time for data classification.

구하기 어렵다는 것을 보여준다. 그리고 하나의 테스트 특징 벡터의 분류 시간 결과를 표 2와 그림 10에 보았다.

표 2, 그림 10에서와 같이 하나의 테스트 특징 벡터를 분류하는데 NNC와 200회의 BPN의 분류 시간이 제안된 다중 클래스 SVMs보다 빠르지만, 에러율이 높으므로 인식률이 저하되는 문제점이 발생한다. 따라서 전체적인 성능은 제안된 방법의 다중 클래스 SVMs보다 낫다고 볼 수 있다. 그리고 기존의 다중 클래스 SVMs의 분류시간은 얼굴 클래스 증가와 함께 크게 증가되었지만, 제안된 방법의 다중 클래스 SVMs의 분류 시간은 기존의 다중 클래스 SVMs의 분류 시간보다 최대 1/9.6 감소된 결과를 보였다.

IV. 결 론

논문에서는 PCA+LDA 특징 추출 기법을 통해 훈련 클래스 특징 벡터들과 테스트 특징 벡터를 각각 추출하고 NNC, BPN(200회 반복, 500회 반복), 모든 얼굴 클래스들을 사용하는 다중 클래스 SVMs를 이용한 얼굴 인식 시스템을 각각 구성하였다. 그리고 NNC를 사용하여 기존의 다중 클래스 SVMs에 사용되는 얼굴 클래스의 수를 줄이는 방법을 제안하고, 기존의 다중 클래스 SVMs 분류기를 사용하여 얼굴 인식 시스템을 구성하여 실험 결과를 비교하였다. 실험 결과, 기존의 다중 클래스 SVMs이 널리 사용되고 있는 대표적인 분류기

NNC, BPN에 비해 최고 7%의 향상된 결과를 보임을 확인하였다. 그리고 기존의 다중 클래스 SVMs에 비해 동일한 에러율을 유지하면서, 얼굴 클래스 수가 증가되더라도 분류 시간이 최대 1/9.6로 감소됨을 알 수 있었다. 따라서, 제안된 방법은 앞으로 많은 얼굴 클래스들이 사용되어질 얼굴 인식 시스템을 위해서 높은 인식률과 빠른 분류 시간을 보장하는 효율적인 얼굴 인식 기법으로 활용될 수 있을 것이다.

참 고 문 헌

- [1] M. Turk, A. Pentland, "Eigenfaces for recognition", Journal of Cognitive Neuroscience, vol.3, no.1, pp.71-86, 1991.
- [2] C. Liu, H. Wechsler, "Enhanced fisher linear discriminant models for face recognition", Proc. of 14th ICPR, Brisbane, Australia, pp.17-20, 1998.
- [3] P. Belhumeur, J. Hespanha and D. Kriegman, "Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection", IEEE Trans. on PAMI, vol. 19, no. 7, pp.711-720, July, 1997.
- [4] M. Aladjem, "Linear discriminant analysis for two classes via removal of classification structure", IEEE Trans. on PAMI, vol. 19, no. 2, pp.187-191, 1997.
- [5] A. Martinez, A. Kak, "PCA versus LDA", IEEE Trans. on PAMI, vol.23, no.2, pp.228-233, 2001.
- [6] J. Yang, H. Yu and W. Kunz, "An efficient LDA algorithm for face recognition", ICARCV, Singapore, December, 2000.
- [7] Vladimir N. Vapnik, The Nature of Statistical Learning Theory, Springer, 1999.
- [8] B. Heisele, P. Ho, and T. Poggio, "Face recognition with support vector machines: global versus component-based approach", IEEE International Conference on Computer Vision, vol.2, pp.688-694, 2001.
- [9] Guodong Guo, Stan Z. Li and Kapluk Chan, "Face Recognition by Support Vector Machines", IEEE International Conference on Automatic Face and Gesture Recognition, pp.26-30, March, 2000.

저 자 소 개

박성욱(정회원)
제36권 S편 제6호 참조

박종욱(정회원)
제36권 S편 제6호 참조

