

# 얼굴영상의 특징공간 추출과 SVM을 이용한 패턴분류 설계

김진숙, 강진숙, 차의영  
\*동의공업대학 컴퓨터정보계열  
\*부산대학교 전자계산학과

## Design of Pattern Classification for Face Image Using Feature Space and SVM

Jin-Sook Kim, Jin-Sook Kang, Eui-Young Cha  
Dept. of Computer Information, Dongeui Institute of Technology  
Dept. of Computer Science, Pusan Nat'l University

### 요약

개인의 신분을 확인하는 생체인식기술은 정보기술이 고도화된 사회 속에서 정보보안의 관점에서 더욱 중요한 문제로 인식되기 시작했다. 이러한 생체인식 영역 중에서 비교적 거부감을 덜 주면서 어느 정도의 인식율을 제공하는 얼굴인식 분야의 연구는 지난 수년간 활발하게 진행되었다. 보통 전통적으로 얼굴인식에는 우선 PCA가 적용되어 데이터를 축소하고 LDA가 얼굴인식을 위한 특징벡터를 추출하는 역할을 수행한다. 본 논문에서는 이러한 이원적인 과정을 동시 대각화를 통해 하나의 과정으로 통합하고 기존의 유클리디언 디스턴스 대신에 SVM(Support Vector Machine) 패턴 분류기를 사용하여 얼굴인식을 수행하는 알고리즘을 제안한다.

### 1. 서론

컴퓨터와 네트워크의 비약적으로 발전하고 급속하게 다양한 응용 분야가 제시되면서, 많은 거래가 사이버 상으로 이루어지게 되었다. 이에 따라 보안의 문제는 선택이 아닌 필수 문제로 인식되기 시작하였고 생체인식도 이러한 사회적 변화의 결과로서 주목받기 시작했다. 생체인식 중에서도 사용자에게 거부감을 비교적 덜 주고 인식률에 있어서도 어느 정도의 성능을 보장하는 연구가 얼굴인식 분야에서 지난 10년간 활발하게 진행되었다.

얼굴인식은 크게 보면 영상 내 얼굴을 검출하는 얼굴검출 단계와 얼굴인식의 두 단계로 분리될 수 있다. 본 논문은 얼굴검출은 이미 수행되었다는 것을 전제한다. 따라서 얼굴인식 단계에 초점을 둔다.

얼굴의 영상을 인식에 사용되는 기법으로는 형판정합(Template Matching) 기법, 수학 통계적인 기법인 주성분 분석(PCA) 기법과 선형판별 분석(LDA) 기법, Support Vector Machine(SVM), 신경망 그리고 Elastic Graph Matching 기법 등 다양한 방법이 적용되고 있다[1].

이 가운데 PCA는 얼굴영상 데이터가 가지는 고차원의 영상공간을 저차원으로 표현하여 고유공간(eigenspace)을 형성한다. 고유공간의 기저를 이루는 벡터들을 고유얼굴(eigenface)[2]라고 한다. PCA는 고차원의 데이터 집합을 저차원 공간으로 표현하는 데는 유용하지만 클래스 분류의 정확도 관점에서는 문제를 가지고 있다. LDA는 클래스 간 분류가 잘 되도록 하는 관점에서 고안된 수학 통계적 분류 방법이다.

이원적 패턴 분류 문제를 해결하기 위한 방안으로 제안된 SVM은 클래스간의 분리 마진을 최대화하여 얻어진 초평면(hyperplane)으로 얼굴 영상 패턴의 분류를 수행한다.

본 논문에서는 이론적 배경이 되는 LDA과 SVM에 대한 논의를 2장에서 상세히 다루고, 3장에서는 이러한 이론을 바탕으로 개선된 얼굴영상 특징 추출 방법을 제안한다. 4장과 5장은 위의 이론을 바탕으로 개선된 얼굴영상 인식 알고리즘을 제안하고 향후 과제에 대하여 논의한다.

### 2. 이론적 배경

### 2.1 선형 판별 분석

좋은 패턴분류 결과를 얻기 위한 중요한 전제는 분류되는 데이터의 내부적인 표현을 적절하게 선택하는 것이다. 이러한 데이터 표현 값을 표현하는데 범위 내의 가능한 한 간결한 클러스터에서 데이터를 요약하여야 한다. 그것으로 또한 각 개별적인 클래스의 분할이 가능하도록 하여야 한다. 여기에 필수적으로 필요한 변환은 분석되는 데이터에 의해 결정된다.

Karhunen-Loeve변환 또는 PCA에 기초한 방법, 즉 보통 "eigenfaces"[2-5]라고 불리우는 방법이 차원 축소에 중요한 역할을 하고 있고 훌륭한 성능을 보여주고 있다. 그러나 패턴 분류 능력을 최대화하기 위해서는 클래스들간 분산과 클래스 내의 분산을 고려하는 LDA가 일반적으로 우수한 성능을 보여왔다. LDA의 기본 아이디어는 특징 데이터들이 변환 후에 가장 잘 분류될 수 있는 선형 변환을 찾는 데 있다. 즉, 같은 클래스 내의 특징들은 더욱 모여지도록 하고 다른 클래스간의 특징들은 서로 더 멀어지도록 하는 선형 변환을 함으로서 분류가 명확해질 수 있도록 하는 것이 LDA의 기본 핵심 개념이다.

M-클래스 문제에서 클래스 내(within) 분산과 클래스 간(between) 분산인  $S_w$  와  $S_b$  는 다음과 같이 정의된다.

$$S_b = \sum_{i=0}^M (\mu_i - \mu) (\mu_i - \mu)^T = \Phi_b \Phi_b^T \quad (1)$$

$$S_w = \sum_{i=0}^M \sum_j = \Phi_w \Phi_w^T \quad (2)$$

위의 식에서  $\mu$  는 전체 평균 벡터를 의미하고  $\Phi_b$  는  $(\mu_i - \mu)$  을 열로 갖는  $n \times M$  행렬이다. 여기서  $n$  은 한 영상의 차원이다.  $\sum_j$  는 각 클래스들의 평균 벡터이며,  $\mu_i$  주위의 서로 다른 클래스  $C_i$  의 샘플 벡터들의 평균적 분산을 나타낸다.

클래스의 분류는 샘플들의 클래스 내 분산 행렬의 디터미넌트에 대한 클래스 간 분산 행렬의 디터미넌트의 비율이 최대화되는 행렬을 통해 이루어진다.

$$T(A) = \arg \max_A \frac{|AS_b A^T|}{|AS_w A^T|} \quad (3)$$

위에서  $A$  는  $m \times n$  ( $m \leq n$ )인 행렬이고 수식 (3)의 최적화 문제에 대한 해는 다음과 같은 일반화된 고유값 문제를 해결하는 것과 같다.

$$S_b A^* = \lambda S_w A^* \quad (4)$$

수식(4)의 해는  $S_w$  의 역행렬을 계산하고 행렬  $S_w^{-1} S_b$  의 고유값 문제를 해결하는 것이지만, 이 방

정식이 고차원 행렬의 역행렬을 포함하고 있기 때문에 사실상 해결이 쉽지 않다. 따라서 실제로 보통 사용되는 LDA 알고리즘은  $S_b$  와  $S_w$ , 모두를 동시에 대각화시킬 수 있는 행렬 즉, 다음 식을 만족하는 행렬  $A$  를 구하는 것이다.

$$A S_w A^T = I, \quad A S_b A^T = \Lambda \quad (5)$$

대부분의 알고리즘은 클래스 내의 분산 행렬이 정칙인 것을 요구한다. 왜냐하면 이 알고리즘은  $S_w$  를 먼저 대각화하기 때문에  $S_w$  가 비정칙이 되면 역행렬이 존재하지 않게 되어 대각화가 불가능해지기 때문이다. 그러나 학습 샘플의 수가 샘플 벡터의 차원보다 작은 경우가 대부분의 경우이므로 문제의 소지가 있다. 이러한 문제는 PCA를 먼저 수행하여 고차원의 영상 공간의 데이터를 저차원으로 사영시킴으로서 해결이 된다. 이러한 PCA단계는  $S_b$  와  $S_w$  모두에게서 영공간(null space)을 제거하는데 도움이 된다.

패턴 분류를 위한 선형 판별 함수는 다음과 같다

$$D_i(X) = A^* T (X - \mu_i), \quad i = 1, 2, \dots, m \quad (6)$$

### 2.2 Support Vector Machine

Support Vector Machine(SVM)은 1995년 Vapnik 와 그의 동료들에 의해 제안되었다. SVM은 원래 이원 패턴 인식 문제를 해결하기 위한 방법으로서 구조화 위험 최소화 이론에 그 바탕을 두고 있다. 기본적인 아이디어[6]는 두 클래스에 속한 데이터의 집합이 주어지면 SMV은 두 클래스 간 거리를 최대화하여, 두 클래스를 분류해내는 최적의 분류 초평면을 찾는다. 여기에서 중요한 역할을 담당하는 support vector 는 각 클래스에 속하는 입력 데이터 중에 초평면에 가장 근접하여 모여있는 벡터를 말한다.

선형적으로 분리 가능한 패턴의 경우에서 훈련벡터와 출력 그리고 초평면은 다음과 같다.

$$(x_1, y_1), \dots, (x_l, y_l), \quad x_i \in R^N, \quad y_i \in \{-1, +1\} \\ \omega^T \cdot x + b = 0 \quad (7)$$




그림 1 초평면(hyperplane)과 분리 마진

위와 같이 훈련벡터 집합이 주어졌을 때 최적의 초평면의 파라미터  $w$  와  $b$  를 구하는 것은 다음과 같이 기준점을  $\pm 1$  에 두고 재 정의된 canonical 초평면의 조건을 만족하여야 한다.

$$y_i [(w \cdot x_i) + b] \geq 1, \quad i=1, \dots, l \quad (8)$$

찾고자 하는 선형 분리 함수를  $g(x)$  라고 한다면, 임의의 입력벡터  $x$  에서  $g(x) = 0$  에 정사영시킨  $x_p$  까지의 거리  $r$  이라 두면  $x$  는 다음의 식과 같다.

$$x = x_p + r \frac{w}{\|w\|} \quad (9)$$

$x$  가 support vector 이면  $r = \frac{\pm 1}{\|w\|}$  이고 분리마진  $\rho$  는  $\rho = \frac{2}{\|w\|}$  이다.  $\rho$  가 최대가 되기 위해서  $\|w\|$  를 최소화시켜야 한다. 따라서 다음의 두 가지 조건, 즉 식 (2)의 조건하에서 식(3)에 의한  $\mathcal{O}(w) = \frac{1}{2} \|w\|^2$ 를 최적화 하는 문제의 해는 라그랑제 함수의 안장점(saddle point)이다.

$$L(w, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l a_i \{y_i [(w \cdot x_i) + b] - 1\} \quad (10)$$

$a_i$  는 라그랑제 승수들이다. 위의 함수는 안장점에서  $w, b$  의 관점에서는 최소가 되며  $a_i$  는 최대가 된다. 안장점은  $w$  와  $b$  를 미분함으로서 구해진다. 1차 영역의 라그랑제 함수식을 전개하여 2차 영역의 문제로 정리하면 다음과 같다.

$$Q(a) = \sum_{i=1}^l a_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l a_i a_j y_i y_j x_i^T \cdot x_j \quad (11)$$

where  $a_i \geq 0, \quad i=1, \dots, l$

$$\sum_{i=1}^l a_i y_i = 0$$

최적의 라그랑제 상수가 결정되면 최적의 가중치 벡터와 최적의 기준값을 구할 수 있다.

$$w_o = \sum_{i=1}^l \alpha_{o,i} y_i x_i \quad (12)$$

$$b_o = -\frac{1}{2} w_o \cdot [x_r + x_s] \quad (13)$$

$x_r$  과  $x_s$  는 support vectors 이고  $\alpha_r, \alpha_s > 0, y_r = 1, y_s = -1$  이다.

새로운 입력 데이터  $x$  에 대해 분류는 다음과 같다.

$$f(x) = \text{sign}(w \cdot x + b) \quad (14)$$

위의 논의는 훈련 데이터가 선형적으로 분리 가능한 경우에만 제한된다. 최적화 분리 초평면을 분리 가능하지 않은 경우까지 일반화시키기 위해서, slack 변수  $\xi_i$  가 도입된다. 따라서 식(2)의 조건은 다음과 같이 수정된다.

$$y_i [(w \cdot x_i) + b] \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i=1, \dots, l \quad (15)$$

일반화된 최적화 분류 초평면은 다음의 식(11) 최소화함으로서 결정되며 그 것을 2차 영역의 문제로 정리하면 식(12)와 같게 된다.

$$\mathcal{O}(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad (16)$$

(C는 주어진 값이다.)

$$Q(a) = \sum_{i=1}^l a_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l a_i a_j y_i y_j x_i^T \cdot x_j$$

where,  $0 \leq a_i \leq C, \quad i=1, \dots, l$

$$\sum_{i=1}^l a_i y_i = 0 \quad (17)$$

최소화 문제에 대한 해답은 라그랑제 승수를 변화시키는 것을 제외하고 분리 가능한 경우와 동일하다.

### 3. 얼굴인식 과정 제안

얼굴 영상을 인식하는데 있어 PCA는 영상 데이터 내부 표현으로 사용하여 데이터 차원을 줄이는데 사용하고, LDA로는 패턴을 더 잘 분류하기 위한 특징 벡터를 추출하여 특징 공간을 만든다. 실제 패턴을 분류하는데는 일반적으로 유클리디언 거리가 적용된다.

2장에서 언급한 것과 같이 PCA단계는  $S_b$  와  $S_w$  모두에게서 영공간(null space)을 제거하는데 도움이 된다. 그러나 이 단계에서는 잠재적으로 유용한 정보를 잃을 수도 있다. 즉, 각 클래스마다 하나의 샘플영상만이 있는 극단적인 경우에  $S_w = 0$  제한을 조건으로  $S_b$  를 최대화하는 것이 의미 있기 때문이다. 따

라서  $S_w$ 가 영공간을 가지고 있다고 단순히 제거할 수는 없다[4].

제안된 알고리즘은 전통적인  $S_w$ 와  $S_b$ 의 동시 대각화 과정을 수정하여 차원 축소 단계를 클래스 분류를 위한 변환 행렬 계산 단계와 통합하고, 패턴 분류 단계에서 다중 SVM을 사용하여 인식의 정확도를 높인다. 알고리즘은 다음과 같다.

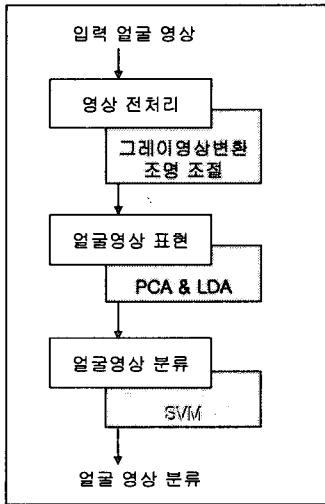


그림 2 제안된 얼굴인식 과정

① 영상 전처리

- ▶ 칼라 영상을  $\frac{R+G+B}{3}$  식에 의해 그레이 영상으로 변환
- ▶ 히스토그램 평활화 수행

② 얼굴 영상 표현

PCA와 LDA를 통합하여 얼굴 영상의 특징을 추출한다. 특징추출에 대한 자세한 과정은 다음과 같다.

- ▶  $S_b$ 의 영공간 제거와 대각화

$$Y^T S_b Y = D_b \quad (18)$$

- ▶  $S_w$  대각화

$$(Y D_b^{-\frac{1}{2}})^T S_b (Y D_b^{-\frac{1}{2}}) = Z^T S_b Z = I \quad (19)$$

고유 분해에 의해  $Z^T S_w Z$ 는 다음과 같이 대각화된다

$$U^T Z^T S_w Z U = D_w \quad (20)$$

$D_w$ 의 가장 작은 고유값에 대응하는 고유벡터들이 가장 잘 분류하는 차원을 이루게 된다.

▶ LDA 변환

$$A = (ZU)^T \quad (21)$$

행렬  $A$ 는 Fisher의 판별식의 분자와 분모를 동시에 다음과 같이 대각화하는 변환이다.

$$A S_w A^T = D_w, \quad A S_b A^T = I \quad (22)$$

③ 얼굴 영상 분류

다중 SVM 분류기를 이용하여 패턴을 분류한다.

4. 결론 및 향후 과제

SVM은 현재 얼굴인식에 보다는 객체 검출(Detection)에 많이 사용되고 있다. 얼굴의 특징벡터도 일종의 패턴으로 분류될 수 있는 데이터이다. SVM은 일단 학습이 완료되면 정확한 분류를 해낼 수 있는 학습 규칙을 가지고 있고 또한 비교적 속도와 복잡도 면에서도 매우 효율적인 패턴 분류기로 알려져 있다. 따라서 얼굴인식에 적용하면 좋은 결과를 얻을 수 있을 것이다.

[참고문헌]

- [1] W. Y. Zhao, R. Chellappa, A. Rosenfeld, P. J. Phillips, Face Recognition: A Literature Survey, UMD CfAR Technical Report CAR-TR-948, 2000
- [2] M. Turk and A. Pentland, "Eigenfaces for recognition", Journal of Cognitive Neurosciences, vol. 3, pp. 71-86, 1991
- [3] Martinez A M, Kak A C. PCA versus LDA. IEEE Transactions on Pattern Analysis and Machine Intelligence, 23(2), 2001: 228-232.
- [4] Hua Yu, Jie Yang, A Direct LDA Algorithm for High-Dimensional Data -- with Application to Face Recognition. Pattern Recognition 34(10), 2001, pp. 2067-2070
- [5] 양희성, 김유호, 이준호, "SKKUfaces: 조명변화, 얼굴 표정 변화에 강인한 얼굴 인식 방법", 소프트웨어 및 응용 제 28권 제2호, 정보과학회 논문지, 2001.2
- [6] C. J. C. Burges. "A Tutorial on Support Vector Machines for Pattern Recognition", Knowledge Discovery and Data Mining, 2(2), 1998