

## 지역특징분석을 이용한 SVM 커널 디자인

이일용\*, 안정호\*\*

### 요약

얼굴인식과 같은 고차원 영상의 패턴분류 문제에서는 특징추출과정이 필수적이라 할 수 있다. 특징 추출방법 중 부분공간기법은 데이터의 표현이 우수할 뿐만 아니라 차원 감소 면에서도 효율적이라 보고되고 있으며, 그 대표적인 방법으로 주성분분석, 선형판별분석 등이 널리 알려져 있다. 하지만, 이들 방법은 전역적 변환 방법으로써 포즈, 조명 등의 변화에 민감하여, 그 변화량이 크면 전역적 변환으로 인한 얼굴정보가 전체적으로 손실될 가능성이 크다. 따라서, 이러한 변화들에 대해 잘 대처하기 위해서는 얼굴영상에서 변화들을 상쇄시키는 정규화 작업을 수행해야만 한다. 정규화를 추구하는 이유는 일반적인 얼굴과 가깝게, 다시말해 평균 얼굴과 가깝게 하기 위함이고, 이러한 정규화를 위해서는 부분적 변환 방법이 이상적이라 할 수 있다. 이 방법은 변환으로 인한 얼굴 정보가 부분적 손실만을 유발하기 때문에 전역적 변환 방법에 비해 적합하다고 할 수 있다.

본 논문에서는 지역적 부분공간기법 중 지역특징분석을 SVM커널에 적용하여, 기존 SVM다항식 커널에 지역적 정보를 포함시킴으로써, 보다 강력하고 새로운 SVM커널을 디자인하였다.

## SVM Kernel Design Using Local Feature Analysis

Lee, Il-Yong\*\*, Ahn, Jung-Ho\*

### Abstract

The purpose of this study is to design and implement a kernel for the support vector machine(SVM) to improve the performance of face recognition. Local feature analysis(LFA) has been well known for its good performance. SVM kernel plays a limited role of mapping low dimensional face features to high dimensional feature space but the proposed kernel using LFA is designed for face recognition purpose. Because of the novel method that local face information is extracted from training set and combined into the kernel, this method is expected to apply to various object recognition/detection tasks. The experimental results shows its improved performance.

**Keywords :** 얼굴인식, 지역특성분석, SVM, 커널, 성근코딩

### 1. 서론

얼굴인식은 생체인식 기술 중 하나로 개개인의 얼굴정보를 이용하여 각종 보안시스템에 적용

가능한 기술로서, 1970년대에 연구가 시작되어 1990년대 이후에 연구가 활발히 진행되어온 분야로 사용자의 거부감이 없고, 사용자 인터페이스가 용이하다는 장점을 가지고 있어 현재는 보안 분야 외에도 오락산업 등에도 많이 적용되고 있는 연구분야이다.

이러한 얼굴인식 문제는 크게 세 가지 카테고리로 나뉘어 질 수 있는데, 이것은 전처리단계, 특징추출단계, 인식단계이다. 이것들은 궁극적으로 패턴인식 성능 향상에 그 최종 목표를 두고 있으며, 각각에 대한 세부적인 연구가 모듈별로 활발히 진행되어왔다.

여러 논문들[3]이 지적했듯이 전처리와 특징추

※ 제일저자(First Author) : 이일용  
접수일:2010년 01월 01일, 완료일:2010년 03월 24일

\* LG전자 전자기술원 정보기술 연구소  
[hamir77@lge.com](mailto:hamir77@lge.com)

\*\* 강남대학교 컴퓨터미디어정보공학부  
[jungcho@kangnam.ac.kr](mailto:jungcho@kangnam.ac.kr)

▣ 이 논문은 2009년도 강남대학교 교내연구비 지원에 의한 것임.

출 단계는 인식을 향상에 지대한 영향을 미친다. 좋은 인식기가 많이 개발되어 있는 지금의 시점에서 얼굴인식 시스템이 인식기를 교체하는 것보다 앞의 두 단계를 향상시키는 것이 현실적으로 더 좋은 얼굴 인식 시스템을 구성할 수 있다는 것이다.

부분공간을 이용한 특징추출 방법으로는 전체 데이터를 잘 표현해주는 기저벡터를 찾는 주성분분석(PCA : Principal Component Analysis)[4][7], 부류간의 평균거리를 최대화 해주는 기저벡터를 찾아주는 선형판별분석(LDA : Linear Discriminant Analysis)[7][8], 데이터의 독립성을 최대화하여 데이터의 원천을 분리해내는 독립성분분석(ICA : Independent Component Analysis)[6], 계수와 기저벡터의 양수화 조건을 가하는 비음수행렬분해(NMF : Nonnegative Matrix Factorization)[6]등이 대표적이라고 할 수 있다. 또한, 주성분분석의 고유벡터간 상관관계를 계산하여 지역특징을 추출함으로써 데이터 표현의 효율성을 높인 지역특징분석(LFA : Local Feature Analysis)이 보고되어 지역특징의 성근코딩(sparse coding)이 얼굴 영상의 차원 감소에 효율적임을 보고하고 있다[1][5].

본 논문에서는 부분공간 특징추출 방법 중 지역특징분석으로 생성된 커널(kernel)을 대표적인 커널 방법론인 SVM(Support Vector Machine)의 커널에 적용하여 새로운 커널을 디자인하는 방법을 기술하고자 한다.

## 2. 관련연구

### 2.1. 지역특징 분석

1996년에 Penev와 Atick에 의해 처음 제안된 지역특징분석[1]은 독립성분분석, 비음수행렬분해와 함께 대표적인 지역적 변환 방법을 사용한 공간 특징추출방법으로 꼽히고 있다. 엄밀히 말하자면, 지역특징분석은 얼굴영상의 전역적인 정보와 부분적 정보를 모두 보존하며, 자체적인 커널을 사용하여 특징공간으로의 사상도 시도하고 있다. 게다가 얼굴인식의 큰 문제점인 얼굴영상의 차원을 효과적으로 줄임으로써 보다 안정적인 계산과 일반화 성능을 성취할 수 있다.

지역특징분석은 우선 입력 데이터들로부터 생

성되는 선형적인 부분공간의 계층적 직교축들을 찾기위해 주성분분석을 수행한다. 각각의 입력영상을  $\phi^t(x)$ ,  $t=1, \dots, T$  라 하고, 이때  $x$ 는 화소값,  $T$ 는 전체 입력영상 수이다. 주성분분석은 아래와 같이 상관계수행렬(correlation matrix)을 대각화 하는 것으로 표현할 수 있다.

$$\begin{aligned} R(x, y) &= \langle \phi^t(x) \phi^t(y) \rangle \\ &= \frac{1}{T} \sum_{t=1}^T \phi^t(x) \phi^t(y) = \sum_{r=1}^T \Psi_r(x) \lambda_r \Psi_r(y) \end{aligned} \quad (1)$$

위 식으로부터 직교축 즉, 고유벡터(eigenvector)들  $\Psi_r(x)$ ,  $r=1, \dots, T$  을 구할 수 있다. 위에서 구해진 직교축들로부터 성분분석을 표현할 수 있는데,

$$\begin{aligned} \phi(x) &= \sum_{r=1}^T A_r \Psi_r(x), \\ A_r &= \int \Psi_r(x) \phi(x) \equiv \int K_r(x) \phi(x) \end{aligned} \quad (2)$$

이렇게 구해진 직교축들 중 제곱평균오차를 최소화 할 수 있는  $N$ 개의 축들을 선택하여 아래와 같이 복원을 할 수 있다.

$$\phi^{rec}(x) \equiv \sum_{r=1}^N A_r \Psi_r(x) \quad (3)$$

주성분분석은 영상차원감소에 윗등한 성능을 보이고, 그 표현이 아주 간결하지만 부분적인 정보를 전혀 포함하지 않고 있다는 단점을 갖고 있다. 그렇기 때문에 얼굴의 지역적인 특성에 대한 정보는 무시되었다고 볼 수 있다. 이 문제점을 해결하기 위해 지역특징분석은 가장 일반적인 지역성 커널을 생성하는데, 이때 커널은 아래 식(4)와 같이 주성분분석으로부터 성취된 축들을 이용한다.

$$K(x, y) = \sum_{r,s} \Psi_r(x) Q_{rs} \Psi_s(y) \quad (4)$$

$$Q_{rs} = \frac{1}{\sqrt{\lambda_r}} U_{rs} \quad (5)$$

이때,  $U_{rs}$ 는  $\Psi_r(x)$ 에 부합하고,  $U^T U = 1$ 을 만족하는 임의의 직교행렬로 정의된다. 따라서, 지역특징분석의 출력은 아래 식(6)과 같이 유도할 수 있다.

$$\begin{aligned} O(x) &= \int \sum_{r=1}^N \Psi_r(x) \frac{1}{\sqrt{\lambda_r}} \Psi_r(y) \phi(y) \\ &= \sum_{r=1}^N \frac{A_r}{\sqrt{\lambda_r}} \Psi_r(x) \end{aligned} \quad (6)$$

그리고, 이들의 상관계수는 아래 식(7)과 같이 주성분분석으로부터 얻어진 축들의 직교성을 이용하여 계산될 수 있다.

$$\langle O(x) O(y) \rangle = \sum_{r=1}^N \Psi_r(x) \Psi_r(y) \equiv P(x,y) \quad (7)$$

이렇듯, 지역특징분석은 주성분분석을 이용한 전역적인 변환으로부터 쉽게 지역적 특징의 상관성을 유도해낼 수 있고, 이러한 상관성을 갖는 지역특징분석의 출력들과 그 출력들에 대한 상관계수들은 아주 중요한 역할을 하게 된다.

위 과정을 요약하자면 다음과 같다. 주성분분석의 고유벡터  $\Psi_r(x)$ 와 고유값  $\lambda_r$ 이 주어졌을 때,

$$K(x,y) = \sum_{r=1}^N \Psi_r(x) \frac{1}{\sqrt{\lambda_r}} \Psi_r(y) \quad (8)$$

$$P(x,y) = \sum_{r=1}^N \Psi_r(x) \Psi_r(y) \quad (9)$$

를 산출해 낼 수 있다. 또한, 지역특징분석 출력들은 전역적인 정보를 모두 보존하고 있기 때문에 아래와 같은 원 영상 복원도 유도해 낼 수 있다.

$$A_r = \int \sqrt{\lambda_r} \Psi_r(x) O(x) \quad (10)$$

$$\phi^{rec}(x) = \sum_{r=1}^N \int \sqrt{\lambda_r} \Psi_r(y) O(y) \Psi_r(x) = \int K^{(-1)}(x,y) O(y) \quad (11)$$

이때, 커널의 역행렬은 식(12)와 같다.

$$K^{(-1)}(x,y) = \sum_{r=1}^N \Psi_r(x) \sqrt{\lambda_r} \Psi_r(y) \quad (12)$$

여기서 두 가지 중요한 사실이 내포되어 있는데, 우선 지역특징분석표현의 복원오차  $\langle \|\phi - \phi^{rec}\|^2 \rangle$ 가 주성분분석표현의 복원오차와 정확히 일치하기 때문에 지역성 정보를 갖는 지역특징분석표현도 최상의 복원 능력을 갖고 있다는 것이다. 그리고 또 다른 한가지는 커널의 역행렬이 정의되었기 때문에 커널로 사상된 이차적 공간(dual space)에서의 어떠한 연산을 수행하여도 그 결과를 입력공간으로 역사상할 수 있다는 점이다. 아래 그림 1은 커널과 지역특징분석 출력들의 상관관계를 보여준다. 그림 1에서 중앙 위의 영상은 전체 데이터의 평균영상(V=400, T=1024)에서의 6개 위치를 나타낸다. 그리고, 밑의 첫번째 열은 커널(N=50)에서의 반응지점들, 두 번째 열은 지역특징분석 출력들의 상관계수

에서의 반응지점들을 나타낸다. 그림에서 알 수 있듯이 각각의 반응지점은 지역성을 띄고있으며, 특히 눈썹(b), 눈꺼풀(c), 광대뼈(e)와 같이 얼굴에서 대칭적인 요소들에 대해서 좌우 동시에 반응한다는 것이다.

### 2.2. 지역 표현으로부터 얻어진 성근분산

앞서 1절에서 지역특징분석으로 인해 주성분분석의 단점을 보완하였다. 이 절에서는 지역성을 띄는 지역특징분석의 출력들의 차원을 줄여 보다 분별력 있는 점을 뽑아내는 방법에 대해 소개한다. 아래 (그림 1)은 지역특징분석의 출력들이다.



(그림 1) 원본영상(13열)과 지역특징분석 출력(24열)

위 (그림2)를 보면 이들은 각 영상의 분별요소들을 부각시킨다. 달리말하자면, 사람마다 개개인이 갖고 있는 얼굴특징들의 상관관계를 나타낸다고도 볼 수 있다. 여기에서 지역특징분석은 각 출력들에 대해 보다 분별력있는 점들을 뽑기위한 방법으로 측면억제기법을 사용하는데, 이 기법은 지역특징분석의 출력영상들 중 하나의 출력영상과 다른 출력영상들과의 상관관계  $P(x, x_m) \equiv P_m(x)$ 를 계산하여 서로 연관성을 갖는 영역을  $O^{pred}(x) = \frac{P_m(x)}{P(x_m, x_m)} O(x_m)$ 으로 예상한다. 이렇게 예상된 영역에 대해서는 활성화를 시키고, 나머지 영역은 모두 억제시킴으로써 특징점들을 추출해낸다. 이 기법이 바로 성근코딩(sparse coding)이다. 성근코딩은 지역특징분

석의 출력영상  $O(x)$  중 활성화된 점  $M$ 들의 집합  $\{O(x_m)\}_{x_m \in M}$  만을 취함으로써 각 지역특징 분석의 출력영상 안에서 가장 강력한 특징들을 추출해낸다. 성근코딩방법은 아래와 같다.

우선 성근점들의 집합  $M^{(0)} = 0$  으로 시작하여, 각 단계마다 획득된 성근점을  $M$ 에 추가한다. 각  $m$ 번째 단계에서는 두 가지 과정을 거친다. 첫째는 현재 성근점집합  $M^{(m)}$  이 주어졌을 때, 아래와 같이  $O(x)$  복원을 수행한다.

$$O^{rec}(x) = \sum_{m=1}^{|M|} a_m(x) O(x_m) \quad (13)$$

이때,  $a_m$ 은  $O(x)$ 의 복원 제공평균오차

$$E = \langle \|O^{err}(x)\|^2 \rangle \quad (14)$$


$$\equiv \langle \|O(x) - O^{rec}(x)\|^2 \rangle$$

를 최소화하는 것으로써 얻을 수 있다.

$$a_m(x) = \sum_{i=1}^{|M|} P(x, x_i) (P'^{-1})_{im}, \quad (15)$$

$$P(x_i, x_m) \equiv P'^{im}$$

$O(x)$ 의 복원을 마친 후  $O(x)$ 의 복원오차 중 가장 큰 점  $O^{rec}(x_{m+1})$ 을 성근점 집합  $M$ 에 추가한다. 위 과정의 반복은  $O(x)$ 복원오차가 어느 일정 값 아래를 만족할 때까지 수행하거나 원하는 수의 성근점을 획득할 때까지 수행한다.



(그림 2) 원본영상과 지역특징분석


출력영상내의 성근점(N=50,  $M^{(20)}$ )



(그림 3) 개인별 성근점

### 2.3. 인식단계에서의 커널 방법론

지난 몇 년동안 SVM커널 피셔 판별(KFD: Kernel Fisher Discriminant), 커널주성분분석(KPCA: Kernel Principal Component Analysis) 등 커널을 이용한 강력한 인식방법들이 소개되어왔다. 이들은 비단 인식문제 뿐만이 아니라 회귀, 비교사학습 등에도 다양하게 적용된다[2][3][4][8][9]. 이들 방법들은 저차원 입력공간에서의 대상 분류를 고차원 특징공간으로 사상하여 분류를 시도한다. 이것은 입력공간에서 선형으로 분류되지 못하는 데이터들을 보다 고차원 특징공간에서의 선형분류를 하기 위함이다. 아래 (그림 4)는 이러한 방법들의 예를 보여준다.



(그림 4) 커널을 이용한 2차원 데이터의 분류 예

위 (그림 4)는 2차원 공간에서 선형적으로 분류되지 않는 데이터를 3차원 특징공간으로의 사상을 시도하여 선형평면에 의해 분류가 가능하다. 이러한 시도는 곧 인식을 향상과 직결될 수

있는 것이다.

이처럼 입력공간에서 특징공간으로의 사상을 결정해주는 함수  $\Phi(x)$ 가 이 방법들의 핵심 문제라 할 수 있는데, 이 사상함수를 구하는 것은 사실상 불가능하다. 그래서, 일종의 편법을 이용한 것이 바로 커널이다. 각각의 데이터를 직접 특징공간에 사상하지 않고, 식(16)과 같이 데이터들 간의 내적 연산을 수행함으로써 사상함수의 역할을 대신할 수 있는데, 이것이 바로 커널 방법론이다.

$$K(x,y) = (\Phi(x) \cdot \Phi(y)), \quad \Phi: R^N \rightarrow F \quad (16)$$

가장 대표적인 커널 방법론은 SVM으로써 통계적 학습이론과 구조적 위험성을 최소화(structural risk minimization)하는 것을 바탕으로 Vapnik에 의해 소개되어 여러 응용분야에 성공적으로 적용되고 있다. SVM은 입력공간에서 선형적으로 분류될 수 없는 데이터들에 대해 고차원 특징공간으로 사상시킨 후 최적의 분리평면을 찾아낸다. 주로 쓰이는 커널로는 표1과 같이 RBF(Radial Basis Function)커널, 다항식커널(Polynomial)커널, 시그모이드(Sigmoid)커널 등이 있다.

<표 1> SVM에 적용되는 대표적 커널 함수들

커널함수	식
RBF	$K(x, x_i) = \exp(- \ x - x_i\ ^2 / \sigma^2)$
Polynomial	$K(x, x_i) = (x \cdot x_i)^{\text{degree}}$
Sigmoid	$K(x, x_i) = \tanh(k(x \cdot x_i) - \theta)$

각 커널의 성능은 데이터의 종류에 따라 서로 장단점을 보이며, 성능의 우월을 입증하는 연구 결과는 없고, 경험적으로 선택해야하는 것으로 알려져 있다.

### 3. 새로운 SVM 커널 디자인

입력영상에 대해 고차원 특징공간으로의 사상을 시도하여 최적의 분류를 시도하는 것은 현재 일반적인 분류방법으로 쓰이고 있으며, 그 중 SVM이 가장 대표적인 방법이라고 할 수 있다.

SVM은 선형분리평면 결정함수  $f(x) = \text{sgn}((w \cdot x) + b)$  를 위해, 기울기벡터

(weight vector)  $w$ 의 놈(norm)을 조정함으로써 VC-차원(VC-dimension)을 결정할 수 있다. 학습영상  $(x_1, y_1), \dots, (x_l, y_l), x_i \in R^N, y_i \in \{\pm 1\}$ 이 주어졌을 때, 분리평면은 아래 식(17)을 최소화함으로써 얻어질 수 있다.

$$\frac{1}{2} \|w\|^2 \quad \text{subject to } y_i \cdot ((x_i \cdot w) + b) \geq 1 \quad (17)$$

for  $i = 1, \dots, l$

그리고, SVM은 노이즈(noise)데이터에 대해 식(18)와 같이 연약변수들(slack variables)을 소개함으로써 보다 강인한 분류를 수행할 수 있다 [Cortes & Vapnik 1995].

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i$$

$$\text{subject to } y_i \cdot ((x_i \cdot w) + b) \geq 1 - \xi_i \quad (18)$$

for  $i = 1, \dots, l$

위의 볼록 최적화 문제(convex optimization problem)를 해결하기 위해 승수  $\alpha_i$ 를 갖는 라그랑지안 함수를 사용하고, 식(19)와 같이 최적화 문제의 듀얼형태(dual form)을 유도할 수 있다.

$$\sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,k=1}^l \alpha_i y_i \alpha_k y_k (x_i \cdot x_k)$$

$$\text{subject to } C \geq \alpha_i \geq 0, \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (19)$$

위 식에 의해 학습영상들에 확장된 형태인  $w = \sum_{i=1}^l \alpha_i y_i x_i$  를 얻을 수 있으며, 이때 식(17)의 제약식을 만족하는  $\alpha_i$  는 0이 아닌 값을 갖게 된다. 또한  $x_i$  들을 서포트벡터들(sv : support vectors)이라고 일컫는다. 따라서, 최종적으로 아래 식(20)과 같은 결정함수를 구할 수 있게 된다.

$$f(x) = \text{sgn} \left( \sum_{i=1}^v \alpha_i y_i (x \cdot x_i) + b \right),$$

$$v = \text{sv의 수} \quad (20)$$

마지막으로 SVM은 입력공간에서 선형분류가 불가능한 학습 영상에 대해서 고차원 특징공간으로의 사상을 시도하는데, 이때 사상함수를 직접적으로 구하는 것이 사실상 불가능하기 때문에 일종의 편법(tricks)으로 커널방법론을 사용한다. 위 식(19)의  $(x_i \cdot x_k) \rightarrow (\Phi(x_i) \cdot \Phi(x_k))$  연산과, 식(20)의  $(x \cdot x_i) \rightarrow (\Phi(x) \cdot \Phi(x_i))$  연산의 내적형태를 커널함수  $K(x,y) \equiv (\Phi(x) \cdot \Phi(y))$ 를

사용하여 아래 식(21), 식(22)로 대치할 수 있는 것이다.

$$\sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,k=1}^l \alpha_i y_i \alpha_k y_k K(x_i, x_k)$$

subject to  $\alpha_i \geq 0, \sum_{i=1}^l \alpha_i y_i = 0$  (21)

$$f(x) = \text{sgn} \left( \sum_{i=1}^v \alpha_i y_i K(x, x_i) + b \right)$$

$v = \text{sv의 수}$  (22)

이때, 주로 사용되는 커널함수는 [표1]에서 보이는 세 가지 함수들이다. 본 논문에서는 SVM에서 대표적으로 사용되어지는 커널함수 중 다항식 커널의 단점을 보완하고자 한다. SVM에서 다항식 커널  $K(x, y) = (x \cdot y)^d$ 을 사용하는 것은 두 영상의 모든 화소(pixel)들을 내적한 후, d만큼 제곱연산을 하여 사상된 특징공간에서 분리평면을 결정한다. 이것은 영상의 지역성을 전혀 고려하지 않기 때문에 바람직하지 못하다고 할 수 있다. 얼굴 영상과 같은 자연영상내에서 서로 거리가 먼 부분들의 상호연관성 보다는 서로 가까운 부분들의 상호연관성이 특징들으로써 보다 높은 신뢰성을 갖는다는 것이다[2].

본 논문에서는 이러한 문제점을 해결하기 위한 방법으로 영상간의 내적을 수행할 때, 지역적 특징정보를 갖는 지역특징분석의 커널을 이용하여 화소간 상호연관 정도에 따라 가중치를 부여하는 것을 제안하였다.

우선 다항식 커널은 식 (23)과 같이 유도할 수 있다.

$$K(x, y) = (x \cdot y)^d = \left( \sum_{i=1}^N z_i^{d_1} \right)^{d_2}$$
 (23)

이때  $d \approx d_1 d_2$ 이고,  $z_i = x_i y_i$ ,  $N$ 은 영상의 화소수이다. 식(23)은 아래 식 (24)과 같이 가중치  $M$ 을 부여한 것과 같다.

$$M^T = (1, 1, 1, \dots, 1), Z^T = (z_1, z_2, z_3, \dots, z_N)$$

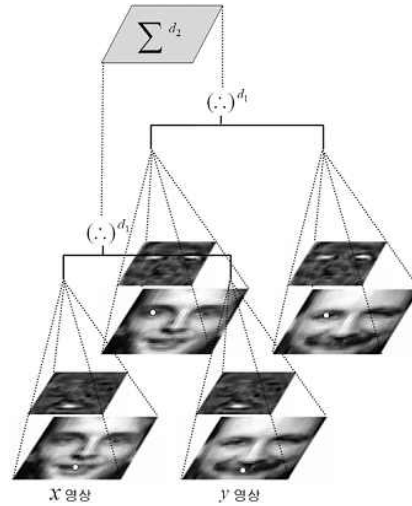
$$K(x, y) = (M^T Z^T)^{d_2}$$
 (24)

최종적으로 다항식 커널은 식(24)과 같이 변경될 수 있다. 이때,  $M$ 은 모든 화소들에게 똑같은 가중치를 주기 때문에 지역적 정보를 무시한다. 이것은 지역적 정보를 지향하는 요즘의 동향에 바람직하다고 볼 수 없다.

본 논문에서는 식 (25)와 같이 가중치가 모두 동일한  $M$ 대신 지역특징분석의 커널  $K$ 를 적용함으로써 각 화소 당 상관관계가 있는 화소들에 가중치를 부여하여 위와 같은 문제점을 해결할 수 있는 방법을 제안하였다.

$$K(x, y) = [(K^T Z)^{d_1}]^{d_2}$$
 (25)

아래 (그림 5)는 제안된 커널을 보여준다.



(그림 5) 지역특징분석의 커널을 이용한 SVM커널 디자인

각 화소들은 자신과 상관관계가 높은 주위 화소 또는 얼굴영상의 특성상 서로 대칭적으로 상관관계가 높은 화소들에 대해 지역특징분석의 커널을 통한 가중치를 부여받을 수 있다. 위 (그림 5)의 과정은 아래와 같이 정리할 수 있다[2].

1. 영상  $x$ 와 영상  $y$ 의 픽셀 간의 곱으로 정의된 또 다른 영상  $z$ 를 생성한다.
2. 모든  $z$ 의 모든 픽셀 값  $z(y)$ 를 식(26)와 같이 지역특징분석의 커널에 투영시켜 지역성의 정보를 포함한  $z'$ 를 생성한다.

$$z'(y) = \int K(x, y) z(y)$$
 (26)

3. 지역성의 차이를 더 늘리기 위해 각각의  $z(y)$ 에  $d_1$ 만큼의 제곱연산을 수행한다.
4.  $z'$  영상의 모든 픽셀들의 값을 더하고, 픽셀간의 거리가 먼 것들의 상관관계를 허락하기 위해  $d_2$ 만큼의 제곱연산을 수행한다.

### 4. 실험결과 및 분석

본 논문의 실험에 사용된 영상들은 캠브릿지 ORL얼굴데이터베이스(Cambridge ORL Face Database)다. 이 영상집합은 총 40개의 얼굴영상으로써, 한 사람당 10장, 40명의 얼굴영상으로 구성되어있다.

각 영상의 크기는 92 × 112이며, 회색영상이다. 아래 (그림 6)은 전체 영상집합의 일부인 각 사람당 1장의 영상, 총 40장을 보여준다.



(그림 6) ORL 영상집합의 일부 (1명당 1장의 영상, 총 40명)

위 원본 영상을 아래 (그림 7)과 같이 영상 전처리 과정을 미리 수행한 후 실험을 시도하였다.



(그림 7) 원 영상들에 대해 전처리 과정을 수행한 영상들

제안한 방법에 대한 실험은 주어진 학습영상 집합들에 대한 지역특징분석의 커널을 SVM커널에 적용하는것으로써, SVM의 다항식 커널의

변형을 수행하였다. ORL영상의 경우 지역특징분석으로써 생성되는 커널은 그 크기가 1024 × 1024의 행렬이다. 따라서 SVM의 커널에 두개의 영상이 입력되면, 두 영상의 화소간 곱을 수행한 후 커널과 내적을 수행한다. 이때, 지역 특징분석의 커널은 지역적 정보를 SVM의 커널에 적용시키는 역할을 하게되는 것이다.


본 실험에서는 SVM의 조건을 모두 똑같이 설정하고, 커널만을 다르게하였다. 다항식 커널의 경우 degree값을 0.1부터 10까지 0.1단위로 변경하며 결과를 측정하였으며, 제안된 커널 역시 d1, d2값을 마찬가지로 변경하며 실험하였다.

본 실험결과는 커널의 degree를 변경하여 얻은 모든 인식률의 평균을 취하지 않고, 최상위 인식률을 취했다. 그 이유는 모든 인식기의 인식 성능은 어떠한 데이터집합에도 완전히 독립적이라고 할 수 없기 때문이다. 이것은 이 실험에서 주어진 데이터 집합에 적합한 다항식 커널의 degree가 존재한다는 의미이다.

다음 <표 2>는 영상에 대해 다항식 커널을 그대로 사용하여 인식했을 때와 제안된 커널을 사용하여 인식했을 때의 인식률을 보여준다.

<표 2> 기존커널과 제안된 커널의 인식률비교

	다항식 커널	제안된 커널
평균인식률	86.5%	87%



(그림 8) 다항식과 제안된 커널과의 인식률 비교

### 5. 결론

본 논문에서는 SVM의 커널에 지역특징분석

의 커널을 적용함으로써 보다 효율적인 SVM 커널을 제안하였다. 우리는 부분공간특징추출방법 중 지역특징분석의 결과가 우수하다는 것을 실험한적이 있다. 우리는 그것을 바탕으로 전역적 특징보다 지역적특징을 기반으로 하는 것이 보다 좋은 정보를 이용하는것이라는 것을 알고 있으며, 제안된 방법은 현재 좋은 성능의 인식기인 SVM 커널의 단점을 보완하고자했던 연구이다.

우리는 본 연구에서 SVM의 커널을 변형하여 새로운 커널을 디자인하였지만, 인식률의 향상 정도에 비해 학습시 시간적, 계산적 비용이 높은 어려움을 겪었다. 하지만 테스트시에는  $O(N)$  ( $N$ 은 픽셀수)의 계산량이 증가되어 큰 문제가 되지 않는다. 이 문제점에 대한 해결 방안으로 커널의 크기를 줄여 계산량을 줄이는 연구가 추가적으로 진행되어야 할 것이다. 또한, 다항식 커널 뿐만 아니라 RBF, 시그모이드 커널도 적용하여 비교분석을 시도하는것도 향후 흥미로운 연구 주제가 될 것으로 기대된다.

### 참 고 문 헌

[1] Penio S Peniv, Joseph J Atick, "Local Feature Analysis : A general statistic theory for object representation", Network : Computation in Neural System, vol. 7, pp. 477-500, 1996

[2] Bernhard Scholkopf, Patrice Simard, Alex Smola, Vladimir Vapnik, "Prior Knowledge in Support Vector Kernels", Advances in Neural Inf. Proc. Systems, vol. 10, pp.640-646, MIT Press, 1998

[3] B. Heisele, P. Ho, and T. Poggio, " Face recognition with Support Vector Machines: Global versus Component-based Approach", IEEE Intl Conf. on Computer Vision, Vancouver, Canada, Vol. 2, pp. 688-694, 2001.


[4] Kwang In Kim, Keechul Jung, and Hang Joon Kim, "Face Recognition Using Kernel Principal Component", IEEE Signal Processing Letters, Vol.9, No.2, 2002

[5] Qiong Yang, Xiaoqing Ding, Zhengang Chen, "Discriminant Local Feature Analysis of Facial Images", Image Processing, Proc. Int. Conf. on, vol 2 Sept. 14-17, pp.863-866, 2003

[6] 유연희, "커널 주 성분 분석의 기저 벡터 근사를 이용한 독립 성분 분석기반 얼굴 표현법", 연세대학교 석사 학위논문, 2004

[7] Aleix M. Martinez, Avinash C. Kak, "PCA versus LDA", Pattern Analysis and Machine Intelligence, IEEE Transactions on , vol. 23, num.2, pp. 228-233, 2003

[8] Juwei Lu; Plataniotis, K.N.; Venetsanopoulos, A.N., " Face recognition using kernel direct discriminant analysis algorithms", Neural Networks, IEEE Transactions on , Vol.14, Issue 1, pp.117 - 126, Jan. 2003



### 이 일 용

2004년 : 연세대학교 공과대학 컴퓨터공학산업시스템공학과 대학원 (석사)

2004년~현재: LG전자 전자기술원

관심분야 : Pattern Recognition, Image Processing, Object Detection & Tracking, Image Enhancement 등



### 안 정 호

1998년 : 연세대학교 수학과(이학석사)

2001년 : Texas A&M University 통계학과(이학석사)

2006년 : 연세대학교 컴퓨터과학과 (공학박사)

2007년~현재: 강남대학교 컴퓨터미디어정보공부 교수

관심분야 : 패턴인식, 얼굴인식, 컴퓨터비전, 로봇비전, 영상처리 등