

논문 2011-48SC-5-2

클래스가 부가된 커널 주성분분석을 이용한 비선형 특징추출

(Nonlinear Feature Extraction using Class-augmented Kernel PCA)

박 명 수*, 오 상 록**

(Myoung Soo Park and Sang-Rok Oh)

요 약

본 논문에서는 자료패턴을 분류하기에 적합한 특징을 추출하는 방법인, 클래스가 부가된 커널 주성분분석(class-augmented kernel principal component analysis)를 새로이 제안하였다. 특징추출에 널리 이용되는 부분공간 기법 중, 최근 제안된 클래스가 부가된 주성분분석(class-augmented principal component analysis)은 패턴 분류를 위한 특징을 추출하기 위해 이용되는 선형분류분석(linear discriminant analysis)등에 비해 정확한 특징을 계산상의 문제 없이 추출할 수 있는 기법이다. 그러나, 추출되는 특징은 입력의 선형조합으로 제한되어 자료에 따라 적절한 특징을 추출하기 어려운 경우가 발생한다. 이를 해결하기 위하여 클래스가 부가된 주성분분석에 커널 트릭을 적용하여 비선형 특징을 추출할 수 있는 새로운 부분공간 기법으로 확장하고, 실험을 통하여 성능을 평가하였다.

Abstract

In this paper, we propose a new feature extraction method, named as Class-augmented Kernel Principal Component Analysis (CA-KPCA), which can extract nonlinear features for classification. Among the subspace method that was being widely used for feature extraction, Class-augmented Principal Component Analysis (CA-PCA) is a recently one that can extract features for an accurate classification without computational difficulties of other methods such as Linear Discriminant Analysis (LDA). However, the features extracted by CA-PCA is still restricted to be in a linear subspace of the original data space, which limits the use of this method for various problems requiring nonlinear features. To resolve this limitation, we apply a kernel trick to develop a new version of CA-PCA to extract nonlinear features, and evaluate its performance by experiments using data sets in the UCI Machine Learning Repository.

Keywords : Class-augmented Kernel Principal Component Analysis, Nonlinear Feature Extraction, Discriminant Features.

I. 서 론

자료 패턴을 분석하는 경우, 자료 각각은 일반적으로 다차원 실수벡터로 표현된다. 벡터 표현(representation)의 각 항은 자료의 서로 다른 측면의 특성들을 대표하며, 특성을 조합하는 방법에 따라 같은 자료라도 다양한 방식으로 표현될 수 있다. 그런데 분

석이 목적하는 바에 따라서는 이러한 표현들 가운데 특수한 표현을 선호되는 경우가 있고, 이 경우 선호되는 표현을 특징(feature)이라 부르며 자료의 본래 표현을 특징으로 변환하는 과정을 특징 추출(feature extraction)이라고 한다.

현재 특징 추출을 위해 다양한 기법들이 개발되어 왔는데, 널리 이용되는 기법들 가운데에 선형 부분공간(linear subspace) 기법이 있다. 선형 부분공간 기법은, 자료가 본래 표현된 공간의 선형 부분공간 가운데 목적에 적절한 특성을 지닌 것을 선택하고 그 위로 자료의 본래 표현을 투영(project)함으로써 특징을 추출하는 기법들을 의미한다. 대표적인 것으로는, 자료 분포를 잘

* 정회원, ** 정회원-교신저자,
한국과학기술연구원 실감교류로보틱스연구센터
(KIST, Human-centered Interaction and Robotics
Research Center)
접수일자: 2011년4월22일, 수정완료일: 2011년8월26일

기술하면서도 저차원인 특징을 찾는 주성분분석(PCA: principal component analysis)^[1]과, 자료를 쉽게 분류할 수 있는 저차원 특징을 찾는 선형판별분석(LDA: linear discriminant analysis)^[2]이 있다. 최근에는 LDA 기반의 여러 기법들이 가지는 계산상의 문제를 가지지 않으면서도 LDA와 마찬가지로 자료 분류에 적합한 특징을 추출할 수 있는, 클래스가 부가된 주성분분석(CA-PCA: class-augmented principal component analysis)^[3]이 새로 개발되었으며 성능에 대한 분석이 이루어졌다^[4].

그러나 이러한 기법들은, 본래 자료 표현의 선형변환(linear transform)에 해당하는 특징들만을 추출할 수 있다는 한계를 공통적으로 가진다. 특히, 이러한 제약은 분류를 위한 특징을 추출해야 하는 LDA와 CA-PCA에 있어서는, 비선형성이 강한 경계를 가지고 분포하는 자료를 분류하는데에 적절한 특징을 추출할 수 없다는 문제점으로 나타난다. 이러한 한계를 해결하기 위하여 선형 부분공간기법을 비선형 부분공간기법으로 확장하는 연구가 진행되었다. 앞서 언급한 PCA는 비선형부분공간기법인 커널 주성분분석(KPCA: kernel PCA)^[5]으로 확장되었고, LDA는 유사한 방법으로 커널 판별분석(KDA: kernel discriminant analysis)^[6], 일반화된 판별분석(GDA: generalized discriminant analysis)^[7] 등 여러 가지 방식으로 확장되었다.

본 논문에서는 앞서 언급한 선형 부분공간기법들 가운데 CA-PCA를 비선형 부분공간기법으로 확장하여 새로운 비선형 부분공간기법인, 클래스가 부가된 커널 주성분분석(CA-KPCA : class-augmented kernel principal component analysis)을 제안하고자 하였다. CA-KPCA는 LDA에 기반한 KDA, GDA 등의 비선형 부분공간기법들이 공통적으로 가지는, LDA에서 비롯된 계산상 문제를 가지지 않으면서도 분류에 더욱 적절한 비선형 특징을 또한 추출할 수 있다는 장점을 가진다. 제안된 CA-KPCA의 성능은, CA-KPCA에 의해 추출된 특징을 가지고 설계된 분류기의 분류성능을 평가기준으로 삼아 CA-PCA에 의해 추출된 특징을 이용한 분류기의 분류성능과 비교함으로써 실험적으로 확인하였다.

II. 본 론

1. 선형 및 비선형 부분공간기법

본래의 자료 n 개에 대한 표현으로 n 개의 d 차원 실수

벡터 $\mathbf{x}_i \in \mathbf{R}^{d \times 1} (i=1, 2, \dots, n)$ 가 주어질 때, 각각에 해당하는 n 개의 r 차원 특징 $\mathbf{f}_i \in \mathbf{R}^{r \times 1} (i=1, 2, \dots, n)$ 은 선형 부분공간기법에서는 공통적으로 아래와 같이 계산된다.

$$\mathbf{f}_i = \mathbf{W}^T \mathbf{x}_i \quad (1)$$

이 식에서 변환행렬 $\mathbf{W} \in \mathbf{R}^{d \times r} (i=1, 2, \dots, n)$ 은 선형 부분공간기법에 따라 다르게 정의되는데, 대표적인 선형 부분공간기법인 PCA의 경우의 변환행렬 \mathbf{W}_{PCA} 는 아래와 같이 정의된다.

$$\mathbf{W}_{PCA} = \operatorname{argmax}_{\mathbf{W}^T \mathbf{W} = \mathbf{I}} \mathbf{W}^T \mathbf{C} \mathbf{W} \quad (2)$$

여기서 $\mathbf{X} = [\mathbf{x}_1 \ \mathbf{x}_2 \ \dots \ \mathbf{x}_n]$ 이고 $\mathbf{C}(\mathbf{X})$ 는 공분산행렬이다. 공분산행렬 $\mathbf{C}(\mathbf{X})$ 는 각 자료에서 평균값 $m = 1/n \sum \mathbf{x}_i$ 을 뺀 $\bar{\mathbf{X}} = [\mathbf{x}_1 - m \ \mathbf{x}_2 - m \ \dots \ \mathbf{x}_n - m]$ 를 이용하여 $\mathbf{C}(\mathbf{X}) = \bar{\mathbf{X}} \bar{\mathbf{X}}^T / (n-1)$ 로 표현될 수 있다.

이와 같은 조건을 만족하는 변환행렬은 다음 고유치 문제의 해로부터 결정될 수 있다.

$$\lambda \mathbf{w} = \mathbf{C}(\mathbf{X}) \mathbf{w} \leftrightarrow \lambda' \mathbf{w} = \bar{\mathbf{X}} \bar{\mathbf{X}}^T \mathbf{w} \quad (3)$$

큰 것부터 순서대로 r 개의 고유치에 해당하는 고유벡터를 $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_r$ 이라고 할 때, 이들로 구성된 변환행렬 $\mathbf{W} = [\mathbf{w}_1 \ \mathbf{w}_2 \ \dots \ \mathbf{w}_r]$ 가 (2)을 만족하는 해가 된다. 변환행렬 \mathbf{W} 가 결정되면, 새로 주어지는 자료에 대해서도 (1)에 의해 특징을 계산할 수 있다.

이와 같은 선형 부분공간기법을 비선형 부분공간기법으로 확장하는 경우, 일반적으로 이용되는 기법이 커널 트릭(kernel trick)이다. (3)에 기술된 고유치 문제를 살펴보면, 고유벡터 $\mathbf{w} = (1/\lambda') \bar{\mathbf{X}} \bar{\mathbf{X}}^T \mathbf{w} = \bar{\mathbf{X}} \boldsymbol{\alpha}$ 와 같은 관계를 생각해볼 수 있다. 이 관계를 (3)에 대입하고 정리하면 아래와 같은 새로운 고유치문제를 얻을 수 있다.

$$\lambda' \boldsymbol{\alpha} = \bar{\mathbf{X}}^T \bar{\mathbf{X}} \boldsymbol{\alpha} \quad (4)$$

이 고유치문제의 고유벡터 $\boldsymbol{\alpha}$ 가 구해지면 앞서의 관계 $\mathbf{w} = \bar{\mathbf{X}} \boldsymbol{\alpha}$ 에 의해 본래의 고유벡터를 구하여 특징을 추출할 수 있다.

그런데, 새로운 고유치문제의 행렬 $\bar{\mathbf{X}}^T \bar{\mathbf{X}}$ 의 각 요소가 자료표현들 간의 내적에 해당한다는 점에 주목할 필요가 있다. 즉, 부분공간의 기저벡터(basis vector) \mathbf{w} 가 본래 주어진 자료 표현의 선형결합 $\mathbf{w} = \bar{\mathbf{X}} \boldsymbol{\alpha}$ 이 아니라

$w = [\phi(x_1) \ \phi(x_2) \ \dots \ \phi(x_n)]\alpha = \Phi(X)\alpha$ 와 같이 본래 자료 표현의 비선형결합으로 표현된 경우라도, 비선형 자료 표현 간 내적 $\psi(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ ($i, j = 1, 2, \dots, n$) 만 주어진다면, 본래의 PCA와 마찬가지로 비선형 부분공간 상에서 자료분포를 잘 기술하는 저차원 특징을 추출할 수 있다는 점을 의미하기 때문이다.

비선형 부분공간 상의 내적이 $\psi(x_i, x_j)$ 로 정의된 경우 고유치문제는 아래와 같이 일반화된다.

$$\lambda' \alpha = \Psi(X) \alpha \tag{5}$$

여기서 $\Psi(X) \in \mathbb{R}^{n \times n}$ 은 각 요소가 $\psi(x_i, x_j)$ 로 정의된 행렬이다.

이 고유치문제의 해 가운데, 큰 것부터 순서대로 r 개의 고유치에 해당하는 고유벡터를 $\alpha_1, \alpha_2, \dots, \alpha_r$ 라고 할 경우, 이를 이용한 새로운 변환행렬에 의해 특징을 아래와 같이 계산할 수 있게 된다.

$$f = A^T \Psi(X, x) \tag{6}$$

여기서 $A = [\alpha_1 \ \alpha_2 \ \dots \ \alpha_r]$ 이고, $\Psi(X, x) \in \mathbb{R}^{n \times 1}$ 은 각 요소가 $\psi(x_i, x)$ 로 정의된 벡터다. 여기서도 마찬가지로, 본래 자료표현 간의 내적만이 필요하며, 구체적으로 자료가 어떤 비선형함수로 표현되는지는 알 필요가 없다는 점에 주목할 필요가 있다.

이상에서 기술된 비선형 부분공간기법을 KPCA라고 하며, 이 과정을 커널 트릭(kernel trick)이라고 한다. 같은 방식을 이용하여 선형 부분공간 기법인 LDA를 비선형 부분공간기법인 KDA로 확장할 수 있다.

2. 클래스가 부가된 커널 주성분분석(CA-KPCA)

클래스가 부가된 주성분분석(CA-PCA)는, 자료의 분류에 적절한 특징을 추출하는 선형 부분공간특징추출방법이다. 본래의 자료 표현에 자료의 클래스에 관한 표현을 부가하고, 이에 대해 PCA를 수행함으로써 특징을




그림 1. 클래스가 부가된 주성분분석^[4]
Fig. 1. Class-Augmented Principal Component Analysis.

추출한다. 자료 표현만을 가지고 특징을 추출하는 PCA에 비해 분류에 적합한 특징을 추출할 수 있고, 분류에 적합한 특징을 추출하는 다른 기법인 LDA에 비해서는 계산상의 문제점을 가지지 않는다는 장점이 있다. 그리고 여기서 확인하게 될 또 다른 장점은 비선형 부분공간기법으로 쉽게 확장될 수 있다는 점이다.

클래스가 부가된 주성분분석은 크게 3단계로 구성된다. 각각은 다음과 같다.

1단계: 자료표현의 분포가 특징추출에 미치는 영향을 최소화하도록 자료표현을 변형한다. 자료 $x_i \in \mathbb{R}^{d \times 1}$ ($i = 1, 2, \dots, n$)에 대하여 PCA를 수행한 이후 정규화하여, 평균은 0이고 모든 방향으로의 분산은 1이 되는 표현 $\bar{x}_i^a \in \mathbb{R}^{d \times 1}$ ($i = 1, 2, \dots, n$)를 구한다.

2단계: 자료를 분류하기 위한 클래스 표현을 결정한다. $1-n_c$ 코딩을 이용하여 자료의 클래스(class)에 대한 표현 $\bar{c}_i^a \in \mathbb{R}^{n_c \times 1}$ ($i = 1, 2, \dots, n$)을 구한다. n_c 는 미리 알려진 클래스의 종류를 의미한다.

3단계: 앞서 결정된 자료표현에 클래스표현을 부가함으로써, 클래스가 부가된 새로운 자료표현 $\bar{x}_i^a = [(\bar{x}_i^a)^T \ (\bar{c}_i^a)^T]^T \in \mathbb{R}^{(d+n_c) \times 1}$ ($i = 1, 2, \dots, n$)을 결정하고, 이에 대하여 PCA를 수행하여 변환행렬을 결정한다. 변환행렬은 아래의 고유치문제의 해로부터 구할 수 있는데,

$$\lambda' w^a = \bar{X}^a \bar{X}^{aT} w^a \tag{7}$$

여기서 $\bar{X}^a = [\bar{x}_1^a \ \bar{x}_2^a \ \dots \ \bar{x}_n^a]$ 를 의미한다. 고유치문제의 해 가운데 큰 순서로 r 개의 고유치에 해당하는 고유벡터 $w_1^a, w_2^a, \dots, w_r^a \in \mathbb{R}^{(d+n_c) \times r}$ 를 선택하고, 그 가운데 자료표현에 해당하는 부분 $w_1, w_2, \dots, w_r \in \mathbb{R}^{d \times r}$ 를 취하여 변환행렬 $W = [w_1 \ w_2 \ \dots \ w_r]$ 를 결정한다.

이러한 과정을 통해서, 본래의 자료 표현보다 자료의 클래스에 대한 표현이 특징 추출에 보다 큰 영향을 주어 클래스 분류에 적합한 특징이 얻어질 수 있다.

이제 커널 트릭을 적용하여 비선형 부분공간기법으로 확장해보자. 앞서와 마찬가지로 고유벡터는

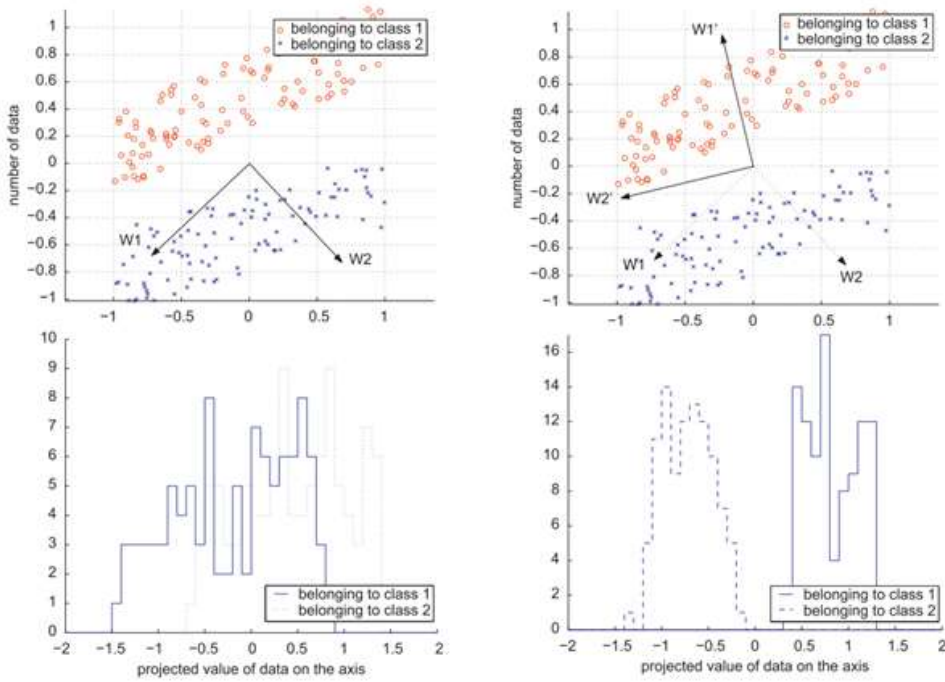


그림 2. 일반적인 주성분분석과, 클래스가 부가된 주성분분석에서 추출된 특징의 예[4]: 좌측의 경우는 일반적인 주성분분석에 의한 특징으로 다른 클래스의 자료가 구분되지 않지만, 우측의 경우는 클래스가 부가된 주성분분석에 의해 추출된 특징으로 다른 클래스의 자료가 분명하게 구분됨을 확인할 수 있음.

Fig. 2. Example of features extracted by conventional PCA and CA-PCA.

$w^a = (1/\lambda') \overline{X^a X^{aT}} w^a = \overline{X^a \alpha}$ 로 표현되므로, 이를 이용하는 새로운 고유치문제틀 아래와 같이 정의할 수 있다.

$$\lambda' \alpha = \overline{X^{aT} X^a} \alpha \tag{8}$$

여기서 $\overline{X^a X^{aT}}$ 에 포함된 내적을 비선형함수로 대신하여 행렬을 구한 후, 이를 이용하여 전체 변환행렬을 구하면 된다. 그런데, 여기에 $\overline{x_i} = [(\overline{x_i^n})^T (\overline{c_i^n})^T]^T$ 라는 정의를 적용하면 $\overline{X^a X^a}$ 는 아래와 같이 표현된다.

$$\overline{X^{aT} X^a} = \overline{X^{nT} X^n} + \overline{C^{nT} C^n} \tag{9}$$

자료표현에서 나온 항과 자료의 클래스 표현에서 나온 항이 분리될 수 있음을 확인할 수 있다.

그런데, KPCA의 경우와는 달리 이를 비선형화하기 전에 두 가지 고려할 점이 있다. 첫째, 자료의 클래스 표현은 자료의 종류에 기반하여 임의로 사용자가 정의한 것이다. 때문에 이러한 클래스 표현에 비선형성을 부여하는 것은 자료 표현과 달리 분류 성능 자체에 큰 영향을 미치지 않을 수 있다. 둘째, 내적을 대신할 비선형함수가 자료 표현과 클래스 표현 모두를 입력으로 정

의될 경우, 클래스를 알지 못하는 자료 곧 분류기 설계를 위하여 클래스가 알려진 자료가 아닌, 분류기를 실제 이용하고자 하는 자료에 대해서는 특징을 추출할 수 없게 된다는 문제가 있다. KPCA의 경우 (6)을 이용하여 새로운 자료에 대한 특징을 구하고자 할 때 $\psi(x_i, x)$ 가 이용되는데, x_i 와 x 가 클래스를 이용하여 결정되어야 하는 값이라면, 클래스를 알아내야 하는 자료에 대해서는 x 를 계산할 수 없으므로 특징을 추출할 수 없게 된다. 그러한 까닭에 클래스를 이용하여 결정되어야 하는 $\overline{X^{aT} X^a}$ 가 아니라, $\overline{C^{nT} C^n}$ 을 제외한 $\overline{X^{nT} X^n}$ 에 포함된 내적만을 비선형함수로 교체할하는 것이 타당할 것이다.

앞서 (9)의 결과는 이러한 방식으로 특징을 추출하기에 적합하다. 즉, 자료표현에서 나온 항과 자료의 클래스 표현에서 나온 항이 분리되어 있으므로 앞서 논의한 바와 같이, 자료 표현 내적에서 계산된 항 $\overline{X^{nT} X^n}$ 만을 쉽게 비선형함수로 대체함으로써 CA-KPCA를 쉽게 정의할 수 있다. 그런데 CA-PCA에서 기술된 바에 따르면, $\overline{X^{nT} X^n}$ 은 본래 PCA에 의해 변환된 특징을 다

시 정규화하는 과정을 통하여 계산되어야 한다. 비선형화하는 과정과 이러한 조건을 수행하기 위해서는, 첫째, 우선 PCA를 대신하여 KPCA를 이용하고, 둘째, PCA 결과에 대한 정규화를 대신하여 KPCA에 의해 특징된 추출에 대한 정규화기법^[8]을 이용할 수 있다. 이러한 과정을 통해 자료표현 부분이 변환된 후에는 본래의 CA-PCA의 과정 그대로 클래스 부분을 더하고, PCA를 수행하게 된다.

III. 실험 및 성능평가

1. 평가방법

제안된 새로운 특징추출 방법의 성능을 평가하기 위하여 UCI Machine Learning Repository^[9]에 포함된 여러 자료집합을 선택하여 이용하였다. 선택된 자료집합은 다양한 입력 수, 자료 수, 그리고 레이블 수를 지니고 있으며 이러한 특징은 표 1에 기술되었다. 자료들은 다양한 응용분야에서 수집된 것으로, 이에 대한 성능으로부터 실제 문제에 제안된 기법을 응용할 경우의 성능을 추측할 수 있다.

전체 평가는, 자료집합의 선택에 따른 성능차이를 무시할 수 있도록 leave-one-out(LOO) 교차검증법을 이용하였다. 요컨대, 주어진 자료들 가운데 1개를 평가를 위해 선택하고 나머지 자료를 이용하여 설계된 분류기

표 1. CA-PCA와 CA-KPCA로부터 추출된 특징을 이용한 1-NN 분류기의 분류성능
Table 1. Classification performance of 1-NN classifiers using features from CA-KPCA and CA-PCA.

자료집합	레이블	입력	자료	1-NN 분류기의 분류성능	
				CA-PCA 특징	CA-KPCA 특징
ECOLI	8	7	336	81.85%	82.14%
GLASS	6	9	214	71.50%	71.50%
HARBERMAN	2	3	306	67.97%	68.30%
IONOSPHERE	2	34	351	92.88%	93.73%
IRIS	3	4	150	97.33%	96.67%
LENSES	3	4	24	83.33%	87.50%
LIVER	2	6	345	65.51%	65.51%
PIMA	2	8	768	71.09%	74.22%
SONAR	2	60	208	87.98%	90.87%
TEACHING	3	5	151	70.86%	70.86%
THYROID	3	5	215	95.81%	96.28%
TICTACTOE	2	9	958	93.11%	93.11%
WBCancer	2	9	699	96.42%	97.00%
WINE	3	13	178	98.88%	99.44%

로 선택된 자료에 대한 분류성능을 평가하며, 이러한 과정을 반복하여 모든 자료 각각에 대한 분류성능을 구한 후에 옳게 분류된 정확성을 평가 지표로 삼는다. 본 실험에서는 선택된 1개를 제외한 나머지 자료, 곧 학습 자료를 이용하여 특징을 추출한 후, 추출된 특징을 이용하여 1-nearest neighborhood (1-NN) 분류기를 구성한 후에, 평가 자료에 대한 분류기의 성공 여부를 구하였다.

2. 결과

앞서 기술된 평가방법에 의한 실험 결과를 표 1에 제시하였다. 표 1의 각 행에는 각각 자료의 이름, 입력 수 (자료 표현의 본래차원), 자료 수, 레이블 수가 제시되어 있고, 또한 마지막 열에는 해당 자료집합에 대하여 CA-PCA와 CA-KPCA를 이용하여 추출된 특징을 이용한 1-NN 분류기의 분류성능을 기록하였다. 분류성능은 백분율로 표시되었다. 본래 다양한 비선형 부분공간 기법과의 비교가 적절할 것이나, CA-PCA가 선형 부분공간기법임에도 불구하고 이미 다양한 비선형 부분공간 기법에 비해 많은 경우 성능상의 우위를 가지는 것이 보고된 바 있기에, CA-KPCA의 비교대상은 CA-PCA로 한정하였다.

결과를 살펴보면, 많은 경우 CA-KPCA에서 추출된 특징을 이용하는 경우, CA-PCA에서 추출된 특징에 비해 적게는 1-2%, 많게는 5%에 이르기까지 분류성능이 전반적으로 향상되고 있음을 확인할 수 있다. 특히 LENSES 자료집합에 대해서는 성능 향상이 두드러지게 나타나는 것을 확인할 수 있는데, 이는 LENSES 자료집합의 경우 자료들이 비선형으로 분포하는 부분이 있어 CA-KPCA가 CA-PCA에 비하여 더욱 적절한 특징을 추출할 수 있기 때문이라 생각된다.

IV. 결 론

본 논문에서는 자료패턴 분석 및 분류기 설계에 유용하게 이용될 수 있는 새로운 비선형 부분공간 특징추출 기법인 CA-KPCA를 제안하였다. 제안한 기법은, 분류에 적합한 선형 특징을 계산상 문제없이 추출할 수 있는 부분공간 기법인 CA-PCA에 변형된 형태의 커널 트릭을 적용하여, 비선형 특징을 추출하도록 확장한 것이다. 제안한 기법의 성능은 UCI Machine Learning Repository에 포함된 여러 자료집합을 이용하여 LOO

교차검증 방법을 통해 실험적으로 평가하였고, 그 결과 CA-KPCA가 CA-PCA에 비해 분류기 설계에 보다 유용한 특징을 추출할 수 있음을 확인하였다.

참 고 문 헌

- [1] I. T. Jolliffe, *Principal Component Analysis*, Springer-Verlag, 1986.
- [2] K. Fukunaga, *Introduction to Statistical Pattern Recognition*, Morgan-Kaufmann, 1990.
- [3] M. S. Park and J. Y. Choi, "Feature Extraction Using Class-Augmented Principal Component Analysis (CA-PCA)", *Lecture Notes in Computer Science*, Vol. 4132, pp. 606-615, 2006.
- [4] M. S. Park and J. Y. Choi, "Theoretical Analysis On Feature Extraction Capability Of Class-Augmented PCA", *Pattern Recognition*, Vol. 42, Issue 11, pp. 2353-2362, 2009.
- [5] B. Schölkopf, A. Smola, and K.-R. Müller, "Nonlinear Component Analysis as a Kernel Eigenvalue Problem", *Neural Computation*, Vol. 10, No. 5, pp. 1299-1319, 1998.
- [6] S. Mika, G. Ratsch, J. Weston, B. Schölkopf, and K.-R. Müller, "Fisher Discriminant Analysis With Kernels", in *Proceedings of 1999 IEEE Signal Processing Society Workshop on Neural Networks for Signal Processing*, Vol. 9, pp. 41-48, 1999.
- [7] G. Baudat and F. Anouar, "Generalized Discriminant Analysis Using A Kernel Approach", *Neural Computation*, vol. 12, pp. 2385-2404, 2000.
- [8] P. Cui and J. Fang, "KPCA Plus FDA For Fault Detection", *Lecture Notes in Computer Science*, Vol. 4493, pp. 597-606, 2007.
- [9] UCI Machine Learning Repository website: <http://archive.ics.uci.edu/ml/>

저 자 소 개



오 상 록(정회원)-교신저자
1980년 서울대학교 전자공학과
학사 졸업.
1982년 KAIST 전기 및 전자공학과
공학석사 졸업.
1987년 KAIST 전기 및 전자공학과
공학박사 졸업.

1987년 3월~1988년 01월 KAIST 시스템
제어 연구실 Post Doc.
2000년 3월~2003년 03월 KIST 지능제어연구
센터 센터장
2003년 9월~2008년 02월 (구)정보통신부 지능형
서비스 로봇 Project Manager, IT 정책
자문관
2009년 11월~2010년 08월 KIST 로봇시스템본부
본부장
2010년 9월~2010년 12월 KIST 대외부원장
1998년 1월~현재 KIST 실감교류로보틱스연구
센터 선임/책임연구원
<주관심분야 : 네트워크 로보틱스, IT 융합, 로봇
기반교육>



박 명 수(정회원)
1998년 서울대학교 전기공학부
학사 졸업.
2000년 서울대학교 전기공학부
공학석사 졸업.
2006년 서울대학교 전기컴퓨터
공학부 공학박사 졸업.

2006년 3월~2010년 06월 서울대학교 전기컴퓨터
공학부 BK21 Post Doc.
2010년 7월~현재 KIST 실감교류로보틱스연구
센터 선임연구원
<주관심분야 : 기계학습, 인공지능, 패턴인식, 지
능로봇, 컴퓨터비전>