

Bhattacharyya 커널을 적용한 Centroid Neural Network

정회원 이 송 재*, 박 동 철**

Centroid Neural Network with Bhattacharyya Kernel

Song-Jae Lee*, Dong-Chul Park** *Regular Members*

요 약

본 논문은 가우시안 확률분포함수 (Gaussian Probability Distribution Function) 데이터 군집화를 위해 중심신경망 (Centroid Neural Network, CNN)에 Bhattacharyya 커널을 적용한 군집화 알고리즘 (Bhattacharyya Kernel based CNN, BK-CNN)을 제안한다. 제안된 BK-CNN은 무감독 알고리즘인 중심신경망을 기반으로 하고 있으며, 커널 방법을 이용하여 데이터를 특징공간에서 투영한다. 입력공간의 비선형 문제를 선형적으로 해결하기 위해 제안된 커널 방법인데, 확률분포 사이의 거리측정을 위해 Bhattacharyya 거리를 이용한 커널방법을 사용하였다. 제안된 BK-CNN을 영상데이터 분류의 문제에 적용했을 때, 제안된 BK-CNN 알고리즘이 Bhattacharyya 커널을 적용한 k-means, 자기조직지도(Self-Organizing Map)와 중심 신경망등의 기존 알고리즘보다 1.7% - 4.3%의 평균 분류정확도 향상을 가져옴을 확인할 수 있었다.

Key Words : GPDF data, Centroid Neural Network, Bhattacharyya, Kernel Method

ABSTRACT

A clustering algorithm for Gaussian Probability Distribution Function (GPDF) data called Centroid Neural Network with a Bhattacharyya Kernel (BK-CNN) is proposed in this paper. The proposed BK-CNN is based on the unsupervised competitive Centroid Neural Network (CNN) and employs a kernel method for data projection. The kernel method adopted in the proposed BK-CNN is used to project data from the low dimensional input feature space into higher dimensional feature space so as the nonlinear problems associated with input space can be solved linearly in the feature space. In order to cluster the GPDF data, the Bhattacharyya kernel is used to measure the distance between two probability distributions for data projection. With the incorporation of the kernel method, the proposed BK-CNN is capable of dealing with nonlinear separation boundaries and can successfully allocate more code vector in the region that GPDF data are densely distributed. When applied to GPDF data in an image classification problem, the experiment results show that the proposed BK-CNN algorithm gives 1.7% - 4.3% improvements in average classification accuracy over other conventional algorithm such as k-means, Self-Organizing Map (SOM) and CNN algorithms with a Bhattacharyya distance, classed as Bk-Means, B-SOM, B-CNN algorithms.

I. 서 론

데이터 분석, 영상 데이터 분류, 패턴 인식과 음성 인식등 기존 연구에서 k-means 알고리즘¹⁾과 자

기조직지도(Self-Organizing Map)²⁾에 기초한 무감독 경쟁 알고리즘이 널리 사용되고 있다. 연구에 쓰인 데이터 모델링은 가우시안 혼합모델 (Gaussian Mixture Model :GMM)로 하고, 최대 또는 최소-

※ 이 논문은 2007년도 정부(교육인적자원부)의 재원으로 한국대학교수협의회 대학교수 국내교류 연구비 지원에 의한 것임.

※ 본 연구는 한국과학재단 특정기초연구(R01-2007-000-20330-0)지원으로 수행되었음.

* (주) LG. Phillips LCD, ** 명지대학교 정보공학과 지능컴퓨팅 연구실

논문번호 : KICS2006-11-510, 접수일자 : 2006년 11월 24일, 최종논문접수일자 : 2007년 8월 23일

Likelihood 분류기를 통해 값을 도출한다. 이 분야에서 k-mean 알고리즘과 자기조직지도가 적용되지만, 이들 알고리즘들은 학습률과 총 학습 반복 횟수 등에 관한 계수 선택에 따라 종종 불안정한 결과를 초래한다. 중심신경망(Centroid Neural Network)으로 불리는 경쟁 군집화 알고리즘은 기존의 k-means와 자기조직지도 알고리즘과 비교하여 효과적으로 준최적해에 안정적으로 수렴한다^[3]. 하지만, 중심신경망은 2차(Euclidean) 거리 측정을 사용하기 때문에 원칙적으로 확정적 데이터(deterministic data)를 다루게 고안되어 있어, 확률적인 데이터의 군집화에는 부적합한 면을 보이고 있다.

확률적인 데이터인 가우시안 분포함수 데이터 군집화 문제들의 인식 정확성을 향상시키기 위해 maximum-likelihood (ML) 측정을 활용하여 도출한 기대치 최대화 (Expectation-Maximization : EM) 알고리즘은 음성인식에서 가우시안 혼합 모델에 효과적으로 적용되고 있다. 하지만, 수렴 속도와 초기 상태에 대한 민감성 때문에 EM은 실제 모델에 적용하기 어렵다^[4]. 이 문제를 해결하기 위한 방법으로 확률분포 데이터에 포함된 모든 정보를 활용하는 cross-entropy^[5]가 있는데, 대표적인 예는 Kullback-Leibler와 Bhattacharyya 거리이다. 가우시안 분포함수 데이터를 효과적으로 군집화 하기 위해 이중 Bhattacharyya를 적용한 중심신경망(B-CNN)이 제안되었는데^[6]. 이는 학습 과정에 요구되는 승자뉴런을 결정하기 위해 Bhattacharyya를 사용했다. 또한, 학습률과 총학습 반복수를 미리 결정할 필요 없는 중심신경망의 장점을 B-CNN은 그대로 유지하였다^[3].

본 논문은 가우시안 분포함수 데이터를 군집화 하기 위한 방안으로 Bhattacharyya 커널을 적용한 중심신경망을 제안한다. 제안된 BK-CNN은 중심신경망 알고리즘을 기반으로 하고 데이터 투영을 위해 커널방법을 활용한다. 즉, 입력 데이터의 선형사상을 고차원 특징 공간에서 수행하기 위한 방안으로 커널 방법을 사용하는데, Mercer 이론에 따르면 이 방법은 입력공간에 존재하는 비선형 문제를 선형적으로 풀 수 있다^[7]. 이에 부합하여 Support Vector Machine^[8]과 퍼지군집화(Fuzzy Clustering)^[9]등 여러 분야에 성공적으로 커널방법이 적용되고 있지만, 이들은 유클리드 거리를 사용하기 때문에 확정적 데이터의 군집화에만 사용될 수 있다. 본 논문은 확률적 데이터 군집화를 위해 두 확률적 데이터 사이의 거리측정 방안으로 Bhattacharyya 커널을 사용한다^[10]. 중심신경망과 Bhattacharyya 커널의 결합은 중

심신경망과 커널 기반의 알고리즘이 가지고 있는 모든 장점들을 내포하는데, 두 확률분포 사이의 유사성을 측정하는 Bhattacharyya 거리를 이용하는 Bhattacharyya 커널은 특별히 확률적 데이터의 군집화를 위해 설계된 것이다.

본 논문의 II장에서 간단하게 기존 중심신경망과 두 확률분포 거리 측정 방법으로 Bhattacharyya 거리를 정의한다. III장에서는 제안된 BK-CNN 알고리즘을 정의하며, IV장에서는 실험결과와 다른 알고리즘들과 비교한 성능을 보여준다. V장에서는 본 논문의 결론이 주어진다.

II. 중심신경망과 발산 거리 측정

2.1 중심신경망

기존의 중심신경망 알고리즘은 k-means 알고리즘을 기반으로 한 무감독 경쟁 알고리즘으로 탁월한 결과를 보여주고 있다^[3,6]. 중심신경망은 k-mean와 자기조직지도 같은 기존 알고리즘이 매 학습마다 연결강도(weight)를 수정하는 것과 달리, 승자와 패자의 연결 강도를 각각 설정하여 현재와 이전 학습에서의 뉴런의 상태에 대한 정보를 이용하여, 가중치를 변화 시킨다. 즉, 이전 학습에서 승자로 선택되지 않았지만 현재의 학습에서 입력데이터에 가장 가까운 뉴런을 승자라 하며, 반대로 이전 학습에서 승자였지만 현재의 학습에서 입력데이터에 가장 가깝지 않다면 현재 학습에서는 패자라고 하여, 각 뉴런이 승자 또는 패자의 상태가 변할 경우에만 연결강도를 수정한다.

다음의 식은 입력 벡터 x 가 n 시간에 인가된 경우, 승자뉴런 j 와 패자뉴런 i 의 연결강도 업데이트를 보여주고 있다.

$$w_j(n+1) = w_j(n) + \frac{1}{N_j+1} [x(n) - w_j(n)]$$

$$w_i(n+1) = w_i(n) + \frac{1}{N_i-1} [x(n) - w_i(n)] \quad (1)$$

여기서 $w_j(n)$ 과 $w_i(n)$ 은 승자 뉴런과 패자 뉴런의 연결강도를 표현하며, N_j 와 N_i 는 현재의 epoch에서 군집 i, j 의 속한 데이터의 수를 의미한다.

중심신경망은 k-means 알고리즘과 자기조직지도 같은 기존 경쟁 알고리즘과 비교하여 몇 가지 장점을 가지고 있다. 중심신경망은 사전에 학습 계수나 전체 학습반복수(epoch)를 설정할 필요가 없으며, 더불어 기존의 군집화 알고리즘에서 문제점으로 대

두 되었던 초기 연결강도 설정의 문제까지 효과적으로 해결함으로써 자동적으로 준최적의 군집화로 이끄는 장점이 있다.

2.2 가우시안 분포함수와 발산거리 척도

기존 k-means 알고리즘과 그의 변형된 알고리즘은 데이터 군집화를 위해 널리 사용되어 지고 있다. 하지만, k-means 알고리즘은 유클리드 거리를 이용하므로, 가우시안 분포함수 데이터를 군집화하기에는 한계를 가지고 있다. 가우시안 분포함수 데이터에 존재하는 모든 통계적 정보를 활용하기 위해 더 유효한 거리 척도가 필요한데, 확률분포 데이터 사이의 거리 측정 방법으로 아래 식으로 표현된 Bhattacharyya 발산 거리 척도가 널리 사용되고 있다.

$$D(G_i, G_j) = \frac{1}{8}(\mu_i - \mu_j)^T \left[\frac{\Sigma_i + \Sigma_j}{2} \right] (\mu_i - \mu_j) \quad (2)$$

$$+ \frac{1}{2} \ln \frac{\left| \frac{\Sigma_i + \Sigma_j}{2} \right|}{\sqrt{|\Sigma_i| |\Sigma_j|}}$$

위에서 μ_i 와 Σ_i 는 분포 G_i 의 평균과 공분산을 지칭한다.

III. Bhattacharyya 커널을 적용한 중심신경망

3.1 가중치 수정 방법

기존의 최소화하기 위한 목적 함수는 아래와 같다.

$$E_i = \sum_{j=1}^N \| \mathbf{x}_i(j) - \mathbf{w}_i \|^2 \quad (3)$$

여기서 $\mathbf{x}_i(j)$ 는 군집 i 의 j 번째 데이터를 지칭한다.

커널적인 측면에서 목적 함수는 사상함수 ϕ 으로 아래와 같이 다시 표현한다.

$$E_i^\phi = \sum_{j=1}^N \| \Phi(\mathbf{x}_i(j)) - \Phi(\mathbf{w}_i) \|^2 \quad (4)$$

식 (4)를 커널의 관계로 다시 표현을 하면,

$$\begin{aligned} & \| \Phi(\mathbf{x}_i(j)) - \Phi(\mathbf{w}_i) \|^2 \\ &= (\Phi(\mathbf{x}_i(j)) - \Phi(\mathbf{w}_i))(\Phi(\mathbf{x}_i(j)) - \Phi(\mathbf{w}_i))^T \\ &= \Phi(\mathbf{x}_i(j))\Phi(\mathbf{x}_i(j))^T - \Phi(\mathbf{x}_i(j))\Phi(\mathbf{w}_i)^T \\ &\quad - \Phi(\mathbf{x}_i(j))^T\Phi(\mathbf{w}_i) + \Phi(\mathbf{w}_i)\Phi(\mathbf{w}_i)^T \\ &= K(\mathbf{x}_i(j), \mathbf{x}_i(j)) + K(\mathbf{w}_i, \mathbf{w}_i) - 2K(\mathbf{x}_i(j), \mathbf{w}_i) \end{aligned}$$

이며, $K(\mathbf{x}_i(j), \mathbf{x}_i(j))=1$, $K(\mathbf{w}_i, \mathbf{w}_i)=1$ 이므로, 목적함수는 아래와 같이 다시 표현 할 수 있다.

$$E_i^\phi = 2 \sum_{j=1}^N (1 - K(\mathbf{x}_i(j), \mathbf{w}_i))$$

커널로 표현된 목적함수를 최소화하기 위해, steepest gradient descent 알고리즘을 사용한다. 학습 방법은 다음과 같이 요약된다.

$$\Delta \mathbf{w}_i = \eta (\mathbf{x}_i(j) - \mathbf{w}_i) = \eta \frac{\partial E_i^\phi}{\partial \mathbf{w}_i}$$

커널 개념으로 K란 문자 대신 발산(Divergence) 개념으로 D로 치환하여 다시 표현하면

$$\begin{aligned} \Delta \mathbf{w}_i &= 2\eta (D(\mathbf{x}_i(j), \mathbf{w}_i))' (\mathbf{x}_i(j) - \mathbf{w}_i) \\ &= 4\eta (\sum_{x \neq j} + \sum_{w_i})^{-1} D(\mathbf{x}_i(j), \mathbf{w}_i) (\mathbf{x}_i(j) - \mathbf{w}_i) \end{aligned}$$

인데, BK-CNN에서 중심신경망과 마찬가지로 학습 계수를 필요로 하지 않게 하기 위해 4η 대신에 $(N_i + 1)^{-1}$ 을 치환한다.

$$\Delta \mathbf{w}_i = (N_i + 1)^{-1} (\sum_{x \neq j} + \sum_{w_i})^{-1} D(\mathbf{x}_i(j), \mathbf{w}_i) (\mathbf{x}_i(j) - \mathbf{w}_i) \quad (5)$$

3.2 Bhattacharyya 커널을 이용한 중심신경망(BK-CNN)

최근에 커널 방법을 이용한 다양한 군집 알고리즘이 제안되고 있다^[11,7]. 이 커널 방법은 저차원 입력 공간에서 고차원 특징 공간으로 데이터 맵핑(Mapping)을 기반으로 하는데, 이를 이용한 Support Vector Machine^[8], Fuzzy Kernel Perception^[12]등 많은 알고리즘에서 좋은 결과를 보여주고 있다.

기존 커널 기반의 군집 알고리즘은 성공적으로 많은 응용 분야에 적용되지만, 유클리드 척도 때문에 확정적 데이터를 기준으로 고안되었다. 그러므로 기존 커널 기준의 알고리즘은 가우시안 분포함수 데이터 군집화에 적합하지 않을 수 있다. 가우시안 분포함수 데이터는 입력 공간의 평균과 공분산으로 표현되어 가우시안 분포함수 데이터 사이의 거리를 측정하기 위해 Bhattacharyya 커널을 적용한다. Bhattacharyya 커널은 가우시안 커널의 확장으로 두 가우시안 분포함수 데이터 사이의 가중치를 곱하여 표현된 발산 측정의 지수함수이다.

$$BK(\mathbf{x}(n), \mathbf{w}_j(n)) = \exp(-\alpha D(\mathbf{x}(n), \mathbf{w}_j(n)) + b) \quad (6)$$

이때 $BK(\mathbf{x}(n), \mathbf{w}_j(n))$ 는 두 가우시안 분포함수 사이 커널을 적용한 Bhattacharyya 척도이다. 본 논문은 가우시안 분포함수 데이터 군집을 위해 식 (6)을 이용한다.

중심신경망과 달리, 여기에서는 평균(μ) 뿐만 아니라 공분산(Σ)을 고려하여, 승자와 패자의 연결강도(weight) 수정에 관한 식을 식 (5)를 이용하는데, 아래와 같이 표현된다.

$$\begin{aligned} \mathbf{w}_j(n+1) &= \mathbf{w}_j(n) + \frac{\alpha BK(\mathbf{x}(n), \mathbf{w}_j(n))}{(N_j+1) * (\sum_{\mathbf{x}(n)} + \sum_{\mathbf{w}_j(n)})} [\mathbf{x}(n) - \mathbf{w}_j(n)] \\ \mathbf{w}_i(n+1) &= \mathbf{w}_i(n) + \frac{\alpha BK(\mathbf{x}(n), \mathbf{w}_i(n))}{(N_i-1) * (\sum_{\mathbf{x}(n)} + \sum_{\mathbf{w}_i(n)})} [\mathbf{x}(n) - \mathbf{w}_i(n)] \end{aligned} \quad (7)$$

위에서 $\mathbf{w}_j(n)$ 과 $\mathbf{w}_i(n)$ 은 승자 뉴런과 패자 뉴런의 연결강도를 각각 표현한다.

공분산(Σ)은 연결강도와 달리 매 반복(iteration)마다 수정하지 않고, 매 전체학습반복(epoch)마다 수정한다.

$$\Sigma_{\mathbf{w}_j}(n+1) = \frac{\sum_{k=1}^{N_j} BK(\mathbf{x}_{k_j}(n), \mathbf{w}_j(n)) \Sigma_{\mathbf{x}_{k_j}}(n)}{\sum_{k=1}^{N_j} BK(\mathbf{x}_{k_j}(n), \mathbf{w}_j(n))}, \quad j = 1, 2, \dots, C \quad (8)$$

이때 n 은 학습 시간을 표현하는 n 번째 epoch를 지칭하고 $\Sigma_{\mathbf{x}_{k_j}}(n)$ 은 n 번째 epoch 시점의 군집 j 에 속하는 k 번째 데이터가 가지고 있는 대각선 공분산(diagonal covariance) 행렬이다.

IV. 실험 결과

본 실험은 Caltech 영상 데이터를 이용하여, 제안된 BK-CNN과 다른 알고리즘을 비교하였다. 실험에 사용된 Caltech 영상 데이터는 한 물체의 다른 방향에서 바라본 관점들로 구성되었으며, 이 정보들은 아래의 주소에서 찾을 수 있다.

<http://www.vision.caltech.edu/html-files/archive.html>

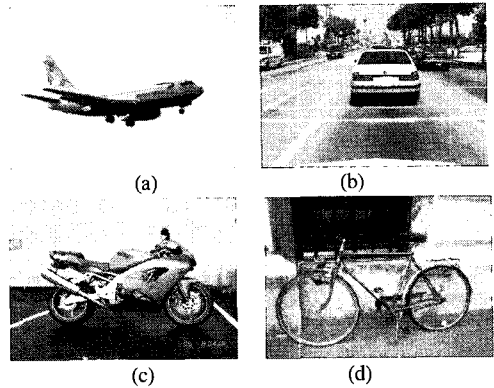


그림 1. (a) 비행기 (b) 자동차 (c) 오토바이 (d) 자전거

이 데이터들 중 우리는 4개의 영상그룹(비행기, 자동차, 오토바이, 자전거)을 이용하였으며, 본 실험은 이를 바탕으로 서로 다른 각도에서 촬영한 200개 영상으로 구성되었다. 이들 중, 100개 영상은 무작위로 선택하여 학습으로 사용하고, 나머지 100개 영상은 각 알고리즘의 성능 측정을 위해 사용하였다. 모든 영상은 같은 해상도를 가지는 흑백영상으로 변환하였고, 실험에 사용된 4개 범주에 속하는 데이터의 한 예는 그림 1에서 보여준다. 각 영상은 8x8 블록의 집합으로 구성되고, 이 블록은 수평과 수직으로 2 픽셀씩 이동된다. 각 블록의 Discrete Cosine Transform (DCT) 계수는 64차원 계수로 계산되고 계산을 용이하기 위해 인간 시각이 지각할 수 있는 32개의 저주파 DCT 계수만 유지한다. 따라서, 각 블록의 데이터에서 얻어진 특징 벡터는 32차원을 가진다. 영상에서 가우시안 분포함수를 측정하기 위해 평균과 공분산 행렬은 영상으로부터 얻어진 모든 블록들로 부터 측정된다. 결론적으로, 32차원 평균과 32x32 공분산 행렬을 가진 가우시안 분포함수는 영상의 특징벡터로 사용되었다.




그림 2. 각 알고리즘의 분류 정확도

모든 영상 데이터는 가우시안 분포함수 데이터로 측정된 후, minimum-likelihood(ML) 분류기를 통해 값이 얻어진다. ML 분류기는 각 BK-CNN 군집 알고리즘 사용에 의해 측정된 각 mixture의 가우시안 혼합 모델 (Gaussian Mixture Model)에 기반을 둔다.

mixture들이 만들어진 후, minimum-likelihood 분류기는 성능 측정용 테스트 영상이 속하는 영상 그룹이 어디에 속하는지 판별하는데 적용된다.

$$Class(\mathbf{x}) = \operatorname{argmin} D(\mathbf{x}, C_i)$$

$$D(G(\mathbf{x}; \mu, \Sigma), C_i) = \sum_k^N w_{ik} D(G(\mathbf{x}; \mu, \Sigma), G(\mathbf{x}; \mu_{i,k}, \Sigma_{i,k}))$$

여기서, \mathbf{x} 는 평균(μ)과 공분산 행렬(Σ)로 표현된 테스트 영상이다. $\mu_{i,k}$ 와 $\Sigma_{i,k}$ 는 클래스 C_i 에 속한 군집 k 의 평균과 공분산 행렬을 각각 표현한다. $w_{i,k}$ 는 영상 그룹 C_i 의 군집 k 의 연결강도 요소이고, N_i 는 클래스 i 에 속한 데이터의 수이다.

그림 2는 다음의 4가지 분류모델 - 1) 자기조직화도를 사용하는 분류 모델(B-SOM), 2) k-means 알고리즘을 사용하는 분류 모델(Bk-means), 3) 중심신경망을 사용하는 분류모델(B-CNN), 4) 제안된 BK-CNN을 사용하는 분류 모델 - 의 분류정확도를 코드벡터의 수를 변화시켜가면서 성능의 변화를 보여준다. 이 그림에서 코드 벡터의 개수는 가우시안 혼합모델의 mixtures의 개수를 대표하는 충분히 많은 양의 코드 벡터들을 확정하기 위해 3개의 코드 벡터에서 부터 7개의 코드 벡터까지의 경우에 대해 실험이 진행되었다. 그림 2로부터 확인할 수 있는 것처럼, 대부분의 알고리즘들은 5개 또는 6개의 코드벡터의 지점에서 최고 분류 정확성을 보여주지만, 제안된 BK-CNN보다는 좋지 않은 결과를 보여준다.

표 1. 코드벡터 7개를 사용한 경우의 분류 정확도

	비행기	자동차	자전거	오토바이	정확도
B-SOM	77.1	100	60.0	95.7	83.2%
Bk-means	82.6	100	54.6	96.0	83.3%
B-CNN	78.0	100	69.0	96.0	85.8%
BK-CNN	86.0	100	70.0	96.0	87.5%

표 1은 코드벡터 7개를 사용한 경우에 대한 각 영상 그룹에 대한 B-SOM, BK-means, B-CNN, 그리고 BK-CNN을 사용하는 분류모델들의 분류정확도인데, 여기서 볼 수 있듯이, BK-CNN을 사용하는 분류모델은 항상 B-SOM, Bk-means, B-CNN을 사

용하는 모델들의 성능에 비해 각각 4.3%, 4.2%, 1.7%의 평균정확도 향상을 얻을 수 있었다. 이를 통해 볼 때, 제안된 BK-CNN은 기존의 알고리즘들에 비해 영상 분류에 매우 적합한 방법임을 알 수 있다.

V. 결론

가우시안 분포함수 데이터의 효율적인 군집화를 위한 방안으로, Bhattacharyya 커널을 적용한 중심신경망 (BK-CNN)이 본 논문에서 제안되었는데, 제안된 BK-CNN은 커널 방법과 Bhattacharyya 척도를 결합한 형태의 경쟁 학습 알고리즘을 수행하는 신경망이다. 본 BK-CNN에서 쓰는 커널 방법은 복잡한 구조의 비선형 문제를 쉬운 형태의 선형 문제로 변환하여 해결할 목적으로, 저차원 특징공간을 고차원 특징 공간으로 데이터를 변환시킨다. 한편, 종전의 방법에서 데이터의 평균값만을 사용하는 것과는 달리, 데이터의 통계적 특성을 이용하는 Bhattacharyya 발산 척도를 사용하기 때문에, BK-CNN은 가우시안 분포함수가 가지고 있는 평균과 분산의 전체 정보를 활용할 수 있어 보다 정확한 군집화를 가능하게 한다. 제안된 BK-CNN의 효율성을 입증하기 위해 영상데이터의 분류에 관한 실험을 수행하였는데, 영상 블록들을 영상 가우시안 분포함수 데이터로 재구성하여, 각 블록의 평균과 분산을 이용할 수 있게 하였다. 실험에서는 기존의 k-means 알고리즘, Kohonen 의 SOM, 중심신경망 알고리즘에 같은 데이터를 사용하여 그 결과를 비교하였는데, 제안된 BK-CNN은, 그 결과는 제안된 알고리즘이 기존의 방법들에 비해 평균정확도에서 각각 4.3%, 4.2%, 1.7%의 향상을 보여주어, 제안된 BK-CNN이 가우시안 확률분포함수를 가지는 데이터의 군집화와 분류에 매우 유용한 방법임을 알 수 있었다.

참고 문헌

- [1] Hartigan, J., "Clustering Algorithms," New York, Wiley, 1975.
- [2] Kohonen, T., "The Self-Organizing Map," *Processing of the IEEE*, vol. 78, pp, 1464-1480, Sept. 1990
- [3] Park, D. C., "Centroid Neural Network," *IEEE Tr. on Neural Networks*, vol. 11, pp520-528, Mar. 2000.
- [4] Yin, H., Allinson, N. M., "Bayesian self-organiz-

ing map for Gaussian mixture," IEE Processings Vison Image and Signal Processing, vol. 148, pp.234-240, Aug. 2001.

- [5] Gokcay, E., Principe, J.C., "Information theoretic clustering," *IEEE Tr. on Pattern Analysis and Machine Intelligence*, vol. 24, pp. 158-171, Feb. 2002.
- [6] Park, D. C., Oh, H.K., Suk, M. S., "Clustering of Gaussian Probability Density Functions Using Centroid Neural Network," *IEE Electronic Letters*, vol. 49, pp. 381- 382, Feb. 2003.
- [7] Girolami, M., "Mercer Kernel-Based Clustering in Feature Space," *IEEE Tr. on Neural Networks*, vol. 13, pp. 780-784, May. 2002.
- [8] Cristianini, N., Shawe-Taylor, J., "An Introduction to Support Vector Machine," *Cambridge, Cambridge Univ.*, 2000.
- [9] Chen, S., Zhang, D., "Robust Image Segmentation using FCM with Spatial Constraints Based on New Kernel-Induced Distance Measure," *IEEE Tr. On Systems Man and Cybernetics*, vol. 43, pp. 1907- 1916, Aug. 2004.
- [10] Jebra, T., Kondor, "Bhattacharyya and Expected Likelihood Kernels," *Proc. COLT*, 2003.
- [11] Muller, K.R., Mika, S., Ratsch, G., Ratsch, G., Tsuda, K., Scholkopf, B., "An Introduction to Kernel-Based Learning Algorithms," *IEEE Tr. on Neural Networks*, vol. 12, pp.181- 201, Mar. 2001.
- [12] Chen, J.H., Chen, C.S., "Fuzzy Kernel Perceptron," *IEEE Tr. on Neural Networks*, vol. 13, pp. 1364- 1373, Nov. 2002.

이 송 재 (Song-Jae Lee)

정회원




상처리

2003년 2월 명지대학교 전기정보 제어(공학사)
 2003년~2006년 명지대학교 정보 제어(공학석사)
 2006년~현재 LG. Philips LCD 연구원
 <관심분야> 신경망, 신호처리, 영

박 동 철 (Dong-Chul Park)

정회원



1980년 2월 서강대학교 전자공학과(공학사)
 1982년 2월 한국과학기술원 전기 및 전자공학과(공학석사)
 1990년 6월 Univ. of Washington (Seattle), Electrical Engineering (Ph.D.)
 1990년 8월~1994년 2월 조교수, Florida Int'l Univ. Dept. of Eelct. and Comp. Eng.
 1994년 3월~현재 명지대학교 정보공학과 교수
 1997년~2000년 IEEE Trans. on Neural Networks, Associate Editor
 1999년~현재 IEEE Senior Member
 <관심분야> 신경망 알고리즘 개발, 음성인식, 멀티미디어 데이터 처리 및 분석