

## 클러스터링 및 영상 분할을 위한 커널 기반의 Possibilistic 접근 방법

### A Kernel based Possibilistic Approach for Clustering and Image Segmentation

최길수 · 최병인 · 이정훈

Kil-Soo Choi, Byung-In Choi and Frank Chung-Hoon Rhee

한양대학교 전자전기제어계측공학과

#### 요약

Fuzzy Kernel C-Means(FKCM) 알고리즘은 커널 함수를 통하여 구형의 데이터뿐만 아니라 Fuzzy C-Means(FCM)에서는 분류하기 힘든 복잡한 형태의 분포를 갖는 데이터를 분류할 수 있다. 하지만 FCM과 같이 노이즈에 대해서는 민감한 성질을 가진다. 이처럼 노이즈(noise)에 민감한 성질을 보완하기 위해서 본 논문에서는 Possibilistic C-Means 알고리즘에 커널 함수를 적용하였다. 제안한 Kernel Possibilistic C-Means(KPCM) 알고리즘은 일반적인 데이터에 대해 FKCM과 같은 성능의 클러스터링 수행이 가능하며 노이즈가 있는 데이터에 대해서는 FKCM보다 정확한 클러스터링을 수행할 수 있다.

#### Abstract

The fuzzy kernel c-means (FKCM) algorithm, which uses a kernel function, can obtain more desirable clustering results than fuzzy c-means (FCM) for not only spherical data but also non-spherical data. However, it can be sensitive to noise as in the FCM algorithm. In this paper, a kernel function is applied to the possibilistic c-means (PCM) algorithm and is shown to be robust for data with additive noise. Several experimental results show that the proposed kernel possibilistic c-means (KPCM) algorithm out performs the FKCM algorithm for general data with additive noise.

**Key words :** Kernel, Clustering, FKCM, KPCM, Noise

#### 1. 서 론

일반적으로 잘 알려진 fuzzy C-means(FCM) 알고리즘은 유클리디안 공간상에서의 거리를 이용하여 퍼지 소속도를 할당해 줌으로써 클러스터링을 수행하게 된다[5]. 대부분의 구형 데이터에 대해서 FCM은 좋은 성능의 클러스터링을 수행하지만 센터를 이루는 점과 패턴들과의 유클리디안 거리를 기준으로 하므로 고리형 데이터와 같이 복잡한 형태의 분포를 가지는 데이터들에 대해서는 클러스터링이 불가능하다. 이러한 단점을 극복하기 위해서 fuzzy kernel C-means(FKCM)가 제안되었다[2]. 이것은 FCM에 커널 함수를 적용하여 데이터를 입력 속성(feature) 공간이 아닌 커널 속성 공간으로 변환하여 클러스터링을 수행한다. 커널 기반의 알고리즘인 FKCM은 구형의 데이터뿐만 아니라 복잡한 형태의 분포를 갖는 데이터에 대해서도 정확한 클러스터링이 가능하다.

그러나 FKCM은 FCM과 같이 퍼지 접근 방법을 사용하기 때문에 패턴과 각 클러스터 센터 사이의 거리에 대한 퍼

지 소속도의 합이 1이어야 한다. 그러므로 노이즈와 같은 패턴에 대해서도 다른 패턴과 같이 퍼지 소속도를 할당하기 때문에 경계면의 위치가 영향을 받게 된다.

이러한 단점을 보완하기 위해서 본 논문에서는 possibilistic 접근 방법을 적용하여 kernel possibilistic C-means(KPCM)을 제안하였다. KPCM은 노이즈와 같이 센터로부터 멀리 떨어진 패턴에 대해서는 다른 패턴과 비교하여 상대적으로 작은 퍼지 소속도를 할당하기 때문에 노이즈가 포함된 데이터에 대해서 더 뛰어난 클러스터링 수행이 가능할 수 있다.

본 논문은 다음과 같이 구성된다. 두 번째 절에서 커널 함수에 대해 설명하고 세 번째 절에서는 FKCM에 대하여 소개한다. 네 번째 절에서는 본 논문에서 제안하고 있는 KPCM에 대해 설명한다. 다음으로 FCM과 FKCM, KPCM의 결과를 비교하고 마지막으로는 논문에 대한 결론을 언급하도록 한다.

#### 2. 커널 함수

커널 방법의 기본적인 생각은 공간 변환 함수를 사용하여 입력 데이터들을 입력 속성 공간에서 커널 함수를 통한 커널 속성 공간으로 변환하여 주는 것이다.

이러한 변환을 하는 것은 입력 속성 공간에서 직선이 아닌 경계면을 갖는 데이터를 더 쉽게 구분하기 위해서 커널

접수일자 : 2004년 9월 30일

완료일자 : 2004년 11월 25일

감사의 글 : 본 연구는 한국과학기술원 영상정보특화 연구센터를 통한 국방과학연구소의 연구비 지원으로 수행되었습니다.

방법을 적용함으로써 직선의 경계면을 갖는 커널 속성 공간으로 바꾸기 위한 것이다.

그림 1과 같이 데이터들의 공간을 변환하기 위하여 공간 변환 함수를 사용한다. 즉 입력 공간에서의 데이터를  $X_i, i=1, \dots, N$ 이라 한다면 함수를 통해 커널 속성 공간으로 변환된 데이터는  $\phi(X_j), j=1, \dots, N$ 로 나타낼 수 있다. 여기에서  $\phi()$ 는 입력 공간의 데이터를 비선형적으로 커널 속성 공간으로 변환시켜주는 함수이다. 이렇게 정의된 변환 함수에 의한 두 함수 값의 내적(inner product)을 커널 함수로서 정의한다 [1].

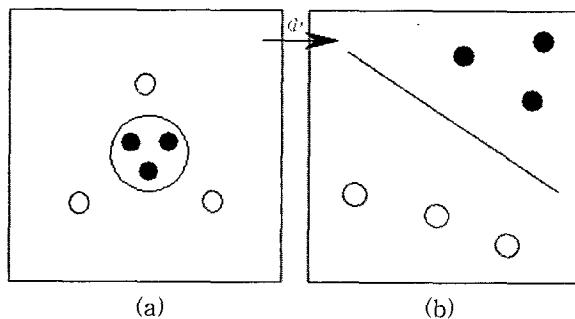


그림 1. 커널 함수에 의한 공간 변환 : (a) Input feature space (b) Kernel feature space

커널 함수로는 다음의 식과 같은 다항식이나 가우시안 등의 함수를 사용할 수 있다.

$$K(X, Y) = \phi(X) \cdot \phi(Y) = (X \cdot Y + b)^d \quad (1)$$

$$K(X, Y) = e^{-\frac{(X-Y)^2}{2\sigma^2}} \quad (2)$$

(1)식의  $d$ 는 다항식의 차수,  $b$ 는 상수를 나타내고, (2)식에서  $\sigma^2$ 은 클러스터 분산(variance)을 나타내는 파라미터이다. 커널 함수를 사용함으로써, 두 벡터에 대한 공간 변환 함수 값을 구하지 않고 커널 함수의 값을 직접 구할 수 있다. 여기에서 공간 변환 함수에 대한 수학적인 정의 없이 커널 함수를 정의하는 것은 다음에서 정의 되어지는 커널 거리를 구하는데 있어서 변환 함수를 통하지 않고 커널 함수에 의해서 거리를 구할 수 있기 때문이다. 입력 공간상에서  $X_i$ 와  $X_j$ 의 커널 속성 공간상 거리는 커널 함수에 의해 (3)과 같이 표현된다.

$$\begin{aligned} d_{ij}^2 &= |\phi(X_i) - \phi(X_j)|^2 \\ &= \phi(X_i)\phi(X_i) - 2\phi(X_i)\phi(X_j) + \phi(X_j)\phi(X_j) \quad (3) \\ &= K(X_i, X_i) - 2K(X_i, X_j) + K(X_j, X_j) \end{aligned}$$

이러한 거리의 식을 이용하여 커널 방법을 적용한 알고리즘을 수행하게 된다.

### 3. 퍼지 커널 C-means 알고리즘(FKCM)

일반적인 FCM의 경우와 마찬가지로 FKCM의 경우에도, 다음의 목적 함수를 최소화하는 것을 기초로 한다.

$$J(X; U, V) = \sum_{j=1}^C \sum_{i=1}^N u_{ij}^m d^2(X_i, V_j), \quad 2 \leq C < N \quad (4)$$

여기에서  $U$ 는 각 클러스터에 대한 소속도,  $u_{ij}$ 를 원소로 가지는 행렬을 나타내고  $m$ 은 퍼지화의 정도를 나타내는 상수로서  $m \in (1, \infty)$ 인 조건을 만족하는 상수이다. 또한  $U$ 는 다음의 조건을 만족해야 한다.

$$\sum_{j=1}^C u_{ij} = 1, \quad \forall i \text{ and } 0 < \sum_{j=1}^N u_{ij} < N, \quad \forall j$$

(4)식의 목적함수를 최소화하는 소속도를 구해보면 다음과 같은 식으로 표현된다.

$$u_{ij} = \frac{(1/d^2(X_i, V_j))^{1/(m-1)}}{\sum_{j=1}^C (1/d^2(X_i, V_j))^{1/(m-1)}}, \quad (5)$$

$$j = 1, \dots, C, \quad i = 1, \dots, N$$

패턴과 센터의 거리,  $d^2(X_i, V_j)$ 은 커널 함수를 이용하여 다음과 같이 나타낼 수 있다.

$$d^2(X_i, V_j) = K(X_i, X_i) - 2K(X_i, V_j) + K(V_j, V_j) \quad (6)$$

초기 센터에 대해 모든 데이터와 센터간의 초기 소속도가식 (5)에 의해서 결정되면 패턴과 센터 사이의 새로운 거리는 다음 식들을 이용하여 갱신할 수 있다.

$$K(X_i, V_j^*) = \frac{\sum_{k=1}^N (u_{jk})^m K(X_k, X_i)}{\sum_{k=1}^N (u_{jk})^m} \quad (7)$$

$$K(V_j^*, V_j^*) = \frac{\sum_{k=1}^N \sum_{l=1}^N (u_{jk})^m (u_{jl})^m K(X_k, X_l)}{\left( \sum_{k=1}^N (u_{jk})^m \right)^2}, \quad (8)$$

$$\text{where } \phi(V_j^*) = \frac{\sum_{i=1}^N (u_{ji})^m \phi(X_i)}{\sum_{i=1}^N (u_{ji})^m} \quad (9)$$

이러한 거리를 이용하여 (5)식의 목적 함수를 최소화 시켜주는 소속도를 구할 수 있다.

이와 같은 과정을 초기에 정의한 종료조건을 만족할 때까지 반복하여 FKCM을 수행한다.

### 4. 제안 알고리즘(KPCM)

KPCM의 기본적인 목적은 서론에서 간단히 설명했듯이 커널 함수를 이용한 공간 변환을 통하여 클러스터링을 수행하던 FKCM보다 노이즈에 대해 강한 성질을 부여하는 것이다. 그래서 본 논문에서는 possibilistic 접근 방법의 목적 함수식을 이용한다. Possibilistic 접근 방법이 노이즈에 영향을 적게 받는 이유는 다음의 예를 통하여 잘 알 수 있다. 그림 2와 같이 양쪽에 두 개의 센터가 있고 가운데에 두 개의 패턴이 놓여 있다고 하자.

각 패턴과 센터들의 좌표를  $\{C_1:(0.2, 0.3), C_2:(0.8, 0.3), P_1:(0.5, 0.3), P_2:(0.5, 0.8)\}$ 으로 표시한다면 퍼지 접근 방법에 의한 소속도는 모두 0.5가 되지만 possibilistic 접근 방법에 의한 소속도는  $P_1$ 에 대해서는 0.625가 되고  $P_2$ 에 대해서는 0.583의 값을 가진다. 이처럼 possibilistic 접근 방법에서는 상대적으로 멀리 있는 패턴에 대해서 더 작은 소속도를 할당한다.

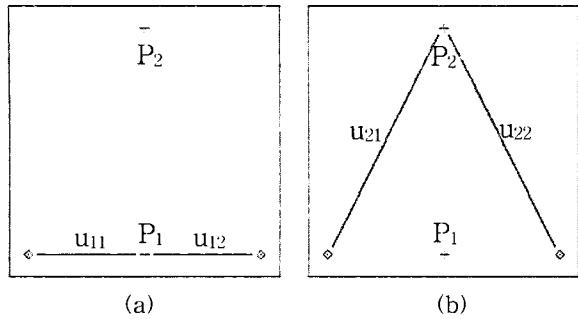


그림 2. 거리에 따른 소속도 : (a) membership among (b) membership among the  $P_1$  and each center the  $P_2$  and each center

이러한 효과를 통하여 노이즈에 더 강한 성질을 갖도록 하기 위해 다음과 같은 possibilistic 접근 방법의 목적 함수를 사용한다.

$$J(X; U, V) = \sum_{j=1}^C \sum_{i=1}^N u_{ij}^m d^2(X_i, V_j) + \sum_{j=1}^C \eta_j \sum_{i=1}^N (1 - u_{ij})^m \quad (10)$$

위의 식에서  $\eta_j$ 는 (12)식에 의해 구해지는 적절한 양수이다.  $\eta_j$ 의 값에 의해 KPCM에서는 노이즈 데이터에 대해서 FKCM보다 상대적으로 작은 소속도를 할당함으로써 노이즈 데이터에 강한 성능을 나타낸다. KPCM에서는 적절한 초기 소속도를 구하기 위해서 먼저 FKCM을 수행한다. 소속도의 식은 다음과 같이 표현할 수 있다.

$$u_{ij} = \frac{1}{1 + \left( \frac{d^2(X_i, V_j)}{\eta_j} \right)^{1/(m-1)}}, \quad (11)$$

$$\text{where } \eta_j = \frac{\sum_{i=1}^N u_{ij}^m d^2(X_i, V_j)}{\sum_{i=1}^N u_{ij}^m} \quad (12)$$

이렇게 정의된 소속도에 대하여 (6)식과 (7), (8), (9)식에 의해 커널 속성 공간상에서의 패턴과 센터의 거리  $d^2(X_i, V_j)$ 를 갱신한다. 위의 과정을 정의된 종료 조건을 만족할 때까지 반복하면 주어진 목적 함수를 최소화 할 수 있는 각 패턴들의 소속도를 구할 수 있다. KPCM 알고리즘은 다음과 같이 정리할 수 있다.

### Kernel Possibilistic C-Means Algorithm

#### Step 1. Initialization of the membership

(Using Fuzzy Kernel C-Means Algorithm)  
Initialize random  $k$  center  $V_k$  and  $m$ ,  $\sigma^2$ ;  
Compute the initial membership  $u_{ij}^{(0)}$ ;

#### Step 2. Minimization of the objective function

(Kernel Possibilistic C-Means Algorithm)

Compute  $d^2(X_i, V_j)$  using (6),(7),(8),(9);  
Do : Calculate  $\eta_j$  using (12);  
Compute  $u_{ij}^{(t)}$  using (11);  
Update  $d^2(X_i, V_j)$  using (6),(7),(8),(9);  
Until :  $|u_{ij}^{(t+1)} - u_{ij}^{(t)}| < \epsilon$ ;

## 5. 실험 결과 및 분석

본 절에서는 일반적인 구형의 데이터들과 복잡한 분포를 가지는 데이터, 그리고 실제적인 영상 데이터에 대해서 본 논문에서 제안하는 커널 possibilistic C-means 알고리즘을 사용하여 FCM과 퍼지 커널 C-means 알고리즘과 비교하도록 한다. 사용된 커널 함수는 가우시안 커널 함수이고 각 실험에 필요한 분산 값은 적절한 값을 임의로 결정하여 사용한다. 그리고 퍼지화의 정도를 나타내 주는  $m$ 값은 1.5를 사용하도록 한다.

### 5.1 A spherical data without noise

첫 번째로 80개의 패턴과 두개의 클러스터로 구성되는 노이즈가 없는 데이터에 대해서 실험한다. 퍼지 커널 C-means와 커널 possibilistic C-means 알고리즘을 수행하기 위하여 필요한 분산 값은 모두 1.0을 사용한다.

그림 3의 결과에서 FCM, FKCM 그리고 KPCM 모두 그림과 같은 일반적인 구형의 데이터에 대해서는 정확한 결과를 얻을 수 있다는 것을 알 수 있다.

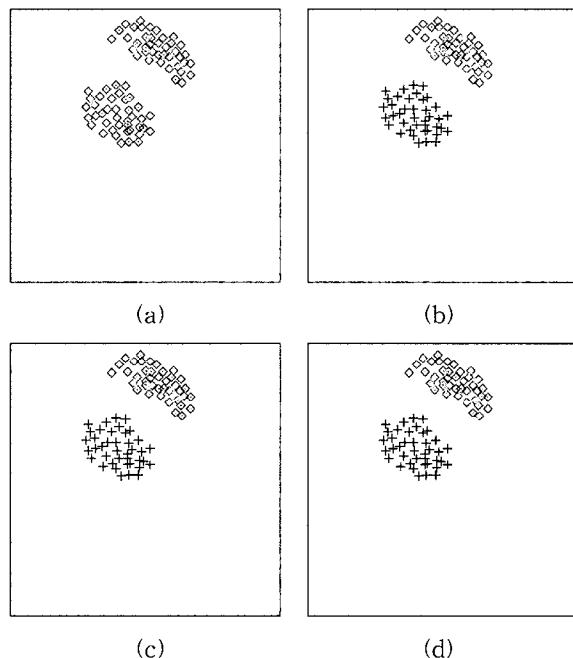


그림 3. 노이즈가 없는 구형의 데이터에 대한 클러스터링 결과 : (a) original data (b) FCM (c) FKCM (d) KPCM

### 5.2 A spherical data with noise

두 번째 실험은 5.1의 실험 데이터에 40개의 노이즈가 포함된 경우이다. 실험에 필요한 분산의 값은 5.1의 경우와 같은 값인 1.0을 모두 사용하였다.

그림 4(a)의 노이즈가 포함되어 있는 데이터에 대해서는 그림 4(b)와 4(c)에서 볼 수 있듯이 FCM과 FKCM의 경우 노이즈의 영향을 받는다. 하지만 possibilistic 접근 방법을 사용하는 KPCM의 경우 노이즈의 영향을 거의 받지 않고 원래의 클러스터를 잘 구분해 내는 것을 알 수 있다.

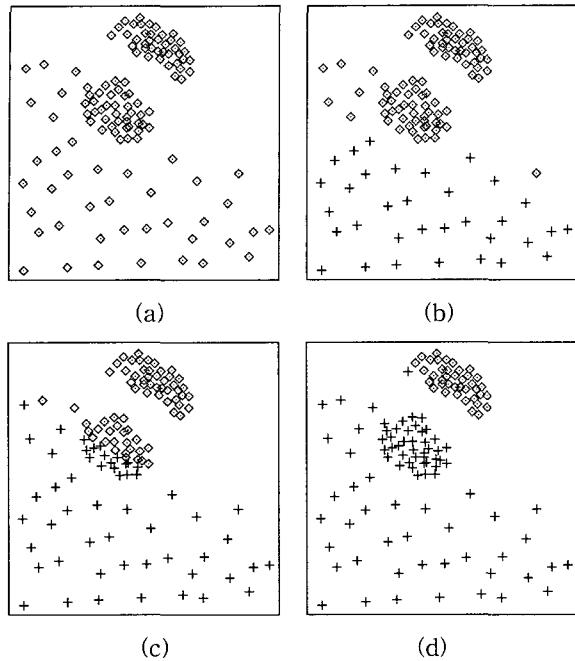


그림 4. 노이즈가 포함된 구형의 데이터에 대한 클러스터링 결과 : (a) noisy data (b) FCM (c) FKCM (d) KPCM

### 5.3 “Ring-shaped” data without noise

그림 5(a)의 데이터는 120개의 패턴과 내부와 외부의 두 개의 클러스터로 구성되는 데이터이다. 클러스터링 수행에 필요한 분산의 값은 FKCM과 KPCM 각각에 대하여 0.006과 0.07의 값을 사용하였다. 그림 5(a)의 고리 모양 데이터에 대한 클러스터링의 경우에 FCM은 정확한 결과를 얻어낼 수 없다. 하지만 커널 거리를 이용하는 FKCM과 KPCM의 경우 두 개의 클러스터를 잘 구분하는 것을 알 수 있다.

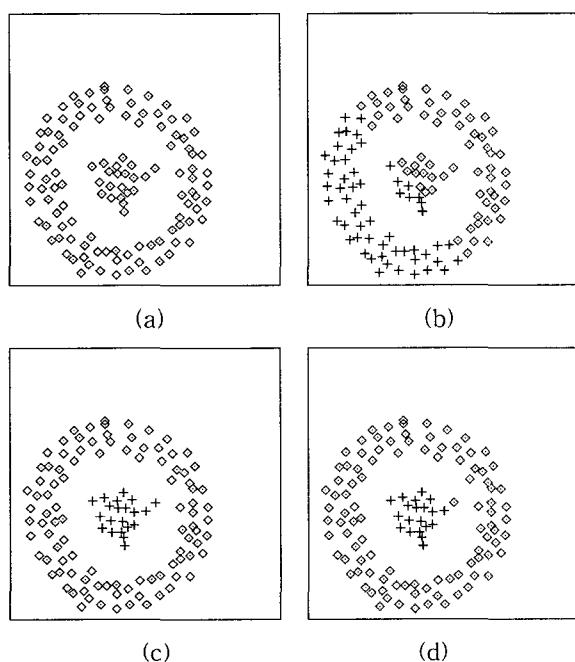


그림 5. 노이즈가 없는 고리 모양 데이터에 대한 클러스터링 결과 : (a) original data (b) FCM (c) FKCM (d) KPCM

### 5.4 “Ring-shaped” data with noise

이번 실험에 사용되는 데이터는 5.3의 실험에서 사용한 고리 모양의 데이터에 40개의 노이즈가 포함되어 있는 데이터이다. 5.3에서와 마찬가지로 분산 값은 각각 0.006과 0.07을 사용한다.

그림 6(b)에서 보듯이 FCM은 노이즈가 없는 경우와 마찬가지로 클러스터 구분을 정확히 하지 못한다. 또한 FKCM의 경우 노이즈로 인한 영향을 받아 클러스터가 한쪽으로 쏠리는 것을 알 수 있다. 하지만 본 논문에서 제안한 KPCM의 경우 노이즈의 영향 없이 원래의 클러스터를 정확히 구분하는 것을 알 수 있다.

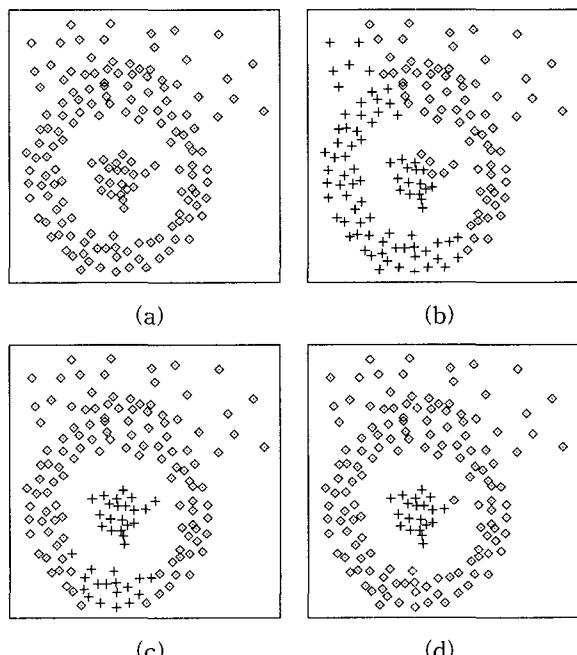
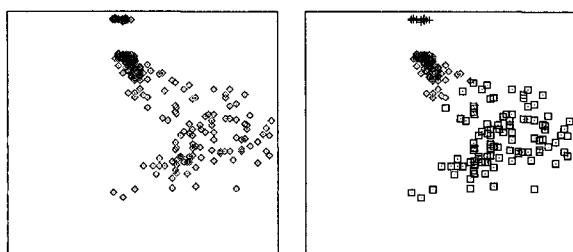


그림 6. 노이즈가 포함된 고리 모양 데이터에 대한 클러스터링 결과 : (a) noisy data (b) FCM (c) FKCM (d) KPCM

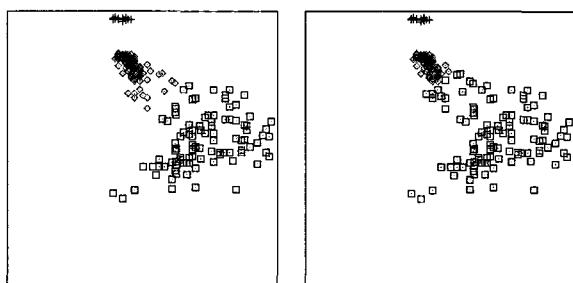
### 5.5 Image data without noise

이제 지금까지의 알고리즘을 이용하여 3개의 영역을 가지는 영상을 분할에 대한 성능의 차이를 비교하도록 한다. 속성은 median filter와 excess green에 의한 결과 영상 값을 사용한다. 먼저  $200 \times 200$ 의 사이즈를 갖는 실제 영상을 분할하기 위해서 각 클러스터에서 100개씩의 샘플 데이터를 추출하여 학습시킨 후 학습된 결과에 의해서 영상을 분할하도록 한다. 300개의 샘플 데이터는 그림 7(a)의 그림과 같다. 알고리즘을 수행하기 위한 FKCM, KPCM의 분산의 값은 모두 1.0을 사용하였다. 그림 7의 결과에서 보듯이 샘플 데이터에 대해서 세 개의 알고리즘 모두 적절한 결과를 얻을 수 있는 것을 알 수 있다. 이에 대한 결과를 사용하여 영상 분할을 하도록 한다. 영상 분할에 대한 결과는 그림 8과 같다.



(a)

(b)



(c)

(d)

그림 7. 노이즈가 없는 영상의 샘플 데이터에 대한  
클러스터링 결과 : (a) sample data of noiseless image  
(b) FCM (c) FKCM (d) KPCM

그림 8의 각 알고리즘에 대한 영상분할 결과에서 FCM과 FKCM은 왼쪽 숲과 길의 끝부분, 그리고 오른쪽 숲의 전신주 부분의 영상 분할이 정확히 이루어지지 않았다. 그림 8(d)의 KPCM의 결과를 살펴보면 샘플 데이터에 대한 결과는 비슷함에도 불구하고 숲의 영역이나 길의 영역에 대해서 적절하게 분할하고 있는 것을 알 수 있다.

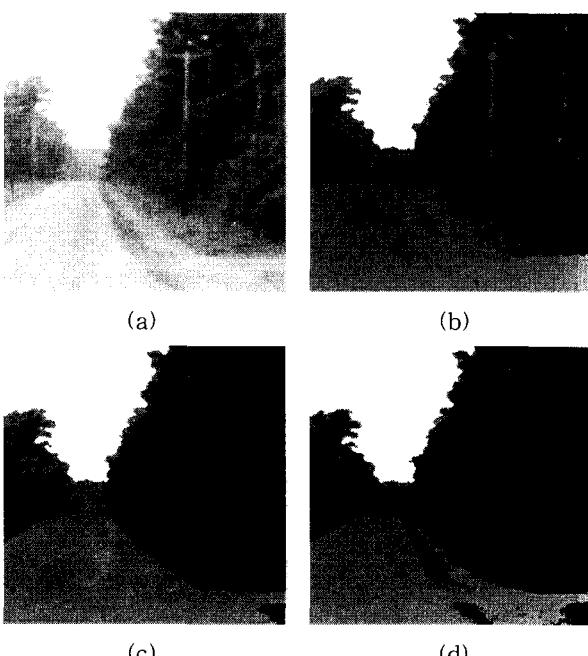
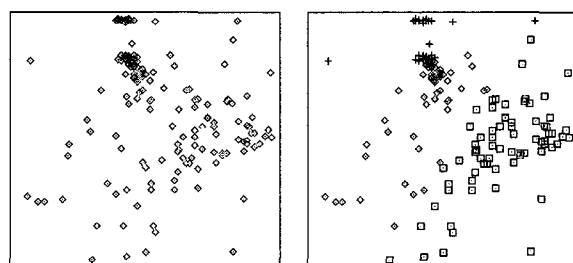


그림 8. 노이즈가 없는 영상의 영역 분할 결과 : (a) original image (b) FCM (c) FKCM (d) KPCM

### 5.6 Image data with noise

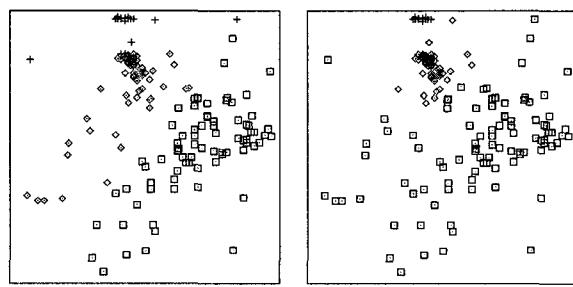
마지막으로 그림 10(a)와 같이 25%의 가우시안 노이즈를 가지는 영상에 대하여 그림 7(a)와 같이 300개의 샘플을 취하여 학습시킨 후 그 결과에 의한 영상 분할의 결과를 비교하도록 한다. 각 파라미터는 5.5의 실험과 같은 값을 사용한다.

그림 9의 결과를 살펴보면 FCM과 FKCM의 경우 클러스터의 영역들이 노이즈의 영향을 받아 변화가 생기지만 KPCM의 경우 노이즈에 크게 영향을 받지 않고 노이즈가 없는 경우와 비슷한 결과를 가진다는 것을 알 수 있다. 영상 분할의 결과는 그림 10과 같다.



(a)

(b)

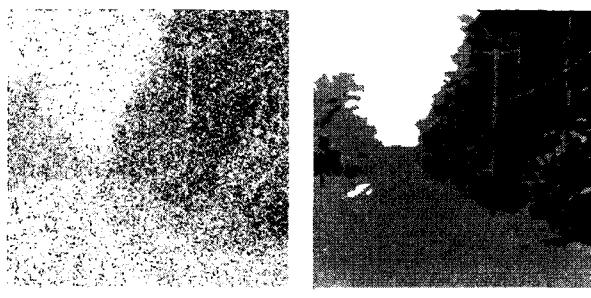


(c)

(d)

그림 9. 노이즈가 포함된 영상의 샘플 데이터에 대한  
클러스터링 결과 : (a) sample data of noisy image  
(b) FCM (c) FKCM (d) KPCM

위의 결과에서 알 수 있듯이 샘플 데이터에 대한 클러스터링에서 노이즈의 영향을 받아 정확한 소속도를 할당하지 못하였기 때문에 그림 10의 FCM과 FKCM의 영상 분할 결과가 노이즈가 없을 때와 비교해서 숲의 영역이 많은 차이를 보인다. 하지만 KPCM의 경우 노이즈의 큰 영향을 받지 않고 길, 숲, 하늘의 영역을 적절하게 구분해 내고 있음을 알 수 있다.



(a)

(b)

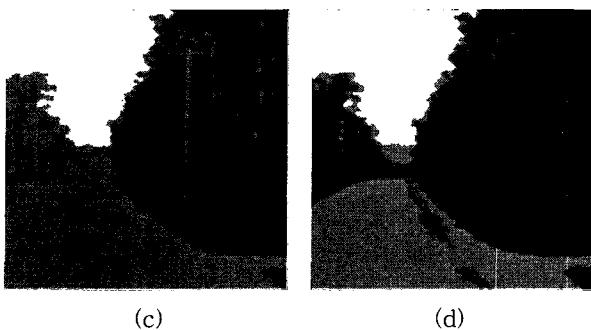


그림 10. 노이즈가 포함된 영상의 영역 분할 결과 :  
(a) noisy image (b) FCM (c) FKCM (d) KPCM

## 6. 결 론

본 논문에서는 커널 함수를 사용하여 KPCM 알고리즘을 제안하였다. 펴지 접근 방법에 커널 함수를 적용한 FKCM은 일반적인 구형 모양의 데이터뿐만 아니라 고리 모양의 데이터에 대해서도 클러스터링이 가능하였다. 하지만 펴지 접근 방법을 사용함으로써 각 센터와 패턴사이의 소속도의 합이 1이어야 하는 조건에 의해 노이즈에 대해서는 민감한 현상을 나타내었다. 본 논문에서 제안된 KPCM은 실험 결과에서 보듯이 FKCM과 마찬가지로 노이즈를 갖지 않는 일반적인 구형의 데이터뿐만 아니라 고리모양의 데이터와 같이 복잡한 형태의 분포를 가지는 데이터에 대해서도 클러스터링이 가능하였다. 또한 노이즈가 포함된 데이터에 대해서는 FKCM의 결과보다 좋은 클러스터링 결과를 가진다는 것을 알 수 있었다. 하지만 FKCM이나 KPCM 모두 분산의 값의 변화에 대해 민감한 단점을 보였다. 주어지는 실험 데이터에 대해 적절한 커널 함수와 커널 함수에 대한 적절한 파라미터를 찾는 과정에 대해서는 향후 연구과제로 남아있다.

## 참 고 문 헌

- [1] M. Girolami, "Mercer Kernel-Based Clustering in Feature Space," *IEEE Trans. Neural Networks*, vol. 13, no. 5, pp. 780-784, May 2002.
- [2] Z. Wu, W. Xie, and J. Yu, "Fuzzy C-Means Clustering Algorithm based on Kernel Method," *IEEE Conf. Computational Intelligence and Multimedia Applications*, pp. 49-54, September 2003.
- [3] R. Krishnapuram and J. Keller, "A Possibilistic Approach to Clustering," *IEEE Trans. Fuzzy Syst.* vol. 1, no. 2, pp. 98-110, May 1993.
- [4] R. Krishnapuram and J. Keller, "A Possibilistic C-Means Algorithm : Insights and Recommendations," *IEEE Trans. Fuzzy Syst.* vol. 1, no. 2, pp. 98-110, May 1993.
- [5] J. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York 1981.
- [6] M. Barni, V. Cappellini, and A. Mecocci,

"Comments on "A Possibilistic Approach to Clustering," *IEEE Trans. Fuzzy Syst.* vol. 4, no. 3, August 1996.

- [7] D. Zhang and S. Chen, "Fuzzy Clustering Using Kernel Method," *IEEE Conf. Control and Automation*, Xiamen, China, June 2002.

## 저 자 소 개



최길수(Kil-Soo Choi)

2003년 : 한양대학교 전자컴퓨터 공학과 졸업  
현재 : 동 대학원 전자전기제어계측공학과 석사과정

관심분야 : Fuzzy Systems, Pattern Recognition, Kernel Transformation.

E-mail : kschoi@fuzzy.hanyang.ac.kr



최병인(Byung-In Choi)

2001년 : 한양대학교 전자공학과 졸업  
2001년~2003년 : 동 대학원 전자전기제어 계측공학과 석사  
현재 : 동 대학원 전자전기제어계측공학과 박사과정

관심분야 : Fuzzy Systems, Pattern

Recognition, Support Vector Machines.

E-mail : bicho@fuzzy.hanyang.ac.kr



이정훈(Frank Chung-Hoon Rhee)

1981년~1985년 : University of Southern California(USC), Dept. of Electrical Eng., BSEE.  
1985년~1987년 : University of Missouri, Dept. of Electrical & Computer Eng., MSEE  
1990년~1993년 : University of Missouri, Dept. of Electrical & Computer Eng., Ph.D.  
1994년~1995년 : 한국전자통신연구원

1995년~현재 : 한양대학교 전자컴퓨터공학부 부교수

2002년~현재 : 제어자동화시스템공학회 편집위원

2003년~현재 : 세계 펴지 학회(IFSA) 한국 지부 대표

관심분야 : Computer Vision, Pattern Recognition, and all aspects of Computational Intelligence.

E-mail : frhee@fuzzy.hanyang.ac.kr