

# 클러스터 중심 왜곡 저감을 위한 클러스터링 기법

## Clustering Method for Reduction of Cluster Center Distortion

정혜천, 서석태, 이인근, 권순학\*

Hye C. Jeong, Suk T. Seo, In K. Lee, Soon H. Kwon\*

영남대학교 전기공학과

Dept. of Electrical Engineering, Yeungnam University

### 요 약

클러스터링은 주어진 임의의 데이터 중에서 유사한 성질을 지닌 데이터를 복수개의 그룹으로 조직화하는 기법이다. 이를 위해 K-Means, Fuzzy C-Means(FCM), Mountain Method(MM) 등과 같은 많은 기법들이 제안되었고 또한 널리 사용되어 지고 있다. 그러나 이러한 기법들은 초기값에 따라 클러스터링 결과가 크게 달라지는 단점이 있다. 특히 가장 널리 사용되는 FCM 기법은 잡음 데이터에 취약하며, 주어진 입력 데이터의 클러스터 내부분산을 최소화 하는 방법을 사용하기 때문에 클러스터링 중심의 왜곡 현상이 발생한다. 본 논문에서는 데이터 가중치에 근거한 비례적 근접데이터 병합을 통하여 클러스터 중심 왜곡을 저감하며 초기값에 영향을 받지 않는 클러스터링 기법을 제안한다. 그리고 FCM으로 얻어진 클러스터 중심과 제안기법을 적용하여 얻어진 클러스터 중심에 대한 비교 검토를 통하여 제안기법의 효용성을 확인한다.

키워드 : 클러스터 중심 왜곡, FCM, 근접데이터, 데이터 가중치.

### Abstract

Clustering is a method to classify the given data set with same property into several classes. To cluster data, many methods such as K-Means, Fuzzy C-Means(FCM), Mountain Method(MM), and etc, have been proposed and used. But the clustering results of conventional methods are sensitively influenced by initial values given for clustering in each method. Especially, FCM is very sensitive to noisy data, and cluster center distortion phenomenon is occurred because the method dose clustering through minimization of within-clusters variance. In this paper, we propose a clustering method which reduces cluster center distortion through merging the nearest data based on the data weight, and not being influenced by initial values. We show the effectiveness of the proposed through experimental results applied it to various types of data sets, and comparison of cluster centers with those of FCM.

Key Words : Cluster center distortion, FCM, Nearest data, Data weight.

## 1. 서 론

클러스터링은 주어진 데이터의 특징을 분석하여 유사한 성질을 갖는 데이터를 동일 그룹으로 분류하는 기법으로 무 감독 추정, 분류, 영상처리 등의 다양한 분야에서 활용되고 있다. 클러스터링의 대표적 기법들로는 K-Means[1], Fuzzy C-Means(FCM)[2], Mountain Method(MM)[3,4]이 있으며, SVM에 기반한 기법[5], 신경망을 이용한 기법[6] 등의 다양한 응용기법들[7~11]이 있다.

이와 같은 기법들 중에서 널리 사용되고 있는 FCM은 주어진 데이터 집합  $X = \{x_1, x_2, \dots, x_n\}$ 의 클러스터 개수  $c$ 를 결정 후  $n \times c$ 의 퍼지 행렬을 반복적 연산을 통하여 생성하는 기법이다. 따라서 초기값이 클러스터링 수렴속도 및 수렴 정확도에 직접적으로 영향을 미친다. 또한 FCM은 클러스터 내부분산 최소화를 통하여 클러스터링을 수행하기 때문에 클러스터 중심 왜곡 현상이 발생한다. 이러한 단점을 극복하기 위하여 클러스터 내부 분산을 최소화하며 클러스

터 중심간의 거리를 최대화하는 Bi-criteria Fuzzy C-Means[10]가 제안되었으나, 이 역시 최적의 클러스터 중심을 제시하지는 못한다.

MM의 경우, 주어진 자료가 존재하는 공간을 적절한 크기로 분할하고, 분할된 공간들의 교점을 클러스터의 중심이 위치할 후보로 가정한 후 설정함수의 값을 만족하는 지점을 클러스터의 중심으로 선정하는 기법이다. 그러나 이 기법 역시 초기 자료 공간 분할에 따라서 클러스터링 결과가 크게 달라지는 단점을 갖고 있다[4].

본 논문에서는 주어진 데이터 집합에서 각 데이터의 가중치에 근거한 비례적 근접데이터 병합을 통하여 클러스터의 중심 왜곡 현상을 저감하며, 초기값에 영향을 받지 않는 클러스터링 기법을 제안한다. 그리고 여러 가지 형태의 데이터 집합에 제안기법을 적용하여 얻어진 클러스터 중심과 FCM기법을 적용하여 얻어진 클러스터 중심의 비교를 통해서 제안기법의 효용성을 확인한다.

## 2. Fuzzy C-Means

FCM은 주어진 데이터 집합 :  $X = \{x_1, x_2, \dots, x_n\}$ 에 대해

접수일자 : 2007년 8월 24일

완료일자 : 2008년 1월 20일

\* Corresponding Author

여 멤버십 함수 값  $u_{ij}$ 와 클러스터 중심 값  $v_i$ 를 갖는 아래의 함수 값을 최적화하도록  $U$  및  $V$ 를 선정하는 문제이다.

$$J_m(U, V; X) = \sum_{j=1}^n \sum_{i=1}^c u_{ij}^m \|x_j - v_i\|^2, \quad m \in [1, \infty]$$

[FCM 기법]

Step 1] 주어진 데이터 집합 :  $X = \{x_1, x_2, \dots, x_n\}$   
초기 퍼지 분할 값  $U^{(0)} = [u_{ik}]$ 를 지정

Step 2] 클러스터의 중심 계산

$$v_i^{(l)} = \frac{\sum_{k=1}^n (u_{ik}^{(l-1)})^m x_k}{\sum_{k=1}^n (u_{ik}^{(l-1)})^m}, \quad 1 \leq i \leq c, \quad l = 1, 2, \dots$$

Step 3] 각 데이터와 중심사이의 거리계산

$$D_{ik} = \|x_k - v_i^l\|$$

Step 4]  $U$ 값을 갱신

$$u_{ik}^{(l)} = \frac{1}{\sum_{j=1}^c (D_{ik}/D_{jk})^{\frac{2}{m-1}}}$$


Step 5] if  $\|U^{(l)} - U^{(l-1)}\| < \epsilon$ , then stop  
else Step 2] ~ Step 4] 반복

즉, FCM은 주어진 조건을 만족할 때까지 반복적 연산을 통해서 최적의 클러스터를 결정하는 기법이다. 그러나 FCM은 클러스터의 내부분산을 최소화하는 방법을 사용하기 때문에 그림 1에 나타난 바와 같이 클러스터 중심 왜곡 현상이 발생한다. 그림 1(b), (c)에서 그림 1(b)는 직관적으로 판단한 주어진 데이터 집합의 최적의 중심을 나타내고 있으며 (c)는 FCM으로 얻어진 중심을 나타내고 있다. 그림 1(c)로부터 클러스터 중심이 거리 개념을 바탕으로 한 내분산이 최소화되는 지점으로 왜곡되는 현상을 확인할 수 있다. 따라서, 이러한 클러스터 중심 왜곡 현상을 저감하는 클러스터링 기법의 개발이 요구되어지고 있다.


### 3. 제안 클러스터 기법

본 논문에서는 데이터 가중치에 따른 비례적 근접데이터 병합을 이용하여 클러스터 중심 왜곡을 최소화하는 기법을 제안한다. 그림 2는 제안기법의 전체 개요도를 나타낸다.

즉, (i) 주어진 데이터를 정규화하고, (ii) 정규화된 데이터 각 쌍 간의 유사도를 측정하여, (iii) 병합할 데이터 후보들을 추출하며, (iv) 기준 측도를 바탕으로 데이터 병합을 수행하고, (v) 클러스터의 개수가 주어진 수와 일치하게 되면 클러스터링을 종료한다. 단계 (iv)의 데이터 병합을 위해서 아래 3.3절에서 자세하게 설명할 데이터 가중치에 근거한 비례적 데이터 병합법을 제안하고, 이를 이용하여 데이터의 병합을 수행한다.



(a)원 데이터 (b)최적 클러스터 중심  
(a)Input data set (b)Optimal cluster centers



(c)FCM으로 얻어진 클러스터 중심  
(c)Centers obtained by FCM

그림 1. FCM 기법의 클러스터 중심 왜곡 예  
(● : 데이터, \* : 최적 중심, □ : FCM 중심)

Fig. 1. Example of cluster center distortion of FCM  
(● : Data, \* : Optimal center, □ : FCM center)

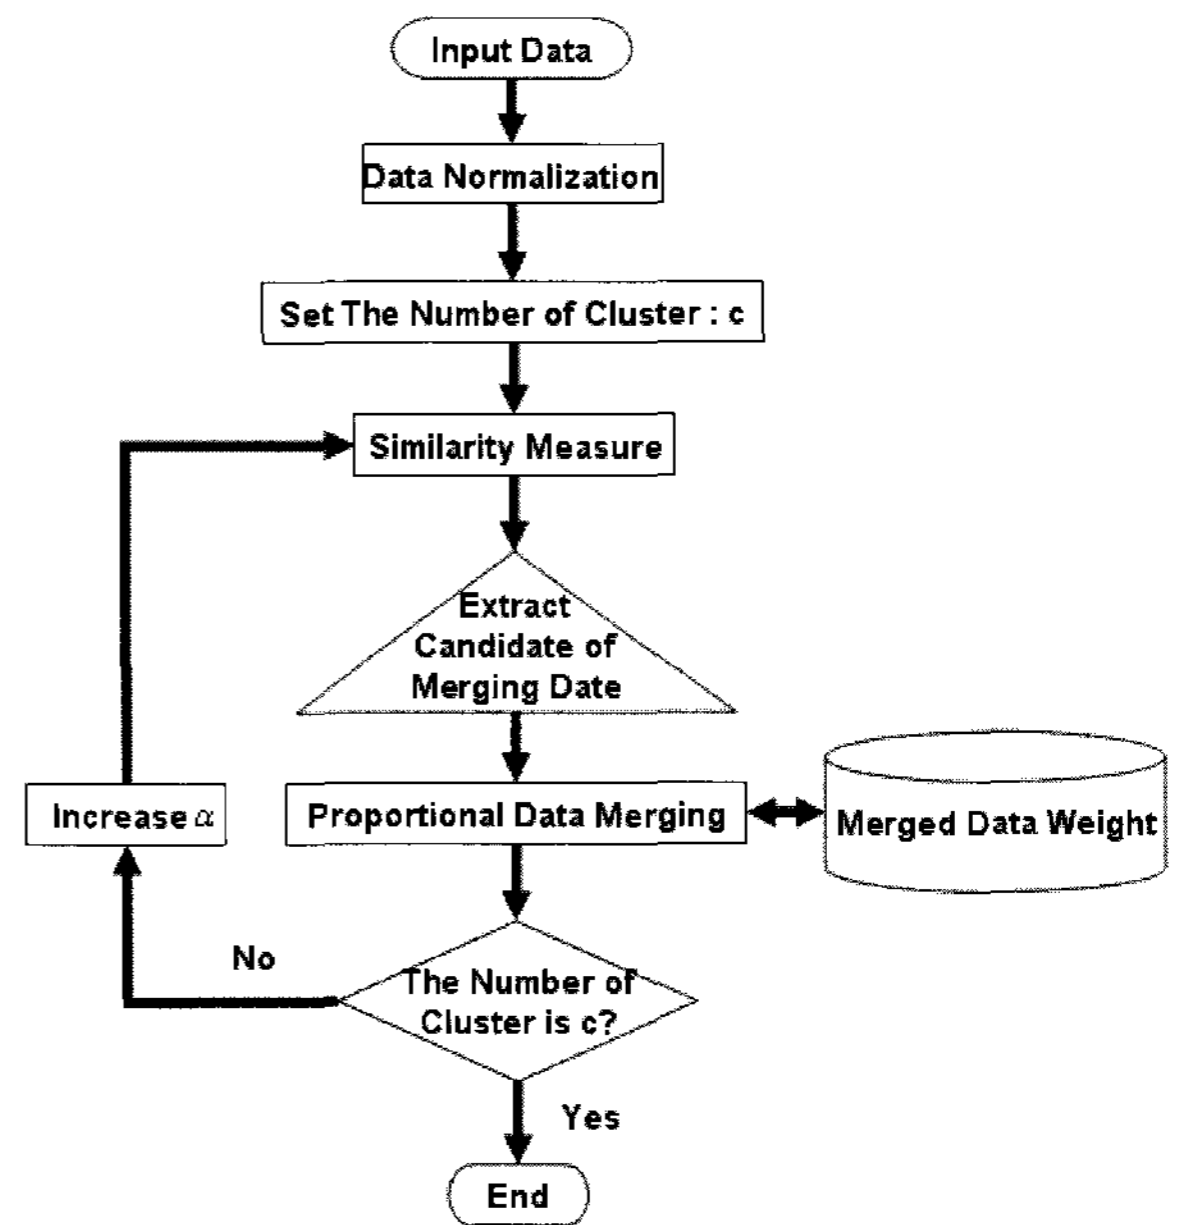


그림 2. 제안 기법의 개요도

Fig 2. Block diagram of the proposed method

#### 3.1. 데이터 정규화

입력 데이터의 분포 범위가 상이하므로, 입력 데이터를 각 속성별로  $[0,1]$ 로 아래와 같이 정규화 한다.

$$\text{입력 데이터 : } X = \{x_i | i = 1, \dots, n\}$$

$$x_i = (a_i^d | d = 1, \dots, D)$$

$$\text{정규화 데이터 : } X' = \{x_i' | i = 1, \dots, n\}$$

$$x_i' = (b_i^d | d=1, \dots, D)$$

$$b_i^d = \frac{a_i^{d'}}{\max(d)} \quad (1)$$

여기서,  $D$  : 데이터 속성 차원

$$a_i^{d'} = (a_i^d - \min(d)), \max(d) = \arg \max_{1 \leq i \leq n} a_i^d$$

$$\min(d) = \arg \min_{1 \leq i \leq n} a_i^d$$

### 3.2. 유사도 측정

정규화된 데이터 집합으로부터 각 데이터간의 거리가 유사도 판단 기준값  $p$ 를 만족하는 경우의 데이터 쌍을 식 (2)와 (3)으로부터 추출한다.

$$C_{ij} = \arg(d_{ij} \leq p) \quad (2)$$

$$p = \sqrt{D} \times \frac{\alpha}{v_r} \quad (3)$$

여기서,  $v_r$  : 데이터 집합의 분산

$$v_r = \frac{\sum_{i=1}^n \|x_i' - \bar{v}\|^2}{n}$$

$$\bar{v} = \frac{1}{n} \sum_{i=1}^n x_i'$$

$n$  : 데이터 개수

$\alpha$  : 비례상수,  $[0, v_r]$

$$d_{ij} = \sqrt{\|x_i' - x_j'\|^2}, i \neq j$$

식 (3)에서  $C_{ij}$ 는 식 (2)에서 측정된  $i$ 번째 데이터와  $j$ 번째 데이터 사이의 거리가  $p$ 이하인 데이터 쌍을 나타낸다. 이렇게 식 (2)와 (3)으로부터 추출된 병합 후보들 중에서 최소거리를 가지는 쌍을 우선적으로 추출하며, 추출된 쌍과 중복되는 데이터 쌍은 병합 후보에서 제외한다.

표 1. 데이터 쌍과 거리 예

Table 1. Example of data pairs and their distances

Data	<i>i</i> th	1	1	1	2	2	3
	<i>j</i> th	2	3	4	3	4	4
$d_{ij}$		0.5	0.3	0.2	0.1	0.6	0.7

표 1과 같은 경우, 유사도 판단 기준값  $p=0.4$ 이면, 병합 후보로 다음과 같은 데이터 쌍이 추출된다.

표 2. 병합 후보 데이터 쌍

Table 2. Candidates of data pairs for merging

Data	<i>i</i> th	1	1	2
	<i>j</i> th	3	4	3
$d_{ij}$		0.3	0.2	0.1

표 2에서 (2,3)의 데이터 쌍과 (1,3)의 데이터 쌍 중에서 3번 데이터가 중복되므로, 최소거리를 가지는 데이터 쌍인 (2,3) 데이터 쌍이 우선적으로 선택되고, (1,3) 데이터 쌍은 병합 후보에서 제외된다. 따라서 최종적으로 (1,4), (2,3)의 데이터 쌍들이 선택된다.

만약 유사도 판단 기준값을 만족하는 데이터 쌍이 존재하지 않을 경우,  $\alpha$ 의 값을 증가 시킨 후 다시 검색한다.

### 3.3. 데이터 가중치에 근거한 비례적 데이터 병합

FCM과 같이 거리 척도에만 의존한 기존의 클러스터링 기법은 클러스터 중심 왜곡 현상이 발생한다. 이러한 문제점을 해결하기 위해 본 논문에서는 데이터 가중치를 이용한 데이터 병합 기법을 제안한다.

초기 각 데이터는 1의 가중치를 가지며 병합 과정에서 데이터 가중치는 누적된다. 예를 들어, 임의의 데이터  $A, B$ 가 병합되어 데이터  $C$ 가 생성된다면,  $C$ 의 가중치는  $A, B$  가중치의 합이 된다. 즉,  $A$ 의 가중치  $w(A)=1$ 이며,  $B$ 의 가중치  $w(B)=1$ 이었다면, 새롭게 생성된 병합 데이터  $C$ 의 가중치는  $w(C)=w(A)+w(B)=2$ 가 된다.

병합된 데이터의 좌표는 가중치에 따라 비례적으로 결정된다. 가중치가 낮은 데이터는 가중치가 높은 데이터 쪽으로 치우치며, 이러한 특성을 이용하여 클러스터 중심 왜곡을 저감시킬 수 있다. 이와 같은 병합을 '비례적 병합'이라고 정의한다.

[비례적 병합 예]

병합 데이터 쌍 ( $A, B$ )가 선택;

경우 1] 두 데이터 ( $A, B$ )의 가중치가 동일한 경우;

if  $w(A)=k, w(B)=k$

{  $A$  좌표: (0.0,0.0)  
 $B$  좌표: (0.4,0.4)

(4)

$\Rightarrow$  병합 데이터  $C$  좌표: (0.2,0.2)

즉,  $A, B$  데이터의 움직인 거리 비 = 1: 1이 되며, 병합 데이터  $C$ 의 가중치는  $w(C)=2k$ 가 된다.

경우 2] 두 데이터 [ $A B$ ]의 가중치가 상이할 경우;

if  $w(A)=3k, w(B)=k$

{  $A$  좌표: (0.0,0.0)  
 $B$  좌표: (0.4,0.4)

(5)

$\Rightarrow$  병합 데이터  $C$  좌표: (0.1,0.1)

즉,  $A, B$  데이터의 움직인 거리 비 = 1: 3이 되며, 병합 데이터  $C$ 의 가중치는  $w(C)=4k$ 가 된다.

3절에서 제안하는 클러스터링 기법을 정리하면 다음과 같다.

[제안 클러스터링 알고리즘]

Step 1] 입력 데이터 집합  $X$ 를 정규화

Step 2] 입력 데이터 클러스터 개수 선정 :  $c$

Step 3] 정규화된 데이터 집합으로부터 분산을 구한 후 유사도 판단 기준값을 설정

Step 4] 초기 데이터 가중치를 1로 설정

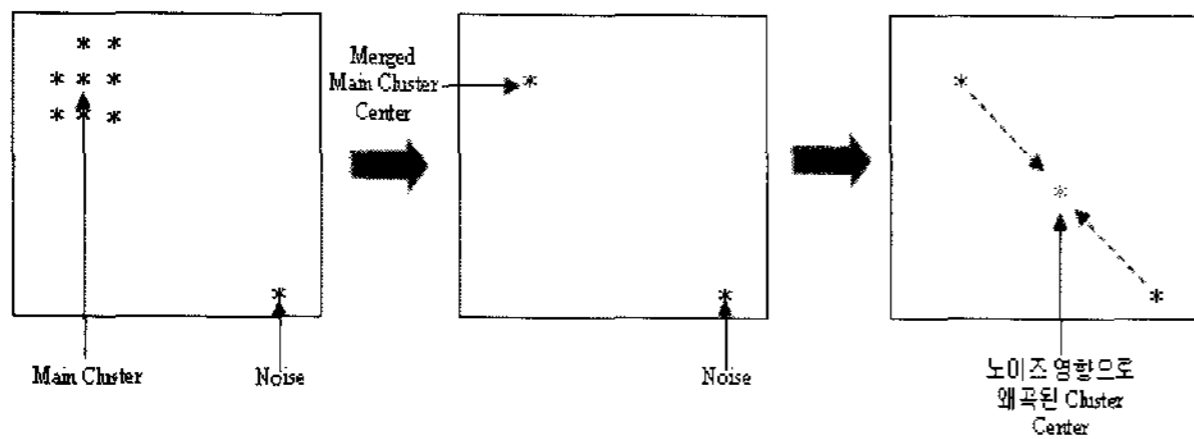
Step 5] 데이터 사이의 거리를 측정

Step 6] 측정된 거리 중 유사도 판단 기준을 만족하는 병합 데이터 후보를 추출

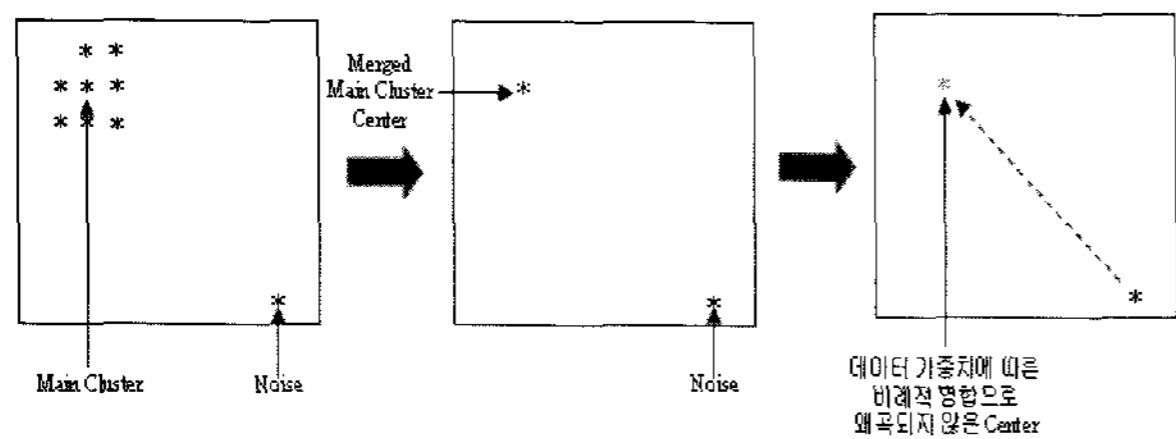
Step 7] 만약 유사도 판단 기준을 만족하는 병합 데이터가 존재하지 않을 경우,  $\alpha$  증가시킨 후 Step 6]를 반복

Step 8] 병합 데이터 후보 중에서 중복 데이터를 제외한다

최종 병합 데이터를 추출  
 Step 9] 추출된 데이터를 비례적으로 병합  
 Step 10] Step 5]~Step9]을 데이터 개수  $n \rightarrow c$ 이 될 때  
 까지 반복



(a)일반적 근접데이터 병합의 중심 왜곡  
 (a)Center distortion by merging the nearest data pair



(b)비례적 병합을 통한 중심왜곡 저감  
 (b)Reduction of center distortion by proportional merging

그림 3. 비례적 병합을 통한 중심 왜곡 저감의 예  
 Fig. 3. Example of reduction of center distortion using proportional merging w.r.t. data weight

#### 4. 모의실험 및 고찰

본 논문에서는 그림 4의 데이터 집합들(Butterfly data set[12], Bensaid data set 1[13], Bensaid data set 2[13], Dunn data set[14], Artificial data set 1, Artificial data set 2)에 대하여 모의실험을 수행하였으며, 제안기법으로 얻어진 각 데이터 집합의 클러스터 중심과 FCM 기법으로 얻어진 클러스터 중심의 비교를 통하여 제안기법의 효용성을 보인다.

모의실험에서 사용된 식 (4)의 비례상수  $\alpha$ 의 증가 간격은 선형적으로 0.0001로 설정하였으며, 중심 비교를 위해서 사용되어진 FCM 기법에서의  $m=2, \epsilon=10^{-9}$ 으로 설정하였다.

그림 5의 (a)~(f)는 FCM으로 얻어진 결과 클러스터 중심이며 (g)~(l)은 제안기법의 결과이다. 위의 결과 그림 5(a), (f), (g), (l)에서 FCM 및 제안기법 모두 효과적으로 클러스터의 중심을 추출함을 확인할 수 있다.

그러나 FCM 결과 그림 5(b), (c), (d), (e)와 제안기법으로 얻어진 결과 그림 5(h), (i), (j), (k)로부터 FCM의 경우 클러스터 중심이 심하게 왜곡되어 있는 반면에 제안기법의 경우 중심의 왜곡이 없음을 확인할 수 있다.

표 3은 각 데이터 집합의 클러스터에 대해서 얻어진 중심과 FCM으로 얻어진 중심 및 제안기법으로 얻어진 클러스터 중심을 비교한 것이다. 표 3에서 각 데이터 집합의 클러스터의 중심은 입력 데이터  $x_i$ 에 대해서 다음과 같이 구해진다.

표 3. 기법에 따른 클러스터 중심 결과 비교  
 Table 3. The comparison of the cluster centers w. r. t. methods

데이터 집합	클러스터 중심	FCM	FCM 편차	제안기법	제안기법 편차
Butterfly	Cluster 1	(1, 2)	(0.855, 2)	(0.714, 2)	0.286
	Cluster 2	(5, 2)	(5.145, 2)	(5, 2)	0
Bensaid 1	Cluster 1	(44.8, 48.8)	(37.8, 48.9)	(44.8, 48.8)	0
	Cluster 2	(91, 49)	(61.6, 48.6)	(91, 49)	0
Bensaid 2	Cluster 1	(1.83, 48.5)	(3.6, 48.5)	(1.83, 48.5)	0
	Cluster 2	(54.55, 48.8)	(48.46, 49.14)	(54.55, 48.8)	0
	Cluster 3	(111, 49)	(72.69, 48.55)	(111, 49)	0
Dunn	Cluster 1	(5, 0)	(9.179, 0)	(5, 0)	0
	Cluster 2	(13, 0)	(14.664, 0)	(13, 0)	0
Artificial Data 1	Cluster 1	(-0.1773, -0.0604)	(5.889, -2.387)	(-0.178, -0.06)	0.0008
	Cluster 2	(-2.8271, -4.9706)	(-10.47, -2.711)	(-2.827, -4.97)	0.0006
Artificial Data 2	Cluster 1	(3, 3)	(2.9, 2.9)	(3, 3)	0
	Cluster 2	(3, 9)	(2.9, 8.9)	(3, 9)	0
	Cluster 3	(3, 15)	(2.9, 15)	(3, 15)	0
	Cluster 4	(3, 21)	(2.9, 21)	(3, 21)	0
	Cluster 5	(9, 3)	(8.9, 2.9)	(9, 3)	0
	Cluster 6	(9, 9)	(8.9, 8.9)	(9, 9)	0
	Cluster 7	(9, 15)	(8.9, 15)	(9, 15)	0
	Cluster 8	(9, 21)	(8.9, 21)	(9, 21)	0
	Cluster 9	(15, 3)	(15, 2.9)	(15, 3)	0
	Cluster 10	(15, 9)	(15, 8.9)	(15, 9)	0
	Cluster 11	(15, 15)	(15, 15)	(15, 15)	0
	Cluster 12	(15, 21)	(15, 21)	(15, 21)	0
	Cluster 13	(21, 3)	(21, 2.9)	(21, 3)	0
	Cluster 14	(21, 9)	(21, 8.9)	(21, 9)	0
	Cluster 15	(21, 15)	(21, 15)	(21, 15)	0
	Cluster 16	(21, 21)	(21, 21)	(21, 21)	0

$$center\_x_i = \frac{x_i}{n}, \quad n : \text{데이터의 개수} \quad (6)$$

위의 식(6)을 통해서 얻어진 각 클러스터의 중심과 FCM으로 얻어진 중심 및 제안기법으로 얻어진 중심의 비교 값이 표 3에 나타나 있다.

표 3의 각 기법에 따른 중심의 편차로부터 Butterfly 데이터와 Artificial 데이터 2의 경우 두 기법 모두 큰 편차 없이 각 클러스터의 중심을 적절히 찾음을 확인할 수 있다. 그러나 Bensaid 데이터 1, 2, Dunn 데이터 집합, Artificial 데이터 1의 경우 FCM으로 얻어진 데이터의 중심은 그 편차 값이 큼을 확인할 수 있다. 특히 Bensaid 데이터 1, 2에서 중심의 왜곡이 심함을 수치적으로 확인할 수 있다. 반면에 제안기법으로 얻어진 중심은 편차가 0, 즉, 왜곡이 없음을 확인할 수 있다.

이와 같은 모의실험 비교 결과로부터 본 논문에서 제안한 데이터 가중치에 따른 비례적 근접데이터 병합을 통하여 클러스터 중심의 왜곡을 저감시킬 수 있음을 확인하였다.

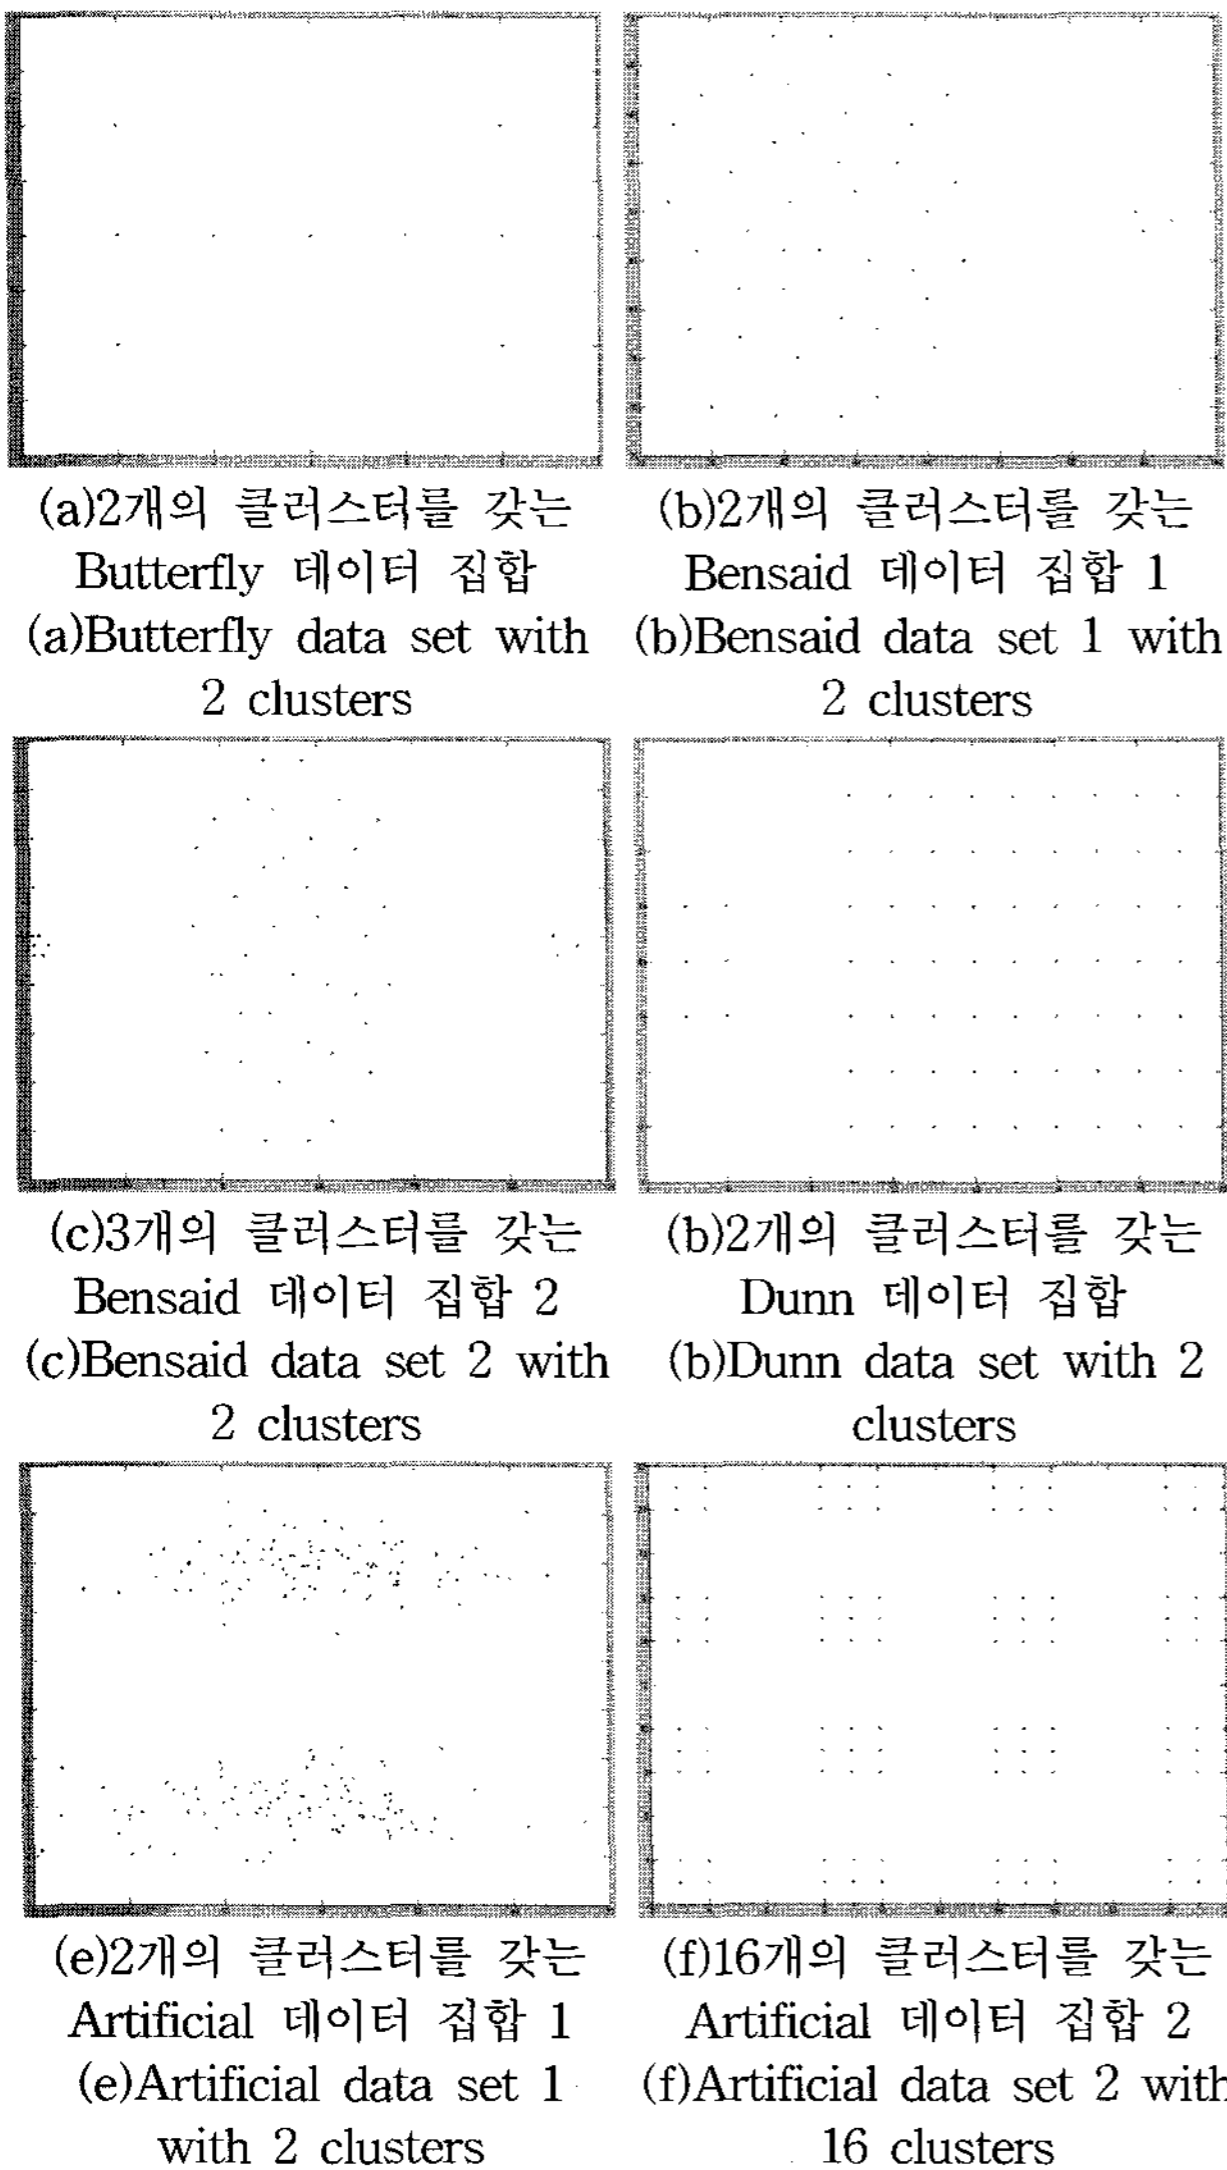


그림 4. 실험에 사용한 데이터 집합  
Fig. 4. Test data sets

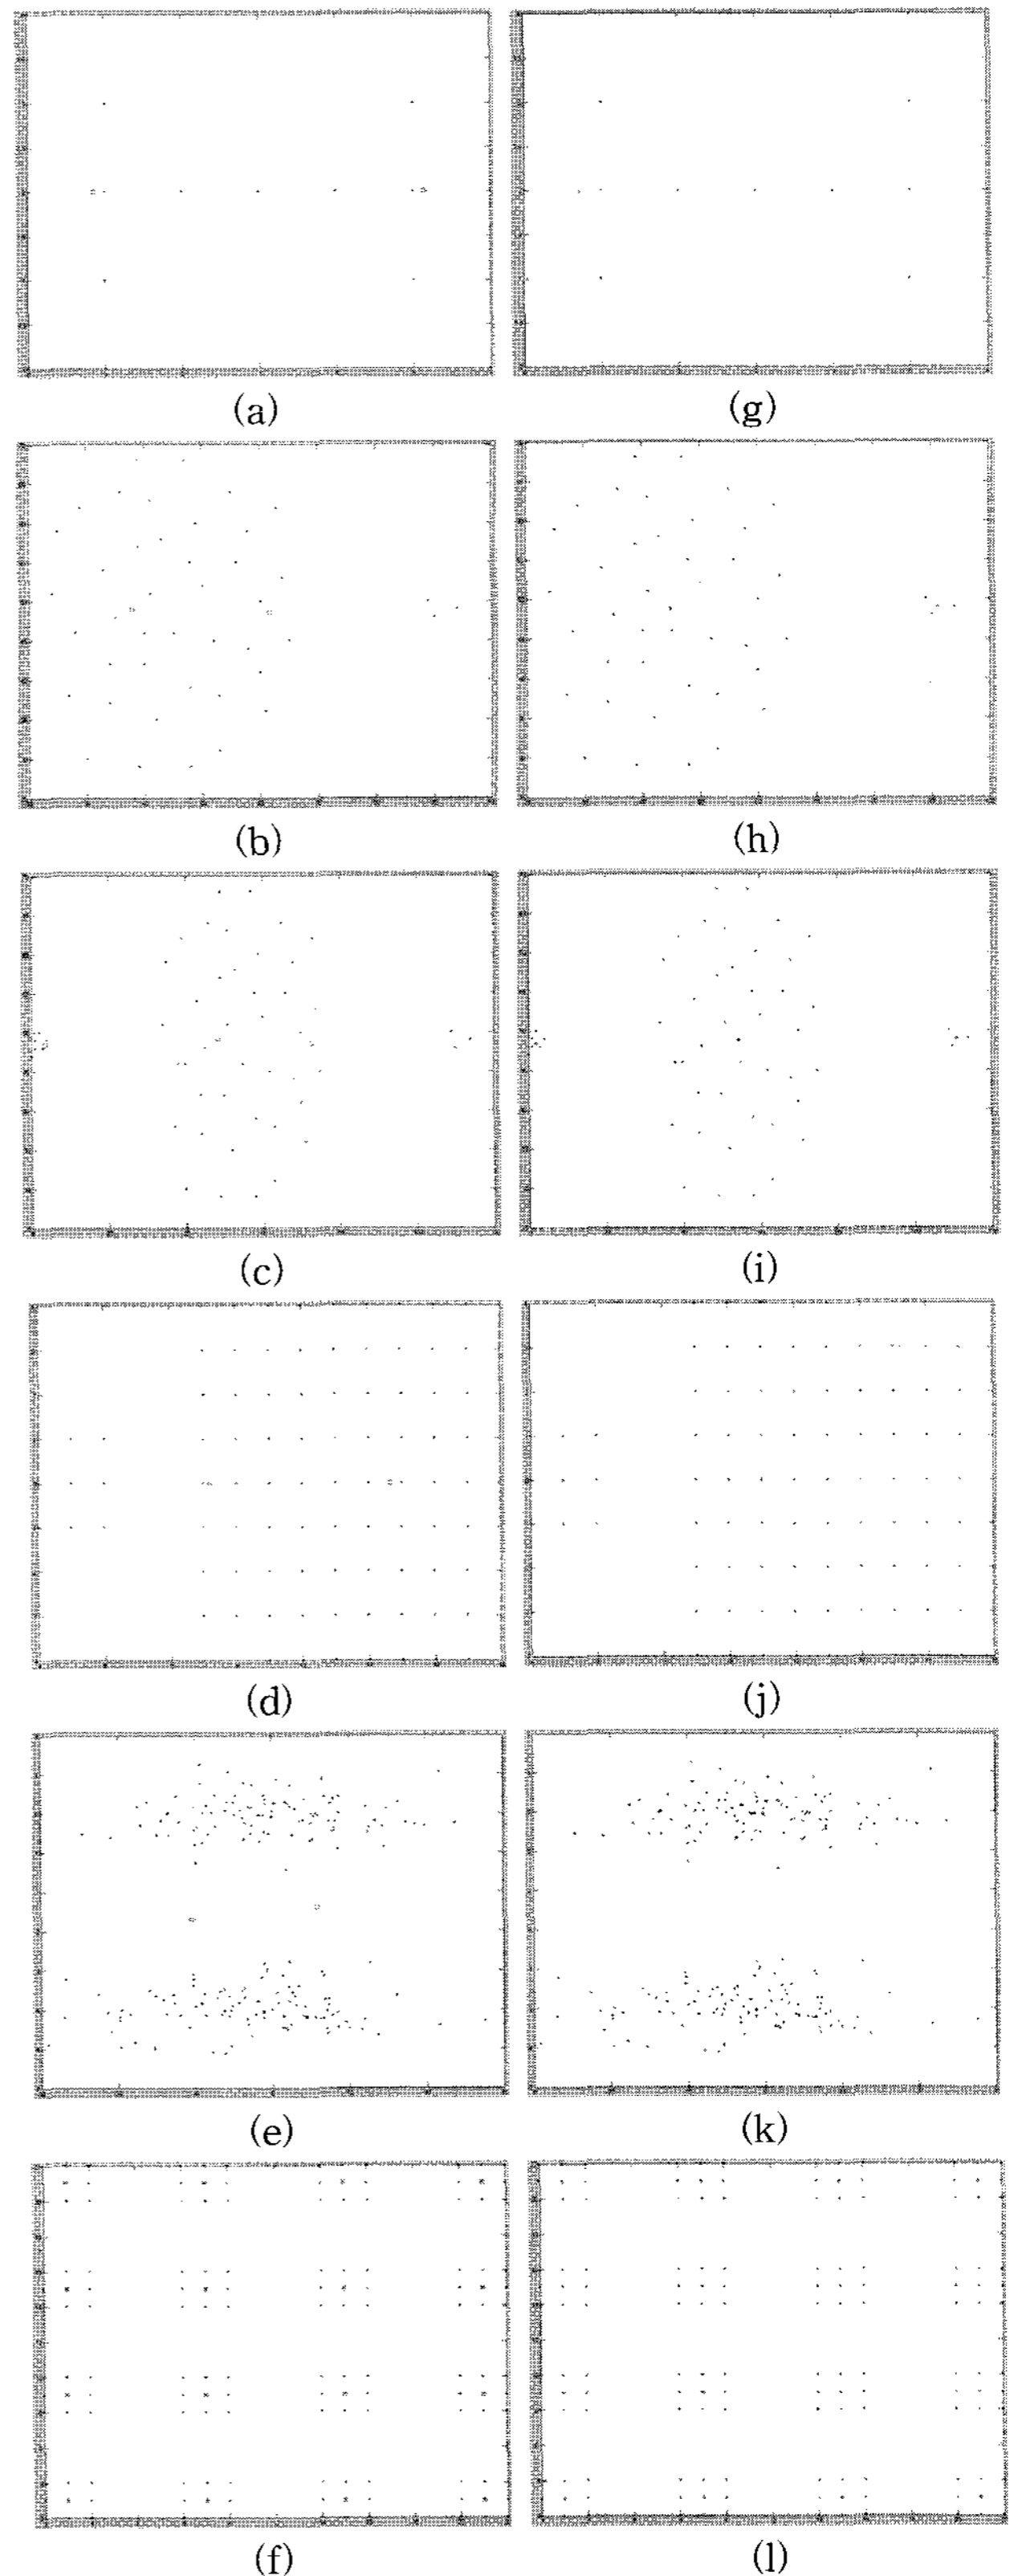


그림 5. 모의실험 결과  
((a)~(f) : FCM으로 얻어진 클러스터 중심,  
(g)~(l) : 제안기법으로 얻어진 클러스터 중심)  
Fig. 5. Experimental results  
((a)~(f) : Cluster centers by FCM,  
(g)~(l) : Cluster centers by the proposed)

## 5. 결 론

본 논문에서는 데이터 가중치와 거리 척도를 이용한 비례적 근접데이터 병합을 통하여 클러스터 중심 왜곡을 저감시킬 수 있는 기법을 제안하였으며, FCM기법으로 얻어진 클러스터 중심과 제안기법으로 얻어진 클러스터 중심 비교 모의실험을 통하여 제안기법의 효용성을 확인하였다.

향후 과제로는 유사도 측정에서 다양한 형태의 데이터 병합을 위한 적응적 비례상수 결정에 대한 연구가 요구되며, 본 논문에서 제안한 기법의 효용성을 검증하기 위한 절차로 다양한 시스템의 중요 변수로의 적용을 통해 효용성을 검증하는 연구가 요구된다.

## 참 고 문 헌

- [1] J. A. Hartigan, M. A. Wong, "A K-means clustering algorithm," *Applied Statistics*, Vol. 28, pp. 100-108, 1979.
- [2] J. C. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*, Pleum, New York, 1981.
- [3] R. R. Yager and D. P. Filev, *Essential of fuzzy modeling and control*, John Wiley & Sons, Inc., New York, 1994.
- [4] 이중우, 손세호, 권순학, "개선된 산 클러스터링 방법," *한국 퍼지 및 지능시스템 학회 논문지*, 제 11권, 1호, pp. 1-8, 2001.
- [5] J. S. Nath, S. K. Shevade, "An efficient clustering scheme using support vector methods," *Pattern Recognition*, Vol. 36, No. 8, pp. 1473-1480, 2006.
- [6] H. Rhee, K. Oh, "A design and analysis of objective function-based unsupervised neural networks for fuzzy clustering," *Neural Processing Letters*, Vol. 4, pp. 82-95, 1996.
- [7] S. Jiang, X. Song, H. Wang, J. J. Han, Q. H. Li, "A clustering-based method for unsupervised intrusion detections," *Pattern Recognition Letters*, Vol. 27, pp. 802-810, 2006.
- [8] T. Hu, Y. Yu, J. Xiong, S. Y. Sung, "Maximum likelihood combination of multiple clusterings," *Pattern Recognition Letters*, Vol. 27, pp. 1457-1464, 2006.
- [9] K. Blekas, I. E. Lagaris, "Newtonian clustering: An approach based on molecular dynamics and global optimization," *Pattern Recognition*, Vol. 40, No. 6, pp. 1734-1744, 2007.
- [10] K. L. Wu, M. S. Yang, "Alternative C-means clustering algorithms," *Pattern Recognition*, Vol. 35, pp. 2267-2278, 2002.
- [11] H. Wang, C. Wang, G. Wu, "Bi-criteria fuzzy C-means analysis," *Fuzzy Sets and Systems*, Vol. 64, pp. 311-319, 1994.
- [12] S. H. Kwon, "Cluster validity index for fuzzy clustering," *Electronics Letters*, Vol. 34, No. 22, pp. 2176-2177, 1998.
- [13] A. M. Bensaid, L. O. Hall, J. C. Bezdek, L. P. Clarke, M. L. Silbiger, J. A. Arrington, R. F. Murtagh, "Validity-guided clustering with applications to image (re)segmentation," *IEEE Trans. Fuzzy Systems*, Vol. 4, No. 2, pp. 112-123, 1996.
- [14] J. C. Dunn, "Indices of partition fuzziness and the detection of clusters in large data sets," *Fuzzy Automata and Decision Processes*, M. M. Gupta, Ed. Elsevier, New York, 1976.

## 저 자 소 개

정혜천(Hye C. Jeong)  
제17권 7호(2007년 12월호) 참조

E-mail : doldory@kotmi.re.kr

서석태(Suk T. Seo)  
제17권 7호(2007년 12월호) 참조

E-mail : kenneth78@yumail.ac.kr

이인근(In K. Lee)  
제17권 7호(2007년 12월호) 참조

E-mail : iklee@ynu.ac.kr

권순학(Soon H. Kwon)  
제17권 7호(2007년 12월호) 참조

E-mail : shkwon@yu.ac.kr