

## 밀도에 무관한 클러스터링 기법의 개선

김성훈<sup>1</sup> · 허경용<sup>2\*</sup>

### Improvement on Density-Independent Clustering Method

Seong-Hoon Kim<sup>1</sup> · Gyeongyong Heo<sup>2\*</sup><sup>1</sup>Department of Software, Kyungpook National University, Sangju 37224, Korea<sup>2</sup>Department of Electronic Engineering, Dong-eui University, Busan 47340, Korea

#### 요 약

클러스터링은 균일한 특성을 가지는 데이터를 클러스터로 묶기 위해 사용되는 비교사 학습 방법 중 하나로 다양한 응용에 사용되고 있으며 FCM(Fuzzy C-Means)이 대표적인 방법 중 하나이다. 하지만 FCM에서 주로 사용되는 유클리드 거리 척도는 밀도가 높은 클러스터가 클러스터링 결과에 많은 영향을 미쳐 밀도가 높은 쪽으로 클러스터의 중심을 위치시키는 문제가 있으며, 이를 해결하기 위한 방법 중 하나가 클러스터 중심 사이의 거리가 가능한 멀어지도록 하는 밀도 무관 클러스터링이다. 하지만 밀도 무관 클러스터링 역시 클러스터 중심 사이의 거리를 정확히 제어하기가 어렵다. 이 논문에서는 클러스터 중심 사이의 거리가 멀어지도록 할뿐만 아니라 클러스터 중심이 밀도가 높은 곳에 위치하도록 하는 향을 추가한 개선된 밀도 무관 클러스터링 방법을 제안한다. 제안하는 방법은 FCM이나 밀도 무관 클러스터링에 비해 실제 클러스터 중심으로 수렴하는 경우가 더 많다는 것을 실험 결과를 통해 확인할 수 있다.

#### ABSTRACT

Clustering is one of the most well-known unsupervised learning methods that clusters data into homogeneous groups. Clustering has been used in various applications and FCM is one of the representative methods. In Fuzzy C-Means(FCM), however, cluster centers tend leaning to high density areas because the Euclidean distance measure forces high density clusters to make more contribution to clustering result. Previously proposed was density-independent clustering method, where cluster centers were made not to be close each other and relived the center deviation problem. Density-independent clustering method has a limitation that it is difficult to specify the position of the cluster centers. In this paper, an enhanced density-independent clustering method with an additional term that makes cluster centers to be placed around dense region is proposed. The proposed method converges more to real centers compared to FCM and density-independent clustering, which can be verified with experimental results.

**키워드** : 클러스터 밀도, 밀도 무관 클러스터링, 유클리드 거리, 퍼지 클러스터링

**Key word** : Cluster density, Density-independent clustering, Euclidean distance, Fuzzy Clustering

Received 17 November 2016, Revised 17 November 2016, Accepted 27 April 2017

\* Corresponding Author Gyeongyong Heo (E-mail:hgycap@deu.ac.kr, Tel:+82-51-890-1675)

Department of Electronic Engineering, Dong-eui University, Busan 47340, Korea

Open Access <https://doi.org/10.6109/jkiice.2017.21.5.967>

print ISSN: 2234-4772 online ISSN: 2288-4165

©This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.  
Copyright © The Korea Institute of Information and Communication Engineering.

## I. 서 론

클러스터링은 주어진 데이터의 유사성을 기준으로 클러스터를 형성하는 비교사 학습 방법 중 하나이다. 소속도 함수에 의한 부분 소속도를 나타내는 퍼지 집합이 Zadeh[1]에 의해 소개된 이후, 소속도를 사용한 퍼지 클러스터링은 대표적인 클러스터링 기법 중 하나로 자리 잡았다. Bezdek[2]에 의해 일반화된 Fuzzy C-Means (FCM)은 퍼지 클러스터링 중 흔히 사용되는 방법 중 하나이다. FCM은 간단하면서도 효과적인 클러스터링 방법이지만 몇 가지 문제점이 있으며, 밀도가 다른 클러스터가 존재하는 경우 밀도가 높은 클러스터 쪽으로 클러스터 중심이 쏠리는 현상이 그 중 하나이다. 실제 데이터의 경우 균일한 밀도를 가지는 클러스터로 구성된 경우가 많지 않으므로 밀도에 따른 클러스터 형성의 왜곡을 방지하는 것은 클러스터링에서 해결해야 할 중요한 문제 중 하나이다. 클러스터의 중심이 잘못 정해지는 왜곡이 발생하면 테스트 데이터가 잘못된 클러스터에 소속되는 문제가 발생하며, 특히 이는 경계면 근처에 놓이는 데이터에 영향을 미쳐 적은 수의 오류로도 전체 성능을 저하시키는 원인이 될 수 있다.

밀도의 영향을 줄이기 위해 클러스터 중심 사이의 거리가 가능한 멀리 떨어져 있도록 하는 밀도 무관 클러스터링(Density-Independent FCM, DI-FCM)이 제안되었으며 FCM에 비해 우수한 성능을 보임이 증명되었다 [3]. 하지만 DI-FCM에서 클러스터 중심 사이의 거리를 결정하는 상수값에 따라 클러스터 중심이 실제 클러스터 중심과는 다른 위치에 오는 경우도 발생할 수 있다.

이 논문에서는 DI-FCM을 개선하여 클러스터 밀도에 영향을 적게 받으면서도 클러스터 중심이 실제 클러스터 중심에 수렴할 확률을 높일 수 있는 개선된 밀도 무관 클러스터링(Enhanced DI-FCM, EDI-FCM)을 제안한다. 제안하는 방법에서는 클러스터의 중심이 밀도가 가장 높은 지역에 위치하도록 클러스터 중심에서 데이터 포인트 사이의 거리 합이 작아지도록 하는 항을 추가하였다.

이 논문의 구성은 다음과 같다. 먼저 2장에서는 FCM에 대해 설명한다. 3장에서는 DI-FCM과 제안하는 EDI-FCM에 대해 살펴보고, 4장 실험 결과를 통해 제안하는 방법의 유효성을 보인다. 결론 및 향후 연구 방향은 5장에서 언급한다.

## II. FCM

클러스터링은 역사가 오랜 만큼 다양한 방법이 제안되었고, 퍼지 클러스터링의 가장 기본적인면서도 대표적인 방법이 Bezdek이 제안한 FCM이다[4,5]. FCM 이전의 이진 클러스터링에서 하나의 데이터 포인트는 하나의 클러스터에만 소속될 수 있다. 이에 비해 FCM은 소속도를 사용하여 하나의 데이터 포인트가 여러 개의 클러스터에 서로 다른 정도로 소속될 수 있도록 하는 점에서 차이가 있다.

$N$ 개의  $d$ 차원 데이터  $X = \{x_i | 1 \leq i \leq N, x_i \in R^d\}$ 가 주어졌을 때, 이를  $C$ 개 그룹으로 클러스터링하기 위해 FCM에서는 식 (1)의 목적 함수를 최소로 한다.

$$J_{FCM} = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|v_j - x_i\|_A^2 \quad (1)$$

$$= \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m d_{ij}^2$$

이 때  $u_{ij}$ 는  $i$ 번째 데이터 포인트  $x_i$ 가  $j$ 번째 클러스터에 소속되는 정도를 나타내는 소속도 값을,  $v_j$ 는  $j$ 번째 클러스터의 중심을,  $m$ 은 퍼지화 정도를 나타내는 상수로 일반적으로 2로 설정된다( $1 < m < \infty$ ).  $d_{ij}$ 는  $i$ 번째 데이터 포인트와  $j$ 번째 클러스터 중심 사이의 거리를 나타내며 이 논문에서는 유클리드 거리 척도를 사용하였다.

FCM에서 하나의 데이터 포인트  $x_i$ 는  $C$ 개의 클러스터에 소속될 수 있지만, 각 클러스터에 소속되는 정도는 서로 달라지며,  $C$ 개 클러스터에 소속되는 정도는 전체 소속도의 합이 1이 되어야 한다는 제약조건을 만족시켜야 한다.

$$\sum_{j=1}^C u_{ij} = 1 \quad (2)$$

식 (2)의 제약조건을 만족시키면서 식 (1)의 목적 함수를 최소화하는 소속도와 클러스터 중심은 라그랑주 승수법을 이용하여 얻은 갱신식을 사용하여 반복최적화(iterative optimization) 방법을 통해 구할 수 있다.

$$v_j = \frac{\sum_{i=1}^N u_{ij}^m x_i}{\sum_{i=1}^N u_{ij}^m} \quad (3)$$

$$u_{ij} = \frac{1}{\|v_j - x_i\|^2} \bigg/ \sum_{k=1}^C \frac{1}{\|v_k - x_i\|^2} \quad (4)$$

### III. 밀도 무관 클러스터링

밀도가 다른 클러스터가 존재하는 경우 클러스터의 중심이 쏠리는 현상은 클러스터 중심과 데이터 포인트 사이의 거리가 유클리드 거리 또는 그 변형에 기반하고 있기 때문이다[6,7]. 클러스터 중심의 쏠림 현상을 방지하기 위한 방법 중 하나가 클러스터의 중심이 가능한 서로 떨어져 있도록 하는 항을 FCM의 목적함수에 추가한 밀도 무관 클러스터링(Density Independent FCM: DI-FCM)이다[3]. DI-FCM의 목적함수는 식 (5)와 같다.

$$J_{DI}(V, U, X) = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|v_j - x_i\|^2 - \alpha \sum_{a=1}^C \sum_{b=1}^C \|v_a - v_b\|^2 \quad (5)$$

FCM에 비해 추가된 항은 중심 사이의 거리 합으로 거리가 클수록 목적함수의 값은 작아지므로 클러스터의 중심이 가능한 멀리 떨어지도록 하는 역할을 한다. 이 때  $\alpha (> 0)$ 는 중심이 떨어져 있는 정도를 목적함수에 반영하는 비율을 나타내는 상수이다.

DI-FCM이 FCM에 비해 실제 클러스터 중심에 수렴할 확률이 더 높지만 한 가지 문제점이 있다. 즉,  $\alpha$  값이 커지면 클러스터 중심 사이의 거리는 멀어지지만 실제 클러스터의 중심에 수렴할 가능성도 줄어들 수 있다는 점이다. 따라서 이 논문에서는 클러스터 중심이 서로 멀리 떨어져 있도록 하면서도 클러스터 중심이 실제 클러스터의 중심에 수렴할 가능성을 높일 수 있도록 새로운 항을 추가한 개선된 밀도 무관 클러스터링(Enhanced Density Independent FCM: EDI-FCM)을 제안한다.

EDI-FCM에서는 실제 클러스터 중심은 밀도가 가장 높은 곳에 위치한다는 사실에서 출발하며, 밀도가 높은 곳에 클러스터 중심이 위치할 경우 클러스터 중심과 데이터 포인트 사이의 거리 합이 작아진다는 점을 사용하였다. EDI-FCM의 목적함수는 식 (6)과 같다. 식 (6)에서  $\beta$ 가 영인 경우에는 식 (5)의 DI-FCM 목적함수와 동일하다. 즉, DI-FCM은 EDI-FCM의 특별한 경우로 생각할 수 있다.

$$J_{EDI} = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^2 \|v_j - x_i\|^2 - \alpha \sum_{a=1}^C \sum_{b=1}^C \|v_a - v_b\|^2 + \beta \sum_{i=1}^N \sum_{j=1}^C \|v_j - x_i\|^2 = \sum_{i=1}^N \sum_{j=1}^C (u_{ij}^2 + \beta) \|v_j - x_i\|^2 - \alpha \sum_{a=1}^C \sum_{b=1}^C \|v_a - v_b\|^2 \quad (6)$$

이 때  $\beta (> 0)$ 는 클러스터 중심을 밀도가 높은 곳에 위치하도록 하는 정도를 목적함수에 반영하는 비율을 나타내며, 3번째 항이 클러스터 중심과 데이터 포인트 사이의 거리 합이 최소화되도록 하는 항이다.

먼저 라그랑지 방정식을  $u_{ij}$ 로 편미분하면 식 (7)을 얻을 수 있다.

$$\frac{\partial L}{\partial u_{ij}} = 2u_{ij} \|v_j - x_i\|^2 - \lambda_i = 0 \quad (7)$$

식 (7)을  $u_{ij}$ 에 대해 정리하면 식 (8)을 얻을 수 있다.

$$u_{ij} = \frac{\lambda_i}{2 \|v_j - x_i\|^2} \quad (8)$$

EDI-FCM 역시 FCM의 제약조건인 식 (2)를 만족시켜야 하므로 식 (8)을 식 (2)에 대입하여 정리하면 식 (9)를 얻을 수 있다.

$$\frac{\lambda_i}{2} = \frac{1}{\sum_{j=1}^C \frac{1}{\|v_j - x_i\|^2}} \quad (9)$$

식 (9)를 식 (8)에 대입하여 정리하면 소속도에 대한 갱신식인 식 (10)를 얻을 수 있다.

$$u_{ij} = \frac{1}{\|v_j - x_i\|^2} \sum_{k=1}^C \frac{1}{\|v_k - x_i\|^2} \quad (10)$$

식 (10)은 FCM의 소속도 갱신식인 식 (4)와 동일하다. 즉, EDI-FCM에서 소속도는 FCM에서와 마찬가지로 클러스터 중심과 데이터 포인트 사이의 유클리드 거리를 바탕으로 결정된다.

클러스터 중심의 갱신식을 구하기 위해 라그랑지 방정식을  $v_j$ 에 대해 편미분한다.

$$\frac{\partial L}{\partial v_j} = 2 \sum_{i=1}^N (u_{ij}^2 + \beta) \|v_j - x_i\| - 2\alpha \sum_{\substack{b=1 \\ b \neq j}}^C \|v_j - v_b\| = 0 \quad (11)$$

식 (11)을  $v_j$ 에 대해 정리하면 클러스터 중심의 갱신식인 식 (12)를 얻을 수 있다.

$$v_j = \frac{\sum_{i=1}^N (u_{ij}^2 + \beta)x_i - \alpha \sum_{\substack{b=1 \\ b \neq j}}^C v_b}{\sum_{i=1}^N (u_{ij}^2 + \beta) - \alpha \sum_{\substack{b=1 \\ b \neq j}}^C 1} = \frac{\sum_{i=1}^N (u_{ij}^2 + \beta)x_i - \alpha \sum_{\substack{b=1 \\ b \neq j}}^C v_b}{\sum_{i=1}^N (u_{ij}^2 + \beta) - \alpha(C-1)} \quad (12)$$

식 (12)를 FCM의 클러스터 중심 갱신식인 식 (3)과 비교해 보면 분모와 분자에 각각 클러스터 중심 사이의 거리를 크게 하면서 밀도가 높은 곳에 클러스터 중심이 위치하도록 하는 항이 반영되어 있음을 알 수 있다. 식 (10)과 식 (12)를 사용하여 EDI-FCM 알고리즘은 그림 1과 같이 나타낼 수 있다.

그림 1에서 수렴 조건은 중심의 최대 이동 거리가  $\epsilon_1$

(=  $10^{-3}$ )보다 작으며 소속도의 최대 변화량이  $\epsilon_2$ (=  $10^{-4}$ )보다 작은 것으로 하였다.

<p>U : data point membership V : cluster center</p>
<p>1: initialize V 2: initialize t = 0 3: do 4: t ← t + 1 5: calculate U using Eq. (10) 6: calculate V using Eq. (12) 7: while U and V do not satisfy convergence qualification 8: return U and V</p>

Fig. 1 EDI-FCM algorithm

FCM, DI-FCM, EDI-FCM의 소속도 갱신식은 모두 동일하지만 클러스터 중심의 갱신식에서만 차이가 있다. 표 1은 각 클러스터링 방법에서 소속도 갱신식을 비교한 것으로 DI-FCM에서 클러스터 중심 거리에 대한 제약이 추가되고 EDI-FCM에서 클러스터 중심 위치에 대한 제약이 추가됨으로써 갱신식이 변경되고 있음을 알 수 있다.

Table. 1 Update equations for cluster centers

Clustering method	Update equation
FCM	$v_j = \frac{\sum_{i=1}^N u_{ij}^m x_i}{\sum_{i=1}^N u_{ij}^m}$
DI-FCM	$v_j = \frac{\sum_{i=1}^N u_{ij}^2 x_i - \alpha \sum_{b=1}^C v_b}{\sum_{i=1}^N u_{ij}^2 - \alpha C}$
EDI-FCM	$v_j = \frac{\sum_{i=1}^N (u_{ij}^2 + \beta)x_i - \alpha \sum_{\substack{b=1 \\ b \neq j}}^C v_b}{\sum_{i=1}^N (u_{ij}^2 + \beta) - \alpha(C-1)}$

#### IV. 실험 결과

기존에 다양한 FCM의 변형이 존재하지만 밀도 차이에 의한 클러스터링의 오류를 해결하고자 한 방법은 DI-FCM이 유일하므로 실험에서는 FCM과 DI-FCM을 제안하는 EDI-FCM과 비교하였다. 그림 2는 FCM, DI-FCM, EDI-FCM을 사용한 전형적인 결과를 보여준다. 샘플 데이터는 3개의 클러스터로 구성되어 있으며 오른쪽 위의 밀도가 높은 클러스터는 500개의 데이터 포인트를, 나머지 2개의 클러스터는 100개의 데이터 포인트를 가진다.

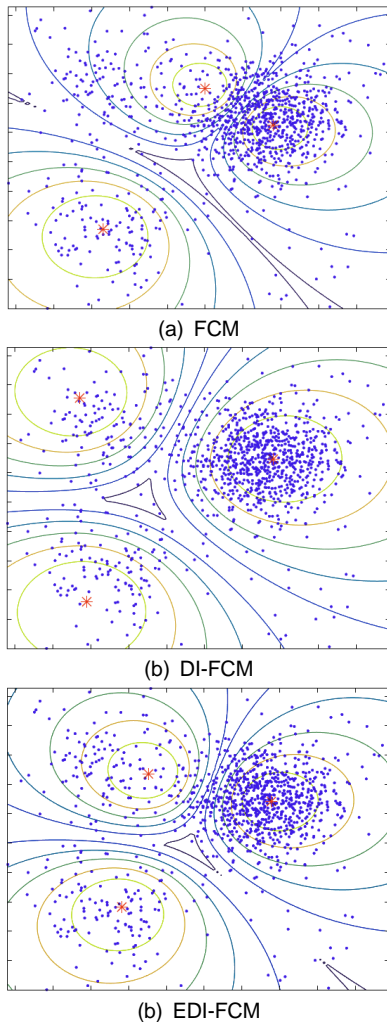


Fig. 2 Clustering results with a dataset having 3 clusters

그림 2에서 볼 수 있듯이 FCM의 경우 클러스터의 중심이 밀도가 높은 클러스터 쪽으로 치우치지만, DI-FCM의 경우 클러스터 중심이 멀어지면서 실제 클러스터 중심에 가까워지고 있다. 하지만 클러스터의 중심이 멀리 위치하도록 강제하기 때문에 실제 클러스터의 중심에서 벗어나 FCM의 경우와는 반대 방향에 클러스터 중심이 정해지고 있다. 반면 EDI-FCM의 경우에는 FCM과 DI-FCM의 중간 지점에서 클러스터 중심이 정해지는 것을 볼 수 있다.

클러스터링은 비교사 학습 방법으로 데이터의 그라운드 트루스(ground truth)를 알 수 없으므로 정량적인 비교를 위해 이 논문에서는 식 (13)의 오류 함수를 정의하여 사용하였다. 오류는 샘플 데이터 생성에 사용된 실제 클러스터 중심( $V_R = \{v_{R,j} | 1 \leq j \leq C\}$ )과 클러스터링 결과로 얻어진 클러스터 중심( $V_{FC} = \{v_{FC,j} | 1 \leq j \leq C\}$ ) 사이의 거리 합을 사용하였다.

$$Error = \sum_{j=1}^C \|v_{R,j} - v_{FC,j}\|^2 \quad (13)$$

표 2는 3가지 클러스터링 방법을 3개의 클러스터를 가지는 샘플 데이터에 적용한 결과를 요약한 것이다. 평균 오류는 임의로 생성된 데이터에 대한 클러스터링을 500회 시행한 후 오류를 평균한 값이다.

Table. 2 Clustering results with a dataset having 3 clusters

Method	Average Error
FCM	3.3097
DI-FCM	2.7790
EDI-FCM	2.5736

실험에서 사용한  $\alpha$ 와  $\beta$ 값은 8과 0.0015로, DI-FCM의 오류를 최소화하는  $\alpha$  값을 실험적으로 결정 한 후,  $\alpha$  값을 고정하고 EDI-FCM에서 오류를 최소화하는  $\beta$  값을 실험적으로 결정하는 순서를 따랐다.

그림 3은 4개의 클러스터로 구성되는 샘플 데이터에 각 클러스터링 방법을 적용한 결과의 예이다. 4개의 클러스터 중 오른쪽 위의 클러스터는 400개의 데이터 포인트를 가지며 나머지 3개 클러스터는 100개의 데이터 포인트를 가진다.

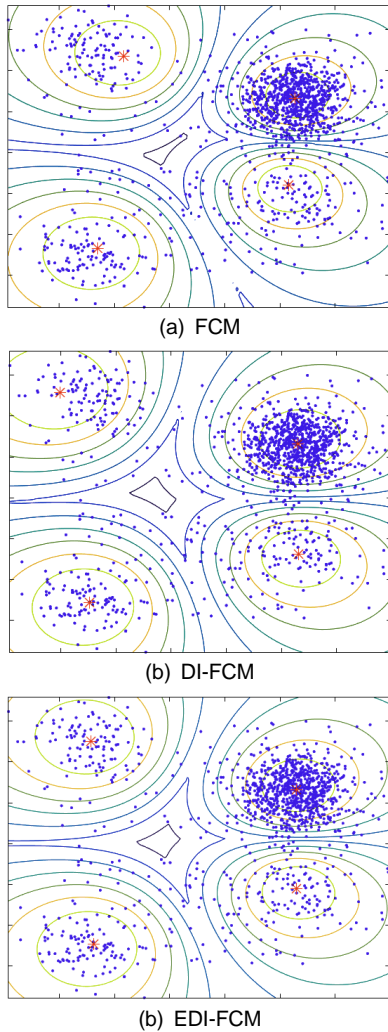


Fig. 3 Clustering results with a dataset having 4 clusters

4개의 클러스터를 가지는 샘플 데이터에 대한 클러스터링 결과 역시 3개의 클러스터를 가지는 샘플 데이터에서와 비슷한 결과를 확인할 수 있다.

Table. 3 Clustering results with a dataset having 4 clusters

Method	Average Error
FCM	1.4003
DI-FCM	1.2935
EDI-FCM	1.0531

표 3은 3가지 클러스터링 방법을 4개의 클러스터를 가지는 샘플 데이터에 적용한 결과를 요약한 것으로, 이전 실험과 마찬가지로 500회 실행 후 오류값의 평균을 나타내었다.

실험 결과에서 알 수 있듯이 제안한 방법은 기존 방법에 비해 실제 클러스터의 중심을 찾아낼 확률이 더 높다. 실제 클러스터의 중심을 찾아내는 것은 특히 클러스터 경계면 근처에 데이터를 오류 없이 클러스터에 소속시킬 가능성을 높이는 일이다.

클러스터 경계면 근처에 놓이는 데이터가 전체 데이터에서 적은 부분을 차지한다고 하더라도 전체 과정으로 흔히 사용되는 클러스터링의 결과가 전체적인 성능에 미치는 영향이 작지 않으므로 중요하다고 하겠다.

## V. 결 론

이 논문에서는 클러스터의 밀도 차이로 인해 클러스터 중심이 실제 중심에서 벗어나는 현상을 줄이기 위한 클러스터링 방법을 제안하였다. 밀도 무관 클러스터링(DI-FCM)이 클러스터 밀도에 의한 왜곡을 다루고는 있지만, 클러스터 사이의 거리만을 반영하여 실제 중심에서 멀어질 수 있는 가능성을 가지고 있었다. 따라서 제안하는 방법에서는 클러스터 중심과 데이터 포인트 사이의 거리를 추가하여 밀도가 높은 곳에 클러스터 중심이 위치할 수 있도록 하였으며, 실험 결과를 통해 이전 방법에 비해 우수한 성능을 보이는 것을 확인할 수 있었다.

이 논문에서는 거리 척도로 유클리드 거리를 사용하였다. 하지만 유클리드 거리는 밀도에 의한 클러스터 왜곡의 주요 원인 중 하나이므로, Gustafson과 Kessel에 의해 제안된 마할라노비스 거리[8,9]나 Gath와 Geva [10]에 의해 제안된 가우스 분포 함수와 밀도 무관 항을 함께 사용하는 방법을 통해 클러스터 왜곡을 더 줄일 수 있을 가능성이 있으며 이에 대한 연구가 진행 중에 있다.

REFERENCES

[1] L.A. Zadeh, "Fuzzy sets," *Information and Control*, vol. 8, no. 3, pp. 338-353, Jun. 1965.

[2] J. Bezdek, *Pattern Recognition with fuzzy Objective Function Algorithms*, New York, Springer, 1981.

[3] B. H. You, W. W. Kim and G. Heo, "An Improved Clustering Method with Cluster Density Independence," *Journal of The Korea Society of Computer and Information*, vol. 20, no. 12, pp. 15-20, Dec. 2015.

[4] S. Miyamoto, *Fuzzy Clustering - Basic Ideas and Overview, Handbook of Computational Intelligence*, Springer, pp. 293-248, 2015.

[5] J. Nayak, "Fuzzy C-means(FCM) Clustering Algorithm: A Decade Review from 2000 to 2014," *Systems and Technologies*, vol. 32, no. 2, pp. 133-179, Dec. 2014.

[6] Z. Zainuddin, "An effective Fuzzy C-Means algorithm based on symmetry similarity approach," *Applied Soft Computing*, vol. 35, no. 10, pp. 433-448, Oct. 2015.

[7] B. Abu-Jamous, *Fuzzy Clustering, Integrative Cluster Analysis in Bioinformatics*, Wiley, 2015.

[8] R. Babuska, P. J. van der Veen and U. Kaymak, "Improved Covariance Estimation for Gustafson-Kessel Clustering," in *Proceeding of the 2002 IEEE International Conference on Fuzzy Systems*, pp. 1081-1085, 2002.

[9] G. Heo, Y. Namkoong and S. H. Kim, "An Extension of Possibilistic Fuzzy C-means using Regularization," *Journal of The Korea Society of Computer and Information*, vol. 15, no. 1, pp. 43-50, Jan. 2010.

[10] I. Gath and A. B. Geva, "Unsupervised Optimal Fuzzy Clustering," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 773-791, Jul. 1989.



김성훈(Seong-Hoon Kim)

연세대학교 전자공학과 공학석사, 공학박사(1990, 1996)  
 유원대학교 컴퓨터공학과 부교수(1996~2006)  
 경북대학교 소프트웨어학과 교수(2006~현재)  
 ※관심분야 : 인공지능, 패턴인식, 서명검증



허경용(Gyeongyong Heo)

연세대학교 전자공학과 공학석사 (1996)  
 University of Florida 컴퓨터공학과 공학박사 (2009)  
 동의대학교 전자공학과 교수 (2012~현재)  
 ※관심분야 : 인공지능, 패턴인식, 로봇공학