

Noisy Image Segmentation via Swarm-based Possibilistic C-means

Jeongmin Yu*

Abstract

In this paper, we propose a swarm-based possibilistic c-means(PCM) algorithm in order to overcome the problems of PCM, which are sensitiveness of clustering performance due to initial cluster center's values and producing coincident or close clusters. To settle the former problem of PCM, we adopt a swam-based global optimization method which can be provided the optimal initial cluster centers. Furthermore, to settle the latter problem of PCM, we design an adaptive thresholding model based on the optimized cluster centers that yields preliminary clustered and un-clustered dataset. The preliminary clustered dataset plays a role of preventing coincident or close clusters and the un-clustered dataset is lastly clustered by PCM.

From the experiment, the proposed method obtains a better performance than other PCM algorithms on a simulated magnetic resonance(MR) brain image dataset which is corrupted by various noises and bias-fields.

▶ Keywords: Noisy Image Segmentation, Possibilistic c-means, Swarm-based Clustering, MR brain Image, Noise level.

I. Introduction

의료 영상 분석에서 영상 분할(Image segmentation)은 핵심 전처리 과정으로 중요한 비중을 지니는 연구 분야 중 하나이다[5, 6, 15]. 하지만, 의료 영상은 종종 의료 영상 장비들에 의해 노이즈 데이터가 첨가되어, 영상 분석을 위한 영상 분할 작업에 심각한 어려움을 가져다준다.

최근 노이즈가 첨가된 의료 영상 분할을 위해 많은 방법론들이 제시되었다. 노이즈 영상 분할 기법들 중, 데이터 사전 학습이 필요 없는 비감독(Unsupervised) 방식의 화소 군집화 알고리즘을 활용한 방법이 많은 관심을 받고 있다. 대표적으로, 확률적 c-평균(possibilistic c-means: PCM) 알고리즘은 퍼지 c-평균(fuzzy c-means: FCM)[2] 알고리즘의 노이즈에 대한 성능 민감도 문제를 극복하기 위해 Krishnapuram과 Keller[1]가 고안한 군집화(clustering) 알고리즘이다. 특히, PCM은 FCM의 제약 사항을 완화 시킴으로써 노이즈 데이터에 대한 군집화 문제를 해결하였다. 하지만 PCM 알고리즘은 다음이 두 가지 취약점이 있다. 첫째, 최종

군집화 성능이 초기 군집(cluster) 중심 값에 상당히 영향을 많이 받고 있으며, 둘째, 많은 노이즈 데이터가 존재할 시 종종 군집 일치 및 근접화(Coincident or close clusters) 문제가 발생한다[3]. 이러한 PCM 알고리즘의 문제점을 해결하기 위해, [4]에서는 주어진 각 데이터와 군집 간의 확률(possibility)과 소속(membership) 값을 동시에 사용함으로써 효율적이고 노이즈 데이터에 강건한 군집화 알고리즘을, 즉 확률적 퍼지 c-평균(possibilistic fuzzy c-means: PFCM)[4] 알고리즘을 제안하였다. 하지만, PFCM 알고리즘 성능이 여전히 군집 중심 값의 초기화에 민감하였고, 데이터에 노이즈가 많이 존재할 시 종종 군집들 간 일치 혹은 근접한 군집들을 군집화 하는 문제점을 가지고 있다.

한편, PCM 알고리즘에 최적의 군집 중심 값을 부여하기 위해 전역 최적화에 효율적인 군락기반(Swarm-based) 최적화 알고리즘들[7, 8, 9]과 PCM 알고리즘을 융합하는 접근방법[10, 16]고안되었다. 이 알고리즘들은 PCM에게 적절한 군집

*First Author: Jeongmin Yu, Corresponding Author: Jeongmin Yu

*Jeongmin Yu (jmyu@nuch.ac.kr), Dept. of Culture Heritage Industry, Korea National University of Culture Heritage

Received: 2018. 11. 12, Revised: 2018. 12. 05, Accepted: 2018. 12. 10.

This work was supported by 2018 Support Project for Academic Research on Traditional Culture in Korea National University of Cultural Heritage.

중심 값을 제공하였지만, 높은 노이즈 레벨 때문에 발생하는 군집 일치 혹은 근접화 문제를 [3] 여전히 극복하지 못하였다.

PCM의 두 가지 문제점들을 동시에 해결하기 위해, 본 논문에서는 군락기반 군집화와 PCM의 융합된 형태의 알고리즘을 제안하였다. 구체적으로는, 군락기반 군집화 알고리즘을 기반으로 PCM에 적절한 군집 중심 값을 자동적으로 초기화하고, 사전에 군집화된 결과 데이터를 제공함으로써 PCM의 군집들 간의 일치 및 근접화 문제를 해결하였다. 제안한 알고리즘은 노이즈가 존재하는 시물레이션 된 자기 공명 (Magnetic Resonance: MR) 뇌 영상에서 기존 PCM 알고리즘들과 비교하여 우수한 성능을 보였다. 제안한 기법은 의료 영상분할 뿐 아니라 다양한 응용(컴퓨터비전, 디지털 문화유산)에서 노이즈 데이터를 처리할 때 유용하게 사용될 것으로 보인다.

본 논문은 다음과 같이 구성되어 있다. II에서는 PCM 알고리즘과 군락기반 군집화 알고리즘의 간단한 개론을 소개한다. III에서는 제안한 군락기반 PCM 알고리즘을 소개하고, IV에서 실험을 통해 제안한 기법과 기존 PCM 알고리즘들의 노이즈가 존재하는 뇌 영상 분할 성능을 분석한다. 마지막으로, 본 논문의 결론과 앞으로의 연구 방향들에 대해서 V에서 다룬다.

II. Backgrounds

1. Possibilistic c-means

모든 PCM 알고리즘은 비지도 학습(Unsupervised Learning) 중 하나이며 주어진 N 개의 데이터를, $X = \{x_1, x_2, \dots, x_N\}$, K 개의 군집으로 군집화 하는 알고리즘이다. N 개의 데이터를 K 개의 군집으로 군집할 때, 거리 기반의 비용 함수(Cost function)를, $J(U, C)$, 최소화하는 방식으로 수행되고 특성이 비슷한 그룹 내의 유사도는 증가하고 특성이 다른 그룹간의 유사도는 감소하는 방향으로 군집화 된다. 비용함수 $J(U, C)$ 는 수식 (1)과 같이 정의된다.

$$J(U, C) = \sum_{i=1}^K \sum_{j=1}^N \mu_{ij}^\lambda d_{ij}^2 + \sum_{i=1}^K \eta_i \sum_{j=1}^N (1 - \mu_{ij})^\lambda \quad (1)$$

$$\text{subject to } 0 \leq \mu_{ij} \leq 1, \sum_{j=1}^N \mu_{ij}$$

(1) 수식에서 $U = [\mu_{ij}]_{K \times N}$ 은 퍼지 구분(fuzzy partition) 매트릭스, $C = \{c_1, c_2, \dots, c_K\}$ 는 군집 중심 값, 거리 값인 $d_{ij} = c_i - x_j$, λ 는 퍼지화 정도를 설정하는 가중치 파라미터, μ_{ij} 는 x_j (즉, 화소 j 의 명도 값)와 c_i (즉, 군집 i 의 명도 값) 간의 소속도 정도를 나타내고, 이것에 대한 정의는 수식 (2)와 같다.

$$\mu_{ij} = \left(1 + \left(\frac{d_{ij}^2}{\eta_i} \right)^{1/(\lambda-1)} \right)^{-1} \quad (2)$$

$$c_i = \frac{\sum_{j=1}^N \mu_{ij}^\lambda x_j}{\sum_{j=1}^N \mu_{ij}^\lambda} \quad (3)$$

수식 (2)에서 η_i 는 scale 파라미터이며, 이것의 정의는 아래의 수식 (4)과 같다.

$$\eta_i = G \frac{\sum_{j=1}^N \mu_{ij}^\lambda d_{ij}^2}{\sum_{j=1}^N \mu_{ij}^\lambda} \quad (4)$$

수식 (4)에서 일반적으로 $G = 1$ 상수 값을 설정한다.

PCM 알고리즘은 아래와 같이 요약할 수 있다.

- (i) 소속 매트릭스 U 를 초기화한다.
- (ii) 수식 (3)을 이용하여 군집 중심 값을 계산한다.
- (iii) 수식 (2)를 이용하여 U 를 업데이트 한다.
- (iv) $\|J^{(t)} - J^{(t-1)}\| < \epsilon$ 조건을 만족할 때까지 (2)번과 (3)과정을 반복한다. ϵ 는 아주 작은 값이다.

노이즈가 존재하는 영상 데이터셋 에 대해서, PCM 알고리즘의 성능은 군집 중심 값 C 와 군집 일치 및 근접화 문제에 민감함을 보이고 있다.

2. Swarm-based Clustering

전역 최적화 문제들을 해결하기 위해 개미, 벌, 파리, 새, 물고기 등의 군락들의 행동양식을 모방한 군락기반 (Swarm-based) 최적화 알고리즘이 많이 사용되고 있다 [7, 8, 9]. 그 중, 알고리즘의 계산 복잡도와 전역 최적화 성능 면에서 입자 군집 최적화 (Particle swarm optimization) 알고리즘이 우수한 성능을 보이고 있다 [8]. 각 입자(Particle)는 최적화 탐색 공간상에서 반복적으로 비용 함수 값이 작은 위치로 이동하는데, 각 입자는 이전 반복까지 찾아낸 각 입자의 최적해와 집단 최적해를 사용한다. 입자군집 최적화에 관한 식은 아래의 두 가지로 표현된다.

$$M_i^{t+1} = M_i^t + V_i^{t+1} \quad (5)$$

$$V_i^{t+1} = w V_i^t + e_1 r_{i1}^t (P_i^t - M_i^t) + e_2 r_{i2}^t (P_g^t - M_i^t) \quad (6)$$

수식 (6)에서 w 는 관성질량 계수이고, e_1, e_2 는 각각 양의 상수로 각각 인식계수, 사회계수라고 한다. r_{i1}, r_{i2} 는 난수이며 범위는 $[0, 1]$ 에서 균등분포를 갖는다. 수식 (5)의 V_i^{t+1} 는 입자 i 번째의 $t+1$ 반복의 입자의 속도이며, M_i^{t+1} 는 입자 i 번째의 $t+1$ 반복시의 입자 위치를 나타낸다. P_i^t 와 P_g^t 는 t 번째 반복 시 각각 지역 최적화

와 전역 최적화를 나타내는 입자의 위치를 뜻한다.

입자 군집 최적화 알고리즘을 변형한 입자 군집 알고리즘을 고안하여 데이터 군집화 응용 문제들에서 우수한 성능을 보이고 있다 [12, 13].

III. Proposed Swam-based PCM

입력 데이터 X 에 대하여 최적의 K 개의 군집 중심 값을 찾는 문제는 전역 최적화 문제이다. 최근, 전역 최적화 문제에 대하여 군락기반 군집화 기법들이 알고리즘 계산 량과 군집화 성능 면에서 우수한 성과를 보이고 있다. 따라서 본 논문에서는 PCM 알고리즘의 문제점을 해결하기 위해, 군락기반 군집화와 PCM 알고리즘의 융합된 접근법을 고안하였다.

Fig. 1은 제안한 군락기반 PCM 알고리즘 과정을 나타내는 알고리즘 흐름도이다.




Fig. 1. Flowchart of the proposed swam-based PCM

먼저, 영상 분할을 위해 노이즈가 존재하는 뇌 MR 영상 X 를 입력 값으로 받는다. 잠정적인 초기 군집 중심 값을 설정하기 위해, 각 영상 화소를 화소 명도 값(pixel intensity)을 기반으로 대응되는 K 구역으로 나눈다. 각 구역에 포함된 화소 값 x_j 의 평균값을 계산하여 각 군집의 중심 값 $D = \{d_1, d_2, \dots, d_K\}$ 으로 할당한다.

그 후, 계산된 잠정적인 군집 중심 값 D 는 전역 최적화에 높은 성능을 보이는 군락기반 군집화(swarm-based clustering) 알고리즘을 이용하여 그 값을 최적화 한다. 최적화된 중심 값 $D' = \{d'_1, d'_2, \dots, d'_K\}$ 을 PCM의 초기 군집 중심 값으로 설정함으로써, PCM 알고리즘의 파라미터 초기화 문제를 해결한다.

한편, 노이즈가 영상 데이터 셋에서 많이 존재할 시 PCM 과정 중 군집들 간 일치 및 근접화 문제가 발생한다. 이러한 문제점을 해결하기 위해, 군락기반 군집화에 의해 최적화된 D' 값과 군집화

된 화소 데이터 셋 $S = \{s_1, s_2, \dots, s_K\}$ 에, $x_j \in s_i$, 대해서 사전 군집화(preliminary clustering) 작업을 수행한다. 구체적으로는 제안된 적응적 임계 모델 (adaptive thresholding model), 즉, 수식 (7)을 기준으로 R 와 Q 화소 값 데이터 셋을 구한다.

$$PC_j = \begin{cases} 1, & \frac{d'_i - x_j}{\sum_{x_j \in s_i} (d'_i - x_j)/p_i} < \gamma, \\ 0, & \text{others} \end{cases}, \quad (7)$$

여기서 $p_i = |s_i|$, γ 는 R 와 Q 화소 값 데이터 셋을 분류하기 위한 임계 파라미터이다. 만일 화소 j 에 대해서 PC_j 값이 1일 경우, x_j 를 R 데이터 셋에 할당하고, PC_j 값이 0일 경우 Q 데이터 셋에 할당한다. PCM을 수행하기 전, 최적화된 중심 값 d'_i 를 PCM의 중심 값 초기화에 사용하고, R 데이터 셋에 속해있는 화소값 x_j 을 대응되는 d'_i 중심 값으로 대체함으로써 PCM 알고리즘의 군집 일치 및 근접화 문제를 사전에 방지한다.

최종적으로, 군집화 되지 않은 Q 데이터 셋에 속한 화소 값 x_j 은 PCM 알고리즘을 통하여 군집화함으로써 영상 분할을 수행을 마친다.

IV. Experiment Results

1. Dataset and Performance Measure




Fig. 2. Clustering results with respect to γ in the T1-weighted 96th MR brain image which corrupted by 9% Gaussian noise and 40% bias-field.

제안한 알고리즘은 McConnel Brain Imaging Centre(BIC) [14]에서 제공하는 시뮬레이션 된 자기공명 뇌 영상 데이터 셋에 적용하여 데이터 군집화 성능을 평가하였다. BIC에서 제공하는 뇌 영상 데이터는 뇌 영상 분할의 참 값(혹은 표준 값)을 제공하기 때문에, 정량적인 분석 방법을 위해 대중적으로 사용되는 데이터 셋이다. 또한 BIC에서는 0%에서 9%의 가우시안 노이즈 레벨과

0%에서 40%의 명도 불균일성 (bias-fields)이 첨가된 뇌 합성 MR 영상을 제공하기에, 다양한 노이즈 레벨의 영상에서 알고리즘의 정성 및 정량적 성능 평가를 할 수 있다. 제안한 알고리즘에서 사용된 시스템 파라미터들은 미세 조정하여 $\gamma=1.5$ (Fig. 2 참조), $\lambda=2.0$ ([1, 4]에서 사용된 동일한 값 할당) 으로 설정하였다.

2. Experimental Results

2.1 Qualitative Results

Fig. 3, Fig. 4, Fig. 5는 기존 알고리즘들과 제안한 알고리즘의 정성적 실험평가 결과를 보여준다. 본 실험 평가를 위해 다양한 가우시안 (Gaussian) 노이즈 7%, 9%와 20%, 40%의 명도 불균등성 레벨이 첨가된 T1-가중치 96번째 MR 뇌 의료 영상을 사용하였다.




Fig. 3. Segmentation results: (a) Original image with 7%/40%(Noise/bias-field level), (b) Ground true of image, (c) Result of PCM with user-defined centers, (d) Result of [10], (e) Result of [16], (f) Result of the proposed method.




Fig. 4. Segmentation results: (a) Original image with 9%/20%(Noise/bias-field level), (b) Ground true of image, (c) Result of PCM with user-defined centers, (d) Result of [10], (e) Result of [16], (f) Result of the proposed method.




Fig. 5. Segmentation results: (a) Original image with 9%/40% (Noise/bias-field level), (b) Ground true of White Matter (WM), Grey Matter (GM), Cerebrospinal Fluid (CSF) and total region, (c) Result of PCM with user-defined centers, (d) Result of [10], (e) Result of [16], (f) Result of the proposed method.

Fig. 3과 Fig. 4에서의 결과와 같이 제안하는 방법이 기존 PCM 기법들[2, 10, 16]과는 달리 군집 일치화 및 근접화 문제를 해결하였고, 참값(Ground truth)과 근접한 결과를 보였다. 또한, Fig. 5에서의 노이즈 영상 분할 결과와 같이 제안한 알고리즘은 기존 PCM 기법들과 비교하여 우수한 분할 성능을 보였다. 특히, PCM은 사전에 설정된(User-defined) 군집 중심 값을 사용한 결과이고, [10], [16]은 사전에 설정된 중심 값을 사용하지 않고 고안된 알고리즘을 통해 계산된 중심 값을 사용한 것이지만, 높은 노이즈 레벨에서 군집 간 근접화로 낮은 군집화 결과를 보였다. 한편, 제안한 알고리즘은 미리 설정된 값을 사용하지 않고 적응적으로 최적화된 군집 중심 값을 계산해서 파라미터들을 초기화하였고, 본 알고리즘을 통해 구해진 사전 데이터 셋 R을 활용하여 군집 일치 및 근접화 문제를 사전에 방지하여, 노이즈에 강건하게 영상 분할 수행하였다.

2.2 Quantitative Results

제안한 알고리즘과 기존 PCM 알고리즘들의 정량적 수치를 비교 평가하기 위해서, 아래의 자카드 유사도 지표 (Jaccard similarity index: JSI)를 사용하였다.

$$J^z(w_g, w_r) = \frac{|w_g^z \cap w_r^z|}{|w_g^z \cup w_r^z|} \tag{8}$$

수식 (8)에서 w_g^z 는 클래스 z의 참 값 (Ground truth) 화소 데이터셋, w_r^z 는 테스트하는 알고리즘의 클래스 z에 대한 군집화 결과 픽셀 데이터 셋을 의미한다. JSI의 값이 1에 근접할수록 군집화 결과가 참값에 가깝다는 것을 의미한다.

Table 1은 기존 PCM 알고리즘들과 제안한 알고리즘의 정량적인 성능평가의 결과를 보여준다. 본 실험에서는 7%, 9% 노이즈 레벨과 20%, 40% 명도 불균등성이 포함된 시뮬레이션된 뇌 영상을 사용하였다. PCM은 사전에 설정된 군집 중심 값을 사용한 결과이고, [10], [16]은 사전에 설정된 중심 값을 사용하지 않고 고안된 알고리즘을 통해 계산된 중심 값을 사용한 것이다. Table 1에서의 결과와 같이, 제안한 알고리즘이 노이즈 영상에서 기존 PCM 알고리즘들 대비 높은 영상 분할 성능을 보였다. 특히, 노이즈 및 명도 불균등성의 레벨이 높을수록 PCM, [10], [16] 알고리즘들 보다 성능적인 면에서 강건한 결과를 보였다. 또한, PCM, [10]기법은 노이즈 레벨 9%에서 최종 군집 간의 중심 값이 서로 근사 혹은 일치하여 입력 데이터의 잘못된 군집화 경향을 보였다. 반면, 제안한 알고리즘은 높은 노이즈 레벨에서도 군집 간 일치 및 근접화 문제를 극복하면서 강건한 영상 분할 결과를 보였다.

한편, 실험에 사용된 알고리즘들(PCM, [10], [16]) 및 제안한 알고리즘의 계산 복잡도는 동일하게 $O(N^2)$ 이다.

Table 1. Quantitative evaluation results for various methods

Methods	Noise level	7%		9%	
		Bias-field	20%	40%	20%
PCM[2]	WM	0.1581	0.2207	0.1584	0.1826
	GM	0.4489	0.4628	0.4383	0.4456
	CSF	0.8633	0.8559	0.8178	0.8275
	Total	0.3946	0.4229	0.3847	0.3977
[10]	WM	0.8784	0.8567	0.1289	0.1911
	GM	0.7774	0.7466	0.3016	0.3015
	CSF	0.8271	0.8068	0.5373	0.5189
	Total	0.8323	0.8069	0.2880	0.3058
[16]	WM	0.8855	0.8567	0.8241	0.8053
	GM	0.7992	0.7633	0.7051	0.6846
	CSF	0.8355	0.8124	0.7544	0.7362
	Total	0.8454	0.8140	0.7678	0.7475
Proposed method	WM	0.8830	0.8660	0.8335	0.8290
	GM	0.7703	0.7438	0.6840	0.6915
	CSF	0.8464	0.8233	0.7914	0.7992
	Total	0.8376	0.8155	0.7736	0.7743

V. Conclusions

본 논문에서는 군락기반 군집화 방법과 PCM의 융합된 형태의 알고리즘을 제안하여, 기존 PCM 계열 알고리즘들 문제점인, 즉, 군집 중심 값 초기화와 군집들 간의 일치 및 근접화 문제를 해결하였다. 특히, 군락기반 군집화 알고리즘을 기반으로 PCM에 최적의 군집 중심 값을 초기화하여 PCM의 파라미터 초기화 문제를 해결하였다. 그리고, 제안된 적응적 임계치 모델을 활용하여 사전에 군집화 된 데이터 셋을 PCM에 제공함으로써 PCM의 군집 간 일치 및 근접화 문제를 해결하였다. 성능 비교를 위한 실험은, 다양한 노이즈 및 명도 불균등성이 첨가된 MR 뇌 영상을 대상으로 정량 및 정성적 실험 평가를 하였고, 제안한 기법이 기존 PCM기법들 보다 높은 성능을 보임을 확인하였다. 제안한 기법은 의료 영상분할 뿐 아니라 다양한 응용에서 노이즈 데이터를 제거 및 군집화를 수행할 때 유용하게 사용될 것으로 기대한다.

앞으로 노이즈가 존재하는 다양한 고차원 데이터 셋에서 제안한 군집 기법의 성능 평가를 수행하고, 그에 따른 적응적인 군집화 알고리즘으로 개선할 것이다.

REFERENCES

[1] R. Krishnapuram, and J. Keller, "A possibilistic approach to clustering," IEEE Transactions on Fuzzy Systems, Vol. 1, No. 2, pp. 98-110, May 1993.
 [2] J. C. Dunn, "A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters," Journal of Cybernetics, Vol. 3, No. 3, pp. 32-57, January 1973.
 [3] M. Barni, V. Cappellini, and A. Mecocci, "Comments on a possibilistic approach to clustering," IEEE Transactions

- on Fuzzy Systems, Vol. 4, No. 3, pp. 393–396, August 1996.
- [4] N. R. Pal, K. Pal, and J. C. Bezdek, "A possibilistic fuzzy c-means clustering algorithm," *IEEE Transactions on Fuzzy Systems*, Vol. 13, No. 4, pp. 517–530, August 2005.
- [5] L. Berger, H. Eoin, M. J. Cardoso, and S. Ourselin, "An Adaptive Sampling Scheme to Efficiently Train Fully Convolutional Networks for Semantic Segmentation", *Proceedings of Medical Image Understanding and Analysis*, pp. 277–286, 2017.
- [6] A. P. Reeves, Y. Xie, and S. Liu, "Large-scale image region documentation for fully automated image biomarker algorithm development and evaluation", *Journal of Medical Imaging*, Vol. 4, No. 2, pp. 101–115, June 2017.
- [7] M. Dorigo, G. D. Caro, and L. Gambardella, "Ant algorithms for discrete optimization," *Artificial Life*, Vol. 5, pp.137–172, 1999.
- [8] J. Kennedy, and R. Eberhart, "Particle Swarm Optimization". *Proceedings of IEEE International Conference on Neural Networks*, pp. 1942–1948. 1995.
- [9] P. Shunmugapriya, and S. Kanmanib, "A hybrid algorithm using ant and bee colony optimization for feature selection and classification (AC-ABC Hybrid)", *Swarm and Evolutionary Computation*, Vol. 36, pp. 27–36, October 2017,
- [10] Y. Zhang, D. Huang, M. Ji, and F. Xie, "Image segmentation using PSO and PCM with Mahalanobis distance," *Expert Systems with Applications*, Vol. 38, No. 7, pp. 9036–9040, 2011.
- [12] R. Cheng, and Y. Jin, "A Competitive Swarm Optimizer for Large Scale Optimization", *IEEE Transactions on Cybernetics*, Vol. 45, No. 2, pp. 191–204, Feb. 2015.
- [13] Z. Yong, G. Dun-wei, and Z. Wan-qiu, "Feature selection of unreliable data using an improved multi-objective PSO algorithm" , *Neurocomputing*, Vol. 171, No. 1, pp. 1281–1290, January 2016
- [14] McConnel Brain Imaging Centre (BIC), <http://www.bic.mcgill.ca/brainweb>
- [15] S. S. M. Salehi, D. Erdogmus, and A. Gholipour, "Auto-Context Convolutional Neural Network (Auto-Net) for Brain Extraction in Magnetic Resonance Imaging," *IEEE Transactions on Medical Imaging*, Vol. 36, pp. 2319–2330, June 2017.
- [16] S. Zhichao, H. Yingb, W. Junjiea, H. Yulina, and Y. Jianyua, "A robust adaptive particle swarm optimization for clustering analysis based on steepest descent method", *Journal of Intelligent & Fuzzy Systems*, vol. 32, no. 1, pp. 23–33, January 2017.

Authors



Jeong Min Yu received the M.S. and Ph.D. degrees from Department of Information and Communications, Gwangju Institute of Science and Technology (GIST), Gwangju, in 2009 and 2014 respectively. Dr. Yu joined the faculty of the Department of Culture

Heritage Industry at Korea National University of Culture Heritage, Bu-yeo, Korea, in 2017. He is currently a assistant Professor in the Department of Culture Heritage Industry at Korea National University of Culture Heritage. He is interested in computer vision, image processing, augmented reality, and digital heritage.