

# 라만분광법에 의한 흑색 플라스틱 선별을 위한 퍼지 클러스터링기반 신경회로망 분류기 설계

## Design of Fuzzy Clustering-based Neural Networks Classifier for Sorting Black Plastics with the Aid of Raman Spectroscopy

김 은 후\* · 배 종 수\* · 오 성 권†

(Eun-Hu Kim · Jong-Soo Bae · Sung-Kwun Oh)

**Abstract** - This study is concerned with a design methodology of optimized fuzzy clustering-based neural network classifier for classifying black plastic. Since the amount of waste plastic is increased every year, the technique for recycling waste plastic is getting more attention. The proposed classifier is on a basis of architecture of radial basis function neural network. The hidden layer of the proposed classifier is composed to FCM clustering instead of activation functions, while connection weights are formed as the linear functions and their coefficients are estimated by the local least squares estimator (LLSE)-based learning. Because the raw dataset collected from Raman spectroscopy include high-dimensional variables over about three thousands, principal component analysis(PCA) is applied for the dimensional reduction. In addition, artificial bee colony(ABC), which is one of the evolutionary algorithm, is used in order to identify the architecture and parameters of the proposed network. In experiment, the proposed classifier sorts the three kinds of plastics which is the most largely discharged in the real world. The effectiveness of the proposed classifier is proved through a comparison of performance between dataset obtained from chemical analysis and entire dataset extracted directly from Raman spectroscopy.

**Key Words** : Raman spectroscopy, Radial basis function neural networks, Artificial bee colony, Principal component analysis

### 1. 서 론

흑색 플라스틱을 재질별 자동 선별을 위해서는 측정 장비이외에 재질별로 분류할 수 있는 분류 알고리즘이 필요하다. 최근에는 인간과 유사한 사고 및 추론방식을 컴퓨터 프로그램으로 구현하여 실생활에 주어진 문제를 스스로 학습하여 문제를 해결하는 인공지능이 주목을 받고 있다. 본 연구에서 퍼지 논리를 포함하는 클러스터링 알고리즘과 신경회로망 구조를 결합한 지능형 패턴 분류기 구현한다. 퍼지 논리는 인간의 언어적 애매모호한 표현을 수치적으로 나타내는 동시에 인간의 추론방법을 방법과 유사한 방법으로 문제를 접근하고 해결하며 신경회로망은 인간의 뇌에서 정보전달 및 처리 과정과 유사한 일련의 학습과정을 모방한 모델이다. 여기에 클러스터링은 주어진 정보간의 유사성을 바탕으로 효과적으로 정보를 군집화하여 모델 학습에 용이한 형태로 데이터를 가공하는 방법이다. 2000년 초반에 Oh와 Pedrycz에 의해 퍼지 추론 시스템의 전반부 구조 설계 및 파라미터 동조에 클러스터링 학습방법을 적용하였다. 클러스터링을 통해 멤버십

함수의 중심점을 결정하고 진화 최적화 연산으로 멤버십 함수의 중심점을 최적화 시켜 성능을 개선하였다. 그 후에 방사형 기저 함수 (radial basis function; RBF) 신경회로망[7, 8]에 클러스터링을 적용하여 은닉층 활성화함수로 사용되는 가우시안 함수의 중심점 및 분포상수를 k-평균 군집 또는 Fuzzy C-means (FCM) 클러스터링을 사용하여 간접적으로 활성화함수의 파라미터 학습에 관여하거나 직접적으로 은닉층 출력으로 활용하였다[9-14].

본 연구에서는 기존 분광법으로 분별하기 힘들었던 생활계 흑색 폐플라스틱의 자동 분류를 위해 라만(Raman) 분광법을 이용하여 재질별 데이터 추출 및 화학적 특징을 분석하여 퍼지 클러스터링 신경회로망 분류기를 통해 생활계에서 가장 많이 배출되는 polyethylene terephthalate(PET), polypropylene(PP), polystyrene(PS) 등의 흑색 플라스틱을 재질에 따라 선별하여 플라스틱 재활용 효율을 향상시키고자 한다. 라만 장비로 추출된 데이터는 고차원 데이터로 분류기의 입력으로 바로 사용하기 부적합하다. 따라서 대표적인 차원 축소 알고리즘인 주성분 분석법 (Principal Component Analysis; PCA)를 통해 정보 손실을 최소로 하는 저차원의 입력 데이터를 생성하여 제안된 분류기의 입력으로 사용된다. 은닉층은 기존의 활성화함수를 사용하는 방법 대신에 퍼지 클러스터링을 통해 클러스터의 중심점들과 입력간의 거리를 퍼지 수로 나타내는 소속 값을 은닉층의 출력으로 사용한다. 은닉층과 출력층의 연결가중치(후반부 다항식)의 계수는 지역 최소자승법을 통해 독립적인 학습을 수행한다. 또한 제안된 분류

† Corresponding Author : Dept. of Electrical Engineering, The University of Suwon, Korea  
E-mail: ohsk@suwon.ac.kr

\* Dept. of Electrical Engineering, The University of Suwon, Korea.

Received : August 18, 2016; Accepted : April 14, 2017

기의 최적의 구조 및 성능 개선을 위해 진화 최적화 알고리즘중 하나인 Artificial Bee Colony(ABC) 알고리즘을 통해 입력변수의 수 및 클러스터의 수 그리고 피지화 계수 등을 최적화한다.

본 논문의 구성은 다음과 같이 구성된다. 2장에서는 라만 분광법에 대해 설명하며 3장에서는 라만 분광법으로부터 추출된 파형(정보) 압축 및 불필요한 정보를 제거하는 차원 축소 알고리즘에 대해 기술한다. 4장에서는 플라스틱을 재질별 분류하기 위한 패턴 분류기에 대한 구조 및 학습방법에 대해 설명하고 5장에서는 패턴 분류기의 최적 파라미터를 동조하기 위한 ABC 최적화 알고리즘에 대해 서술한다. 마지막으로 6장 결론에서 논문을 요약하며 마무리한다.

## 2. 혼합 테스뜨플라스틱의 화학적 특성 분석을 위한 라만 분광법

라만 분광법(Raman spectroscopy)은 특정 분자에 레이저와 같은 단색의 강한 빛을 쬐었을 때 원자들 간의 진동 및 전자들 사이의 상호작용에 의해 고체 내에서 빛 에너지가 발생하는 산란광을 이용하는 방법이다. 진동수만큼 차이가 있는 산란광이 생기는 것을 라만효과라고하며 이런 현상을 이용하여 분자의 진동 스펙트럼을 관찰하는 방법을 라만 분광법이라고 한다[1]. 라만 분광법을 이용해 흑색 플라스틱의 고유 산란광을 측정하여 분류 알고리즘의 입력으로 사용한다[2,6]. 플라스틱의 종류는 현재 생활계 폐플라스틱 폐기물로 많이 배출되는 polyethylene terephthalate (PET), polypropylene(PP), polystyrene(PS)등을 사용하였으며 플라스틱 종류에 따른 화학식 구조를 그림 1에 나타내었다. PET의 경우 Carbonyl group(C=O) stretching, Ring C1-C4 stretching, CO-C stretching 등의 특성이 다른 두 개의 플라스틱 PP, PS와 비교했을 때 눈에 띄며, PP의 경우 Methyl group(-CH3)이 가장 큰 특징을 나타낸다. PS의 경우 Benzene ring breathing mode, double bonds(C=C) 등이 다른 두 개의 플라스틱 특징과 차이를 보인다[15-17].

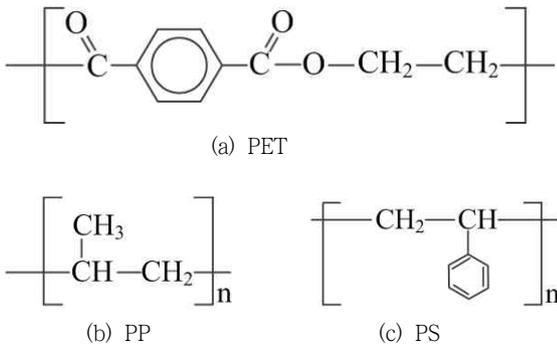


그림 1 플라스틱 재질별 화학 구조식  
Fig. 1 Molecular structures by kinds of plastic

표 1은 기존 다수 논문을 참고하여 라만 분광법을 통해 추출한 재질별 고유 화학적 특성을 파장대별로 기록하였다[2-4]. 서

표 1 라만 분광법을 이용한 플라스틱 재질별 화학적 특성  
Table 1 Chemical characteristics by types of plastic through Raman spectroscopy

(a) PET

Wave number(cm <sup>-1</sup> )	Assignment
795	Ring torsion and C=O stretching
858	Ring C-C eater CO-C
1289	CO-C stretching
1613	Ring C1-C4 stretching
1725	C=O stretching

(b) PP

Wave number(cm <sup>-1</sup> )	Assignment
398	$\omega CH_2 + \delta CH$
841	$rCH_2 + \nu C-CH_3$
1034	$\nu C-CH_3 + \nu C-C + \delta CH$
1257	$\delta CH + tCH_2 + rCH_3$
1307	$\omega CH_3 + tCH_2$
1457	$\delta CH_2_{asym} + \delta CH_2$
2871	$\nu CH_3_{sym}$

(c) PS

Wave number(cm <sup>-1</sup> )	Assignment
621	Benzene ring vibration
1001	Benzene ring breathing mode
1032	C-H in plane bending mode
1155	C-C stretching vibration
1602	C=C vibration

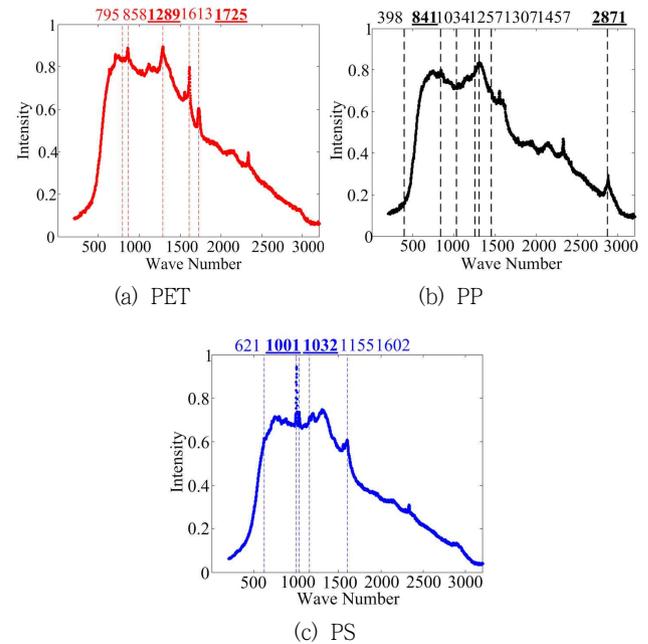


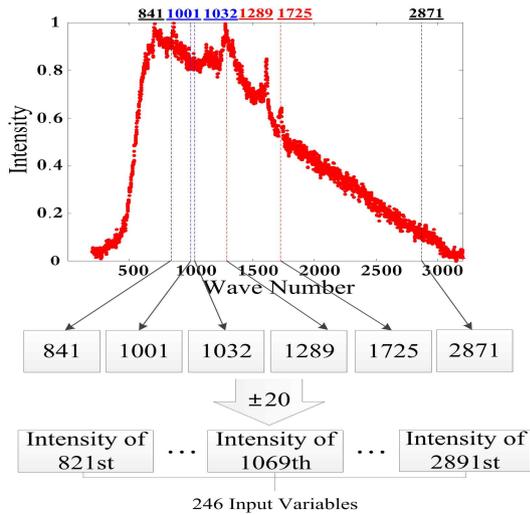
그림 2 플라스틱 재질별 화학적 특성 점  
Fig. 2 Chemical characteristic points by kinds of plastic

로 다른 화학식을 바탕으로 다른 파장 수에서 각 재질별 고유 특징들을 나타낸다.

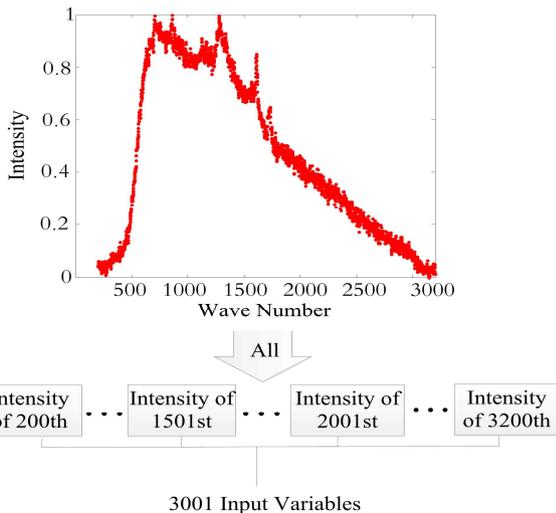
그림 2는 표 1의 재질별 특성이 나타나는 파수(wave number)와 실험을 통해 직접 측정된 재질별 파수를 비교하였다. 재질별 데이터 획득을 위해 라만 장비는 Ocean Optics사의 ID-Raman Reader를 사용하였으며 시료마다 0.5초 동안 측정하여 파수를 획득하였다. 그림 2와 표 1을 비교해보면 실제 측정된 파수와 표 1에 정리된 파수가 전부 일치하지는 않는다. 이는 실제 사용한 장비와 기존 논문들에서 사용한 장비 및 실험 조건 등이 다르고 같은 플라스틱이라도 제조사마다 구성 성분 비율이 다르기 때문이다. 따라서 본 실험에서는 실제 측정 파수에서 강도가 상승하는 고유 파수(eigen wave number)들을 선택하는 동시에 재질별 중복되지 않게 고유 파수(eigen wave number)들을 제외하여 최종적으로 재질별 두 개의 고유 파수를 선택하여 입력

데이터를 생성하였다. 선택된 고유 파수는 PET는 1289cm<sup>-1</sup> 및 1725cm<sup>-1</sup>을 선택하였으며 PP는 841cm<sup>-1</sup> 및 2871cm<sup>-1</sup> 그리고 PS는 1001cm<sup>-1</sup> 및 1032cm<sup>-1</sup>를 각각 선택하였으며 표 1에 볼드체로 표시하였다.

그림에서 파수는 분류기의 사용되는 입력변수의 차원(수)을 의미한다. 실험에서는 Case I과 Case II로 경우의 수를 두고 입력 변수 생성을 다르게 적용하였다. Case I의 경우는 라만 분광법을 통해 3001개의 입력 차원 중 재질별 고유 파수를 두 개씩 선택하고 각 재질별 고유 파수를 기준으로 ±20의 구간을 설정하여 선택된 파수마다 41개의 정보를 입력변수로 선택한다. 총 6개의 고유 파수를 일렬로 연결하면 그림 3(a)와 같이 총 246개의 입력 변수가 구성되고 주성분 분석법을 이용하여 한 번 더 차원 축소를 통해 제안된 분류기의 입력 데이터를 생성하였다. Case II는 라만 분광법을 통해 3001개의 입력 차원을 바로 주성분 분석법을 사용하여 한 번만 차원 축소를 수행하여 분류기의 입력을 생성하였다. Case I은 재질별 화학적 특성을 고려하여 입력변수를 생성하는 방법이며 Case II는 화학적 특성을 고려하지 않고 순수 라만 분광법에서 획득된 파형만을 이용하여 입력변수를 생성하는 차이점이 있다. 플라스틱 하나당 라만 분광법을 통해 측정된 입력변수는 총 3001개의 고차원으로 구성된다.



(a) 재질별 화학적 고유 파수를 이용한 입력변수 구성(Case I)



(b) 전체 파수를 이용한 입력변수 구성(Case II)

그림 3 Case별 입력변수 구성 비교

Fig. 3 Comparison of configuration of input variables by Case

### 3. 차원 축소를 위한 주성분 분석법

주성분 분석법은 고차원의 데이터 정보 손실을 최소화 하면서 저차원의 특징 데이터로 축소하는 기법이다. 패턴분류기를 이용하여 학습을 수행할 때 고차원의 데이터는 실제 학습에 필요한 패턴 또는 규칙이외에 노이즈 및 불필요한 특성까지 포함하고 있어 성능 저하에 한 요인이 되며 또한 과도한 학습량을 필요로 한다. 본 연구에서는 이런 문제점들을 해결하고자 주성분 분석법(Principal Component Analysis; PCA) 알고리즘을 사용하였다 [18]. 라만 분광법을 통해 얻은 데이터에 적용한 차원 축소 과정은 아래와 같은 단계로 진행된다.

[Step 1] 학습 데이터  $X$  구성

$$X = \{x_1, x_2, x_3, \dots, x_N\} \in R^n \quad (1)$$

여기서,  $n$ 은 입력변수의 차원 수를 의미하며,  $N$ 은 패턴의 수를 의미한다.

[Step 2]  $X$ 의 평균 벡터를 계산

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

[Step 3] 평균 벡터  $\bar{x}$ 를 이용하여 학습 데이터의 평균을 0으로 정규화

$$\phi_i = x_i - \bar{x} \quad (3)$$

[Step 4] 정규화된 학습 데이터  $\Phi$ 의 공분산 행렬  $C$  계산

$$C = \frac{1}{N} \sum_{i=1}^N \phi_i \cdot \phi_i^T \quad (4)$$

[Step 5]  $n$ 개의 고유벡터  $e$ 에서 큰 고유 값  $\lambda$ 을 갖는  $m$ 개의 고유벡터를 순차적으로 선택하여 변환행렬 획득

$$E = [e_1, e_2, \dots, e_m] \quad (5)$$

[Step 6] 각 학습데이터와 고유벡터와의 사영을 통해 특징 벡터를 획득

$$\Omega = E^T \Phi, \quad \Omega = [\omega_1, \omega_2, \omega_3, \dots, \omega_N] \in R^m \quad (6)$$

식 (6)을 통해 획득한 특징 벡터가 분류기의 최종 입력이 된다. 처음 라만 분광법을 통해 획득한 입력 차원은 3001개가 되며 그 중 고유 파수 선택으로 가공된 입력 차원은 그림 3과 같이 246개가 된다. 나아가 주성분 분석법을 통해 246개에서 고유 값이 큰 순서대로 50개를 선택하여 Step 6을 통해 50차원의 입력 데이터를 최종 선택하였다.

#### 4. 퍼지 클러스터링기반 신경회로망 구조 및 학습방법

본 장에서는 플라스틱의 재질별 선별을 위한 퍼지 클러스터링기반 신경회로망 패턴 분류기의 구조 및 학습방법에 대해 소개한다.

##### 4.1 퍼지 클러스터링기반 신경회로망 구조

퍼지 클러스터링기반 신경회로망 패턴 분류기는 기존 방사형 기저 함수(radial basis function; RBF) 신경회로망과 같이 입력층 은닉층 출력층과 같이 세 부분으로 구성된다. 방사형 기저 함수와 구조적으로 가장 큰 차이는 은닉층에 있다. 퍼지 클러스터링기반 신경회로망은 FCM 클러스터링의 중심점 및 소속 값(멤버십 값)이 은닉층을 구성한다. 따라서 입력층과 은닉층사이의 연결가중치는 FCM 클러스터링의 중심값과 동일하며 은닉층의 출력은 FCM 클러스터링의 소속 값이 된다. 추가적으로 은닉층과 출력층사이의 연결가중치는 상수항 또는 다항식으로 구성된다. 퍼지 클러스터링기반 신경회로망 패턴 분류기의 구조는 아래 그림 4와 같다[19].

퍼지 클러스터링기반 신경회로망은 퍼지 규칙으로 네트워크 구조를 표현할 수 있다. 식 (7)과 같이 입력층부터 은닉층까지를 퍼지 규칙의 전반부로 표현할 수 있으며 은닉층과 출력층사이의 연결가중치는 퍼지 규칙의 후반부로 정의할 수 있다. 또한 출력층은 퍼지 규칙의 추론부로 각 퍼지 규칙의 가중평균을 이용하여 최종 출력을 구하고 각 부류(class)의 출력 값을 비교하여 분류기의 최종 부류를 선택한다. 퍼지 규칙의 전반부에 해당하는 IF절은 FCM 클러스터링을 통해 형성되며 후반부의 THEN절은 1차선형식으로 표현 할 수 있다.

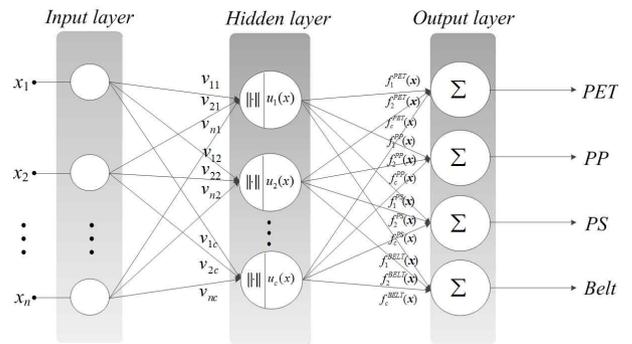


그림 4 퍼지 클러스터링기반 신경회로망 패턴분류기 구조  
Fig. 4 Structure of fuzzy clustering-based neural network pattern classifier

$$R_i^j : IF \ x \text{ is } u_i \text{ with } v_i \text{ THEN } f_i^j(x) \quad (7)$$

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left( \frac{\| \mathbf{x}_k - \mathbf{v}_i \|}{\| \mathbf{x}_k - \mathbf{v}_j \|} \right)^{2/(m-1)}} \quad (8)$$

$$f_i^j(x_1, \dots, x_n) = a_{i0}^j + \sum_{p=1}^n a_{ip}^j x_p \quad (9)$$

여기서,  $R_i^j$ ( $i=1, \dots, c; j=1, \dots, cs$ )는 퍼지 규칙을 나타내며  $u_i$ 와  $v_i$ 는 FCM 클러스터링의 소속 값 및 중심 값을 각각 의미한다. 후반부 다항식  $f_i^j(x)$ 는 1차선형식을 사용하였으며  $a_{ip}^j$ ( $p=0, \dots, n$ )는 파라미터 계수를 의미한다.

후반부 다항식의 파라미터 계수 추정은 지역 최소자승법을 사용하여 계수를 추정한다. 퍼지 규칙이 정의되면 각 퍼지 규칙을 통해 분류기의 최종 출력을 구한다. 이 때 분류기의 출력은 데이터의 부류 수만큼 생성되고 각 부류에 해당하는 분류기 출력 중 가장 큰 값을 갖는 출력이 분류기의 최종 출력이 된다.

$$\hat{y}_j = \sum_{i=1}^c u_i f_i^j(x) \quad (10)$$

$$\hat{y}_i > \hat{y}_j, \quad i \neq j (i, j = 1, \dots, cs) \quad (11)$$

##### 4.2 퍼지 클러스터링기반 신경회로망 학습방법

본 절에서는 퍼지 클러스터링기반 신경회로망 패턴 분류기에서 은닉층 적합도를 생성하는 FCM 클러스터링 알고리즘과 연결가중치의 파라미터를 추정하는 지역 최소자승법에 대해 설명한다.

###### 4.2.1 FCM 클러스터링

퍼지 클러스터링은 소프트 클러스터링이라 불리며 이는 하드 클러스터링과 구분된다. 일반적으로 하드 클러스터링과 소프트 클러스터링의 큰 차이점은 데이터와 클러스터간의 소속개념에 있다. 하드 클러스터링의 경우, 각 데이터가 정확하게 하나의 클러

스터에 속하며 이 때 가중치는 1이 되며 나머지 속하지 않은 클러스터에 대한 가중치는 0이 된다. 소프트 클러스터링의 경우, 각 데이터는 특정한 클러스터에만 속하지 않고 각 클러스터의 중심점을 기준으로 데이터가 클러스터에 얼마만큼 소속되어 있는지를 가중치로서 표현하고 이 때 가중치의 총 합은 1이 된다[20,21].

FCM 클러스터링 알고리즘 가장 많이 사용되는 퍼지 클러스터링 방법 중 하나이며 1981년 Bezdek 교수에 의해 소개되었다. FCM 클러스터링의 목적함수는 식 (12)와 같다.

$$J(u_{ik}, v_i) = \sum_{i=1}^c \sum_{k=1}^N u_{ik}^m \|x_k - v_i\|^2 \quad (12)$$

목적함수를 최소화하는 중심점  $v_i$ 와 소속 값  $u_{ik}$ 는 반복 학습을 통해 최적의 값을 찾으며 학습 방법은 다음과 같다.

**[단계 1]** 클러스터의 개수  $c(2 \leq c \leq M)$ 을 정하고 퍼지화계수  $m(1 < m < \infty)$ 을 선택한다. 초기 소속행렬  $U^{(0)}$ 을 초기화 하고 반복 횟수를  $r(r=0, 1, \dots)$ 로 표시한다.

$$U^{(r)} = \left\{ u_{ik} \in [0, 1], \sum_{i=1}^c u_{ik} = 1 \forall k, 0 < \sum_{k=1}^N u_{ik} < n \forall i \right\} \quad (13)$$

**[단계 2]** 식 (14)를 이용하여 FCM 클러스터 중심점  $v_i^{(r)} = \{v_{i1}^{(r)}, \dots, v_{in}^{(r)}\}$  및 소속 값  $u_{ik}$ 를 계산한다.

$$v_{ij}^{(r)} = \frac{\sum_{k=1}^N u_{ik}^m x_{kj}}{\sum_{k=1}^N u_{ik}^m} \quad (14)$$

여기서,  $u_{ik}$ 는 0과 1사이의 소속을 나타내는 정도의 값으로  $i$ 번째 클러스터에 속해져 있는  $x_k$ 의  $k$ 번째 데이터의 소속정도를 나타낸다.  $v_i$ 는  $i$ 번째 클러스터 중심 벡터이다.

**[단계 3]** 다음과 같이 새로운 소속행렬  $U(r+1)$ 을 계산한다.

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left( \frac{d_{ik}}{d_{jk}} \right)^{2/(m-1)}}, \quad (d_{ik} = \|x_k - v_i\|) \quad (15)$$

여기서  $\|\cdot\|$ 은 입력변수와 각 클러스터의 중심점간의 유클리드 거리를 의미한다.

**[단계 4]** 다음 식 (16)을 계산해서 만일  $\Delta > \epsilon$  이면  $r=r+1$ 로 정하고 [단계 2]로 가서 다시 알고리즘을 반복 수행하고 그렇지 않고  $\Delta \leq \epsilon$ 이면 알고리즘을 종료한다. 여기서,  $\epsilon$ 는 임계값이다.

$$\Delta = \|U^{(r+1)} - U^{(r)}\| = \max_{i,k} |u_{ik}^{(r+1)} - u_{ik}^{(r)}| \quad (16)$$

#### 4.2.2 연결가중치 학습을 위한 지역 최소자승법

지역 최소자승법(local least squares estimator; LLSE)은 최

소자승법과 가중 최소자승법의 특징을 결합하여 퍼지 규칙의 파라미터 학습에 더욱 유용한 형태로 식 (17)와 같다[19].

$$Q_j = \sum_{i=1}^c \sum_{k=1}^N u_{ik}^2 (t_{ik} - f_i^j(x_k))^2 \quad (17)$$

$$t_k = \begin{cases} +1 & \text{If } y_k = j \\ -1 & \text{Otherwise} \end{cases} \quad (18)$$

$y_k$ 는 정수로 표현되는 실제 클래스를 의미하며 식(18)에 의해 학습하고자 하는 클래스의 출력은 1이 되고 나머지 출력은 -1로 변환하여 학습에 사용한다. 또한 이 과정을 클래스 수만큼 반복한다.

표준 최소자승법은 전체 퍼지 칩에 대한 후반부 다항식의 파라미터 계수를 동시에 추정하기 때문에 각 퍼지 규칙의 역할에 대한 해석력이 떨어진다. 또한 가중 최소자승법의 경우 실제 출력과 후반부 다항식만을 고려하여 오차를 최소화하기 때문에 각 퍼지 규칙의 후반부 파라미터 계수를 독립적으로 추정할 수는 있지만 각 퍼지 규칙의 해석력보다는 후반부 Then절을 해석하는데 집중된다. 제안된 지역 최소자승법은 각 퍼지 규칙의 출력이 실제 출력에 전반부 적합도를 고려한 부분 출력을 기준으로 학습을 수행한다. 식 (13)과 같이 FCM의 특성상 전반부의 적합도의 합은 항상 1을 만족하므로 실제 출력에 전반부 적합도를 곱한 부분 출력들의 합은 항상 실제 출력과 같다. 결과적으로 각 퍼지 규칙은 실제 출력의 부분 출력과 오차를 최소화하여 각 퍼지 규칙의 후반부 다항식 계수를 독립적으로 추정하였으며 각 퍼지 규칙의 해석력을 향상시켰다.

미분을 통해  $i$ 번째 퍼지 규칙에 대한 후반부 다항식의 계수 추정을 위한 행렬식은 식(19)와 같다.

$$A_i^j = (X^T X)^{-1} X^T U_i T_j \quad (19)$$

$$X = \begin{bmatrix} u_{11} & \dots & u_{1c} & u_{11}x_{11} & \dots & u_{1c}x_{11} & \dots & u_{11}x_{1n} & \dots & u_{1c}x_{1n} \\ u_{21} & \dots & u_{2c} & u_{21}x_{21} & \dots & u_{2c}x_{21} & \dots & u_{21}x_{2n} & \dots & u_{2c}x_{2n} \\ \vdots & \vdots \\ u_{N1} & \dots & u_{Nc} & u_{N1}x_{N1} & \dots & u_{Nc}x_{N1} & \dots & u_{N1}x_{Nn} & \dots & u_{Nc}x_{Nn} \end{bmatrix},$$

$$U_i = \begin{bmatrix} u_{i1} & 0 & \dots & 0 \\ 0 & u_{i2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & u_{iN} \end{bmatrix}, \quad T_j = \begin{bmatrix} t_{j1} \\ t_{j2} \\ \vdots \\ t_{jN} \end{bmatrix}, \quad A_i^j = \begin{bmatrix} a_{i0}^j \\ a_{i1}^j \\ \vdots \\ a_{in}^j \end{bmatrix}.$$

여기서,  $A_i$ 는 추정하고자 하는  $i$ 번째 퍼지 규칙의 다항식의 계수를 의미하며  $T_j$ 는 1과 -1로 변환된 출력데이터,  $U_i$ 는  $i$ 번째 입력공간에 대한 입력 데이터들의 소속 값을 의미한다. 행렬  $X$ 는 표준 최소자승법과 동일한 행렬로 구성된다.

### 5. Artificial Bee colony를 이용한 최적화 과정

#### 5.1 Artificial Bee Colony 정의 및 연산자

Artificial Bee Colony(ABC)은 꿀벌 집단의 식량 수집과정은

모방한 진화 최적화 알고리즘이다. ABC 최적화 알고리즘은 일벌 (Employed bees), 탐색 벌(Onlooker bees), 스카우트 벌(Scout bees)등과 같이 세 개의 연산자로 이루어져있으며 일벌과 탐색 벌은 지역탐색을 담당하며 스카우트 벌은 전역탐색을 수행한다. 식량의 위치정보는 지역 해에 해당하며 지역 해 주변을 연산자 (일벌, 탐색벌)를 통해 탐색하여 전역 해를 찾아가는다. 식량이 있는 다수의 공간을 일벌들이 탐색하여 먹이가 풍부한 위치를 적합도로서 표현하며 그 정보를 바탕으로 탐색 벌은 식량이 풍부한 후보지역을 중심으로 또 다른 지역을 탐색한다. 스카우트 벌은 일 벌 및 탐색 벌과는 달리 기준에 알려진 식량 위치(지역 해)중 전역 해가 존재할 가능성이 낮은 지역 해(식량 위치)를 제거하고 새로운 위치(지역 해)를 생성하는 역할을 한다[22-24]. ABC 알고리즘의 최적화 과정은 다음과 같은 과정으로 진행된다.

[Step 1] 주어진 탐색 공간 내에서 초기 집단을 생성한다. 이때 초기 집단은 일벌과 탐색 벌로 구분하여 독립적으로 생성되며 일반적으로 개체 수는 식량 지역(지역 해)의 1/2이 된다.

$$NP(t) = [s_1(t), s_2(t), \dots, s_n(t)] \quad (20)$$

$$s_i(t) = [x_1(t), x_2(t), \dots, x_D(t)] \quad (21)$$

여기서, NP는 일벌 또는 탐색 벌의 개체 수를 의미한다. 각 개체  $s_i(t)$ 는 D차원의 벡터로 구성되며 최적화하기 위한 파라미터 수를 의미한다.

[Step 2] 식 (22) 통해 n개의 일벌생성하고 목적함수 평가 및 적합도 생성

$$x_{ij}^{new}(t+1) = x_{ij}(t) + \phi_{ij}(x_{ij}(t) - x_{kj}(t)) \quad (22)$$

여기서,  $\phi$ 은 [-1 1]사이의 난수를 의미한다.

[Step 3] [step 2]의 적합도를 가지고 식(23)을 이용하여 확률 값으로 변환

$$p_i = \frac{fit_i}{\sum_{j=1}^s fit_j} \quad (23)$$

여기서,  $i$ 는 개체의 수를 나타낸다.

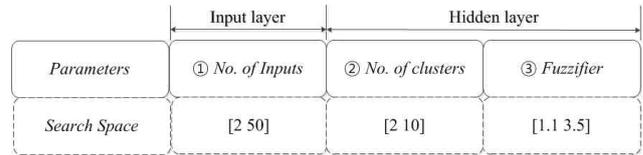
[Step 4] 확률 값이 큰 식량 지역을 우선순위로 식(22)를 이용하여 n개의 정찰 벌을 생성하고 목적함수 평가 및 적합도 생성

[Step 5] 기존 식량지역 주변에 우수한 식량 자원 탐색 횟수가 제한조건을 넘어가면 스카우트 벌을 통해 해당 식량지역 정보를 삭제하고 새로운 식량 지역을 임의로 생성

[Step 6] 종료 조건을 만족 할 때 까지 [Step 2] ~[Step 5] 반복 수행

## 5.2 ABC를 이용한 분류기의 최적화 방법

본 논문에서는 ABC 최적화 알고리즘을 통해 흑색 플라스틱 선별을 위한 퍼지 클러스터링기반 신경회로망 분류기의 구조 및 파라미터를 최적화 한다. ABC를 이용하여 제안된 분류기의 입력 변수의 수와 은닉층에서 FCM 클러스터링의 클러스터 수 그리고 퍼지화 계수 등 총 세 개의 파라미터를 최적화 한다.



### Interpretation of parameters

- ① Number of input variables after PCA
- ② Number of clusters of FCM
- ③ Fuzzifier of FCM

그림 5 최적화 알고리즘의 파라미터 구조

Fig. 5 Parametric structure of optimization algorithm

학습 데이터의 패턴 분류율과 검증 데이터의 패턴 분류율의 평균값을 ABC 알고리즘의 목적함수로 사용한다.

$$Objective Function = TR \times (1 - \theta) + VR \times \theta \quad (24)$$

여기서, TR은 학습 데이터의 패턴 분류율(pattern classification rate on training dataset)을 의미하며 VA는 검증 데이터의 패턴 분류율을 나타낸다.  $\theta$ 는 비중계수로 학습 데이터 및 검증 데이터의 영향력을 결정한다. 실험에서는 0, 0.5, 1로 설정하였다.

## 6. Artificial Bee colony를 이용한 최적화 과정

본 실험에서는 총 400개의 데이터를 사용한다. 실제 재활용 센터에서 라만 분광법을 통해 PET, PP, PS 재질별 100개씩 수집하고 실제 컨베이어 벨트에 시료가 없는 경우도 라만 분광법으로 측정하여 100개를 수집하였다. 라만 분광법은 컨베이어 벨트위에 시료의 유무를 알 수 없는 상태에서 항상 일정한 간격으로 빛을 방출하기 때문에 실제 자동선별 시스템에서는 재질이 없는 경우의 수도 고려해주기 위해서다 또한 분류기의 구조를 최적화시키기 위해 아래와 같은 ABC 알고리즘의 파라미터를 설정하여 최적화를 수행한다.

제안된 분류기의 패턴 분류율은 식(25)를 통해 계산된다.

$$CR = \frac{1}{N} \sum_{k=1}^N I(y_k = \hat{y}_k), \quad I = \begin{cases} 1 & \text{If } y_k = \hat{y}_k \\ 0 & \text{Otherwise} \end{cases} \quad (25)$$

성능평가는 5 폴드 교차 검증(fold cross validation)을 사용하였다. 일반적으로 5fcv는 데이터를 학습(Training)과 실험(Testing) 데이터로 분할한다. 하지만 최적화시 학습데이터의 성

표 2 ABC 알고리즘의 초기 파라미터 설정

Table 2 Initial setting of parameters in ABC algorithm

Parameters	Initial values
No. of generations	60
No. of food sources	30
No. of employed bees	15
No. of onlooker bees	15
Limit for scout bee	5
<b>Search Space</b>	<b>Range</b>
No. of Input variables( <i>In</i> )	[2 50]
No. of clusters in FCM( <i>R</i> )	[2 10]
Fuzzification coefficient in FCM( <i>m</i> )	[1.1 3.5]
<b>Method for generating input variables</b>	<b>No. of input variables before PCA</b>
Case I: Chemical peaks-based dataset	246
Case II: Entire dataset	3001

1st of 5fcv	Testing	Training	Training	Training	Training
2nd of 5fcv	Training	Testing	Training	Training	Training
3rd of 5fcv	Training	Training	Testing	Training	Training
4th of 5fcv	Training	Training	Training	Testing	Training
5th of 5fcv	Training	Training	Training	Training	Testing

(a) In case without optimization

1st of 5fcv	Testing	Training	Training	Training	Validation
2nd of 5fcv	Validation	Testing	Training	Training	Training
3rd of 5fcv	Training	Validation	Testing	Training	Training
4th of 5fcv	Training	Training	Validation	Testing	Training
5th of 5fcv	Training	Training	Training	Validation	Testing

(b) In case with optimization

그림 6 5 폴드 교차 검증 데이터 구성

Fig. 6 Data configuration of 5-fold cross validation

능을 목적함수로 사용하면 과적합이 발생하기 때문에 그림 6와 같이 검증(Validation) 데이터를 추가로 분할하여 학습과 검증 데이터를 이용하여 최적화를 수행하였으며 실험 데이터는 최적화 후의 분류기 성능을 평가하는 하는데 사용된다.

표 3은 제안된 분류기의 패턴 분류율을 최적화 유무에 따라 정리하였다. 표 3(a)는 최적화를 사용하지 않고 분류기의 입력변수의 수 및 클러스터의 수 등의 파라미터를 임의로 설정하였으며, 5fcv를 통해 성능을 평가하였다 이 때 검증(validation) 데이터가 학습데이터에 포함되어 학습 및 실험 데이터의 2분할로 패턴 분류율을 나타내었다. 표 3(b)는 ABC 최적화 알고리즘을 통해 얻어진 최적의 분류기 파라미터 및 패턴 분류율을 나타낸다.

라만 분광법을 통해 획득한 파형을 화학적 특성 분석 없이 주 성분 분석법을 통한 차원 축소를 한 Case II의 경우가 전반적으로 학습 및 실험 데이터의 패턴 분류율이 우수함을 알 수 있다. Case I의 경우 입력변수의 수가 10개 와 20개 일 때 실험 데이터의 패턴 분류율이 92%로 가장 높게 나왔으며, Case II는 입력

표 3 제안된 분류기의 성능평가

Table 3 Pattern classification rate without optimization

(a) Without ABC optimization

Case	<i>In</i>	<i>R</i>	<i>m</i>	Training_CR		Testing_CR	
				Mean	STD	Mean	STD
I	10	2	2.0	92.75	1.28	92.00	4.38
				93.38	1.11	91.75	4.89
				93.44	0.91	92.00	3.38
				93.44	1.34	91.75	4.20
				94.88	1.05	91.50	5.55
	20	2		95.38	1.11	91.25	5.99
				95.38	1.11	92.00	4.73
				95.69	1.09	91.50	5.26
				95.44	0.90	90.50	5.20
				96.06	0.98	91.50	5.62
	30	2		96.13	0.90	90.75	5.05
				95.94	0.83	90.75	5.05
				96.44	1.26	90.75	6.29
				96.69	1.05	91.50	5.41
				96.38	1.34	90.75	5.12
	40	2		96.63	1.28	90.75	4.73
				97.31	0.87	89.75	8.17
				97.38	1.22	89.75	8.72
				97.13	1.28	90.00	6.90
				97.31	1.39	89.00	7.15
II	10	2	94.50	1.48	92.50	4.51	
			94.81	1.54	92.50	4.59	
			94.81	1.51	92.75	4.87	
			94.88	1.22	92.50	4.59	
			95.38	1.49	94.00	4.09	
	20	2	96.19	1.24	94.25	3.26	
			95.88	1.39	94.00	3.69	
			96.00	1.20	93.75	3.54	
			95.81	1.34	94.50	4.01	
			96.50	0.95	94.25	3.38	
	30	2	96.25	1.29	94.50	3.38	
			96.38	1.12	94.50	3.38	
			97.13	0.60	94.25	4.20	
			97.06	0.65	95.00	3.42	
			96.63	0.81	95.00	3.42	
	40	2	96.94	0.68	95.00	3.42	
			97.56	0.46	94.75	4.37	
			97.75	0.26	95.00	4.15	
			97.56	0.46	95.00	4.15	
			97.56	0.46	94.75	4.18	

In: Number of input variables after PCA; R: Number of nodes in the hidden layer; m: Fuzzification coefficient

(b) With ABC optimization

Case	$\theta$	<i>In</i>	<i>R</i>	<i>m</i>	Training_CR		Validation_CR		Testing_CR	
					Mean	STD	Mean	STD	Mean	STD
I	0	11	4	3.0	92.25	1.52	93.25	4.56	93.00	4.29
	0.5	21	4	1.3	98.08	0.86	91.50	6.21	91.25	5.93
	1	50	5	1.1	100.00	0.00	74.25	6.99	73.25	4.89
II	0	34	3	1.6	97.83	0.75	95.75	3.14	95.75	3.14
	0.5	50	3	1.6	98.67	0.19	95.75	3.60	94.75	4.18
	1	50	5	1.1	100.00	0.00	86.00	6.00	83.75	4.42

In: Number of input variables after PCA; R: Number of nodes in the hidden layer; m: Fuzzification coefficient

변수의 수가 40개 및 50개에서 패턴 분류율일 95%로 총 400개 중 20개를 오 분류하였다. 표 3(b)는 ABC 최적화 알고리즘을 통해 Case별 최적 파라미터를 동조하였으며 그 때의 패턴 분류율을 보여준다. 목적함수의 비중 계수를  $\theta=0,0.5,1$ 과 같이 세 개의 서로 다른 값을 설정하여 최적화를 수행하였으며,  $\theta=0$ 일 때 가장 우수한 성능을 나타낸다. 최적화를 통해 Case I은 92%에서 93%로 상승하였으며 Case II는 95%에서 95.75%로 상승하였다.

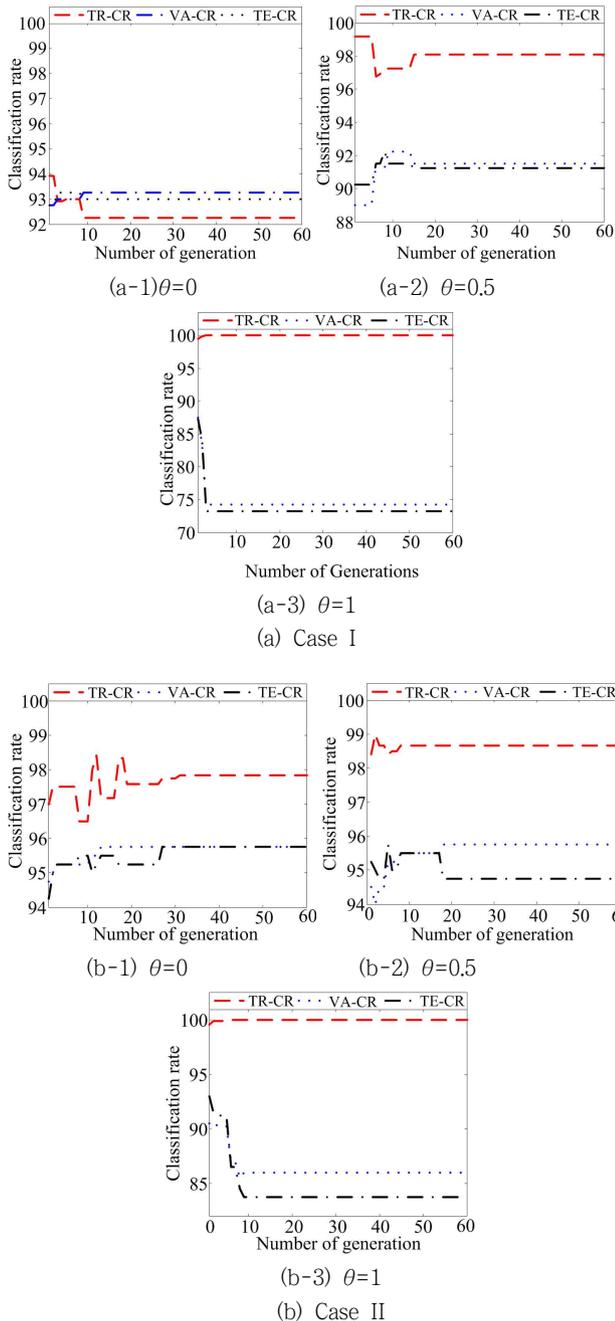


그림 7 비중 계수에 따른 세대별 패턴 분류율  
 Fig. 7 Pattern classification rate by number of generations according to portion coefficients

그림 7은 비중 계수의 변화에 따른 세대별 패턴 분류율의 수렴 과정을 보여준다.  $\theta=0$  일 때 검증 데이터의 패턴 분류율이 상승과 함께 실험 데이터의 패턴 분류율도 상승한다.  $\theta=1$ 에서는 Case I과 II 모두 최적화의 탐색 범위의 최대 조건(입력변수의 수: 50, 클러스터의 수: 5)을 찾는 최적화가 진행되며 학습 데이터의 패턴 분류율은 100%에 도달하지만 과적합이 발생하여 검증 데이터의 성능은 74.25%(Case I) 및 86.00%(Case II)에 머무르는 동시에 실험 데이터의 성능도 73.25%(Case I) 및 83.75%(Case I)를 나타낸다.

표 4는  $\theta=0$ 일 때 각 재질별 분류 성공 및 실패 개수를 나타낸다. Case I의 경우 재질 중 PET의 분류 실패 개수가 12개로 가장 많았다. 12개중 PP로 6개, PS로 6개씩 PET를 다른 재질로 분류하였다. 그 다음으로는 컨베이어 벨트를 PET로 7개 PS로 3개씩 분류 실패하였다. Case II도 PET 재질의 분류 실패 개수가 12개로 가장 많았으며 각각 PP로 3개, PS로 8개를 각각 기록하였다. 하지만 컨베이어의 분류 실패 개수가 2개로 Case I보다 상당한 높은 성공률을 나타낸다. 실제 재활용 센터에서 사용되는 라만 장비의 재질 측정시간 및 재질과 센서의 이격거리등과 같은 설치 조건들의 변화를 통해 성능 향상을 기대할 수 있다.

표 4 플라스틱 재질별 분류 성공/실패 개수

Table 4 Number of classification success/failure by plastic materials

(a) Case I: Chemical peak points-based dataset

	PET	PP	PS	Belt
PET	88/100	6/100	6/100	0/100
PP	2/100	97/100	0/100	1/100
PS	1/100	2/100	97/100	0/100
Belt	7/100	0/100	3/100	90/100

(b) Case II: Entire dataset

	PET	PP	PS	Belt
PET	88/100	3/100	8/100	1/100
PP	0/100	99/100	1/100	0/100
PS	0/100	2/100	98/100	0/100
Belt	2/100	0/100	0/100	98/100

## 7. 결 론

본 논문에서는 흑색 폐플라스틱의 재질별 자동분류를 위해 퍼지 클러스터링기반 신경회로망 패턴 분류기를 제안하였다. 라만 분광법을 이용하여 흑색 플라스틱의 재질별 파형을 획득하고 화학적 특성과 비교하여 재질마다 가장 잘 나타나는 고유 특성 점을 두 개씩 선택하여 입력변수를 생성 및 화학적 특성 분석없이 순수 파형을 이용하여 입력변수를 생성하는 방법을 고려했었다. 라만 분광법 및 특성 점을 이용한 입력차원은 고차원으로 구성되어 때문에 주성분 분석법을 통해 저차원의 특징 데이터로 변환하여 분류기의 입력으로 사용하였으며 퍼지 클러스터링기반 신경회로망을 통해 입력정보를 이용하여 플라스틱 재질을 선별하였다.

퍼지 클러스터링기반 신경회로망은 단일 신경회로망 구조를 기본으로 하며 은닉층에 FCM 클러스터링을 사용하여 입력공간을 데이터간의 유사성을 바탕으로 클러스터와 데이터간의 거리를 퍼지수로 나타내어 은닉층 출력으로 사용하였다. 또한 연결가중치는 1차선형식을 사용하였으며 각 연결가중치를 독립적으로 학습시키기 위해 지역 최소자승법을 사용하였다. 나아가 최적의 분류기를 설계하기 위해 ABC 최적화 알고리즘을 적용하여 입력변수의 수 및 클러스터의 수 그리고 퍼지화 계수 등을 최적화하여 성능을 개선하였다. 실험에 사용된 데이터는 실제 재활용 센터에서 구축된 선별시스템에서 직접 추출하였으며 실험을 통해 화학적 특성 분석없이 라만 장비로부터 취득된 순수 파형을 가공해 입력변수를 사용한 경우가 화학 분석을 이용하는 방법(Case 1)보다 전체적인 성능이 우수함을 보인다. 라만 장비의 위치 및 파라미터의 수정을 통해 제안된 패턴 분류기의 성능 향상을 기대할 수 있다.

### 감사의 글

This study was supported by the R&D Center for valuable Recycling(Global-Top R&D Program) of the Ministry of Environment.(Project No.2016002250002)

### References

- [1] K.I. Seo, "A Study on Development of Automatic Sorting for Recyclable Materials by Visible Rays and Near-Infrared Ray(NIR) Sensor," Ph.D dissertation, Dept. Energy and Environmental Engineering, Seoul National University of Technology, Seoul, 2010.
- [2] R. K. Khanna, M. Junker, A. Zumbusch, and H. Schnokel, "Raman-spectroscopy of Oligomeric SiO Species Isolated in Solid Methane," *Journal of Chemical Physics*, vol. 111, no. 17, pp. 7881-1881, Aug. 1999.
- [3] H. Masoumi, S. M. Safavi, and Z. Khani, "Identification and classification of plastic resins using near infrared reflectance spectroscopy," *International Scholarly and Scientific Research & Innovation*, vol. 6, no. 5, pp. 877-884, 2012.
- [4] A. Tsuchida, Y. Tsuchida, T. Yoshida, K. Arikata and H.Kawazumi, "Versatile waste plastic identifier based on raman spectroscopy for material recycle," 7th International Symposium on Feedstock Recycling of Polymeric Materials (7th ISFR 2013), New Delhi, India, 23-26, 2013.
- [5] H. Kawazumi, A. Tsuchida, , T. Yoshida, Y. Tsuchida, "High-Performance Recycling System for Waste Plastics Using Raman Identification," *Progress in Sustainable Energy Technologies* vol II, pp. 519-529, 2014.
- [6] J. R. Anema, A. G. Brolo, A. Felten, and C. Bittencourt, "Surface-enhanced Raman Scattering from Polystyrene on Gold Clusters," *Journal of Raman Spectroscopy*, vol. 41, no. 7, pp. 745-751, July 2010.
- [7] J. N. Choi, Y. I. Lee, and S. K. Oh, "Fuzzy Radial Basis Function Neural Networks with Information Granulation and Its Genetic Optimization," *Lecture Notes in Computer Science*, vol. 5552, pp. 127-134, 2009.
- [8] A. Y. A. Omary and M. S. Jamil, "A New Approach of Clustering Based Machine-Learning Algorithm," *Knowledge-Based Systems*, vol. 19, no. 4, pp. 248-258, 2006.
- [9] K. M. O. Bryson, "Towards Supporting Expert Evaluation of Clustering Results Using A Data Mining Process Model," *Information Sciences*, vol. 180, no. 3, pp. 414-431, 2010.
- [10] M. Liu, X. Jiang, and A. C. Kot "Multi-Prototype Clustering Algorithm," *Pattern Recognition*, vol. 42, no. 5, pp. 689-698, 2009.
- [11] H. Zhou, Y. Liu, L. Li, and B. Wei, "A Clustering Approach to Free Form Surface Reconstruction from Multi-View Range Images," *Image and Vision Computing*, vol. 27, no. 6, pp. 725-747, 2009.
- [12] P. Minicozzi, F. Rapallo, E.Scalas, and F. Donderob, "Accuracy and Robustness of Clustering Algorithms for Small-Size Applications in Bioinformatics," *Physica A: Statistical Mechanics and its Application*, vol. 387, no. 25, pp. 6310-6318, 2008.
- [13] S. K. Oh, W. D. Kim, and W. Pedrycz, "Design of radial basis function neural network classifier realized with the aid of data preprocessing techniques: design and analysis," *International Journal of General Systems*, vol. 45, no. 4, pp. 434-454, Dec. 2016.
- [14] S. K. Oh, W. D. Kim, W. Pedrycz, and B. J. Park, "Polynomial-based radial basis function neural networks (P-RBF NNs) realized with the aid of particle swarm optimization," *Fuzzy Sets and Systems*, vol. 163, no. 1, pp. 54-77, Jan. 2011.
- [15] Gnosys Global Ltd, "PET Analysis," TSAN11- Application Notes.
- [16] M. A. De Baez, P. J. Hendra, and M. Judkins, "The Raman Spectra of Oriented Isotactic Polypropylene," *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, vol. 51, no. 12, pp. 2117-2124, Nov. 1995.
- [17] D. H. Zhang, J. G. Qin, J. S. Shen, Y. Wang, and W. J. Liu, "Study on The Concentration Dependence of Orientation of Polystyrene on Siver by The Sers Technique," *Chinese Journal of Polymer Science*, vol. 18, no. 2, pp. 177-180, April 2000.

[18] I. T. Jolliffe, "Principal Component Analysis." New York: Springer, 2002.

[19] E.-H. Kim, S.-K. Oh, and H.-K. Kim, "Comparative Analysis of Learning Methods of Fuzzy Clustering- based Neural Network Pattern Classifier," The Transactions of the Korean Institute of Electrical Engineers, vol. 65, no. 9, pp. 1541-1550, 2016.

[20] J. C. Bezdek, "Pattern Recognition with Fuzzy Objective Function Algorithms," Plenum, New York, 1981.

[21] J. C. Bezdek, R. Ehrlich, and W. Full, "FCM: The Fuzzy C-Means Clustering Algorithm," Computers & Geoscience, vol. 10, no. 2-3, pp. 191-203, 1984.

[22] D. Karaboga, B. Akay, "A Comparative Study of Artificial Bee Colony Algorithm," Applied Mathematics and Computation, vol. 214, pp. 108-132, 2009.

[23] S. Shi, C. M. Pun, H. Hu, and Hao Gao, "An improved artificial bee colony and its application," Knowledge-Based Systems, vol. 107, no. 1, pp. 14-31, Sep. 2016.

[24] D. Dervis Karaboga, "An Idea Based On Honey Bee Swarm for Numerical Optimization," Technical Report-TR06, Erciyes University, Engineering Faculty, Computer Engineering Department 2005.



**배종수 (Jong-Soo Bae)**

2015년 수원대학교 전기공학과 공학사, 동 대학원 석사(2017). 관심분야는 퍼지 추론 시스템, 뉴럴 네트워크, 진화론적 최적화 알고리즘, GranularComputing 등.

Tel : 031-222-6544

Fax : 031-220-2667

E-mail : inkansoo@suwon.ac.kr



**오성권 (Sung-Kwun Oh)**

1981년 연세대학교 전기공학과 공학사, 동 대학원 석사(1983), 박사(1993), 1983~1989년 금성산전연구소(선임연구원). 1996~1997년 캐나다 Manitoba 대학 전기 및 컴퓨터공학과 Post-Doc. 1993~2004년 원광대학교 전기전자 및 정보공학부 교수, 2005~현재

수원대학교 전기공학과 교수. 2002~현재 대한전기학회, 퍼지및 지능시스템학회 편집위원, 2013년~현재 Information Sciences 편집위원. 관심분야는 퍼지 시스템, 퍼지-뉴럴 네트워크, 자동화 시스템, 고급 computational intelligence, 지능 제어 등.

Tel : 031-229-8162

Fax : 031-220-2667

E-mail: ohsk@suwon.ac.kr

**저 자 소 개**



**김은후 (Eun-Hu Kim)**

2009년 수원대학교 전기공학과 공학사, 동 대학원 석사(2011), 박사(2016), 2016~현재 수원대학교 전기공학과 Post-Doc. 관심분야는 퍼지 이론, 신경 회로망, 클러스터링, 최적화 알고리즘, 컴퓨터 지능 및 지능 제어 등.

Tel : 031-222-6544

Fax : 031-220-2667

E-mail: wdskim@suwon.ac.kr