

논문 2009-46CI-1-13

# 다단계 특징벡터 기반의 분류기 모델

## (Multistage Feature-based Classification Model)

송 영 수\*, 박 동 철\*\*

(Young-Soo Song and Dong-Chul Park)

### 요 약

본 논문은 다단계 특징벡터를 이용한 분류기 모델(Multistage Feature-based Classification Model: MFCM)을 제안하는데, MFCM은 주어진 데이터에서 추출된 특징벡터 전체를 한 번에 이용하지 않고, 같은 성질들의 특징벡터들끼리 모아, 여러 단계에 걸쳐서 분류에 이용한다. 학습단계에서, 같은 성질을 가지는 특징벡터 그룹 각각을 이용하는 국지적 분류기의 분류 정확도 산출을 통해 각 특징벡터그룹의 기여도를 측정한다. 분류단계에서는 각 특징벡터그룹의 기여도에 따라 차등적으로 가중치를 적용하여 최종적인 분류결론을 이끌어 낸다. 본 논문에서는 MFCM의 개념을 기존의 몇 가지 분류 알고리즘에 적용하고, 음악 장르 분류 문제에 응용하여, 제안된 알고리즘의 유용성에 관한 실험을 수행하였다. 실험의 결과 제안된 MFCM을 이용하는 분류기는 기존의 알고리즘과 비교하여 분류정확도에서 평균적으로 7%-13%의 성능향상을 보여준다.

### Abstract

The Multistage Feature-based Classification Model(MFCM) is proposed in this paper. MFCM does not use whole feature vectors extracted from the original data at once to classify each data, but use only groups related to each feature vector to classify separately. In the training stage, the contribution rate calculated from each feature vector group is drew throughout the accuracy of each feature vector group and then, in the testing stage, the final classification result is obtained by applying weights corresponding to the contribution rate of each feature vector group. In this paper, the proposed MFCM algorithm is applied to the problem of music genre classification. The results demonstrate that the proposed MFCM outperforms conventional algorithms by 7% - 13% on average in terms of classification accuracy.

**Keywords :** Multistage feature, Classification model, Clustering algorithm, Music genre classification

## I. 서 론

근래에 들어, 오디오/비디오 입력장치들의 발달로 이들 입력장치들로부터 수집된 많은 양의 데이터가 여러 가지 목적으로 각종 저장장치에 저장되고 있다. 그 데이터들을 이용하여 분류 또는 인식분야에 적용하고자

하는 경우에, 아무런 가공 없이 데이터를 사용하기에는 데이터의 크기가 너무 크며, 연산량의 과다로 발생하는 문제를 해결하기 위해서 원본 데이터로부터 각 특징들을 추출하여, 그 데이터를 대표할 수 있는 특징벡터를 이용한 방법이 패턴인식 분야에서 널리 사용되어 왔다.

각 데이터 집합들을 효과적으로 분류하기 위해서는 데이터를 대표하는 특징벡터의 추출과 효율적인 군집화 알고리즘이 필요하다. 특히, 본 논문의 목적인 음악 데이터의 장르 분류를 위하여, 각 장르의 고유한 특징을 반영하기 위한 특징벡터를 추출하는 많은 연구가 진행되어 왔다<sup>[1~7]</sup>. 그 중 Music Fish Group<sup>[3]</sup>은 소리의 세기(Loudness), 높이(Pitch), 밝기(Brightness), 대역폭(Bandwidth), 화성(Harmony)과 같은 특성들을 음악 데

\* 정회원, 팬텍계열 일본모델개발실  
(PANTECH Group, Japanese Model Research Lab.)

\*\* 정회원, 명지대학교 정보공학과  
(Dept. of Information Eng., Myong Ji University)

※ 본 연구는 한국과학재단 특정기초연구 (R01-2007-000-20330-0) 지원 및 2007년도 정부의 재원으로 한국대학교수협의회 대학교수 국내교류 연구비 지원에 의한 것임.

접수일자: 2008년9월12일, 수정완료일: 2009년1월5일

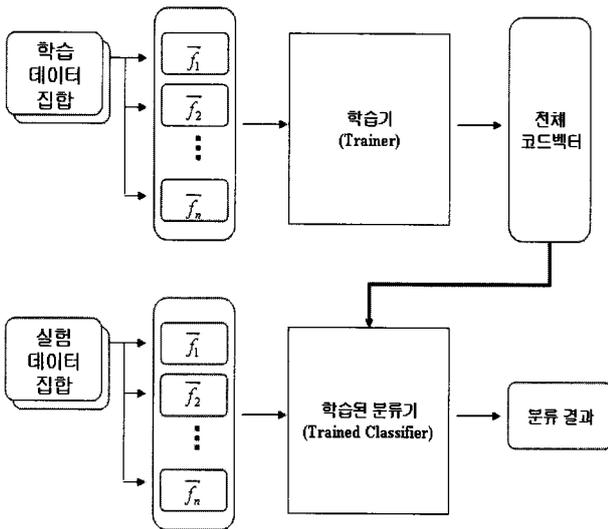


그림 1. 기존의 분류 모델  
Fig. 1. Conventional Classification Model.

이터에서 추출하도록 제안하였다. 또한 Foote<sup>[4]</sup>는 MFCC (Mel-scaled Frequency Cepstral Coefficients)<sup>[8]</sup> ~<sup>[9]</sup>를 추출하는 방법을 제안하였고, Li<sup>[5]</sup>는 이산 웨이블릿 변환을 사용하여 특성을 추출하였다. 또한, Tzanetakis와 Cook<sup>[6]</sup>은 음색의 성질(Timbral Texture), 리듬의 성질(Rhythmic Content), 음의 높이(Pitch content)와 같은 특성들을 추출하여 이용하였다.

추출된 특성들을 표현하는 특징벡터들은 각 성분이 서로 다른 특성과 크기를 가지므로, 각각의 특징벡터 성분을 같은 공간상에서 구별 없이 분류기의 입력벡터로 사용하는 것은 효과적이지 않을 수도 있다. 이를 보완하기 위한 여러 가지 방안들이 강구되고 있는데, 그 중 정규화 방법은 서로 다른 특징벡터의 성분들을 정규화 된 크기로 만들어 이용하는 방법이다. 하지만, 각 특성 성분이 여전히 같은 공간상에 구별 없이 사용되고 있으므로, 제한된 정도의 성능향상만을 기대할 수 있다. 이를 해결하기 위한 시도로, 음성인식에서는 LPC Cepstrum을 이용한 Multi-Stream 처리와<sup>[10]</sup>, 필터뱅크를 통해 얻은 서로 다른 대역의 Cepstrum 특징을 다른 입력공간에서 이용하는 Multi-Band 모델<sup>[11]</sup>을 사용하여 분류성능의 향상을 이끌어냈다. 그러나 이들 방법은 특징벡터가 단지 LPC Cepstrum에서 추출된 데이터에 한정하므로, LPC Cepstrum을 특징벡터로 사용하는 분류 문제에만 이용할 수 있는 제약조건이 있다.

본 논문은 일반적인 데이터에서 여러 가지 방법들을 통해 추출된 다양한 종류의 특징요소들을 효과적으로 이용하여, 분류기의 성능을 높이는 방법을 제안한다. 우

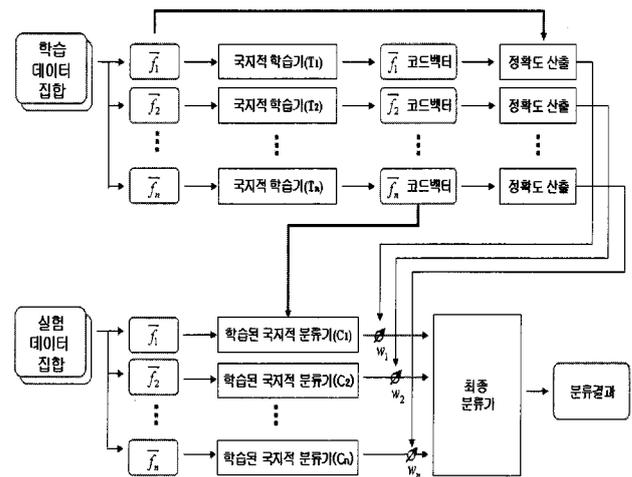


그림 2. 제안된 다단계 특징벡터를 이용하는 분류모델  
Fig. 2. Multistage Feature-based Classification Model.

리는 이 방법을 다단계 특징벡터를 이용하는 분류 모델 (Multistage Feature-based Classification Model: MFCM)이라 부른다. 제안된 분류모델은 전체의 특징요소들을 같은 의미를 가지는 요소들의 몇 개의 그룹으로 나누고, 각각의 그룹에 속하는 특징요소들을 이용해서 여러 개의 특징벡터를 구성한다. 구성된 특징벡터들은 독립적으로 서로 다른 공간상에서 국지적 분류기에 이용되므로, 각 특징벡터의 고유의 특성들을 최대한 보장 받게 된다.

본 논문의 II장에서는 제안된 분류모델에 대해 살펴보고, III장에서 분류모델에 사용할 신경망 알고리즘에 대해 간단히 알아본다. IV장에서는 실험을 통해 제안된 분류모델의 성능을 살펴보고, V장에서는 결론을 내린다.

## II. 다단계 특징을 이용하는 분류모델

우리는 여러 가지의 분류기 모델을 이용하여 효과적으로 데이터들을 분류하고 있다. 그림1에서 설명하는 것처럼, 데이터 분류는 각기 다른 집합들이 주어 졌을 때, 각 데이터 집합에 대해 군집화 알고리즘을 이용한 학습과정을 거친 후, 학습을 통해 얻은 코드벡터들을 이용하여 데이터를 분류한다. 그러나 데이터들을 분류하고자 할 때, 데이터에서 추출된 특징벡터들을 이용하게 되는데 추출 알고리즘에 따라 다양한 종류의 특징벡터들을 얻을 수 있다. 이 특징벡터들은 각각 다른 특성들과 크기를 가지므로 각각의 특징벡터들을 같은 공간상에서 학습하는 것은 각각의 특징벡터들의 고유의 특성들을 살리지 못하며, 오히려 옳지 않은 판단의 결과

값을 도출할 수 있다.

이 논문에서 제안하는 분류모델이 그림 2에 간단히 소개되었다. 제안된 분류 모델은 각 특성의 학습데이터(특징벡터)를 국지적 학습기에서 각각 학습시키고, 학습데이터에 대해 각 특성마다 정확도를 산출하여 기여도를 계산한다. 또한 실험과정에서는 각각 학습된 국지적 분류기를 가지며, 각각의 분류기에서 나온 결과 값에 각 특성에 대한 기여도를 계산하여 최종 분류기에서 최종의 분류 결과 값을 얻는다. 제안된 분류모델은 각각의 특성들에 대해 독립된 공간상에서 학습하므로 서로 다른 특징벡터들의 고유한 특성들이 서로 간섭하는 것을 방지한다. 또한 각 학습데이터에 대한 정확도 산출을 통해 각 특성들에 대한 평가 기준으로 기여도를 측정한다.

주어진 데이터  $\vec{x}$ 에서 추출한 특징벡터  $\vec{f}$ 는 같은 특성을 가지는 N개의 소그룹 특징벡터  $\vec{f}_i$  ( $i = 1, 2, \dots, N$ )로 나누어진다. 즉,

$$\vec{f} = [\vec{f}_1^T : \vec{f}_2^T : \dots : \vec{f}_N^T]^T \quad (1)$$

학습과정에서는 각각의 특징벡터  $\vec{f}_i$  ( $i = 1, 2, \dots, N$ )를 이용해서 N 개의 국지적 분류기  $C_i$ 를 독립적으로 구성하게 된다. 또한, 각각의 국지적 분류기  $C_i$ 에 학습에 사용하지 않은 검증데이터를 이용하여, 국지적 분류기  $C_i$ 의 분류정확도  $\alpha_i$ 를 구하며, N 개의 국지적 분류기의 전체 분류기에 대한 분류기여도  $\omega_i$ 를 다음의 식에 의하여 정의한다.

$$\omega_i = \frac{\alpha_i}{\sum_{j=1}^N \alpha_j} \quad (2)$$

주어진 데이터  $\vec{x}$ 에 대해, 학습된 국지적 분류기,  $\{C_1, C_2, \dots, C_N\}$ , 각각의 학습된 분류기의 기여도,  $\{\omega_1, \omega_2, \dots, \omega_N\}$ ,가 주어져 있을 때, 데이터  $\vec{x}$ 를 M 개의 클래스 중 하나의 클래스에 속하는 분류의 문제가 있다고 가정한다. 이때, 주어진 데이터  $\vec{x}$ 를 표현하는 특징벡터  $\vec{f}$ 는 식(1)에서와 같이 N개의 소그룹 특징벡터로 이루어진다고 가정한다. 주어진 데이터  $\vec{x}$ 에서 추출한  $\vec{f}_i$  ( $i = 1, 2, \dots, N$ )가 대응하는 국지적 분류기  $C_i$  ( $i = 1, 2, \dots, N$ )를 통과하면, 데이터  $\vec{x}$ 와 M 개의 군집과의 거리는 다음의 식으로 표현된다.

$$\{d_{i1}(\vec{x}), d_{i2}(\vec{x}), \dots, d_{iM}(\vec{x})\}, i = 1, 2, \dots, N \quad (3)$$

즉, 주어진  $\vec{x}$ 는 N 개의 국지적 분류기를 각각 통과하게 되며, 각각의 국지적 분류기에서는 주어진 데이터의 M 개의 군집에 대한 거리를 발생시킨다. 또한, 각각의 국지적 분류기의 기여도를 고려하여,  $\vec{x}$ 와 각 군집과의 거리를 다음의 식으로 구한다.

$$d_i(\vec{x}) = \sum_{j=1}^N \frac{d_{ji}(\vec{x})}{\omega_j}, i = 1, 2, \dots, M \quad (4)$$

여기서  $d_{ji}(\vec{x})$ 는 국지적 분류기  $j$ 에서  $\vec{x}$ 와 군집  $i$  사이의 거리를 나타내며,  $\omega_j$ 는 국지적 분류기  $j$ 의 기여도를 나타낸다. 따라서,  $\vec{x}$ 에 대한 분류 결과,  $Class(\vec{x})$ ,는 다음의 식으로 정해진다.

$$Class(\vec{x}) = \underset{i}{\operatorname{argmin}} d_i(\vec{x}), \forall i = 1, 2, \dots, M \quad (5)$$

### III. 실험에 사용된 군집화 알고리즘

현재까지 많은 군집화 알고리즘이 개발 되어 왔으며 많은 분야에 쓰이고 있다<sup>[12~17]</sup>. 그중에 대표적인 알고리즘이 Self-Organization Map (SOM)<sup>[12]</sup> 알고리즘과 Fuzzy C-Means (FCM)<sup>[13~14]</sup> 알고리즘이다. SOM 알고리즘은 수많은 논문에서 소개 되었으며, 여기서는 FCM 알고리즘과 FCM 알고리즘을 개선한 GBFCM 알고리즘<sup>[17]</sup>에 대해서 간단히 살펴본다.

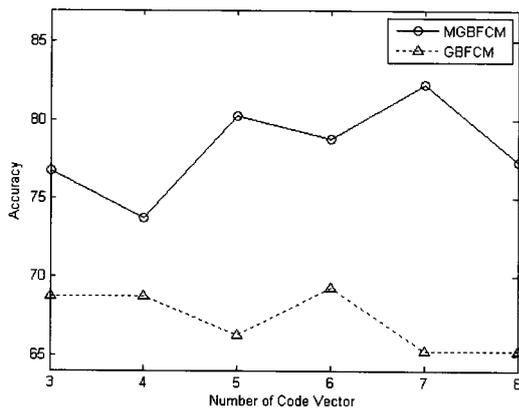
#### 1. Fuzzy C-Means (FCM) 알고리즘

Bezdek에 의해 제안되어 널리 사용되고 있는 FCM 알고리즘은 목적함수로 식(6)과 같이 정의 된다.

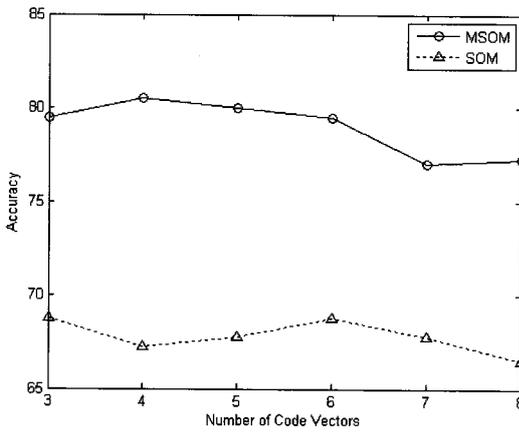
$$J(X, U, V) = \sum_{j=1}^n \sum_{i=1}^c (u_{ji})^m d_{ij}^2 \quad (6)$$

여기서  $d_{ij}$ 는 입력  $\vec{x}_j$ 와 군집의 코드벡터인  $\vec{v}_i$  사이의 Euclidean 거리를 나타내며,  $u_{ji}$ 는 군집(i)와 입력(j)사이의 멤버십 등급이다. m은 가중지수, c는 군집의 수, n은 입력데이터의 수이다. 또한 멤버십 등급의 합은 식(7)와 같이 항상 1로 제안한다.

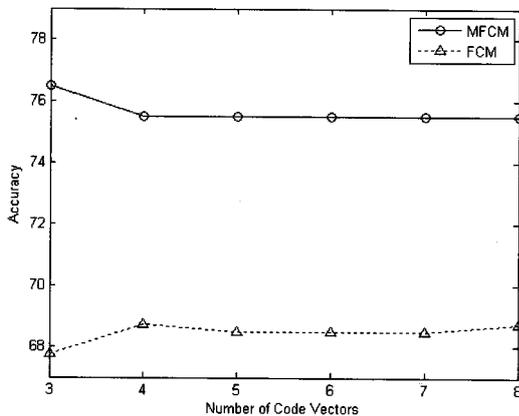
$$\sum_{i=1}^c u_{ij} = 1, \forall 1, \dots, n \quad (7)$$



(a) SOM



(b) FCM



(c) GBFCM

그림 3. 코드벡터에 따른 각 알고리즘의 분류 정확도  
Fig. 3. Classification accuracy of different algorithms with various numbers of code vectors.

Bezdek은 목적함수를 최소화시키기 위한 조건을 다음과 같이 제안하였다. 식 (8)은 멤버십 등급과 각 군집의 코드벡터를 갱신하기 위한 식이다.

$$u_{ji} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{kj}}\right)^{\frac{2}{m-1}}}, \quad v_i = \frac{\sum_{j=1}^n u_{ji}^m x_j}{\sum_{j=1}^n u_{ji}^m} \quad (8)$$

FCM에서는 식(8)과 식(9)를 반복적으로 실행하여, 코드벡터를 학습시켜 최적화된 군집결과를 얻을 수 있다.

### 2. Gradient Based Fuzzy C-Means(GBFCM)

FCM 알고리즘에서는 코드벡터를 갱신하기 위해서 모든 데이터를 사용하지만 GBFCM 알고리즘은 각 iteration에서 오직 하나의 데이터를 가지고 코드벡터를 갱신할 수 있도록 제안되었다<sup>[17]</sup>. GBFCM 알고리즘 역시 FCM에서 주어진 목적함수를 사용하는데, 최적의 코드벡터를 찾기 위한 조건으로 기울기 감소 방법을 이용한다. 식 (9)는 각 군집 코드벡터에 대한 갱신 식이다.

$$v_{i+1} = v_i - 2\eta u_{ji} (v_i - x_j) \quad (9)$$

또한, 식(10)은 GBFCM 알고리즘의 멤버십 등급을 갱신하기 위한 식이다.

$$u_{ji} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{kj}}\right)^2} \quad (10)$$

FCM과 GBFCM 알고리즘은 같은 목적함수를 사용한다는 것이 공통점이지만, FCM 알고리즘은 코드벡터를 한번 갱신하기 위해 모든 데이터가 사용되는 반면, GBFCM 알고리즘은 주어진 각각의 데이터에 대해 식 (9)와 식(10)을 교대로 적용하며, 최적의 코드벡터와 멤버십 등급을 구하게 되고, 학습시간과 정확성에서 더 낫은 결과를 얻는다<sup>[17]</sup>.

## IV. 실험 및 결과

우리는 제안된 분류 모델을 이용하여 클래식, 컨트리, 힙합, 재즈의 각각의 음악장르를 분류하기 위한 실험을 하였다. 이 실험에서의 음악 데이터는 오디오 CD나 인터넷 사이트에서 다양하게 수집되었으며, 각각의 데이터들은 다른 포맷과 다른 주파수로 구성 되어 있으므로 같은 조건에서 특징벡터를 얻기 위하여 22,050 Hz, 16 bit mono 파일들로 동일하게 변환하였다. 실험을 위해서 클래식, 컨트리, 힙합, 재즈의 4개의 음악 장르의 음악을 각 30초의 길이로 각 장르 당 300개씩, 총 1,200개

데이터를 수집하였으며, 수집된 데이터의 총 시간은 10 시간이다.

음악 데이터에서 특징벡터들을 얻기 위하여 Tzanetakis와 Cook<sup>[1]</sup>이 개발한 공개 소스 코드인 Marsyas 프로그램을 사용 하였는데, 하나의 음악 데이터에서 9차원 FFT 계수, 10차원 MFCC 계수, 24차원 DWT 계수의 총 43차원 특징벡터를 추출했다. 또한 제안된 분류모델을 비교하기 위하여 3가지 특성 전부를 이용하여 43차원 특징 벡터를 학습하는 기존 방법과 이 논문에서 제안한 각 특성들을 독립적으로 이용하는 분류모델을 서로 비교 분석했다. 또한 각 데이터들을 학습하기 위하여 군집화 알고리즘인 SOM, FCM, GBFCM 알고리즘을 이용하였다.

이 실험에서 각 장르의 300개 중 무작위로 추출한 200개의 데이터는 학습데이터로 사용하였으며 나머지

표 1. 여러 모델의 분류정확도 (%)  
Table 1. Classification accuracy of different algorithms.(%)

	클래식	컨트리	힙합	재즈	평균 정확도
SOM	85	50	68	72	68.75
FCM	92	46	73	63	68.5
GBFCM	88	47	74	68	69.25
MFCM SOM	94	63	86	75	79.5
MFCM FCM	100	54	85	64	75.5
MFCM GBFCM	100	77	97	55	82.25

표 2. 제안된 분류모델의 대한 혼동 테이블  
Table 2. Confusion table for the proposed MFCM.

(a) MFCM SOM

	클래식	컨트리	힙합	재즈
클래식	94	0	0	6
컨트리	26	63	7	4
힙합	0	14	86	0
재즈	11	10	4	75
정확도	79.5			

(b) MFCM FCM

	클래식	컨트리	힙합	재즈
클래식	100	0	0	0
컨트리	25	54	13	8
힙합	0	15	85	0
재즈	18	15	3	64
정확도	75.5			

(c) MFCM GBFCM

	클래식	컨트리	힙합	재즈
클래식	100	0	0	0
컨트리	22	77	0	1
힙합	0	3	97	0
재즈	13	31	1	55
정확도	82.25			

100개의 데이터는 검증데이터로 사용하였다. 그림 2는 코드벡터의 수가 증가함에 따른 각각의 알고리즘의 정확도를 나타낸다. 그림 3 (a)는 SOM 알고리즘을 바탕으로 실험한 결과이며, (b)는 FCM 알고리즘에 대한 분류 정확도를 나타낸다. 그림 3의 (a), (b) 에서와 같이 평균적으로 SOM, FCM 알고리즘의 기존 분류모델은 각 코드벡터에서 70%의 결과 값을 넘지 못하는 반면, 제안된 분류모델을 적용한 분류기는 80% 정도의 정확도를 산출해 내고 있다. 각 알고리즘에서 코드벡터의 수에 상관없이 평균적으로 기존의 분류모델보다 제안된 분류모델이 10%이상의 높은 정확도를 갖는다.

표 1은 코드벡터의 수가 6개 일 때 각 알고리즘에서의 최종 정확도를 나타내는데 제안된 분류모델에서 클래식 장르는 모든 알고리즘에서 이상적인 결과를 보이며, 컨트리, 힙합, 재즈 장르에서도 평균적으로 기존의 알고리즘보다 좋은 성능을 보인다. 클래식 장르는 다른 장르에 비해 높은 정확도를 가지므로 이 실험에 사용된 특성들은 다른 장르보다 클래식 장르를 분리해 내기에 더 적합하다. 표 2에서는 제안된 분류모델에 대한 혼동 테이블을 나타낸다. 모든 알고리즘에서 컨트리 장르의 25% 정도가 클래식 장르로 분류 되었는데 컨트리 장르가 클래식 장르와 많은 부분이 비슷하다는 것을 나타낸다. 또한 재즈 장르는 다른 장르들에 고르게 분류되었다. 이는 재즈 장르가 음악적으로 다른 장르들의 특징을 공유하는 것에 기인하는 것으로 유추된다.

## V. 결 론

본 논문에서는 데이터를 표현하는 여러 가지의 특성을 같은 성질의 특성을 나타내는 것들의 그룹으로 나누고, 각 그룹의 특성들을 한 개의 특징벡터로 구성한다. 따라서 본 논문의 모델에서는 각각의 데이터가 몇 조각의 특징벡터를 이용해 표현되는데, 이는 기존의 분류기 모델에서 특징벡터가 각 데이터마다 1개씩 존재하는 것과 대비 된다. 본 논문의 모델에서는 각 데이터 마다 존재하는 여러 조각의 특징벡터들을 각각 독립적으로 이용하는 국지적 분류기를 구성하게 되며, 학습에서 국지적 분류기의 분류정확도를 계산하여, 각각의 국지적 분류기의 전체 분류에 대한 기여도로 사용한다. 본 논문에서는 SOM, FCM, GBFCM 알고리즘을 기반으로 하는 기존의 분류모델과 제안된 분류모델(MFCM)에 적용하여 실험에 사용하였다. 기존의 분류모델에서는 각 음

악장르에서 추출된 여러 특성들을 하나의 벡터로 하기 때문에 고유의 특성들을 독립적으로 사용하지 못하였으나, 제안된 분류모델을 사용하였을 경우에는 각 특성을 최대한 보장하며 분류하므로 상대적으로 높은 성능을 얻을 수 있었다.

실험에서는 4가지의 음악장르를 분류하기 위해 다양한 특징벡터들과 군집화 알고리즘을 사용하였으며, 제안된 분류모델을 이용하였을 경우 기존 분류모델보다 SOM은 10.75%, FCM은 7%, GBFCM은 13%의 개선된 결과를 얻을 수 있었다. 그러나 실험의 결과에서 보듯이 재즈와 컨트리의 분류결과가 만족스럽지 못했는데, 이들 음악의 분류에 효율적인 특징벡터의 추출에 대한 연구가 계속되어야 할 것이다.

### 참 고 문 헌

- [1] N. Scaringella, G. Zoia, and D. Mlynek, "Automatic genre classification of music content: a survey," *IEEE Signal. Proc. Mag.*, V. 23, No.2, pp. 133-141, 2006.
- [2] K. Kim, S. Kim, J. Jeon, K. Park, "Quick Audio Retrieval Using Multiple Feature Vectors," *IEEE Trans. Consumer Electronics*. V. 52, No.1, 2006.
- [3] E. Wold, T. Blum, D., Keislar, and J. Wheaton, "Content-based classification, search, and retrieval of audio", *IEEE Trans. Multimedia*, V.3, No.3, pp 27-36. 1996.
- [4] J. Foote, "Content-based retrieval of music and audio", *Proc. SPIE, Multimedia Storage and Archiving Systems*, pp 138-147. 1997.
- [5] G. Li, and A. Khokar, "Content-based indexing and retrieval of audio data using wavelets", *Proc. Int. Conf. Multimedia Expo.* pp 885-888. 2000.
- [6] G. Tzanetakis, and P. Cook, "Musical genre classification of audio signals", *IEEE Trans. Speech Audio Process.* V. 10, No.5, pp. 293-302, 2002.
- [7] Y. Song and C. Zhang, "Content-Based Information Fusion for Semi-Supervised Music Genre Classification," *IEEE Trans. Multimedia*, V.10, No.1, pg. 145-152, 2007.
- [8] 정성윤, 김민성, 손종목, 배건성, "PCA-optimized 필터뱅크 기반의 MFCC 특징파라미터 추출 및 한국어 4연숫자 전화음성에 대한 인식실험," 전자공학회논문지, 제41권 SP편, 6호, 279-2839쪽, 2004년 6월
- [9] 박찬웅, "은닉 마코프 모델과 캡스트럴 계수들에 따른 한국어 속삭임의 인식 비교," 전자공학회논문지, 제43권 IE편, 제2호, 22-29쪽, 2006년 2월
- [10] H. Christensen, B. Lindberg, and O. Andersen, "Employing heterogeneous information in a multi-stream framework", *Proc. IEEE Int. Conf. ICASSP '00 Vol 3.* pp 1571-1574. 2000.
- [11] S. Okawa, and E. Bocchieri, A. Potamianos, "Multi-band speech recognition in noisy environments", *Proc. IEEE Int. Conf. ICASSP '98 Vol 2.* pp 641-644. 1998.
- [12] T. Kohonen, "The Self-Organizing Map", *Proc. IEEE*, Vol. 78. pp 1464-1480. 1990.
- [13] J. C. Bezdek, "A convergence theorem for the fuzzy ISODATA clustering algorithms", *IEEE Trans. Pattern Anal. Mach. Int.*, Vol. 2. pp 1-8. 1980.
- [14] 광현욱, 오준택, 손영호, 김옥현, "엔트로피 기반의 가중치와 분포크기를 이용한 향상된 FCM 알고리즘," 전자공학회논문지 제43권 SP편, 제4호, 1-8쪽, 2006년 4월
- [15] D.-C Park, and Y.-J. Woo, "Weighted Centroid Neural Network for Edge Preserving Image Compression", *IEEE Trans. Neural Networks*, V.12, No. 5, pp 1134-1146. 2001.
- [16] D.-C Park et al., "Centroid Neural Network with a Divergence Measure for GPDF Data Clustering", *IEEE Trans. Neural Networks*, V.19, No. 6, pp 948-957. 2008.
- [17] Carl Looney, *Pattern Recognition Using Neural Networks*, Oxford University Press, New York, pp 252 -254, 1997.

저 자 소 개



송 영 수(정회원)  
 2006년 명지대학교 정보공학과  
 학사 졸업.  
 2008년 명지대학교 정보공학과  
 석사 졸업.  
 2009년 현재 팬택계열 일본모델  
 개발실 연구원.

<주관심분야 : 신경망, 인공지능, 신호처리>



박 동 철(정회원)  
 1980년 서강대학교 전자공학과  
 학사 졸업.  
 1982년 한국과학기술원 전기 및  
 전자공학과 석사 졸업.  
 1990년 Univ. of Washington,  
 Seattle, Dept. of Electrical  
 Eng. 박사 졸업.

2009년 현재 명지대학교 정보공학과 교수.

<주관심분야 : 지능컴퓨팅, 신호처리>