

스펙트럼 대비 MFCC 특징의 음악 장르 분류 성능 분석

Study on the Performance of Spectral Contrast MFCC for Musical Genre Classification

서진수*
(Jin Soo Seo*)

*강릉원주대학교 전자공학과

(접수일자: 2010년 3월 25일; 채택일자: 2010년 5월 13일)

본 논문에서는 새로운 형태의 스펙트럼 특징인 스펙트럼 대비 MFCC (SCMFCC)를 제안하고 음악 장르 분류 성능을 분석하였다. 음악 장르 분류를 위해서는 장르 간의 차이를 두드러지게 할 수 있는 특징을 사용해야 하므로, 음악의 화음 구조 및 강약을 잘 표현하는 스펙트럼 대비 특징들이 관심을 받아왔다. 본 논문에서 제안된 SCMFCC는 멜-스펙트럼 상에서 스펙트럼의 대비를 이용하여 기존의 MFCC를 음악 분류에 적합하도록 변형했다. 널리 사용되고 있는 음악 장르 데이터베이스에서 실험을 수행하여, 제안된 SCMFCC 특징의 음악 장르 분류 성능을 기존의 다른 특징들과 비교하였다.

핵심용어: 음악 장르, MFCC, 스펙트럼 대비, 장르 분류

투고분야: 음향 신호처리 분야 (1,2)

This paper proposes a novel spectral audio feature, spectral contrast MFCC (SCMFCC), and studies its performance on the musical genre classification. For a successful musical genre classifier, extracting features that allow direct access to the relevant genre-specific information is crucial. In this regard, the features based on the spectral contrast, which represents the relative distribution of the harmonic and non-harmonic components, have received increased attention. The proposed SCMFCC feature utilizes the spectral contrast on the mel-frequency cepstrum and thus conforms the conventional MFCC in a way more relevant for musical genre classification. By performing classification test on the widely used music DB, we compare the performance of the proposed feature with that of the previous ones.

Keywords: Musical Genre, MFCC, Spectral Contrast, Genre Classification

ASK subject classification: Acoustic Signal Processing (1,2)

I. 서론

일반적으로 사람들은 자신의 음악에 대한 선호도를 장르로 표현한다. 사람들이 이야기하는 장르에는 클래식, 재즈, 팝, 락 등 다양하며 그 구분 또한 주관적이다. 따라서 음악 장르 분류를 자동화하는 것은 어려운 일이라 여겨져 왔다. 하지만 최근 분류 성능을 크게 향상시킨 다양한 연구 결과들이 나타나고 있어 주목을 받고 있다 [1]. 장르는 가장 기본적이고 널리 사용되는 음악의 메타 데이터이므로, 음악 장르 분류기는 대용량 음악 라이브러리 관리, 음악 추천 및 정보 제공 서비스 등에 활용될 수 있다.

음악 장르 분류는 일반적으로 그림 1과 같이 이루어진다. 준비 단계에서 분류기를 기존에 장르를 알고 있는 음악의 특징 데이터를 이용하여 학습한다. 학습된 분류기를 이용하여 입력 음악 파일의 특징에 대해서 장르 분류를 수행한다. 음악 장르 분류를 위해서는 장르 간의 차이를 두드러지게 할 수 있는 특징을 사용해야 하며, 일반적으로 MFCC (mel-frequency cepstral coefficients) 등의 스펙트럼 기반 특징이 널리 사용되어 왔다 [2-4]. 일반적으로 짧은 길이의 프레임 (수 십에서 수 백 ms)에서 얻은 스펙트럼 특징들을 모아서 1초에서 30초 길이의 오디오 세그먼트에서의 평균, 분산, 상관관계 (correlation) 등의 통계학적 특징을 구해서 사용한다. 오디오 장르 분류기에 사용되는 분류 방법에는 SVM (support vector machines), LDA (linear discriminant analysis), GMM

(Gaussian mixture model), k -NN (k -nearest neighbor) 등이 있다 [5, 6].

음악 장르 분류기의 성능은 분류 알고리즘도 중요하지만 그 보다는 사용되는 특징에 의해서 크게 영향을 받는다. 따라서 다양한 특징들이 연구되어 왔으며, 오디오 신호의 스펙트럼 특징을 잘 나타내는 MFCC가 대표적이며 그 밖에 spectral centroid, spectral roll-off frequency, band energy ratio, delta spectrum magnitude 등 다양한 특징들이 장르 분류에 적용되었다 [7, 8]. 스펙트럼 특징 외에 음악의 템포, 리듬, 멜로디를 이용하는 시도도 있었으나 아직 이러한 고수준의 음악 특징에 대한 정확한 추정이 어려우므로 아직까지는 상대적으로 분석이 쉬운 저수준의 스펙트럼 특징이 널리 사용되고 있다. 본 논문에서는 음악 장르 분류 성능을 향상시킬 수 있는 새로운 스펙트럼 특징으로 스펙트럼의 대비 차이에 기반한 SCMFCC (spectral contrast MFCC)를 제안한다. 이미 부밴드 스펙트럼의 대비 특징인 OSC (octave-based spectral contrast) [9]가 음악 분류에 적용되었으며 우수한 성능을 보였다 [9, 10]. 이러한 스펙트럼 대비 특징은 음악 장르의 차이가 주로 음악의 화음 구조 및 강약에 의해서 결정된다는 가정하에 시도되어 우수한 분류 성능을 보였다. 본 논문에서는 기존 OSC 특징에서 착안하여 멜 캡스 트럼 상에서 스펙트럼 크기의 대비 정보를 이용하는 SCMFCC를 제안한다. 기존의 MFCC가 오디오 스펙트럼 형태의 근사화에 집중했다면, 제안된 SCMFCC는 스펙트럼의 형태 근사화와 함께 대비차이의 정보 두 가지를 모두 명시적으로 표현할 수 있는 장점이 있어서 MFCC에 비해서 음악 장르 분류에 더 적합하다.

본 논문에서는 음악 장르 분류 성능 향상에 도움이 될 수 있는 새로운 특징인 SCMFCC를 제안하고 실험적으로 그 성능을 검증하였다. II장에서 스펙트럼 대비에 기반한

OSC와 제안된 SCMFCC 방법에 대해서 살펴보고, III장에서 제안된 특징의 성능을 대용량의 오디오 데이터에 대해서 실험하고 장르 분류 성능을 기존 특징들과 비교 분석한다.

II. 음악 장르 분류를 위한 스펙트럼 특징

본 논문에서는 음악 장르 분류를 위해서 기존의 MFCC, OSC 특징과 둘의 장점을 모아서 제안된 SCMFCC 특징을 고려하였다. 세 가지 특징은 모두 음악 신호를 짧은 길이의 프레임(수 십에서 수 백 ms)으로 나누고, 각 프레임의 스펙트럼으로부터 얻어지는 스펙트럼 특징이다.

2.1. MFCC 특징 추출

MFCC 특징은 음성 인식 분야에서 다른 스펙트럼 특징들에 비해서 탁월한 성능을 보여 널리 사용되고 있다. 또한 음악 추천 및 장르 분류 등 다양한 음악 신호 처리 분야에도 이용되어 우수한 성능을 보인다고 알려져 있다 [1, 2, 4, 7]. 각 프레임의 스펙트럼을 멜 필터뱅크 (mel-filterbank)를 통과한 후에 각 부밴드의 에너지의 합을 구하고 로그 함수와 DCT (discrete cosine transformation)를 적용하여 MFCC를 구한다. 일반적으로 MFCC에서는 DCT 결과 중 저주파 (low-frequency) 계수 중 12~20개 정도를 분류를 위한 특징으로 이용한다.

2.2. OSC 특징 추출

다양한 스펙트럼 특징들이 존재하지만, OSC와 기존 특징들의 가장 큰 차이점은 부밴드 내에서 스펙트럼의 합을 구하는 것이 아니라 부밴드 내의 스펙트럼의 대비 (최대값과 최소값의 차이) 정보를 이용하는 것이다. 이를 통해 기존의 특징으로는 명시적으로 표현할 수 없던 대비 정보를 활용할 수 있는 장점이 있다. 특히 음악 장르는 화음의 구조와 세기 등에 밀접한 관련이 있으므로 이러한 대비 정보를 활용하면 분류 성능을 향상시킬 수 있다. OSC의 경우 멜 스케일이 아니라 좀 더 넓은 대역인 옥타브 스케일의 부밴드에서 얻어진다. 각 옥타브 스케일의 부밴드는 겹쳐지지 않으며 시작과 끝 주파수는 Hz 단위로 0~200, 200~400, 400~800, 800~1600, 1600~3200, 3200~6400 으로 총 6개의 주파수 대역이 사용되었다 [9]. OSC 특징은 각 부밴드에서 peak와 valley값을 구하고 그 차이인 대비를 기반으로 하고 있다. 예를 들어 FFT를 통해서 얻어진 b 번째 부밴드의 스펙트럼이 $X_b = \{X_{b,1}$,

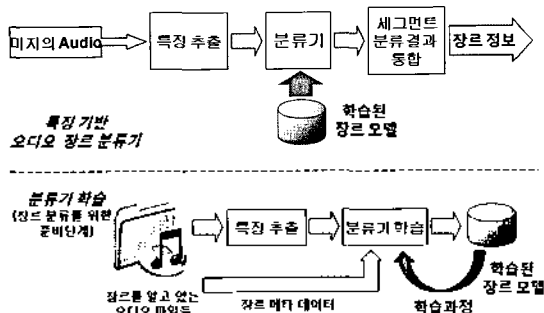


그림 1. 특징 기반 음악 장르 분류 블록선도
Fig. 1. Block diagram of feature-based musical genre classification.

$X_{b,2}, \dots, X_{b,N_b}$ 로 주어진다 하자. 먼저 스펙트럼 X_b 를 내림차순으로 정렬했을 때 $X'_b = \{X'_{b,1}, X'_{b,2}, \dots, X'_{b,N_b}\}$ 라고 하면, b 번째 부밴드의 $peak_b$ 와 $valley_b$ 값은 neighborhood factor인 α 값에 따라서 아래와 같이 주어진다 (본 논문에서는 $\alpha = 0.2$ 로 사용함) [9].

$$\begin{aligned} peak_b &= \log \left(\frac{1}{\alpha N_b} \sum_{i=1}^{\alpha N_b} X'_{b,i} \right) \\ valley_b &= \log \left(\frac{1}{\alpha N_b} \sum_{i=1}^{\alpha N_b} X'_{b,N_b-i+1} \right) \end{aligned} \quad (1)$$

얻어진 $peak_b$ 와 $valley_b$ 값의 차이가 바로 대비 정보가 되고 아래와 같이 주어진다.

$$sc_b = peak_b - valley_b \quad (2)$$

각 부밴드의 sc_b 와 $valley_b$ 값을 분류에 이용하며 6개의 부밴드를 사용했으므로 12차의 특징이 얻어진다. 여기서 valley의 정보는 대비 정보인 sc를 보충하는 역할을 한다.

2.3. SCMFCC 특징 추출

본 논문에서 제안된 SCMFCC 특징 추출 과정은 그림

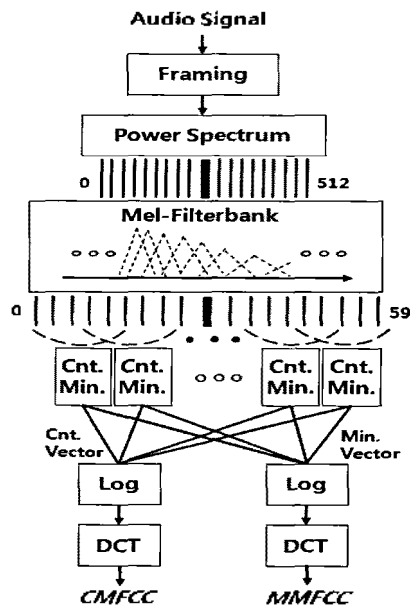


그림 2. 멜 캡스트럼 상에서의 대비 정보를 이용한 SCMFCC 추출 과정 블록선도

Fig. 2. Block diagram of the SCMFCC extraction based on the spectral contrast on the mel-frequency cepstrum.

2와 같다. 입력 오디오 신호를 프레임으로 나누고 FFT를 통해서 스펙트럼을 구한 후 멜 필터뱅크를 통과하여 M 개의 부밴드로 나누고 각 부밴드 에너지의 합을 구하는 과정은 MFCC와 동일하다. 그림 2의 예에서는 1024길이의 FFT를 사용하고 M 의 값으로 60을 사용하였다. MFCC의 경우 얻어진 M 개의 멜 스케일 부밴드 에너지에 로그를 취하고 DCT를 가하는 반면에 제안된 SCMFCC에서는 그림 2에 나온 바와 같이 M 개의 멜 스케일 부밴드 에너지를 50%씩 겹쳐 가면서 (overlap) K 개씩 모으고 (본 논문에서 $M=60$, $K=10$), 그 K 개의 에너지 값들 중에서 최대와 최소의 차이인 대비값과 최소값을 특징으로 하고 로그와 DCT를 각각 가한다. 이렇게 얻어진 대비값과 최소값에 대한 멜 캡스트럼을 통칭하여 SCMFCC라 한다. 실제로는 대비값에 대한 MFCC인 CMFCC (contrast MFCC)와 최소값에 대한 MFCC인 MMFCC (minimum MFCC) 이렇게 따로 얻어지고, 각각에서 N 차씩 취하면 $2N$ 차 SCMFCC를 얻는다. 이 때 CMFCC와 MMFCC에서의 차수를 다루게 할 수도 있으나, 실험적으로 같은 차수를 사용하는 것에 비해서 성능면에서 큰 차이를 보이지 않았으므로, 본 논문에서는 같은 차수씩 취하여 SCMFCC를 구성하였다.

III. 실험 결과

본 장에서는 II장에서 살펴본 세 가지 특징에 대해서 음악 분류 성능을 서로 비교하고, 기존의 다른 연구 결과들과도 성능을 비교하였다. 분류 성능 비교를 용이하게 하기 위해서 기존 논문들에서 널리 사용되고 있고 www.music-ir.org에서 다운로드가 가능한 Magnatune 음악 DB를 사용하였다. Magnatune 음악 DB는 총 1458곡으로 이루어져 있으며 classical (CL), electronic (EL), jazz (JA), metal (ME), rock (RO), world (WO) 이렇게 6가지 장르로 구분되어 있다. 음악 DB중 절반인 729곡에서 얻어진 특징으로 분류기를 학습하고, 나머지 반의 음악 파일들에 대해서 장르 분류 성능을 실험하였다.

실험에 사용되는 음악 파일들을 모노로 바꾸고 22050 Hz로 샘플링 주파수를 맞춘 후, 1024 길이의 해닝 (Hanning) 윈도우를 50%씩 겹쳐 가면서 (overlap) 적용하고 FFT를 가한다. 이렇게 주파수 도메인으로 신호를 변환해서 얻은 각 프레임의 스펙트럼으로부터 MFCC, OSC, SCMFCC를 각각 계산하였다. 본 실험의 MFCC와 SCMFCC에서는 DCT를 수행한 후 멜 스케일 부밴드 에너지의 평균값인 0번째 캡스트럼 원소까지 특징으로 포함

하였다. 장르 분류에서는 일반적으로 각 프레임 별로 장르 분류 결과를 내지 않고, 연속된 프레임들의 특징들의 통계적 특징에 대해서 분류기를 구성하게 된다. 본 논문에서 사용된 세그먼트의 길이는 연속된 256개의 프레임으로 약 6초이다. 세그먼트 레벨의 특징은 보통 세그먼트 내의 프레임들의 특징의 평균, 분산 등의 정보를 이용한다 [7-10]. 본 과제에서도 평균과 분산을 사용했다. 음악 파일 내의 모든 세그먼트들의 분류 결과들을 모아서 최다수 선택 원칙 (majority voting)을 통해서 그 곡의 장르 분류 결과를 정하였다. 사용될 특징이 결정되면, 다음으로 그 특징에 맞는 분류기를 선택해야 한다. 여러 분류 문제에서 널리 사용되고 있는 SVM (linear kernel), LDA, GMM (10 components) 의 세 가지 분류기에 대해서 각 특징 별로 성능을 구하여 비교 분석하였다. 장르 분류 실험에서 사용된 분류기는 모두 MATLAB Arsenal 라이브러리 함수를 이용하여 구현하였다.

일반적으로 특징의 차수가 높을수록 분류기를 학습하고 구현하는데 계산량이 커지지만 분류 성능은 향상되는 경향을 보인다. 따라서 공정한 비교를 위해서 MFCC와 SCMFCC의 차수를 OSC와 같은 12차수로 맞춘 후에 성능을 비교하면 표 1과 표 2와 같다. 표 1을 보면 같은 차수에 대해서 세 가지 분류기 모두에서 스펙트럼 대비를 이용한 SCMFCC와 OSC가 MFCC에 비해서 우수한 장르 분류 성

능을 가짐을 알 수 있다. 전반적으로 SCMFCC와 OSC는 성능이 유사하였으나 GMM 분류기에서는 SCMFCC가 1% 정도 더 분류 성능이 우수하였다. 표 2는 표 1의 결과 중에서 SVM 분류기를 사용했을 때 고려한 특징들의 각 장르별 분류 정확도이다. 다양한 전자악기들을 조합하여 대역별로 스펙트럼의 고저 차이가 두드러진 electronic 장르에서는 제안된 SCMFCC가 MFCC와 OSC의 중간 정도의 성능을 보였으나, 스펙트럼 고저 차이가 덜 두드러진 그 외 장르들에서는 제안된 SCMFCC가 MFCC와 OSC의 장점을 모두 살려서 가장 높은 분류 성능을 보임을 확인할 수 있다.

다음으로 12차에서 22차까지 차수를 가변해 가면서 MFCC와 SCMFCC의 성능을 비교하면 표 3과 같다. 이번 실험에서는 SVM 분류기를 사용하였다. 모든 차수에 대해서 기존에 가장 널리 사용되는 MFCC 특징에 비해서 SCMFCC 특징의 분류 성능이 우수함을 알 수 있다. MFCC를 이용한 가장 좋은 결과가 12차의 SCMFCC와 비슷한 정도의 분류 성능을 보였다. 같은 음악 DB를 사용하고 고차원 텐서 [11] 또는 비음수 행렬 분해 (nonnegative matrix factorization) [12] 등의 복잡하고 차수가 더 높은 특징을 사용한 최근 결과들이 80.95%에서 83.5% 정도의 분류 성능을 보임을 감안하면, 제안된 특징인 SCMFCC가 장르 분류에 효과적임을 알 수 있다.

본 논문에서 고려한 세 특징인 MFCC, OSC, SCMFCC를 조합하여 분류 성능을 분석하면 표 4와 같다. 세 특징 모두 프레임 별로 12차를 사용하였으며, 따라서 2종류 특징이 조합되면 24차이고 세 특징이 모두 사용되면 36차의 특징 크기를 가진다. 두 특징 조합인 경우 OSC와 SCMFCC의 결합의 경우 표 1의 결과인 단일 특징의 분류 정확도와 비교할 때 5% 이상 성능을 향상시켜서 가장 우수하였다. 세 특징 조합의 경우 상대적으로 큰 분류 성능의 향상을 보이지 않았다. 제안된 특징인 SCMFCC가 기존의 특징들과 함께 사용되어, 음악 분류에 도움이 될 수 있는 새로운 정보를 제공함을 알 수 있고 최근의 다른 연구 결과들 [11, 12]과 비교할 때도 조합 특징이 우수한

표 1. 다양한 분류기에 대한 세 특징의 음악 분류 성능 (%)
Table 1. Classification accuracy (%) of the three features for various classification algorithms.

특징\분류기	SVM	LDA	GMM
MFCC	75.72	72.02	74.49
OSC	79.56	71.33	78.46
SCMFCC	79.56	71.61	79.84

표 2. 세 특징의 각 장르별 분류 성능 (%)
Table 2. Classification accuracy (%) of the three features for each genre.

특징\장르	CL	EL	JA	ME	RO	WO
MFCC	96.56	71.93	57.69	71.11	62.75	40.98
OSC	97.19	87.72	57.69	84.44	62.75	42.62
SCMFCC	97.81	79.82	69.23	86.67	64.71	43.44

표 3. 특징의 차수에 대한 음악 분류 성능 (%)
Table 3. Classification accuracy (%) of the features versus the feature dimensions.

특징\차수	12	14	16	18	20	22
MFCC	75.72	75.86	79.01	77.92	78.19	77.78
SCMFCC	79.56	79.84	79.84	81.07	81.21	81.48

표 4. 세 가지 특징들을 조합했을 때의 장르 분류 성능 (%)
Table 4. Classification accuracy (%) of the combinations of the three features.

특징\분류기	SVM	LDA	GMM
MFCC+OSC	83.95	75.58	81.62
MFCC+SCMFCC	84.36	76.13	81.34
OSC+SCMFCC	85.60	77.09	82.03
세 특징 모두 사용	86.15	77.78	81.89

표 5. SCMFCC 분류 결과에 대한 오분류표 (마지막 행은 각 장르 별 분류 정확도 (%)임)

Table 5. Confusion matrix of the classification result of the SCMFCC (The last row is the classification accuracy (%) of each genre.)

	CL	EL	JA	ME	RO	WO
CL	313	5	2	0	2	41
EL	0	91	3	0	18	17
JA	0	0	18	0	1	0
ME	0	1	0	39	12	0
RO	0	8	1	6	66	11
WO	7	9	2	0	3	53
	97.81	79.82	69.23	86.67	64.71	43.44

성능을 보임을 알 수 있다.

오분류의 경향을 알아보기 위해서 표 5에 SCMFCC를 특징으로 사용했을 때의 장르 분류 결과의 오분류표를 구하였다. 표 5에서 CL, EL, JA, ME, RO, WO는 각각 classical, electronic, jazz, metal, rock, world 의 6 장르를 가리킨다. 먼저 제안된 특징이 전반적으로 다양한 장르에 대해서 잘 동작함을 알 수 있다. 상대적으로 다양한 형식의 음악이 섞여있는 world 장르가 가장 분류하기가 힘들었다. 그 외 대부분의 오분류는 음악 형식상 가까운 electronic, rock, metal 장르 사이에서 일어남을 알 수 있다.

IV. 결론

본 논문에서는 음악 장르 분류를 위한 새로운 특징인 SCMFCC를 제안하고, 기존의 스펙트럼 특징들과 장르 분류 성능을 비교 분석하였다. 제안된 특징인 SCMFCC는 기존 MFCC와 OSC의 장점을 결합하여, 스펙트럼의 형태 근사화와 함께 음악의 화음 구조 및 강약을 잘 표현할 수 있는 대비 정보를 명시적으로 표현할 수 있는 장점이 있어서 음악 분류에 적합하다. 실험 결과 SCMFCC는 MFCC에 비해서 분류 성능이 우수하고 OSC와 유사하거나 조금 더 나은 성능을 보였다. 추출이 복잡하고 차수가 더 높은 특징을 사용하는 다른 논문들의 결과들과 비교했을 때도 역시 유사하거나 우수한 성능을 보였다. SCMFCC는 OSC와는 달리 성능 향상을 위해서 차수의 조절이 용이하고, MFCC를 얻는 과정에서 얻어질 수 있는 장점이 있다. 본 연구는 음악 장르 분류에 대해 다루었으나, 제안된 SCMFCC는 MFCC가 사용되었던 음성과 음악 정보 처리 문제에 선별적으로 적용되어 성능을 향상시킬 수 있을 것으로 기대된다.

감사의 글

본 연구는 지식경제부, 문화체육관광부 및 한국산업기술평가관리원의 지식경제 기술 혁신사업의 일환으로 수행하였음. [2010- - , DRM 비적용 환경하에서의 콘텐츠 보호 유통 기술 개발]

참고 문헌

1. M. Casey, R. Veltkamp, M. Goto, M. Leman, C. Rhodes, and M. Slaney, "Content-based music information retrieval: Current directions and future challenges," *Proceedings of the IEEE*, vol. 96, no. 4, 2008.
2. E. Pampalk, A. Flexer, and G. Widmer, "Improvements of audio-based music similarity and genre classification," in *Proc. Int. Conf. on Music Info. Retrieval (ISMIR-05)*, Sep. 2005.
3. 이장규, 윤원중, 박규식, "한국 전통음악 (국악)에 대한 자동 장르 분류 시스템 구현," *한국음향학회지*, vol. 24, no. 1, pp. 29-37, 2005.
4. A. Meng, P. Ahrendt, J. Larsen, and L.K. Hansen, "Temporal feature integration for music genre classification," *IEEE Trans. Audio, Speech, Language Process.*, vol. 15, no. 5, July 2007.
5. R.O. Duda, P.E. Hart, and D.G. Stork, *Pattern Classification*, Wiley-Interscience, 2001.
6. N. Scaringella, G. Zoia, and D. Mlynek, "Automatic genre classification of music content: a survey," *IEEE Signal Processing Magazine*, vol. 23, no. 2, pp. 133-141, Mar. 2006.
7. Martin F. McKinney, Jeroen Breebaart, "Features for audio and music classification," in *Proc. Int. Conf. on Music Info. Retrieval (ISMIR-03)*, 2003.
8. J. Bergstra, N. Casagrande, D. Erhan, D. Eck, and B. Kegl, "Aggregate features and ADABOOST for music classification," *Machine Learning*, vol. 65, no. 2, pp. 473 - 484, Dec. 2006.
9. D. N. Jiang, L. Lu, H. J. Zhang, J. H. Tao, and L. H. Cai, "Music type classification by spectral contrast feature," in *Proc. IEEE ICME 02*, vol. 1, pp. 113-116, 2002.
10. K. West, S. Cox, "Features and classifiers for the automatic classification of musical audio signals," in *Proc. Int. Conf. on Music Info. Retrieval (ISMIR-04)*, 2004.
11. I. Panagakis, E. Benetos, and C. Kolropoulos, "Music genre classification: A multilinear approach," in *Proc. Int. Conf. on Music Info. Retrieval (ISMIR-08)*, Sep. 2008.
12. A. Holzapfel and Y. Stylianou, "Musical genre classification using nonnegative matrix factorization-based features," *IEEE Trans. Audio, Speech, Language Process.*, vol.16, no. 2, Feb. 2008.

저자 약력

•서진수 (Jin Soo Seo)

한국음향학회지 제28권 제4호 참조