
음악 추천을 위한 다중 옥타브 밴드 기반 장르 분류기

임신철* · 장세진** · 이석필** · 김무영***

Multiple octave-band based genre classification algorithm for music recommendation

Shin-Cheol Lim* · Sei-Jin Jang** · Seok-Pil Lee** · Moo Young kim***

이 논문은 2011년도 정부(지식경제부)의 재원으로 산업원천기술개발사업의 지원 받아 수행된 연구임

요약

본 논문은 음악 추천을 위한 새로운 장르 분류 알고리즘을 제안하였다. 특히, 장르 분류 알고리즘에 사용되는 특징 벡터 중 octave-based spectral contrast (OSC)의 성능 개선을 위해서 심리청각 모델과 악기별 사용 octave 범위에 근거하여 새로운 band-pass filter를 설계하였다. 10개 장르별 음악을 포함하고 있는 GTZAN database에 대해서 10-fold corss validation 실험 결과, 다중 옥타브 OSC에 대해서 기존 OSC에 비해 2.26% 향상된 인식율을 얻을 수 있었다. 또한, 기존의 mel-frequency cepstral coefficient (MFCC)와 복합 특징 벡터를 구성하여 실험한 결과, 향상된 인식율을 얻을 수 있었다.

ABSTRACT

In this paper, a novel genre classification algorithm is proposed for music recommendation system. Especially, to improve the classification accuracy, the band-pass filter for octave-based spectral contrast (OSC) feature is designed considering the psycho-acoustic model and actual frequency range of musical instruments. The GTZAN database including 10 genres was used for 10-fold cross validation experiments. The proposed multiple-octave based OSC produces better accuracy by 2.26% compared with the conventional OSC. The combined feature vector based on the proposed OSC and mel-frequency cepstral coefficient (MFCC) gives even better accuracy.

키워드

음악 장르 분류, 음악 추천, MFCC, OSC, 텍스쳐 윈도우

Key word

Music genre classification, music recommendation, MFCC, OSC, Texture window

* 준회원 : 세종대학교

접수일자 : 2011. 02. 19

** 정회원 : 전자부품연구원 디지털미디어연구센터

심사완료일자 : 2011. 03. 26

*** 종신회원 : 세종대학교 정보통신공학과 (교신저자, mooyoung@sejong.ac.kr)

I. 서 론

최근 들어 대용량의 디지털 음원이 사용자에게 서비스됨에 따라서 자동적으로 음악을 추천해주는 시스템들이 등장하고 있다. 일반적인 음악 추천 시스템은 다른 사람들의 플레이 리스트 또는 사이트별 인기곡을 추천 해주는 시스템이 대부분이다 [1][2]. 하지만, 이 경우 사용자의 취향과 일치하지 않거나 접하기 쉬운 노래만을 추천하는 경우가 많기 때문에, 사용자를 만족시키기에 부족한 부분이 있다.

따라서, 협업필터링 (collaborative filtering)[3] [4]와 음악의 특징벡터(feature vector)와 패턴인식 기법을 이용하여 추천하는 시스템이 연구되고 있다 [5][6]. 협업 필터링은 아마존 등에서 도서를 추천하는 시스템과 비슷하게, 사용자가 자주 듣는 곡의 종류를 분석하여 유사한 접속 패턴을 보이는 다른 사용자의 플레이 리스트 내 곡들을 추천해 주는 시스템이다. 하지만, 특정한 접속 패턴을 가지지 않는 사용자에 대해서는 사용이 제한적이다. 반면에, 특징벡터와 패턴인식 기법을 이용한 추천 시스템은 자신이 현재 듣는 음악의 장르나 무드 등을 분석하여 유사한 장르나 무드의 음악을 추천해 주는 시스템이다. 본 논문에서는 청취 음악과 유사한 장르의 음악을 추천해주는 시스템을 설계하기 위해서 음악별 장르를 자동으로 분류해주는 알고리즘을 제안하고자 한다.

장르에 대한 정의는 문화, 가수, 시장에 따라 또는 나라마다 혹은 사람마다 차이가 있으므로, 음악별 장르의 경계를 명확히 구분하기는 힘들다 [7]. 따라서, Tzanetakis는 blues, classic, country, disco, hiphop, jazz, metal, pop, reggae, rock 등 10개의 음악 장르를 정의하고, spectral roll-off/ flux/centroid, mel-frequency cepstral coefficient (MFCC) 등 다양한 특징 벡터를 이용하여 장르를 분류하였다 [8]. Jiang은 jazz, pop, romantic, baroque, rock의 5가지 장르에 대해서 octave-based spectral contrast (OSC)라는 새로운 특징 벡터를 제안하였다 [9].

분류기도 많이 연구 되고 있는데, Chang, Jang, 그리고 Iliopoulos는 Support Vector Machine (SVM)과 Sparse Representation Classification (SRC)을 비교하였다 [10]. 그 결과, SVM에 비해 SRC가 높은 장르 분류

성공률을 나타내었지만, sparse한 data를 찾기 위한 l_1 -minimization에 많은 계산량이 필요하였다. [10]에서처럼 분류기가 성능에 많은 영향을 주지만, 우리는 특정 벡터에 연구의 초점을 두고 분류기로 SVM을 사용하였다.

본 논문에서는 청각 심리학 모델과 실제 악기 연주 주파수 범위에 의거하여 다중 옥타브 밴드 기반 OSC 특징 벡터를 추출하였고, 제안된 OSC와 MFCC를 복합적으로 사용하는 장르 분류 알고리즘을 제안하였다.

본 논문의 구성은 다음과 같다. II장에서는 제안한 음악 장르 분류 알고리즘에 기반한 음악 추천 시스템에 대해 설명한다. III장에서는 실험을 통해 기존 방식과 제안한 방식의 성능을 평가하였고, 마지막으로 IV장에서는 최종 결론 및 향후 연구방향을 기술했다.

II. 장르 분석을 이용한 음악 추천 시스템

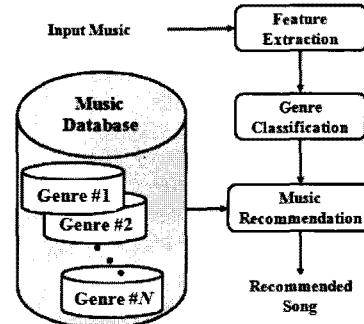


그림 1. 음악 추천 시스템 블록도
Fig. 1 Block diagram of music recommendation system

그림 1은 장르 분석에 기반한 음악 추천 시스템의 블록도이다. 입력 음악으로부터 특징 벡터를 추출한 후 해당 곡의 장르를 자동 분류하여, 데이터베이스 내에 저장되어 있는 음악들 중 유사한 장르의 음악을 추천해주는 시스템이다. 이는 방대한 데이터베이스 중 유사한 스타일의 음악을 검색하는데 효율적이다. 따라서, 본 논문에서는 자동으로 장르를 분류하는 알고리즘을 제안하고자 한다. 장르 분류 시스템은 다음 절들에서 보듯이 음악

의 특징 벡터를 추출하는 부분과 특징을 이용해 장르를 분류하는 분류기로 나눌 수 있다.

2.1. 음악 특징 추출

음악의 특징 벡터는 다양한 방법들로 추출할 수 있다. 본 논문에서는 음성 신호의 인식에 가장 널리 사용되는 mel-frequency cepstral coefficient (MFCC)와 음악 신호의 특성을 잘 나타내는 octave-based spectral contrast (OSC)를 사용하였다. 특히, 심리음향 모델과 실제 악기들의 연주 주파수 범위에 의거하여 OSC 밴드를 나누는 방법을 제안하고자 한다.

2.1.1. MFCC

MFCC는 사람의 청각시스템을 모델링한 필터를 사용한다. 따라서, 음성인식, 화자인식이나 다양한 소리를 인식하는 시스템에 많이 사용된다 [11][12]. 본 논문에서는 13차 MFCC를 추출하여 사용하였다.

2.1.2. OSC

OSC는 각 밴드 별 스펙트럼의 peak와 valley 값을 이용하여 특징 벡터를 추출한다. 에너지가 몰려 있는 peak 부분은 대체로 음악의 harmonic과 관련이 있고, valley는 non-harmonic과 관련된다. 따라서, OSC는 음악의 harmonic과 non-harmonic을 동시에 고려하는 특징 벡

터이다 [9]. MFCC가 청각 모델 필터를 사용함에 비해서, OSC는 octave를 기반으로 한 필터를 사용한다. 따라서 mel-scale band-pass filter 대신 octave-based band-pass filter를 사용한다.

N 포인트 discrete Fourier transform (DFT)으로 구한 스펙트럼을 $\{x_1, x_2, \dots, x_N\}$ 로 정의하고, i 번째 밴드 내 스펙트럼을 $\{x_{i,1}, x_{i,2}, \dots, x_{i,N_i}\}$ 으로 정의한다. 여기서, N_i 는 i 번째 밴드 내 주파수 빈의 수를 의미한다. 스펙트럼을 내림차순으로 정리하여 $\{x'_{i,1}, x'_{i,2}, \dots, x'_{i,N_i}\}$ 라고 하면 소팅된 스펙트럼은 $\{x'_{i,1} \geq x'_{i,2} \geq \dots \geq x'_{i,N_i}\}$ 의 관계를 가진다. 여기서 i 번째 밴드의 peak와 valley는 다음과 같이 구한다.

$$P_i = \log \left(\frac{1}{\alpha N_i} \sum_{j=1}^{\alpha N_i} x'_{i,j} \right) \quad (1)$$

$$V_i = \log \left(\frac{1}{\alpha N_i} \sum_{j=1}^{\alpha N_i} x'_{i,N_i-j+1} \right) \quad (2)$$

α 는 밴드별 최대값과 최소값을 얼마나 참조할지를 결정하는 상수이다. 본 논문에서는 α 를 0.02로 설정하였다. Peak값과 valley값의 차를 이용한 spectral contrast는 다음과 같이 구할 수 있다.

$$SC_i = P_i - V_i \quad (3)$$

표 1. 제안하는 octave-based band-pass filter의 주파수 범위 (샘플링 주파수=22050 Hz)

Table 1. Frequency range of octave-based band-pass filter (sampling rate=22050 Hz)

band(I)	Type I	Type II	Type III	Type IV	Type V
single -octave based bands	1 [0-100)	[0-100)	[0-100)	[0-100)	[0-100)
	2 [100-200)	[100-200)	[100-200)	[100-200)	[100-200)
	3 [200-400)	[200-400)	[200-400)	[200-400)	[200-400)
	4 [400-800)	[400-800)	[400-800)	[400-800)	[400-800)
	5 [800-1600)	[800-1600)	[800-1600)	[800-1600)	[800-1600)
	6 [1600-3200)	[1600-3200)	[1600-3200)	[1600-3200)	[1600-3200)
	7 [3200-6400)	[3200-6400)	[3200-6400)	[3200-6400)	[3200-6400)
	8 [6400-11025)	[6400-11025)	[6400-11025)	[6400-11025)	
multiple -octave based bands	1 [0-200)	[0-800)	[0-11025)	[0-11025)	
	2 [200-800)	[800-11025)			
	3 [800-3200)	[0-11025)			
	4 [3200-11025)				

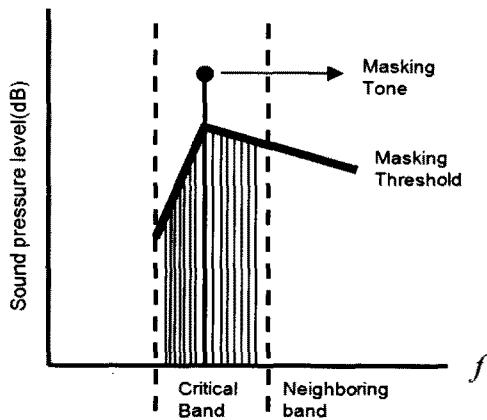


그림 2. 심리청각모델 – Simultaneous masking
Fig. 2 Psychoacoustic model – Simultaneous masking

본 논문에서는 I 개 밴드에 대한 spectral contrast와 valley를 특징 벡터로 사용하게 된다. 따라서, OSC의 특징 벡터 차수는 2^*I 가 된다.

그림 2는 심리청각 모델 중 하나인 simultaneous masking curve를 나타낸다. 본 그림에서는 critical band 내에서 발생한 tone이 masking curve 보다 적은 값을 가지는 noise를 마스킹 하는 현상을 나타내고 있다. 하지만, 해당 tone은 critical band 밖의 noise도 일부 마스킹 함을 볼 수 있다. 따라서, 본 논문에서는 기존의 single-octave based band 별로 특징 값을 추출하는 방식을 개선하여, multiple-octave based band 별로도 추가적인 특징 값을 추출하여 복합적으로 이용하였다. 즉, OSC에서 사용하는 스펙트럴 피크 값은 octave band 별 최대값을 의미하며, 이러한 tone들의 집합은 해당 밴드 내 신호 뿐 아니라 밴드 밖의 신호에도 영향을 줄 수 있음을 가정하였다.

본 논문에서는 octave-based band-pass filter를 표 1과 같이 변경하여 설계하였다. Type I은 전통적인 single-octave based band를 나타내며, 각 octave 별로 독립적으로 band-pass filter를 표현하고 있다. Type II는 두 개 octave 쪽을 묶어서 multiple-octave based band를 구성하였다. Type III 방식은 네 개 octave 쪽 묶은 밴드와 Nyquist 주파수까지의 global octave에 대한 밴드로 multiple-octave band를 구성하였다. Type IV는 Type III에서 사용한 global 밴드가 중요하다고 생각하여 Type I에 추가하여 구성하였다.

Type II, III, IV의 경우에는 single-octave based band 이외에 multiple-octave based band를 추가적으로 참조 하므로, 전통적인 Type I에 비하여 특징 벡터 차수가 증가하게 된다. Type V는 전통적인 Type I과 특징 벡터 차수를 동일시하기 위해서, 여러 악기별로 연주가 이루어지는 octave 범위를 조사하였다 [13]. 그 결과, 8번째와 9번째 octave를 사용하는 악기가 거의 없는 것으로 조사되었다. 따라서, Type I에서 약 8번째 octave G부터 9번째 octave E까지 보는 6400-11025 Hz 주파수 밴드를 제외하고, global 특징으로 대체하여 Type V를 구성하였다.

2.1.3. Texture window

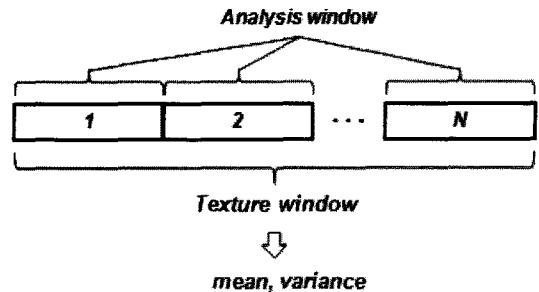


그림 3. texture window와 analysis window의 관계 및 특징 벡터의 평균과 분산을 계산 방법
Fig. 3 The relationship between analysis window and calculation method to mean and variance of feature vector in texture window

음성 인식이나 화자 인식 등에서는 analysis window에서 구한 특징 벡터를 직접적으로 사용한다. 그러나 음악의 장르나 무드 분류 시에는, 그림 3과 같이 N 개의 analysis window를 texture window로 묶어서 특징을 추출한다 [8]. 한 곡당 T 개의 texture window가 생성된다 고 할 때, 각 texture window 별 analysis window에서 추출한 K 차 특징 벡터 $\{AF_n[k]\}_{1 \leq n \leq N, 1 \leq k \leq K}$ 의 평균 $\{M[k]\}_{t=1,2,\dots,T}$ 과 분산 $\{V_t[k]\}_{t=1,2,\dots,T}$ 을 구한다. 그 후 $\{M[k], V_t[k]\}_{t=1,2,\dots,T}$ 에 대한 평균을 전체 texture window에 대해서 구한 후 장르 분류를 위한 최종적인 특징 벡터로 사용한다. 즉, 한 곡에 대해서 2^*K 차 특징을 추출한다.

표 2. 다중 옥타브 밴드 기반의 octave-based band-pass filter의 실험결과 (10회 평균과 표준편차)
Table. 2 Experimental Result of octave-based band-pass filter of multiple-octave band (mean and standard derivation of 10 times)

구분	Type I (conventional method)	Type II	Type III	Type IV	Type V
accuracy (%)	71.12 (0.405)	73.02 (0.673)	73.38 (0.452)	71.92 (0.507)	72.02 (0.627)
order	32	48	44	36	32

2.2. SVM

추출된 특징 벡터를 입력으로 SVM을 이용해서 장르 분류를 수행하였다 [14-16]. SVM은 구조적인 위험 최소화를 사용한 패턴 인식 방법이다. 커널 함수의 선과 분류 할 데이터가 만날 때까지 확장한 폭을 margin이라고 할 때, SVM은 마진을 최대화하는 최적 분류 초평면을 다음과 같이 구한다.

$$f(x) = \sum_{i=1}^n \alpha_i K(x_i, x) + b \quad (8)$$

여기서 α_i , $K(x_i, x)$ 와 b 는 각각 라그랑제 상수, 커널 함수, 그리고 바이어스를 나타낸다. SVM은 linear, polynomial, radial basis 함수 등 다양한 커널 함수를 지원한다. SVM을 수행하는 방법에는 하나의 클래스와 선택된 클래스를 제외한 전체 클래스와 비교하는 1-against-all과 각각의 클래스를 비교하는 1-against-1이 있다. 1-against-all은 계산량이 적은 반면, 1-against-1보다 분류 성공률이 낮다. 본 논문에서는 linear 커널 함수를 적용한 1-against-1을 사용하였다.

III. 실험 결과

제안하는 장르 분류 알고리즘의 성능을 평가하기 위해서, 본 논문에서는 GTZAN 음악 데이터베이스를 사용하였다 [17]. GTZAN 데이터베이스는 blues, classical, country, disco, hiphop, jazz, metal, pop, reggae, rock의 총 10개의 장르를 포함하고 있다. 모노, 22050Hz, 16bit, AU 포맷으로 각 장르당 100곡, 한 곡당 30초씩 구성되어 있다.

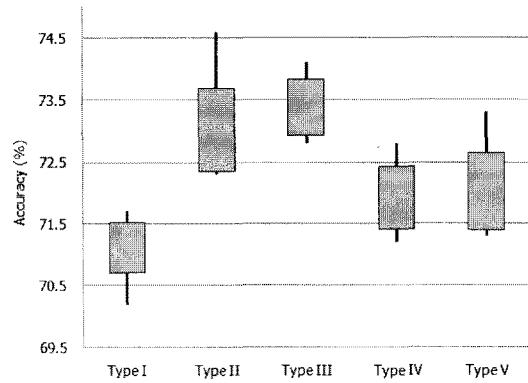


그림 4. 다중 옥타브 밴드 기반의 octave-based band-pass filter의 t-test 결과 (10회)

Fig. 4 T-test result of octave-based band-pass filter of multiple-octave band (10 times)

Analysis window는 20ms로 설정하고, 10ms overlap을 하면서 특징을 추출하였다. Texture window는 1초로 설정되었으며 99개의 analysis window를 포함하도록 하였다. Texture window의 경우 overlap을 하지 않았다. 따라서 30초의 음악에 대해서 30개의 texture window를 적용하였다. II장에서 기술한 방식으로 특징 벡터를 추출한 후, SVM을 이용하여 장르를 분류하였다. SVM은 선형 커널 함수와 1-against-1 방식을 사용하였고, 실험 결과의 reliability를 향상시키기 위해서 10-fold cross-validation (CV) 실험을 진행하였다. 10-fold CV는 전체 음악 데이터베이스의 90%를 이용하여 모델을 학습하고 나머지 10%를 이용하여 장르 인식을 수행하는 과정이다. 또한, 실험의 reliability를 보다 향상시키기 위해서 10-fold CV를 10회 반복 수행하였다.

표 2와 그림 4는 OSC 밴드의 범위를 심리청각모델을 참조하여 재설정한 표 1에 대한 실험 결과이다. 그림 4

를 보면, Type I으로 표현된 전통적인 single-octave band 기반 방식의 성능에 비해, Type II-V에 제안한 multiple-octave band 기반 방식의 성능이 전체적으로 우수함을 알 수 있다. 두 개 octave씩을 묶어서 밴드를 구성하는 Type II 방식은 Type I 방식에 비해 성능은 우수했으나 특징 차수가 32에서 48로 증가하므로 더 많은 계산량을 요구한다.

Type III 방식은 네 개 octave씩을 묶어서 밴드를 구성하였고 추가적으로 global한 밴드를 이용하여 특징을 추출하였다. Type II 방식과 비교하여 global 특징의 추가로 특징 벡터 차수는 44로 감소하였으며, 73.38%로 가장 우수한 장르 분류 성공률을 나타냈다.

Global 특징의 중요성과 특징 차수를 감안하여 Type IV를 설계하였으나, Type II나 III와 비교해서 성능이 감소함을 알 수 있었다.

Type V 방식에서는 8번째와 9번째 octave를 사용하는 악기가 거의 없는 점에 착안하여, 6400 Hz 이상의 주파수 밴드를 global 밴드로 대체하였다. 그 결과 특징 벡터 차수는 Type I과 동일한 32차였으나, 0.9%의 성능 향상을 나타냈다. Type II-V의 실험결과에 의해, 심리청각모델에 기반한 multiple-octave band별 특징 추출 방식이 기존 방식에 비해서 우수함을 알 수 있었다. 그리고 Type III-V의 실험에 의거하여 global 밴드가 중요한 것을 알 수 있었다.

표 3. 각 특징 벡터별 장르 분류 성공률
Table. 3 The genre classification accuracy of each feature vector

Feature	Accuracy(%)		Order	
	Type I	Type III	Type I	Type III
MFCC	67.73		26	
OSC	71.12	73.38	32	44
MFCC + OSC	78.53	78.87	58	70

표 3은 각 특징별 장르 분류 성공률과 사용된 특징 벡터의 차수를 나타낸다. MFCC와 OSC의 복합 특징 벡터는 표 2에서 얻은 결과를 바탕으로 구성하였다. 단일 특징 벡터로 장르 분류를 수행한 결과, OSC의 71.12% 및 73.38%에 비하여 MFCC는 67.73%로 낮은 분류 성공률을 보였다. 반면, MFCC와 Type III OSC를 결합한 복합 특징 벡터는 78.87%로 단일 특징 벡터를 사용한 것보다

높은 성능을 보였다. 하지만, OSC만 사용한 특정 벡터에 비해서 차수가 26차 증가하였다. 또한, 복합 특정 벡터의 구성 시에도 Type I을 이용한 OSC보다 다중 옥타브를 고려한 Type III를 이용한 OSC를 결합한 방식의 성능이 더 우수하였다.

IV. 결 론

본 논문에서는 음악 추천 시스템을 위한 자동 장르 분류 알고리즘을 제안했다. 장르 분류 알고리즘은 OSC의 밴드 범위 설정을 심리청각모델에 근거하여 재설정하여 2.26%의 성능의 향상을 가져왔다. 또한, MFCC와 OSC를 복합 특정 벡터로 사용한 결과, 단일 특정 벡터를 사용한 것보다 높은 성능을 보였다. 그리고, 밴드 범위를 재설정한 OSC를 결합한 결과가 기존 OSC와 결합한 결과보다 성능이 더 높았다.

향후에는 장르 이외에 무드를 인식하는 알고리즘과 음악 간 유사성을 비교하는 알고리즘을 추가하여 음악을 추천하는 시스템을 구현해 볼 예정이다. 또한, 장르 분류의 성공률을 올리기 위해 다양한 특징 벡터 및 분류기를 제안할 예정이다.

감사의 글

이 논문은 2011년도 정부(지식경제부)의 재원으로 산업원천기술개발사업의 지원을 받아 수행된 연구임(No. 10037244).

참고문헌

- [1] <http://www.melon.com>
- [2] <http://bugs.co.kr>
- [3] B. Shao, D. Wang, T. Li, and M. Ogiara, "Music Recommendation Based on Acoustic Features and User Access Patterns," *IEEE Trans. Speech Audio*

- Process.*, vol. 17, no. 8, pp. 1602-1611, 2009.
- [4] L. Cao and M. Guo, "Consistent Music Recommendation in Heterogeneous Pervasive Environment," *IEEE Int. Symposium on Parallel and Distributed Process. with Applications*, pp. 495-501, 2008.
- [5] D-M. Kim, K-S. Kim, K-H. Park, J-H. Lee and K. M. Lee, "A music recommendation system with a dynamic k-means clustering algorithm," *Int. Conf. Machine Learning and Applications*, pp. 399-403, 2007.
- [6] X. Zhu, Y-Y. Shi, H-G. Kim, and K-W. Eom, "An integrated music recommendation system," *IEEE Trans. Consumer Electronics*, vol. 52, no. 3, pp. 917-925, 2006.
- [7] N. Scaringella, G. Zoia, and D. Mlynek, "Automatic genre classification of music content: A survey," *IEEE Signal Process.*, vol. 23, no. 2, pp. 133-141, 2006.
- [8] G. Tzanetakis and P. Cook, "Musical genre classification of audio signals," *IEEE Trans. Speech Audio Process.*, vol. 10, no. 5, pp. 293-302, 2002.
- [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 Int. Conf. Multimedia and Expo*, vol. 1, pp. 113-116, 2002.
- [10] K. K. Chang, J-S. R. Jang, and C. S. Iliopoulos, "Music Genre Classification via Compressive Sampling," *Int. Society for Music Information Retrieval Conf.*, pp. 387-392, 2010.
- [11] 김창근, 박진영, 박정원, 이광석, 허강인, "독립성분 분석을 이용한 DSP 기반의 화자 독립 음성 인식 시스템의 구현," *한국해양정보통신학회논문지*, no. 8, vol. 2, pp. 359-364, 2005.
- [12] 박진영, 이광석, 고시영, 허강인, "잡음환경에서의 음성인식을 위한 변이특성을 고려한 파라메터," *한국해양정보통신학회*, 학술대회논문집, pp. 469-472, 2005.
- [13] The range of a musical instrument :
["http://en.wikipedia.org/wiki/Range_\(music\)"](http://en.wikipedia.org/wiki/Range_(music))
- [14] Y. Wang, "A Tree-Based Multi-class SVM Classifier for Digital Library Document," in Proc. *IEEE Int. Conf. Multimedia and Information Technology*, pp. 15-18, 2008.
- [15] 이금분, 조범준, "다중 클래스 SVM을 이용한 EMD 기반의 부정맥 신호 분류," *한국해양정보통신학회*, *한국해양정보통신학회논문지*, no. 14, vol. 1, pp. 16-22, 2010.
- [16] 한학용, "패턴인식 개론 : MATLAB 실습을 통한 입체적 학습," 2005.
- [17] GTZAN Genre Collection Database,
["http://marsyas.info/download/data_sets"](http://marsyas.info/download/data_sets)

저자소개



임신철(Shin-Cheol Lim)

2011.2 세종대학교
전자통신공학과 공학사
2011.3 ~ 현재 세종대학교
전자통신공학과
석사과정

※ 관심분야: 화자인식, 음악정보검색, compressed sensing



장세진(Sei-jin Jang)

1995.2 경북대학교
전자공학과 공학사
1997.2 경북대학교 대학원
전자공학과 공학석사

1997-2002 대우전자 전략기술연구소 전임연구원
2002-현재 KETI 차세대음향산업지원센터<센터장>



이석필(Seok-Pil Lee)

1990.2 연세대학교 전기공학과
공학사
1992.2 연세대학교 대학원
전기공학과 공학석사

1997.2 연세대학교 대학원 전기전자공학과 공학박사
1997-2002 대우전자 영상 연구소 선임연구원
2002-현재 KETI 디지털미디어연구센터 <센터장>



김무영(Moo Young Kim)

1989.3 ~ 1993.2 연세대학교

전자공학과 학사

1993.3 ~ 1995.2 연세대학교

전자공학과 석사

1995.2 ~ 2000.12 삼성종합기술원 전문연구원

2001.1 ~ 2004.11 Royal Institute of Technology

(KTH, 스웨덴) Dept. Signals, Sensors,
Systems, 박사

2004.12 ~ 2005.2 Royal Institute of Technology (KTH,
스웨덴) Dept. Signals, Sensors,
Systems, Post Doc

2005.2 ~ 2006.8 Ericsson Research (스웨덴), Senior
Research Engineer

2006.8 ~ 현재 세종대학교 정보통신공학과, 부교수
※ 관심분야: 음성/오디오 신호처리 및 코딩,
패턴인식, 정보이론