

# 멀티 신호를 이용한 환경 인식 성능 개선

## Improvement of Environment Recognition using Multimodal Signal

박준규, 백성준  
전남대학교 전자컴퓨터공학부

Jun-Qyu Park(junq14@naver.com), Seong-Joon Baek(tozero@chonnam.ac.kr)

### 요약

본 연구에서는 9가지 환경에서 마이크로폰과 자이로센서, 가속도센서를 이용하여 얻은 데이터를 특징 추출한 후 각 특징들을 조합하여 GMM (Gaussian Mixture Model)을 이용한 분류실험을 수행하였다. 기존의 환경 인식에 관한 연구들에서는 주로 마이크로폰을 이용한 환경음 데이터를 통해 인식주체의 환경 상황을 인식하고자 하였으나, 여러 노이즈들이 결합한 형태로 좋은 특징을 얻기 어려운 환경음의 구조적 특성으로 인해 그 인식 성능에 한계가 있었다. 이에 본 연구에서는 환경상황을 인식하기 위한 또 다른 방법으로 인식주체의 움직임 특성을 반영하기 위해 자이로센서와 가속도센서의 데이터를 특징에 추가 적용하는 방식을 제안하였다. 실험결과 따르면 마이크로폰을 통해 얻은 환경음의 특징만을 이용하는 기존의 방식들에 비해 가속도센서를 통해 얻은 데이터를 기존의 환경음 특징벡터와 조합한 경우에서 5% 이상 평균 인식률이 개선되는 것을 확인할 수 있었다.

■ 중심어 : | 상황인지 | 가속도센서 | 자이로센서 | 가우시안 믹처 모델 |

### Abstract

In this study, we conducted the classification experiments with GMM (Gaussian Mixture Model) from combining the extracted features by using microphone, Gyro sensor and Acceleration sensor in 9 different environment types. Existing studies of Context Aware wanted to recognize the Environment situation mainly using the Environment sound data with microphone, but there was limitation of reflecting recognition owing to structural characteristics of Environment sound which are composed of various noises combination. Hence we proposed the additional application methods which added Gyro sensor and Acceleration sensor data in order to reflect recognition agent's movement feature. According to the experimental results, the method combining Acceleration sensor data with the data of existing Environment sound feature improves the recognition performance by more than 5%, when compared with existing methods of getting only Environment sound feature data from the Microphone.

■ keyword : | Context Aware | Acceleration Sensor | Gyro Sensor | GMM |

## I. 서론

인간 중심의 IT 기술은 계속되어 진보되어 왔고 이

같은 추세는 앞으로도 지속될 것이다. 이러한 동향의 핵심 기술 중 하나인 상황인지는 국내외의 연구들이 활발히 진행되고 있으며, 특히 최근 비약적인 발전을 이

\* 본 연구는 지식경제부 및 정보통신연구진흥원의 대학 IT연구센터 지원사업의 연구결과로 수행되었음  
(NIPA- 2010-C1090-1011-0008)

접수번호 : #100830-001

접수일자 : 2010년 08월 30일

심사완료일 : 2010년 12월 14일

교신저자 : 박준규, e-mail : junq14@naver.com

루고 있는 휴대전자기기 분야에서는 사용자의 환경상황을 인지하여 다양한 서비스를 제공하려는 노력이 진행되고 있다[1].

본 논문에서는 외부로부터 환경정보를 입력받는 방법으로 휴대폰 기반에서 마이크로폰과 자이로센서 가속도 센서를 통한 신호입력을 고려하였고, 이들 센서의 경우 현재 스마트 폰에 탑재되고 있는 추세로서 기존 시스템의 활용도를 높일 수 있다는 장점이 있다. 휴대전화에서 환경상황 인식 기능은 극장이나 강의실 같은 사용자의 위치 정보를 바탕으로 공공장소에서 자동으로 에티켓모드로 전환하는 등의 기능을 제공할 수 있다. 또한 이 휴대전화에서 상황인지 기능은 휴대폰시장의 트렌드가 되고 있는 스마트 폰에 지원되는 위성항법 장치의 정보와 결합하여 어린이나 노약자 또는 범죄용의자의 위치 정보를 이 전보다 더욱 자세히 제공할 수 있을 것이다. 이와 유사하게 환경음 인식기능에 의한 사용자의 위치 정보는 다른 정보와의 결합으로 새로운 서비스를 제공할 수 있게 할 것이다.

기존의 환경 인식 분야에서는 마이크로폰을 통해 획득한 환경음 데이터를 바탕으로 환경을 인식하는 연구들이 진행되고 있으며 기존 음성 인식 분야의 대표적인 특징 추출 방식인 MFCC (Mel-Frequency Cepstral Coefficients)와 LPCC (Linear Prediction Cepstrum Coefficients)를 특징 추출에 주로 이용해 왔다[2-5]. 최근의 연구들에서는 이들을 기반으로 점차 발전된 형태의 특징 추출 기법들을 제안하고 있고, 여기에는 둘 이상의 특징 추출 방식을 조합하여 인식 성능을 개선시킨 연구들이 대부분을 이루고 있다[6-9].

환경음의 특성인 무작위성, 높은 분산성을 비롯한 여러 가지 문제들로 인해 기존의 환경상황 인식 시스템에서는 환경의 class 수가 증가 할수록 그 인식 성능이 급격히 감소 하거나[9], 고려하는 환경의 종류에 따라 인식 성능에 차이가 발생한다. 이러한 환경음 분류의 특성을 고려하여 대표적 기존연구들의 인식 성능을 살펴보면, 먼저 12차 MFCC 특징과 기타 시간, 주파수영역의 특징을 조합하여 이를 바탕으로 5개의 class를 분류한 연구에서 92%의 인식 성능을 보여주고 있다[6]. 또한 64차 MFCC 특징을 PCA(Principal component

Analysis)를 이용하여 축소한 후 이를 이용하여 11개의 class를 분류한 작업에서는 77%의 성능을[7], 14개 class를 12차 MFCC특징을 사용하여 분류한 연구에서 70%의 인식 성능을 보여주고 있다[9].

하지만 환경음 데이터에 의존하는 기존의 환경상황 인식 방식은, 여러 노이즈들이 결합되어 근본적으로 좋은 특징을 추출하기 힘든 환경음의 구조적 특성을 그대로 반영하고 있다. 그 결과 기존의 연구결과에서는 유사한 환경상황들 간에 분류오류가 발생하는 것을 크게 개선하지 못하고 있다. 이에 본 연구에서는 현재 스마트 폰에 탑재되고 있는 자이로센서와 가속도센서를 통해 인식주체의 움직임 특성을 모델링 하여 보다 정확한 환경상황 인식을 위한 새로운 특징조합을 제안하고 실험을 통해 제안한 방식이 환경 인식의 성능을 개선시킬 수 있음을 보이고자 한다.

## II. 실험 데이터 준비와 특징 추출

### 1. 실험 데이터 준비

실험에서 사용한 데이터는 총 9가지 환경에서 휴대용 microphone과 자이로센서 및 가속도센서를 이용하여 획득하였다. 각 환경은 서울 7개호선의 지하철 내부(Subway), 고속철도 내부(KTX), 버스 내부(Urban Bus), 승용차 내부(Vehicle), 극장 내부(Theater), 식당 내부(Restaurant), 강의실 내부(Classroom), 실외 걷기(Outside Walking), 실외 뛰기(Outside Running)이며 각 환경에서 획득한 환경음과 두 가지 센서 데이터의 길이는 대략 60분 전후이다. 본 연구에서 환경음을 얻기 위한 휴대용 microphone은 A600R((주)사파, 서울)을 사용하였고 환경음의 샘플링 주파수는 8kHz, 양자화비트는 16bits이다. 또한 자이로센서는 NT IDG300 모듈((주)엔터렉스, 대전)을 사용하였고 이 모듈은 2축 각속도를 측정할 수 있으므로 3축의 각속도를 측정하기 위해 2개의 모듈을 상호 수직으로 구성하였다. 가속도 센서는 NT Acc7260 모듈((주)엔터렉스, 대전)을 사용하였으며 3축 가속도를 획득 할 수 있게 하였다.

이를 통해 우리는 총 9가지 상황에서 각각 3종류의

데이터를 획득 하였고 구축한 데이터베이스의 세부적인 측정시간과 각 상황, 기타 정보들을 [표 1]에 나타내었다.

표 1. 데이터베이스 구축 정보

상황	측정시간	측정횟수	비고
지하철 내부	20분	7회	서울 7개호선
자동차 내부	20분	4회	중형/소형
KTX 내부	40분	2회	서울-광주
버스 내부	25분	4회	광주시내버스
실외 걷기	5분	12회	남녀구분
실외 뛰기	5분	12회	남녀구분
극장 내부	20분	3회	광주시내 극장
식당 내부	20분	3회	뷔페/일반식당
강의실 내부	20분	3회	대학원 강의

## 2. 특징 추출

환경음의 전처리 과정은 Pre-emphasis, Windowing 으로 구성된다. 일반적으로 환경음 신호는 20Hz~18kHz의 주파수를 가지며 300Hz를 최대로 하여 1kHz 이상부터 에너지 크기가 작아지는 현상을 보인다. 이러한 특성을 보상하기 위해 다음과 같은 고대역 통과 특성을 갖는 pre-emphasis 필터를 사용하였다.

$$H(z) = 1 - 0.97z^{-1} \quad (1)$$

Pre-emphasis 과정을 거친 신호는 일정한 길이의 프레임으로 나누는데 이때 각 프레임 사이의 정보 손실을 고려하여  $N$ 개의 샘플로 blocking하여 하나의 프레임으로 사용하고 다시  $M$ 개의 샘플만큼 이동하여 중첩을 시킨 후, 다시  $N$ 개의 샘플로 blocking하여 다음 프레임으로 사용한다. 본 실험에서는 중첩의 길이  $M$ 은  $N/2$ 로 사용하였다.

프레임으로 나뉜 데이터는 각 프레임 양끝단의 불연속 지점에서 주파수 영역으로 변환 시 원하지 않는 정보를 최소화하기 위해 각 프레임에 다음 식과 같은 Hamming window를 적용하였다.

$$w(n) = 0.54 - 0.46\cos\left(\frac{2\pi n}{N-1}\right) \quad (2)$$

특징 추출을 위해서 본 연구에서는 잡음에 강인한 특성을 보이는 것으로 알려진 MFCC를 사용하였다.

$c[k]$ 를 입력 캡스트럼,  $n$ 이 캡스트럼의 차수,  $L$ 이 윈도우 계수라고 할 때 liftering은 다음 식과 같다.

$$m[k] = \left(1 + \frac{L}{2} \sin \frac{\pi n}{L}\right) c[k] \quad (3)$$

본 실험에서 사용한 윈도우 계수  $L$ 은 22이고, 사전 실험에서 MFCC 차수에 따른 인식 성능과 계산량을 고려한 후 12차로 고정하였다. 실험에서 사용한 MFCC 추출 과정을 [그림 1]에 나타내었다.

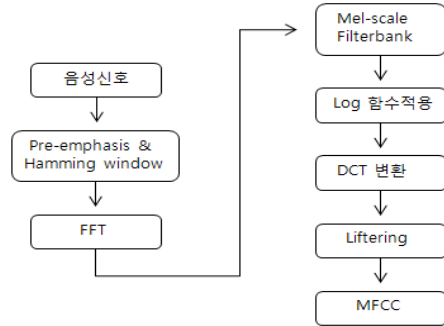


그림 1. MFCC 추출 과정

가속도 센서는 물체의 운동 상태인 가속도, 진동, 충격 등의 동적 힘을 순시 적으로 감지 할 수 있으며 자이로 센서는 물체에 일어나는 회전 운동의 각속도를 검출하는 계측기이다. 이들 센서를 이용한 적용들은 매우 다양하며 최근에는 증강현실과 3D 게임을 위해 스마트폰에 탑재되고 있는 추세이다. 이들 센서는 x, y, z의 3축으로 각각 가속도와 각속도를 계산하는데 본 논문에서는 이들 센서 고유의 출력데이터를 별도의 처리 없이 특징벡터로 사용하였으며 각각 3차의 특징을 사용하였다. 또한 센서의 출력은 매 초당 10회로 100msec마다 각각의 데이터를 얻도록 하였고, MFCC 특징과의 조합을 위해 해당 프레임길이 만큼의 센서의 출력을 평균한 값을 그 특징으로 삼았다.

결국 실험에서 사용한 특징벡터는 MFCC 12차 특징에 가속도 센서 특징 3차, 자이로 센서 특징 3차를 서로

조합하여 구성하였다.

### III. 분류방법 및 실험결과

#### 1. GMM

GMM은 주어진 데이터 집합의 분포밀도를 여러 개의 가우시안 확률밀도함수로 모델링하고 실제 데이터를 기반으로 최대 우도를 가지는 클래스를 선택하는 패턴 인식 방법이다[7][8]. 추출한 특징이  $D$ 차라고 할 때 특징 벡터  $\mathbf{X} = \{x_1, x_2, \dots, x_N\}$ 라고 하면  $M$ 개의 혼합 성분(Mixture Component)을 가지는 가우시안 확률밀도함수의 우도(Likelihood)는 다음의 식과 같다.

$$p(x_t|\lambda) = \sum_{i=1}^M p_i b_i(x_t) \quad (4)$$

$$b_i(x_t) = \frac{1}{(2\pi)^{D/2} |\Sigma_i|^{1/2}} \exp\left(-\frac{1}{2}(x_t - \mu_i)^T \Sigma_i^{-1} (x_t - \mu_i)\right) \quad (5)$$

$$\sum_{i=1}^M p_i = 1, 0 \leq p_i \leq 1, \quad (6)$$

GMM 모델의  $t$  번째 성분 파라미터  $\lambda$ 는 가우시안 혼합 성분 밀도의 가중치(mixture weight)  $p_i$ , 평균 벡터(mean vector)  $\mu_i$  그리고 공분산 행렬(covariance matrix)  $\Sigma_i$ 로 나타낼 수 있으며 다음 식을 이용해 반복적으로 구할 수 있다.

$$\lambda = \{p_i, \mu_i, \Sigma_i\}, \quad i = 1, \dots, M \quad (7)$$

$$p_i = \frac{1}{T} \sum_{t=1}^N p(i|\mathbf{x}_t, \lambda) \quad (8)$$

$$\mu_i = \frac{\sum_{t=1}^N p(i|\mathbf{x}_t, \lambda) \mathbf{x}_t}{\sum_{t=1}^N p(i|\mathbf{x}_t, \lambda)} \quad (9)$$

$$\Sigma_i = \frac{\sum_{t=1}^N p(i|\mathbf{x}_t, \lambda) \mathbf{x}_t^2}{\sum_{t=1}^N p(i|\mathbf{x}_t, \lambda)} - \mu_i^2 \quad (10)$$

여기서  $i$ 번째 성분의 사후 확률(*a posteriori* probability)은 다음과 같다.

$$p(i|\mathbf{x}_t, \lambda) = \frac{p_i b_i(\mathbf{x}_t)}{\sum_{i=1}^M p_i b_i(\mathbf{x}_t)} \quad (11)$$

일반적으로 GMM의 Mixture 수는 인식률과 시스템의 계산량에 직결되는 것으로 적당한 Mixture 개수를 고려하는 것은 중요한 문제이다.

#### 2. 실험결과

본 실험에서는 전체 데이터를 임의로 추출하여 훈련 그룹과 테스트 그룹으로 나누었고, 훈련 그룹에서는 GMM을 이용하여 9개의 클래스 각각의 모델을 생성하였다. 테스트 그룹에서는 공정한 성능평가를 위해 전체 테스트 데이터를 10등분하여 테스트 그룹 내에서 10회의 validation을 수행하였다. 이 훈련 그룹과 테스트 그룹에서 사용한 전체 데이터의 대략적인 크기는 [표 2]와 같다.

표 2. 프레임 사이즈에 따른 특징 데이터의 개수

크기(ms) \ 그룹	200	400	600	800	1000
테스트 그룹	1000	1500	2000	3000	4000
훈련 그룹	2000	2500	3000	5000	6000

MFCC 특징데이터에 가속도, 자이로 센서의 특징 데이터를 각각 조합한 경우와 그렇지 않는 경우의 인식 성능을 비교하기에 앞서 GMM 모델의 Mixture 개수를 고정할 필요가 있으므로 우리는 Mixture 개수에 따라 각 특징데이터들을 분류한 인식결과를 비교해보았고

이를 [그림 2]에 나타내었다. 그래프를 보면 Mixture의 개수가 늘어날수록 각각의 방식에서 인식률은 점차 증가하나 그 증가율이 로그스케일을 따르고 있음을 알 수 있고 그에 비해 계산량은 점차 증가한다. 이에 우리는 각 방식에 따른 인식률을 고려한 후 Mixture의 개수를 13개로 고정하였고, 이를 기준으로 각 특징 조합을 이용한 GMM 분류 결과를 비교하였다.

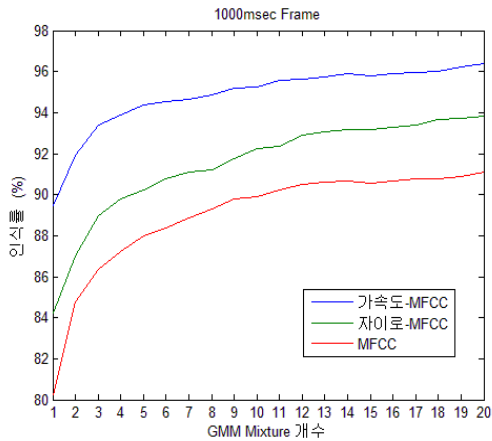


그림 2. GMM Mixture 개수에 따른 인식률

또한 그래프를 살펴보면 세 가지의 특징조합방식 중 가속도-MFCC 특징 조합에서 가장 좋은 성능을 보이고 있고, 자이로-MFCC 조합이 다음으로 좋은 성능을 보임을 알 수 있다.

[표 3]에서는 프레임 길이에 따른 각 특징 조합의 GMM 분류 결과를 보여주고 있다. 일반적으로 상황인지 시스템에서는 가능한 실시간으로 상황을 파악해야

하는 것이 중요한 문제이다. 그러므로 우리는 최대 1초 간격으로 상황인지를 한다는 가정 하에 5가지 프레임 길이에 따른 각각의 특징데이터조합을 GMM 분류한 후 인식 결과를 비교 하였고, 1000msec에서 95.94%로 가장 좋은 성능을 보여주고 있음을 확인하였다.

이 는 고려하는 데이터의 길이가 길수록 인식 성능이 조금씩 나아지는 일반적인 경향과 일치하는 것이다.

표 3. 각 특징 조합에 따른 13개 Mixture GMM 분류 결과.

특징방식 길이 (ms)	MFCC	자이로-MFCC	가속도-MFCC
200	86.21%	90.40%	94.71%
400	87.91%	91.27%	94.66%
600	89.07%	92.14%	95.19%
800	89.51%	92.76%	95.53%
1000	90.62%	93.07%	95.94%

위의 결과들을 바탕으로 보다 구체적인 분석을 위해 [표 4]에서는 MFCC 특징벡터를 GMM으로 분류한 인식결과를, [표 5]에서는 MFCC 특징과 가속도센서의 특징을 조합한 특징벡터를 분류한 결과를 confusion matrix로 나타내었다. 먼저 MFCC 특징 벡터만을 이용한 [표 4]를 분석해 보면 인식 성능 저하의 주원인이 시내버스와 KTX, 지하철, 또 실외 뛰기와 실외 걷기인 것을 확인할 수 있었다. 이 환경상황들은 상대적으로 주변잡음이 많으며 서로 유사한 구조적 특성으로 인해 상호간에 인식 오류를 적지 않게 발생시키고 있고, 이들은 공통적으로 사용자가 이동하거나 움직이고 있는 상

표 4. 1000msec 12차 MFCC 특징, 13개 Mixture의 GMM 분류 결과

	버스	강의실	KTX	식당	뛰기	지하철	극장	자동차	걷기
버스	85.90%	0.00%	4.40%	0.10%	1.80%	4.00%	0.60%	2.50%	0.70%
강의실	0.00%	97.90%	0.00%	1.20%	0.00%	0.10%	0.10%	0.00%	0.70%
KTX	4.90%	0.00%	88.80%	0.00%	1.60%	1.10%	0.30%	3.00%	0.30%
식당	0.00%	1.30%	0.00%	95.00%	0.40%	1.10%	0.10%	0.00%	2.10%
뛰기	0.50%	0.00%	1.30%	0.10%	87.60%	2.80%	0.40%	0.40%	6.90%
지하철	3.00%	0.00%	2.00%	0.60%	2.00%	88.10%	0.00%	0.90%	3.40%
극장	0.20%	0.30%	0.00%	0.00%	0.20%	0.30%	97.70%	0.60%	0.70%
자동차	2.90%	0.00%	3.10%	0.00%	0.90%	0.30%	1.30%	90.10%	1.40%
걷기	0.90%	0.70%	1.50%	2.60%	5.90%	2.20%	0.50%	1.20%	84.50%

표 5. 1000msec MFCC-가속도 15차 특징벡터, 13개 Mixture의 GMM 분류 결과

	버스	강의실	KTX	식당	뛰기	지하철	극장	자동차	걷기
버스	93.30%	0.00%	1.80%	0.20%	0.60%	0.70%	0.50%	2.60%	0.30%
강의실	0.00%	97.30%	0.00%	1.40%	0.00%	0.00%	1.10%	0.00%	0.20%
KTX	0.80%	0.00%	97.40%	0.00%	0.10%	1.30%	0.00%	0.40%	0.00%
식당	0.00%	2.70%	0.00%	96.40%	0.20%	0.10%	0.30%	0.00%	0.30%
뛰기	0.30%	0.00%	0.00%	0.00%	93.80%	0.40%	0.10%	0.10%	5.30%
지하철	0.30%	0.00%	1.20%	0.00%	0.80%	97.10%	0.10%	0.30%	0.20%
극장	0.30%	0.30%	0.10%	0.10%	0.10%	0.00%	98.30%	0.70%	0.10%
자동차	2.90%	0.00%	0.80%	0.00%	0.30%	0.00%	0.40%	95.40%	0.20%
걷기	0.60%	0.40%	0.20%	0.30%	3.40%	0.30%	0.10%	0.20%	94.50%

황인 것을 확인할 수 있었다. 다음으로 기존의 MFCC 특징에 가속도센서의 특징데이터를 조합하여 분류한 [표 5]를 분석해 보면 [표 4]에서 알 수 있었던 성능 저하의 주원인들 간의 인식 오류가 개선되었음을 확인할 수 있었다. 이는 인식주체의 움직임특성을 모델링할 수 있는 가속도 센서 데이터를 특징벡터에 이용함으로써 기존 MFCC 특징 방식을 보완할 수 있다는 것을 의미하는 결과이다.

#### IV. 결론

기존의 환경음 데이터를 이용하여 상황인지를 하는 방식은 여러 노이즈들이 결합되어 근본적으로 좋은 특징을 추출하기 힘든 환경음의 구조적 특성을 그대로 반영하고 있고, 그로 인해 상대적으로 주변잡음이 많고 상호 유사한 구조적 특성을 보이는 인식주체가 이동하는 환경상황을 모델링하지 못하는 단점이 있었다. 이는 본 연구에서 고려한 9가지 상황에서 시내버스와 KTX, 지하철, 또 실외 뛰기와 실외 걷기 등에서 주로 인식오류가 발생하였음을 볼 때 쉽게 알 수 있다. 이를 개선하는 방법으로 본 연구에서는 기존의 환경음 데이터를 이용한 MFCC 특징에 가속도 센서와 자이로 센서의 특징을 조합하는 방식을 제안하였고, 그 결과 가속도 센서의 데이터를 MFCC 특징과 조합한 경우에서 평균인식률을 96% 가까이 끌어올릴 수 있었다. 이를 통해 본 연구에서는 가속도센서와 자이로센서의 데이터를 기존의 MFCC 특징과 조합하는 방식의 도입으로 환경상황인식의 성능을 개선시킬 수 있음을 확인하였다.

하지만 환경음 인식의 실제 서비스를 고려해 보면 환경음의 큰 분산성으로 인해 환경음 전체를 DB로 구성하고 이를 학습시키는 것은 한계가 있음을 알 수 있다. 때문에 인식하고자 하는 특정 환경음 이외의 환경음이 시스템에 입력된다는 가정 하에 이를 처리하는 방법이 필요하며, 앞으로의 연구에서는 특정 도메인이 정해져 있지 않은 상황에서의 인식 성능을 유지하는 방법을 강구 할 것이다.

#### 참고 문헌

- [1] <http://www.teco.edu/tea/>
- [2] L. Ma, B. P. Milner, and D. Smith, "Acoustic environment classification," ACM Transactions on Speech and Language Processing, Vol.3, No.2, pp.1-22, 2006.
- [3] Y. Toyoda, J. Huang, S. Ding, and Y. Liu, "Environmental sound recognition by multilayered neural networks," International Conference on Computer and Information Technology, pp.123-127, 2004.
- [4] L. Couvreur and M. Laniray, "Automatic noise recognition in urban environments based on artificial neural networks and hidden Markov models," InterNoise, Prague, Czech Republic, pp.1-8, 2004.
- [5] N. Sawhney, "Situational awareness from

environmental sounds,” MIT Media Lab. Technical Report, 1997.

- [6] S. Chu, S. Narayana, C.-C. J. Kuo, and M. J. Mataric, “Where am I? Scene recognition for mobile robots using audio features,” in Proc. ICME, 2006.
- [7] R. G. Malkin and A. Waibel, “Classifying user environment for mobile applications using linear autoencoding of ambient audio,” in Proc. ICASSP, 2005.
- [8] A. Eronen, V. Peltonen, J. Tuomi, A. Klapuri, S. Fagerlund, T. Sorsa, G. Lorho, and J. Huopaniemi, “Audio-based context recognition,” IEEE Trans. on Audio, Speech, and Language Processing, Vol.14, No.1, pp.321-329, 2006(1).
- [9] S. Chu, S. Narayanan, and C.-C. Jay Kuo “Environmental Sound Recognition With Time-Frequency Audio Features,” IEEE Trans. on Audio, Speech, and Language Processing, Vol.17, No.6, pp.1-16, 2009.
- [10] A. Kobayashi, T. Iwamoto, S. Nishiwama “UME : Method for Estimating User Movement Using an Acceleration Sensor,” in Proc. SAINT, 2008.
- [11] C. M. Bishop, *Neural networks for pattern recognition*, Oxford University Press, UK, 1995.
- [12] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*, Jone Wiley & Son, Inc. 2001.

저 자 소 개

박 준 규(Jun-Qyu Park)

준회원



- 2009년 2월 : 전남대학교 전자컴퓨터공학부(공학사)
- 2009년 3월 ~ 현재 : 전남대학교 전자공학과(석사과정)

<관심분야> : 디지털 신호처리, 패턴인식

백 성 준(Seong-Joon Baek)

정회원



- 1989년 2월 : 서울대학교 전자공학과(공학사)
- 1992년 2월 : 서울대학교 전자공학과(공학석사)
- 1999년 2월 : 서울대학교 전자공학과(공학박사)

▪ 2002년 3월 ~ 현재 : 전남대학교 전자공학과 교수  
<관심분야> : 의료, 통신, 음성 관련 디지털 신호처리