

Minimum Classification Error 방법 도입을 통한 Gaussian Mixture Model 환경음 인식성능 향상

Gaussian Mixture Model using Minimum Classification Error for Environmental Sounds Recognition Performance Improvement

한다정, 박아론, 박준규, 백성준
전남대학교 전자컴퓨터공학부

Da-Jeong Han(secret8787@naver.com), Aaron Park(dode@daum.net),
Jun-Qyu Park(junq14@naver.com), Sung-June Baek(tozero@chonnam.ac.kr)

요약

본 연구에서는 환경음 인식 성능의 향상을 위하여 GMM의 훈련 방식에 MCE 도입을 제안하였다. 이는 환경음 데이터 모델링에 사용할 분류오류함수를 정의할 때 해당 클래스의 로그우도 뿐 아니라 다른 클래스의 로그우도도 같이 고려함으로써 변별력 있는 분류가 이뤄질 수 있게 한다. 모델의 파라미터는 전체 클래스를 고려한 손실함수를 정의하고, GPD(generalized probabilistic descent) 알고리즘을 이용하여 추정하였다. 제안된 방법의 인식 성능 비교를 위해 모두 9가지 환경음을 전처리 과정과 MFCC(mel-frequency cepstral coefficients)를 이용하여 12차 특징을 추출하고, 이를 혼합 성분의 수에 따라 GMM 분류 실험을 행하였다. 실험 결과에 따르면 혼합 성분을 19개 사용한 경우에서 MCE 훈련 방식이 평균 87.06%의 인식률로 가장 좋은 성능을 보였다. 이 결과로 제안한 MCE 훈련 방식이 환경음 인식에서 GMM의 훈련 방식으로 효과적으로 사용될 수 있음을 확인하였다.

■ 중심어 : | 상황인식 | 환경음 | GMM | MLE | Minimum Classification Error

Abstract

In this paper, we proposed the MCE as a GMM training method to improve the performance of environmental sounds recognition. We model the environmental sounds data with newly defined misclassification function using the log likelihood of the corresponding class and the log likelihood of the rest classes for discriminative training. The model parameters are estimated with the loss function using GPD(generalized probabilistic descent). For recognition performance comparison, we extracted the 12 degrees features using preprocessing and MFCC(mel-frequency cepstral coefficients) of the 9 kinds of environmental sounds and carry out GMM classification experiments. According to the experimental results, MCE training method showed the best performance by an average of 87.06% with 19 mixtures. This result confirmed us that MCE training method could be effectively used as a GMM training method in environmental sounds recognition.

■ keyword : | Context Aware | Environmental Sounds | GMM | MLE | Minimum Classification Error

* 본 연구는 2011년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (No. 2011-0009213)

I. 서론

최근 스마트폰이나 태블릿PC의 이용이 급속히 증가함에 따라 지능형 서비스에 대한 요구가 확대되고 있다. 지능형 서비스는 사용자의 상황에 필요한 정보와 서비스를 실시간으로 제공할 수 있는 스마트 환경의 핵심 기술이다. 이 서비스는 이동성, 지능성, 융합성, 양방향성의 특징을 기반으로 개인의 특성이 반영된 맞춤형 서비스를 가능하게 한다[1]. 상황인식(context aware)은 사용자가 처한 환경이나 위치 등의 특정 상황을 인식하여 제공되는 지능형 서비스이다[2]. 상황인식 기술은 사용자 중심의 설계, 개인화 서비스, 위치정보, 지식 검색 등을 포함한 다양한 분야에서 현재 활용되고 있다[3]. 이 기술은 데스크톱과 웹을 이용한 유선 서비스에서 스마트기기와 무선인터넷을 중심으로 한 모바일 환경으로 발전하고 있다.

모바일 환경에서 상황인식은 센서와 마이크로폰과 같은 가속도, 위치, 온도, 소리 등의 디바이스 정보와 사용자가 생성한 데이터 및 개인 정보 등을 이용한다. 예를 들어, 사용자가 극장이나 강의실과 같은 공공장소에 있는 경우 상황 정보를 바탕으로 자동으로 휴대용 단말기를 에티켓 모드로 전환하는 등의 서비스를 제공할 수 있다. 이 경우에 GPS(global positioning system)와 전자지도를 기반으로 한 위치 정보만으로 서비스를 제공하기엔 한계가 있으며 환경음 인식 기술을 이용한 환경 정보를 통하여 적절한 서비스를 제공할 수 있다.

환경음 인식 기술은 기존의 음성 인식 기술을 토대로 그 성능을 개선하는 방향으로 발전하고 있다. 환경음은 무작위성과 높은 분산성 등의 특성으로 인하여 클래스가 증가할수록 인식 성능이 급격히 감소한다[4]. 따라서 환경음 인식 기술의 전처리, 특징추출, 분류 과정은 이러한 특성이 충분히 고려되어야 한다. 기존 연구에는 환경음 인식에 MFCC 특징을 사용하여 GMM 분류 방법을 적용한 환경음 인식 연구결과와 사후 확률(*a posteriori probability*)에 후처리기법을 적용하여 그 성능을 개선한 연구 결과 등이 있는데[5], 이러한 연구의 대부분은 GMM을 분류 방법으로 이용하였다[6-9].

GMM의 일반적인 훈련방식인 MLE는 데이터의 로그

우도(log likelihood)를 최대로 하는 가우시안 모델의 파라미터를 추정한다. 하지만 이 방식은 각 클래스를 독립적으로 모델링하므로 환경음 특성에 효과적으로 대응하지 못하는 문제가 있다. 이러한 단점은 분류오류의 최소화를 보장하지 못하여 시스템의 성능 저하로 직결된다[4]. 이에 비해 MCE는 전체 클래스를 고려한 손실 함수(loss function)를 최소화함으로써 분류오류에 직접적으로 관여하여 변별력 있는 훈련을 보장한다[10].

본 연구에서는 환경음 인식 성능의 향상을 위해 GMM의 훈련방식에 MCE의 도입을 제안하였다. 서로 다른 9가지 환경음은 몇 가지 전처리 방법을 적용한 다음 MFCC를 이용하여 12차의 특징으로 변환하고 혼합 성분의 수에 따른 GMM 분류 실험을 행하였다. 그리고 제안한 방법의 효율성을 입증하기 위해 MLE 훈련 방식을 사용한 경우와 MCE를 도입한 결과를 비교하고 그 결과를 분석하였다.

본 논문의 구성은 다음과 같다. II장에서 실험에 사용된 데이터를 소개하고, III장에서는 기존 훈련방식인 MLE와 제안한 훈련방식인 MCE에 대해 기술한다. 다음 IV장에서는 제안하는 기법의 성능 평가를 위해 실시한 실험과 그 결과에 관해 고찰하고 마지막으로 V장에서는 결론을 맺는다.

II. 실험 데이터와 전처리

실험에서 사용한 데이터는 모두 9가지 환경에서 모바일기반 microphone을 이용하여 획득하였다. 환경음 데이터 각각의 길이는 대략 60분 전후이고, 샘플링 주파수는 8kHz, 양자화비트는 16bits이다. 구축한 환경음 데이터베이스의 정보들을 [표 1]에 나타내었다.

표 1. 환경음 데이터베이스 구축 정보

환경음 상황	측정시간	측정횟수	비고
지하철 내부	20min	7회	서울 7개호선
자동차 내부	20min	4회	중형/소형
KTX 내부	40min	2회	서울-광주
버스 내부	25min	4회	광주시내버스
실외 걷기	5min	12회	남녀구분
실외 뛰기	5min	12회	남녀구분

극장 내부	20min	3회	광주시내 극장
식당 내부	20min	3회	뷔페/일반식당
강의실 내부	20min	3회	대학원 강의

환경음 데이터는 프레임의 길이가 N 이고 다음프레임은 $N/2$ 만큼 이동하여 이전 프레임과 중첩하는 방식으로 분할하였다. 본 실험에서 사용한 프레임의 길이는 N 은 8000이다. 분할 시에는 Hamming 창을 이용하였으며, 분할된 데이터는 고주파 성분을 강조하여 주파수 특성을 평탄하게 하도록 pre-emphasis를 적용하였다.

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

전처리 과정을 거친 데이터는 MFCC를 사용하여 12차 특징을 추출하였다.

III. GMM 훈련 알고리즘

GMM은 주어진 데이터의 분포를 여러 개의 가우시안 확률밀도함수로 모델링하는 방법이다. M 개의 혼합 성분(mixture component)을 갖는 특징벡터 $\mathbf{X}_k = \{\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_T\}$ 의 가우시안 분포는 다음과 같다.

$$\Theta = \{\theta_1, \theta_2, \dots, \theta_k\}, \quad \theta = \{p_m, \mu_m, \Sigma_m\}_{m=1}^M \quad (2)$$

$$p(\mathbf{x}_t | \theta) = \sum_{m=1}^M p_m N(\mathbf{x}_t | \mu_m, \Sigma_m) \quad (3)$$

$$\sum_{m=1}^M p_m = 1, \quad 0 \leq p_m \leq 1 \quad (4)$$

이때 Θ 는 GMM 파라미터들의 집합이며, k 는 각 모델에 해당하는 클래스의 수를 나타낸다. 각 가우시안 분포의 파라미터 θ 는 가우시안 혼합 성분 밀도 가중치(mixture weight) p_m , 평균 벡터(mean vector) μ_m 그리고 공분산 행렬(covariance matrix) Σ_m 로 나타낼 수 있다. 본 실험에서 사용한 GMM 파라미터 Θ 의 초기값은 k -means 알고리즘으로 추정하였다.

1. MLE

MLE는 우도가 최대가 되게 하는 각각의 모델 파라미터 θ 를 추정한다. 이 때 최대 우도(maximum likelihood)를 찾기 위해 EM(expectation-maximization) 알고리즘을 이용하며 식은 다음과 같다[11].

$$\hat{p}_m = \frac{1}{T} \sum_{t=1}^T \hat{p}(i | \mathbf{x}_t, \hat{\theta}) \quad (5)$$

$$\hat{\mu}_m = \frac{\sum_{t=1}^T \hat{p}(i | \mathbf{x}_t, \hat{\theta}) \mathbf{x}_t}{\sum_{t=1}^T \hat{p}(i | \mathbf{x}_t, \hat{\theta})} \quad (6)$$

$$\hat{\Sigma}_m = \frac{\sum_{t=1}^T \hat{p}(i | \mathbf{x}_t, \hat{\theta}) \mathbf{x}_t^2}{\sum_{t=1}^T \hat{p}(i | \mathbf{x}_t, \hat{\theta})} - \hat{\mu}_m^2 \quad (7)$$

여기서 i 번째 성분의 사후 확률은 다음과 같다.

$$\hat{p}(i | \mathbf{x}_t, \hat{\theta}) = \frac{\hat{p}_m N(\mathbf{x}_t | \mu_m, \Sigma_m)}{\sum_{m=1}^M \hat{p}_m N(\mathbf{x}_t | \mu_m, \Sigma_m)} \quad (8)$$

MLE는 각 가우시안 모델에 대한 우도를 최대로 하는 것을 목표로 할 뿐이며 데이터를 모델링 할 때 해당 클래스의 데이터만을 고려한다. 이는 각 클래스를 변별력 있게 분류할 수 있는 성능은 보장하지 않는다.

2. MCE

MCE는 최소분류오류 확률값을 정확히 구하는 대신 분류오류로 인하여 발생하는 손실함수를 최소화 하는 방법이다[12][13]. 이 방식은 로그 우도를 이용하여 변별함수(discriminant function) $G_k(\cdot)$ 를 정의하고, 모델 파라미터 θ 에 대한 특징벡터 \mathbf{X}_k 의 로그 우도인 $g_k(\mathbf{X}_k; \theta)$ 를 이용하여 다음과 같은 분류오류함수(misclassification function)를 정의한다.

$$d_k(\mathbf{X}_k; \theta) = -g_k(\mathbf{X}_k; \theta) + G_k(\mathbf{X}_k; \theta) \quad (9)$$

$$G_k(\mathbf{X}_k; \theta) = \max_{y \neq k} g_y(\mathbf{X}_k; \theta) \quad (10)$$

이 때 $d_k(\mathbf{X}_k; \boldsymbol{\theta})$ 가 양수이면 변별함수 $G_k(\cdot)$ 가 많이 반영되었음을 의미한다. $G_k(\cdot)$ 는 해당 클래스인 k 를 제외한 나머지 클래스를 이용한 로그우도이므로 분류 오류가 발생한 것을 의미한다. 반대로 $d_k(\mathbf{X}_k; \boldsymbol{\theta})$ 가 음수이면 해당 클래스에 대한 로그우도인 $g_k(\mathbf{X}_k; \boldsymbol{\theta})$ 를 많이 반영함으로써 분류오류가 발생하지 않음을 의미한다.

따라서 주어진 데이터에 대해 $d_k(\mathbf{X}_k; \boldsymbol{\theta})$ 값이 적을수록 더 좋은 모델이라고 볼 수 있다. 이와 같이 MCE는 해당 클래스뿐만 아니라 그 외의 나머지 클래스의 데이터를 모두 고려하여 분류오류함수를 정의함으로써 변별력을 향상시킬 수 있다.

손실함수는 분류오류함수 d_k 를 이용하고 함수 값의 범위가 [0 1]이 되도록 다음과 같은 sigmoid function으로 정의된다.

$$l_k(\mathbf{X}_k; \boldsymbol{\theta}) = \frac{1}{1 + \exp(-\gamma d_k)} \quad (11)$$

이 때 γ 는 상수이며 손실함수의 기울기를 조절하는 역할을 한다. 본 실험에서 사용한 γ 는 0.1이다. MCE 방식은 GPD 알고리즘을 이용하여 손실함수가 최소가 되는 파라미터 $\boldsymbol{\theta}$ 를 추정한다. GMM 파라미터의 제약조건인

$$\Sigma_m > 0, \sum_{m=1}^M p_m = 1 \text{ 를 유지하기 위해 } \hat{p}_m = \log p_m,$$

$\hat{\mu}_m = \mu_m / \sigma_m, \hat{\Sigma}_m = \log \Sigma_m$ 으로 파라미터 변환을 수행하고 매 반복마다 다음과 같이 업데이트한다[14-15].

$$\hat{\boldsymbol{\theta}}(r+1) = \hat{\boldsymbol{\theta}}(r) - \epsilon_r \nabla l_k(\mathbf{X}_k; \hat{\boldsymbol{\theta}}) \quad (12)$$

$$\nabla_{\hat{\boldsymbol{\theta}}_j} l_k(\mathbf{X}_k; \hat{\boldsymbol{\theta}}) = \frac{\partial l_k}{\partial d_k} \frac{\partial d_k}{\partial g_j} \nabla_{\hat{\boldsymbol{\theta}}_j} g_j(\mathbf{X}_k; \hat{\boldsymbol{\theta}}) \quad (13)$$

$$\nabla_{\hat{\boldsymbol{\theta}}_j} g_j(\mathbf{X}_k; \hat{\boldsymbol{\theta}}) = \frac{1}{T} \sum_{t=1}^T \frac{1}{b_j(\mathbf{x}_t)} \nabla_{\hat{\boldsymbol{\theta}}_j} b_j(\mathbf{x}_t) \quad (14)$$

이 때 ϵ_r 은 r 번째 반복에서 learning step size만큼 단조 감소한다. $\partial l_k / \partial d_k = \gamma l_k(1 - l_k)$ 이며, $\partial d_k / \partial g_j$ 는 j 가 현재 클래스인 k 와 같으면 -1이 된다. 또한 j 가 k 를 제외한 클래스 중에서 변별함수를 최대로 하는 클래스

인 y 와 같다면 1이며 그 외에는 0이 된다. $\nabla_{\hat{\boldsymbol{\theta}}_j} b_j(\mathbf{x}_t)$ 는 다음과 같고 j 는 생략하여 나타내었다.

$$\frac{\partial b(\mathbf{x}_t)}{\partial \hat{p}_m} = p_m N(\mathbf{x}_t | \mu_m, \Sigma_m) \quad (15)$$

$$\frac{\partial b(\mathbf{x}_t)}{\partial \hat{\mu}_m} = \frac{\mathbf{x}_t - \mu_m}{\sigma_m} p_m N(\mathbf{x}_t | \mu_m, \Sigma_m) \quad (16)$$

$$\frac{\partial b(\mathbf{x}_t)}{\partial \hat{\Sigma}_m} = \left\{ \left(\frac{\mathbf{x}_t - \mu_m}{\sigma_m} \right)^2 - 1 \right\} p_m N(\mathbf{x}_t | \mu_m, \Sigma_m) \quad (17)$$

IV. 실험결과

본 실험에서는 각 클래스의 데이터를 훈련그룹과 실험그룹으로 나누었는데 각각의 데이터 수는 2569개, 514개이다. 분류실험은 MLE와 MCE 훈련방식을 적용하여 혼합성분의 개수를 1부터 20까지 증가시켜 수행하였다. 두 가지 분류실험 모두 초기 파라미터 추정은 k -means를 적용하였고 GMM은 초기 파라미터 추정 값에 따라 인식성능이 달라지므로 실험을 총 3회 수행한 후 평균한 결과를 [그림 1]에 제시하였다.

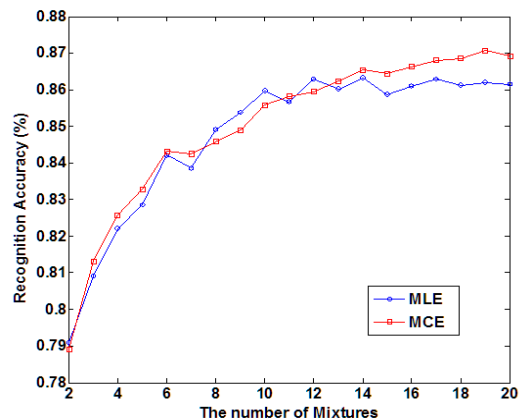


그림 1. MLE와 MCE 훈련방식 및 혼합성분 개수에 따른 인식률

[그림 1]을 살펴보면, 첫째로 기존 훈련방식인 MLE

를 적용하였을 경우 14개의 혼합성분을 사용했을 때 86.31%의 최대 인식률을 보였다. 이 때 MCE를 적용한 인식률 결과는 86.53%로써 0.22% 향상되었다. 둘째로 MCE 훈련방식을 적용하였을 경우 19개의 혼합성분을 사용했을 때 87.06%의 최대 인식률을 나타내었다. 이 경우 역시 MLE를 적용한 인식 성능보다 0.86% 향상된 결과를 확인할 수 있다. 이를 바탕으로 MLE와 MCE 훈련방식을 적용하였을 때 가장 높은 성능을 보인 경우는 MCE 훈련방식을 사용한 경우임을 알 수 있다.

또한, [그림 1]에서 알 수 있듯이 1부터 12개의 혼합성분까지는 MLE와 MCE 훈련방식이 서로 번갈아가며 성능이 향상되다가 13개 이상의 혼합성분에 대해서는 MCE가 더 좋은 성능을 보임을 확인할 수 있다. 10개 이하의 혼합성분의 개수는 환경음의 무작위성과 높은 분산성을 잘 고려하여 데이터를 모델링하기 어렵기 때문에 10개 이상의 혼합성분이 사용되어 지는데 본 실험결과를 통해 환경음을 잘 표현하기 위해 쓰이는 혼합성분의 개수에서는 MCE가 더 좋은 성능을 보임을 알 수 있다.

MCE 훈련방식을 적용함으로써 향상된 인식성능을 자세히 살펴보기 위해, GMM 혼합성분의 수에 따른 MLE보다 향상된 MCE 인식 성능을 [그림 2]에 나타내었다.




그림 2. GMM 혼합성분 수에 따른 MLE보다 향상된 MCE 인식률

[그림 2]는 각 혼합성분의 수에 대해 MLE 훈련방식을 적용한 경우의 인식률을 '0'으로 볼 때, 증가되거나

감소된 MCE 훈련방식의 인식률을 나타내고 있다. MCE 방식을 적용한 경우가 모든 GMM 혼합성분의 수에서 인식률이 향상된 건 아니지만 6개의 혼합성분을 제외한 나머지 14개의 혼합성분에서 MLE 훈련방식보다 더 높은 성능을 보였다. 특히 혼합성분의 수를 19개 적용한 경우 MLE 훈련방식 보다 향상된 성능은 0.86%이다. 이는 MCE 훈련방식 도입을 통한 최대 인식 성능 향상 수치가 0.86%임을 알 수 있다.

이 결과로부터 MCE 훈련방식이 환경음을 모델링 할 때 해당 클래스뿐만 아니라 나머지 클래스에 대한 로그우도를 이용하여 모델링함으로써 환경음 데이터의 무작위성과 높은 분산성을 갖는 구조적 특성에 대응하여 변별력을 향상시키는 것을 확인하였다. 또한, 실제로 환경음을 잘 표현하기 위해 쓰이는 12개 이상의 혼합성분에서 향상된 인식성능을 보임으로써 환경음 인식에 효과적으로 적용될 수 있음을 확인하였다.

V. 결론

본 연구에서는 환경음 인식 성능의 향상을 위하여 GMM의 훈련 방식에 MCE 도입을 제안하였다. GMM의 일반적인 훈련방식인 MLE는 각 클래스를 독립적으로 모델링하므로 환경음의 특성에 효과적으로 대응하지 못하는 반면 MCE는 전체 클래스를 고려하여 손실함수를 최소화하므로 인식 성능을 향상할 수 있다. 인식 성능의 비교 실험을 위해 모두 9가지 환경음을 전처리 과정과 MFCC를 이용하여 12차의 특징을 추출하고 혼합성분의 수에 따른 GMM 분류 실험의 입력으로 사용하였다. 실험 결과에 따르면 혼합성분을 19개 사용한 경우에서 MCE 훈련 방식이 평균 87.06%의 인식률로 가장 좋은 성능을 보였다. 이 결과로 제안한 MCE 훈련방식이 환경음 인식에서 GMM의 훈련 방식으로 효과적으로 사용될 수 있음을 확인하였다. 이 결과를 토대로 MCE 훈련 방식을 도입한 GMM을 이용하여 환경음 인식에 적합한 특징을 추출하는 방법을 연구할 계획이다.

참고 문헌

- [1] 한국정보화진흥원 국가정보화기획단 정보화전략 기획부, *스마트 시대의 패러다임 변화 전망과 ICT 전략*, 한국정보화진흥원, 2010.
- [2] B. Schilit, N. Adams, and R. Want, "Context-aware computing applications," In proceedings of IEEE Workshop on Mobile Computing Systems and Applications, pp.85-90, 1994.
- [3] 홍일영, *상황인지 소프트웨어, 이젠 몸짓을 넘어 마음을 읽어야한다*, 한국소프트웨어진흥원, 2008.
- [4] 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.
- [5] 박준규, 백성준, "후처리를 이용한 환경음 인식 성능 개선," 한국콘텐츠학회, 제10권, 제7호, pp.31-39, 2010.
- [6] 박준규, 백성준, "멀티 신호를 이용한 환경 인식 성능 개선," 한국콘텐츠학회, 제10권, 제12호, pp.27-33, 2010.
- [7] S. Chu, S. Narayanan, and C. C. Jay Kuo, "Environmental sound recognition using MP-based features," IEEE International Conference on Acoustics, Speech and Signal Processing, pp.1-4, 2008.
- [8] M. Cowling and R. Sitte, "Comparison of techniques for environmental sound recognition," Pattern Recognition Letters, Vol.24, No.15, pp.2895-2907, 2003.
- [9] 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.
- [10] B. H. Juang, W. Chou, and C. H. Lee, "Minimum classification error rate methods for speech recognition," IEEE Trans. Speech Audio Process, Vol.5, No.3, pp.257-265, 1997.
- [11] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*, John Wiley & Sons, 2001.
- [12] B. H. Juang and S. Katagiri, "Discriminative learning for minimum error classification," IEEE Trans. signal processing, Vol.40, No.12, pp.3043-3054, 1992.
- [13] C. Ma and E. Chang, "Comparison of discriminative training methods for speaker verification," IEEE International conference, Acoustic, Speech and Signal processing, Vol.1, pp.192-195, 2003.
- [14] Yusuke Kida and Hiroyoshi Yamamoto, "Minimum classification error interactive training for speaker Identification," IEEE International conference, Acoustic, Speech and Signal processing, Vol.1, pp.641-644, 2005.
- [15] C. Miyajima, K. Tokuda, and T. Kitamura, "Minimum classification error training for speaker identification using gaussian mixture models based on multi-space probability distribution," EUROSPEECH, Vol.4, pp.2837-2840, 2001.

저자 소개

한 다 정(Da-Jeong Han)

준회원



- 2010년 2월 : 전남대학교 전자공학컴퓨터공학과(공학사)
- 2010년 3월 ~ 현재 : 전남대학교 전자컴퓨터공학과 석사과정

<관심분야> : 디지털 신호처리, 패턴 인식, 환경음 인식

박 아 론(Aaron Park)

정회원



- 2006년 2월 : 전남대학교 전자컴퓨터정보통신공학부(공학사)
- 2008년 2월 : 전남대학교 전자공학과(공학석사)
- 2009년 8월 : 전남대학교 전자컴퓨터공학과(박사수료)

<관심분야> : 디지털 신호처리, 패턴인식

박 준 규(Jun-Qyu Park)

준회원




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

<관심분야> : 디지털 신호처리, 패턴인식

백 성 준(Sung-June 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