

SMV코덱의 음성/음악 분류 성능 향상을 위한 최적화된 가중치를 적용한 입력벡터 기반의 SVM 구현

Analysis and Implementation of Speech/Music Classification for 3GPP2 SMV Codec Employing SVM Based on Discriminative Weight Training

김 상 균*, 장 준 혁*, 조 기 호**, 김 남 수**
(Sang-Kyun Kim*, Joon-Hyuk Chang*, Ki Ho Cho**, Nam Soo Kim**)

*인하대학교 전자공학부, **서울대학교 전기컴퓨터공학부
(접수일자: 2009년 2월 3일; 수정일자: 2009년 5월 6일; 채택일자: 2009년 5월 20일)

본 논문에서는 변별적 가중치 학습 (discriminative weight training) 기반의 최적화된 가중치를 가지는 입력벡터를 구성하여 support vector machine (SVM)을 이용한 기존의 3GPP2 selectable mode vocoder (SMV)코덱의 음성/음악 분류 성능을 향상 시키는 방법을 제안한다. 구체적으로, 최소 분류 오차 (minimum classification error (MCE)) 방법을 도입하여, 최적화된 가중치를 각각의 특징벡터별로 부가한 SVM을 적용하여 기존의 가중치를 고려하지 않은 SVM 기반의 알고리즘과 비교하였으며, 우수한 음성/음악 분류 성능을 보였다.

핵심용어: 음성/음악 분류 알고리즘, Selectable Mode Vocoder (SMV), Support Vector Machine (SVM), Minimum Classification Error, 변별적 가중치 학습

투고분야: 음성처리 분야 (2,4)

In this paper, we apply a discriminative weight training to a support vector machine (SVM) based speech/music classification for the selectable mode vocoder (SMV) of 3GPP2. In our approach, the speech/music decision rule is expressed as the SVM discriminant function by incorporating optimally weighted features of the SMV based on a minimum classification error (MCE) method which is different from the previous work in that different weights are assigned to each the feature of SMV. The performance of the proposed approach is evaluated under various conditions and yields better results compared with the conventional scheme in the SVM.

Keywords: Speech/Music Classification Algorithm, Selectable Mode Vocoder (SMV), Support Vector Machine (SVM), Minimum Classification Error, Discriminative Weight Training

ASK subject classification: Speech Signal Processing (2,4)

I. 서론

최근의 이동통신기기는 다양한 멀티미디어 서비스를 구현하고 있다. 때문에 제한된 주파수 대역에서의 효율적인 통신환경을 구축하기 위한 연구가 활발히 진행되고 있다. 제한된 주파수 대역을 효과적으로 사용하기 위하여 입력 신호의 특징에 따라서 선택적으로 프레임마다 4단계로 나누어 전송물을 결정해 부호화 하는 방식은

3GPP2의 표준 코덱인 selectable mode vocoder (SMV)에서 사용하고 있다 [1][2]. 입력 신호의 종류에 따라 프레임마다 전송률을 적절히 부여하는 것이 이동통신기기에서의 통화음질을 결정짓는 중요한 과제이다. 특히 최근의 이동통신 환경은 음성전달에만 국한 된 것이 아니라 음악, 사진, 영상 등과 같이 다양한 정보를 제한된 주파수 대역에서 전송해야 한다. 그러므로 효과적인 음성/음악 분류 방법을 찾기 위한 연구가 절실하다 [3][4].

본 논문에서는 변별적 가중치 학습 (discriminative weight training) 기반의 support vector machine (SVM)을 이용한 음성/음악 분류알고리즘을 제안한다. SMV코덱

책임저자: 장 준 혁 (changjh@mha.ac.kr)
인천시 남구 용현동 253 인하대학교 전자공학부
(전화: 032-860-7423; 팩스: 032-868-3654)

인코딩부분의 전처리과정에서 추출한 파라미터 중 통계적 학습 분류성능이 우수한 것들을 모아 변별적 가중치 학습을 위한 최소 분류 오차 minimum classification error (MCE) 방법을 이용하여 추출한 최적의 가중치를 적용하여 특징벡터로 사용하였다. 구체적으로 [5]에서 SVM기반의 음성/음악분류기법이 기존의 SMV코덱의 방법보다 우수한 성능을 보였으나, 이때 각 SVM에 입력되는 특징벡터에는 동일한 가중치가 적용되어 있어 실제 상황을 고려하고 있다고 보기 어렵다. 제안된 방식에서는 MCE방법에서 도출한 최적화된 가중치를 SVM의 입력 벡터에 적용함으로써 동일한가중치를 특징벡터에 적용한 기존의 SVM 기반의 방법 [5]과 음성/음악 분류 성능을 다양한 환경에서 비교하였다.

본 논문의 II장에서는 SMV코덱에서 추출한 특징벡터를 SVM에 적용한 음성/음악 분류 방법을 알아보고 III장에서는 변별적 가중치 학습을 이용하여 구한 최적의 가중치를 특징벡터에 적용한 SVM 음성/음악 알고리즘을 소개한다. IV장에서는 다양한 환경에서 기존의 SVM 실험결과와 제안된 알고리즘의 실험결과를 비교하였으며 V장에서 결론을 맺는다.

II. 동일 가중치를 적용한 SVM 음성/음악 분류방법

2.1. SMV코덱에서 추출된 특징벡터

SMV코덱 인코딩부분의 전처리과정에서 추출한 파라미터 중 많은 음성과 음악 데이터에 대해 수동으로 히스토그램을 이용한 통계적 학습 분류성능을 조사하였다. 이중 음성/음악 분류성능이 우수한 6개의 특징벡터를 선택하였고 아래와 같이 정리한다.

1. 이동 평균 에너지 \bar{E}

$$\bar{E} = 0.75 \cdot \bar{E} + 0.25 \cdot E \tag{1}$$

여기서 E 는 프레임 에너지이다.

2. 잡음/목음의 이동 평균 반사계수 $\bar{k}_N(i)$

$$\bar{k}_N(i) = 0.75 \cdot \bar{k}_N(i) + 0.25 \cdot k_1(i), \quad i = 1, \dots, 10 \tag{2}$$

여기서 i 는 차수이다.

3. 부분적 잔류 에너지의 이동 평균 $\overline{E_N^{res}}$

$$\overline{E_N^{res}} = 0.9 \cdot \overline{E_N^{res}} + 0.1 \cdot E^{res} \tag{3}$$

여기서 $\overline{E_N^{res}}$ 는 위의 k_N 에 따라서 값이 갱신된다.

4. 정규화 된 피치 상관도의 이동 평균 $\overline{corr_p}$

$$\overline{corr_p} = 0.8 \cdot \overline{corr_p} + 0.2 \cdot \left(\frac{1}{5} \cdot \sum_{i=1}^5 corr_p^B(i) \right) \tag{4}$$

여기서 $corr_p^B(i)$ 는 이전 프레임의 피치 상관도이다.

5. 주기적 계수 \bar{c}_{pr}

$$\bar{c}_{pr} = \alpha \cdot \bar{c}_{pr} + (1 - \alpha) \cdot c_{pr} \tag{5}$$

여기서 α 는 c_{pr} 에 따라 값을 바꿔주는 정해진 가중치이다.

6. 음악 연속 계수의 이동 평균 \bar{c}_M

$$c_M = 0.9 \cdot \bar{c}_M + 0.1 \cdot c_M \tag{6}$$

SMV의 VAD에서는 식 (1)~(5)로 부터 나온 결과를 정해진 문턱 값과 비교하여 음성의 유무를 판단하며 Music Detection에서는 $\bar{c}_{pr} \geq 18$ 또는 $\bar{c}_M > 200$ 이면 음악으로 판단한다 [6].

2.2. SVM 음성/음악 분류방법

이진 패턴 분류에 뛰어난 성능을 보이는 SVM은 패턴을 고차원 특징 공간으로 사상(mapping)시킬 수 있어 선형 분리가 불가능한 패턴의 선형분리를 가능하게 하고 알려지지 않은 확률 분포를 갖는 데이터에 대해 잘못 분류하는 확률을 최소화 하는 구조적인 위험 최소화(structural risk minimization) 방법에 기초하고 있다 [7]. 선형적으로 분류 가능한 데이터에 대한 이진 분류에 있어 두 개의 클래스를 분류할 수 있는 많은 초평면(hyperplane) 중 클래스의 가장 가까운 점들과 마진이 최대가 되는 최적의 초평면을 구함으로써 높은 일반화 성능을 기대할 수 있다.

학습 데이터가 $(x_1, y_1), \dots, (x_n, y_n), y \in \{-1, 1\}$ 과 같이 주어질 때 초평면 방정식은 $w^T x_i + b = 0$ 이다. 여기서 w 는 초평면에 대한 단위(normal) 법선벡터이고 b 는 중심에서 초평면까지의 거리이다. 이때 SVM의 학습 능력을 높이기 위해서는 최적의 초평면을 구해야 한다.

즉, 마진을 최대화해야하므로 아래의 조건을 만족해야 한다.

$$\text{Minimize : } \mathcal{J}(w) = \frac{\|w\|^2}{2} \tag{7}$$

$$\text{Subject to : } y_i(w^T x_i + b) - 1 \geq 0, \text{ for } i = (1, \dots, N) \tag{8}$$

최적의 \hat{w} 와 \hat{b} 은 라그랑지안 최적화 (lagrangian optimization) 기법을 이용하여 목적식과 제약식을 결합한 후 라그랑제 승수 α_i 를 포함하여 다음과 같은 식으로부터 구한다.

$$\mathcal{J}(w, b, a) = \frac{1}{2} \|w\|^2 + \sum_{i=1}^m \alpha_i (y_i \cdot [w^T x_i + b] - 1), \tag{9}$$

$$(\alpha_i \geq 0, i = 1, 2, \dots, N).$$

마진 최대화에 karush-kuhn-tucker (KKT) 조건을 적용하여 아래의 두 식에서 각각 최적 가중치 벡터 \hat{w} 와 최적 바이어스 \hat{b} 을 구한다.

$$\hat{w} = \sum_{i=1}^{N_s} \alpha_i y_i x_i \tag{10}$$

$$\hat{b} = \frac{1 - y_i w^T x_i}{y_i} \quad \forall y_i = 1, \tag{11}$$

최종적으로 임의 패턴 x 가 주어질 때, 식 (10), (11)에서 구해진 \hat{w} 와 \hat{b} 을 사용하여 아래의 판별함수에 의해 분류 결과가 계산되어 진다.

$$f(x) = \text{sgn}(\sum_{i=1}^N \hat{\alpha}_i y_i x_i^T x + \hat{b}). \tag{12}$$

음성 신호는 정확하게 선형분리가 되지 않기 때문에 비선형 변환함수를 이용하여 보다 고차원의 공간으로 사상시키면 선형 분리가 가능한 조건이 된다. 사상된 공간에서도 원 공간에서의 거리 관계를 어느 정도는 보존시킬 필요가 있기 때문에, 사상 함수를 이용하여 커널함수 (kernel function)를 다음과 같이 정의한다 [8].

$$K(x, x') = \Phi(x)^T \Phi(x'). \tag{13}$$

식별 함수와 최적화 문제에 $\Phi(x)$ 을 쓰지 않고 $K(\cdot)$ 로만 나타낼 수 있는데 이러한 계산 회피 방법을 커널트릭

표 1. 커널 함수의 종류
Table 1 Type of Kernel function.

Kernel function	Type of Classifier
Polynomial	$K(x, x') = (x^T x' + 1)^p$
RBF	$K(x, x') = \exp(-\frac{\ x - x'\ ^2}{2\sigma^2})$
Sigmoid	$K(x, x') = \tanh(\beta_0 x^T x' + \beta_1)$

릭 (kernel trick)이라 하고 Φ 가 존재할 수 있는 커널 함수가 주어진 경우에만 유용하며 표 1에서와 같이 주어지지 않더라도 비선형 SVM의 최종판별 함수는 아래식과 같다.

$$f(x) = \text{sign}(\sum \hat{\alpha}_i y_i K(x_i, x_j) + \hat{b}). \tag{14}$$

III. 변별적 가중치 학습 및 제안된 알고리즘

기존의 SVM 기반의 음성/음악 분류 방법은 SMV코덱 인코딩부분의 전처리과정에서 자동적으로 추출되는 파라미터 중 통계적 학습 분류성능이 우수한 것들을 모아 별도의 계산과정 없이 특징벡터로 사용하였다 [5]. 그림 1은 SMV의 음성/음악 분류에 사용되는 특징벡터이고 보이는 것처럼 각각의 분포가 다르며 음성/음악 분류에 모든 특징벡터가 동일하게 영향을 준다고 볼 수 없다. 때문에 본 논문에서는 이 특징벡터에 대해 변별적 가중치 학습을 적용하여 음성/음악 분류에 영향을 미치는 정도에 따라 적절한 가중치를 적용한 최적의 음성/음악 분류 판별식을 아래와 같이 정의한다.

$$f(Wx) = \text{sign}(\sum \hat{\alpha}_i y_i K(Wx_i, Wx_j) + b) \tag{15}$$

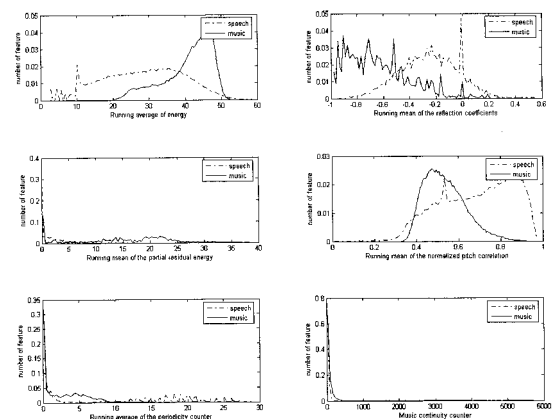


그림 1. SMV 특징벡터에 대한 음성/음악 분포도
Fig. 1. Normalized distributions of the SMV feature vectors for speech and music.

x 는 식 (1)~(6)에서 구한 특징벡터이고 $W = \{w_1, w_2, \dots, w_6\}$ 는 가중치벡터로 다음의 조건을 만족한다.

$$\sum_{i=1}^6 w_i = 1, \quad w_i > 0, \quad (16)$$

식 (16)의 제약조건 때문에 가중치 w 은 다음과 같이 변경된다.

$$\tilde{w}_i = \log w_i. \quad (17)$$

학습 데이터 각각의 프레임에서 음성 $h_s(\cdot)$ 과 음악 $h_m(\cdot)$ 을 나누는 두 개의 함수를 아래와 같이 정의한다.

$$h_s = f(Wx) - \eta \quad (18)$$

$$h_m = -f(Wx) + \eta \quad (19)$$

η 는 음성과 음악을 분류하는 문턱값이다.

최적의 가중치를 구하기 위해 generalized probabilistic descent (GPD) 기반의 MCE 훈련을 적용한다 [8]. 학습 데이터의 음성/음악 분류 오류 E 를 아래와 같이 나타낸다.

$$E(n) = \begin{cases} h_m(n) - h_s(n) & \text{if } h_s \text{ is true class} \\ h_s(n) - h_m(n) & \text{if } h_m \text{ is true class} \end{cases} \quad (20)$$

음성/음악 분류 결과가 옳바르면 $E(n)$ 의 값은 음수가 된다.

오류가 발생했을 때 가중치를 업데이트해주기 위한 손실함수 L 은 다음과 같다.

$$L = \frac{1}{1 + \exp(-\gamma E)}, \quad \gamma > 0 \quad (21)$$

γ 는 sigmoid 함수의 기울기이다.

가중치 \tilde{w}_i 분류결과가 옳바르면 전 프레임의 값을 그대로 사용하지만 오류가 발생하면 아래와 같은 계산에 의해 새로운 값으로 업데이트된다 [9][10].

$$\tilde{w}_i(n+1) = \tilde{w}_i(n) - \mu \frac{\partial L}{\partial w_i} \Big|_{w_i = \tilde{w}_i(n)} \quad (22)$$

μ 는 단순 감소 구간의 크기이다.

\tilde{w}_i 를 업데이트한 후에는 다음과 같이 w_i 를 복원한다.

$$w_i = \frac{\exp(\tilde{w}_i)}{\sum_{i=1}^6 \exp(\tilde{w}_i)}. \quad (23)$$

본 논문에서는 최적의 가중치를 기존의 특징벡터에 적용하여 판별식 식 (15)에 의해 효과적인 음성/음악 분류를 하였다. SVM 트레이닝에 사용된 커널함수는 표 1의 커널 함수 중 radial basis function (RBF)를 사용하였다.

IV. 실험 결과

본 논문에서는 변별적 가중치 학습 기반의 SVM을 이용한 강인한 음성/음악 분류 알고리즘 성능을 평가하기 위해 기존 SVM 기반의 음성/음악 분류 방법을 receiver operating characteristics (ROC) 곡선과 음성/음악 검출 확률 (P_d)로 표현하여 비교하였다. 그림 2는 위의 MCE 훈련 방법을 통해 얻어진 최적의 가중치 분포를 보여준다.

본 실험을 위해서 사용된 음성 데이터베이스는 8 kHz로 샘플링 된 약 6 sec 정도의 깨끗한 음성으로 326명의 남자와 138명의 여자 화자에 의해서 각 10개의 파일이 발음된 TIMIT 데이터베이스가 사용되었다.

음악 데이터베이스는 CD로부터 여러 장르의 음악을 모바일 폰을 통해서 녹음하였고, 8 kHz로 다운 샘플링 되었으며, 5분 정도의 음악파일이 사용되었다. 제외한 음성/음악 분류 알고리즘의 모델은 음성 파일 4200개와 음악 파일 60개 (메탈 12개, 재즈 12개, 블루스 12개, 힙합 12개, 클래식 12개)를 이용하여 트레이닝 하였다.

SVM 기반의 음성/음악 분류 방법과 제안된 알고리즘의 객관적인 성능을 평가하기 위해서 테스트 파일을 만들었다. 동일한 데이터에 의한 성능 향상을 피하기 위해서




그림 2. SMV 특징벡터에 따른 가중치 분포
Fig. 2. Weights distribution according to the SMV feature vectors.

트레이닝에 사용된 음성/음악 데이터는 테스트에 사용되지 않았다. 테스트 파일은 5개 음성 파일 (6~12 초), 5개 음악 파일 (28~32초), 10개 무음 (3~15 초)을 사용하여 만들었다.

다양한 음악 장르에 대한 음성/음악 분류 성능을 확인하기 위해서 테스트 파일의 음악을 2가지 형태로 각 장르별 (힙합, 메탈, 재즈, 블루스, 클래식)로 구성된 형태의




그림 3. 동일 가중치를 적용한 SVM과 제안된 알고리즘의 음성/음악 분류에 대한 ROC 곡선
Fig. 3. ROC curve for the speech/audio classification using the SVM and the proposed method.

표 2. 동일 가중치를 적용한 SVM과 제안된 알고리즘의 음성/음악 분류 성능 비교

Table 2. Comparison of speech/music detection probability P_d between the method of the SVM and the proposed technique.

TEST	Method	Music(P_d)	Speech(P_d)	P_e
Metal	SMV	0.22	0.91	0.65
	SVM	0.90	0.92	0.10
	Proposed	0.90	0.95	0.09
Blues	SMV	0.15	0.90	0.70
	SVM	0.90	0.90	0.10
	Proposed	0.84	0.95	0.13
Hip-hop	SMV	0.28	0.90	0.60
	SVM	0.66	0.90	0.29
	Proposed	0.84	0.92	0.14
Jazz	SMV	0.27	0.92	0.60
	SVM	0.35	0.90	0.54
	Proposed	0.75	0.88	0.22
Classic	SMV	0.50	0.90	0.42
	SVM	0.81	0.91	0.17
	Proposed	0.88	0.92	0.11
Mixed	SMV	0.21	0.93	0.65
	SVM	0.72	0.90	0.24
	Proposed	0.85	0.95	0.13

테스트 파일 60개, 음악 장르가 혼합된 형태의 테스트 파일 24개 총 84개의 테스트 파일을 만들었다. 두 시스템의 실제 성능을 알아보기 위해서 테스트 파일의 20 ms마다 실제로 결과값 0 (무음), 1 (음성), 2 (음악)로 수동으로 작성한 것과 비교하였다 [10].

그림 3은 기존 방법의 음성/음악 분류 성능과 제안된 음성/음악 분류의 전체적인 성능을 ROC 곡선으로 표현하여 비교한 것이다. 그림 3을 보면 제안된 음성/음악 분류 방법이 기존 SVM보다 우상향쪽에 위치하므로 성능이 더 뛰어난 것을 알 수 있다. ROC곡선은 SVM에서 이진 분류를 할 때 문턱 값을 -1~1까지 0.01씩 증가 시키면서 변화하는 음성/음악의 검출 확률 (P_d)을 나타낸 것이다.

표 2는 기존의 방법과 제안된 변별적 가중치 학습 기반의 SVM 알고리즘에서 음성/음악 검출 확률 (P_d)을 나타낸다. 우측에 P_e (Probability of Error)값은 음성과 음악에 대한 미검출 확률 ($1-P_d$)에 테스트 데이터의 음성과 음악 비율을 적용하여 정규화한 값이며 특히 메탈, 힙합, 재즈, 클래식, 혼합에서 뛰어난 성능을 보였다.

결론적으로 위의 ROC 곡선과 표 2에서 보는 것과 같이 본 논문에서 제안한 알고리즘이 기존의 동일 가중치를 적용한 SVM보다 음성/음악 분류 성능이 비등하거나 특수한 음악에서는 우수한 것을 알 수 있다. 특히, 입력벡터에 대해 최적화된 가중치가 다양한 데이터베이스를 기반으로 기계학습에 기반한 MCE기법에 도출되면 계산량의 증가가 거의 없이 효과적인 성능향상을 도모할 수 있다는 점이 장점이다.

V. 결론

본 논문에서는 변별적 가중치 학습을 이용하여 기존 SVM 기반의 3GPP2 selectable mode vocoder (SMV)의 음성/음악 분류 성능을 향상시키는 방법을 제시하였다. SMV코덱 인코딩부분의 전처리과정에서 추출한 특징벡터를 사용하여 MCE 훈련을 통한 최적의 가중치를 구하였다. 이렇게 구한 가중치를 특징벡터에 적용한 효과적인 SVM 분류기법을 제시하였다. 변별적 가중치를 적용한 SVM의 음성/음악 분류 성능 평가를 위해 동일한 가중치를 적용한 SVM 분류 알고리즘과 비교하였으며, 다양한 음악장르에 대해 시스템의 성능을 평가한 결과 본 논문에서 제안한 음성/음악 분류 방법이 우수한 성능을 보였다.

감사의 글


본 연구는 한국과학재단의 국가지정연구실 사업 (NO. ROA-2007-00 0-10022)과 또한 본 연구는 지식경제부 출연금으로 ETRI, SoC산업진흥센터에서 수행한 IT SoC 핵심설계인력양성사업의 연구결과입니다.

참고 문헌

1. Y. Gao, E. Shlomoi, A. Benyassine, J. Thyssen, Huan-yu Su and C. Murgia, "The SMV Algorithm Selected by TIA and 3GPP2 for CDMA Applications," *Proc. IEEE International Conference on Acoustics, Speech and Signal Processing*, vol. 2, pp. 709-712, May 2001.
2. 3GPP2 Spec., "Source-controlled variable-rate multimedia wideband speech codec (VMR-WB), service option 62 and 63 for spread spectrum systems," *3GPP2-C, S0052-A*, v.1.0, Apr. 2005.
3. J. Saunders, "Real-time discrimination of broadcast speech/music," *Proc. IEEE International Conference on Acoustics, Speech, and Processing*, vol. 2, pp. 993-996, May 1996.
4. W. Q. Wang, W. Gao and D. W. Ying, "A fast and robust speech/music Discrimination Approach," *Proc. International Conference on Information, Communications and Signal Processing*, vol. 3, pp. 1325-1329, Dec. 2003.
5. 김상균, 장준혁, "SMV코덱의 음성/음악 분류 성능 향상을 위한 Support Vector Machine의 적용", *전자공학회논문지*, 제45권, 제6호, pp.142-147, 2008.
6. 3GPP2 Spec., "Selectable Mode Vocoder (SMV) Service Option for Wideband Spread Spectrum Communication Systems," *3GPP2-C, S0030-0*, v3.0, Jan. 2004.
7. V. N. Vapnik, "An overview of statistical learning theory," *IEEE Trans. Neural Networks*, vol. 10, no. 5, pp. 988-999, 1999.
8. N. Cristianini and J. Shawe-Taylor, *An introduction to support vector machines and other kernel-based learning methods*, Cambridge Univ. Press, 2000.
9. B.-H. Juang, W. Chou and C.-H. Lee, "Minimum classification error rate methods for speech recognition," *IEEE Trans. Speech Audio Processing*, vol. 5, no. 3, pp. 257-265, 1997.
10. S.-I. Kang, Q.-H. Jo and J.-H. Chang, "Discriminative weight training for a statistical model-based voice activity detection," *IEEE Signal Processing Letter*, vol. 15, pp. 170-173, 2008.


저자 약력

•김 상 균(Sang-Kyun Kim)



2008년 2월: 인하대학교 전자공학과 학사
2008년 3월~현재: 인하대학교 전자공학부 석사과정

•장 준 혁(Joon-Hyuk Chang)



1998년 2월: 경북대학교 전자공학과 학사
2000년 2월: 서울대학교 전기공학부 석사
2004년 2월: 서울대학교 전기컴퓨터공학부 박사
2000년 3월~2005년 4월: ㈜넷데스 연구소장
2004년 5월~2005년 4월: 캘리포니아 주립대학, 산타바바라 (UCSB) 박사후연구원
2005년 5월~2005년 8월: 한국과학기술연구원 (KIST) 연구원
2005년 9월~현재: 인하대학교 전자전기공학부 조교수

•조 기 호(Ki ho Cho)



2007년 2월: 서울대학교 전기공학부 학사
2009년 2월: 서울대학교 전기컴퓨터공학부 석사
2009년 3월~현재: 서울대학교 전기컴퓨터공학부 박사과정

•김 남 수(Nam Soo Kim)



1988년 2월: 서울대학교 전자공학과 학사
1990년 2월: 한국과학기술원 전기 및 전자공학과 석사
1994년 8월: 한국과학기술원 전기 및 전자공학과 박사
1993년 5월~1998년 2월: 삼성종합기술원 전문연구원
1998년 3월~현재: 서울대학교 전기공학부 교수