

# 가우시안 혼합모델에서 점진적 강인적응을 통한 화자확인 성능개선

## Performance Enhancement for Speaker Verification Using Incremental Robust Adaptation in GMM

김 은 영\*, 서 창 우\*, 임 영 환\*, 전 성 채\*\*  
(Eunyoung Kim\*, Changwoo Seo\*, Yonghwan Lim\*, Seongchae Jeon\*\*)

\*숭실대학교 글로벌 미디어학부, \*\*한국전기연구원  
(접수일자: 2008년 12월 20일; 수정일자: 2009년 1월 16일; 채택일자: 2009년 2월 16일)

본 논문에서는 화자확인을 위해서 가우시안혼합모델에 forgetting factor를 갖는 점진적 강인적응 방법을 제안하였다. 화자인식 시스템에서 적은 양의 데이터로 좋은 성능을 얻기 위하여 화자모델 적응방법이 사용되고 있다. 그러나, 현재 사용되고 있는 적응방법은 불규칙한 발성변화와 잡음 같은 이상치에 취약하고, 그것은 부정확한 화자모델을 만들 수 있다. 또한 시간이 지날수록 모델에 새로운 데이터가 적용되는 비율이 줄어들게 되는 문제점이 있다. 제안된 알고리즘은 가우시안혼합모델을 이용한 화자모델에서 이상치에 의한 왜곡과 새로운 데이터에 대한 적응 비율을 일정이상으로 유지할 수 있도록 하기 위하여 점진적 강인적응 방법을 제안하였다. 점진적 강인적응은 화자인식에서 적은 양의 데이터로 등록하고 테스트된 새로운 데이터로 모델을 적응시키는 방법이다. 실험결과는 7개월에 걸쳐서 수집된 데이터로부터 제안된 방법이 이상치에 강인하고 새로운 데이터의 적응 비율을 일정하게 유지시킴을 보였다.

**핵심용어:** 화자확인, 가우시안혼합모델, 점진적강인적응, 가중치함수, forgetting factor

**투고분야:** 음성처리 분야 (2.5)

In this paper, we propose a Gaussian Mixture Model (GMM) based incremental robust adaptation with a forgetting factor for the speaker verification. Speaker recognition system uses a speaker model adaptation method with small amounts of data in order to obtain a good performance. However, a conventional adaptation method has vulnerable to the outlier from the irregular utterance variations and the presence noise, which results in inaccurate speaker model. As time goes by, a rate in which new data are adapted to a model is reduced. The proposed algorithm uses an incremental robust adaptation in order to reduce effect of outlier and use forgetting factor in order to maintain adaptive rate of new data on GMM based speaker model. The incremental robust adaptation uses a method which registers small amount of data in a speaker recognition model and adapts a model to new data to be tested. Experimental results from the data set gathered over seven months show that the proposed algorithm is robust against outliers and maintains adaptive rate of new data.

**Keywords:** Speaker verification, Gaussian mixture model, Incremental robust adaptation, Weight function, Forgetting factor

**ASK subject classification:** Speech Signal Processing (2.5)

### I. 서론

Gaussian Mixture Model (GMM)을 이용한 화자인식 (speaker recognition)에서 높은 인식률을 얻기 위해서는

학습과정에서 화자모델을 등록할 때, 다중 세션을 통해서 녹음된 많은 양의 데이터가 요구된다 [1,2]. 그러나 음성인식 (speech recognition)과 달리 화자인식에서는 개인 화자에 의해서 녹음된 많은 양의 데이터를 이용하는 것은 사실상 불가능하다. 따라서 화자확인 적응 (speaker verification adaptation) 방법이 제안되었다 [3,4]. 화자확인 적응은 등록과정에서 적은 양의 데이터를 이용하여

책임저자: 서 창 우 (cwseo@ssu.ac.kr)  
156-743 서울시 동작구 상도동 511번지 숭실대학교 글로벌 미디어학부  
(전화: 02-826-9872; 팩스: 02-822-3622)

화자모델을 형성하고, 확인과정에서 발생화자가 화자로 인증 확인된 경우에만 모델을 적응시키는 방법이다. 최근, 화자적응을 위한 차별적 학습 (discriminative training) [5]과 점진적 적응방법 (incremental adaptation method) [6]이 제안되었다. 점진적 적응방법에서의 화자모델은 한 세션에서 발생된 적은 양의 데이터로부터 등록하고 다음 세션에서의 새로운 데이터로 점진적으로 적응된다. 그러나 이런 접근 방법은 다음 세션에서 발생된 음성 데이터가 이상치 (outlier)를 포함하고 있을 때, 기존의 적응방법에서 얻어진 화자모델은 부정확하게 된다.

본 논문에서는 화자확인을 위한 forgetting factor을 갖는 GMM에서의 점진적 강인적응 방법 (incremental robust adaptation: IRA)을 제안하였다. 제안된 알고리즘은 발생변화와 잡음과 같은 이상치의 영향에 강인하고 그리고 시간의 경과에도 불구하고 정확하게 화자모델을 적응하기 위한 일반적인 화자모델에 새로운 데이터를 균일하게 적응시킴으로써 높은 인식률을 얻을 수 있다. 본 논문에서의 연구는 이상치의 영향을 줄이고, 새로운 데이터에서 적응 비율 (adaptation rate) 감소를 막기 위해 forgetting factor를 이용하여 균일하게 유지시키는 것이다.

논문의 구성은 다음과 같다. 2장에서는 GMM을 위한 화자적응 방법을 소개한다. 3장에서는 논문에서 제안한 등록과 테스트를 위한 점진적 강인적응 (IRA) 방법을 설명하고, 4장에서는 실험결과를 서술하였다. 마지막으로 5장에서는 결론을 기술하였다.

## II. GMM을 이용한 화자적응모델

화자인식 (speaker recognition)의 등록과정에서 길이가  $T_n$  인  $N$ 개의 학습열의 집합을  $X^N = \{X_n, n = 1, \dots, N\}$ ,  $X_n = \{x_n(t), t = 1, \dots, T_n\}$ 이라 하자. 여기서,  $x_n(t) \in R^L$ 는  $L$ -차원 벡터이다. 이때, 가우시안 혼합밀도  $p(x_n(t)|\theta)$ 는 다음과 같이  $M$  다중변환 가우시안 함수의 가중화된 합으로 나타낼 수 있다 [2].

$$p(x_n(t)|\theta) = \sum_{i=1}^M p_i b_i(x_n(t)), \quad (1)$$

여기서,

$$\theta = \{p_i, \mu_i, \Sigma_i, i = 1, 2, \dots, M\} \quad (2)$$

$\theta$ 는 파라미터 벡터, 그리고  $p_i$ 는  $\sum_{i=1}^M p_i = 1$  조건을 만

족시키는  $m$ 차 혼합성분을 위한 가중치 (weight)를 나타낸다.  $b_i(x_n(t))$ 는 다음과 같이  $m$ 차 정규밀도 함수로 나타낼 수 있다.

$$b_i(x_n(t)) = \frac{1}{(2\pi)^{L/2} |\Sigma_i|^{1/2}} \exp\left\{-\frac{1}{2}(x_n(t) - \mu_i)^T \Sigma_i^{-1} (x_n(t) - \mu_i)\right\}, \quad (3)$$

여기서  $\mu_i$ 는 평균 벡터 (mean vector), 그리고  $\Sigma_i$ 는 공분산 행렬 (covariance matrix)이다.

화자의 모델이 등록된 후, 테스트 과정에서  $(N+1)$ 번째 음성 데이터  $x_{N+1}(t)$ 가 주어지면, 모델을 위한 적응 식은 다음과 같이 나타낼 수 있다.

- Mixture Weights,

$$p_i^{N+1} = \frac{p_i^N T_N + \frac{1}{T_{N+1}} \sum_{t=1}^{T_{N+1}} p(i|x_{N+1}(t), \theta^N)}{T_N + T_{N+1}} \quad (4, a)$$

- Means,

$$\mu_i^{N+1} = \frac{\mu_i^N \gamma_i^N + \sum_{t=1}^{T_{N+1}} p(i|x_{N+1}(t), \theta^N) x_{N+1}(t)}{\gamma_i^N + \sum_{t=1}^{T_{N+1}} p(i|x_{N+1}(t), \theta^N)} \quad (4, b)$$

- Variances,

$$\Sigma_i^{N+1} = \frac{\Sigma_i^N \gamma_i^N + \sum_{t=1}^{T_{N+1}} p(i|x_{N+1}(t), \theta^N) (x_{N+1}(t) - \mu_i^N)(x_{N+1}(t) - \mu_i^N)^T}{\gamma_i^N + \sum_{t=1}^{T_{N+1}} p(i|x_{N+1}(t), \theta^N)} \quad (4, c)$$

위 식에서,  $\gamma_i^N = \sum_{n=1}^N \sum_{t=1}^{T_n} p(i|x_n(t), \theta^N)$ 는 등록과정에서 저장된 값이고 그리고  $(N+1)$ 번째 데이터가 입력될 때, 다음과 같이 적응시킬 수 있다.

$$\gamma_i^{N+1} = \gamma_i^N + \sum_{t=1}^{T_{N+1}} p(i|x_{N+1}(t), \theta^N). \quad (5)$$

## III. GMM을 위한 점진적 강인적응

### 3.1. 등록과정

음성의 등록과정에서  $N$ 개의 데이터  $X^N = \{X_n, n = 1, \dots, N\}$ ,  $X_n = \{x_n(t), t = 1, \dots, T_n\}$ 가 사용되었다고 가정하자.

$X^N$ 에 이상치가 존재할 때, 일반적인 GMM의 파라미터 추정 방법은 이상치에 민감하다는 문제점을 공통적으로 가지고 있다 [7,8]. 따라서, GMM에서의 신뢰할 수 있는 추정을 얻기 위해서 M-추정 (maximum likelihood-type estimator) 방법 [9]에 기초한 강인한 추정 방법을 제안하였다. M-추정 방법은 신호 오류가 한계치보다 작을 때와 그렇지 않을 때 각각 다른 값을 적용하는 방법이다. 본 논문의 M-추정에 기초한 강인한 추정 방법은 식 (6)과 같이 나타낼 수 있다.

$$J = \sum_{n=1}^N \lambda^{N-n} \sum_{t=1}^{T_n} \rho[\log p(x_n(t)|\theta)] \quad (6)$$

위 식에서,  $\rho[\cdot]$ 는 손실함수 (loss function)로 큰 확률 밀도  $\log p(x_n(t)|\theta)$ 는 작은 가중치 (weight) 값을 갖기 때문에, 이상치의 영향을 줄이기 위해서 사용되었다. 그리고 forgetting factor  $\lambda, 0 < \lambda \leq 1$ 는 변화하는 파라미터를 추적하기 위해서 최근 데이터에 가중치를 부과하는 방법이다 [7,10]. 여기서  $\lambda = 1$ 은 과거의 발생에 의한 영향을 그대로 적용하는 것이고,  $\lambda >> 0$ 는 이전의 영향을 거의 받지 않고 화자의 변화를 추적하겠다는 것이다. 식 (6)의 M-추정 방법은 참고문헌 [9]과 달리 가중치 값에 의해서 분포 오류를 줄이는 방법이다. 모델의 재추정 식은  $J$ 를 모델 파라미터  $p, \mu, \Sigma_i$ 에 의해서 최소화함으로써 얻을 수 있다. 먼저  $\frac{\partial J}{\partial p_i} = 0, \frac{\partial J}{\partial \mu_i} = 0, \frac{\partial J}{\partial \Sigma_i} = 0$ 로 함으로써 강인한 GMM 재추정 식은 다음과 같이 얻을 수 있다.

- Mixture Weights

$$p_i^N = \frac{\sum_{n=1}^N \lambda^{N-n} \sum_{t=1}^{T_n} w_n(t) p(i|x_n(t), \theta)}{\sum_{n=1}^N \lambda^{N-n} \sum_{t=1}^{T_n} w_n(t)} \quad (7.a)$$

- Means

$$\mu_i^N = \frac{\sum_{n=1}^N \lambda^{N-n} \sum_{t=1}^{T_n} w_n(t) p(i|x_n(t), \theta) x_n(t)}{\sum_{n=1}^N \lambda^{N-n} \sum_{t=1}^{T_n} w_n(t) p(i|x_n(t), \theta)} \quad (7.b)$$

- Variance

$$\Sigma_i^N = \frac{\sum_{n=1}^N \lambda^{N-n} \sum_{t=1}^{T_n} w_n(t) p(i|x_n(t), \theta) (x_n(t) - \mu_i)(x_n(t) - \mu_i)^T}{\sum_{n=1}^N \lambda^{N-n} \sum_{t=1}^{T_n} w_n(t) p(i|x_n(t), \theta)} \quad (7.c)$$

여기서,  $p(i|x_n(t), \theta)$ 는  $i$ 에서의 사후확률  $p(i|x_n(t), \theta) = \frac{p_i b_i(x_n(t))}{\sum_{j=1}^M p_j b_j(x_n(t))}$ 이고  $w_n(t)$ 는 가중치 함수 (weighted function)이다.  $z_n(t) = \log p(x_n(t)|\theta)$ 일 때,  $w_n(t)$ 는  $w_n(t) = \frac{\partial \rho[z_n(t)]}{\partial z_n(t)}$

와 같이 정의할 수 있다. 본 논문에서는  $w_n(t) = 1/(1 + z_n(t))^\beta / \beta$ 로 주어지는 코시 가중치 함수 (Cauchy's weight function)를 사용하였고,  $\beta$ 는 스케일 파라미터이다 [9]. 여기서 큰  $z_n(t)$ 는 작은  $w_n(t)$  값을 갖기 때문에, 식 (7)에서 이상치의 영향을 줄일 수 있다.

### 3.2. 테스트 과정

모델 파라미터  $\theta^N$ 이  $N$ 개의 음성 데이터  $X^N$ 의 초기집합으로 등록되고, 새로운 테스트 데이터  $X_{N+1} = \{x_{N+1}(1), \dots, x_{N+1}(T_{N+1})\}$ 이 주어진다면  $(N+1)$ 번째 재추정 식은 다음과 같이 구할 수 있다.

- Mixture Weights,

$$p_i^{N+1} = \frac{\lambda p_i^{N+1} W(N) + \sum_{t=1}^{T_{N+1}} w_{N+1}(t) p(i|x_{N+1}(t), \theta^N)}{W(N) + \sum_{t=1}^{T_{N+1}} w_{N+1}(t)} \quad (8.a)$$

- Means,

$$\mu_i^{N+1} = \frac{\lambda \mu_i^N W(N) + \sum_{t=1}^{T_{N+1}} w_{N+1}(t) p(i|x_{N+1}(t), \theta^N) x_{N+1}(t)}{W(N) + \sum_{t=1}^{T_{N+1}} w_{N+1}(t) p(i|x_{N+1}(t), \theta^N)} \quad (8.b)$$

- Variance,

$$\Sigma_i^{N+1} = \frac{\lambda \Sigma_i^N W(N) + \sum_{t=1}^{T_{N+1}} w_{N+1}(t) p(i|x_{N+1}(t), \theta^N) (x_{N+1}(t) - \mu_i^N)(x_{N+1}(t) - \mu_i^N)^T}{W(N) + \sum_{t=1}^{T_{N+1}} w_{N+1}(t) p(i|x_{N+1}(t), \theta^N)} \quad (8.c)$$

위 식에서,  $W(N) = \sum_{n=1}^N \lambda^{N-n} \sum_{t=1}^{T_n} w_n(t)$ , 그리고  $w_p(N) = \sum_{n=1}^N \lambda^{N-n} \sum_{t=1}^{T_n} w_n(t) p(i|x_n(t), \theta^N)$ 이다. 만약 새로운 데이터  $X_{N+1}$ 이 이상치를 포함한다면,  $w_{N+1}(t)$ 이 작은 값을 갖게 되어 이상치의 영향을 줄일 수 있다. 식 (8)에서  $W(N+1)$ 과  $w_p(N+1)$ 은 반복적으로 식 (9)와 같이 계산할 수 있다.

$$W(N+1) = \lambda W(N) + \sum_{t=1}^{T_{N+1}} w_{N+1}(t) \quad (9.a)$$

$$w_p(N+1) = \lambda w_p(N) + \sum_{t=1}^{T_{N+1}} w_{N+1}(t) p(i|x_{N+1}(t), \theta^{N+1}) \quad (9.b)$$

테스트 과정에서 사용된 forgetting factor  $\lambda$  의 범위는  $\lambda \leq 1$  이다. 만약 forgetting factor  $\lambda$  가 작으면, 새로운 데이터의 영향은 증가되고 그리고 일반적인 모델의 영향은 줄어든다.

### IV. 실험 결과

화자확인 실험에서 제안된 방법의 성능을 검증하기 위해서 제안된 방법 (IRAGMM: Incremental Robust Adaptive GMM)과 일반적인 GMM에 기초한 방법들 (GMM: GMM without Adaptation, AGMM: Adaptive GMM)을 사용하여 실험하였다. 실험에 사용된 음성 데이터는 12명의 화자 (남자:7, 여자:5)로부터 획득하였고, 개인별 화자의 데이터는 1세션을 월 단위로 하여 7세션 (T0, T1, ..., 그리고 T6) 동안 70개 (매일 10분장)의 데이터를 테스트에 사용하였다. 음성의 분석과정에서 샘플링 주파수는 11,025 kHz, 12차 mel-frequency cepstral coefficient (MFCC) [2] 그리고 13차 멘타 갭스트럼 [11]이 사용되었다. 음성 분석 프레임은 180 샘플이고 50% 중첩을 적용하였다. 초기 화자모델은 첫 번째 세션에서 등록을 위해서 발생된 5문장을 가지고 등록시켰고, 화자적응은 말성화자가 화자로 인증 확인된 경우에만 성립되는 지도 학습 (supervised learning) 방식으로 진행하였다. 실험에서 적용된 이상치는 전체 입력신호에서 음성검출을 수행한 후 음성 구간이 아닌 비음성 (nonspeech) 구간을 이상치로 간주하였다. 비음성 구간에 대한 검출은 전처리 과정에서 자동 끝점 검출 (endpoint detection)을 통한 비음성 데이터를 이상치로 간주하였고, 잡음이나 인공적인 소리들 부과하지는 않았다. 본 논문에서의 이상치 적용은 음성 데이터의 처음과 끝부분에 추가하였고, 전체 음성 데이터의 프레임 수를 계산하여 5%의 이상치를 추가하였다. 그리고 GMM에서 사용된 혼합성분은 32개이고 실험의 화자모델 적용에서 사용된 forgetting factor  $\lambda$  는 0.9 ~ 0.95를 실험적으로 적용하였다.

그림 1은 발생변화나 이상치가 존재하지 않고, 단지 시간의 경과에 따른 등기오율 (equal error rate: EER)을 나타낸 것이다. 이상치가 발생하지 않을 때, IRAGMM, GMM, 그리고 AGMM은 비슷한 EER을 보였다. 그러나 어느 정도의 시간이 경과된 세션 T3에서 T6까지 적응과정을 갖는 IRAGMM과 AGMM의 EER은 적응과정을 갖지 않는 GMM보다 줄어들었다. 시간이 지남에 따라서 IRAGMM과 AGMM은 낮은 EER을 보였다.

그림 2는 전체 데이터에서 5%의 이상치가 존재할 때, 시간이 경과됨에 따른 EER 변화를 나타낸 것이다. 이상치가 발생할 때, GMM과 AGMM은 인증성공 후 오염된 신호로 화자모델이 적용이 되어 부정확한 화자모델로 생성되었다. 따라서 테스트 과정에서의 이상치의 영향을 받아서, 오거설 (False Reject)이 증가되어 EER이 높아졌다. 그리고 깨끗한 데이터를 테스트할 경우에도 오거설하거나, 사칭자인 경우에도 오인중 (False Accept)하는 일이 발생하게 된다. 한번 잘못 적용된 모델은 이상치가 발생하지 않았을 때의 적응모델의 성능만큼 회복할 수 없다. 그러나 제안된 IRAGMM은 이상치의 영향을 최소화시켜서 테스트를 하기 때문에, 이상치가 발생하지 않았을 때와 비슷한 형태의 성능결과를 보였다.

또한, 이상치의 영향을 최소화 시켜서 모델을 적응시키기 때문에 처음 이상치가 발생할 경우에도 모델이 부정확하게 적용되어 가는 것을 방지 할 수 있었다. 결과적으로 이상치가 발생할 경우에도 이상치가 발생하지 않는 경우와 비슷하게 성능을 쫓아가는 것을 볼 수 있다.

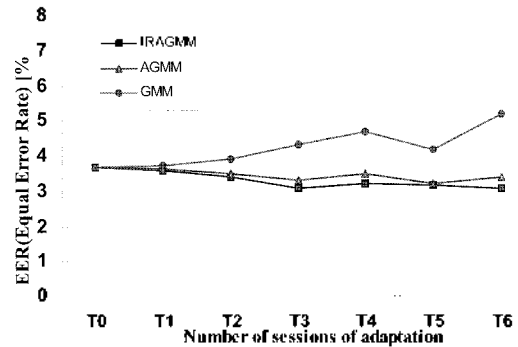


그림 1. 화자확인을 위한 등기오율 (%) (깨끗한 음성)  
Fig. 1. Equal error rate (%) for speaker verification (clean speech).

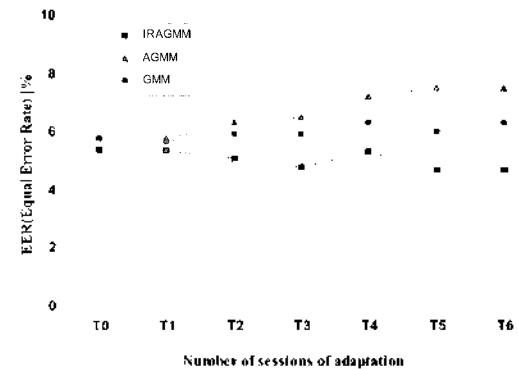


그림 2. 화자확인을 위한 등기오율 (%) (5% 이상치 존재)  
Fig. 2. Equal error rate (%) in speaker verification (with 5% outliers).

## V. 결론

본 논문에서는 화자확인을 위해서 GMM에 forgetting factor를 갖는 점진적 강인적응 방법을 제안하였다. 제안된 알고리즘은 발생변화나 잡음과 같은 이상치(outlier)의 왜곡에 강인하고, 새로운 데이터에 대한 적응 비율을 일정하게 유지시켜 줌으로써 높은 인식율을 갖는 화자인식 모델을 제공하였다. 점진적 강인적응(incremental robust adaptive)은 화자인식에서 적은 양의 데이터로 등록하고 테스트된 새로운 데이터로 모델을 적응시키는 방법이다. 실험결과로부터 제안된 방법이 이상치에 강인하고 새로운 데이터의 적응 비율을 일정하게 유지시켜주는 것을 알 수 있다.

## 감사의 글

“본 연구는 2009년도 송실대학교 교내연구비 지원으로 이루어졌습니다.”

## 참고 문헌

1. S. Furui, "Cepstral analysis technique for automatic speaker verification," *IEEE Trans. ASSP-29*, vol. 2, no. 2, pp. 254-272, 1981.
2. D. A. Reynolds, and R. C. Rose, "Robust text-independent speaker identification using Gaussian mixture speaker models," *IEEE Trans. Speech Audio Process.*, vol. 3, no. 1, pp. 72-83, 1995.
3. J. L. Gauvain, and C. H. Lee, "Maximum a posteriori estimation for multivariate Gaussian mixture observations of Markov chains," *IEEE Trans. Speech Audio Process.*, vol. 2, no. 2, pp. 291-298, Mar. 1994.
4. S. Ahn, and H. Ko, "Speaker adaptation in sparse training data for improved speaker verification," *Electronics Letters*, vol. 36, no. 4, pp. 371-373, 2000.
5. J. McDonough, M. Wolfel, and E. Stoimenov, "Comparison of techniques for combining speaker adaptation with discriminative training," in *Proc. ICASSP*, Honolulu, Hawaii, USA, 2007.
6. C. Fredouille, and J. Mariethoz, "Behavior of a Bayesian adaptation method for incremental enrollment in speaker verification," in *Proc. ICASSP*, no. 2, pp. 1197-1200, 2000.
7. T. Yang, J. Lee, K.Y. Lee, and K. Sung, "On robust Kalman filtering with forgetting factor for sequential speech analysis," *Signal Processing*, vol. 63, pp. 151-156, 1997.
8. Y. Lee, J. Lee, and K.Y. Lee, "Efficient Speaker Identification Based on Robust VQ-PCA," *LNCS 2668*, vol. 63, pp. 631-638, 1997.
9. P. J. Huber, *Robust Statistics*, New York: Wiley, 1981.

10. L. P. Heck, and N. Mirghafori, "On-Line Unsupervised Adaptation in Speaker Verification," in *Proc. ICSLP*, 2000.
11. S. Young, G. Evermann, D. Kershaw, G. Moore, J. Odell, D. Ollason, D. Povey, V. Valtchev, and P. Woodland, *The HTK Book (for HTK version 3.2)*, Cambridge University Engineering Department, 2002.

## 저자 약력

### • 김 은 영 (Eunyoung Kim)



1999년 : 한경대학교 컴퓨터학과(공학사)  
 2003년 : 송실대학교 컴퓨터공학과 (공학석사)  
 2004년 ~ 현재 : 송실대학교 글로벌 미디어학부 박사 수료 (미디어공학)  
 2003년 ~ 현재 : 여주대학 컴퓨터정보과 (경영강사)  
 \*주관분야: 모바일 시스템, 콘텐츠 공학, 멀티미디어 시스템

### • 서 창 우 (Changwoo Seo)



1996년 : 창원대학교 전자공학과(공학사)  
 1998년 : 창원대학교 전기전자제어공학부(공학석사)  
 2003년 : 송실대학교 정보통신전자공학부(공학박사)  
 2003년 ~ 2005년 : ㈜인스모바일 책임연구원  
 2005년 ~ 2007년 : ㈜에스씨디 정보통신연구소 책임연구원  
 2008년 ~ 현재 : 송실대학교 글로벌 미디어학부 연구 교수  
 \*주관분야: 음성/영상 신호처리, 모바일 시스템, 멀티미디어 시스템

### • 임 영 환 (Yonghwan Lim)



1977년 : 경북대학교 수학과(이학사)  
 1979년 : 한국과학기술원 전산학과(이학석사)  
 1979년 ~ 1996년 : 한국전자통신연구소 책임연구원  
 1985년 : Northwestern University(이학박사)  
 1996년 ~ 현재 : 송실대학교 글로벌 미디어학부 교수  
 \*주관분야: 멀티미디어 공학, 모바일 시스템

### • 전 성 채 (Seongchae Jeon)



1995년 : 창원대학교 전자공학과(공학사)  
 1997년 : 창원대학교 전자공학과(공학석사)  
 2006년 : 한국과학기술원 원자력공학과(공학박사)  
 2006년 ~ 현재 : 한국전기연구원 선임연구원  
 \*주관분야: Solid state radiation sensor, 의료 신호처리