

# SVM의 확률 출력을 이용한 새로운 Global Soft Decision 기반의 음성 향상 기법

## Global Soft Decision Using Probabilistic Outputs of Support Vector Machine for Speech Enhancement

조 규 행\*, 장 준 혁\*  
(Q-Haing Jo\*, Joon-Hyuk Chang\*)

\*인하대학교 전자전기공학부  
(접수일자: 2007년 12월 20일; 채택일자: 2008년 1월 16일)

본 논문에서는 support vector machine (SVM) 기반의 global soft decision (GSD)을 이용한 새로운 음성 향상 기법을 제시한다. 일반적으로 soft decision (SD) 이득 추정 및 잡음 전력 추정에 근거한 음성 향상 기법이 hard decision을 이용한 음성 향상 기법 보다 우수한 성능을 보이는 것으로 알려져 있다. 특히, 각 프레임에서의 음성 부재에 대한 효과적인 척도인 전역음성 부재확률 (global speech absence probability, GSAP)을 SD 기반의 음성 향상 기법에 적용한 여러 연구가 진행되었다. 본 논문에서는 sigmoid 함수를 이용하여 얻어진 SVM의 확률 출력에 의해 추정된 새로운 GSAP를 음성 향상 기법에 적용한다. 제안된 알고리즘의 성능은 다양한 잡음 환경에 적용하여 PESQ 및 MOS 평가 방법을 바탕으로 기존의 GSD 기반의 스펙트럼 향상 기법과 비교하여 향상된 결과를 나타내었다.

**핵심용어:** 음성 향상, Support vector machine, Global soft decision

**투고분야:** 음성처리 분야 (2,3)

In this paper, we propose a novel speech enhancement technique using global soft decision (GSD) based on the probabilistic outputs of support vector machine (SVM). Generally, speech enhancement algorithms applied soft decision gain modification and noise power estimation have better performance than those employing hard decision. Especially, global speech absence probability (GSAP), which is known as an effective measure of the speech absence in each frame, has been adopted to SD-based speech enhancement methods. For this reason, we introduce a new GSAP estimated from the probabilistic output of SVM using sigmoid function. The performance of the proposed algorithm is evaluated by the PESQ and MOS test under various noise environments and yields better results compared with the conventional GSD scheme.

**Keywords:** Speech enhancement, Support vector machine, Global soft decision

**ASK subject classification:** Speech Signal Processing (2,3)

### 1. 서론

음성 인식과 부호화 등의 시스템에서 배경 잡음이 존재하는 경우 두드러진 성능 저하와 관련하여 음성 향상과 관련된 많은 연구가 진행되었다. 그 중 대표적인 음성 향상 기법으로 음성의 존재와 부재에 대한 확률을 기반으로 한 soft decision (SD)이 널리 알려져 있으며 [1], 특히 각각의 스펙트럼 성분별로 soft decision을 수행하는 기존의 방법 대신 주어진 프레임에서 전역적으로 수

행하는 global soft decision (GSD)을 기반으로 한 음성 향상 기법이 우수한 성능을 보이는 것으로 알려져 있다 [2].

한편 패턴 인식 분야에서 널리 사용되고 있는 support vector machine (SVM)의 출력을 확률값으로 변환하는 효과적인 방법이 제시되었다 [3]. 이를 이용하여 본 논문에서는 SVM의 확률 출력을 GSD 기반 음성 향상 기법의 주요 파라미터인 전역음성 부재확률 (global speech absence probability, GSAP)로 대체한 새로운 스펙트럼 향상 기법을 제안한다. 구체적으로 GSD 기반 음성 향상 기법의 주요 파라미터인 우도비 (likelihood, LR)를 SVM의 특징 벡터로 이용하여 음성의 존재 유무에 대한 분류를 실시한다. 이 때 각 프레임에 대한 SVM의 출력값을 sigmoid

책임저자: 장 준 혁 (chang@inha.ac.kr)  
420-751 인천시 남구 용현동 253  
인하대학교 전자전기공학부  
(전화: 032-860-7423; 팩스: 032-868-3654)

함수를 이용하여 확률값으로 매핑함으로써 음성의 존재에 대한 확률을 구하고 이를 GSAP로 대체한다.

제안된 알고리즘은 다양한 잡음 환경에서 객관적 평가와 주관적 평가를 바탕으로 기존의 GSD 기반의 스펙트럼 향상 기법과 성능을 비교하였으며, 평가 결과 대부분의 잡음 환경에서 제안된 방법이 우수한 음성 향상 성능을 나타내었다.

## II. Global Soft Decision 기반 음성 향상

먼저 시간축 상에서 원래의 음성신호  $x$ 에 잡음신호  $d$ 가 인가되어 입력신호  $y$ 을 만든다고 가정한다. 이를 discrete Fourier transform (DFT)을 통해 주파수 축으로 변환하면 아래와 같이 표현된다.

$$Y(t) = X(t) + D(t) \tag{1}$$

여기서  $Y(t) = [Y_1(t), Y_2(t), \dots, Y_N(t)]^T$ ,  $X(t) = [X_1(t), X_2(t), \dots, X_N(t)]^T$  그리고  $D(t) = [D_1(t), D_2(t), \dots, D_N(t)]^T$ 는 각각  $t$ 번째 프레임에서의 DFT 계수 벡터이다.  $H_0$ ,  $H_1$ 이 각각 음성의 부재와 존재를 나타낸 가설이라고 하면 주어진 가정으로부터 다음과 같이 기술된다.

$$H_0: \text{speech absent} : Y(t) = D(t) \tag{2}$$

$$H_1: \text{speech present} : Y(t) = X(t) + D(t). \tag{3}$$

음성과 잡음신호의 스펙트럼이 복소 가우시안 분포를 따른다고 가정하면, 가설  $H_0$ 와  $H_1$ 을 조건으로 한 확률밀도함수는 아래와 같이 주어진다 [2].

$$p(Y_k(t)|H_0) = \frac{1}{\pi \lambda_{d,k}(t)} \exp\left\{-\frac{|Y_k(t)|^2}{\lambda_{d,k}(t)}\right\} \tag{4}$$

$$p(Y_k(t)|H_1) = \frac{1}{\pi [\lambda_{d,k}(t) + \lambda_{s,k}(t)]} \exp\left\{-\frac{|Y_k(t)|^2}{\lambda_{d,k}(t) + \lambda_{s,k}(t)}\right\} \tag{5}$$

여기서  $\lambda_{s,k}(t)$ 와  $\lambda_{d,k}(t)$ 는 각각 음성과 잡음 신호의 분산을 나타낸다. 각각의 주파수 채널별 성분이 통계적 독립이라고 가정하면, 입력 신호  $y$ 의  $t$ 번째 프레임에서의 GSAP는 아래와 같이 표현된다 [2].

$$p(H_0|Y(t)) = \frac{p(Y(t)|H_0)p(H_0)}{p(Y(t)|H_0)p(H_0) + p(Y(t)|H_1)p(H_1)} = \frac{1}{1 + \frac{p(H_1)}{p(H_0)} \prod_{k=1}^N A(Y_k(t))} \tag{6}$$

여기서  $p(H_0) (= 1 - p(H_1))$ 는 음성 부재에 대한 사전 확률이며,  $A(Y_k(t))$ 는 각 주파수 채널별 LR를 나타내며 다음과 같다.

$$A(Y_k(t)) = \frac{p(Y_k(t)|H_1)}{p(Y_k(t)|H_0)} = \frac{1}{1 + \xi_k(t)} \exp\left\{\frac{\gamma_k(t)\xi_k(t)}{1 + \xi_k(t)}\right\} \tag{7}$$

여기서  $\gamma_k(t) = |Y_k(t)|^2 / \lambda_{d,k}(t)$ ,  $\xi_k(t) = \lambda_{s,k}(t) / \lambda_{d,k}(t)$ 는 각각 a posteriori signal-to-noise ratio (SNR)와 a priori SNR이다. 음성 부재 구간에서 갱신되는 잡음 신호로부터 구한 잡음 분산  $\hat{\lambda}_{d,k}$ 를 이용하여 a posteriori SNR  $\hat{\gamma}_k$ 를 추정하며, 또한 a priori SNR  $\hat{\xi}_k$ 는 decision-directed (DD) 방식을 이용하여 다음과 같이 추정한다 [4],[5].

$$\hat{\gamma}_k(t) = \frac{|Y_k(t)|^2}{\hat{\lambda}_{d,k}(t)} \tag{8}$$

$$\hat{\xi}_k(n) = \alpha \frac{|\hat{X}_k(t-1)|^2}{\hat{\lambda}_{d,k}(t-1)} + (1-\alpha)K[\hat{\gamma}_k(t)-1] \tag{9}$$

여기서  $|\hat{X}_k(t-1)|$ 은 이전 프레임에서 추정된 음성 신호의  $k$ 번째 스펙트럼 성분의 크기에 대한 추정치이며, 최소자승 평균오차 (minimum mean-square error, MMSE)에 기반하여 구한다. 또한  $\alpha$ 는 가중치 값이며, 연산자  $K[\cdot]$ 은 아래와 같다.

$$K[x] = \begin{cases} x & \text{if } x \geq 0 \\ 0 & \text{otherwise.} \end{cases} \tag{10}$$

$\hat{X}(t) = [\hat{X}_1(t), \hat{X}_2(t), \dots, \hat{X}_N(t)]^T$ 을  $n$ 번째 프레임에서의 깨끗한 음성의 추정치라고 할 때, 기존의 스펙트럼 향상 기법은 오염된 음성 신호의 각각의 주파수 성분  $Y_k(t)$ 에 이득 함수  $G(\cdot)$ 를 적용하여  $\hat{X}_k(t)$ 을 추정한다. 이득 함수를 구하는 다양한 방법 중 본 논문에서는 musical 잡음에 우수한 성능을 보이는 Epharim-Malah의 noise suppression rule을 적용하며, 추정치  $\hat{X}(t)$ 는 다음과 같이 표현된다 [4].

$$\hat{X}_k(t) = G(\eta_k(t), \gamma_k(t)) Y_k(t) \tag{11}$$

여기서 이득 함수  $G(\cdot)$ 는 다음과 같이 주어진다.

$$G(\eta, \gamma) = \frac{\sqrt{\pi}}{2} \sqrt{\frac{\eta}{\gamma(1+\eta)}} \exp\left\{-\frac{\gamma\eta}{2(1+\eta)}\right\} \times \left[ \left(1 + \frac{\gamma\eta}{1+\eta}\right) I_0\left(\frac{\gamma\eta}{2(1+\eta)}\right) + \left(\frac{\gamma\eta}{1+\eta}\right) I_1\left(\frac{\gamma\eta}{2(1+\eta)}\right) \right] \tag{12}$$

여기서  $t_0$ 와  $t_1$ 은 각각 수정된 베셀 함수의 0차 1차 버전이다. 또한 soft decision 기법을 바탕으로 음성의 존재와 부재에 대한 확률 정보를 이용하여 다음과 같이 수정된 이득 함수  $\tilde{G}$ 를 적용하여  $\hat{X}_k(t)$ 을 추정한다 [2].

$$\hat{X}_k(t) = \tilde{G}(y_k(t), \gamma_k(t)) Y_k(t) \quad (13)$$

여기서

$$\tilde{G}(\cdot) = (1 - p(I_{t_0}|Y(t))) C(\cdot). \quad (14)$$

### III. SVM 확률 출력을 이용한 음성 향상 기법

#### 3.1. Support Vector Machine

Vapnik이 제안한 SVM은 통계적 학습 이론에 기반을 둔 패턴 분류기이다 [6]. 기존의 학습 알고리즘은 학습 집단을 이용하여 학습 데이터의 수행도를 최적화하기 위한 경험적 위험 최소화 (Empirical Risk Minimization, ERM) 방법을 기초로 하고 있는 반면, SVM은 분류 오류 확률을 최소화하는 구조적인 위험 최소화 (Structural Risk Minimization) 방법에 기초하고 있다.

두 개의 클래스에 대한 학습 데이터가  $(x_1, z_1), \dots, (x_l, z_l), x \in R^n, z_i \in \{+1, -1\}$ 과 같이 주어졌을 때, 초평면에 대한 방정식은  $(w \cdot x) + b = 0$ 과 같이 초평면에 직교하는 가중치 벡터  $w$ 와 바이어스  $b$ 로 표현된다. 이 때 SVM은 학습 데이터로부터 최적 초평면을 위한 support vector  $x_i^*$ 를 구하며, 이를 바탕으로 임의의 입력 데이터  $x$ 가 주어졌을 때 SVM의 출력값은 아래 식과 같이 표현된다.

$$f(x) = (w^* \cdot x) + b^* = \sum_{i=1}^M \alpha_i^* z_i (x_i^* \cdot x) + b^* \quad (15)$$

여기서  $w^*, b^*$ 와  $\alpha_i^*$ 는 각각 학습 데이터로부터 구한 최적 가중치 벡터, 최적 바이어스와 라그랑지 승수이며  $M$ 은 support vector의 총 개수이다.

일반적으로 입력 데이터의 경우 명확하게 선형 분류가 되지 않는 경우가 대부분이며, 이를 위해 커널 함수  $K$ 를 이용하여 고차원 공간으로 사상시켜 고차원 특징 공간에서의 분류를 아래와 같이 실시한다 [6].

$$f(x) = (w^* \cdot x) + b^* = \sum_{i=1}^M \alpha_i^* z_i K(x_i^* \cdot x) + b^*. \quad (16)$$

#### 3.2. SVM 확률 출력을 이용한 음성 향상 기법

SVM의 출력값은 식(15)과 (16)에서 모두가 입력 데이터와 support vector들과의 내적의 합으로 일종의 거리를 나타내며, 출력값의 크기에 따라 입력 데이터와 클래스 간의 상관성을 보여준다 [7]. SVM으로부터 확률값을 직접 구할 수 없으므로, SVM 출력으로부터 확률값을 구하는 여러 방법들이 제시되었다 [3],[6]. 이를 바탕으로 음성 신호의 각 프레임에서 음성의 존재 유무에 대한 SVM 확률 출력을 도출하면, 각 프레임에서 음성의 존재에 대한 확률을 얻는다.

본 논문에서는 오염된 임의의 입력 신호로부터 깨끗한 음성신호를 추정하기 위하여 GSD 기법을 적용하며, 이 때 식(14)의 GSAP를 SVM 출력값의 확률로써 대체한다. 구체적으로 식(7)의 각 주파수별 LR을 SVM의 특징 벡터로 이용하여 음성의 존재 유무에 대한 분류를 실시하며, 이를 Platt이 제안한 아래와 같은 sigmoid 함수를 이용하여 SVM 확률 출력을 구한다 [3].

$$F(I_{t_1}|f(A)) = \frac{1}{1 + \exp(Af(A)+B)} \quad (17)$$

여기서  $A$ 와  $B$ 는 각각 sigmoid 함수의 파라미터이며,  $f(A)$ 는 입력된 입력 신호로 구해진 LR에 대한 SVM 출력이다. 이 때  $A$ 와  $B$ 는 학습 데이터로부터 우도 추정법 (maximum likelihood estimation)에 의해 구해진다. 먼저 학습 데이터에 대한  $i$ 번째 출력  $f_i(A)$  ( $i=1, \dots, l$ )의 목표 확률값  $t_i$ 를 학습 데이터의 클래스 라벨  $z_i$ 를 이용하여 다음과 같이 정의한다.

$$t_i = \frac{z_i + 1}{2}. \quad (18)$$

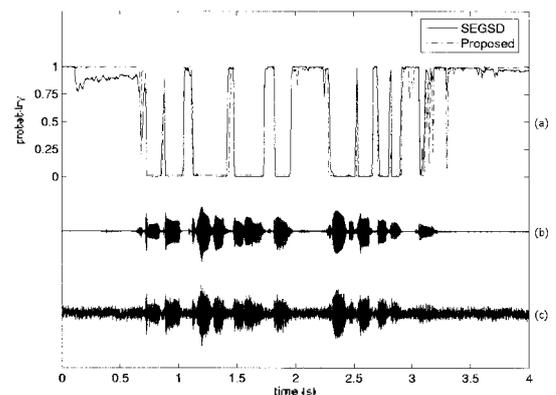


그림 1. F16 잡음 (SNR = 5 dB)에서의 GSAP 비교. (a) GSAP (b) 깨끗한 음성 파형 (c) 잡음 섞인 음성 파형  
Fig. 1. Comparison of GSAP under the F16 noise (SNR = 5 dB). (a) GSAP (b) Clean speech waveform (c) Noisy speech waveform.

이 때 두 파라미터에 의해 최적의 확률값을 갖도록 최소화 문제를 최적화하는 다양한 알고리즘들 중 본 논문에서는 model-trust minimization 알고리즘을 이용하여 구한다 [3]. 구체적으로 식(17)의 파라미터  $A, B$ 는 학습 데이터를 이용하여 로그 우도 (log likelihood) 최소화  $\min \left[ - \sum (t_i \log P(H_1|f_i(A)) + (1-t_i) \log P(H_0|f_i(A))) \right]$ 에 의해 최적화된 값을 찾는다.

최종적으로 식(17)로부터 도출된 각 프레임 별 음성 존재 확률  $P(H_1|f(A))$ 를 이용하여 구한 깨끗한 음성의 추정치는 아래와 같다.

$$\hat{X}_k(t) = \tilde{G}^*(\eta_k(t), \gamma_k(t)) Y_k(t) \tag{19}$$

여기서

$$\tilde{G}^*(\cdot) = P(H_1|f(A)) G(\cdot). \tag{20}$$

그림 1은 F16 잡음 SNR 5 dB에서의 기존의 GSAP (SEGSD)와 제안된 SVM 확률 출력으로부터 구한 GSAP를 나타내고 있다. 여기서 제안한 GSAP 값이 음성의 존재 여부에 대해 더욱 결실한 추정을 보여주고 있다.

#### IV. 실험 결과 비교 및 분석

먼저, SVM 확률 출력을 구하기 위해 음성 데이터로부터 학습을 실시한다. 사용된 음성 데이터는 각각 4명의 남성, 여성 화자가 발음한 깨끗한 음성을 8 kHz로 샘플링 하였으며, 총 226초의 음성 데이터를 음성과 비음성 부분으로 10 ms마다 수동으로 표시하여 클래스를 구성하였다. 잡음 환경을 고려하여 vehicular, street 그리고 white 잡음을 각각 5, 10 그리고 20 dB의 SNR에 대해 부과하였다. SVM의 특징 벡터 차수는 16개의 주파수 채널에서 구한 LR로 총 16차로 구성하였다. 또한 음성 데이터의 비선형 특성을 고려하여 식(16)의 커널 함수  $K$ 는 radial basis function (RBF) 커널을 적용하여 학습을 실시한다. 최종적으로 본 실험에서는 학습을 통하여 총 126,965개의 support vector가 생성되었다.

식(17)의 SVM 확률 출력을 위한 sigmoid 함수의 두 파라미터  $A, B$ 는 학습에 사용된 데이터로부터 구한 SVM 출력값과 클래스를 이용하여 구하였으며, 각각의 파라미터 값은  $A = -1.97, B = -0.122$ 이다.

제안된 음성 향상 알고리즘의 음질 평가를 위해 PESQ와 MOS 테스트를 수행하였다. 이 때, 실험에 사용된 음성

표 1. 다양한 노이즈 환경에서 PESQ 비교

Table 1. Comparison of PESQ under the various noise conditions.

Noise type	Method	SNR (dB)		
		5	10	15
White	SEGSD	1.918	2.276	2.605
	Proposed	1.945	2.293	2.621
Vehicle noise	SEGSD	3.323	3.594	3.845
	Proposed	3.376	3.640	3.884
F-16 noise	SEGSD	2.289	2.640	2.951
	Proposed	2.352	2.679	2.970

표 2. 다양한 노이즈 환경에서 MOS 및 가설 검증 결과 비교 (95% 신뢰구간)

Table 2. Comparison of MOS and hypothesis test result under the various noise conditions (with 95% confidence interval).

Noise type	Method	SNR (dB)		
		5	10	15
White	SEGSD	1.74 (±0.32)	2.38 (±0.36)	3.02 (±0.36)
	Proposed	1.77 (±0.31)	2.47 (±0.34)	3.03 (±0.35)
	Hypothesis test	NW	NW	NW
Vehicle noise	SEGSD	3.47 (±0.21)	3.69 (±0.20)	4.14 (±0.19)
	Proposed	3.63 (±0.23)	3.74 (±0.26)	4.23 (±0.18)
	Hypothesis test	B	NW	B
F-16 noise	SEGSD	2.54 (±0.33)	2.96 (±0.31)	3.68 (±0.37)
	Proposed	2.55 (±0.27)	2.98 (±0.30)	3.71 (±0.42)
	Hypothesis test	NW	NW	NW

데이터가 학습 데이터와 같을 경우 SVM 분류에 대해 종속적인 성능을 보일 수 있으므로, 이를 피하기 위해 다른 화자와 잡음 환경으로 구성하였다.

첫 번째 실험으로, PESQ 테스트를 위해 각각 3명의 남성, 여성 화자가 총 60개의 문장을 발음한 깨끗한 음성을 8 kHz로 샘플링 하였으며, 세 가지 형태의 잡음을 부가하였다. 부가된 잡음은 NOISEX-92 데이터베이스의 vehicular, white 그리고 F-16 잡음이며, SNR은 각각 5, 10 그리고 15 dB로 달리하였다. PESQ 테스트 결과 다양한 잡음 환경에서 전체적으로 제안된 음성 향상 기법이 우수한 성능을 보여주었으며, 특히 낮은 SNR에서 향상 폭이 큰 것을 알 수 있다.

두 번째로 MOS 테스트에 사용된 음성 데이터는 각각 3명의 남성, 여성 화자가 발음한 총 18개의 문장의 깨끗한 음성을 8 kHz로 샘플링 하였으며, PESQ 테스트와 동일

하게 잡음 환경을 구성하였다. 잡음 제거 알고리즘에 적용하여 잡음이 제거된 음성 데이터를 대상으로 10명의 청취자에 의해 MOS를 결정하였으며, 표 2는 MOS 결과와 기존의 음성 향상 기법 (SEGSD)에 대한 제안된 기법의 가설 검증 (hypothesis test) 결과를 보여주고 있다 [8]. 결과를 고찰해보면, 대부분의 잡음 환경에 대해서 제안된 SVM 확률 출력을 이용한 GSD 음성 향상 기법이 기존의 GSD 음성 향상 기법보다 우수한 성능을 가지고 있으며, 이는 SVM의 우수한 분류 성능에 의해 도출한 확률값이 GSAP로써 더욱 적합하기 때문이다.

## V. 결론

본 논문에서는 GSAP의 추정을 위해 SVM 출력을 확률값으로 변환하는 새로운 GSAP 추정 알고리즘을 제안하였다. 효과적인 GSAP의 추정을 위해 입력 신호의 각 프레임에서 구한 IR을 SVM의 특징벡터로 사용하여, sigmoid 함수로부터 확률값을 도출한다. 최종적으로 SVM의 확률 출력을 기존의 GSAP와 대체하여 구성된 제안된 음성 향상 기술의 성능을 평가하기 위해 PESQ 및 MOS 평가를 하였으며 다양한 잡음 환경에서 제시된 GSAP 추정이 기존의 방법보다 향상된 결과를 나타내었다.

## 감사의 글

이 논문은 2006년 정부(교육인적자원부)의 재원으로 한국학술진흥재단의 지원을 받아 수행된 연구임 (KRF-2006-311-D00733).

## 참고 문헌

1. R. J. McAulay and M. L. Malpass, "Speech enhancement using a soft-decision noise suppression filter," IEEE Trans. Acoust., Speech, Signal Processing, ASSP-28, 137-145, Apr. 1980.
2. N. S. Kim, J.-H. Chang, "Spectral enhancement based on global soft decision," IEEE Signal Processing Letters, 7(5), pp. 108-110, May 2000.
3. J. Platt, "Probabilistic outputs for support vector machines and comparison to regularized likelihood methods," Advances in Large Margin Classifiers, MIT Press, 2000.
4. Y. Ephraim and D. Malah, "Speech enhancement using a minimum mean-square error short-time spectral amplitude estimator," IEEE Trans. Acoust., Speech, Signal Processing, 32(6), 1109-1121, Dec. 1984.
5. O. Cappe, "Elimination of musical noise phenomenon with the Ephraim and Malah noise suppressor," IEEE Trans. Speech and Audio Processing, 2(2), 345-349, Apr. 1994.
6. V. Vapnik, *Statistical learning theory*. Wiley, New York, 1998, forthcoming.
7. Xin Dong and Wu Zhaohui, "Speaker recognition using continuous density support vector machines," Electronics letters, 37(17), 1099-1101, Aug. 2001.
8. J.-H. Chang and N. S. Kim, "Speech enhancement: new approaches to soft decision," IEICE Trans. Inf. and Syst., vol. E84-D(9), 1231-1240, Sep. 2001.

## 저자 약력

### • 조규형 (Jo-Haing Jo)

2004년 2월 인하대학교 전자공학과 학사  
2004년 7월~2006년 7월 LG, Philips LCD 연구원  
2006년 9월~현재 인하대학교 전자공학부 석사



### • 장준혁 (Joon-Hyuk Chang)

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

