

논문 2005-42SP-5-6

베르누이-가우스 혼합 모델의 효과적인 파라미터 추정과 영상 잡음 제거에 응용

(Effective Parameter Estimation of Bernoulli-Gaussian Mixture Model and its Application to Image Denoising)

엄 일 규*, 김 유 신**

(Il Kyu Eom and Yoo Shin Kim)

요 약

일반적으로 웨이블릿 계수는 적은 수의 크기가 큰 계수와 많은 수의 작은 크기의 계수로 구성되어 있다. 따라서 본 논문에서는 웨이블릿 계수의 성긴 특성에 근거한 베르누이-가우스 혼합 모델을 이용한 잡음 제거 방법을 제안한다. 베르누이-가우스 혼합 모델은 베르누이 랜덤 변수와 가우스 혼합 랜덤 변수의 곱으로 구성되며, 이에 대한 베이저안 추정법으로 잡음 제거를 수행한다. 본 논문에서는 국부 자승 오차의 기대값을 이용하여 통한 베르누이 랜덤 변수에 대한 간략화된 파라미터의 추정을 통하여 효율적인 잡음 제거 방법을 제시한다. 모의실험 결과를 통하여 본 논문의 방법이 직교 웨이블릿 변환을 사용한 최신의 잡음 제거 방법보다 우수한 성능을 나타낸다는 것을 보여준다.

Abstract

In general, wavelet coefficients are composed of a few large coefficients and a lot of small coefficients. In this paper, we propose image denoising algorithm using Bernoulli-Gaussian mixture model based on sparse characteristic of wavelet coefficient. The Bernoulli-Gaussian mixture is composed of the multiplication of Bernoulli random variable and Gaussian mixture random variable. The image denoising is performed by using Bayesian estimation. We present an effective denoising method through simplified parameter estimation for Bernoulli random variable using local expected squared error. Simulation results show our method outperforms the states-of-art denoising methods when using orthogonal wavelets.

Keywords : 베르누이-가우스 혼합 모델, 웨이블릿, 베이저안 추정법, 잡음 제거, 국부 기대 자승 오차

I. 서 론

영상 획득 방법에 대한 기술이 발전하고 있지만, 획득된 영상에서 잡음을 제거하는 후처리의 필요성이 제기되고 있다. 디지털 영상에 대한 잡음 제거의 문제는 다음과 같이 모델링될 수 있다.

$$o = v + n \tag{1}$$

여기서 v 는 잡음이 없는 화소값, o 는 관측된 잡음이 첨가된 화소값을 나타낸다. n 은 평균이 영이고 분산이 σ_n^2 인 독립적이고 동일하게 분포된 가우스 랜덤 변수이다. 잡음에 대한 정보를 가지고 있다면, 관측된 o 로부터 최적의 v 를 추정하는 것이 잡음 제거의 목적이다.

Donoho와 Johnston^[1]이 웨이블릿 영역에서의 임계화를 이용한 잡음 제거 방법을 발표한 이래 웨이블릿 변환을 이용한 영상 및 신호의 잡음을 제거하는 방법이 일반화되고 있다. 웨이블릿 영역의 잡음 제거에 대한

* 정회원, 밀양대학교 정보통신공학과
(Dept. of Information and Communications,
Miryang National University)

** 정회원, 부산대학교 컴퓨터 및 정보통신 연구소
(Research Institute of Computer and Information
and Communicaiton)

접수일자: 2005년2월17일, 수정완료일: 2005년4월25일

모델링은 식 (1)을 웨이블릿 변환함으로써 다음과 같이 구성된다.

$$\mathbf{y} = \mathbf{w} + \mathbf{n}' \quad (2)$$

여기서 \mathbf{w} 와 \mathbf{y} 는 각각 웨이블릿 영역에서의 원영상과 잡음이 첨가된 관찰 영상이다. \mathbf{n}' 은 식 (1)에서와 마찬가지로 분산이 σ_n^2 인 가우스 랜덤 변수이다.

베이저안 추정법에 의한 잡음 제거 방법은 웨이블릿 계수의 prior 모델 및 파라미터의 추정이 중요한 요소로 작용한다. 일반적으로 웨이블릿 계수의 prior를 가우스 모델로 설정하는 경우^[2,3,4,8,9]가 많은데 이는 해석적으로 풀리는 해를 구하기 위함이다. 이 경우에는 원 신호의 분산이 파라미터가 되는데, ML(maximum likelihood) 추정법 또는 MAP(maximum a posterior) 추정법 등을 일반적으로 사용한다.

그러나 웨이블릿 계수의 통계적 특성은 일반적으로 비-가우스 분포를 가지는 것으로 알려져 있다^[6,7,10,11]. 잡음 제거를 위한 웨이블릿 계수의 비-가우스 통계적 특성으로 가우스 혼합 모델^[6,7], 가우스 스케일 혼합 모델^[10], 베르누이-가우스 모델^[11] 등이 사용되고 있다. 비-가우스 분포를 사용하는 경우에는 신호의 분산뿐만 아니라 베르누이 모델 등에 대한 추가적인 파라미터의 추정이 필요하게 된다.

본 논문에서는 웨이블릿 계수의 성긴 특성을 베르누이 랜덤 변수와 가우스 혼합 랜덤 변수의 곱으로 모델링되는 베르누이-가우스 혼합 모델을 이용한 잡음을 제거하는 방법을 제안한다. 또한 국부 자승 오차의 기댓값을 이용하여 베르누이 랜덤 변수에 대한 반복법이 없는 파라미터의 추정 방법을 제안한다. 모의실험 결과를 통하여 본 논문의 방법이 최신의 잡음 제거 방법보다 우수한 성능을 나타낸다는 것을 보여준다.

본 논문의 구성은 다음과 같다. II장에서는 베르누이-가우스 혼합 모델과 이에 대한 베이저안 추정방법을 기술하고, III장에서는 국부 자승 오차의 기댓값을 이용한 파라미터의 추정 방법을 제시한다. 모의 실험 결과를 통하여 제안 방법의 우수성을 IV장에서 보이고, V장에서 결론을 맺는다.

II. 베르누이-가우스 혼합 모델

1. 웨이블릿 계수의 베르누이-가우스 혼합 모델

웨이블릿 계수는 적은 수의 크기가 큰 계수와 많은

수의 작은 크기의 계수로 구성되어 있다. 이러한 특성을 반영할 수 있는 방법으로 큰 분산을 가지는 가우스 랜덤 변수와 작은 분산을 가지는 가우스 랜덤 변수의 혼합 모델이 있다. 웨이블릿 계수의 스파이크 특성은 가우스 혼합 모델과 베르누이 모델의 결합으로 표현할 수 있다. 즉, 스파이크 랜덤 변수 \mathbf{z} 는 다음과 같다.

$$\mathbf{z} = (\mathbf{q}, \mathbf{w}) \quad (3)$$

식 (3)에서 \mathbf{q} 는 베르누이 랜덤 변수이고 다음과 같이 나타난다.

$$P(\mathbf{q}_k = 1) = \lambda, P(\mathbf{q}_k = 0) = 1 - \lambda \quad (4)$$

\mathbf{w} 는 주어진 \mathbf{q} 에 대하여 가우스 랜덤 변수로써 다음과 같이 나타난다.

$$\mathbf{w}_k \sim \mathcal{N}(0, \mathbf{q}_k \sigma_l^2 + (1 - \mathbf{q}_k) \sigma_s^2) \quad (5)$$

여기서 \mathcal{N} 은 가우스 확률 밀도함수를 나타내고 σ_l^2 및 σ_s^2 은 가우스 랜덤 변수의 분산이고 $\sigma_l^2 > \sigma_s^2$ 이다. 잡음 제거를 위해서는 \mathbf{q}_k , σ_l^2 , 및 σ_s^2 를 추정해야 한다.

2. 베이저안 추정 방법

관찰된 영상 \mathbf{y} 가 주어졌을 때, 베이저안 추정법은 다음과 같이 사후 likelihood를 최대화시키는 것으로 표현된다.

$$(\hat{\mathbf{q}}, \hat{\mathbf{w}}) = \arg \max_{(\mathbf{q}, \mathbf{w})} p(\mathbf{y}|\mathbf{q}, \mathbf{n})p(\mathbf{w}|\mathbf{q}, \mathbf{n})P(\mathbf{q}|\mathbf{n}) \quad (6)$$

식 (6)에서 $\hat{\mathbf{q}}$ 는 로그 likelihood $L(\mathbf{q})$ 를 최대화시키는 형태로 다음과 같이 구한다.

$$\hat{\mathbf{q}} = \arg \max_{\mathbf{q}} L(\mathbf{q}) \quad (7)$$

또한 로그 likelihood는 다음과 같이 나타난다.

$$L(\mathbf{q}) = -\log(\det \mathbf{B}(\mathbf{q})) - \mathbf{z}^t (\mathbf{B}(\mathbf{q})^{-1} \mathbf{y}) - 2(\sum_k \mathbf{q}_k) \log(1 - \lambda) / \lambda \quad (8)$$

여기서

$$\mathbf{B}(\mathbf{q}) = E[\mathbf{z} \mathbf{z}^t] = \Gamma_w(\mathbf{q}) + \sigma_n^2 \mathbf{I} \quad (9)$$

$$\Gamma_w(\mathbf{q}) = \sigma_s^2 \mathbf{I} + (\sigma_l^2 - \sigma_s^2) \mathbf{Q}, \mathbf{Q} = \text{diag}(\mathbf{q}_k) \quad (10)$$

여기서 \mathbf{I} 는 단위행렬을 나타내며, $\text{diag}(\mathbf{q}_k)$ 는 \mathbf{Q} 행렬

의 대각 성분을 나타낸다.

식 (7)에 의해서 \hat{q} 를 알고, 관찰된 영상 y 를 알고 있다고 가정하면, w 는 가우스 랜덤 변수이기 때문에 다음과 같이 해석적으로 계산할 수 있다.

$$\hat{w} = \Gamma_w(\hat{q})(B(\hat{q}))^{-1}y \quad (11)$$

식 (11)은 스파이크 모델에 대한 베이지안 추정치이다.

이와 같은 베이지안 추정법을 이용하면 w 는 해석적으로 구할 수 있는 반면에 q 는 해석적으로 구하지 못하는 단점이 존재한다. 즉, q 에 대하여 m 개의 샘플이 존재하면 2^m 개의 가능한 해가 존재할 수 있다. 따라서 다양한 반복적인 수치해석적 방법^[12,13]을 통하여 q 의 추정값을 구해야 하는 단점이 있다.

III. 제안 방법

1. 파라미터의 추정

본 논문에서는 원 영상과 추정 영상에 대한 국부 자승 오차의 기댓값을 이용하여 수치해석적 방법 없이 q 의 값을 추정하고, 잡음을 제거하는 방법을 제안하고자 한다.

모든 q 의 값이 '1'이라 가정하면 식 (5)에서 x_k 는 가우스 랜덤 변수가 된다. 따라서 가우스 prior에 대한 베이지안 추정법에 의한 w 의 추정은 국부적인 형태로 다음과 같이 구해진다.

$$\hat{w}_k = h_k y_k = \frac{\hat{\sigma}^2(w_k)}{\hat{\sigma}^2(w_k) + \sigma_n^2} y_k, h_k = \frac{\hat{\sigma}^2(w_k)}{\hat{\sigma}^2(w_k) + \sigma_n^2} \quad (12)$$

여기서 $\hat{\sigma}^2(w_k)$ 는 w_k 의 분산에 대한 추정값이다. w_k 및 \hat{w}_k 에 대한 국부 자승 오차의 기대값 e_k 를 다음과 같이 정의할 수 있다.

$$e_k = E\{(w_k - h_k y_k)^2\} \quad (13)$$

식 (13)을 풀면 국부 자승 오차의 기대값은

$$e_k = \frac{2}{M} \frac{\sigma_n^4}{\sigma^2(y_k)} + \sigma_n^2 - \frac{\sigma_n^4}{\sigma^2(y_k)} \quad (14)$$

로 된다^[14]. 식 (14)에서 M 은 국부 분산 $\sigma^2(y_k)$ 를 구하기 위한 커널의 크기이며, 본 논문에서는 정방향의

커널 크기 $M=9$ 를 사용하였다.

만약 $e_k > \sigma^2(w_k)$ 의 조건을 가정한다면, 이 조건은 오차의 자승값이 웨이블릿 계수의 분산값 보다 큰 경우가 도난다. 따라서 이 경우는 잘못된 추정으로 볼 수 있다. 본 논문에서는 이러한 현상을 잡음 환경하에서 모든 k 에 대하여 $q_k = 1$ 로 두었을 때 즉, w 를 가우스 모델로 보았을 경우에 기인하는 것으로 가정한다.

$\sigma^2(w_k) = \sigma^2(y_k) - \sigma_n^2$ 을 $e_k > \sigma^2(w_k)$ 의 조건에 대입하면,

$$e_k = \frac{2}{M} \frac{\sigma_n^4}{\sigma^2(y_k)} + 2\sigma_n^2 - \frac{\sigma_n^4}{\sigma^2(y_k)} > \sigma^2(y_k) \quad (15)$$

가 되고, (15)의 부등식을 풀면

$$\sigma^2(y_k) < (1 + \sqrt{2/M})\sigma_n^2 \quad (16)$$

이 된다.

본 논문에서는 식 (16)을 이용하여 q_k 의 추정값을 다음과 같이 구한다. 즉,

$$\hat{q}_k = \begin{cases} 0, & \sigma^2(y_k) < (1 + \sqrt{2/M})\sigma_n^2 \\ 1 & \sigma^2(y_k) \geq (1 + \sqrt{2/M})\sigma_n^2 \end{cases} \quad (17)$$

그림 1 및 그림 2는 $\sigma_n^2 = 100$ 이고, $M=9(3 \times 3$ 국부 창)일 경우의 Lena 및 Barbara 영상의 q_k 의 추정값을 나타낸다. 그림 1 및 그림 2에서 볼 수 있는 바와 같이 영상의 에지 부분 즉, 큰 크기의 계수값에 $q_k = 1$ 로 나타남을 볼 수 있다.

2. 잡음 제거

잡음 제거를 위한 베이지안 추정법은 식 (11)에 의해서 다음과 같이 나타난다.

$$\hat{w}_k = \frac{\hat{\sigma}_s^2(w_k) + \hat{q}_k(\hat{\sigma}_l^2(w_k) - \hat{\sigma}_s^2(w_k))}{\hat{\sigma}_s^2(w_k) + \hat{q}_k(\hat{\sigma}_l^2(w_k) - \hat{\sigma}_s^2(w_k)) + \sigma_n^2} y_k \quad (18)$$

여기서 $\hat{\sigma}_l^2(w_k)$ 및 $\hat{\sigma}_s^2(w_k)$ 각각 분산의 추정값이며, ML(maximum likelihood) 추정법을 이용하여 다음과 같이 구해진다.

$$\hat{\sigma}_l^2(w_k) = (\sigma_l^2(y_k) - \sigma_n^2)_+ \quad (19)$$

$$\hat{\sigma}_s^2(w_k) = (\sigma_s^2(y_k) - \sigma_n^2)_+ \quad (20)$$




그림 1. (a) $\sigma_n^2 = 100$ 일 때의 잡음이 섞인 Lena 영상

(b) 잡음이 첨가된 Lena 영상의 \hat{q}_k 값.

Fig. 1. (a) Noisy Lena image when $\sigma_n^2 = 100$

(b) \hat{q}_k value of noisy Lena image.




그림 2. (a) $\sigma_n^2 = 100$ 일 때의 잡음이 섞인 Barbara 영

상 (b) 잡음이 첨가된 barbara 영상의 \hat{q}_k 값.

Fig. 2. (a) Noisy Barbara image when $\sigma_n^2 = 100$

(b) \hat{q}_k value of noisy Barbara image.

식 (19), (20)에서 $(g)_+$ 는 $g \geq 0$ 일 때, g 이고, $g < 0$ 일 때 0으로 두는 연산자이다. 그리고

$$\sigma_i^2(y_k) = \frac{1}{|c_k|} \sum_{y_i \in c_k} \hat{q}_i y_i^2 \quad (21)$$

$$\sigma_s^2(y_k) = \frac{1}{|c_k|} \sum_{y_i \in c_k} (1 - \hat{q}_i) y_i^2 \quad (22)$$

이며, 여기서 c_k 는 분산을 추정하기 위한 이웃 계수의 집합이고, $|c_k|$ 는 c_k 의 수이다.

IV. 모의실험

제안된 영상 잡음 제거 방법을 이용하여 표준 영상

표 1. 다양한 잡음 제거 방법 및 잡음 강도에 대한 잡음 제거된 Lena 영상의 PSNR 값.

Table 1. PSNR results for several denoising methods with Lena image.

σ_n	PSNR			
	10	15	20	25
LAWML[2]	34.18	32.11	30.65	29.50
LAWMAP[2]	34.32	32.33	30.90	29.80
Bivariate[8]	34.23	32.32	31.04	29.92
Cai[9]	34.22	32.23	30.85	29.79
Chang[3]	-	32.36	31.04	30.04
제안방법 1(Db8)	34.31	32.38	31.04	29.95
제안방법 2(Db8)	34.36	32.43	31.08	30.01
제안방법 1(QMF9)	34.48	32.60	31.28	30.25
제안방법 2(QMF9)	34.54	32.66	31.35	30.32

표 2. 다양한 잡음 제거 방법 및 잡음 강도에 대한 잡음 제거된 Barbara 영상의 PSNR 값.

Table 2. PSNR results for several denoising methods with Barbara image.

σ_n	PSNR			
	10	15	20	25
LAWML[2]	32.50	30.10	28.50	27.26
LAWMAP[2]	32.60	30.19	28.53	27.24
Bivariate[8]	32.25	29.97	28.36	27.16
Cai[9]	-	-	-	-
Chang[3]	-	29.92	28.33	27.20
제안방법 1(Db8)	32.56	30.21	28.60	27.39
제안방법 2(Db8)	32.60	30.25	28.65	27.45
제안방법 1(QMF9)	32.74	30.41	28.82	27.65
제안방법 2(QMF9)	32.79	30.46	28.88	27.71

(Lena, Barbara:8bpp)에 대하여 모의실험을 하였다. 가우스 백색 잡음은 MATLAB을 사용하여 생성하였다. 웨이블릿 변환을 위해서는 다른 잡음 제거 결과들과의 비교를 위해서 Daubechies의 8-탭 직교 웨이블릿 필터(Db8) 및 QMF 9-탭 필터(QMF9)^[15]를 사용하여 다섯 번의 웨이블릿 변환을 수행하였다. 또한 신호의 분산을 추정하기 위한 $|c_k|$ 는 웨이블릿 스케일에 따라 거친 스케일에서 섬세한 스케일로 갈수록 (9, 9, 9, 25, 25)로 설정하였다.

표 1 및 표 2는 Lena 및 Barbara 영상에 대하여 제안 방법과 다양한 잡음 제거 방법을 비교한 결과를 나타낸다. 표 1 및 표 2에서 제안 방법 1은 식 (18)을 그대로 사용한 경우이며, 제안 방법 2는 \hat{q}_k 에 대한 오차를 보상하기 위하여 \hat{q}_k 의 기댓값 즉, $E(\hat{q}_k)$ 를 사용한 경우이다. $E(\hat{q}_k)$ 를 사용한 경우가 \hat{q}_k 를 사용한 경우보다 약간의 PSNR 개선이 있음을 알 수 있다. 표에서 볼



그림 3. $\sigma_n = 20$ 일 때의 Lena 영상에 대한 기존 방법과 제안 방법의 잡음 제거 결과. (a) LAWML (30.65dB), (b) LAWMAP (30.90dB), (c) Bivariate (31.04dB), (d) 제안 방법 (31.35dB).

Fig. 3. Denoising results for Lena of conventional methods and the proposed method when $\sigma_n = 20$. (a) LAWML (30.65dB), (b) LAWMAP (30.90dB), (c) Bivariate (31.04dB), (d) The Proposed method (31.35dB).

수 있듯이 제안 방법의 결과가 다른 방법의 결과와 대등하거나 우수함을 알 수 있다. 특히 QMF 9-탭 필터를 사용한 경우는 Lena 및 Barbara 영상에 대하여 다른 방법보다 우수한 결과를 보이고 있다. 일반적으로 잡음 제거에 사용하는 Daubechies의 8-탭 직교 웨이블릿 필터보다 QMF 9-탭 필터가 잡음 제거에 효율적이라는 것을 알 수 있다.

그림 3 및 그림 4는 각각 Lena 및 Barbara 영상에 대하여 다양한 잡음 제거 방법을 수행한 비교 결과이다. 그림에서 볼 수 있듯이 본 논문의 방법은 주관적으로도 우수한 결과를 보임을 알 수 있다.

V. 결 론

본 논문에서는 웨이블릿 계수의 베르누이-가우스 혼합 모델링을 이용한 잡음 제거 방법을 제안하였다. 베르누이-가우스 혼합 모델은 베르누이 랜덤 변수와 가우스 혼합 랜덤 변수의 곱으로 모델링될 수 있으며, 이에 대한 베이저안 추정법으로 잡음 제거를 수행하였다. 본 논문에서는 국부 자승 오차의 기대값을 이용한 임계화 방법을 통한 베르누이 랜덤 변수에 대한 간략화된 파라미터의 추정을 통하여 효율적인 잡음 제거 방법을 제시하였다. 모의실험 결과를 통하여 본 논문의 방법이 직교 웨이블릿 변환을 사용한 최신의 잡음 제거 방법보



그림 4. $\sigma_n = 20$ 일 때의 Barbara 영상에 대한 기존 방법과 제안 방법의 잡음 제거 결과. (a) LAWML (28.50dB), (b) LAWMAP (28.53dB), (c) Bivariate (28.36dB), (d) 제안 방법 (28.88dB).

Fig. 4. Denoising results for Barbara of conventional methods and the proposed method when $\sigma_n = 20$. (a) LAWML (28.50dB), (b) LAWMAP (28.53dB), (c) Bivariate (28.36dB), (d) The Proposed method (28.88dB).

다 우수한 성능을 나타낸다는 것을 보여 주었다.

참고 문헌

- [1] D. L. Donoho and I. M. Jonhstone, "Adapting to unknown smoothness via wavelet shrinkage," J. Amer. Statist. Assoc., vol. 90, no. 432, pp. 1200-1224, 1995.
- [2] M. K. Mihcak, I. Kozintsev, K. Ramchandran, and P. Moulin, "Low-complexity image denoising based on statistical modeling of wavelet coefficients," IEEE Signal Processing Letters, vol. 6, pp. 300-303, 1999.
- [3] S. G. Chang, B. Yu, and M. Vetterli, "Spatially adaptive wavelet thresholding with context modeling for image denoising," IEEE Trans. Image Processing, vol.9, pp.1522-1531, 2000.
- [4] M. K. Mihcak, I. Kozintsev, K. Ramchandran, "Spatially Adaptive statistical Modeling of Wavelet Image Coefficients and Its Application to Denosing," Proc. IEEE Int. Conf. Acous., Speech and Signal Processing, vol.6, pp. 3253-3256, 1999.
- [5] J. Liu and P. Moulin, "Image denoising based on scale-space mixture modeling of wavelet coefficients," Proc. IEEE Int. Conf. on Image Processing, Kobe, Japan, 1999.

- [6] J. K. Romberg, H. Choi, and R. G. Baraniuk, "Bayesian tree-structured image modeling using wavelet-domain hidden Markov models," *IEEE Trans. Image Processing*, vol.10, no.7, pp. 1056-1068, 2001.
- [7] H. Choi, J. Romberg, R. Baraniuk, and N. Kingsbury, "Hidden Markov Tree Modeling of Complex Wavelet Transforms," *Proc. IEEE Int. Conf. Acous., Speech and Signal Processing*, Istanbul, Turkey, June, 2000.
- [8] L. Sendur and I. W. Selesnick, "Bivariate shrinkage with local variance estimation," *IEEE Signal Processing Letters*, vol.9, no.12, pp.438-441, 2002.
- [9] Z. Cai, T. H. Cheng, C. Lu, and K. R. Subramanian, "Efficient wavelet based image denoising algorithm," *Electron. Lett.*, vol. 37, no.11, pp.683-685, 2001.
- [10] J. Pirtilla, V. Strela, M. Wainwright and E. Simoncelli, "Adaptive Wiener Denoising Using a Gaussian Scale Mixture Model," *Proc. IEEE Int. Conf. on Image Processing*, 2001.
- [11] J. C. Pesquet, H. Krim, D. Laporini and E. Hamman, "IEEE Int. Conf. Acous., Speech and Signal Processing," pp. 2634-2637, 1996.
- [12] Y. Goussard, J. Idier and G. Demoment, "A New Algorithm for Iterative Deconvolution of Sparse Spike Trains," *IEEE Int. Conf. Acous., Speech and Signal Processing*, 1990.
- [13] F. Champagnat, J. Idier and G. Demoment, "Deconvolution of Sparse Spike Train According for Wavelet Phase Shifts and Colored Noise," *IEEE Int. Conf. Acous., Speech and Signal Processing*, 1993.
- [14] M. Kazubek, "Wavelet Domain Image Denoising by Thresholding and Wiener Filtering," *IEEE Signal Processing Letters*, vol.10, no.11, pp.324-326, 2003.
- [15] E. H. Adelson, E. Simoncelli, and R. Hingorani, "Orthogonal pyramid transforms for image coding," *Proc. SPIE*, vol.845, pp.50-58, 1987.

— 저 자 소 개 —



엄 일 규(정회원)

1990년 부산대학교 전자공학과
학사.1992년 부산대학교 전자공학과
석사.1998년 부산대학교 전자공학과
박사.1997년~현재 밀양대학교 정보통신공학과 부교수
<주관심분야 : 통계신호처리, 영상처리, 웨이블릿
변환 신호처리, 신경회로망>

김 유 신(정회원)

1974년 서울대학교 전자공학과
학사.1980년 U.C. Berkeley 전자공학과
석사.1983년 Stanford University
전자재료 박사과정 수학.

1995년 Cornell University Ph.D

1983년~현재 부산대학교 전자공학과 교수

현재 한국 과학철학회 회장

<주관심분야 : 영상처리, 신경회로망, 공학윤리,
과학기술철학>