

# 다중 정규화 매개 변수를 이용한 혼합 norm 영상 복원 방식

준회원 최 권 열\*, 정회원 김 명 진\*, 홍 민 철\*

## A Mixed Norm Image Restoration Algorithm Using Multi Regularization Parameters

Kwon Yul Choi\* Associate Member, Myoung-Jin Kim\*, Min-Cheol Hong\* Regular Members

### 요 약

본 논문에서는 다중 정규화 매개 변수를 이용한 혼합 norm 영상 복원 방식을 제안한다. 임의의 분포를 갖는 첨가 노이즈를 효율적으로 제거하기 위해 정규화 완화  $l_2$  함수와 정규화 완화  $l_4$  함수를 결합한 새로운 혼합 norm 정규화 완화 함수가 유도된다. 각 완화 함수의 완화도를 제어하기 위해 개별적인 정규화 매개 변수가 정의 되고, 정규화 완화  $l_2$  함수와 정규화 완화  $l_4$  함수의 상대적 기여도를 제어하기 위한 혼합 norm 정규화 매개 변수가 kurtosis를 이용해 정의된다. 안정적인 해를 얻기 위해 반복기법이 사용되었으며, 이들의 수렴 여부가 분석되었다. 다양한 분포를 갖는 첨가 노이즈가 실험에 사용되었으며, 이를 통해서 제안된 방식의 성능을 평가할 수 있었다.

**Key Words** : Restoration, Mixed norm, Regularization, Iterative algorithm

### ABSTRACT

In this paper, we propose an iterative mixed norm image restoration algorithm using multi regularization parameters. A functional which combines the regularized  $l_2$  norm functional and the regularized  $l_4$  norm functional is proposed to efficiently remove arbitrary noise. The smoothness of each functional is determined by the regularization parameters. Also, a regularization parameter is used to determine the relative importance between the regularized  $l_2$  norm functional and the regularized  $l_4$  norm functional using kurtosis. An iterative algorithm is utilized for obtaining a solution and its convergence is analyzed. Experimental results demonstrate the capability of the proposed algorithm.

### 1. 서 론

디지털카메라, 캠코더 및 스캐너와 같은 디지털 영상 획득 장치에 의해 얻어진 영상은 일반적으로 원영상과 일치하지 않는다. 그것은 원영상의 훼손된 복사본과 같다. 훼손의 요인은 주어진 상황에 따라

다양하다. 영상 복원이란 이렇게 훼손된 영상으로부터 최대한 원영상에 가까운 영상을 추정해내는 것을 말한다. 훼손된 영상으로부터 요구되는 정보를 충분히 얻어낼 수 없다면, 해당 영상은 무의미하다. 그러므로 영상 복원은 필수적으로 요구되는 분야이다. 의료 영상 및 인공위성에 의해 획득된 영상의

\* 본 연구는 서울시 산학연 협력사업 (과제번호 10544) 및 숭실대학교 교내 연구비 지원 사업에 의해 수행되었음.

\* 숭실대학교 정보통신전자공학부 (tantis@vpl.ssu.ac.kr, webzealer@vpl.ssu.ac.kr, mhong@ssu.ac.kr)

논문번호 : KICS2007-07-338 접수일자 : 2007년 7월 31일, 최종논문접수일자 : 2007년 10월 31일

판독 전 화질 개선 및 압축으로 인해 훼손된 영상의 만족스런 화질 보장을 위한 화질 개선등이 영상 복원의 활용 예이다<sup>1)</sup>.

영상 복원 문제는 영상 훼손 현상에 대한 모델링에서부터 시작한다. 임의의  $M \times N$  크기 영상은 단일 움직임, 영상 획득 시스템의 초점의 부정확성, 대기 산란 현상 및 기타 현상으로 인해 열화되며, 전송 및 저장 과정에서 발생하는 노이즈에 의해 더욱 영상 화질은 훼손되게 된다. 이와 같은 영상 훼손 현상은 식 (1)과 같이 모델화된다<sup>1)</sup>.

$$y = Hx + n, \quad (1)$$

식 (1)에서  $y, x, n$ 은 스택 순서로 재배열된  $MN \times 1$  크기 벡터로 각각 훼손 영상, 원영상 및 첨가 노이즈를 나타내며,  $H$ 는  $MN \times MN$  크기의 PSF (Point Spread Function)을 표현하는 행렬을 나타낸다. 행렬  $H$ 는 공간 불변 또는 공간 변화 훼손을 나타낼 수 있다.

영상 복원 문제를 표현하기 위해 일반적으로 MSE (Mean Squared Error) norm 방식이 사용되어 왔다<sup>1-2)</sup>. MSE 방식은 LMS (Least Mean Squared) 방식의 결과로 유도 가능하다. 이와 같이 LMS 방식을 영상 복원 문제를 표현 또는 접근하기 위해 주로 사용하는 이유는 LMS 방식이 수학적으로 다루기 쉽고, 첨가 노이즈가 가우시안 분포를 갖는 경우 최적화된 결과를 얻기에 용이하기 때문이다.

수많은 응용 분야에서 첨부 노이즈는 비가우시안 또는 다양한 노이즈의 결합된 형태를 취할 수 있으며, 이와 같은 경우, 2차 이상의 고차 norm을 적용 필터 과정에 적용하였다<sup>3-5)</sup>. 더불어, 영상 복원 문제에 LMS와 LMF (Least Mean Fourth)를 결합시킨 방식을 적용한 결과를 통해 특정 첨가 노이즈 환경에서 LMF 방식이 LMS 방식보다 우월한 성능을 보임이 입증되었다<sup>6)</sup>.

본 논문에서는 정규화 완화  $l_2$  함수 및 정규화 완화  $l_4$  함수를 결합시킨 혼합 norm 영상 복원 방식을 제안한다. 각 함수의 완화도를 제어하기 위해 함수별 정규화 매개 변수를 정의했으며, 정규화  $l_2$  함수와 정규화  $l_4$  함수에 대한 상대적 기여도를 제어하기 위한 혼합 norm 정규화 매개 변수를 정의하였다.

본 논문은 다음과 같이 구성되어 있다. 2장에서는 제안된 다중 정규화 매개 변수를 이용한 혼합

norm 영상 복원 방식에 대해 제안한다. 또한, 혼합 norm의 상대적 기여도를 결정하기 위해 사용되는 kurtosis 함수에 대해 고찰한다. 3장에서는 반복 영상 복원 기법에 대해 설명하며, 수렴 조건에 대한 분석에 대해 기술한다. 4장에서는 정규화 매개 변수들의 결정 방식에 대해 기술하며, 마지막으로 5장 및 6장에서는 실험 결과 및 결론에 대해 기술한다.

## II. 다중 정규화 매개변수를 이용한 혼합 norm 복원 방식

불량조건(ill-posed condition)을 포함하는 영상 복원 문제를 해결하기 위해 정규화 기법이 널리 연구되어 왔다. CLS (Constrained Least Square) 방식은 영상은 일반적으로 완만하다는 사전정보를 제약 조건으로 사용하기 위해 정규화 기법을 도입한 방식이다. 하지만 이 방식 또한 LMS 방식으로 이루어져 있으므로 비가우시안 분포를 갖는 첨가 노이즈에 대해 비효율적이다. 특히 일반적인 경우, 첨가 노이즈는 uniform, Cauchy 및 다양한 분포를 갖고 있으므로 CLS 기법을 일반 응용 분야에 적용하기에는 한계가 있다.

이미 기술된 바와 같이 비가우시안 및 가우시안 분포를 갖는 첨가 노이즈에 의해 훼손된 영상을 효과적으로 처리하기 위해서 LMS와 LMF가 결합된 방식이 효과적임을 알 수 있다. 이를 반영한 함수를 식 (2)와 같이 정의한다.

$$M(x) = (1 - \gamma(n))M_1(x) + \gamma(n)M_2(x), \quad (2)$$

위 식에서  $\gamma(\cdot)$  ( $0 \leq \gamma(n) \leq 1$ )은  $M_1(x)$  및  $M_2(x)$ 의 상대적 기여도를 제어하는 혼합 norm 정규화 변수이며,  $M_1(x)$  및  $M_2(x)$ 는 다음과 같이 정의된다.

$$\begin{aligned} M_1(x) &= \|y - Hx\|_2^2 + \alpha_1(x) \|Cx\|_2^2, \\ M_2(x) &= \|y - Hx\|_4^4 + \alpha_2(x) \|Cx\|_4^4, \end{aligned} \quad (3)$$

식 (3)에서  $\|\cdot\|_p$ 는  $l_p$  norm을 의미하며,  $C$ 는 고주파 통과 필터를 나타낸다. 또한, 식 (3)의  $\alpha_1(x)$  및  $\alpha_2(x)$ 는  $M_1(x)$  및  $M_2(x)$ 의 완화도를 제어하는 정규화 매개 변수를 의미한다.

LMS 및 LMF의 성능은 참고문헌 [3-6]에서 이미 비교 및 분석되었다. 즉, sub-Gaussian 분포를

갖는 신호에 대해 LMF 방식이 LMS 방식보다 성능이 우월한 반면, 첨가 노이즈가 super-Gaussian 분포를 갖는 신호에 대해 LMS 방식이 LMF 방식보다 성능이 우월하다. 이와 같은 특성에 따라 식 (2)에서는 첨부 노이즈가 super-Gaussian일 때  $M_2(x)$  함수가 무시될 수 있도록  $\gamma(n) \approx 0$ 임이 바람직스러우며, 첨부노이즈가 sub-Gaussian에 대해서는  $M_1(x)$  함수가 고려되지 않도록  $\gamma(n) \approx 1$ 이 바람직스럽다. 반면에 혼합 노이즈인 경우  $\gamma(n)$ 이  $M_1(x)$  및  $M_2(x)$ 를 효과적으로 제어할 수 있도록 결정되어야 한다. 하지만 대부분의 응용 분야에서 첨가 노이즈 분포는 알려져 있지 않으므로  $\gamma(n)$ 는 이용 가능한 정보로부터 예측되어야 한다.

임의의 신호에 대한 가우시안 정도는 kurtosis로부터 결정할 수 있으며, 이것으로부터 유도된 랜덤 변수  $r$ 에 대해 가우시안 정도는 식 (4)와 같다<sup>6)</sup>.

$$\chi(r) = \frac{1}{MN} \|r\|_4^4 - 3\left(\frac{1}{MN} \|r\|_2^2\right)^2 \quad (4)$$

식 (4)에서 정의된 kurtosis는 가우시안 신호에 대해 '0'인 값을, super-Gaussian에 대해 양의 값을, sub-Gaussian 신호에 대해 음의 값을 갖게 된다.

### III. 반복 해 및 수렴 조건

#### 3.1 반복해

본 논문에서는 식 (2)에서 정의된 혼합 norm 함수를 최소화하기 위해 steepest-descent 방식을 적용하였다.  $M(x)$ 를  $x$ 에 대해 gradient를 취한 결과는 다음과 같다.

$$\begin{aligned} \nabla_x M(x) = & -(1-\gamma(n))[2H^T(y-Hx) - 2\alpha_1(x)C^T Cx \\ & - \nabla_x \alpha_1(x) \|Cx\|_2^2] - \gamma(n)[4H^T(y-Hx)^3 - 4\alpha_2(x) \\ & C^T(Cx)^3 - \nabla_x \alpha_2(x) \|Cx\|_4^4] = 0, \end{aligned} \quad (5)$$

식 (5)에서  $\nabla_x \alpha_1(x) = 0$  및  $\nabla_x \alpha_2(x) = 0$  이므로 분석 과정에서 고려하지 않아도 된다. 복원 영상을 얻기 위해 successive approximation 방식을 식 (5)에 적용하면 반복해는 식 (6)과 같이 기술될 수 있다.

$$\begin{aligned} x_{k+1} = & x_k + \beta[(1-\gamma(n))(H^T(y-Hx_k) - \alpha_1(x_k)C^T Cx_k) \\ & + 2\gamma(n)(H^T(y-Hx_k)^3 - \alpha_2(x_k)C^T(Cx_k)^3)], \end{aligned} \quad (6)$$

식 (6)에서  $\beta$ 는 수렴 속도 및 수렴성을 보장하는 이완 매개 변수이다. LMS 및 LMF의 상대적 기여도를 제어하는 혼합 norm 정규화 매개 변수,  $\gamma(n)$ 는 반복해에서 예측된 첨부 노이즈에 의해 결정되므로 식 (6)은 다음과 같이 표현될 수 있다.

$$\begin{aligned} x_{k+1} = & x_k + \beta[(1-\gamma(n_k))(H^T(y-Hx_k) - \alpha_1(x_k)C^T Cx_k) \\ & + 2\gamma(n_k)(H^T P(x_k)(y-Hx_k) - \alpha_2(x_k)C^T Q(x_k)Cx_k)] \\ = & x_k + \beta[H^T((1-\gamma(n_k))I + 2\gamma(n_k)P(x_k))(y-Hx_k) \\ & - C^T(\alpha_1(x_k)(1-\gamma(n_k))I + \alpha_2(x_k)2\gamma(n_k)Q(x_k))Cx_k], \end{aligned} \quad (7)$$

식 (7)에서  $I$ 는 주대각 성분이 '1'인 단위 행렬을 의미하며,  $P(x)$  및  $Q(x)$ 는  $MN \times MN$  크기의 대각 행렬로서 대각 성분은  $P(x_k)_{i,i} = (y_i - (Hx_k)_i)^2$  및  $Q(x_k)_{i,i} = ((Cx_k)_i)^2$ 을 의미한다.

#### 3.2 수렴성 및 수렴 조건

반복 기법이 수렴하기 위한  $\beta$ 의 조건을 찾기 위해 contraction mapping theorem을 이용한다. 식 (7)의 연속된 두 반복해인  $x_k, x_{k+1}$ 의 차는 식 (8)과 같이 정리될 수 있다.

$$\begin{aligned} x_{k+1} - x_k = & (x_k - x_{k-1}) + \beta[H^T H(x_k - x_{k-1}) - H^T \\ & (\theta_1(x_k) - \theta_1(x_{k-1})) + H^T H(\theta_2(x_k) - \theta_2(x_{k-1})) + \\ & 2(\theta_3(x_k) - \theta_3(x_{k-1})) - 2(\theta_4(x_k) - \theta_4(x_{k-1})) - \\ & C^T C(\theta_5(x_k) - \theta_5(x_{k-1})) - C^T(\theta_6(x_k) - \theta_6(x_{k-1}))], \end{aligned} \quad (8)$$

식 (8)에서  $\theta_1(x_k) = \gamma(n_k)y$ ,  $\theta_2(x_k) = \gamma(n_k)x_k$ ,  $\theta_3(x_k) = \gamma(n_k)P(x_k)y$ ,  $\theta_4(x_k) = \gamma(n_k)P(x_k)Hx_k$ ,  $\theta_5(x_k) = \alpha_1(x_k)x_k$ ,  $\theta_6(x_k) = \alpha_2(x_k)Q(x_k)Cx_k$ . 비선형 인자  $\theta_1(x_k), \theta_2(x_k), \theta_3(x_k), \theta_4(x_k), \theta_5(x_k)$  및  $\theta_6(x_k)$ 는 다음과 같이 선형화 될 수 있다<sup>7)</sup>.

$$\begin{aligned} \theta_1(x_k) - \theta_1(x_{k-1}) & \approx J_{\theta_1}(x_k)(x_k - x_{k-1}), \\ \theta_2(x_k) - \theta_2(x_{k-1}) & \approx J_{\theta_2}(x_k)(x_k - x_{k-1}), \\ \theta_3(x_k) - \theta_3(x_{k-1}) & \approx J_{\theta_3}(x_k)(x_k - x_{k-1}), \\ \theta_4(x_k) - \theta_4(x_{k-1}) & \approx J_{\theta_4}(x_k)(x_k - x_{k-1}), \\ \theta_5(x_k) - \theta_5(x_{k-1}) & \approx J_{\theta_5}(x_k)(x_k - x_{k-1}), \\ \theta_6(x_k) - \theta_6(x_{k-1}) & \approx J_{\theta_6}(x_k)(x_k - x_{k-1}), \end{aligned} \quad (9)$$

식 (9)에서  $J_{\theta_1}(x_k), J_{\theta_2}(x_k), J_{\theta_3}(x_k), J_{\theta_4}(x_k), J_{\theta_5}(x_k)$  및  $J_{\theta_6}(x_k)$ 는 Jacobian 행렬을 의미한다. 식 (9)를 이용해 식 (8)은 다음과 같이 간단히 정리될 수 있다.

$$x_{k+1} - x_k = [I - \beta((1 - \gamma(n_k))H^T H + 6\gamma(n_k)H^T P(x_k)H + \alpha_1(x_k)C^T C + 2\alpha_2(x_k)C^T Q(x_k)C)](x_k - x_{k-1}) \quad (10)$$

$$\gamma(n_k) = \frac{\exp(-c\chi(n_k))}{1 + \exp(-c\chi(n_k))} \quad (14)$$

where  $\begin{cases} n_k = y - Hx_k \\ c > 0 \end{cases}$

그러므로 contraction mapping theorem에 의해 반복 기법이 수렴하기 위한 조건은 식 (11)과 같다.

$$\|I - \beta((1 - \gamma(n_k))H^T H + 6\gamma(n_k)H^T P(x_k)H + \alpha_1(x_k)C^T C + 2\alpha_2(x_k)C^T Q(x_k)C)\| < 1, \quad (11)$$

식 (11)에서  $(1 - \gamma(n_k))H^T H + 6\gamma(n_k)H^T P(x_k)H + \alpha_1(x_k)C^T C + 2\alpha_2(x_k)C^T Q(x_k)C$ 는 양치 정의 행렬 (positive definite matrix)이므로 식 (11)은 다음과 같이 기술될 수 있다.

$$|1 - \beta\lambda_{\max}((1 - \gamma(n_k))H^T H + 6\gamma(n_k)H^T P(x_k)H + \alpha_1(x_k)C^T C + 2\alpha_2(x_k)C^T Q(x_k)C)| < 1, \quad (12)$$

위 식에서  $\lambda_{\max}(A)$ 는 행렬  $A$ 의 최대 singular 값을 의미한다.  $H$  및  $C$ 가 최대 singular 값이 '1'이 되도록 결정되면, 수렴 조건을 제어하는 이완 완화 매개 변수가 식 (13)의 조건을 만족하는 경우, 식 (7)의 반복해는 수렴하게 된다.

$$0 < \beta < \frac{2}{(1 - \gamma(n_k))\delta_1 + \alpha_1(x_k) + 2\alpha_2(x_k)\delta_2}$$

$$\text{where } \begin{cases} \delta_1 = \lambda_{\max}(H^T P(x_k)H) \\ \delta_2 = \lambda_{\max}(C^T Q(x_k)C) \end{cases}, \quad (13)$$

#### IV. 정규화 매개 변수 결정

$M_1(x)$  함수와  $M_2(x)$  함수의 상대적 기여도를 결정하는 혼합 norm 정규화 매개 변수는 식 (4)의  $\chi(r)$ 에 의해서 제어되어야 하며,  $\gamma(\infty) \approx 0$ 와  $\gamma(-\infty) \approx 1$  조건을 만족해야만 한다. 그러므로 혼합 norm 정규화 매개 변수는 지수함수를 이용해 식 (14)와 같이 결정될 수 있다. 그림 1에  $c$ 에 따른  $\gamma(\chi(n_k))$ 를 나타내었다.




그림 1.  $\gamma(\chi(n_k))$  그래프

또한  $M_1(x)$  함수와  $M_2(x)$  함수의 완화도를 제어하는  $\alpha_1(x_k)$  및  $\alpha_2(x_k)$ 는 참고문헌 [6]과 [8]에서 사용한 방식과 유사하게 다음과 같이 결정된다.

$$\alpha_1(x_k) = \frac{\|y - Hx_k\|_2^2}{\tau_1 - \|Cx_k\|_2^2} \quad (15)$$

where  $\tau_1 \geq \|y\|_2^2 \approx \|x\|_2^2$

$$\alpha_2(x_k) = \frac{\|y - Hx_k\|_4^4}{\tau_2 - \|Cx_k\|_4^4} \quad (16)$$

where  $\tau_2 \geq \|y\|_4^4 \approx \|x\|_4^4$

#### V. 실험 결과

제안된 방식의 성능을 검증하기 위해  $256 \times 256$  크기의 다양한 영상을 실험하였으며, 다양한 신호 대 잡음비 (SNR)에 대해 실험하였다. 본 논문에는 "Lena" 영상에 대한 실험 결과를 제시하였다. 원영상을  $5 \times 5$  uniform 마스크를 이용해 열화시켰으며, Uniform (sub-Gaussian) 및 Laplacian (super-Gaussian) 분포를 갖는 노이즈를 열화된 영상에 첨가하여 훼손 영상을 생성하였다. 그리고 반복 과정의 종료 조건으로 식 (17)을 사용하였다.

$$\frac{\|x_{k+1} - x_k\|_2^2}{\|x_k\|_2^2} \leq 10^{-7} \quad (17)$$

성능 비교를 위해 신호 대 잡음비 개선 ( $\Delta_{SNR}$ )을 측정하였다.  $k$ 번째 반복을 통한 복원 영상의  $\Delta_{SNR}$ 은 식 (18)과 같이 정의된다.

$$\Delta_{SNR} = 10 \log_{10} \frac{\|y - x\|_2^2}{\|y - x_k\|_2^2} \quad (18)$$

표 1에 객관적 검증을 위해 다양한 노이즈 및 SNR에 대한  $\Delta_{SNR}$  성능 비교를 나타내었다. 제안 방식은 LMS 방식보다 다양한 첨부 노이즈에 대해 우월한 성능을 보였으며, 특히 sub-Gaussian 분포를 갖는 노이즈가 첨부된 경우 성능 향상이 매우 뛰어난 것을 확인할 수 있었다.

그림 2은 10 dB Uniform 노이즈를 열화 영상에 첨가시킨 훼손 영상을 나타내며, 훼손 영상을 LMS 및 제안 방식을 이용하여 복원된 영상을 그림 3 및 4에 나타내었다. 첨부 노이즈가 상대적으로 감소된 반면, 윤곽선 부근이 상대적으로 보존되었음을 알 수 있다.

## VI. 결론

본 논문에서는 다중 정규화 매개 변수를 이용한 혼합 norm 영상 복원 방식에 대해 제안하였다. 가우시안 분포를 갖는 노이즈 이외의 다양한 첨가 노이즈를 효과적으로 처리하기 위해 기존의 LMS 방식에 LMF 방식을 혼합하였다.  $l_2$  norm 기반의 정규화 완화 함수와  $l_4$  norm 기반의 정규화 완화 함수의 상대적 기여도를 제어하는 혼합 norm 정규화 매개 변수를 이용해 정의하였으며, 상기 매개 변수는 매 반복 영상에서 예측된 노이즈 성분의 kurtosis에 의해 결정되었다. 제안 방식은 LMS 방식보다 다양한 첨가 노이즈에 대해 우월한 성능을 보였다. 특히 sub-Gaussian 분포를 갖는 노이즈가 첨가된 경우 성능 향상이 보다 뛰어남을 확인할 수 있었다. 또한 제안 방식은 혼합 norm 정규화 매개 변수 및 다중 정규화 매개 변수를 주어진 영상의 복원 과정에서 유도함으로써 신호의 사전 정보 없이 수행할 수 있는 큰 장점을 갖고 있다.

표 1.  $\Delta_{SNR}$  성능 비교

Noise Type	SNR (dB)	LMS $\Delta_{SNR}$	제안방식 $\Delta_{SNR}$
Uniform	10	3.25	3.89
Uniform	20	2.11	2.71
Uniform	30	3.58	4.01
Laplacian	10	3.17	3.36
Laplacian	20	2.09	2.31
Laplacian	30	3.58	3.67
Gaussian	10	3.19	3.22
Gaussian	20	2.08	2.30
Gaussian	30	3.59	3.72
Combination	10	4.42	4.68
Combination	20	2.05	2.39
Combination	30	3.02	3.34



그림 2. 훼손 영상 (5×5 uniform blur, 10 dB Uniform Noise)



그림 3. LMS 방식을 이용한 그림 1의 복원 영상



그림 4. 제안 방식을 이용한 그림 1의 복원 영상

참고 문헌

- [1] M. R. Banham and A. K. Katsaggelos, "Digital image restoration," *IEEE Signal Processing Magazine*, vol. 14, pp. 24-41, March 1997.
- [2] H. C. Andrews and B. R. Hunt, *Digital Image Restoration*, Prentice-Hall, New York, 1977.
- [3] S. A. Kassam and H. V. Poor, "Robust techniques for signal processing: A survey," *Proc. of IEEE*, vol. 73, pp. 433-481, March 1985.
- [4] E. Walach and B. Widrow, "The least mean fourth adaptive algorithm and its family," *IEEE Trans. on Information Theory*, vol. IT-30, pp. 275-283, March 1984.
- [5] J. A. Chambers, O. Tanrikulu, and A. G. Constantinides, "Least mean mixed-norm adaptive filtering," *Electronics Letters*, vol. 30, pp. 1574-1575, Sept. 1994.
- [6] M.-C. Hong, T. Stathaki, and A. K. Katsaggelos, "Iterative regularized least-mean mixed-norm image restoration," *Optical Engineering*, vol. 41, pp. 2515-2524, Oct. 2002.
- [7] D. G. Luenberger, *Linear and Nonlinear Programming*, Addison-Wesley, 1989.
- [8] M. G. Kang and A. K. Katsaggelos, "General choice of the regularization functional in regularized image restoration," *IEEE Trans. on Image Processing*, vol. 4, pp. 594-602, May 1995.

최 권 열 (Kwon Yul Choi)

준회원



2006년 2월 숭실대학교 정보통신  
전자공학부 졸업 (학사)  
2006년 3월~현재 숭실대학교 정  
보통신공학과 석사과정 재학중  
<주관심분야>  
영상 복원 및 개선, 정지 및 동영상  
상 필터링, 영상 부호화

김 명 진 (Myoung-Jin Kim)

정회원



2002년 2월 한국방송대학교 컴  
퓨터학과 졸업 (학사)  
2005년 2월 한국방송대학교 정  
보학과 졸업 (석사)  
2005년 3월~현재 숭실대학교 정  
보통신공학과 박사과정 재학중  
<주관심분야> 영상통신 및 Rate  
Control, 동영상 부호화, 영상 복원 및 enhancement

홍 민 철 (Min-Cheol Hong)

정회원



1988년 2월 연세대학교 전자공  
학과 졸업 (학사)  
1990년 8월 연세대학교 전자 공  
학과 졸업 (석사)  
1990년 7월~1991년 8월 LG 정  
보통신 연구원  
1997년 9월 Northwestern Univer-  
sity, 전기 및 컴퓨터 공학과 졸업 (박사)  
1997년 9월~1998년 8월 Northwestern University,  
Research Fellow  
1998년 9월~2000년 2월 LG 전자, 선임연구원  
2000년 3월~현재 숭실대학교, 부교수  
<주관심분야> 영상 복원 및 enhancement, 정지 및 동  
영상 필터링, 동영상 부호화, 비선형 필터링, Image  
Deconvolution, Rate Control