

# 신경회로망을 이용한 주파수 모듈화된 deinterlacing

우 동 현\*, 엄 일 규\*\*, 김 유 신\*\*\*

## Frequency Modularized Deinterlacing Using Neural Network

Dong-Hun Woo\*, Il-Kyu Eom\*\*, Yoo-Shin Kim\*\*\*

### 요 약

영상은 일반적으로 에지 영역과 평탄 영역으로 나누어 질 수 있다. 평탄 영역은 대부분 저주파 성분으로 이루어져 있지만, 에지 영역에서는 고주파 성분이 주가 된다. 따라서, 각 영역에 따른 특성을 고려한 deinterlacing 방법이 효율적이라고 할 수 있다. 본 논문에서는 국부 영역의 분산을 사용하여 영상을 에지 영역과 평탄 영역으로 분리하고 분리된 에지 영역과 평탄 영역에 대하여 모듈화된 신경 회로망을 사용한 deinterlacing 방법을 제안한다. 제안 방법에서는 모듈화된 구조로 인해 각 영역의 신경회로망이 유사한 데이터들만을 집중적으로 학습할 수 있고 서로 다른 영역의 데이터들로 인한 학습방해가 적은 장점이 있다. 또한 신경 회로망의 입력으로 국부 평균을 제거한 값을 사용함으로써 화소의 국부 평균 밝기값의 변화로 인한 학습 성능 저하를 방지할 수 있다. 모의 실험에서 제안된 알고리즘은 기존 알고리즘들보다 개선된 성능을 보였다.

key Words : deinterlacing; neural network; modular.

### ABSTRACT

Generally images are classified into two regions: edge and flat region. While low frequency components are popular in the flat region, high frequency components are quite important in the edge region. Therefore, deinterlacing algorithm that considers the characteristic of each region can be more efficient. In this paper, an image is divided into edge region and flat region by the local variance. And then, for each region, frequency modularized neural network is assigned. Using this structure, each modularized neural network can learn only its region intensively and avoid the complexity of learning caused by the data of different region. Using the local AC data for the input of neural network can prevent the degradation of the performance of learning due to the average intensity values of image that disturbs the effective learning. The proposed method shows the improved performance compared with previous algorithms in the simulation.

### I. 서 론

일반적인 TV에서는 시스템의 제약으로 인해 비월주사 방식을 사용한다. 비월주사 방식은 한 프레임의 반씩 번갈아 주사하기 때문에 깜빡임

(flicker) 현상 같은 화질 열화를 야기할 수 있다. 최근에는 순차주사 방식을 사용하는 모니터나 HDTV 등이 보급됨에 따라 비월주사 방식의 영상을 순차주사 방식으로 변환하는 deinterlacing 문제가 중요한 과제로 부각되었다. 다른 관점에서

\* 부산대학교 전자공학과 지능정보처리 연구실(dhwoo@pusan.ac.kr), \*\*밀양대학교 정보통신공학과

\*\*\*부산대학교 컴퓨터 및 정보통신연구소

논문번호 : #030175-0428, 접수일자 : 2003년 4월 28일

불 때 deinterlacing은 일종의 영상 확대, 즉 2차원 보간 문제로 생각할 수 있다. 따라서 deinterlacing은 정지영상과 동영상의 확대 및 super-resolution에도 응용될 수 있으며 영상을 축소해서 전송한 후 송신단에서 축소된 영상을 다시 확대하는 개념으로 동영상 압축 및 전송에도 활용될 수 있다<sup>[5]</sup>.

기존의 deinterlacing 방법들은 크게 움직임 정보(motion information)를 이용하는 방법과 움직임 정보를 이용하지 않은 방법으로 구분할 수 있다. 움직임 정보를 이용하는 방법들은 MPEG 같은 표준 동영상 압축에 쓰이는 움직임 벡터를 사용한다. 즉, 보간할 영역의 위치에 상응하는 이전 필드로부터의 움직임 벡터를 사용하여 현재 필드의 영역을 보간하는 방법이 일반적으로 사용되고 있다. 최근에는 쌍방향에서 움직임 벡터를 찾는 방법<sup>[2]</sup>과, 이전의 N 개의 필드와 이후의 N 개의 필드에서 소수점의 정확도(1/2, 1/4)로 움직임 벡터를 찾는 방법<sup>[3]</sup>이 제안되었다. 이 방법은 움직임 벡터를 정확히 찾는 경우에는 상당히 좋은 성능을 나타내지만 움직임 벡터를 찾는 과정에서 계산량 부담이 크며 움직임을 잘못 찾았을 경우에는 상당한 화질의 열화가 일어난다.

한편, 움직임 정보를 이용하지 않는 방법은 대체로 계산량 부담이 작고 움직임 정보를 이용하는 방법에서 움직임 정보를 잘못 찾았을 경우 야기될 수 있는 심각한 화질의 열화는 없다. 그러나 다른 필드의 정보 없이 하나의 필드에서 기존의 화소들만을 이용해서 보간해야 하므로 뭉뚱화 현상(blurring artifact)을 피하기가 어렵다. 이 방법 중의 대표적인 방법에는 ELA(Edge line based algorithm)<sup>[4]</sup>가 있다. ELA는 간단한 계산량으로 영상의 에지를 잘 살려줄 수 있는 장점이 있다. 최근에는 ELA 개선한 여러 방법들이 제안되었는데 그 중 Lee<sup>[5]</sup>의 논문에서는 ELA를 강한 에지에만 적용함으로써 평탄 영역과 약한 에지에서의 불필요한 적용을 피했다. 그러나 이런 공간 영역 보간 방법들은 주위의 기존 화소들의 가중치 평균에 기반을 두기 때문에 일종의 저대역 통과 필터를 가한 결과를 낳게 되어 고주파 성분을 효과적으로 보간하기가 어렵다.

신경 회로망<sup>[6]</sup>은 인간의 두뇌의 학습을 모델링한 알고리즘으로 패턴 인식, 함수 추정 및 신호 처리 분야 등에 널리 응용되고 있다. 신경 회로망의 장점은 기대되는 출력(desired output)대한 정

보를 활용할 수 있고 구현 방법이 비교적 단순하다는 것이다. 그러나 신경 회로망은 음성이나 영상 같이 복잡한 학습 데이터에 대해서는 학습 과정에서 극부 최소값에 빠지기 쉬운 단점이 있다. 또한 학습 데이터의 크기가 커지고 다양해 질수록 다양한 변화를 담을 용량이 부족해져 성능의 저하가 일어난다. Plaziac<sup>[1]</sup>은 신경회로망을 이용한 deinterlacing 방법을 제안하였다. 이 방법은 보간하고자 하는 화소 주변에 있는 이웃 화소들의 값을 입력으로 하여 추정 화소값과 기대 화소값의 오차를 최소화시키는 MLP(multi-layer perceptron) 신경회로망을 사용하여 우수한 결과를 나타내었다. 그러나 에지, 텍스처, 평탄 영역 등과 영상의 국부적 특성을 반영하고 있지 못한 구조를 가지고 때문에 세밀한 학습에 한계를 가지고 있다.

본 논문에서는 영상의 국부적 주파수 특성에 따라 서로 독립적인 신경회로망 구조를 가지는 모듈화된 신경회로망을 사용한 deinterlacing 방법을 제안한다. 제안 방법에서는 영상을 에지 영역과 평탄 영역으로 분류하고, 분류된 영상에 대하여 각각 하나의 신경 회로망을 할당한다. 각 주파수 영역에 할당된 신경회로망은 주어진 유사한 특성의 영상만을 집중적으로 학습하게 되므로 다양한 형태의 학습 데이터를 하나의 신경 회로망으로 학습할 때보다 효과적으로 학습을 수행할 수 있다. 또한 신경 회로망의 입력을 국부 영역의 평균값을 뺀 나머지 AC 값을 입력으로 사용하여 영상의 밝기값에 관계없이 화소의 상대적 차이만으로 학습이 수행되도록 하였다. 모의 실험 결과에서 제안 알고리즘은 기존의 방법 및 신경회로망을 사용한 방법보다 개선된 PSNR을 보여주고 있다.

본 논문은 다음과 같이 구성되어 있다. 먼저 2장에서 이전의 deinterlacing 방법들을 소개하고 그 장단점을 살펴본다. 3장에서 제안 알고리즘에 대해 설명하며, 4장에서 모의 실험 결과를 보여주고 5장에서 결론을 맺는다.

## II. Deinterlacing 방법의 고찰

### 2.1. ELA<sup>[1]</sup>

ELA(Edge-Line based Algorithm)는 공간 영역에서의 대표적인 deinterlacing 알고리즘으로 주변 화소 정보를 이용하여 보간될 화소의 값을 추

정하는 방법이다. 그림 1은 알고리즘의 개념을 보여 준다. 그림 1에서 a, b, c, d, e는 화살표에 의해 대응되어지는 화소값의 차이를 나타낸다. 이 차이값들 중 가장 작은 차이를 보이는 화소들의 쌍이 선택되고, 그 쌍의 평균을 이용하여 보간될 화소의 값을 추정한다. 이 방법은 구현이 간단하고 영상의 윤곽을 부드럽게 보존한다. 그러나 잡음에 민감하고 평균을 사용하기 때문에 고주파 성분의 손상을 야기한다. 또한 에지가 아닌 평탄 영역과 에지의 방향성이 명확하지 않은 영역에서도 억지로 방향성을 찾아 보간하기 때문에 오히려 화질의 열화가 생기는 경우도 있다. 이를 보완하기 위해 평탄 영역과 방향성이 명확하지 않은 에지를 간단한 판별 알고리즘에 의해 제외된 modified ELA도 제안되었다<sup>(5)</sup>.




그림 1. ELA의 개념  
Figure 2. The interpretation of ELA

2.2. 선형 필터에 의한 방법<sup>(7)</sup>

신호처리의 관점에서 보면 Deinterlacing은 일종의 보간 문제이기 때문에 보간된 영상의 화질은 입력 영상을 up-sampling한 후 적용되는 저대역 통과 필터를 어떻게 설계하느냐가 중요한 문제가 된다. [8] 선형 필터를 이용한 방법은 다음과 같은 선형 필터를 사용하여 deinterlacing을 하는 방법이다.

$$h[n] = \frac{[-6 \quad 38 \quad 1 \quad 38 \quad -6]}{64} \quad (1)$$

선형 필터를 이용한 방법은 일반적으로 사용되는 쌍방향 보간 필터(bilinear interpolation filter)보다 개선된 주파수 특성을 가진다. 특히 고주파 성능이 많은 영상에서 우수한 성능을 보여준다. 그러나 저주파 성분이 많은 영상에서 화질의 열화를 보여주며 블록화 현상을 발생시키는 단점이 있다. 그림 2는 선형 필터와 쌍방향 보간 필터의 주파수 특성을 비교한 그림이다.




그림 2. 선형 필터와 쌍선형 보간필터의 주파수 특성 비교

Figure 2. The comparison of frequency response between bilinear and linear filter

2.3. 미디언 필터에 의한 방법<sup>(4)</sup>

미디언 필터를 이용한 방법은 그림 3과 같이 보간할 화소 주위의 a, b, c, d, e, f 6개의 화소 중 중간값을 가진 화소를 보간될 화소값으로 추정하는 방법이다. 미디언 필터는 수직 에지를 보간하는 데 뛰어난 성능을 보여주고 하드웨어 부담이 작다. 그러나 수직 상세 성분을 보간할 때 화질의 열화가 일어나고 영상의 텍스처 같은 부분에서 왜곡을 일으킨다.




그림 3. 미디언 필터  
Figure 3. The median filter

2.4. 신경 회로망을 이용한 방법

일반적인 MLP 신경회로망은 그림 4와 같은 구조를 가지며 역전파 알고리즘을 사용하여 기대 출력값과 신경회로망의 출력값의 오차를 최소화시키는 방법을 사용하여 패턴 인식이나 함수 추정, 신호 처리 분야 등에서 뛰어난 성능을 보여왔다<sup>(9)(10)</sup>. 그림 4

에서  $\mathbf{x}$ 는 신경 회로망의 입력 벡터이고,  $\mathbf{y}$ 는 출력 벡터이다. 신경 회로망의 가중치(weight)는 다음과 같은 delta 학습 법칙에 의해 학습된다.

$$\Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}}, \quad \Delta v_{ji} = -\eta \frac{\partial E}{\partial v_{ji}} \quad (2)$$

식 (1)에서  $\Delta w_{kj}$ 는 출력층의 가중치 변화량이며,  $\Delta v_{ji}$ 는 은닉층의 가중치 변화량이다. 또,  $E$ 는 모든 훈련 데이터에 대한 에러이며,  $\eta$ 는 학습 계수이다. 식(1)에서와 같이 MLP는 훈련 데이터에 대해 에러를 감소하는 방향으로 가중치를 조절한다<sup>[6]</sup>. 따라서 신경 회로망을 이용한 deinterlacing의 경우 기대 출력(desired output)을 목표로 학습하게 되므로 보간할 화소의 정보를 활용할 수 있다.




그림 4. 역전파 알고리즘을 가지는 MLP  
Figure 4. MLP with back propagation

Plaziac<sup>[11]</sup>은 그림 5에서 보는 바와 같이 30개의 입력 화소와 3개의 출력 화소를 가지는 구조를 사용한 deinterlacing 방법을 제안하였다. 그림 5에서 어두운 부분은 신경회로망의 입력이며, 'X'로 표시된 부분은 출력을 나타낸다. 역전파 알고리즘은 단지 주어진 목표값에 도달하도록 가중치를 학습시키기 때문에 가중치의 값이 음수를 가질 수 있다. 따라서 신경 회로망을 이용한 방법은 에지의 고주파 성분을 잘 보존할 수 있다. 반면에, 대부분의 기존 알고리즘들은 가중치에 양의 값들만을 가지는 가중치 평균 기반이기 때문에 에지에서 뭉롱화 현상을 야기한다. 그러나 신경 회로망은 영상이나 음성 같은 복잡하고 다양한 패턴을 가진 데이터를 학습할 때는 극부 최소값에 빠지기 쉽고 성능의 저하가 발생한다<sup>[6]</sup>. 영상의 경우를 예로 들면, 영상에서는 에지 영역과 평탄 영역의 주파수 특성이 다르므로 하나의 신경 회로망은 상당히 다른 특성을 가지는 두

종류의 데이터를 학습해야 되는 부담이 따른다. 따라서 유사한 데이터만을 학습하는 경우에 비해 보간의 성능이 떨어지게 된다. 학습 데이터의 크기가 크고, 다양성이 클수록 성능의 저하는 더 심해진다.




그림 5. 신경 회로망을 이용한 deinterlacing<sup>[11]</sup>에서 입력과 출력의 구조  
Figure 5. The input and output structure of the deinterlacing method using neural network<sup>[11]</sup>

### III. 영역별 주파수 특성과 신경 회로망에 기반을 둔 deinterlacing

영상에서는 에지 영역과 평탄 영역의 특성 차이에 의해 이러한 현상이 두드러진다. 급격한 변화가 많은 에지 영역은 고주파 성분을 상당 부분 포함하고 있기 때문에 화소 밝기에 급격한 변화들이 많지만, 평탄 영역은 저주파 성분이 대부분이므로 화소의 밝기 변화가 완만하다. 특히 영상과 같이 다양한 패턴을 가지면서 규모가 큰 학습 데이터에 대해서는 신경 회로망의 성능이 저하된다. 본 논문에서는 이러한 문제를 해결하기 위해서 영상을 에지 영역과 평탄 영역으로 분할하고 분할된 영역에 대해 독립적인 신경 회로망을 할당하는 주파수에 모듈화된 신경회로망 구조를 제안한다. 영상의 영역에 대해 모듈화된 신경 회로망은 각 영역에서 유사한 학습 패턴만을 집중적으로 학습하게 되므로 단일 신경 회로망보다 학습을 효율적으로 할 수 있다. 또한 단일 신경 회로망의 경우와는 달리 각 영역의 특성에 알맞은 학습 계수(learning rate)를 선택할 수 있는 장점이 있다.

본 논문에서는 먼저 입력 영상을 식 (3)과 같이 극부 영역의 분산을 사용하여 에지 영역과 평탄 영

역으로 분리한다.

$$\sigma^2[i, j] = \frac{1}{|c_{i,j}|} \sum_{m, n \in c_{i,j}} (x[i+m][j+n] - m[i, j])^2 \quad (3)$$

식(3)에서  $|c_{i,j}|$ 는  $x[i, j]$ 를 중심으로 하는 이웃 화소 수를 나타내고,  $m[i, j]$ 는 국부 평균을 나타낸다. 식 (3)과 같은 국부 분산 값이 문턱값보다 크면 그 화소는 에지 영역으로 분류하고 그렇지 않으면 평탄 영역으로 분류한다. 그림 6은 국부 분산을 사용하여 Lena영상을 에지 영역과 평탄 영역으로 분리한 결과이다. 그림 6에서 에지 영역은 흰 색으로 나타내고 평탄 영역은 검은색으로 표시하였다.




그림 6. 국부분산을 이용한 평탄 영역과 에지 영역의 분리

Figure 6. The separation of edge and flat region using local variance

식(3)에 의해 분리된 영상의 영역에 대하여 본 논문에서는 그림 7과 같은 신경회로망 구조를 사용한다. 즉 에지 영역과 평탄 영역에 대하여 각각 독립적인 하나의 신경회로망이 사용되며, 각 영역별로 독립적으로 학습된다. 또한 본 논문에서는 계산량을 줄이고, 한 번에 입력되는 학습 데이터의 양을 줄이기 위하여 20개의 입력과 1개의 출력을 가지는 구조를 사용한다.

Plaziac<sup>(1)</sup>의 방법과 같이 신경 회로망의 입력으

로 입력 화소의 밝기를 사용할 경우, 같은 AC변화를 보이는 국부 영역이라도 국부 평균값에 따라 다른 데이터로 인식하므로 학습이 효율적이지 못하다. 따라서 제안 방법에서는 식 (4)와 같이 신경 회로망의 입력으로 화소의 밝기에 국부 영역의 평균을 빼 값  $x_i[i, j]$ 를 입력으로 사용한다.

$$x_i[i, j] = x[i, j] - m[i, j] \quad (4)$$

식 (4)와 같이 국부 평균이 제거된 화소값을 입력으로 사용함으로써, 화소의 국부 평균 밝기값에는 영향을 받지 않고, 평균에 대한 상대적인 화소값의 차이를 입력으로 사용하여 학습의 효율을 높일 수 있다.





그림 7. 영상의 국부 주파수 특성에 기반을 둔 모듈화


Figure 7. The modularization based on local frequency characteristic of image

#### IV. 모의 실험 결과

본 논문에서는 객관적인 성능 평가를 위해 제안 알고리즘과 기존 알고리즘들의 PSNR을 비교하였다. 이를 위해 다음과 같은 조건으로 모의 실험을 수행했다. 먼저 신경 회로망의 학습을 위해 tiffany, truck, tank, airplane, aerial, zelda, couple, mandrill, elaine, goldhill, crowd, bridge 의 12개 영상이 사용되었다. 그림 8은 2개의 채널로 모듈화 된 신경 회로망의 학습 오차를 나타내고 있다. 그림 8에서 볼 수 있듯이 평탄 영역에 대해서는 오차가 완만하게 감소함을 볼 수 있고, 주파수가 높은 에지 영역에 대해서는 오차가 유동적인 모습을 볼 수 있다.



(a)



(b)

그림 8. 2채널로 모듈화 된 신경회로망의 에러곡선(AC 입력) (a) 평탄 영역 (b) 에지 영역  
Figure 8. The error curve for neural network modularized by 2 channel(AC input)  
(a) flat region (b) edge region

학습된 신경회로망을 이용하여 lena, babara, boat, peppers, woman, lake, man 등과 같이 7개의 영상을 이용하여 테스트를 수행하였다. 또한 제안 알고리즘과의 성능 비교를 위해 선형 필터, 미디언 필터가 비교를 위해 사용되었다. 표1은 각 영상에 대한 PSNR 결과를 보여준다. 표1에서 제안 방법 SNN은 모듈화되지 않은 단일 신경회로망의 입력과 출력 구조를 간략화한 방법이며, 제안 방법 MNN은 모듈화된 신경회로망을 사용한 경우이다. 표1에서 볼 수 있는 바와 같이 제안 알고리즘 중 단일 신경 회로망을 사용한 경우는 Plaziac의 결과[1]와 비슷한 성능을 보이면서 입력 패턴의 구조가 더 단순하기 때문에 계산량이 절감되는 장점이 있다. 한편, 모듈화 된 신경 회로망은 단일 신경 회로망의 경우나 ELA, 선형 필터,

median 필터에 비해 개선된 PSNR 성능을 보여준다. 특히, 선형 필터의 경우와 비교해 볼 때, 평탄 영역이 많은 peppers, woman 의 영상에는 상당한 성능의 개선을 보여주었으며 선형 필터가 우수한 성능을 보이는 lena, boat, babara같은 복잡한 에지가 많은 영상에서도 PSNR 에서 앞서거나 거의 동등한 성능을 보여주었다. 또한 Plaziac의 논문에서 지적한 바와 같이 신경 회로망을 이용한 방법은 잡음에 강인한 신경 회로망의 특성으로 인해 잡음 환경에서는 ELA, 선형 필터나 median 필터 같은 알고리즘에 비해 성능 개선의 폭이 크다.

주관적인 화질 비교에서 신경회로망에 대한 AC 입력의 경우가 화소값 입력의 경우보다 개선된 화질을 보여준다. 그림 9은 Lena 영상에 대해 AC입력과 화소값 입력의 경우에 대한 화질 비교이다. 그림에서 보는 바와 같이 AC입력의 경우에는 Lena의 모자챙의 긴 에지에서 화소값 입력의 경우보다 매끄럽게 보간하는 것을 볼 수 있다. 그림 10은 선형 필터와 모듈화된 신경회로망을 이용한 방법과의 화질 비교이다. 그림에서 보는 바와 같이 모자챙 부분에서 블러화 현상을 일으키는 선형 필터와는 달리, 제안 방법은 그 부분을 잘 보간하는 것을 확인할 수 있다.

### V. 결론

본 논문에서는 주파수 모듈화된 신경 회로망을 이용한 deinterlacing 방법을 제안하였다. 제안 알고리즘에서는 먼저 주어진 영상에 대해 국부 분산을 이용하여 평탄 영역과 에지 영역으로 나누고 각 영역에 대해 하나의 신경 회로망을 할당하였다. 이를 통해 각 신경 회로망은 유사한 패턴만을 집중적으로 학습하게 되므로 단일 신경 회로망에 비해 효과적으로 학습할 수 있었다. 또한 제안 알고리즘에서는 서로 다른 국부 평균값에 의한 학습의 비효율성을 극복하기 위해 신경회로망의 입력으로 화소의 밝기값에서 국부 평균값을 뺀, 국부 AC값을 신경 회로망의 입력으로 사용했다. 모의 실험에서 제안 알고리즘은 기존의 deinterlacing 알고리즘이나 단일 신경 회로망의 경우보다 개선된 성능을 보여주었다.

표 1. 제안 알고리즘의 PSNR 비교

Table 1. The PSNR comparison of proposed algorithm

Test Image	ELA	Linear	Median	SNN	MNN
Lena	33.59	38.03	36.78	38.28	38.55
Boat	30.70	36.88	33.45	36.77	36.86
Peppers	33.75	33.51	32.73	35.60	36.06
Barbara	24.04	33.44	27.93	32.22	33.20
Woman	40.17	40.74	42.38	42.69	43.20
Lake	28.78	30.92	30.96	31.46	31.63
Man	30.87	33.51	33.07	33.92	34.00




(a) (b)

그림 9. 국부 AC 값에 의한 영상 화질 개선

(a) 국부 AC 입력 (b) 화소값 입력

Figure 9. The image quality improvement by local AC value (a) local AC value as input (b) intensity value as input



(a) (b)

그림 10. 제안 방법과 선형 필터에 의한 방법과의 주관적인 비교 (a) 제안방법 (b) 선형필터에 의한 방법

Figure 10. The subjective quality comparison between proposed algorithm and method using linear filter (a) the proposed algorithm (b) method using linear filter

참고 문헌

[1] Nathalie Plaziac "Image interpolation using neural networks" , *IEEE trans. image processing*, Vol. 8, No. 11, pp. 1647-1651, Nov. 1999.

[2] Y. Y. Jung et. al. "An effective de-interlacing technique using motion compensated interpolation" *IEEE trans. consumer electronics*, Vol. 46, No. 3, pp. 460-466, Aug. 2000.

[3] B. Martins, and S. Forchhammer, "A unified approach to restoration, deinterlacing and resolution enhancement in decoding MPEG-2 video" , *IEEE trans. circuit and systems for video technology*, Vol. 12, No. 9, pp. 803-811, Sep. 2002.

[4] G. D. Haan, and E. B. Bellers, "Deinterlacing - an Overview" , *In Proc. IEEE*, Vol. 86, No. 9, pp. 1839-1857, Sep. 1998.

[5] H. Y. Lee, et. al. "Adaptive scan rate up-conversion system based on human visual characteristics" , *IEEE trans. consumer electronics*, Vol. 46, No. 4, pp. 999-1006, Nov. 2000.

[6] J. M. Zurada, *Introduction to artificial neural system*, PWS Publishing Co., 1995.

[7] ISO/IEC/JTC1/WG11/MPEG93/143,

[8] A. V. Oppenheim, R.W. Schaffer, *Discrete-time signal processing*, Prentice Hall, 1989.

[9] S. W. Lee "Off-line recognition of totally unconstrained handwritten numerals using multilayer cluster neural network," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 18, pp.648-652, June 1996.

[10] Dong-Hun Woo, Charm-Han Ko, Hyun-Min Kang, Yoo-Shin Kim, Hyung-Soon Kim, "Narrowband to

Wideband Conversion of Speech  
Using Modularized Neural Network  
"7th International symposium  
Artificial Life and Robotics, Vol.2,  
pp. 622-625, January.18,2002,  
Beppu, Oita, JAPAN.

우 동 현(Dong-Hun Woo)

정회원



1998년 2월 : 부산대학교 전  
자공학과 졸업  
2000년 2월 : 부산대학교 전  
자공학과 석사  
2000년 3월~현재 : 부산대학  
교 전자공학과  
박사과정

〈주관심분야〉 영상처리, 음성 처리, 신경 회로망


엄 일 규(Il-Kyu Eom)

정회원

한국통신학회논문집 제28권 제8C호 참조

김 유 신(Yoo-Shin Kim)

정회원



1974. 2 서울 대학교  
전자공학과 졸업  
1980. 6 U.C. Berkeley  
전자공학 석사  
1983.6 Stanford Univ.  
전자재료 박사과정  
1995.1 Cornell Univ.  
Ph.D

1974. 3 - 1978. 8 한국원자력 연구소 근무  
2002 현재 부산대학교 전자공학과 교수  
한국과학철학회 부회장, 공학기술학회 공학교  
육연구 논문지 편집이사, 한국 과학사학회 이  
사, 한국통신학회 정보사회연구회 회장

〈주관심분야〉 정보사회론, 과학철학, 영상처리, 인공지능