

의료영상의 질환인식

Recognition of Disease in Medical Image

신승수

(주)시그마정보기술 연구소장

이상복

한국관광대학 교수

조용환

충북대학교 컴퓨터정보통신연구소

중심어 : 특징추출, 신경회로망, 질환인식

요약

본 논문에서는 의료영상에서 특정 장기를 추출하여 질환 부위를 인식하는 알고리즘을 제안한다. 의료영상이 추출되어진 장기 부위에서 질환을 인식하기 위하여 단일 신경회로망을 이용하면 신경회로망의 학습 능력과 일반화 능력이 한정적이므로 성능개선에 많은 문제가 있다. 따라서 추출된 장기로부터 질환부위를 인식하는 것은 신경회로망을 복합적인 방법, 즉 RBF (Radial Basis Function), BP (Back Propagation)로 구성하여 단일 신경회로망의 단점을 극복하였다. 본 논문에서 제안하는 알고리즘은 입력 의료영상의 다양한 형태 변화에 적응력이 뛰어남을 실험결과로 알 수 있었다. 그리고, 전체 알고리즘의 수행시간이 장기추출 알고리즘을 포함하여 일반적으로 10초 이내에 수행됨을 실험 결과 알 수 있었다. 제안된 알고리즘은 실시간으로 의료영상의 질환부위를 인식하여 판별 자동화를 통해 원격의료에 사용되어 질 수 있다.

Seung-Soo Shin

Sigma Information Technology Lab. Manager

Sang-Bock Lee

Professor, Korea Tourism College

Yong-Hwan Cho

RICIC Chungbuk National University

Abstract

In this paper, we suggests a algorithms of recognizing the disease region by extracting particular organ from medical image. This method can extract liver region in spite of input image including many organs and charged format by using multi-threshold of feed-back-structure for segmentation liver region, and suggest the recognition of disease region in extracted liver, using multi-neural network structured by RBF and BP, overcoming the defect of single-neural network. The algorithm in this paper is proficient in adaptation for a multi form change of input medical image. This algorithm can be used at tele-medicine through automatic recognition after recognizing of the disease region by real-time medical image.

I. 서론

의료영상에서 특정 장기를 추출하여 질환부위를 인식하는 방안은 판독 자동화를 위한 방법으로 연구되어지고 있으며, 향후 원격의료에서 필수적인 과제이다[1],[2]. 이전의 연구들을 살펴보면 크게 의료영상에서 특정 장기부위를 추출하는 수준에 머무르고 있으며 추출된 장기영역에서 질환을 인식하는 방법은 연구가 미미한 실정이다[3]. 의료영상에서 장기부위를 추출하는 방법에는 전처리에 의한 방법[1],[2]과, 전처리를 하지 않고 추출하는 방법[1],[2]으로 나누어지며, 의료영상에서 특정 장기를 추출 후 질환을 인식하는 방법에는 신경회로망을 이용한 방법, 통계학적인 방법, 구문론적 방법으로 나누어지고 있다. 의료영상의 추출되어진 장기 부위에서

질환을 인식하기 위하여 단일 신경회로망을 이용하면 신경회로망의 학습 능력과 일반화 능력이 한정적이므로 성능개선에 많은 문제가 있다. 따라서 본 논문에서는 신경회로망을 복합적인 방법, 즉 RBF(Radial Basis Function), BP(Back Propagation)로 구성하여 단일 신경회로망의 단점을 극복하고자 한다. 이러한 방법은 단일 신경회로망보다 일반화 능력과 인식률의 측면에서 뛰어난 실험 결과를 얻을 수 있었다.

II. 의료영상의 특징

본 연구를 위해 전문의에 의해 선별된 의료영상은 그림 1과 같다. 그림 1(a)는 위 영상으로 화살표로 표시한 부위가

암 조직에 의하여 함몰되어 있다[5]. 그림 1(b)는 가슴을 단순 촬영한 영상으로 화살표로 표시한 부분이 폐 질환으로 인하여 다른 부위보다 희게 나타난다[6]. 그림 1(c)는 CT영상으로서 간 부위에 화살표로 표시된 부분이 간질환으로 인해 간 조직의 켈사가 나타나고 안쪽에 석회화가 이루어져 있다[7]. 그림 1(d)는 복부 초음파 영상이다. 둥글게 보이는 부분이 신장이며 신장 질환으로 인하여 초음파가 통과하지 못해 영상의 아래 부분이 희게 나타나 있다[8]. 그림 1(e)는 뇌 혈관 조영영상으로 화살표로 표시한 부위에 혈액이 출혈되고 있는 것을 나타낸다[8].

의료 영상은 그림 1과 같이 인체의 장기 부위가 영상 전체에 분포하고 있으며 배경 부분과 장기 부분으로 크게 구분된다.

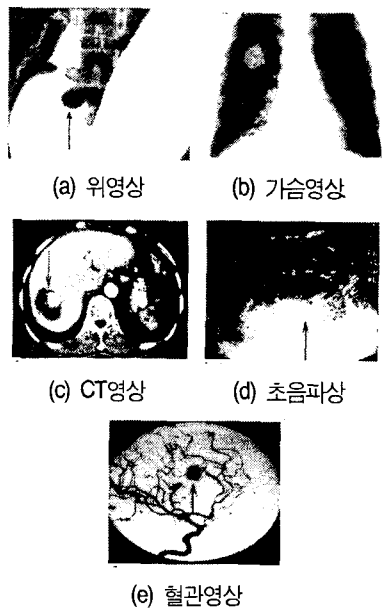


그림 1. 전문의에 의해 선별된 의료영상

III. 의료영상의 특징 추출

1. 웨이브렛 변환에 의한 의료영상의 특징 추출

디지털 신호처리 과정은 연속적인 신호를 일정한 간격으로 샘플링하고 양자화하여 디지털 신호로 변환한 후 컴퓨터 처리를 한다. 디지털 신호는 원 신호의 특징을 손실 없이 변환하기 위해서 높은 샘플링 주파수와 양자화 레벨이 요구된다. 샘플링 과정에서 신호의 특성에 따라 입력 신호변화가 급격한 부분은 간격을 조밀하게 샘플링하고 완만한 부분은 간격

을 크게 하여 샘플링하는 것이 효율적이다. 이와 같은 샘플링 방법은 시간영역에서는 불가능하지만 신호를 푸리에 변환(Fourier Transform)한 후 웨이브렛 변환을 하면 가능하다. 웨이브렛 변환을 이용하면 고정 크기의 창 함수를 이용하는 단구간 푸리에 변환(STFT : Short Time Fourier Transform)보다 저주파영역에서 효과적으로 신호의 특성을 추출할 수 있다.

1.1. 웨이브렛 변환의 분해와 합성

푸리에 변환은 변환 구간이 $-\infty$ 에서 $+\infty$ 이기 때문에 넓은 영역에서 주파수 정보의 추출이 가능하지만 신호의 국부적인 주파수에 대한 특성을 추출하는 데는 효율적이지 못하다. 따라서, STFT가 필요하며 STFT는 식 (1)과 같이 정의된다.

$$Sf(\omega, \tau) = \int_{-\infty}^{\infty} f(x) \omega(x - \tau) e^{-j\omega x} dx \quad (1)$$

$$= \int_{-\infty}^x f(x) \omega(x - \tau) e^{-j\omega x} dx$$

식 (1)에서 ω 는 가우시안 창 함수(Window function)이며, $\omega e^{-j\omega x}$ 는 대역 통과 특성을 갖는다. 따라서, STFT는 신호를 창 함수에 의해 일정 간격의 주파수 대역으로 분해하는 것으로 신호 특성에 관계없이 고정 크기의 창 함수를 사용하므로 시간 해상도 및 주파수 해상도가 일정하다. STFT에서 창 함수 ω 의 시간축 너비 Δx 와 주파수 대역폭 Δf 사이에는 다음 식 (2)와 같은 관계가 있다.

$$\Delta x \times \Delta f \geq \frac{1}{4\pi} \quad (2)$$

웨이브렛 변환은 이러한 STFT의 고정 해상도의 단점을 해결하기 위하여 시간-주파수 평면에서 고주파 대역은 짧은 윈도우(Short window)를 적용하여 시간 해상도를 높이고 저주파 대역에서는 긴 윈도우(Long window)를 적용하여 주파수 해상도를 높일 수 있다. Ingrid Daubechies와 Stephane Mallat 등에 의해 발표된 웨이브렛 변환은 푸리에 변환과 같이 기저 함수들의 집합으로 신호를 분해하는 방법이다. 그러나, 푸리에 변환과 달리 국부적으로 에너지가 집중된 대역 통과 신호인 웨이브렛들을 기저 함수로 사용한다. 이러한 웨이브렛들은 모 웨이브렛(Mother wavelet)이라 불리는 하나의 원형 웨이브렛(Prototype wavelet)을 확장하고 이동시켜 얻을 수 있다. 웨

이브렛 변환에서는 확장된 신호의 주파수를 언급하는 것보다 몇 배로 확장했는가 하는 확장인자를 언급하며 이 인자를 스케일(Scale)이라 부른다. 이때, 스케일의 값으로는 2^j 의 배수가 주로 사용된다. 스케일이 증가할수록 주어진 스케일에서 웨이브렛 변환 신호의 공간 해상도는 떨어지고 낮은 주파수 대역 성분을 나타내게 된다. 웨이브렛 변환은 원형 웨이브렛인 $\psi(x)$ 를 신축/병진(Dilation/Translation)하여 구하며 식 (3)과 같다.

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \quad (3)$$

여기서, a 는 스케일링 계수이고, b 는 병진 계수이다. 그리고, $a^{1/2}$ 는 정규화 인자(Normalization factor)이며, $a < 1$ 이면 시간축의 폭이 작은 고주파 웨이브렛이고 $a > 1$ 이면 폭이 큰 저주파 웨이브렛이다. 웨이브렛의 형태는 제한한 사람에 따라 형태가 다양하며 각각의 웨이브렛의 특성과 장점에 따라서 응용 분야가 다르다.

최근 여러 응용 분야에서 그 특성으로 인해 널리 이용되는 것으로 Daubechies 웨이브렛이 있다. 그림 2는 Daubechies 웨이브렛의 기본 원형을 나타낸다.


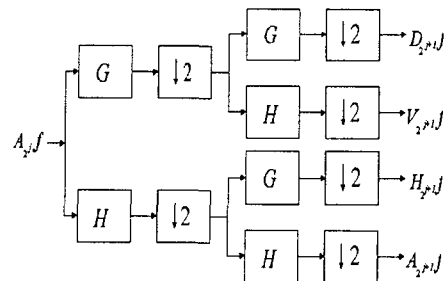


그림 2. Daubechies 웨이브렛의 기본 원형


정규직교기저(Orthonormal basis)로 분해된 2차원 신호는 식 (4)와 같이 공간적으로 방향성을 지닌 주파수 성분으로 분해된다.

$$\begin{aligned} A_{2^j,1}f &= \sum_k \sum_l h(2m-k) h(2n-l) A_{2^j}f \\ H_{2^j,1}f &= \sum_k \sum_l h(2m-k) g(2n-l) A_{2^j}f \\ V_{2^j,1}f &= \sum_k \sum_l g(2m-k) h(2n-l) A_{2^j}f \\ D_{2^j,1}f &= \sum_k \sum_l g(2m-k) g(2n-l) A_{2^j}f \end{aligned} \quad (4)$$


식 (4)에서 h 는 분해 저역 통과 필터의 전달 함수이고, g 는 분해 고역 통과 필터의 전달 함수이다. 그림 3은 DWT에 의한 2차원 신호의 분해 및 합성을 나타내었으며, 그림 3(a)는 2차원 이상 근사화 신호의 분해 과정이며 그림 3(b)는 합성 과정의 블록도이다. 그림 3(c)는 다해상도로 분해된 2차원 신호의 계수 행렬을 나타낸다. 즉, 공간적으로 방향성을 지닌 주파수 성분의 패킷(Packet)들로서 2레벨 분해된 계수 행렬이며 그림 3(c)에서 VH1은 1레벨 분해된 수직 고주파 성분들의 계수 행렬을 의미하고 HH1 및 DH1은 각각 수평 고주파 성분과 대각 고주파 성분의 계수 행렬을 의미한다. 또한, L2는 2레벨 분해된 저주파 성분의 계수 행렬을 의미한다.



(a) 분해



(b) 합성



(c) DWT 계수 매트릭스

그림 3. DWT에 의한 2차원 신호의 분해 및 합성

식 (4)에 의한 웨이블릿 분해 알고리즘은 표 1과 같다.

표 1. Matlab에 의한 DWT 알고리즘

```
int i,n;
LO = Input Image;
for(i=1;i<n;i++){
  [Li,HHi,VHi,DHi]=DWT2(Li-1,'db2');
  printf Li;
  printf HHi;
  printf VHi;
  printf DHi;
}
```

표 1은 매트랩(Matlab)에 의한 DWT 알고리즘을 나타내었으며, 표 1의 알고리즘에 의해 웨이블릿 분해를 한 후 각 레벨(Level)별 특징 파라미터를 분석하여 최적의 값을 찾아낸다.

1.2. 특성 다항식의 계수 추출

웨이블릿 변환에서 얻어진 저주파영역, 수평 고주파영역, 수직 고주파영역, 대각 고주파영역 중에서 의료영상의 특성상 특징이 저주파영역에 많이 남아 있다. $n \times n$ 저주파영역의 계수행렬을 다항식으로 표현하면 식 (5)와 같다.

$$f(A)x = (a_0A^n + a_1A^{n-1} + \dots + a_{n-1}A + a_nE)x = (a_0\lambda^n + a_1\lambda^{n-1} + \dots + a_{n-1}\lambda + a_n)x \quad (5)$$

그러므로 식 (6)과 같이 정의된다.

$$f(A)x = f(\lambda)x, \quad x \neq 0 \quad (6)$$

식 (6)은 $f(\lambda)$ 가 행렬 $f(A)$ 의 고유값임을 나타내고 있다. 따라서 표 1의 알고리즘으로 웨이블릿 변환하여 얻어진 저주파영역의 $n \times n$ 행렬에서 특성 다항식을 구하여 계수값을 표 2의 계수값을 구하는 알고리즘을 이용하여 계수값을 구하면 $(n+1)$ 개의 계수를 구할 수 있다. 구해진 $(n+1)$ 개의 계수값을 특징 파라미터로하여 정규화시킨 후 신경회로망의 입력 벡터로 이용한다.

표 2. 계수값을 구하는 알고리즘

```
Input low frequency matrix(A) after 4-level DWT;
Polynomial(A);
z(j)=eigenvalue(A);
c(0,0)=1;
for(j=0;j<n;j++){
  c(1,j+1)=c(1,j+1)-z(j)*c(0,j);
}
```

2. 신경회로망에 의한 질환부위 인식

패턴 인식을 위한 대표적인 방법들은 원형 정합법, 통계적 방법, 구문론적 방법, 신경회로망을 이용한 패턴 인식이 있다. 신경회로망을 이용하여 패턴 인식을 할 경우 다른 패턴 인식 방법에 비해 다음과 같은 장점이 있다. 첫째, 구조적으로 병렬성을 내재하고 있기 때문에 신경회로망의 병렬처리 능력을 이용하여 신속한 처리가 가능하다. 둘째, 입력하는 패턴이 미리 학습된 패턴에 비해 약간 손상된 형태일지라도 잘 인식해 낼 수 있는 결함 허용 능력을 가지고 있다. 셋째, 학습되지 않은 새로운 입력 패턴에 대해서도 가장 유사한 부류의 패턴을 찾아낼 수 있는 적응능력이 있다.

그러므로 영상의 잡음이나 왜곡, 크기의 다양성, 위치의 변화 등에 유연하게 적응하며 의료영상의 질환부위를 자동으로 인식할 수 있다.

의료영상에서 질환부위를 인식하는 연구는 1970년대 후반

CT가 임상에 사용되어 의료영상이 디지털화되면서 관심을 가지게 된 분야로서 아직까지 의료영상의 질환부위가 가지고 있는 형태 및 검사 부위의 다양성 때문에 뚜렷한 성과가 없는 분야이다. 최근에는 디지털화 된 의료영상에서 검사 부위 별로 분할하는 연구 논문들이 주종을 이루고 있고, 간혹 질환 부위 인식에 관한 연구 논문에서도 검사 목적 부위를 인식하는 수준에 머무르고 있다.

IV. 신경회로망의 구성

1. Hamming Distance를 이용한 분류 방식

대부분의 패턴 분류기는 각 패턴의 특징에 대한 고려 없이 적용되어지고 있다. 본 논문에서는 가로, 세로, 좌측 대각 방향, 우측 대각 방향 값의 분포를 각 패턴의 특징으로 정의하였고 각 패턴에 대하여 Hamming distance를 이용해 가장 근접한 패턴을 찾아내는 방식으로 하였다.

2. RBF(Radial Basis Function)

RBF네트워크는 빠른 학습속도, 일반화, 단순화의 특징으로 데이터 분류, 비선형 시스템 모델링 등에 적용되고 있으며, 일반적인 BP와 같은 다층 퍼셉트론이 잘 수행하지 못하는 복잡한 형태의 데이터를 분류하는데 사용되고 있다[11],[12],[13].

신경회로망의 관점에서 RBF 네트워크는 그림 4와 같이 3개의 층으로 구성된 전방향신경회로망 (Three layer feed forward network) 형태를 갖추고 있다. 이런 구조적 형태의 특징으로 각 계층이 개별적인 순서를 결정하기 때문에 학습 속도가 다층 퍼셉트론보다 빠른 특징을 가지고 있다[14],[15].




그림 4. RBF 네트워크의 구조

입력층과 출력층간에 있는 은닉층은 클러스터링하는 역할을 수행하게 된다. 은닉층의 목적은 주어진 자료 집합을 유사한 클러스터들(Homogenous clusters)로 분류하는 것이다. 여기서 유사하다는 것은 입력 데이터들에 대한 특징 벡터 공간 사이에서 한 클러스터내의 벡터들간의 거리를 측정하여 정해진 반경내에 존재하면 같은 클러스터로 속하고, 아니면 다른 클러스터에 속하게 하는 것이다. 그러나, 정해진 반경 내에서 클러스터링하는 것은 잘못된 클러스터를 선택하는 단점을 가지게 된다. 그러므로 은닉층을 결정하는 것은 RBF 네트워크의 전반적인 효율성에 큰 영향을 준다. 본 논문에서는 ART2를 적용함으로써 보다 정확한 클러스터링을 수행하도록 한다. ART2의 구조는 그림 5와 같다.

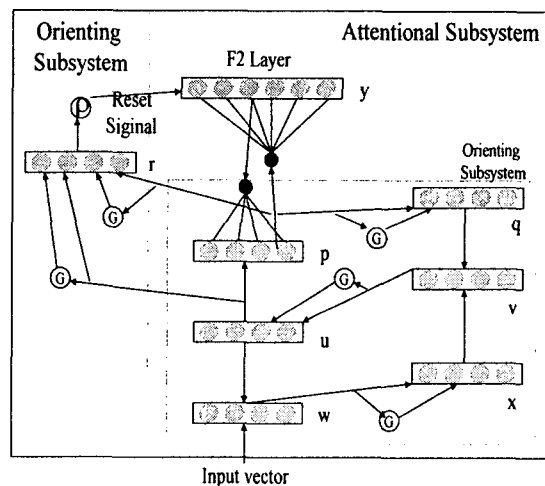


그림 5. ART2의 구조

3. Back-propagation Network

지도학습 모델중의 하나인 오류 역전파(Back-propagation) 학습 알고리즘은 다층 퍼셉트론 구조로 비선형 판별 문제를 해결할 수 있어 많은 분야에 응용되고 있다. 이 알고리즘의 기본 원리는, 입력층의 각 유니트에 입력패턴을 주면, 이 신호는 각 유니트에서 변환되어 은닉층에 전달되고 최후에 출력층에서 신호를 출력하게 된다. 이 출력값과 기대값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결 강도를 조정해 나간다.

V. 실험 및 고찰

실험에서 사용한 영상은 전문의 조언에 의하여 선별된 복부 CT영상을 입력 영상으로 하였고, Pentium-700MHz와 Visual C++언어 및 Matlab을 이용하여 알고리즘을 구현했다. 사용되는 영상은 256×256으로 8bit Grayscale을 사용하였다.

대부분의 입력 복부 CT영상은 해상도가 높고 배경부분과 장기 부분의 구분이 뚜렷하여 추출이 용이하였으나 다른 입력 의료영상에서는 장기 부위의 추출이 쉽지 않았다. 실험중 이러한 부분의 문제는 입력 의료영상이 훼손되어 장기와 배경사이의 구분이 모호하여 실험에서 오차를 발생하고 있었다. 이러한 문제는 이미 추출되어진 장기의 위치로 추출되어지지 않은 장기의 위치를 예측하여 추출할 수 있으나 추출 후에도 이러한 장기의 훼손정도에 의하여 질환부위 인식 과정 중 오 인식이 발생되어 짐을 알 수 있었다. 이러한 문제의 해결은 입력 의료영상에서 장기와 배경 그리고 노이즈간의 훼손정도의 차이를 줄일 수 있는 영상처리 알고리즘 개발이 필요할 것으로 생각되어진다.

인식 과정에서는 각 인식기에서 인식된 결과를 이용하여 후처리 과정을 거치게 된다. 후처리 과정에서는 각 장기 인식 결과에 대하여 카운트하게 되고 가장 높은 카운트를 인식 결과로 채택하였다. 실시간으로 처리된 켈사가 있는 입력 복부 CT영상에 대한 인식결과가 그림 6에 나타나 있다.

표 3과 같이 간장 부위의 질환에 의하여 켈사가 있는 부위의 질환인식은 92.7%의 인식율을 보였고, 간 질환에 의하여 간 경화가 있는 질환의 인식율은 91.4%, 그리고 질환에 의하여 형태가 변형된 질환의 경우는 93.2%의 인식율을 보였다.




그림 6. 인식결과

표 3. 복부 CT영상에서 질환부위 인식의 결과

	입력 영상수	인식율
질환부위 켈사	16	92.7%
질환부위 경화	12	91.4%
질환부위 변형	6	93.2%

VI. 결론

본 논문에서 제안하는 알고리즘은 실시간으로 의료영상의 질환부위를 인식하여 판별 자동화를 통해 원격의료에 사용되어 질 수 있다. 제안된 알고리즘은 입력 의료영상의 다양한 형태 변화에 적응력이 뛰어난 실험결과로 알 수 있었다. 그리고, 전체 알고리즘의 수행시간이 장기추출 알고리즘을 포함하여 일반적으로 10초 이내에 수행됨을 실험결과 알 수 있었다.

앞으로의 연구과제는 입력 의료영상의 장기위치 변화가 심한 경우의 장기추출 알고리즘의 개발과 질환부위 인식에서 후처리 알고리즘을 개선시켜야하겠고, 실제 임상에서 시스템을 구축하여 성능 평가를 계속하여야 하겠다.

참 고 문 헌

- [1] 이상복, 의료영상의 질환부위 인식과 차등입축에 관한 연구, 청주대학교박사학위논문, 1999.
- [2] 이상복, 이주신, "Wavelet 변환과 신경회로망에 의한 위장 영상의 질환부위 패턴인식 알고리즘," 대한전자공학회논문지, Vol.36S, No.5, pp.70-77, 1999.
- [3] Seung-Wha Yoo, Yung-Chang Sung, Jun-Sik Cho, Seung-Mu Noh, Kyung-Suk Shin, Jong-Won Park, "Segmentation of Liver and Spleen by using Lattice Estimation System in Abdominal CT Image," ITC-CSCC'99, pp.991-994, 1999.
- [4] 이상복, 이주신, "의료영상의 특징추출 알고리즘에 관한 연구," 한국통신학회 1998-11T, 1998.
- [5] 원영진 외, "위장관계 평활 근육종의 간 전이에 대한 경동

맥 화학 색전증에 관한 연구," 대한방사선의학회지, 제 37권, pp.605-609, 1997.

[6] Heon Lee, M.D., "Leiomyoma of the Trachea, A Case Report," J. of Korean Radiologist Soc., Vol.37, pp.1067-1069, 1997.

[7] In-Hee Lee, et al, "Comparison of Various Needles in Renal Biopsy," J. of Korean Radiologist Soc., Vol.38, pp.511-516, 1988.

[8] 이지영 외, "폐혈성 뇌색전증의 방사선학적 소견," 대한방사선의학회지, 제 38권, pp.15-20, 1998.

[9] 육창근, 양황규, 강명호, 차의영, "Fuzzy C-Means 알고리즘을 이용한 개선된 RBF 네트워크에 대한 연구," 한국정보처리학회 추계학술발표논문집, 제 4권, 제 3호, 1997.

[10] Youmin Ahang, X. Rong Li, Zhiwei Zhu, "A New Clustering and Training Method for Radial Basis Function Networks," ICNN, No.1, pp.311-315,

[11] 황영섭, 방승양, "RBF 신경망 분류기의 효율적 구성 방법," 한국정보과학회, Vol.21, No.5, pp.451-460, 1997.

[12] Yann le Cun "Generalization and Network Design Strategies," Connectionism in Perspective, pp.143-155, 1989.

[13] R. Hecht-Nielsen, "Theory of Back-propagation Neural Network," IJCNN, Vol.1, pp.593-605, 1989.

[14] 이성환, 패턴인식의 원리 I, II권, 홍릉과학출판사, 1997.

신승수(Seung-Soo Shin)

종신회원



2001년 2월 충북대학교 대학원
(이학박사)

현재 (주)시그마정보기술 연구소장
<관심분야> : 이미지프로세싱, 의료정보,
영상통신, ATM, 트래픽공학

이상복(Sang-Bock Lee)

종신회원



1987년 2월 한밭대학교 전자계산학과
(공학사)

1994년 2월 청주대학교 대학원
전자계산학과(공학석사)

2000년 2월 청주대학교 대학원
전자공학과(공학박사)

1995년 3월 ~ 2001년 2월 대원과학대학 컴퓨터정보처리과
조교수

2001년 3월 ~ 현재 한국관광대학 디지털콘텐츠과 조교수
<관심분야> : 이미지프로세싱, 의료정보, 영상통신, 신경망

조용환(Yong-Hwan Cho)

종신회원



1989년 2월 고려대학교 대학원
(이학박사)

1982년 3월 ~ 현재 충북대학교
전기전자및컴퓨터공학부 교수

현재 (사)한국콘텐츠학회 회장

<관심분야> : 무선인터넷, 멀티미디어통신, 트래픽공학, ATM,
정보통신정책