

## 신경회로망에 의한 의료영상 질환인식

이준행\*, 이흥만\* 김태식\*\*, 이상복\*

남부대학교 방사선학과\*, 한국국제대학교 제약공학부\*\*

### Disease Recognition on Medical Images Using Neural Network

Junhaeng Lee\*, Heungman Lee\*, Taesik Kim\*\*, Sangbock Lee\*

Dept. of Radiology Nambu University\*, School of Pharmaceutical Engineering\*\*

#### 요 약

본 논문에서는 신경회로망을 이용한 의료영상의 질환부위 인식방법을 제안하였다. 질환부위 인식을 위한 신경회로망은 입력층, 은닉층, 출력층으로 구성하여 적응 오차 역전파 알고리즘으로 학습하였다. 신경회로망에 입력된 의료영상의 특징 파라미터는 웨이브릿 변환에 의하여 분해된 저주파 영역을 행렬식으로 표현하여 특성 다항식의 계수값  $(n+1)$ 개로 하였다. 추출된 특징 파라미터는 탄젠트시그모이드 전달함수의 범위로 정규화하여 신경회로망의 입력 벡터로 이용하였다.

제안된 방법의 타당성을 입증하기 위해서 실험에 사용된 입력 의료영상을 가지고 모사실험을 통해 질환부위의 인식률을 평가하였다.

실험 결과 4레벨 DWT로 변환된 저주파영역 행렬의 특성 다항식 계수를 탄젠트시그모이드 전달함수의 범위로 정규화하여 신경회로망의 입력 벡터로 이용했을 때 최적의 학습 횟수를 보였다. 신경회로망의 학습은 적응 오차 역전파 알고리즘을 사용하였고, 학습계수를 0.01, 모우멘텀을 0.95로 하였을 때, 위영상에 대해서는 55회, 가슴영상은 55회, CT 영상은 46회, 초음파영상은 55회 그리고 혈관영상에 대해서는 157회 등의 최적의 학습 횟수를 보이며 100%의 인식률을 보였다.

**Key ward :** Medical Image, Neural Network, Image Recognition, Wavelet

#### Abstract

In this paper has proposed to the recognition of the disease on medical images using neural network. The neural network is constructed as three-layers of the input-layer, the hidden-layer and the output-layer. The training method applied for the recognition of disease region is adaptive error back-propagation.

The low-frequency region analyzed by DWT are expressed by matrix. The coefficient-values of the characteristic polynomial applied are  $n+1$ . The normalized maximum value  $+1$  and minimum value  $-1$  in the range of tangent-sigmoid transfer function are applied to be use as the input vector of the neural network.

To prove the validity of the proposed methods used in the experiment with a simulation experiment, the

input medical image recognition rate the evaluation of areas of disease.

As a result of the experiment, the characteristic polynomial coefficient of low-frequency area matrix, conversed to 4 level DWT, was proved to be optimum to be applied to the feature parameter. As for the number of training, it was marked fewest in 0.01 of learning coefficient and 0.95 of momentum, when the adaptive error back-propagation was learned by inputting standardized feature parameter into organized neural network.

As to the training result when the learning coefficient was 0.01, and momentum was 0.95, it was 100% recognized in fifty-five times of the stomach image, fifty-five times of the chest image, forty-six times of the CT image, fifty-five times of ultrasonogram, and one hundred fifty-seven times of angiogram.

## I. 서론

과학기술의 발달로 최근의 의료영상은 빠르게 디지털 영상으로 바뀌고 있다. 병원의 영상의학과에서 생성되는 의료영상은 DR(Digital Radiography), CR(Computed Radiography) 장비들에 의하여 디지털 영상으로 바뀌고 있으며, CT(Computed Tomograph-y), PET(Positron Emission Tomography), SPECT(Sing-le Positron Emission Computed Tomography), Ultras-onography장비들을 통하여 디지털 의료영상을 생성하고 있다. 이렇게 생성된 디지털 의료영상은 컴퓨터에 저장되어 관리되고 있다.

현재 사용 중인 의료 정보시스템을 크게 분류하면, 환자와 관련된 정보를 관리하는 HIS(Hospital -Information System)와 방사선과에서 취급하고 있는 의료영상들을 관리하는 RIS(Radiology Information -System), 그리고 의료영상 데이터를 수집하고 저장하여 전송하는 PACS(Picture Achieving & Communi-cation System) 등으로 나눌 수 있다<sup>[1]</sup>.

PACS는 빠른 네트워크로 연결된 컴퓨터 시스템을 통하여 여러 장소에서 동시에 같은 영상을 받아 볼 수 있으며, 의료영상을 다른 병원으로 신속히 전송할 수 있어서 종합 병원과 개인 병원간의 협력 체계를 통해서 전문의사의 정확한 진단을 가능할 수 있게 한다. 현재 사용 중에 있는 PACS는 영상 획득 시스템, 영상 저장 및 데이터베이스, 통신 네트워크, 영상 디스플레이 시스템 등으로 구성되어 있다<sup>[2]</sup>.

의료영상이 디지털영상으로 바뀌면서 종래에는 할 수 없었던 영상의 화질개선, 기하학적인 변환, 영상의 특징 부각, 영상 압축과 복원을 자유롭게 할 수 있게 되었고 최근에는 영상인식 알고리즘을 통한 CAD(Computed Aided Diagnosis)에 관한 관심과 연구가 활발하게 이루어지고 있다. 본 논문에서는 신경회로망의 학습에 의해 의료영상의 질환부위를 인식 방법을 제안하고자 한다.

## II. DWT에 의한 특징추출

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 양자화레벨이 요구된다. 샘플링과정에서 신호의 특성에 따라 입력 신호변화가 급격한 부분은 간격을 조밀하게 샘플링하고 완만한 부분은 간격을 크게 하여 샘플링하는 것이 효율적이다. 이와 같은 샘플링 방법은 시간영역에서는 불가능하지만 신호를 푸리에 변환(Fourier Transform)한 후 웨이브릿 변환을 하면 가능하다.

웨이브릿 변환을 이용하면 고정 크기의 창 함수를 이용하는 단구간 푸리에 변환(STFT : Short Time Fourier Transform)보다 저주파영역에서 효과적으로 신호의 특성을 추출할 수 있다<sup>[3][4][5]</sup>.

### 1. Wavelet Transform

Ingrid Daubechies와 Stephane Mallat 등에 의해 발표된 웨이브릿 변환은 푸리에 변환과 같이 기저 함수들의 집합으로 신호를 분해하는 방법이다<sup>[3]</sup>. 그러나 푸리에 변환과 달리 국부적으로 에너지가 집중된 대역 통과 신호인 웨이브릿들을 기저 함수로 사용한다. 이러한 웨이브릿들은 모 웨이브릿(Mother wavelet)이라 불리는 하나의 원형 웨이브릿(Prototype wavelet)을 확장하고 이동시켜 얻을 수 있다. 웨이브릿 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<sup>[7]</sup>. 스케일이 증가할수록 주어진 스케일에서 웨이브릿 변환 신호의 공간 해상도는 떨어지고 낮은 주파수 대역 성분을 나타내게 된다<sup>[7]</sup>. 웨이브릿 변환은 원형 웨이브릿인  $\psi(x)$ 를 신축/병진(Dilation/Translation)하여 구하며 식 (1)과 같다<sup>[5]</sup>.

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

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 웨이브릿이고  $a > 1$ 이면 폭이 큰 저주파 웨이브릿이다. 웨이브릿의 형태는 제안한 사람에 따라 형태가 다양하며 각각의 웨이브릿의 특성과 장점에 따라서 응용 분야가 다르다<sup>[7]</sup>. 최근 여러 응용 분야에서 그 특성으로 인해 널리 이용되는 것으로 Daubechies 웨이브릿이 있다. 그림 1은 Daubechies 웨이브릿의 기본 원형을 나타낸다.





그림 1. Daubechies 웨이브릿의 기본 원형


정규 직교 기저(Orthonormal basis)로 분해된 2차원 신호는 식 (2)와 같이 공간적으로 방향성을 지닌 주파수 성분으로 분해된다<sup>[7]</sup>.

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


식 (2)에서  $h$ 는 분해 저역 통과 필터의 전달 함수이고  $g$ 는 분해 고역 통과 필터의 전달 함수이다. 그림 2는 DWT에 의한 2차원 신호의 분해 및 합성을 나타내었으며, 그림 2 (a)는 2차원 이산 근사화 신호의 분해 과정이며 그림 2 (b)는 합성 과정의 블록도이다. 그림 2 (c)는 다해상도로 분해된 2차원 신호의 계수 행렬을 나타낸다. 즉, 공간적으로 방향성을 지닌 주파수 성분의 패킷(Packet)들로서 2레벨 분해된 계수 행렬이며 그림 2 (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) 분해그림



(b) 합성



(c) DWT 계수 매트릭스

그림 2. DWT에 의한 2차원 신호의 분해 및 합성

식 (2)에 의한 웨이브릿 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 웨이브릿 분해를 한 후 각 레벨(Level)별 특징 파라미터를 분석하여 최적의 값을 찾아 낸다.

2. 특성 다항식의 계수 추출

웨이브릿 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 (3)과 같다.

$$\begin{aligned}
 f(A)x &= (a_0A^n + a_1A^{n-1} + \dots + a_{n-1}A + a_nE)x \\
 &= (a_0\lambda^n + a_1\lambda^{n-1} + \dots + a_{n-1}\lambda + a_n)x
 \end{aligned}
 \tag{3}$$

그러므로 식 (4)와 같이 정의된다.

$$f(A)x = f(\lambda)x, x \neq 0
 \tag{4}$$

식 (4)은  $f(\lambda)$ 가 행렬  $f(A)$ 의 고유값임을 나타내고 있다. 따라서 표 1의 알고리즘으로 웨이브릿 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 정규화 시킨 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);
}
    
```

### III. 신경회로망에 의한 질환부위 인식

패턴 인식을 위한 대표적인 방법들은 원형 정합법, 통계적 방법, 구문론적 방법, 신경회로망을 이용한 패턴 인식이 있다<sup>[8][9][11][12][13]</sup>.

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 질환 부위를 자동으로 인식할 수 있다<sup>[4][5][6][7][14]</sup>.

의료영상에서 질환부위를 인식하는 연구는 1970년대 후반 CT가 임상에 사용되어 의료영상이 디지털화 되면서 관심을 가지게 된 분야로서 아직까지 의료영상의 질환부위가 가지고 있는 형태 및 검사 부위의 다양성 때문에 뚜렷한 성과가 없는 분야이다. 최근에는 디지털화 된 의료영상에서 검사 부위별로 분할하는 연구 논문들이 주종을 이루고 있고, 간혹 질환 부위 인식에 관한 연구 논문에서도 검사 목적 부위를 인식하는 수준에 머무르고 있다<sup>[15]</sup>.

### 1. 신경회로망 구성

신경회로망에 의한 패턴 인식은 입력 영상의 데이터로부터 중요한 특징이나 속성을 추출하여 입력 데이터를 식별할 수 있는 부류로 분류하는 것으로 정의할 수 있으며, 영상 패턴의 특징을 나타내는 파라미터를 특징 파라미터라고 하고, 특징 파라미터들로 구성된 형상을 특징 패턴이라고 하며, 특징 패턴을 구하는 작업을 특징 추출이라고 한다<sup>[20][21]</sup>.

신경회로망을 이용한 패턴 인식 방법은 세 가지로 대별된다. 첫 번째 방법은 특징 추출 단계를 거치지 않고 입력 영상 패턴을 직접 신경회로망에 입력하여 패턴을 인식하는 방법이고, 두 번째는 전통적인 패턴 인식 방법에서 특징 파라미터를 추출한 후 신경회로망에 의해서 패턴을 분류 인식하는 방법이며, 세 번째 방법은 특징 추출과 분류를 각각 신경회로망을 적용하여 하는 방법이다. 첫 번째 방법은 입력 영상 패턴을 직접 신경회로망에 입력하여 인식하는 방법으로서 이상적이긴 하지만 영상의 해상도에 따라 많은 유니트 수가 필요하며 연결선의 개수도 증가하기 때문에 실제 패턴 인식 시스템으로 구현하기가 어렵다.

그러나, 특징 파라미터를 추출한 후 신경회로망을 이용하는 두 번째 방법은 소수의 입력 벡터를 사용하기 때문에 유니트 수와 연결선 수를 줄일 수 있어서 신경회로망 구현이 간단하므로 현재 대부분의 신경회로망을 이용한 패턴 인식 시스템에서 이 방법을 사용하고 있다. 본 연구에서는 입력층, 은닉층, 출력층으로 구성된 신경회로망을 그림 3과 같은 구조로 구성하여 적응 오류 역전파 학습 알고리즘에 의하여 학습한다.

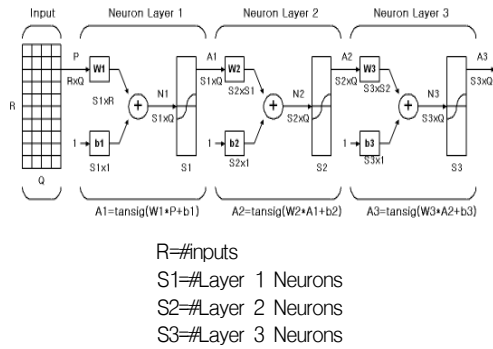


그림 3. 신경 회로망의 구조

2. 적응오차역전파학습

오차 역전파 학습은 우선, 목표함수  $d$ 와 퍼셉트론의 출력  $h$ 의 유사한 정도를 나타내는 오차는 식 (5)와 같다.

$$E \equiv \frac{1}{2|X|} \sum_{x \in X} \alpha(x) \cdot \|h(x) - d(x)\|^2 \quad (5)$$

식 (5)에서  $|\cdot|$ 는 학습 패턴의 수이고,  $\|\cdot\|$ 는 벡터의 유클리드 노름(Norm)이며,  $\alpha(x)$ 는 각 패턴  $x$ 에서  $h$ 와  $d$ 의 유사함을 나타내는 미리 정해진 함수이다.

오차 E를 최소화 하는 입력층과 은닉층의 연결강도 가중치

$$w_{ij} (i = 0, 1, \dots, n; j = 1, 2, \dots, m) \text{와}$$

은닉층과 출력층의 가중치

$$v_{jk} (j = 0, 1, \dots, m; k = 1, 2, \dots, l) \text{를}$$

결정한다.

현재의 가중치  $V_{jk}(old), W_{ij}(old)$ 를 새로운 가중치  $v_{jk}(new), w_{ij}(new)$ 로 수정하는 규칙은 식 (6), (7)과 같다.

$$v_{jk} (\neq w) = v_{jk}(old) - \frac{\Delta}{|X|} \sum_x \delta_{2k}(x) f_j(x) \quad (6)$$

$$(j = 0, 1, \dots, m; k = 1, 2, \dots, l)$$

$$w_{ij} (\neq w) = w_{ij}(old) - \frac{\Delta}{|X|} \sum_x \delta_{1j}(x) x_i \quad (7)$$

$$(i = 0, 1, 2, \dots, n; j = 1, 2, \dots, m)$$

식 (6)과 (7)에서  $\delta_{2k}, \delta_{1j}$ 는 목표함수  $d$ 와 퍼셉트론  $h$ 의 오차로 결정되며,  $\delta_{1j}$ 를 구하기 위해서는  $\delta_{2k}$ 값을 이용해야 하므로 입력층 가중치를 수정할 때 이용되는 오차는 출력층 쪽의 오차가 된다.

즉, 입력층에서 출력층 쪽으로 가중치를 수정하여 갈 때 이용되는 오차는 패턴 정보가 퍼셉트론에 유입되는 방향과는 반대쪽으로 전파되어 가기 때문에 이러한 유형의 학습방법을 오차 역전파 학습법이라 한다<sup>[22][23][24][25][26][28][29]</sup>.

적응 오차 역전파 알고리즘의 학습은 임의의 작은 값으로 인접층 유니트 간의 연결강도를 초기화한 후 학습 데이터를 입력층에 반복적으로 제공함으로써 학습을 한다. 이 과정에서 입력 벡터와 연결강도에 의하여 계산된 출력층에서의 출력값과 기대하고 있던 목표 출력값과의 차이 즉, 오차를 하위층으로 전파시킴으로써 하위층과의 연결강도를 재조정한다.

이와 같이 입력이 앞으로 전달되어 출력을 얻는 전방향 연산 과정과 오차를 역으로 전파하여 연결강도를 재조정하는 학습 과정으로 구성되는 과정은 신경 회로망 전체의 연결강도가 조정되어 총 평균 자승 오차가 기준치 안에 수렴할 때까지 반복적으로 학습이 이루어진다.

표 3. 적응 EBP 알고리즘

```

입력: 입력, 은닉, 출력소자의 수: n, m, l; 목표함수: d; 학습패턴의 집합: X; 시간폭: Δ; 학습종료 조건: ε;
출력:가중치 :  $W_{ij}, i = 0, \dots, n, j = 1, \dots, m$  ;
가중치:  $V_{jk}, j = 0, \dots, m, k = 1, \dots, l$ ;
{ for(i=0; i<=n; i++)
  for(j=1; j<=m; j++)  $W_{ij}$ =initial_value;
  for(j=0; j<=m; j++)
    for(k=1; k<=l; k++)  $V_{jk}$ =initial_value;
  for( ; ){
    for(  $\forall X = (X_1, \dots, X_n)^t \in X$  ) {
      for(j=1; j<=m; j++)
         $f_j(x) = \delta(W_{0j} + W_{1j}X_1 + \dots + W_{nj}X_n)$ ;
      for(k=1; k<=l; k++)
         $h_k(x) = \delta(V_{0k} + V_{1k}f_1(x) + \dots + V_{mk}f_m(x))$ ;
      for(k=1; k<=l; k++)
         $\delta_{2k} = \alpha(x) [h_k(x) - d_k(x)] h_k(x) (1 - h_k(x))$ ;
      for(j=1; j<=m; j++)
         $\delta_{1j}(x) = [ \sum_{k=1}^l \delta_{2k}(x) v_{jk} ] f_j(x) (1 - f_j(x))$ ; }
       $\delta_{max} = 0$ ;  $f_0(x) = 1$ ;
      for(j=0; j<=m; j++)
        for(k=1; k<=l; k++){
           $\delta_{vjk} = \sum_X \delta_{2k}(x) f_j(x)$ ;
          if (  $|\delta_{vjk}| > \delta_{max}$  )  $\delta_{max} = |\delta_{vjk}|$ ; }
       $X_0 = 1$ ;
      for(i=0; i<=n; i++)
        for(j=1; j<=m; j++){
           $\delta_{wij} = \sum_X \delta_{1j}(x) X_i$ ;
          if (  $|\delta_{wij}| > \delta_{max}$  )  $\delta_{max} = |\delta_{wij}|$ ; }
       $\delta = \Delta / \delta_{max}$ ;
      for(j=0; j<=m; j++)
        for(k=1; k<=l; k++)  $V_{jk} = V_{jk} - \delta \cdot \delta_{vjk}$ ;
      for(i=0; i<=n; i++)
        for(j=1; j<=m; j++)  $W_{ij} = W_{ij} - \delta \cdot \delta_{wij}$ ;
      E=수정된 가중치로 오차 계산;
      if(  $E \leq \epsilon$  ) break; } }

```

#### IV. 실험 및 결과

본 연구에서 제안한 방법의 타당성을 검토하기 위하여 그림 4의 실험영상에서 제시한 위영상, 가슴영상, CT영상, 초음파영상, 혈관 조영상을  $[512 \times 512 \times 2^8]$  해상도로 Matlab toolbox와 C 프로그램을 하여 그림 5의 실험 흐름도와 같은 순서로 실험하였다.

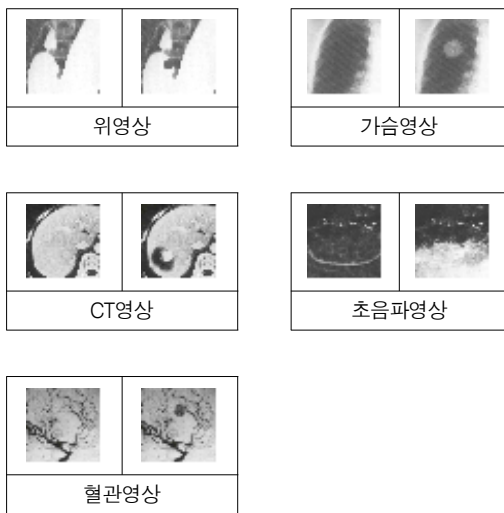


그림 4. 실험영상

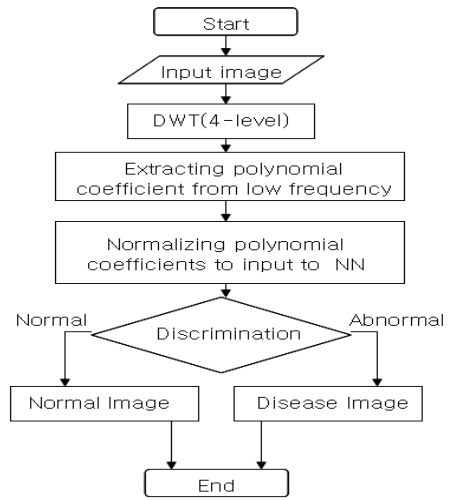


그림 5. 실험절차

최적 파라미터를 찾아내기 위해 그림 6의 DWT 흐름도와 같이 수행하였다.

그림 6에서  $L_i$ 는 저주파영역의 계수를 나타내는 변수이며,  $HH_i$ 는 수평 고주파영역,  $VH_i$ 는 수직 고주파영역 그리고  $DH_i$ 는 대각 고주파영역의 계수를 나타내는 변수이다

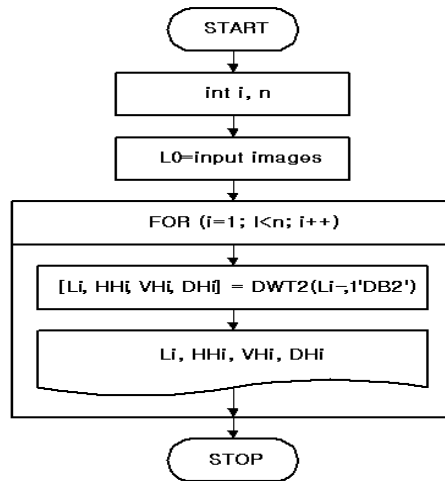



그림 6. DWT 흐름도


그림 7은 교차신호와 출력벡터의 오차범위를 나타




내었으며, 그림 7 (a)에는 위영상의 학습곡선으로 학습 횟수가 55회일 때 수렴하였음을 나타내었고, 그림 7 (b)에는 가슴영상의 학습곡선으로 학습 횟수가 55회일 때 수렴함을 나타내었다. 또한 그림 7 (c)는 CT영상에 대한 학습곡선으로 오차의 범위가 0.01보다 적었을 때를 인식한 것으로 하였고, 그림 7 (d)에는 초음파영상에 대한 학습곡선으로 나타내었으며 학습 횟수는 55회였다. 그리고 그림 7 (e)에는 혈관영상에 대한 학습곡선의 학습의 횟수는 157회였으며, 표 4에는 학습 횟수를 나타내었다.




(a) 위영상




(b) 가슴영상



(c) CT영상



(d) 초음파영상



(e) 혈관영상

그림 7. 교사신호와 출력 백터의 오차범위

표 4. 각 영상에 대한 학습 횟수

영 상	위영상	가슴 영상	CT 영상	초음파 영상	혈관 영상
신경회로망학습 횟수	55	55	46	55	157

## V. 결론

본 논문에서는 의료영상의 질환여부를 인식하는 방법을 제안하였다. 제안된 방법의 타당성을 검증하기 위해서 위영상, 가슴영상, 초음파영상, CT영상, 혈관조영상을  $512 \times 512 \times 2^8$  의 영상크기로 영상처리 시스템에 입력하여 모사실험 한 결과 다음과 같은 결론을 얻었다.

1. DWT 변환 후 저주파영역을 특성 다항식으로 표현하고 계수값을 특징 파라미터 로 추출할 경우 적은 수의 파라미터로 영상의 특징을 추출할 수 있었다.
2. 실험 결과 4레벨 DWT 변환된 저주파영역의 계수 행렬로부터 특징 파라미터를 추출하였을 때, 인식을 위한 최적의 특징 파라미터가 됨을 알 수 있었다.
3. 4레벨 DWT한 후 저주파영역의  $32 \times 32$  계수 행렬에서 특성 다항식의 계수값 33 개를 신경회로망의 입력 벡터로 이용하기 위해서 탄젠트시그모이드 전달 함수의 범위인 최대값 +1, 최저값 -1로 정규화시켰다.
4. 신경회로망의 구성은 입력층, 은닉층, 출력층의 3층으로 하였고, 적응 오차 역전파 알고리즘에 33개의 입력 벡터를 이용하여 학습계수를 0.01, 모우멘텀을 0.95로 하였을 때, 최적임을 알 수 있었다.
5. 최적 학습계수를 0.01로, 모우멘텀을 0.95로 하였을 때, 위영상에 대해서는 55회, 가슴영상은 55회, CT영상은 46회, 초음파영상은 55회 그리고 혈관영상에 대해서는 157회 등의 최적의 학습 횟수를 보이며 100%의 인식률을 보였다.

[참고문헌]

- [1] O.Ratib, M.d., Ph.d. "From PACS to the World Wide Web" [osman@cih.hcuge.ch](mailto:osman@cih.hcuge.ch).
- [2] 탁계래, 김우생, 이상범, "의료영상 저장 전송시스템(PACS)의 발전 및 연구 방향", 정보과학회지, 제 16권, 제 12호, PP. 6-12, 1998.
- [3] I. Daubechies, "Orthonormal bases of compactly supported wavelets", Co- mmun. Pure Appl. Math., Vol. 41, No. 7, PP. 909-996, 1988.
- [4] Stephane G. Mallat, "A theory for multiresolutional signal decomposition; the wavelet representation", IEEE trans. Pattern Anal. Machine Intell., Vol. 11, No. 7, PP. 674-693, July, 1989.
- [5] Ingrid Daubechies, "Ten Lectures on Wavelets", SIAM, 1994.
- [6] Yves Meyer, "Wavelets", SIAM, 1994.
- [7] 이명길, "웨이브렛 변환과 神經回路網을 이용한 SMD IC 패턴 認識에 관한 研究", 청주대학교 대학원 박사학위 논문, 1999년 8월
- [8] J. T. Tou, R. C. Gonzalez, "Pattern Recognition Principles", Addison We- sely Publishing Company, 1974.
- [9] Arun D. Kulkarni, "Artificial Neural Networks for Image Understanding", Van Nostrand Reinhold, 1994.
- [10] Laurene Fausett, "Fundamentals of Neural Networks", Prentice Hall, 1994.
- [11] Mazin G. Rahim, "Artificial Neural Networks for Speech Analysis/Syn- thesis", CHAPMAN & HALL, 1994.
- [12] 김희승, "영상인식", 생능출판사, 1994.
- [13] 이성환, "패턴 인식의 원리 I, II", 홍릉과학출판사, 1997.
- [14] Yoh-Han Pao, "Adaptive Pattern Recognition and Neural Network", Addison Wesley Publishing Company, 1989.
- [15] K. S. Fukushima and A. Rosenfeid, "Pattern recognition and computer vision", IEEE Computer, PP. 274-282, October, 1994.
- [16] Wen-Shou Chou and Yung-Chang Chen, "A new fast algorithm for eff- ective training of neural classifiers", Pattern Recognition, Vol. 25, No. 4, PP. 423-429, 1992.
- [17] James A. Freeman, David M. Skapura, "Neural networks algorithm, app- lication and programming techniques", Addison-Wesley Publishing Compa- ny Inc., PP. 89-123, 1991.
- [18] A. Khotanzad and J. H. Lu, "Distortion invariant character recognition by a multilayer perceptron and backpropagation learning", IEEE ICNN, Vol. I, PP. 625-632, July, 1988.

- 
- [19] Seung-Wha Yoo, Yung-Chang Sung, Jun-Sik Cho Seung-Mu Noh, Kyung-Suk Shin and Jong-Won Park, “Segmentation of Liver and Spleen by Lattice Estimation System in Abdominal CT Image”, Proceedings of ITC-CSCC '99, PP. 991-994, 1999. 7.
- [20] 이상복, 이주신, “병소 부위 인식을 위한 특징 추출 파라미터 추출에 관한 연구”, 한국통신학회논문지, 제23권, 제11호, 1998. 11.
- [21] 이상복, 이주신, “Wavelet에 의한 의료영상의 병소부위 특징 추출”, 한국컴퓨터정보학회논문지, 제3권 제3호, 1998. 10.
- [22] S. Haykin “Neural Network-A Comprehensive Foundation”, Macmillan, PP. 106-120, 1994.
- [23] 박인정, “다층퍼셉트론의 인식력 향상에 관한 연구”, 대한전자공학회 논문지, Vol. 28b, No. 1, PP. 1-8, 1991.
- [24] R. Schalkoff, “Pattern Recognition-Statistical, Structural and Neural Approach”, John Wiley & Sons, Inc., 1992.
- [25] S. Y. Kung, “Digital Neural Networks”, Prentice-Hall, PP. 1-41, 1989.
- [26] James L. McClelland, David E. Rumelhart, “Parallel distributed processing”, The MIT Press, Vol. 1 ~ Vol. 2, 1986.
- [27] Jacek M. Zurada, “Introduction to artificial neural system”, West Publishing Company, 1992.
- [28] James L. McClelland, David E. Rumelhart, “Parallel distributed processing”, The MIT Press, Vol. 1 ~ Vol. 2, 1986.