

論文99-36S-5-8

Wavelet변환과 신경회로망에 의한 위장 영상의 질환 부위 패턴 인식 알고리즘

(Disease Region Pattern Recognition Algorithm of Gastrointestinal Image using Wavelet Transform and Neural Network)

李尙福 * , 李周信 **

(Sang Bock Lee and Ju Shin Lee)

요 약

본 논문에서는 Wavelet을 이용한 위장 영상의 질환 부위 특징을 추출하여 질환 부위 패턴을 인식할 수 있는 알고리즘을 제안하였다. 전처리 과정으로서 위장 영상의 형태정보는 입력 영상을 DWT(Discrete wavelet transform)에 의해 4레벨 DWT 계수 행렬을 구하고 계수 행렬의 특징에 따라 저주파 계수 행렬로부터 저주파 특징 파라미터 32개, 수평 고주파 계수 행렬로부터 수평 고주파 특징 파라미터 16개, 수직 고주파 계수 행렬로부터 수직 고주파 특징 파라미터 16개, 그리고, 대각 고주파 계수 행렬로부터 대각 고주파 특징 파라미터 32개 등 모두 96개의 특징 파라미터를 추출한 후 각각의 특징 파라미터를 최대 값 +0.5로 최소 값을 -0.5로 정규화 하여 신경회로망의 입력 벡터로 사용하였다. 위장 영상 패턴 인식을 위한 신경회로망은 교사 학습을 요구하는 다층 구조의 오차 역전파(Error back propagation)알고리즘으로 하였고 구조적 특성을 이용하여 입력층, 중간층, 출력층의 계층 구조로 설계하였다. 설계된 신경회로망의 학습은 학습계수를 0.2로 모우멘텀을 0.6으로 설정하여 출력층의 최대오차가 0.01보다 작을 때까지 수행하였으며 약 8000회 정도 학습한 결과 설정값 보다 작은 결과를 얻었고 질환의 종류나 위치, 크기에 관계없이 100%의 인식율을 얻었다.

Abstract

In this paper, we suggest some algorithms of pattern recognition which can recognize the disease region pattern through extracting disease region feature from the gastrointestinal image using wavelet. In the preprocessing, the shape informations of gastrointestinal image are selected by performing the discrete wavelet transform(DWT) with four level coefficient matrix. In this approach, based on the characteristics of the coefficient matrix, 96 feature parameters are calculated as follows : Firstly, obtaining 32 feature parameters which have the characteristics of low frequency from the coefficient matrix of low frequency. In the second place, 16 horizontal feature parameters according to the horizontal high frequency are calculated from the coefficient matrix of horizontal high frequency. In the third place, 16 vertical feature parameters are also calculated using the same kind of procedure with respect to the vertical high frequency. Finally, 32 feature parameters of diagonal high frequency are obtained from the coefficient matrix of diagonal high frequency. Consequently, 96 feature parameters are normalized with maximum value +0.5 and minimum value -0.5, being used to input vector of neural network. Error back propagation algorithm is used for recognizing disease region of gastrointestinal image pattern, which is composed of three layers with the use of structural features; input layer, hidden layer and output layer. The learning of designed neural network is carried out until maximum error of the output layer goes down 0.01 with learning coefficient 0.2 and momentum 0.6. As a result of learning about 8,000 times, the maximum error of the output layer turned out to be 0.01, and gaining 100% rate of recognition irrespective of kinds, location and size.

* 正會員, 大元工科大學 電算情報處理科

(Department of computer & Information Process,
Daewon Technical College)

** 正會員, 淸州大學校 電子工學科

(Department of Elec. Eng., Chongju University)
接受日字:1999年1月4日, 수정완료일:1999年4月27日

I. 서론

영상 처리 분야 중 패턴 인식은 도형인식, 문자인식, 지문인식, 물체인식 등의 분야에서 괄목할 만한 연구 결과를 가져왔다. 특징 추출을 위한 전처리 방법 중 입력 영상을 이진 영상으로 변환하여 에지 검출 및 세션화 처리를 한 후 외곽선, 면적, 둘레 등과 같은 형상 정보를 가지고 인식하는 공간영역에서의 방법은 해상도나 정렬, 회전 등 환경 변화에 따른 정확한 특징 파라미터의 추출이 어렵고, 인식 하고자 하는 물체의 크기에 따라 특징 파라미터의 수가 증가하며 특징 파라미터의 추출 과정이 복잡하다는 문제점을 내포하고 있다.

이용 영상 중 위장 영상은 방사선 불투과성 물체인 황산 바륨을 조영제로 써서 위벽에 코팅하여 검사하는 방법으로 질환 부위로 황산 바륨이 집중되어 신호의 변화가 급격하게 된다.

웨이브릿 변환은 신호의 변화가 급격한 부분에서는 고해상도로 분해하고, 신호의 변화가 완만한 부분에서는 낮은 해상도로 분해하는 다해상도 분해가 가능한 변환 방법이다.

신경회로망을 이용한 패턴 인식 방법은 크게 세 가지로 대별된다. 첫째 특징 추출 단계를 거치지 않고 입력 영상 패턴을 직접 신경회로망에 입력하여 패턴을 인식하도록 하는 방법이고, 둘째 전통적인 패턴 인식 방법에서 특징 파라미터를 추출한 후 신경회로망에 의해서 패턴을 분류 인식하는 방법이며, 셋째 특징 추출과 분류 단계에 각각의 신경회로망을 적용하는 방법이다. 특징 파라미터를 추출한 후 신경회로망을 이용하는 둘째 방법은 소수의 입력 벡터를 사용하기 때문에 유니트 수와 연결선 수를 줄일 수 있어 신경회로망 구현이 간단하고 용이하다.

본 논문에서는 웨이브릿 변환에 의한 위장 영상의 질환 부위 특징을 추출하여 신경회로망에 의한 질환 부위 패턴을 인식하는 알고리즘을 제안하였으며 실험 영상은 위장 영상 중 위궤양 영상으로 하였다.

II. 위장 영상의 질환 부위 특징

질환 부위가 있는 위장 영상의 예를 그림 1에 나타내었다.

그림 1 (a)는 위체 후벽 소만측에 생긴 궤양형 위암을 보여주고 있다.

그림 1 (b)에서 위각을 보면, 강낭콩 크기 만한 윤곽돌출이 바륨과 가스에 의해서 이중으로 조영되어 나타난다^[1]. 그림 1 (c)는 전형적인 천공성 위궤양의 바륨조영영상으로 화살표로 표시한 부분에 윤곽돌출이 나타난다. 그림 1 (d)는 위암으로 인하여 위저 및 위체 부위에 불규칙한 윤곽선 결손을 보여주는 바륨조영영상으로서, 원래의 위 윤곽선이 점선으로 표시되어 있다^[1].

그림 1에서 보여진 것처럼 위장의 질환 부위는 다음과 같은 특징을 갖는다.

- (1) 위 점막이 질환 부위로 끌려간다.
- (2) 질환 부위가 밖으로 돌출 된다.
- (3) 질환 부위가 함몰된다




그림 1. 질환 부위가 있는 위장 영상 (a) 바륨도포 영상 (b) 윤곽 돌출 영상 (c) 바륨 충만 영상 (d) 음영 결손 영상

Fig. 1. Gastrointestinal image including disease region (a) Barium relief image (b) Outpouching image (c) Barium full filling image (d) Filling defect image.

이와 같은 질환 부위의 특징 파라미터를 웨이브릿 변환에 의해 검출하고자 한다. 웨이브릿 변환은 신호의 변화가 급격한 부분에서는 샘플링 간격을 작게 완만한 부분에서는 간격을 크게 하여 처리하는 방법으로 공간 영역에서 특징 파라미터를 추출하는 과정보다 간단하고, Discrete cosine transform을 이용하는 방법보다 처리시간을 단축 할 수 있으며 고정된 차합수를 이용하는 단구간 푸리에 변환(Short Time Fourier Transform)보다 신호의 특성 추출을 효과적으로 처리할 수 있다.^[2, 3]

III. Wavelet 변환에 의한 질환 부위 특징 파라미터 추출

1. Wavelet 변환

웨이브릿 변환은 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 값으로 2^j 의 배수가 주로 사용된다. 스케일이 증가할수록 주어진 스케일에서의 웨이브릿 변환 신호의 공간 해상도는 떨어지고 낮은 주파수 대역의 성분을 나타내게 된다. 가우시안 함수와 같은 형태의 평활화 함수 $\theta(x)$ 의 도함수를 $\psi(x)$ 라 할 때 $\psi(x) = \frac{d\theta(x)}{dx}$ 로 두면 $\theta(x)$ 의 도함수를 $\int_{-\infty}^{\infty} \theta(x) dx = 1$, $\lim_{x \rightarrow \pm\infty} \theta(x) = 0$ 의 성질을 가지고 있으며 $\theta(x)$ 의 도함수 $\psi(x)$ 는 다음 식(1)을 만족한다.

$$\int_{-\infty}^{\infty} \psi(x) dx = 0 \tag{1}$$

웨이브릿은 식(1)의 성질을 만족시키는 모 웨이브릿이라 불리는 하나의 원형 웨이브릿인 $\psi(x)$ 를 신축/병진(Dilation/Translation)하여 구하며 식 (2)와 같다.^{[2] [4]}

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \tag{2}$$

여기서, a 는 스케일링 계수이고, b 는 병진 계수이다. 그리고, $a^{1/2}$ 는 정규화 인자이며 $a < 1$ 이면 시간축의 폭이 작은 고주파 웨이브릿이고 $a > 1$ 이면 폭이 큰 저주파 웨이브릿이다. 정규 직교 기저로 분해된 2차원 신호는 다음 식 (3)과 같이 공간적으로 방향성을 지닌 주파수 성분으로 분해된다.

$$\begin{aligned} A_{2 \dots j} f &= \sum_k \sum_l h(2m-k)h(2n-l)A_{2 \dots j} \\ H_{2 \dots j} f &= \sum_k \sum_l h(2m-k)g(2n-l)A_{2 \dots j} \\ V_{2 \dots j} f &= \sum_k \sum_l g(2m-k)h(2n-l)A_{2 \dots j} \\ D_{2 \dots j} f &= \sum_k \sum_l g(2m-k)g(2n-l)A_{2 \dots j} \end{aligned} \tag{3}$$

식(3)에서 h 는 분해 저역 통과 필터의 전달 함수이고 g 는 분해 고역 통과 필터의 전달 함수이다.

2. 질환 부위 특징 파라미터의 추출과 정규화

표 1. 특징 파라미터 추출 알고리즘

Table 1. The algorithm for extracting feature parameter.

```

/*저주파 계수행렬의 특징 파라미터 추출*/
[CA1,CH1,CV1,CD1]=DWT2(IMG,'db2');
[CA2,CH2,CV2,CD2]=DWT2(CA1,'db2');
[CA3,CH3,CV3,CD3]=DWT2(CA2,'db2');
[CA4,CH4,CV4,CD4]=DWT2(CA3,'db2');
for(i=1:16;)
    for(j=1:16;)
        A4H(j)=A4H(j)+abs(CA4(i,j));
        A4V(i)=A4V(i)+abs(CA4(i,j));
    end;
end;
/*수평 고주파 계수행렬에 대한 파라미터추출*/
for(i=1:16;)
    for(j=1:16;)
        H4V(i)=H4V(i)+abs(CH4(i,j));
    end;
end;
/*수직 고주파 계수행렬에 대한 파라미터추출*/
for(i=1:16;)
    for(j=1:16;)
        V4H(i)=V4H(i)+abs(CV4(i,j));
    end;
end;
/*대각 고주파 계수행렬의 특징 파라미터추출 */
for(i=1:16;)
    for(j=1:16;)
        D4H(j)=D4H(j)+abs(CD4(i,j));
        D4V(i)=D4V(i)+abs(CD4(i,j));
    end;
end;
    
```

위장 영상에서의 질환 부위 패턴 인식을 위한 특징 파라미터의 추출은 먼저 해상도가 $[256 \times 256 \times 2^8]$ 인 위장 영상의 입력 영상 신호를 식(3)에 의해 DWT하여 4레벨 DWT 계수 행렬을 구한다. 두 번째로 각각의 계수 행렬로부터 특징에 따라 모두 96개의 특징 파라미터를 표1에 기술된 알고리즘에 의해 4레벨 DWT 계수 행렬에서 구한다.

파라미터 추출의 기준은 위장 영상이 웨이브릿 변환된 후, 각각 분해된 계수를 분석하면 대부분의 에너지는 저주파 영역에 존재하고 수평 및 수직 고주파 영

역 계수, 그리고 위장 영상의 대각 영역에는 상대적으로 에너지 밀집도가 낮은 이유로 저주파 계수 행렬로부터 32개, 수평 고주파 계수 행렬로부터 16개, 수직 고주파 계수 행렬로부터 16개, 대각 고주파 계수 행렬로부터 32개의 특징 파라미터를 추출한다. 특징 파라미터를 96개로 한 이유는 위장 영상에서 정보를 가장 많이 가지고 있는 저주파 영역에서 32개의 변환 계수를 선택하였고, 수평 고주파 영역의 계수 16개, 수직 고주파 영역의 계수 16개, 고주파 성분에서 민감한 대각 영역의 계수 32개를 특징 파라미터로 선택한다. 결과적으로 96개의 특징 파라미터를 선정하였고 파라미터 수를 100개 이상으로 늘렸을 경우 신경회로망의 입력층의 크기가 커져서 학습 시간이 상대적으로 오래 걸리는 단점이 있게된다. 파라미터 수를 90개 이하로 줄였을 경우에 많은 실험적 경험으로 얻은 결론은 본 연구에서 추구하는 인식율을 기대할 수 없게 된다. 공간 해상도의 변화와 특징 파라미터 수와의 관계는 공간 해상도가 다양한 영상일지라도 웨이브릿 변환된 계수 행렬의 특성은 저주파 영역으로부터 수평, 수직 고주파 및 대각 영역의 에너지 분포는 균일한 통계적 특성을 가지기 때문에 파라미터 수와는 무관하게 된다. 따라서 입의 영상의 공간 해상도에 대응하여 추출하고자 하는 특징 파라미터 수를 변화시킬 필요는 없다. DWT 계수 행렬로부터 구한 특징 파라미터를 신경회로망의 입력 벡터로 이용하기 위해서는 정규화 과정이 요구된다. 정규화는 특징 파라미터를 일정한 영역의 값으로 변환시키는 것을 의미하며 각각의 특징 파라미터들 중 최대 값을 +0.5로 그리고 최소 값을 -0.5가 되도록 수행하였다.

IV. 위장 영상의 질한 부위 패턴 인식을 위한 신경회로망의 구성

신경회로망을 이용하여 패턴 인식을 할 경우 기존의 패턴 인식 방법에 비해 다음과 같은 장점을 가지고 있다. 첫째, 구조적으로 병렬성을 내재하고 있기 때문에 신경회로망의 병렬 처리 능력을 이용하여 신속한 처리가 가능하다. 둘째, 입력하는 패턴이 미리 학습된 패턴에 비해 약간 손상된 형태일지라도 잘 인식해낼 수 있는 결함 허용 능력을 가지고 있다. 셋째, 학습되지 않은 새로운 입력 패턴에 대해서도 가장 유사한 부류의 패턴을 찾아낼 수 있는 적응 능력이 있다. 따

라서, 영상의 잡음이나 왜곡, 크기의 다양성, 위치의 변화 등에 유연하게 적응하며 패턴을 인식할 수 있다.^{[5] [6]} 다층 구조의 퍼셉트론은 입력층과 출력층 사이에 하나 이상의 중간층(hidden layer)을 갖는 전방향 신경회로망이다. 다층 퍼셉트론은 단층 퍼셉트론과 유사한 구조를 가지고 있으나 중간층과 각 유니트의 입출력 특성을 비선형으로 함으로써 그 능력을 향상시켜 단층 퍼셉트론의 단점을 극복하였다.^{[7] [8]} 그림 2는 하나의 중간층을 갖는 다층 퍼셉트론의 구조를 나타내고 있다.




그림 2. 다층퍼셉트론
Fig. 2. Multi-layer perceptron.

다층 퍼셉트론은 층의 개수가 증가 할수록 퍼셉트론이 형성하는 경계 결정 능력이 향상된다. 즉, 단층인 경우 패턴 공간을 두 영역으로 나누어주고 2층인 경우 오목한 개구역 또는, 볼록한 폐구역을 형성하며 3층인 경우에는 이론상 어떠한 형태의 결정 구조도 형성할 수 있다.^{[7] [8]} 이와 같이 다양한 패턴들을 분류할 수 있는 다층 퍼셉트론은 역전파 학습 알고리즘을 사용하여 학습한다.

역전파 알고리즘의 학습은 임의의 작은 값으로 인접층 유니트간의 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 하위

층과의 연결강도를 재조정한다. 이와 같이 입력이 앞으로 전달되어 출력층을 얻는 전방향 연산 과정과 오차를 역으로 전파하여 연결강도를 재조정하는 학습 과정으로 구성되는 과정은 신경회로망 전체의 연결강도가 조정되어 총 평균 자승 오차가 기준치안에 수렴할 때까지 즉, 시스템이 안정될 때까지 반복적으로 학습이 이루어진다.

위장 영상의 질환 패턴 인식을 위한 신경회로망은 David E. Rumelhart^[8] 등에 의해 제안된 교사학습을 요구하는 다층 구조의 오차 역전파 알고리즘을 이용하여 입력층은 $[12 \times 8]$ 로 중간층은 $[6 \times 4]$ 로 하였고, 출력층은 질환의 위치(4개의 위치)와 종류에 대한 정보를 출력할 수 있도록 $[2 \times 2]$ 로 그림 3와 같이 설계하였다.




그림 3. 위장 영상의 질환 부위 패턴을 위한 신경회로망
Fig. 3. Neural network for recognizing the gastro-intestinal image disease region pattern.

표 2. 교사신호의 구성 (a) 위장 영상의 교사신호 (b) 각 영상별 교사신호의 크기

Table 2. The configuration of teaching vector for (a) the teaching vector of double contrast gastrointestinal image including stomach ulcer in angle and (b) teaching vector for each models.

[모델 a-1-1]	
0.5	-0.5
-0.5	-0.5

모델	종류	교사신호
model a	barium relief	0.5
model b	filling defect	0.4
model c	outpouching	0.3
model d	full filling	0.2

교사신호를 필요로 하는 오차 역전파 학습 알고리즘은 출력층의 목표가 되는 설정값을 입력시켜 주어야 한다. 표 2는 교사신호의 구성을 표시하며 표 2(a)에서 행과 열 방향은 질환의 위치를 표시하고, 표 2(b)에는 위장 영상의 영상 종류별 교사신호의 크기를 표시하였다. 표 2에서 [모델 a-1-1]은 상부위장 영상의 위궤양 패턴, 이중 조영상을 의미한다.

V. 실험 및 고찰

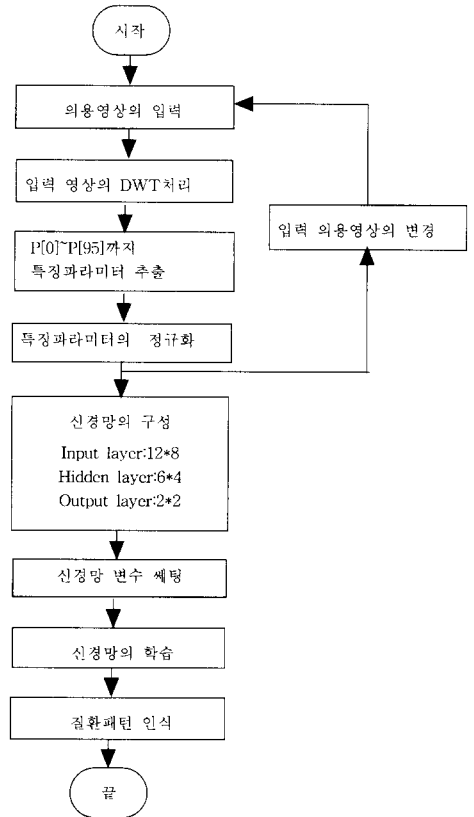


그림 4. 위장 영상의 질환 부위 패턴 인식 순서도
Fig. 4. Flowchart of disease region Pattern recognition on gastrointestinal image.

본 논문에서 제안된 알고리즘의 타당성을 검토하기 위한 모의 실험은 그림 4과 같이 실행하였다. $256 \times 256 \times 2^8$ 레벨의 그림 6에 있는 영상을 입력 영상으로 하여 펜티엄 PC에서 MATLAB의 toolbox를 이용하여 실험하였다.

특징 파라미터 추출은 입력 영상을 각각 DWT에 의해 4레벨 계수 행렬을 구한 후 계수 행렬의 특징에

따라 저주파 계수 행렬로부터 저주파 특징 파라미터 32개, 수평고주파 계수 행렬로부터 수평 고주파 특성 파라미터 16개, 수직 고주파 계수 행렬로부터 수직고주파 특징파라미터 16개 그리고, 대각 고주파 계수 행렬로부터 대각 고주파 특징 파라미터 32개 등 모두 96개의 특징 파라미터를 표 1에 제안된 알고리즘을 사용하여 표 3과 같이 추출하였다. DWT계수 행렬로부터 구한 특징 파라미터를 신경회로망의 입력 벡터로 이용하기 위해서는 정규화 과정이 요구된다. 정규화는 특징 파라미터를 일정한 영역의 값으로 변환시키는 것을 의미하며, 각각의 계수 행렬의 특징에 따른 특징 파라미터들을 검색한 후 각각 최대 값을 +0.5, 최소 값을 -0.5로 하여 정규화를 수행하였다. DWT계수 행렬로부터 추출한 96개의 특징파라미터를 정규화하여 위장 영상의 질한 패턴 인식을 위한 신경회로망의 입력 벡터로 사용하였다. 위장 영상 질한 패턴 인식을 위한 신경회로망은 입력층, 중간층, 출력층을 각각 $[12 \times 8]$, $[6 \times 4]$, $[2 \times 2]$ 의 계층으로 설계하였다. 설계된 신경회로망의 학습은 반복학습과 수렴점의 최적 trade off point를 실험적으로 학습계수를 0.2로 모우멘텀을 0.6으로 설정하여 8,000회 정도 수행한 결과 출력층의 출력 값과 교사신호와의 최대오차가 그림 5와 같이 0.01보다 작은 결과를 얻었다.

표 3. 특징추출 Table
Table 3. Feature extraction table.

(a) Position 1

2204.9887	13017.7654	34801.9876	35291.9204	54204.2657	3435.3217	3455.5733	3455.5364
34765.3915	41231.6785	43433.9071	42231.5369	42306.5924	45632.9678	41232.8974	41231.5041
2376.9870	13312.5672	45231.3966	43654.5029	35675.5412	27805.9875	26708.9874	36511.9872
39034.1678	42341.6976	410881.6675	41231.7895	42412.6667	48257.9018	45206.9123	42041.6782
84234.8712	8907.7456	654.7851	97.7456	87.3423	213.8709	121.4352	109.3452
786.8976	712.8976	54.0956	49.9812	58.1245	63.5653	76.2345	63.8342
8762.9871	8071.6784	93.7564	7834.9864	2367.2541	256.0987	453.9845	586.1254
776.4345	85.8923	82.9887	70.8774	421.4565	67.97564	76.9887	8765.8774
651.3456	702.8756	341.7865	49.6556	39.2323	96.4554	201.9894	218.4545
236.4556	189.7634	69.1233	48.86412	64.2343	90.7895	58.3445	86.2323
6454.7634	287.8776	30.1215	89.2323	454.2343	76.2131	36.7654	343.8774
235.5653	36.4527	51.5432	82.3532	78.2311	67.2344	34.7661	537.5356

(b) Position 2

2342.6753	15432.6548	43651.5438	46521.7321	4200.4452	44851.9847	42008.6512	43615.9834
43676.5619	41281.3125	35433.9750	38231.7814	33906.1762	33882.5374	35831.8297	34231.3434
2368.4523	14322.8345	44321.2341	45209.9529	36543.2213	28789.8876	28786.6234	28996.8345
38956.7612	417561.5643	43211.8712	41289.9123	43126.7123	41238.9714	43126.6740	45231.2346
8564.9834	8120.2563	69.9341	69.5421	78.5634	68.3489	69.2145	84.8342
634.6123	1232.8766	154.9865	89.3012	89.5648	97.1238	129.8734	541.9234
8871.9342	8108.9123	126.3129	2874.8123	1918.4523	356.5231	287.7324	388.3421
616.9845	128.2560	81.8123	78.9123	117.8394	68.1214	73.1298	8316.9120
372.6123	388.8123	68.5643	58.4196	71.4881	43.7324	75.9231	81.7123
167.8912	115.6512	154.9867	67.5432	69.8431	109.8905	105.8612	198.9843
256.9812	271.8912	69.7823	71.8432	123.8765	125.54381	165.3214	234.6544
79.0567	45.9127	68.6589	66.4521	61.3429	86.3768	54.9412	291.7388

(c) Position 3

2301.4532	13173.9785	36732.5438	34554.8762	34653.4012	36101.4328	33096.5467	35612.6198
34765.7896	41032.9135	41383.7850	42228.8456	42376.5612	42209.6439	42067.9124	41231.6754
2321.0678	15328.4563	43221.6523	44279.7523	42556.1118	42590.1567	42793.0066	42393.4512
42307.9663	42065.6146	29656.3167	26734.1265	28727.2893	33238.2534	41122.3842	44135.6129
8257.5923	8120.2563	563.4943	59.6522	69.4356	98.9659	109.8142	144.4569
831.7453	712.5864	63.4652	61.1791	63.6571	60.7045	72.9976	68.4561
8562.7632	8321.9888	98.9663	112.7623	65.3412	72.7612	93.4586	112.3420
413.8734	467.4561	630.7809	132.0098	2891.7612	2312.1967	175.9342	81236.9452
376.8345	578.5123	153.7121	53.6754	76.6547	116.0678	91.8721	87.8653
316.2319	145.8732	58.4329	43.6521	64.8120	74.6734	45.8173	82.4523
343.4529	263.8945	65.1201	63.8213	57.6457	55.1893	58.8612	59.3471
134.6723	256.6891	175.0989	161.2314	254.3621	183.4788	59.9412	261.5628

(d) Position 4

2241.4681	13011.9121	42359.6838	43112.0142	43167.6531	43521.1131	42316.6578	43231.2318
43512.8609	38456.1432	34578.4352	34670.3518	34781.7562	34671.5092	34467.5760	33721.0813
2231.6541	13439.6127	43321.8211	43186.8437	42891.7271	42673.9667	42651.9469	42473.6412
42251.7844	42879.8327	33348.4581	28794.5465	28454.1152	31067.2578	40879.1894	44037.6159
8385.0531	8156.0917	49.6729	57.6729	84.4866	58.2551	65.6731	76.8556
1161.7534	1082.6759	189.6432	68.5435	64.3708	83.5231	168.7561	1782.9823
8883.3451	8615.0923	92.4577	103.0354	61.6879	67.5127	95.6798	118.9894
161.4501	1365.3987	1031.8741	303.0068	1317.6124	1674.6567	221.5674	8151.6153
363.8954	378.1132	46.8287	39.7649	67.5327	43.6067	68.8781	54.4531
128.3453	265.9870	64.4329	67.7451	55.9671	85.2451	98.4652	236.9121
247.932	364.8662	66.1329	68.0506	56.4372	47.3984	58.3509	65.9823
53.6348	115.0981	142.0945	143.7682	176.8704	237.7659	56.5623	281.6882

학습곡선




그림 5. 위 궤양 영상의 질한 부위 패턴 인식 학습곡선
Fig. 5. The training curve of the disease region pattern recognition.

출력층에서 목표로 하는 교사신호를 표 4와 같이 하였으며 특징 패턴에 대한 출력된 벡터는 표 5와 같았다.

표 4. 위궤양 영상 목표 교사신호

Table 4. The teaching vector of gastric ulcer image.

(a) Position 1

	a-1-1	
+0.5		-0.5
-0.5		-0.5

(b) Position 2

	a-1-2	
-0.5		+0.5
-0.5		-0.5

(c) Position 3

a-1-3	
-0.5	-0.5
+0.5	-0.5

(d) Position 4

a-1-4	
-0.5	-0.5
-0.5	+0.5

표 5. 학습 패턴과 동일한 형태의 특징 패턴에 대한 출력 벡터의 예 (위 궤양 영상)

Table 5. An example of output vector for the same feature pattern as a trained pattern(Stomach ulcer image).

a-1-1		a-1-2	
0.492460	-0.495761	-0.498453	0.492341
-0.498793	-0.499956	-0.499784	-0.497341
a-1-3		a-1-4	
-0.498769	-0.499432	-0.497845	-0.490564
0.492321	-0.496781	-0.496754	0.497623

신경 회로망에서 위장 영상 질환 패턴에 대한 인식의 기준은 식(4)와 같이 출력층의 출력 벡터와 교사신호와의 최대오차가 0.01보다 작은 값을 가질 때 인식한 것으로 판정하였다.

$$\text{if (교사신호} - \text{출력신호)} < 0.01$$

then 인식 else 비인식 (4)

신경회로망의 학습에 사용되었던 패턴과 동일한 형태의 특징 패턴을 입력 벡터로 하여 신경회로망에 입력시킨 결과 출력층의 최대오차가 0.01보다 작았다.

표 6. 비학습한 특징 패턴에 대한 출력 벡터의 예 (위궤양 영상)

Table 6. An example of output vector for the untrained feature pattern (Stomach ulcer image).

a-1-1		a-1-2	
0.492175	-0.495691	-0.497525	0.4909741
-0.498087	-0.499995	-0.499994	-0.496686
a-1-3		a-1-4	
-0.498393	-0.499995	-0.499994	-0.493444
0.491978	-0.497230	-0.496260	0.497474

신경회로망의 학습에 사용하지 않았던 특징 패턴을 입력 벡터로 하여 신경회로망에 입력하였을 때에 대한 출력 결과는 표 6과 같았다.

신경회로망의 학습에 사용하지 않았던 특징 패턴을 입력 벡터로 하여 신경회로망에 입력시켰을 때 출력층의 최대오차가 0.022404였다.

실험을 수행하여 얻은 결과를 기반으로 질환 패턴에 대한 인식을 판정하기 위하여 설정하였던 교사신호와 출력층에서 출력된 출력 벡터와의 최대오차는 표 7, 표 8과 같았다.

표 7. 학습 패턴과 동일한 형태의 특징 패턴에 대한 출력층의 최대오차

Table 7. The maximum error of the output layer of same feature pattern as a trained pattern.

	Position 1	Position 2	Position 3	Position 4
Barium relief	0.001851	0.002761	0.001443	0.002956
Filling defect	0.001456	0.001324	0.000967	0.000768
Outpouching	0.002437	0.001041	0.001476	0.001298
Full filling	0.006754	0.007869	0.007214	0.004609

표 8. 비학습한 특징 패턴에 대한 출력층의 최대 오차

Table 8. The maximum error of the output layer of untrained feature pattern.

	Position 1	Position 2	Position 3	Position 4
Barium relief	0.022403	0.014234	0.012813	0.011562
Filling defect	0.01287	0.006376	0.020567	0.005768
Outpouching	0.004109	0.005634	0.003098	0.001558
Full filling	0.006648	0.006154	0.006634	0.006745

따라서, 신경회로망의 학습에 사용한 특징 패턴과 동일한 형태의 특징 패턴을 신경회로망에 입력하여 인식하였을 때 질환의 종류나 위치, 크기에 관계없이 인 식율은 100%로 나타났다.



(a)

(b)




그림 6. 입력 영상(위궤양 영상)
Fig. 6. input image(Stomach ulcer).

VI. 결론

본 논문에서는 웨이브릿 변환에 의한 질환 부위 특징을 추출하여 위장 영상의 질환 부위 패턴 인식 알고리즘을 제안하였다. 제안된 방법의 타당성을 검증하기 위하여 위궤양 영상을 입력하여 실험을 수행한 결과 다음과 같은 결론을 얻었다.

1. 입력 영상을 DWT하여 얻은 4레벨 DWT계수 행렬로부터 직접 특징 파라미터를 추출하기 때문에 전형적인 공간 영역에서의 특징 파라미터를 추출하는 과정 보다 단순화 할 수 있었다.

2. 신경회로망의 학습은 학습계수를 0.2로 모우멘텀을 0.6으로 설정하여 출력층의 최대오차가 0.01보다 작을 때까지 수행하였으며 약 8000회 학습한 결과 최대오차가 설정값보다 작았다.


3. 신경회로망의 학습에 사용한 특징 패턴과 동일한 형태의 특징 패턴을 신경회로망에 입력하여 인식하였을 때 질환의 종류나 위치, 크기에 관계없이 인식율이 100%로 나타났다.

이와 같은 연구 결과는 위장 영상의 판별 시스템에 이용할 수 있으며, 원격의료에도 유용하게 쓰일 것이다.

참고 문헌

- [1] 박용휘, “상부소화기X선진단”, 수문사, pp. 201-253, 1982년 5월.
- [2] I.Daubechies, “Orthonormal bases of compactly supported wavelets”, SPIE Optical Engineering Press, 1991.
- [3] Yves Meyer, “Wavelets”, SIAM, 1994.
- [4] E.A.B. da Silva and M.Ghanbari, “On the performance of linear phase wavelet transform in low bit-rate image coding”, IEEE trans. On Image Processing, Vol. 5, 1996.
- [5] Arun D. Kulkarni, “Artificial Neural Networks for Image Understanding”, Van Nostrand Reinhold, 1994.
- [6] R. Schalkoff, “Pattern Recognition Statical, Structural, and Neural Approachs”, John Wiley & Son Inc., 1992.
- [7] Jack M. Zurada, “Introduction to artificial neural system”, West Publishing Company, 1992.
- [8] James L. McClelland, David E. Rumelhart, “Parallel distributed processing”, The MIT Press, Vol. 1, Vol. 2, 1986.

저자 소개



李 尚 福(正會員)
1958년 1월 28일생. 1987년 2월 대전산업대학교 전자계산과 졸업. 1994년 2월 청주대학교 대학원 전자계산과 졸업 공학석사. 1997년 8월 청주대학교 대학원(전자공학과 : 컴퓨터공학전공) 박사수료. 1995년 3

월부터 현재 : 대원공과대학 전산정보처리과 조교수, 전자계산소장. 1987년 4월 ~ 1992년 2월 서울컴퓨터 주식회사 이사. 주관심분야는 의용영상, PACS, 영상통신

李 周 信(正會員)
공학박사, 청주대학교 이공대학 전자공학과 정교수. 1996년 3월 ~ 1998년 2월 청주대학교 이공대학장. 1998년 3월 ~ 1999년 2월 청주대학교 기획관리처장