

역전달 신경회로망을 이용한 심전도 파형의 부정맥 분류

권 오 철 · 최 진 영 · 조 진 호* · 이 건 일

Classification of ECG Arrhythmia Signals Using Back-Propagation Network

Oh Cheol Kweon, Jin Young Choi, Jin Ho Cho*, and Khun Il Lee

- Abstract -

A new algorithm classifying ECG Arrhythmia signals using Back-propagation network is proposed. The base-line of ECG signal is detected by high pass filter and probability density function, then input data are normalized for learning and classifying. In addition, ECG data are scanned to classify Arrhythmia signal which is hard to find R-wave. A two-layer perceptron with one hidden layer along with error back-propagation learning rule is utilized as an artificial neural network. The proposed algorithm shows outstanding performance under circumstances of amplitude variation, baseline wander and noise contamination.

1. 서 론

심전도(electrocardiogram)는 심장의 활동시에 나타나는 전기적 신호로서 이는 심장의 상태와 질환을 알아보는데 중요한 자료로 쓰인다. 지금까지 심전도 부정맥(arrhythmia)의 검출 및 진단을 위해 PR, RR, ST 등의 간격과 QS의 폭, 심박수 및 축의 편위 등을 진단변수로 하는 알고리듬이 많이 제시되었다.^{1~4)} 이러한 다양한 진단변수들을 실시간으로 추출하여 처리하기 위해서는 파이프라인 구조

〈접수 : 1989년 11월 27일〉

경북대학교 공과대학 전자공학과

* 경북대학교병원 의공학과, 경북대학교 공과대학 전자공학과

Dept. of Electronics, Kyungpook National University

* Dept. of Biomedical Eng., Kyungpook University Hospital and Dept. of Electronics, Kyungpook National University

와 같은 병렬처리방식 등을 이용하거나, 다양한 템플레이트(template)와 자료를 메모리에 내장시켜 진단에 이용할 수 있을 정도의 용량을 갖는 컴퓨터가 필요하다. 또한 이러한 진단변수외에 상호상관계수를 이용하여 부정맥 패턴을 분류하는 방식도 제안되었으나⁵⁾ 상호상관계수를 구하기 위하여 상당한 시간이 소요되므로 실시간으로 처리하기 위해서는 복잡한 하드웨어를 포함한 고속의 컴퓨터가 필요하다.

이러한 문제점들을 해결하기 위한 방법으로 최근 패턴분류 분야에서 활발히 연구되고 있는 신경회로망을 이용하여 심전도의 부정맥 패턴을 분류하는 방법이 연구되고 있다. Carroll 등⁶⁾은 심전도 분석에 신경회로망을 이용함으로써 기존의 방법보다 부정맥 진단의 정확도를 향상시킬 수 있음을 보고한 바 있으며, Cho 등⁷⁾은 해밍모델(Hamming model)을 이용하여 심전도 부정맥을 진단하는 알고리듬을 제시하였다. 그러나 해밍모델을 이용한 기존의 방법은 기저선을 찾지 않고 임의의 진폭을 가진 심전도를 정규화 없이 그대로 학습시켰으며,

R파를 기준으로 양자화하여 인가하였기 때문에 기저선이 변동한 경우와 심전도 파형의 진폭이 크게 변한 경우 및 R파에 이상이 있는 부정맥의 진단에는 정확도가 떨어지는 문제점들이 있었다. 신경회로망을 이용하여 기저선 변동 및 잡음유입의 경우에도 정확한 분류가 이루어지도록 하기 위해서는 심전도 신호의 기저선을 먼저 찾아야 한다. 또한 전형적인 부정맥을 갖는 다양한 표본심전도를 정규화하여 학습시키고, 진단할 심전도 역시 정규화하여 분류하여야 정확도가 향상된다. 그리고 심전도에는 종상에 따라서 유사도가 큰 성질을 지닌 부정맥 패턴이 다양하게 존재하며, 심전도 신호가 아날로그 신호이기 때문에 이진신호를 입력으로하는 모델을 사용할 경우 효과적인 분류가 어렵다.

본 논문에서는 이러한 문제점을 해결하기 위하여 고역 통과 여파기와 화률밀도 함수를 이용하여 심전도 신호의 기저선을 찾고, 입력 자료를 정규화하는 전처리과정을 수행하여 학습과 진단에 사용하였다. 또한 R파를 찾기가 어려운 부정맥을 분류하기 위하여 심전도 자료를 시간추이로 주사(scanning)하면서 부정맥을 진단케 하였다. 제안한 알고리듬에서는 다풋이며 아날로그 입력으로 연산이 가능한 역전달 회로망(back-propagation network)을 이용하였다. 본 알고리듬은 분류하고자 하는 부정맥들을 전처리한 후 각 뉴런간의 적절한 연결강도(connection strength)를 구하기 위해 신경회로망을 학습시키고, 학습된 연결강도를 이용하여 심전도 자료를 시간추이로 주사하면서 부정맥 패턴을 분류하도록 하였다. 위의 알고리듬으로 심전도의 측정시에 생길 수 있는 진폭이 변화된 경우와 기저선이 변동된 경우 그리고 잡음유입의 경우에 대한 신호들을 각각 시뮬레이션하여 제시한 알고리듬이 우수한 분류능력을 가짐을 입증하였다.

2. 이 론

신경회로망은 수학적 알고리듬의 적용이 곤란한 문제를 학습방법에 의하여 효과적으로 해결할

수 있고 흐려진(fuzzy) 자료와 잡음에 둔감한 특징을 가지므로 컴퓨터를 사용하여 심전도와 같이 비효율적인 패턴분류(pattern classification)의 문제를 효율적으로 처리하는데 매우 적합하다. 일반적으로 신경회로망은 학습방식에 따라 지도학습(supervised learning)모델과 자율학습(unsupervised learning)모델로 구분할 수 있으나 심장질환에 관한 부정맥은 그 종상에 대한 형태가 이미 임상적으로 알려져 있기 때문에 지도학습모델이 유리하다. 지도학습모델중 흡프필드모델(Hopfield model)과 해밍모델(Hamming model)은 이전 입력을 사용하고, 적응적 훈련(adaptive training)이 불가능하다. 그러므로 종상에 따라서 발생하는 심전도 패턴간의 차이가 근소한 부정맥 패턴들을 분류하는 경우에는 다풋구조를 가지고, 적응적으로 훈련하며, 아날로그 신호의 입력으로 연산이 가능한 역전달 네트워크모델이 보다 효과적이다. 역전달 네트워크는 학습상태(learning phase)와 정상동작상태(working phase)의 두가지 기능을 가진다. 학습상태는 입력신호에 의한 출력과 원하는 출력신호(reference)와의 차이를 줄이는 방향으로 뉴런간의 연결강도를 학습방법에 따라 적절히 조절하며, 정상동작상태는 입력신호와 학습상태에서 학습한 연결강도로서 출력을 계산한다.

부정맥을 분류하기 위하여 사용한 역전달 네트워크의 뉴런간의 연결구조는 그림 1과 같다.

그림 1에서 보는 바와 같이 하나의 은닉층(hid-

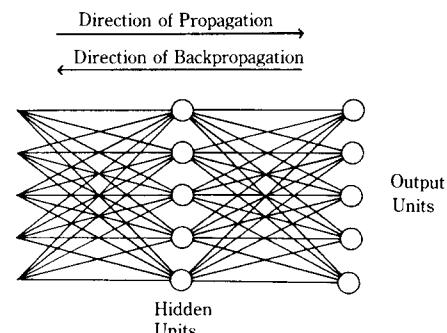


그림 1 뉴런간의 연결구조

Fig. 1 Interconnection structure of the neurons.

den layer)을 가진 회로망으로 순방향의 연결(forward pass)은 정상동작상태에서의 신호의 흐름방향이며, 역방향의 연결(backward pass)은 학습상태에서의 신호의 흐름방향이다. 역전달 회로망을 구성하는 단일 뉴런의 구조는 아래의 그림 2와 같다.

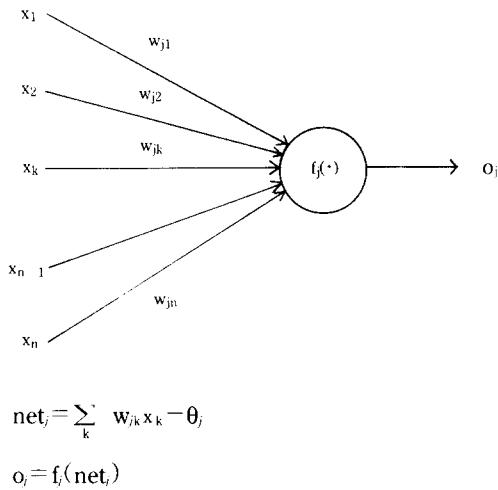


그림 2 단일 뉴런의 구조

Fig. 2 Structure of a neuron

단일 뉴런의 net값은 n개의 심전도 입력에 각각 연결강도 w 를 인가하고 입력 x 와 w 의 곱의 합에서 문턱값 θ 를 빼 값으로 활성함수(activation function)를 거쳐 활성값으로 되고 다시 출력함수를 거쳐 출력값이 된다. 여기서 $f(\cdot)$ 는 뉴런의 활성함수로서 비선형이고 미분가능하여야 한다. 본 논문에서 사용한 활성함수는 sigmoid function으로 아래와 같다.

$$f(\text{net}) = \frac{2}{1 + e^{-\text{net}}} - 1 \quad (1)$$

학습과정은 뉴런간의 연결강도를 w , N개의 학습시킬 패턴중 패턴 p에 해당하는 목표값(target value)을 t_p . 그리고 네트워크의 출력을 $o_p(w)$ 라고 할때 각 패턴에 대응하는 오차를

$$e_p = t_p - o_p(w) \quad (2)$$

로 정의하고 에너지 함수(energy function) $E_p(w)$ 를

$$E_p(w) = \|e_p\|^2 = \|t_p - o_p(w)\|^2 \quad (3)$$

라고 할때 전체 패턴에 대응하는 에너지 함수 $E(w)$ 는

$$E(w) = \sum_p E_p(w) \quad (4)$$

이며, 학습이란 이 에너지 함수를 최소로 하는 연결강도를 구하는 것이다. 따라서 $t+1$ 시각에서의 상위 i뉴런과 하위 j뉴런의 연결강도 w_{ji} 는

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}(t) \quad (5)$$

으로 조정되며, 여기서 연결강도의 변화값 $\Delta w_{ji}(t)$ 는

$$\Delta w_{ji}(t) = \eta \cdot \delta_{ji} \cdot o_{ji} + a \cdot \Delta w_{ji}(t-1) \quad (6)$$

으로 쓰기도 한다. 이때 δ_{ji} 는 i가 출력뉴런일 경우 $f'_i(\text{net}_{ji})(t_{ji} - o_{ji})$ 이고, i가 내부뉴런일 경우는 $f'_i(\text{net}_{ji}) \sum_k \delta_{jk} w_{ki}$ 이다. 여기서 η 는 학습율(learning rate)이며, a는 모멘트항으로 과거의 연결강도 변화값의 반영율로서 두 변수 모두 적당히 클때 수렴속도를 빠르게 하는 것으로 알려져 있다.*

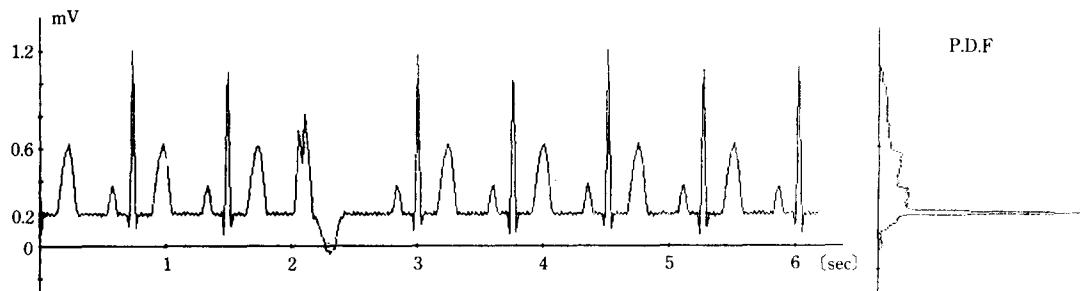
P파 및 R파, S파 및 T파 등의 시간간격 및 스펙트럼을 진단변수로 하는 기존의 분류방법에서는 입력된 심전도를 1Hz미만의 고역통과 여파기를 통과시켜 사용할 경우 기저선 변동은 크게 문제가 되지 않았다. 그러나 심박수가 변동한 경우나 부정맥이 출현하는 경우 고역통과 여파기만을 통과한 기저선은 직류값의 변화를 수반하기 때문에 패턴 분류의 방법으로 분류할 경우 분류 정확도에 큰 영향을 미치게 된다. Alste 등⁹⁾은 FIR필터(finite impulse response filter)를 이용하여 기저선 변동과 잡음을 제거하였으나, 본 논문에서는 처리시간의 간략화를 위하여 신경회로망이 잡음에 둔감한 특징을 가지므로 잡음은 제거하지 않고 0.7Hz의 차단 주파수를 갖는 고역통과 여파기를 사용하여 기저선 변동만을 제거하였다. 또한 고역통과 여파기를 사용하여 기저선 변동을 제거함으로써 생기는 기저선의 하강은 화률밀도함수를 도입하여 입력된 심전도 자료중 진폭의 최대치와 최소치 구간을 N개의 양자와 레벨로 나누어

가장 밀도가 높은 레벨의 값을 기저선으로 취하였다.
다음 그림은 확률밀도함수를 이용하여 기저선을 찾은 그림이다.

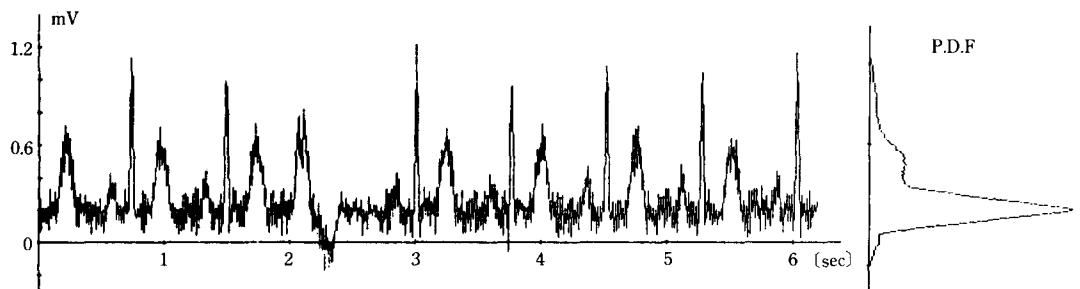
그림 3에서 a)는 잡음이 유입되지 않은 심전도와 이의 밀도함수이며, b)는 잡음이 유입된 심전도 신호와 이의 밀도함수를 나타낸 것이다. 그리고 c)는 두

경우의 확률밀도함수를 동일 좌표축에 그린 것으로 잡음이 유입된 경우에도 기저선을 정확히 검출할 수 있음을 보여준다.

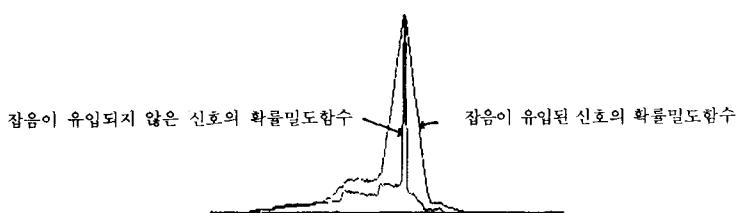
지금까지 대부분의 패턴분류는 R파를 기준으로 분류되어 왔으나, R파에 이상이 있거나, R파를 찾기 어려운 신호를 패턴분류의 방법으로 분류하기 위



a) 정상적인 심전도 신호와 이의 확률밀도함수
a) normal ECG signal and it's PDF



b) 잡음이 유입된 심전도 신호와 이의 확률밀도함수
b) noise contaminated signal and it's PDF



c) 동일 축상에 그린 확률밀도함수의 비교
c) comparision of different PDF depicted the same axes

그림 3 확률밀도함수를 이용한 기저선 검출

Fig. 3 Base-line detection by probability density function

해서는 입력자료를 주사하면서 부정맥을 분류하는 것이 효과적이다.

본 논문에서는 알고리듬을 크게 두 부분으로 구성하였다. 즉 학습시키기 위한 증상들의 기저선을 찾고 정규화하여 역전날 신경회로망을 학습시키는 부분과, 진단하고자 하는 심전도 신호와 학습된 연결강도를 이용하여 진단하는 부분으로 나누어진다. 첫번

째 부분은 심전도 파형중 분류하고자 하는 부정맥들을 선택하여 신경회로망을 학습시키는 부분이다. 두 번째 부분은 학습시킨 연결강도를 이용하여 심전도 자료를 시간 추이로 주사하면서 각 주사입력에 의한 출력값들과 정상 패턴의 목표값을 제외한 각 패턴의 목표값들과의 오차를 구한다. 계산된 오차중에서 가장 작은 오차의 입력을 재인가하여 가장 큰 출력뉴런의 패턴을 부정맥 패턴으로 결정하였다. 이에 대한 순서도는 그림 4에서와 같다

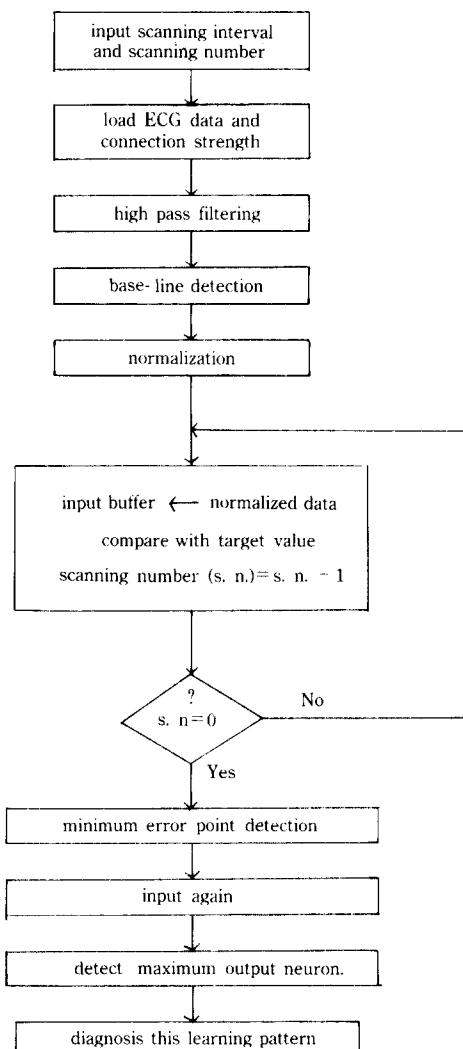


그림 4 신경회로망을 이용한 부정맥분류 알고리듬

Fig. 4 An algorithm to classify ECG Arrhythmia by neural net.

3. 시뮬레이션 및 결과 고찰

본 논문에서 제안한 알고리듬을 이용하여 심전도 부정맥을 검출하기 위하여 부정맥 시뮬레이터(Dynatec,217A)의 LEAD I신호를 자료획득보드(DT2821)를 이용하여 A/D변환하여 IBM/AT로 처리하였다. 샘플링 주파수는 부정맥의 특징을 그대로 살리면서 입력버퍼의 수를 줄일 수 있는 정도인 100Hz로 하였으며 심박수는 80bpm으로 하였다. 입력버퍼의 수와 은닉층에서의 뉴런의 수, 그리고 출력 뉴런의 수는 각각 85, 50, 30개로 하였고, 학습율은 0.3, 모멘트항은 0.7로 하였으며, 기저선을 찾기위한 양자화 레벨 N은 100으로 하였다. x번째 학습패턴의 목표값은 출력층의 x번째 뉴런의 값은 +0.9, 이외의 출력뉴런의 값은 -0.9로 하여 학습시켰다. 목표값을 ±0.9로 정한 이유는 학습한 패턴보다 큰 값의 패턴에 대해서도 학습한 패턴을 분류하고 학습시간을 줄이기 위해서이다.

그림 5는 제안한 알고리듬의 각 수행 단계에서의 처리된 신호의 변화를 나타내었다. a)는 진폭이 1mV인 심전도 파형에 진폭이 0.15mV인 랜덤 잡음과, 진폭이 1mV이고 주파수가 0.4Hz인 정현파가 유입된 신호이고, b)는 a)의 신호를 차단 주파수가 0.7Hz인 고역통과 여파기를 통과한 신호이며, c)는 기저선을 찾은 신호이다. 그리고 d)는 최대값 1로 정규화시킨 신호이다. 위의 파형들로부터 상당한 기저선 변동의 경우에도 기저선을 정확하게 검출할 수 있음을 알 수 있다.

각종 실험 조건하에서 시뮬레이션을 수행한 결과는 표 1과 같다. 본 알고리듬이 주사를 행하는 방

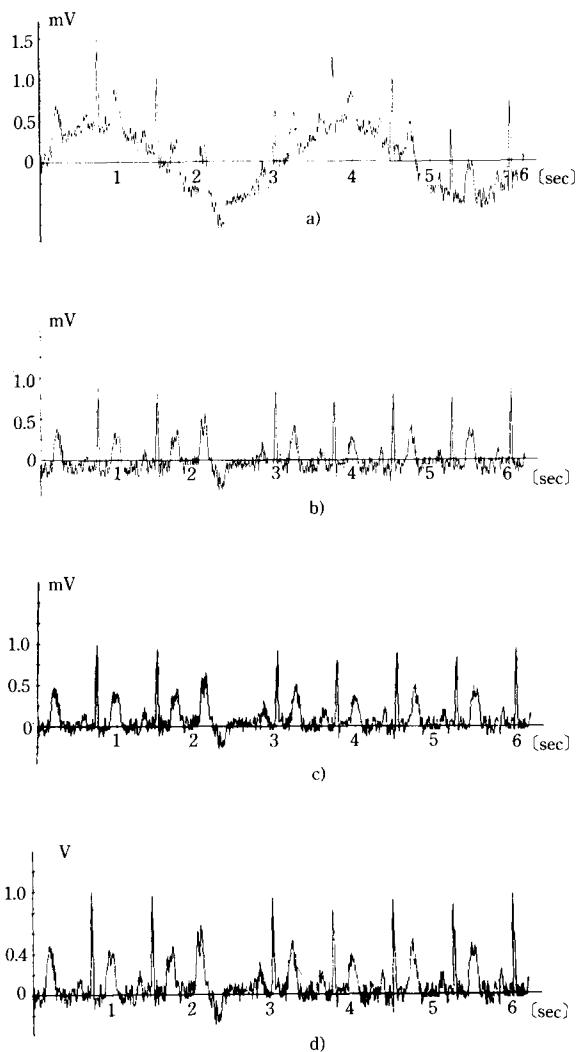


그림. 5 시뮬레이션 과정의 신호

- a) 진폭 변화, 기저선 변동, 잡음유입의 신호
- b) 고역통과 여파기를 통과한 신호
- c) 기저선을 찾은 신호
- d) 정규화를 행한 신호

Fig. 5 Signals in process of simulation.

- a) applied signal in case of amplitude variation, baseline drift and noise corruption
- b) high-pass-filtered signal
- c) baseline-detected signal
- d) normalized signal

표 1. 각종 실험조건에서의 부정맥 분류의 결과

Table 1. The result of classifying ECG Arrhythmia under the various conditions.

실험조건	진단결과	진단율
학습한 패턴	30/30	100%
학습하지 않은 패턴	20/20	100%
진폭이 변화된 패턴	0.5mV	30/30
	1.5mV	30/30
	3.0mV	30/30
잡음이 유입된 패턴	0.1mV	30/30
	0.125mV	30/30
	0.15mV	28/30
기저선이 변동된 패턴	30/30	100%

식이기때문에 정상인의 심전도를 포함한 30 종류의 학습한 패턴과 학습하지 않은 20종류의 패턴에서 어느 시점에서 부정맥이 발생하더라도 모두 분류하였으며, 정규화하였기 때문에 QRS의 진폭이 0.5mV, 1.5mV, 3mV인 총 90가지의 경우에 대하여 모두 정확하게 분류가 이루어졌다. 또한 신경회로망이 잡음에 둔감한 특징을 가지므로 QRS이 진폭이 1mV인 신호에 대하여 각각 0.125mV, 0.1mV의 랜덤잡음이 유입된 신호에 대하여 모두 분류하였으며, 진폭이 0.15mV인 랜덤잡음이 유입되었을때 두 가지를 제외한 모든 경우에 대하여 정확히 분류됨을 확인하였다. 분류하지 못한 두 경우는 그림 5에서와 같이 P파의 크기와 비슷한 잡음이 유입된 경우로서 육안으로 알아보기 어려운 신호였다. 해결방안으로는 입력버퍼의 수를 크게하면 잡음에 더욱 둔감해지므로 이러한 신호도 분류가 가능할 것으로 생각된다.

그리고 80bpm의 부정맥을 학습시켰기 때문에 RR 간격이 변하는 다른 심박수의 부정맥에 대해서는 분류하기가 어렵다. 이러한 부정맥을 분류하기 위해서는 각각의 경우에 대한 부정맥을 학습시켜야 한다. 이때 학습시켜야 할 부정맥의 수가 증가하므로 메모리의 용량과 수행시간의 제한으로 인하여 처리하는데 한계가 있을 수 있으며, 또한 소프트웨어적인 방법으로 시뮬레이션을 하였기 때문에 실시간으로 처리하지 못하였으나 하드웨어와 결합하여 처리를 행

할 경우 실시간으로 처리될 것으로 기대되며 이에 대한 연구가 현재 진행중에 있다.

4. 결 론

본 논문에서는 고역 통과 여파기와 화률 밀도 함수를 이용하여 심전도 신호의 기저선을 찾고 입력 자료를 정규화하는 전처리과정을 수행하여 학습과 진단에 사용하고, R파를 찾기 어려운 부정맥을 분류하기 위해서 심전도 자료를 시간축으로 주사하면서 부정맥을 진단하는 알고리듬을 제시하였다. 제안한 알고리듬에서 사용한 신경회로망은 적응 학습과 아날로그 신호의 입력으로 연산이 가능한 역전달 회로망을 이용하였다.

제안한 알고리듬으로 심전도의 측정시에 생길 수 있는 진폭이 변화된 경우와 기저선이 변동된 경우, 그리고 잡음유입의 경우에 대한 심전도 신호들을 각각 시뮬레이션하여 0.15mV의 잡음이 유입된 경우의 두가지를 제외한 모든 경우의 신호에 대하여 정확히 분류됨을 확인하여 제시한 알고리듬이 우수한 분류 능력을 가짐을 입증하였다.

참 고 문 헌

- 1) Nitish V. Thakor, "Estimation of QRS complex power spectra for design of a QRS filter", IEEE Trans. Biomed. Eng., vol. BME-31, pp.702 – 705, No.11, November. 1984
- 2) Jiapu Pan and Willis J. Tompkins, "A real-time QRS detection algorithm", IEEE Trans. Biomed. Eng., vol. BME-32, pp.230 – 235, No.3, Mar. 1985
- 3) 유흥로, 최경훈, 이명호, 박규태, "마이크로 컴퓨터를 이용한 실시간 ECG 자동진단 알고리즘", 대한의공학회지, vol. 6, No. 1, pp.55 – 64, 1985.
- 4) 황선철, 정희교, 김용만, 이명호, "심방성 부정맥 진단 알고리즘에 관한 연구", 대한의공학회지, vol. 10, No. 1, pp. 17 – 23, 1989
- 5) Peng-Wie Hsia, Janice M.Jenkins, Yair Shmoni, Kevin P. Gage, John T. Santinga, and Bertram Pitt, "An automated system for ST segment and Arrhythmia analysis in exercise radionuclide ventriculography", IEEE Trans. Biomed. Eng., vol. BME-33, pp. 585 – 593, June 1986.
- 6) T. O. Carroll, Haresh Ved., "A neural network for ECG analysis", IEEE.INNS. vol. II, pp. 575, June, 1989.
- 7) 조성복, 조진호, 이건일, "해밍 신경회로망을 이용한 ECG 파형의 부정맥 분류" 대한전자공학회 1989년도 하계종합학술대회 논문집, vol. 12, No. 1, pp. 477 – 480, 1989.
- 8) Richard P. Lippmann "An introduction to computing with neural nets" IEEE. ASSP magazine, pp. 4 – 22, Apr. 1987.
- 9) J. A. Van Alste, "Removal of base-line wander and power-line interference from the ECG by an efficient FIR filter with a reduced number of taps", IEEE Trans. Biomed. Eng., vol. BME-32, pp. 1052 – 1060, No. 12, DEC. 1985
- 10) A. Jun-Wei Wong, "Recognition of general patterns using neural network", Biol. Cybern. 58, pp. 360 – 372, 1988.