

퍼지 신경망과 웨이블릿 변환을 이용한 부정맥 분류 퍼지규칙의 추출

Extracting Arrhythmia Classification Fuzzy Rules Using
A Neural Network And Wavelet Transform

김덕용, 임준식

경원대학교 전자계산학과

Deok-Yong Kim and JoonShik Lim

Dept of Computer Science, Kyungwon University

E-mail : kyo535@gmail.com

요약

본 논문은 가중 퍼지소속함수 기반 신경망(Neural Network with Weighted Fuzzy Membership Functions, NEWFM)을 이용하여 심전도 신호로부터 조기심실수축(Premature Ventricular Contraction, PVC)을 판별하는 퍼지규칙을 추출하고 있다. NEWFM은 자기적응적(self adaptive) 가중 퍼지소속함수를 가지고 주어진 입력 데이터로부터 학습하여 퍼지규칙을 생성하고 이를 기반으로 정상 파형과 PVC 파형을 구분한다. 분류 성능 평가를 위하여 MIT/BIH 부정맥 데이터 베이스를 사용하였으며, NEWFM의 입력은 심전도의 파형에 웨이블릿 변환을 적용하여 추출된 웨이블릿 계수를 사용하였다. 여기에 비중복면적 분산 측정법을 적용하여 중요도가 낮은 계수를 제거하면서 최소의 m 개 특징입력만을 사용한 하이퍼박스로 단순화 시킨다. 이러한 방법으로 추출된 2개의 웨이블릿 계수를 사용한 퍼지규칙은 96%의 PVC 분류성능을 보여준다.

1. 서론

심전도(ECG) 신호는 인체에서 심장 박동에 따른 전기적인 변화를 잘 보여준다. 심전도는 파형의 높이, 간격 등에 따라 P-QRS-T 군으로 특징지어 진다. 최근 심전도의 이러한 특성을 이용하여 심장 질환을 진단하기 위한 여러 알고리즘들이 개발되고 있다[4][5][6][7][8][9][10][11][12]. 심장질환들 중에서도 부정맥은 위급한 질환중의 하나로서 그 중에서 조기심실수축(Premature Ventricular Contraction, PVC)은 비정상적인 자극으로 인한 수축이다. 이러한 조기심실수축을 분류하는 방법에는 신경회로망을 이용하는 방법이 있는데 Fuzzy-ARTMAP 에서는 기존 방법보다 우수한 성능을 보여주고 있다[1].

본 논문에서는 정상과 조기심실수축 비트(beat)를 분류하기 위하여 가중 퍼지소속함수 기

반 신경망(Neural Network with Weighted Fuzzy Membership Functions, NEWFM)[2]을 이용하였다. NEWFM은 분류 성능이 뛰어나며 학습이 끝나고 특징 입력의 수가 최소화 될 수 있기 때문에 모바일(mobile) 환경 및 임베디드(embedded) 시스템에 적합하다. 심전도의 파형에 웨이블릿 변환을 적용하여 추출된 계수를 사용하여 신경망의 입력 데이터로 사용하였다. 신경망에서 추출된 퍼지규칙들 중에서 중요도가 낮은 계수들은 제거되며 최소의 특징입력들만이 남아 퍼지규칙을 형성하고 분류에 적용된다.

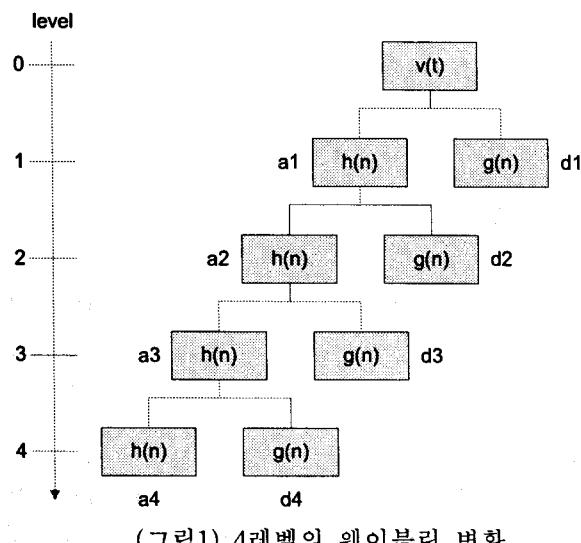
2. 심전도 전처리

본 논문에서 심전도 파형의 QRS군의 검출은 MIT/BIH 부정맥 데이터 베이스에서 대역통과필터를 거친 데이터를 이용하였다[3]. 심전도 파형

의 윈도우 크기는 대칭적으로 R파를 중심으로 127ms 전과 127ms 후까지의 254ms 를 사용한다. 하나의 윈도우 파형의 특징을 추출하기 위하여 웨이블릿 변환을 적용하였다.

웨이블릿 변환(Wavelet Transform)은 신호처리에 있어서 시간-주파수 영역에서의 동시 분석이 가능한 방법으로 추출된 웨이블릿 계수(Wavelet Coefficient)는 웨이블릿 모함수(Mother Wavelet)에 대한 유사도를 나타낸다. 웨이블릿 변환은 스케일 함수와 모함수를 입력신호와 곱하여 저대역필터(a low-pass filter)와 고대역필터(a high-pass filter)로 분할하게 된다.

본 논문에서는 Haar 웨이블릿을 이용하여 레벨 3과 4의 주파수 대역에서 d3, d4, a4 의 웨이블릿 계수로 구성된 특징들을 사용하였다. 레벨 1과 2의 주파수 대역에서의 웨이블릿 계수들은 레벨 3과 4에 비해 특징적인 면이 적을 뿐 아니라 잡음을 포함하고 있어 사용하지 않는다.

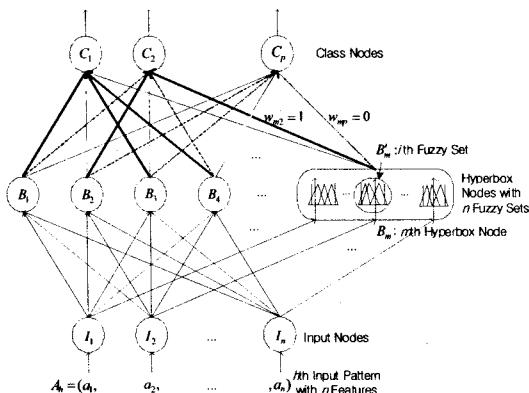


웨이블릿 계수를 추출하기 위하여 MIT/BIH 부정맥 데이터 베이스로부터 정상과 조기심실수 축의 2가지 파형을 선택하였다. 4레벨의 Haar 웨이블릿 변환을 적용한 뒤, d3에서 32개, d4와 a4에서 각각 16개, 총 64개의 웨이블릿 계수를 특정 입력으로 사용한다.

3. 가중 퍼지소속함수 기반 신경망

NEWFM의 구조는 그림 2에서 볼 수 있듯이 입력, 하이퍼박스, 클래스의 3개 입력 계층으로 구성된다. 입력 계층은 n 개의 입력노드들로 구성되며 각 입력노드는 하나의 특징입력을 받게 된다. 하이퍼박스 계층은 m 개의 하이퍼박스 노드

로 구성되며, l 번째 하이퍼박스 노드 B_l 은 단 하나의 클래스 노드에 연결되어 n 개의 퍼지집합을 갖는다. B_l 의 i 번째 퍼지집합은 B_l^i 로 표시되는데 대, 중, 소로 구성된 3개의 가중 퍼지소속함수를 가진다. 출력 계층은 p 개의 클래스 노드들로 구성되며 각 클래스 노드는 하나 혹은 하나 이상의 하이퍼박스 노드에 연결되어 있다. 입력노드로 입력되는 h 번째 입력 패턴은 $I_h = \{A_h = (a_1, a_2, \dots, a_n), class\}$ 로 기록되며 class는 분류 결과이고 A_h 는 n 개 입력 특징으로 구성된다.

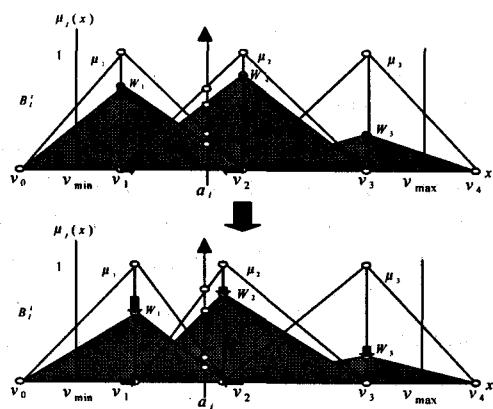


(그림 2) 가중 퍼지 소속함수 신경망의 구조

하이퍼박스노드 B_l 과 클래스노드 C_i 사이의 연결 가중치는 w_{il} 로서 연결되어 있다면 $w_{il}=1$ 로 설정된다. 그림 3의 v_1, v_2, v_3 는 대, 중, 소 퍼지소속함수의 중심위치이고 학습 중에 좌우로 조정된다. μ_j 는 B_l^i 의 퍼지소속함수이며 $j=1, 2, 3$ 은 대, 중, 소 퍼지소속함수의 인덱스를 나타낸다. 각 퍼지소속함수 μ_j 의 모양은 3 개의 위치 (v_{j-1}, v_j, v_{j+1}) 로 표현되는 삼각형으로 되어 있는데 소속함수의 강도(strength)를 나타내는 소속함수 가중치 W_j ($0 \leq W_j \leq 1$, 초기값 $0.45 \leq W_j \leq 0.55$)를 갖는다. 그림 3에서의 $Adjust(B_l)$ 연산은 h 번째 입력패턴인 $A_h = (a_1, a_2, \dots, a_n)$ 에 의해, B_l 내의 퍼지소속함수와 그 가중치를 조정한다. 입력 a_i 를 받는 B_l^i 의 v_j 와 W_j 는 a_i 값에 의하여 조정되며 ($j=1, 2, 3$), 그 결과 새로운 중심위치인 $new(v_j)$ 와 새로운 가중치인 $new(W_j)$ 가 다음과 같이 설정된다. α 와 β 는 0~1사이의 학습율 범위이고 변수 E_j 는 v_j 와 입력 a_i 간의 차이를 나타낸다. 만일 E_j 가 인접 E_{j+1} 보다 크면 적은 것이 선택된다.

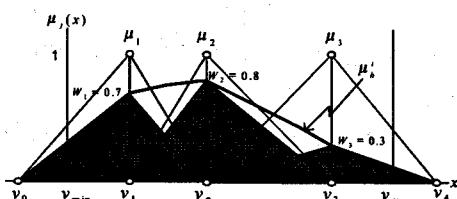
$$new(v_j) = v_j + \alpha E_j \mu_j(a_i) W_j \quad (1)$$

$$new(W_j) = W_j + \beta (\mu_j(a_i) - W_j) \quad (2)$$

(그림 3) B_i^i 의 Adjust (B_i) 연산

학습을 거친 NEWFM은 입력패턴을 분류하기 위한 if-then 형식의 퍼지규칙 추출에 사용될 수 있다. 학습을 거친 후에는 하이퍼박스노드 B_i 의 각 퍼지집합에는 3개의 가중 퍼지소속함수 (weighted fuzzy memberships, WFM, 그림 4의 회색 부분)가 포함된다. 규칙들은 WFM으로부터 직접 추출될 수 있다. $\mu_b^i(x)$ (그림 4의 굵은 선)로 표시된 WFM의 경계합(bounded sum)은 다음과 같이 정의되며 WFM의 경계합 (BSWFM)은 그림 4에서와 같이 3개의 WFM의 퍼지 특성을 통합한다.

$$\mu_b^i(x) = \sum_{j=1}^3 B_i^j(\mu_j(x)) \quad (3)$$



(그림 4) 3개 가중 퍼지소속함수의 경계합 예(굵은 선)

4. 실험 및 평가

분류 성능 평가를 위해 MIT/BIH 부정맥 데이터 베이스에서 전체 환자 레코드를 이용하여 정상과 PVC를 각각 202개씩 총 404개를 무작위로 추출하여 실험에 사용하였다.

아래의 식(4)-(7)은 성능 평가를 위해 사용되었으며 사용된 식들의 의미는 다음과 같다.

$N \text{ to } P$ = 정상을 PVC로 분류한 경우

$P \text{ to } N$ = PVC를 정상으로 분류한 경우

Specificity = 정상으로 올바르게 분류한 경우

Sensitivity = PVC를 올바르게 분류한 경우

$$\% \text{ 총 에러율} \quad (4)$$

$$= \frac{N \text{ to } P + P \text{ to } N}{\text{No. of total tested beats}} \times 100$$

$$\% \text{ Specificity} \quad (5)$$

$$= \frac{\text{No. of tested normal beats} - N \text{ to } P}{\text{No. of tested normal beats}}$$

$$\% \text{ Sensitivity} \quad (6)$$

$$= \frac{\text{No. of tested PVC beats} - P \text{ to } N}{\text{No. of tested PVC beats}}$$

$$\% \text{ PVC 분류} \quad (7)$$

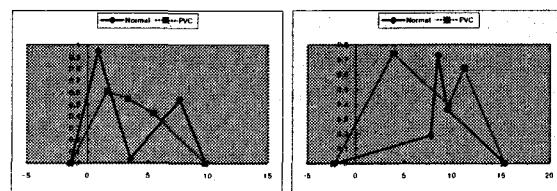
$$= \frac{\text{No. of tested PVC beats} - P \text{ to } N - N \text{ to } P}{\text{No. of tested PVC beats}}$$

NEWFM을 이용하여 64개의 웨이블릿 계수 중에서 2개만을 사용한 퍼지규칙은 그림 5와 같다. 이러한 2개의 규칙만을 사용하여 정상과 PVC를 분류한 결과는 표1과 같다.

<표 1> PVC 분류 성능

Specificity	99.50%
Sensitivity	96.53%
PVC 분류	96.04%
총 에러율	1.98%

NEWFM을 이용하여 추출된 2개의 퍼지규칙을 가지고 실현한 결과 96%의 분류 성능과 1.98%의 에러율을 보였다. Fuzzy-ARTMAP 을 이용한 방법에서는 정상과 PVC의 96%의 분류 성능을 보여주고 있지만 구현이 복잡하다는 단점이 있다. 본 논문에서의 분류성능은 96%를 보여주고 있으며 2개의 웨이블릿 계수를 이용하여 2개의 퍼지규칙만을 사용하기 때문에 모바일 환경 및 임베디드 시스템에서의 구현이 간단하다.



(그림 5) 추출된 2개의 퍼지규칙

5. 결론

본 논문에서는 NEWFM을 이용하여 심전도 신호에서의 정상과 PVC를 분류하였다. 입력은 MIT/BIH 부정맥 데이터 베이스를 사용하였으며

심전도의 파형에 Haar 웨이블릿을 적용하여 64 개의 계수를 추출하였다. 신경망의 학습이 끝난 후에는 중요도가 낮은 계수들을 제거하며 최소의 퍼지규칙을 추출하였다. 중요도가 높다고 판단된 2개의 웨이블릿 계수(47, 48번째 계수)는 고주파 영역의 3레벨에 위치하고 있으며 이는 R파의 중요성을 보여준다. 이는 파형의 중요한 부분만 윈도우를 적용함으로써 윈도우의 크기를 줄일 수 있다. 본 논문에서의 실험 결과는 분류성능이 96% 를 보여주며 2개의 웨이블릿 계수를 사용한 2개의 퍼지 규칙만을 사용하기 때문에 향후 PVC의 진단에 있어 모바일 환경 및 임베디드 시스템으로의 적용이 가능하다.

6. 참고문헌

- [1] Fredric M. Ham and Soowhan Han. "Classification of Cardiac Arrhythmias Using Fuzzy ARTMAP", IEEE Trans. on BME. VOL, 43, No. 4, pp.425-430. 1996.
- [2] Joon-Shik Lim. "Finding Fuzzy Rules for IRIS by Neural Network with Weighted Membership Functions", International Journal of Fuzzy Logic and Intelligent Systems, vol. 4, No. 2, pp. 211-216.
- [3] "MIT/BIH arrhythmia database directory" (CD-ROM), Harvard Univ. and Mass. Inst. of Tech. Div. of Health Sciences and Tech., Cambridge, MA, document BMEC TR010(revised), July 1992.
- [4] G. A. Carpenter, S. Grossberg and J. Reynolds, "ARTMAP : Supervised real-time learning and classification of nonstationary data by a self-organizing neural network," Neural Networks, Vol.4, pp.565-588, 1991.
- [5] R. Jang, "ANFIS : Adaptive network-based fuzzy inference system," IEEE Trans. Syst., Man, Cybern., Vol.23, pp.665-685, May-June, 1993.
- [6] T. Kasuba, "Simplified Fuzzy ARTMAP," IEEE AI Expert, pp.19-25, Nov., 1993.
- [7] Ho J. Kim, Tae W. Ryu, Thai T. Nguyen, Joon S. Lim, and Sudhir Gupta, "A Modified Fuzzy Min-Max Neural Network for Pattern Classification," Computational Science and Its Applications ICCSA 2004 (LNCS 3046), pp.792-798, Springer-Verlag, 2004.
- [8] H.-M. Lee, K.-H. Chen and I.-F. Jiang, "A Neural Networks with Disjunctive Fuzzy Information," Neural Networks, Vol.11, pp. 1113-1125, 1998.
- [9] C. T. Lin and C. S. George Lee, "Neural-network-based fuzzy logic control and decision system," IEEE Trans. Computers, Vol.40, No.12, Dec., 1991.
- [10] P. Simpson, "Fuzzy min-max neural networks-Part 1 : Classification," IEEE Trans., Neural Networks, Vol.3, pp. 776-786, 1992.
- [11] C. Z. Ye, J. Yang, D. Y. Geng, Y. Zhou, N. Y. Chen, Fuzzy Rules to Predict Degree of Malignancy in Brain Glioma, Medical and Biological Engineering and Computing, Vol.40, 2002.
- [12] J. S. Wang and C. S. G. Lee, "Self-Adaptive Neuro-Fuzzy Inference System for Classification Applications," IEEE Trans., Fuzzy Systems, Vol.10, No.6, pp.790-802, 2002.