

이산 웨이블릿 변환과 퍼지 신경망을 이용한 조기심실수축 추출

장형종[†], 임준식^{**}

요 약

본 논문은 심전도(ECG) 신호로부터 조기심실수축(PVC)을 자동 탐지하는 방법으로 이산 웨이블릿 변환과 퍼지 신경망을 이용하는 방안을 제시하고 있다. 심전도 신호를 이산 웨이블릿 변환(DWT)으로 특징을 추출한 후, 퍼지 신경망으로 학습하여 정상 비트와 PVC 비트를 분류한다. 윈도우 크기는 R파를 기준으로 $-31/360 \sim +32/360$ 초를 사용하며, 웨이블릿 변환은 d3, d4, d5의 웨이블릿 계수 14개를 사용한다. 퍼지 신경망은 가중 퍼지소속함수 기반 신경망을 사용한다. 본 논문은 벤치마킹 데이터로 MIT-BIH 부정맥 데이터베이스를 사용하여 Shyu 실험군(7개 레코드)에서는 전체 분류율에서 97.04% 보다 높은 99.91%의 신뢰성 있는 결과를 나타내었고, Inan 실험군(40개 레코드)에서는 각각 SE는 82.57% 보다 높은 84.67%, SP는 98.33% 보다 높은 99.39%, 전체 분류율은 96.85% 보다 높은 98.01%의 신뢰성 있는 결과를 나타내었다.

Detection of Premature Ventricular Contraction Using Discrete Wavelet Transform and Fuzzy Neural Network

Hyoung Jong Jang[†], Joon Shik Lim^{**}

ABSTRACT

This paper presents an approach to detect premature ventricular contraction(PVC) using discrete wavelet transform and fuzzy neural network. As the input of the algorithm, we use 14 coefficients of d3, d4, and d5, which are transformed by a discrete wavelet transform(DWT). This paper uses a neural network with weighted fuzzy membership functions(NEWFM) to diagnose PVC. The NEWFM discussed in this paper classifies a normal beat and a PVC beat. The size of the window of DWT is $-31/360 \sim +32/360$ second(64 samples) whose center is the R wave. Using the seven records of the MIT-BIH arrhythmia database used in Shyu's paper, the classification performance of the proposed algorithm is 99.91%, which outperforms the 97.04% of Shyu's analysis. Using the forty records of the MIT-BIH arrhythmia database used in Inan's paper, the classification performance of the proposed algorithm is 98.01%, which outperforms 96.85% of Inan's one. The SE and SP of the proposed algorithm are 84.67% and 99.39%, which outperforms the 82.57% and 98.33%, respectively, of Inan's study.

Key words: Premature Ventricular Contraction(PVC, 조기심실수축), Fuzzy Neural Network(퍼지신경망), Discrete Wavelet Transform(이산 웨이블릿 변환), Arrhythmia(부정맥)

※ 교신저자(Corresponding Author): 임준식, 주소: 경기도 성남시 수정구 복정동 (461-701), 전화: 031)750-5750, FAX: 031)750-5662, E-mail: jslim@kyungwon.ac.kr
접수일: 2008년 9월 30일, 완료일: 2009년 1월 13일

[†] 정회원, 경원대학교 전자계산학과 박사
(E-mail: jhlab@gmail.com)

^{**} 준회원, 경원대학교 컴퓨터소프트웨어전공 교수

1. 서론

질병관리본부는 국내 심장마비 환자의 생존율이 4.6% 정도로 다른 국가에 비해 매우 떨어진다는 조사결과를 2008년 3월 발표했다. 이는 환자나 가족이 응급증상에 대한 이해가 부족한 데다 응급대처에도 미숙해 전문적인 치료를 받기까지 상당한 시간이 걸리기 때문이다. 국내 심장마비 환자의 생존율은 다른 나라의 15~40%에 비해 훨씬 낮았으며, 특히 미국 심장마비 환자의 생존 퇴원을 40%에 비해 매우 낮은 수치이다. 이와 같은 현실에서 심질환의 초기 대처는 심질환 환자의 생존율을 높이는 주요 요인이 된다.

심장 질환의 증가에 따라 심장의 전기적 활동을 나타내는 심전도(electrocardiogram, ECG) 자동 진단에 대한 연구와 진단의 정확성을 높이기 위한 알고리즘 개발이 활발히 이루어지고 있다. 심전도 신호에서 심장 질환을 자동 진단하기 위해 신경망 및 퍼지 이론을 결합한 퍼지 신경망이 제안되어 왔다[1-3]. 심전도 신호의 특징을 추출하기 위해 푸리에 변환 및 웨이블릿 변환이 사용되고 있으며, 퍼지 신경망과 함께 심장 질환 분류에 사용되고 있다[4,5].

자동 진단이 어려운 심장 질환은 주로 부정맥(arrhythmia)으로, 부정맥은 여러 가지 원인에 의하여 심장 내 전기적 신호의 형성이나 전달 과정에 이상이 생겨 발생한다. 부정맥 중에서 가장 빈번히 일어나는 증상은 조기심실수축(early ventricular contraction, PVC)이다. PVC는 동방결절에서 정상적인 수축을 내보내기 전에 심실내의 흥분된 세포가 심실을 직접 수축시킴으로써 발생하게 되는데, 심실 빈맥이나 심실세동 등 긴급한 부정맥을 유발하게 한다. 이러한 PVC를 자동 진단하는 방법으로 웨이블릿 변환 계수를 특징입력으로 하는 퍼지 신경망이 연구되어 왔다[5-7].

Shyu[5]는 QRS 넓이와 지속시간을 입력으로 하는 퍼지 신경망을 사용하여 전체 분류율 97.04%의 결과를 나타내고 있다. 그러나 Shyu의 방식은 실험 레코드가 7개로 비교적 단순하여 다른 실험군에 적용하기가 어려운 단점을 지니고 있다. Inan[8]은 40개의 레코드를 사용했다는 점에서 다른 논문들과 차이를 나타내고 있으며, 웨이블릿 변환 계수와 RR 간격을 결합한 특징 벡터를 다중 퍼셉트론(multi-layer perceptron, MLP)을 이용하여 실험하였다. 실험 결

과 SE 82.57%, SP 98.33%, 전체 분류율 96.85%의 결과를 나타내고 있다.

본 논문은 정상 비트와 PVC 비트를 분류하기 위하여 가중 퍼지소속함수 기반 신경망(neural network with weighted fuzzy membership functions, NEWFM)[9,10]을 사용한다. NEWFM은 위스콘신 유방암[11], 붓꽃(iris)[12], 포도주[13] 등에 대한 벤치마킹 분류실험에서 높은 성능을 입증하였다. 본 논문에서는 MIT-BIH 부정맥 데이터베이스[14]의 심전도 데이터를 이산 웨이블릿 변환을 이용하여 계수를 추출하고, 이 계수를 NEWFM의 입력으로 사용하여 정상 비트와 PVC 비트를 분류한다. 본 논문에서는 비교 실험군으로 Shyu[5], Inan[8]의 실험군을 사용한다.

본 논문의 구성은 다음과 같다. 2장에서는 본 연구와 관련된 지식에 대해 살펴본다. 시간-주파수 영역에서의 신호처리 분석 방법인 이산 웨이블릿 변환에 대해 알아보고, 본 논문에서 사용할 가중 퍼지소속함수 기반 신경망에 대해 알아본다. 3장에서는 조기심실수축 진단 알고리즘에 대해 알아보고, 4장에서는 실험 결과와 타 논문과의 비교 평가를 실시한다. 마지막으로 5장에서는 본 논문의 결론을 맺는다.

2. 관련 연구

2.1 이산 웨이블릿 변환(Discrete Wavelet Transform)

모함수(mother wavelet)를 ϕ 라 하면, 웨이블릿 변환 함수 f 는 식(1)과 같다.

$$f * \phi_s(x) = \frac{1}{s} \int_{-\infty}^{\infty} f(t) \phi\left(\frac{x-t}{s}\right) dt \quad (1)$$

여기서 $s = 2^j$ (j 는 정수)라 하면, 웨이블릿 변환은 식(2) 및 식(3)과 같이 계산할 수 있다.

$$S_{2^j} f(n) = \sum_{k \in \mathbb{Z}} h_k S_{2^{j-1}} f(n - 2^{j-1}k) \quad (2)$$

$$W_{2^j} f(n) = \sum_{k \in \mathbb{Z}} g_k S_{2^{j-1}} f(n - 2^{j-1}k) \quad (3)$$

g_k (detail)는 웨이블릿 계수와 관련된 FIR(finite impulse filters) 고대역(high-pass) 필터 계수이고, h_k (approximation)는 스케일 함수 계수와 관련된 FIR 저대역(low-pass) 필터 계수이다. 각 필터를 지

나 그 길이가 반으로 감소한 신호를 다음 스케일 레벨에서 반복하여 변환시킨다. 웨이블릿 변환으로 추출된 웨이블릿 계수는 웨이블릿 모함수에 대한 유사도로, 이는 주어진 시간에 따른 주파수 신호를 나타낸다. 본 논문에서는 Haar 모함수를 사용한다. 식(4)는 Haar 스케일 함수를, 식(5)는 Haar 웨이블릿 함수를 나타낸다.

$$\phi(t) = \begin{cases} 1 & t \in [0, 1) \\ 0 & t \notin [0, 1) \end{cases} \quad (4)$$

$$\Phi(t) = \begin{cases} 1 & t \in [0, 1/2) \\ -1 & t \in [1/2, 1) \\ 0 & t \notin [0, 1) \end{cases} \quad (5)$$

본 논문은 MIT-BIH 부정맥 데이터베이스에서 Haar 모함수를 사용한 이산 웨이블릿 변환 계수를 퍼지 신경망의 특징입력으로 사용한다. 스케일 레벨 1, 2 주파수 대역에서의 웨이블릿 계수들은 고주파 간섭에 의한 영향을 받고, 스케일 레벨 6 이상에서는 기저선의 변화에 의해 영향을 받기 때문에, 스케일 레벨 3, 4, 5의 웨이블릿 계수를 사용한다[5].

윈도우 사이즈를 결정하기 위해 부정맥 데이터베이스에서 MLII 리드에 대한 정상과 조기심실수축에 대한 통계를 작성한다. 그림 1은 128/360초(R파 기준 -63/360~+64/360초)의 심전도 신호를 나타낸 것으로, 정상 비트의 평균과 표준편차, PVC 비트의 평균과 표준편차이다.

그림 2는 정상 비트와 PVC 비트를 웨이블릿 변환을 통해 추출한 레벨 3, 4의 d3, d4 계수에 대한 평균과 표준편차이다. 두 그림을 분석해보면 R파를 중심으로 특징이 분포되어있음을 알 수 있다. 윈도우 사이즈는 2^n 형태로 표현되어야 하므로 64개 데이터, 즉 64/360초로 결정한다. 정확한 윈도의 범위는 R파를 기준으로 -31/360~+32/360초이다. 윈도우 설정의 결과로, d5(2개), d4(4개), d3(8개)의 웨이블릿 계수로 구성된 14개의 특징입력들을 선택한다.




그림 1. 심전도 신호의 평균과 표준 편차

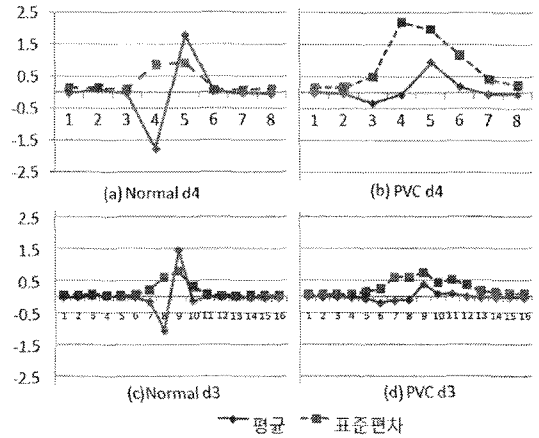


그림 2. 웨이블릿 계수의 평균과 표준 편차

2.2 가중 퍼지소속함수 기반 신경망 (Neural Network with Weighted Fuzzy Membership Functions, NEWFM)

본 논문에서는 정상 비트와 PVC 비트를 분류하기 위한 방법으로 가중 퍼지소속함수 기반 신경망을 사용한다. NEWFM은 입력으로부터 학습된 가중 퍼지소속함수의 경계합을 이용하여 클래스를 분류하는 지도(supervised) 퍼지 신경망이다[9,10]. NEWFM의 구조는 그림 3에서 보는 바와 같이 입력, 하이퍼박스, 클래스의 3개 계층으로 구성되어 있다. 입력 계층에는 n 개의 입력 노드들로 구성된다. 하이퍼박스 계층은 m 개의 하이퍼박스 노드로 구성된다. 출력 계층은 p 개의 클래스 노드들로 구성된다. 입력노드로 입력되는 h 번째 입력 패턴은 $I_h = \{A_h = (a_1, a_2, \dots, a_n)\}$, $class$ }로 기록되며 여기서 $class$ 는 분류 결과이고 A_h 는 n 개 특징입력으로 구성된다.

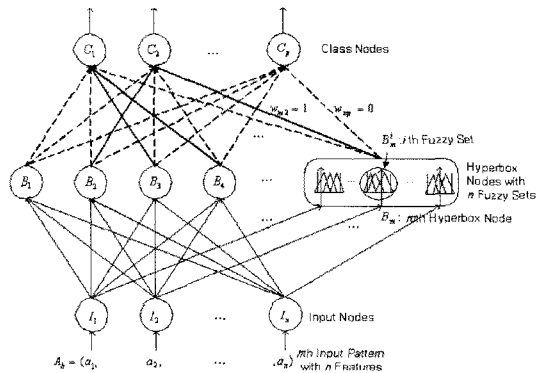


그림 3. 가중 퍼지소속함수 기반 신경망의 구조

그림 4의 v_1, v_2, v_3 는 B_i^j 로 표기되는 대, 중, 소 퍼지 소속함수의 중심위치이고 학습 시 좌우로 조정된다. 입력 a_i 는 $v_{\min} \sim v_{\max}$ 범위 안에 있다. $\mu_j(\cdot)$ 는 B_i^j 의 가중 퍼지소속함수를 나타낸다. 각 가중 퍼지소속함수 $\mu_j(\cdot)$ 의 모양은 $(v_{j-1}, 0), (v_{j-1}, 0), (v_j, W_j)$ 의 세 점으로 표현되는 삼각형이다. 여기서 W_j 는 소속함수의 가중치($0 \leq W_j \leq 1$)를 의미한다. $Adjust(B_i)$ 은 B_i 의 학습 시 입력 $A_n = (a_1, a_2, \dots, a_n)$ 에 의해 B_i 내의 B_i^j ($1 \leq i \leq n$)들을 조정하는 함수이다. a_i 를 입력받는 B_i^j 의 v_j 와 W_j 는 그림 4와 같이 a_i 에 수렴하는 방향으로 조정된다.

학습을 거친 하이퍼박스 노드 B_i 은 입력패턴을 분류하기 위한 if-then 형식의 퍼지규칙으로 사용될 수 있다. B_i^j 는 3개의 가중 퍼지소속함수($\mu_j(\cdot)$, weighted fuzzy membership functions, WFM, 그림 5의 회색 부분)로 구성된다. 그림 5의 굵은 선으로 표시된 $\mu_b^i(\cdot)$ 은 WFM의 경계합(bounded sum of WFM, BSWFM)으로써 식(6)과 같고 3개의 WFM의 퍼지




그림 4. B_i^j 의 $Adjust(B_i)$ 연산 전후의 예




그림 5. 3개 가중 퍼지소속함수의 경계합

특성을 통합하게 된다. 학습된 BSWFM $\mu_b^i(\cdot)$ 은 i 번째 입력에 대한 퍼지규칙으로 이용된다.

$$\mu_b^i(x) = \sum_{j=1}^3 B_i^j(\mu_j(x)) \quad (6)$$

3. 조기심실수축 진단 알고리즘

본 논문에서는 심전도 신호를 P-QRS-T 한 주기 단위로 분석하여 조기심실수축을 진단한다. 조기심실수축 진단 알고리즘의 개요는 그림 6에 나타나 있다. 입력된 360Hz의 심전도 신호에서 QRS를 추출하고 추출된 R파를 중심으로 윈도우를 씌운 후, 이산 웨이블릿 변환을 이용하여 특징을 추출한다. 추출된 특징 벡터는 가중 퍼지소속함수 기반 신경망을 이용하여 'Normal' 비트와 'PVC' 비트로 분류한다.




그림 6. 조기심실수축 진단 알고리즘 개요

조기심실수축 진단 알고리즘을 세부적으로 표시하면 그림 7과 같다. 그림 6의 알고리즘 개요와 연관 지어 설명하면, 'ECG' 신호가 입력되는 부분은 Step 1과 같고 'QRS 추출'은 Step 2와 같다. 여기서 사용한 QRS 추출 알고리즘은 Pan과 Tomkins의 알고리즘을 기반으로 경사면의 정보를 사용하여 개선된 알고리즘이다[15,16]. 'Wavelet'은 Step 3, Step 4와 같다. Step 3에서는 R파를 기준으로 64/360초의 데이터를 윈도우로 설정한다. Step 4에서는 설정된 윈도우 데이터를 이산 웨이블릿 변환한다. 스케일 레벨 5의 이산 웨이블릿 변환을 실행하면 $a_1 \sim a_5, d_1 \sim d_5$ 계수가 출력된다. 이 중에서 스케일 레벨 3, 4, 5의 d_3, d_4, d_5 웨이블릿 계수 14개를 추출한다. 'NEWFM'은 Step 5와 같다. 미리 학습된 가중 퍼지소속함수를 이용하여 Step 4에서 구한 14가지 특징 벡터를 이용하여 'Normal' 비트와 'PVC' 비트로 분류한다. 이러한 과정을 반복 수행하는 부분은 Step 6이다.

그림 8은 조기심실수축 진단 알고리즘에서 Inan 실험군에 사용된 14개의 웨이블릿 계수에 대한 퍼지

```

Step 1 : Read Data  $X_i$  // Data Input
Step 2 : Detect QRS $_j$  // [15][16]
if(DetectQRS( $X_i$ ))
    Case Detect QRS :  $t = i$ ;
    Go to Step 3;
    Case Not Detect QRS :
        Repeat Step 1;
Step 3 : Set Windows
 $Y_j = \{X_{t-31}, X_{t-30}, \dots, X_{t_i}, \dots, X_{t+31}, X_{t+32}\}$ ;
Step 4 : Calculate Discrete Wavelet Transform
// Using Haar
Output : Level 3. detail - 8 coefficients
        Level 4. detail - 4 coefficients
        Level 5. detail - 2 coefficients
Step 5 : Test NEWFM // see 2.2 NEWFM
// using BSWFM (see fig 8)
Input : 14 coefficients
Output : 'Normal' or 'PVC'// classifier
Step 6 : Repeat Step 1.
    
```

그림 7. 조기심실수축 진단 알고리즘

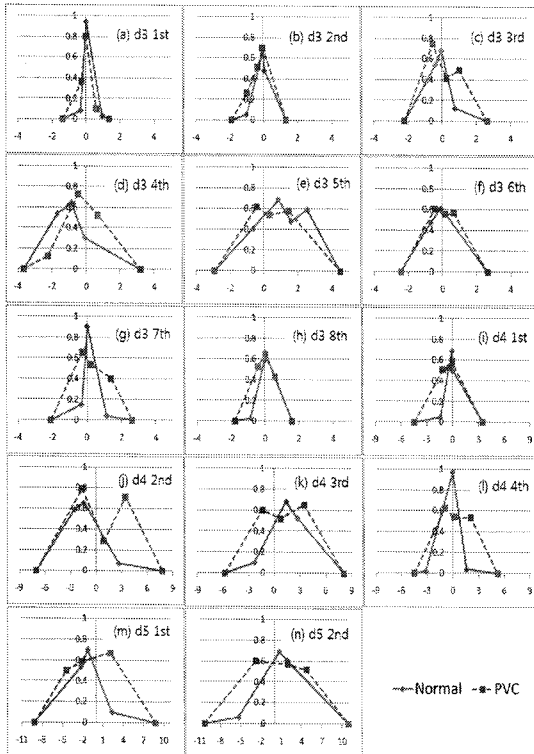


그림 8. 14개 계수에 대한 가장 퍼지소속함수의 경계합 소속함수를 보여주고 있다. 이 퍼지소속함수는 그림 5에서 언급한 가장 퍼지소속함수의 경계합 (BSWFM)을 의미한다. 이를 통해 14개 계수에 대한

시간상의 특징지점에서 'Normal' 비트와 'PVC' 비트의 차이점을 가시적으로 볼 수 있으며 이에 따른 주파수 특성 분석을 가능하게 한다. 14개의 가장 퍼지소속함수의 경계합은 그림 7의 조기심실수축 진단 알고리즘에서 Step 5 단계에서 입력되는 14개의 특징 벡터에 적용되어 결과를 출력한다.

4. 실험 및 결과 분석

본 논문에서는 알고리즘 성능 평가를 위한 벤치마킹 데이터베이스로 MIT-BIH 부정맥 데이터베이스를 사용한다. MIT-BIH 부정맥 데이터베이스는 총 48명의 환자들의 기록으로, 각각 30분이 조금 넘는 시간 동안의 심전도 데이터로 구성되어있다. 각 레코드는 2채널로 기록되었고, 샘플링 레이트(sampling rate)는 360Hz이다. MIT-BIH 부정맥 데이터베이스는 벤치마킹 데이터로 가장 많이 인용되고 있는 데이터베이스이다.

본 논문에서는 성능 평가를 위해 분류 알고리즘의 성능 평가 기준으로 사용하는 SE(sensitivity, 민감성), SP(specificity, 특이성), Accuracy(전체 분류율)를 사용한다. SE와 SP는 각각 식(7) 및 식(8)과 같고, Accuracy는 식(9)와 같다. 여기서, TP(true positive)는 정상 신호를 정상 신호로 분류되는 것을, TN(true negative)은 PVC 신호가 PVC 신호로 분류되는 것을 의미한다. 또한 FP(false positive)는 PVC 신호가 정상 신호로 분류되는 것을, FN(false negative)은 정상 신호가 PVC 신호로 분류되는 것을 의미한다.

$$SE(sensitivity) = \frac{TP}{TP + FN} \quad (7)$$

$$SP(specificity) = \frac{TN}{TN + FP} \quad (8)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

4.1 Shyu 실험군과의 비교 평가

알고리즘 성능 평가를 위해 표 1에서와 같이 Shyu [5]의 실험군을 사용한다. Shyu는 QRS 넓이와 지속 시간을 입력으로 하는 퍼지 신경망을 사용하였다. 조기심실수축 진단 알고리즘의 인식 결과는 표 2와 같다.

표 1. Shyu 실험군 (MIT-BIH 부정맥 데이터베이스)

| 레코드 | NOR | PVC | LBBB | RBBB | APC | 합계 |
|-----|-------|-----|------|------|-----|-------|
| 111 | - | 1 | 2123 | - | - | 2124 |
| 115 | 1953 | - | - | - | - | 1953 |
| 116 | 2302 | 109 | - | - | 1 | 2412 |
| 119 | 1543 | 444 | - | - | - | 1987 |
| 221 | 2031 | 396 | - | - | - | 2427 |
| 230 | 2255 | 1 | - | - | - | 2256 |
| 231 | 314 | 2 | - | 1254 | 1 | 1571 |
| 합계 | 10398 | 953 | 2123 | 1254 | 2 | 14730 |

표 2. 조기심실수축 진단 알고리즘 인식 결과

| 레코드 | TP | TN | FP | FN |
|-----|-------|-----|----|----|
| 111 | 2122 | 0 | 1 | 1 |
| 115 | 1953 | 0 | 0 | 0 |
| 116 | 2303 | 106 | 3 | 0 |
| 119 | 1543 | 444 | 0 | 0 |
| 221 | 2031 | 389 | 7 | 0 |
| 230 | 2255 | 0 | 1 | 0 |
| 231 | 1569 | 2 | 0 | 0 |
| 합계 | 13776 | 941 | 12 | 1 |

표 3. Shyu와의 분류성능 비교

| 레코드 | SE(%) | | SP(%) | | Accuracy(%) | |
|-----|-------|-------|-------|-------|-------------|-------|
| | Shyu | NEWFM | Shyu | NEWFM | Shyu | NEWFM |
| 111 | 100 | 0 | 80.55 | 99.95 | 80.56 | 99.91 |
| 115 | - | - | 99.90 | 100 | 99.9 | 100 |
| 116 | 95.41 | 97.25 | 99.69 | 100 | 99.49 | 99.88 |
| 119 | 100 | 100 | 100 | 100 | 100 | 100 |
| 221 | 98.74 | 98.23 | 99.60 | 100 | 99.38 | 99.71 |
| 230 | 100 | 0 | 99.96 | 100 | 99.96 | 99.96 |
| 231 | 100 | 100 | 100 | 100 | 100 | 100 |
| 합계 | 99.02 | 98.74 | 96.67 | 99.99 | 97.04 | 99.91 |

조기심실수축 진단 알고리즘과 Shyu와의 분류 성능 비교는 표 3과 같다. 결과적으로 14개의 특징입력으로 Shyu의 결과보다 SE는 99.02% 보다 떨어지는 98.74%이지만, SP는 96.67% 보다 높은 99.99%, Accuracy는 97.04% 보다 높은 99.91%의 분류결과를 보여주고 있다.

4.2 Inan 실험군과의 비교 평가

앞 절에서 비교 실험군으로 사용한 Shyu 실험군

은 전체 MIT-BIH 부정맥 데이터베이스 48개 레코드 중 7개만을 사용한 것으로 실험군이 적다는 한계를 지니고 있다. Shyu의 방식은 실험 레코드가 비교적 단순하여 사용된 QRS 넓이와 지속시간 퍼지소속 함수를 다른 실험군에 적용하기가 어려운 단점을 지니고 있다.

이에 비해 본 절에서 비교 실험군으로 사용할 Inan[8]의 실험군은 퍼지 신경망을 사용하지는 않았으나 40개의 레코드를 사용했다는 점에서 의미가 있다. Inan은 웨이블릿을 이용한 특징 벡터와 RR 간격 비율을 특징 벡터로 하고 하나의 은닉층을 갖는 다층 신경망을 이용하여 PVC 비트를 분류하였다. MIT-BIH 부정맥 데이터베이스는 각 레코드 당 2 리드의 데이터가 있다. Inan은 MLII 리드를 사용하여 훈련 및 테스트 하였고, 40개의 레코드 중에서 MLII가 없는 102, 104 레코드는 V5 리드를 사용하였다.

인식 결과와 분류 성능 비교는 표 4와 같다. 결과적으로 14개의 특징입력으로 Inan의 결과보다 SE는 82.57% 보다 높은 84.67%, SP는 98.33% 보다 높은 99.39%, Accuracy는 96.85% 보다 높은 98.01%의 분류결과를 보여주고 있다.

5. 결 론

본 논문은 가중 퍼지소속함수 기반 신경망과 이산 웨이블릿 변환을 이용하여 조기심실수축 자동 탐지 방안을 제안하고 있다. 제안한 진단 알고리즘은 P-QRS-T 한 주기 동안, 즉 평균 0.75초 내외의 심전도 신호를 이용하여 대표적인 부정맥인 조기심실수축 신호를 자동으로 분류하는 알고리즘이다. 제안한 조기심실수축 진단 알고리즘은 이산 웨이블릿 변환을 이용하여 특징 14개를 추출한 후에 가중 퍼지소속함수 기반 신경망으로 학습하여 정상 비트와 조기심실수축 비트를 분류하는 방법이다. 이산 웨이블릿 변환의 윈도우 크기는 R파를 기준으로 -31/360~32/360초(64개 데이터)를 사용하며, 이산 웨이블릿 변환을 사용하여 d3, d4, d5의 웨이블릿 계수 14개를 특징 벡터로 추출한다. 실험에 특징입력으로 사용된 스케일 레벨 3~5의 웨이블릿 계수는 고주파 잡음, 기저선 변화, 인위적 잡음 등에 대한 영향을 현저히 줄여준다. 제안한 조기심실수축 진단 알고리즘은 Shyu 실험군(7개 레코드)에서는 Accuracy에서

표 4. 조기심실수축 진단 알고리즘 인식 결과와 Inan과의 분류성능 비교

| 레코드 | Beat | | NEWFM | | | | SE(%) | | SP(%) | | Accuracy(%) | |
|-----|--------|------|-------|------|------|-----|-------|-------|-------|-------|-------------|-------|
| | Normal | PVC | TP | TN | FP | FN | Inan | NEWFM | Inan | NEWFM | Inan | NEWFM |
| 100 | 2,239 | 1 | 2239 | 1 | 0 | 0 | 100 | 0 | 100 | 100 | 100 | 100 |
| 101 | 1,860 | - | 1860 | 0 | 0 | 0 | - | - | 99.84 | 100 | 99.84 | 100 |
| 102 | 99 | 4 | 99 | 4 | 0 | 0 | 75 | 100 | 27.27 | 100 | 29.12 | 100 |
| 103 | 2,082 | - | 2082 | 0 | 0 | 0 | - | - | 100 | 100 | 100 | 100 |
| 104 | 163 | 2 | 161 | 1 | 1 | 2 | 50 | 50.00 | 76.69 | 98.77 | 76.37 | 98.18 |
| 105 | 2,526 | 41 | 2482 | 6 | 35 | 44 | 4.88 | 14.63 | 94.69 | 98.26 | 93.26 | 96.92 |
| 106 | 1,507 | 520 | 1506 | 295 | 225 | 1 | 89.81 | 56.73 | 99.27 | 99.93 | 96.84 | 88.85 |
| 107 | - | 59 | 0 | 59 | 0 | 0 | 94.92 | 100 | - | - | 94.92 | 100 |
| 109 | - | 38 | 0 | 35 | 3 | 0 | 65.79 | 92.11 | - | - | 65.79 | 92.11 |
| 112 | 2,537 | - | 2534 | 0 | 0 | 3 | - | - | 99.64 | 99.88 | 99.64 | 99.88 |
| 113 | 1,789 | - | 1789 | 0 | 0 | 0 | - | - | 98.26 | 100 | 98.26 | 100 |
| 114 | 1,820 | 43 | 1814 | 43 | 0 | 6 | 100 | 100 | 93.56 | 99.67 | 93.71 | 99.68 |
| 115 | 1,953 | - | 1953 | 0 | 0 | 0 | - | - | 100 | 100 | 100 | 100 |
| 116 | 2,302 | 109 | 2301 | 106 | 3 | 1 | 77.98 | 97.25 | 99.30 | 99.96 | 98.34 | 99.83 |
| 118 | - | 16 | 0 | 10 | 6 | 0 | 43.75 | 62.50 | - | - | 43.75 | 62.50 |
| 119 | 1,543 | 444 | 1543 | 444 | 0 | 0 | 100 | 100 | 100 | 100 | 100 | 100 |
| 121 | 1,861 | 1 | 1860 | 1 | 0 | 1 | 100 | 100 | 99.35 | 99.95 | 99.35 | 99.95 |
| 122 | 2,476 | - | 2466 | 0 | 0 | 10 | - | - | 100 | 99.60 | 100 | 99.60 |
| 123 | 1,515 | 3 | 1515 | 2 | 1 | 0 | 33.33 | 66.67 | 100 | 100 | 99.87 | 99.93 |
| 200 | 1,743 | 826 | 1711 | 791 | 35 | 32 | 93.94 | 95.76 | 99.20 | 98.16 | 97.51 | 97.39 |
| 201 | 1,625 | 198 | 1625 | 1 | 197 | 0 | 87.88 | 0.51 | 99.69 | 100 | 98.41 | 89.19 |
| 202 | 2,061 | 19 | 2061 | 0 | 19 | 0 | 89.47 | 0 | 99.76 | 100 | 99.67 | 99.09 |
| 203 | 2,529 | 444 | 2270 | 424 | 20 | 259 | 91.89 | 95.50 | 86.34 | 89.76 | 87.17 | 90.62 |
| 205 | 2,571 | 71 | 2571 | 69 | 2 | 0 | 100 | 97.18 | 99.84 | 100 | 99.84 | 99.92 |
| 208 | 1,586 | 992 | 1583 | 975 | 17 | 3 | 99.09 | 98.29 | 98.86 | 99.81 | 98.95 | 99.22 |
| 210 | 2,423 | 194 | 2417 | 158 | 36 | 6 | 85.05 | 81.44 | 97.73 | 99.75 | 96.79 | 98.40 |
| 212 | 923 | - | 923 | 0 | 0 | 0 | - | - | 99.02 | 100 | 99.02 | 100 |
| 213 | 2,641 | 220 | 2639 | 217 | 3 | 2 | 43.18 | 98.64 | 100 | 99.92 | 95.63 | 99.83 |
| 214 | - | 256 | 0 | 233 | 23 | 0 | 47.66 | 91.02 | - | - | 47.66 | 91.02 |
| 215 | 3,196 | 164 | 3187 | 132 | 32 | 9 | 3.05 | 80.49 | 99.66 | 99.72 | 94.94 | 98.78 |
| 217 | 244 | 162 | 244 | 149 | 13 | 0 | 91.98 | 91.98 | 96.31 | 100 | 94.58 | 96.80 |
| 219 | 2,082 | 64 | 2081 | 56 | 8 | 1 | 75.00 | 87.50 | 99.71 | 99.95 | 98.97 | 99.58 |
| 220 | 1,954 | - | 1953 | 0 | 0 | 1 | - | - | 100 | 99.95 | 100 | 99.95 |
| 221 | 2,031 | 396 | 2031 | 356 | 40 | 0 | 99.49 | 89.90 | 100 | 100 | 99.92 | 98.35 |
| 223 | 2,029 | 473 | 2023 | 187 | 286 | 6 | 40.38 | 39.53 | 99.85 | 99.70 | 88.6 | 88.33 |
| 228 | 1,688 | 362 | 1673 | 306 | 56 | 15 | 87.85 | 84.53 | 97.92 | 99.11 | 96.14 | 96.54 |
| 230 | 2,255 | 1 | 2253 | 1 | 0 | 2 | 100 | 100 | 97.69 | 99.91 | 97.69 | 99.91 |
| 231 | 314 | 2 | 314 | 2 | 0 | 0 | 100 | 100 | 100 | 100 | 100 | 100 |
| 233 | 2,230 | 831 | 2224 | 826 | 5 | 6 | 82.77 | 99.40 | 95.42 | 99.73 | 91.99 | 99.64 |
| 234 | 2,700 | 3 | 2700 | 2 | 1 | 0 | 100 | 66.67 | 99.96 | 100 | 99.96 | 99.96 |
| 합계 | 67097 | 6959 | 66687 | 5892 | 1067 | 410 | 82.57 | 84.67 | 98.33 | 99.39 | 96.85 | 98.01 |

97.04% 보다 높은 99.91%의 신뢰성 있는 결과를 나타내었고, Inan 실험군(40개 레코드)에서는 SE는 82.57% 보다 높은 84.67%, SP는 98.33% 보다 높은 99.39%, Accuracy는 96.85% 보다 높은 98.01%의 신뢰성 있는 결과를 나타내었다.

참 고 문 헌

- [1] T. H. Linh, S. Osowski, and M. Stodolski, "On-Line Heart Beat Recognition Using Hermite Polynomials and Neuro-Fuzzy Network," *IEEE Trans. on Instrumentation and Measurement*, Vol. 52, No. 4, pp. 1224-1231, 2003.
- [2] S. Osowski and T. H. Linh, "ECG Beat Recognition Using Fuzzy Hybrid Neural Network," *IEEE Trans. on Biomedical Engineering*, Vol. 48, No. 4, pp. 1265-1271, 2001.
- [3] R. Silipo and C. Marchesi, "Artificial Neural Networks for Automatic ECG Analysis," *IEEE Trans. on Signal Processing*, Vol. 46, No. 5, pp. 1417-1425, 1998.
- [4] K. Minami, H. Nakajima, and T. Toyoshima, "Real-Time Discrimination of Ventricular Tachyarrhythmia with Fourier-Transform Neural Network," *IEEE Trans. on Biomedical Engineering*, Vol. 46, No. 2, pp. 176-185, 1999.
- [5] L.-Y. Shyu, Y.-H. Wu, and W. Hu, "Using Wavelet Transform and Fuzzy Neural Network for VPC Detection from the Holter ECG," *IEEE Transactions on Biomedical Engineering*, Vol. 51, Issue 7, pp. 1269-1273, 2004.
- [6] F. M. Ham and Soowhan Han. "Classification of Cardiac Arrhythmias Using Fuzzy ARTMAP," *IEEE Trans. on Biomedical Engineering*, Vol. 43, No. 4, pp. 425-430, 1996.
- [7] C. Ramirez-Rodriguez and M. Hernandez-Silveria, "Multi-Thread Implementation of a Fuzzy Neural Network for Automatic ECG Arrhythmia Detection," *Proceedings in Computers in Cardiology 2001*, pp. 297-300, 2001.
- [8] O. T. Inan, L. Giovanrandi., G. T. A. Kovacs, "Robust Neural-network Based Classification of Premature Ventricular Contractions Using Wavelet Transform and Timing Interval features," *IEEE Transaction on Biomedical Engineering*, Vol. 53, Issue 12, pp. 2507-2515, 2006.
- [9] J. S. Lim, D. Wang, Y.-S. Kim, and S. Gupta, "A Neuro-fuzzy Approach for Diagnosis of Antibody Deficiency Syndrome," *Neurocomputing 69, Issues 7-9*, pp. 969-974, 2006.
- [10] J. S. Lim, T-W Ryu, H-J Kim, and S. Gupta, "Feature Selection for Specific Antibody Deficiency Syndrome by Neural Network with Weighted Fuzzy Membership Functions," *LNCS 3614*, pp. 811-820, Springer-Verlag, 2005.
- [11] 임준식, "가중 퍼지 소속함수 기반 신경망을 이용한 Wisconsin Breast Cancer 예측 퍼지규칙의 추출," 한국정보처리학회, 제11-B권, 제6호 pp. 717-722, 2004.
- [12] J. S. 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, 2004.
- [13] J. S. Lim and S. Gupta, "Feature Selection Using Weighted Neuro-Fuzzy Membership Functions," *The 2004 International Conference on Artificial Intelligence (IC-AI'04)*, Vol. 1, pp. 261-266, 2004.
- [14] R. Mark and G. Moody, *MIT-BIH arrhythmia Database Directory*, Mass. Inst. of Tech. (MIT), 1988.
- [15] J. Pan and W.J. Tompkins, "A Real-Time QRS Detection Algorithm," *IEEE Transactions on Biomedical Engineering*, Vol. 32, No. 3, pp. 230-236, 1985.
- [16] P. Laguna, "New Electrocardiographic Signal

Processing Techniques : Application to Long-term Records,” Ph. D. dissertation, Science Faculty, University of Zaragoza, 1990.



장 형 종

1997년 경원대학교 수학과 학사
2000년 경원대학교 대학원 전자계산학과 석사
2009년 경원대학교 대학원 전자계산학과 박사
관심분야 : 인공지능, 퍼지, 신경망



임 준 식

1986년 인하대학교 전자계산학과 학사
1989년 University of Alabama at Birmingham, Dept. of Computer Science M.S.

1994년 Louisiana State University, Dept. of Computer Science Ph.D.

1995년~현재 경원대학교 컴퓨터소프트웨어전공 교수
관심분야 : neuro-fuzzy systems, biomedical systems