

자동 조기심실수축 탐지를 위한 최소 퍼지소속함수의 추출[☆]

Minimum Fuzzy Membership Function Extraction for Automatic Premature Ventricular Contraction Detection

임 준식*

Joon-Shik Lim

요약

본 논문은 가중 퍼지소속함수 기반 신경망(neural network with weighted fuzzy membership functions, NEWFM)을 이용하여 심전도(ECG) 신호로부터 조기심실수축(premature ventricular contractions, PVC)을 자동 탐지하는 방안을 제시하고 있다. NEWFM은 MIT-BIH 데이터베이스의 부정맥 심전도를 웨이블릿 변환(wavelet transform, WT)한 계수로부터 학습하여 정상 과 PVC 과형을 구분한다. 비중복면적 분산 측정법을 적용하여 중요도가 가장 높은 웨이블릿 변환의 d3과 d4의 8개 계수를 추출하였다. 이를 특징입력을 3개의 실험군에 사용하여 각각 99.80%, 99.21%, 98.78%의 신뢰성 있는 전체분류율을 나타내었고, 이는 각 실험군에 대한 특징입력의 종속성이 적음을 보여준다. 추출된 8개 계수의 ECG 신호 구간과 퍼지소속함수를 제시함으로써 특징입력에 대한 명시적인 해석을 가능하게 하였다.

Abstract

This paper presents an approach to detect premature ventricular contractions(PVC) using the neural network with weighted fuzzy membership functions(NEWFM). NEWFM classifies normal and PVC beats by the trained weighted fuzzy membership functions using wavelet transformed coefficients extracted from the MIT-BIH PVC database. The eight most important coefficients of d3 and d4 are selected by the non-overlap area distribution measurement method. The selected 8 coefficients are used for 3 data sets showing reliable accuracy rates 99.80%, 99.21%, and 98.78%, respectively, which means the selected input features are less dependent to the data sets. The ECG signal segments and fuzzy membership functions of the 8 coefficients enable input features to interpret explicitly.

☞ Keyword : Premature Ventricular Contraction(PVC), Fuzzy Neural Networks, Wavelet Transforms, Weighted Fuzzy Membership Functions

1. 서론

심전도(electrocardiogram, ECG)는 심장근육의 수축 확장에 따른 활동 전류의 전위차를 나타낸 것으로 심근경색이나 부정맥 등 심장계의 질환을 측정하는데 사용된다. 컴퓨터를 이용하여 ECG에 나타난 심장질환을 자동 탐지 및 진단하기 위해 신경망 및 퍼지집합 이론을 결합한 적용적 의사

결정지원 툴(adaptive decision support tool)인 퍼지 신경망(fuzzy neural networks, FNN)이 제안되어 왔다[1][10][11][13]. ECG 신호의 특징을 추출하기 위해서 푸리에 변환 및 시간-주파수 분석 기법인 웨이블릿 변환(wavelet transform, WT)이 선호되고 있으며 퍼지신경망에 접목되어 심장질환 분류에 사용되고 있다[9][14]. 심장질환들 중에서도 부정 맥은 위급한 질환이며 조기심실수축(premature ventricular contractions, PVC)은 부정맥 중 가장 빈번히 나타난다. PVC는 동방결절에서 정상적인 수축을 내보내기 전에 심실내의 흥분된 세포가 심실을 직접 수축시킴으로써 발생하게 되는데 심실

* 정회원 : 경원대학교 전자거래학부 부교수
jslim@kyungwon.ac.kr

[2006/10/10 토고 - 2006/10/11 심사 - 2006/11/07 심사완료]
☆ 본 논문은 2005년도 정부재원(교육인적자원부 학술연구 조성사업비)으로 한국학술진흥재단의 지원을 받아 수행된 연구임 (KFR-2005-042-D00264)

빈맥이나 심실세동 등 위급한 부정맥을 유발하게 한다. 이러한 PVC를 자동 탐지하는 방법으로 웨이블릿 변환 계수를 특징입력으로 하는 퍼지신경망이 연구되어 왔다[2][12][14].

본 논문은 정상과 PVC를 분류하기 위하여 가중 퍼지소속함수 기반 신경망(neural network with weighted fuzzy membership functions, NEWFM)[4][6]을 이용하는 방안을 제안하고 있다. NEWFM은 아이리스(iris)[3], 위스콘신 유방암[7], 포도주[5] 등에 대한 벤치마킹 분류실험에서 최소화한 특징입력으로 해석이 가능한 퍼지규칙을 만들어준다.

Ham[2]은 2개의 LPC 계수와 평균제곱값을 입력으로 하는 fuzzy ARTMAP을 이용하여 96.995%의 PVC 분류율을 보여주었다. Shyu[14]는 QRS 넓이와 지속시간을 입력으로 하는 퍼지신경망을 사용하여 99.79%의 전체분류율을 갖는 퍼지소속함수를 제시하였다. 그러나 Ham의 방식은 해석이 가능한 규칙을 제공할 수 없으며 Shyu의 방식은 실험 레코드가 비교적 단순하여 사용된 QRS 넓이와 지속시간 퍼지소속함수를 다른 실험군에 적용하기가 어려운 단점을 지니고 있다. 따라서 일반적인 특징입력을 찾는 것과 분류를 위한 규칙이 명시적으로 나타나는 방식이 요구되고 있다.

본 논문에서는 NEWFM을 사용하여 MIT-BIH 데이터베이스[8]의 부정맥 심전도를 웨이블릿 변환한 특징입력으로부터 정상 파형과 PVC 파형을 구분한다. 비중복면적 분산측정법[5]을 사용하여 PVC 분류를 위한 중요도가 가장 높은 8개의 웨이블릿 계수를 추출하고 이들 8개 계수의 학습된 퍼지소속함수를 제시하고 있다. 추출된 8개의 특징입력이 다양한 실험군에 적용될 수 있음을 검증하기 위해 Shyu, Ham, Shyu+Ham 실험군들을 사용하였다. 그 결과 각각 99.80%, 99.21%, 98.78%의 신뢰성 있는 전체분류율을 보여주었으며, Shyu+Ham 실험군에 대한 8개 계수의 퍼지소속함수를 제시함으로써 특징입력에 대한 해석을 가능하게 하였다.

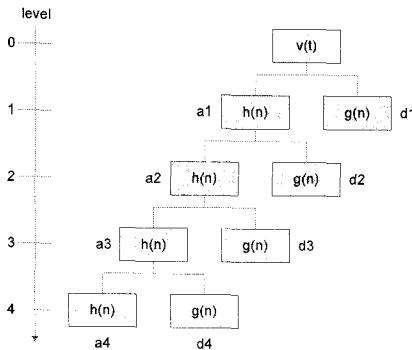
2. 웨이블릿 변환(Wavelet Transforms)

웨이블릿 변환은 신호처리에 있어서 시간상의 국소적인 특정 지점에서의 주파수 특성을 분석함으로써 전역적 주파수 특성 정보를 주는 푸리에 분석의 단점을 보완해 준다. 비연속 웨이블릿 변환은 시간-주파수 신호를 다양한 스케일의 비연속 신호로 분리해 준다. 그림 1은 이분 비연속 웨이블릿 분리 구현을 위한 필터뱅크를 보여주고 있다. detail이라고 하는 $g(n)$ 은 웨이블릿 계수와 관련된 FIR(finite impulse filters) 고대역필터(high-pass filters) 계수이고, approximation이라고 하는 $h(n)$ 은 스케일 함수 계수와 관련된 FIR 저대역필터(low-pass filters) 계수이다. 각 필터를 지나 그 길이가 반으로 감소한 $h(n)$ 신호로 다음 스케일 레벨에서 반복하여 변환 시킨다. 웨이블릿 변환으로 추출된 웨이블릿 계수는 웨이블릿 모함수(mother wavelet)에 대한 유사도로써 이는 스케일에 의해 주어진 시간에 따른 주파수 신호를 나타낸다.

본 논문은 MIT-BIH 부정맥 데이터베이스에서 Haar 모함수를 사용한 웨이블릿 변환 계수를 특징입력으로 사용하였다. 이들 중 스케일 레벨 1과 2의 주파수 대역에서의 웨이블릿 계수들은 고주파 간섭에 의한 영향을 받고 스케일 레벨 5와 6에서는 기저선의 변화에 의해 영향을 받기 때문에[14], 스케일 레벨 3과 4의 주파수 대역에서 d4(16개)와 d3(32개)의 웨이블릿 계수로 구성된 48개의 특징입력을 선택하였다. 심전도 파형의 윈도우 크기는 R파를 중심으로 100/360 초 전파 150/360 초 후까지의 250/360 초이다.

3. 가중 퍼지소속함수 기반 신경망 (Neural Network with Weighted Fuzzy Membership Function, NEWFM)

NEWFM은 입력으로부터 학습된 가중 퍼지소속함수의 경계합을 이용하여 클래스 분류를 하는

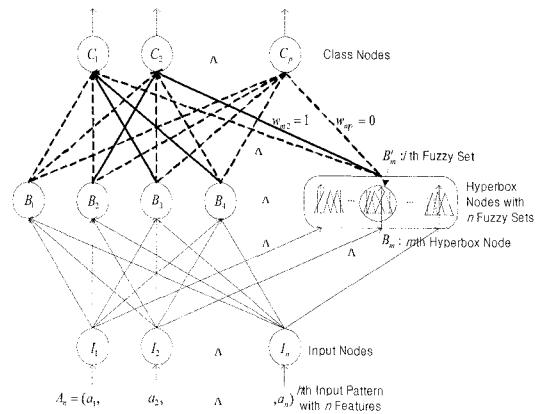


<그림 1> 스케일 레벨 4인 이분 비연속 웨이블릿 변환

supervised 퍼지 신경망이다[4][6]. 가장 퍼지소속 함수의 경계합은 가중치를 갖는 대, 중, 소의 3개 퍼지소속함수의 경계합을 하나의 퍼지소속함수로 합성한 것이다. NEWFM의 구조는 그림 2에서 보는 바와 같이 입력, 하이퍼박스, 클래스의 3 개 계층으로 구성되어 있다. 입력 계층에는 n 개의 입력노드들로 구성되며 각 입력노드는 하나의 특징 입력을 입력받게 된다. 하이퍼박스 계층은 m 개의 하이퍼박스 노드로 구성되고, i 번째 하이퍼박스 노드 B_i 은 단 하나의 클래스 노드에 연결되며 n 개의 퍼지집합을 갖는다.

B_i 의 i 번째 퍼지집합은 B_i^j 로 표시되는데 대, 중, 소로 구성된 3개의 가중 퍼지소속함수를 갖는다. 출력 계층은 p 개의 클래스 노드들로 구성되며 각 클래스 노드는 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 여기서 *class*는 분류값이고 A_h 는 n 개 특징입력으로 구성된다.

하이퍼박스노드 B_i 과 클래스노드 C_i 사이의 연결 가중치는 초기값으로 연결이 안 된 상태에서는 $w_{ii} = 0$ 이 주어지나 연결 시 $w_{ii} = 1$ 로 설정된다. B_i 과 클래스노드 C_i 를 초기에 연결하기 위해서 입력 $I_h = \{A_h = (a_1, a_2, \dots, a_n), class\}$ 에 따른 각 하이퍼박스의 *Output*(B_i) 값 중 최대값을 갖는 B_i 과 $i = class$ 인 C_i 를 선택한다. 초기 연결 이후, 입력 I_h 에



<그림 2> 가중 퍼지소속함수 신경망(NEWFM)의 구조

대해 최대값을 갖는 B_i 과 C_i 가 연결된 경우에만 B_i 이 학습된다. 함수 *Output*(B_i)은 다음과 같다.

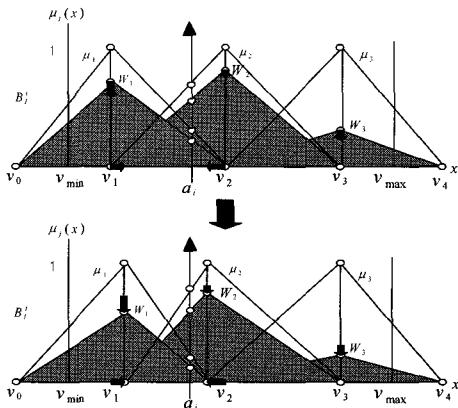
$$Output(B_i) = \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^3 B_i^j(v_j(a_i)) W_j.$$

그림 3의 v_1, v_2, v_3 는 B_i^j 로 표기되는데 대, 중, 소 퍼지소속함수의 중심위치이고 학습 시 좌우로 조정된다. v_0 와 v_4 는 일정한 값으로 고정되어 있다. 입력 a_i 는 그림 3의 $v_{min} \sim v_{max}$ 범위 안에 있다.

$\mu_j(\cdot)$ 은 B_i^j 의 가중 퍼지소속함수를 나타내며 $j=1,2,3$ 은 대, 중, 소 가중 퍼지소속함수의 인덱스를 각각 나타낸다. 각 가중 퍼지소속함수 $\mu_j(\cdot)$ 의 모양은 $(v_{j-1}, 0), (v_j, 0), (v_j, W_j)$ 의 세 점으로 표현되는 삼각형이다. 여기서 W_j 는 소속함수의 강도(strength)를 나타내는 소속함수 가중치($0 \leq W_j \leq 1$, 초기값: $0.45 \leq W_j \leq 0.55$)를 의미한다.

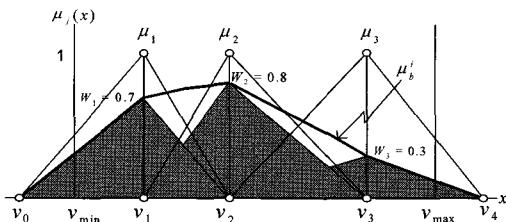
$Adjust(B_i)$ 은 B_i 의 학습시 입력 $A_h = A_h = (a_1, a_2, \dots, a_n)$ 에 의해 B_i 내의 B_i^j 들($1 \leq i \leq n$)을 조정하는 함수이다. 입력 a_i 를 받는 B_i^j 의 v_j 와 W_j ($j=1,2,3$) a_i 값에 의하여 그림 3과 같이 a_i 값에 수렴하는 방향으로 조정된다.

학습을 거친 하이퍼박스노드 B_i 은 입력패턴을 분류하기 위한 *if-then* 형식의 퍼지규칙으로 사용될 수 있다. B_i^j 는 3개의 가중 퍼지소속함수($\mu_j(\cdot)$,

〈그림 3〉 B_i^j 의 Adjust(B) 연산 전후의 예

where $j=1,2,3$, weighted fuzzy membership functions, WFM, 그림 4의 회색 부분)로 구성된다. 그림 4의 굵은 선으로 표시된 $\mu_b^i(\cdot)$ 은 WFM의 경계합(bounded sum of WFM, BSWFM)으로써 다음 식과같이 정의되며 3개의 WFM의 퍼지 특성을 통합하게 된다. 학습된 BSWFM $\mu_b^i(\cdot)$ 은 i 번째 입력에 대한 퍼지규칙으로 이용된다.

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



〈그림 4〉 3개 가중 퍼지소속함수의 경계합(BSWFM) 예 (굵은 선)

4. 실험 결과(Experimental Results)

정상과 PVC의 분류성능 평가를 위해 <표 1>에서와 같이 Shyu[14]의 MIT-BIH 실험군을 사용하였다. NEWFM은 Haar 모함수를 이용하여 웨이블릿 변환된 스케일 레벨 3과 4의 d4(16개)와 d3(32개)의 48개 웨이블릿 계수를 입력받아 학습하게

된다. 48개 웨이블릿 계수 중 중요도가 높은 특정 입력을 추출하기 위해 비중복면적 분산측정법[5]을 사용하여 최종적으로 8개의 웨이블릿 계수(d4의 5-8번째와 d3의 10-13번째 계수)를 구하게 된다. 8 개 웨이블릿 계수를 입력받아 학습된 BSWFM을 이용하여 PVC와 정상비트를 분류하게 되며 그 결과는 <표 2>에 나타나고 있다.

여기서 TP(true positive)는 정상과 RBBB 등 PVC가 아닌 비트를 PVC가 아닌 비트로 분류되는 것을, TN(true negative)은 PVC가 PVC로 분류되는 것을 의미한다. 또한 FP(false positive)는 PVC가 PVC가 아닌 비트로 분류되는 것을, FN(false negative)은 PVC가 아닌 비트가 PVC로 분류되는 것을 의미한다. SE(sensitivity)와 SP(specificity)는 $SE = TN/(TN+FP)$ 와 $SP = TP/(TP+FN)$ 으로, Accuracy(전체분류율)는 $(TP+TN)/(TP+TN+FP+FN)$ 으로 정의된다. 결과적으로 8개의 특정입력으로 Shyu의 결과보다 SE, SP, Accuracy가 모두 향상된 99.21%, 99.93%, 99.80%의 분류결과를 보여주고 있다<표 2>.

〈표 1〉 Shyu(14)의 MIT-BIH 실험군

MIT/BIH	정상(개)	PVC(개)	RBBB(개)	합계(개)
115	1953	-	-	1953
116	2302	109	-	2411
119	1543	444	-	1987
221	2031	396	-	2427
230	2255	1	-	2256
231	314	2	1254	1560
합계	10398	952	1254	12594

8개의 특정입력을 더 줄여 2개의 웨이블릿 계수(d4의 7번째와 d3의 11번째 계수)를 사용한 결과 <표 3>에서와 같이 SE, SP, Accuracy가 각각 99.21%, 99.99%, 99.86%로 8개를 사용한 결과보다

〈표 2〉 NEWFM과 Shyu(14)와의 분류성능 비교

MIT / BIH	TP	TN	FP	FN	SE(%)		SP(%)		Accuracy(%) (전체분류율)			
					NEWFM		Shyu[14]		NEWFM		Shyu[14]	
115	1947	0	0	6	-	-	99.69	99.90	99.69	99.90	-	-
116	2300	106	3	2	97.25	95.41	99.87	99.69	99.79	99.49	-	-
119	1543	444	0	0	100	100	100	100	100	100	-	-
221	2031	383	13	0	96.72	98.74	100	99.60	99.46	99.38	-	-
230	2255	0	1	0	100	100	-	99.96	99.96	99.96	-	-
231	1558	2	0	0	100	100	100	100	100	100	-	-
합계	11634	955	17	8	99.21	98.83	99.93	99.86	99.80	99.79	-	-

더 높은 분류율을 보이고 있다. 그러나 2개의 특징입력이 다른 실험군에서도 더 향상된 분류결과를 나타내지는 못한다. 〈표 4〉는 Ham[2]의 MIT-BIH 실험군을 보여주고 있으며 이 실험군을 2개의 계수(d4의 7번째와 d3의 11번째)와 8개의 계수(d4의 5-8번째와 d3의 10-13번째)를 이용하여 학습한 결과 Shyu 실험군에서와 반대로 2개의 계수를 사용한 경우 전체분류율이 99.21%에서 97.97%로 감소하고 있다<표 5>. 이는 Shyu 실험군에서 사용된 2개의 특징입력이 Shyu 실험군에 종속적임을 의미하며 8개의 특징입력이 실험군에 대한 종속성이 적음을 보여준다.

최종적으로 종속성이 적은 특징입력인 8개의 계수(d4의 5-8번째와 d3의 10-13번째)를 이용하여 Shyu와 Ham의 실험군(Shyu+Ham 실험군)을 모두 포함한 중복되지 않은 10개의 레코드(115, 116, 119, 208, 210, 221, 228, 230, 231, 233)를 사용하여 학습한 결과 〈표 5〉에서와 같이 SE, SP, Accuracy가 각각 93.53%, 99.62%, 98.78%의 분류결과를 보여주고 있다. 이는 Shyu와 Ham의 실험군에 비해서 낮은 분류율을 보이고 있지만 다른 형태의 두 실험군을 모두 사용하여 신뢰할 수 있는 98.78%의 전체분류율을 보인 점에서 그 의미가 있다. 이때 특징입력으로 사용된 8개의 웨이블릿 계수(d4의 5-8번째와 d3의 10-13번째)는 Shyu

와 Ham의 실험군에서 사용된 계수로써 PVC의 자동 탐지를 위한 일반성을 지니고 있다. 그럼 5는 Shyu+Ham 실험군에서 사용된 8개의 웨이블릿 계수에 대한 퍼지소속함수를 보여주고 있다. 이 퍼지소속함수는 그림 4에서 보여준 가중 퍼지소속함수의 경계합(BSWFM)을 의미한다. 이를 통해 8개 계수에 대한 시간상 특정지점에서 정상과 PVC 신호의 차이점을 가시적으로 볼 수 있으며 이에 따른 주파수 특성 분석을 가능하게 한다.

〈표 3〉 Shyu 실험군의 특징입력 수에 따른 NEWFM 분류성능 비교

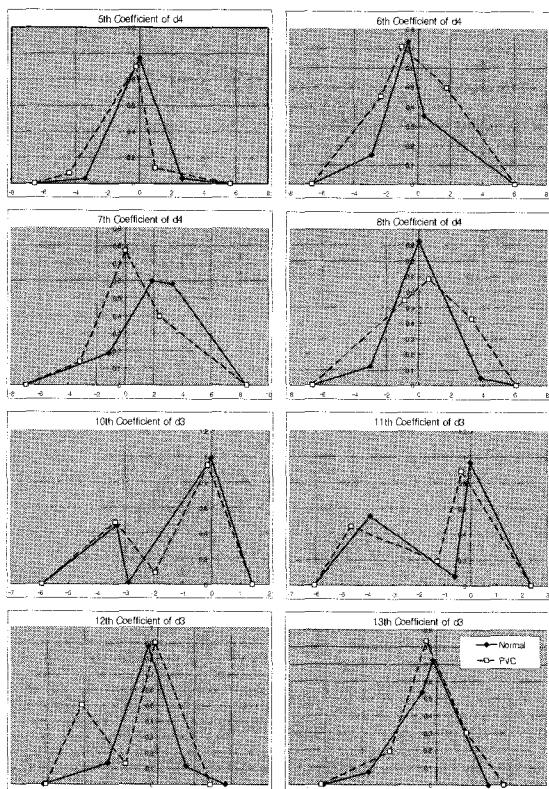
MIT/ BIH	SE(%)		SP(%)		Accuracy(%) (전체분류율)	
	특징입력 8개	특징입력 2개	특징입력 8개	특징입력 2개	특징입력 8개	특징입력 2개
115	-	-	99.69	100	99.69	100
116	97.25	97.25	99.87	99.91	99.79	99.83
119	100	100	100	100	100	100
221	96.72	96.72	100	100	99.46	99.46
230	100	100	-	-	99.96	99.96
231	100	100	100	100	100	100
합계	99.21	99.21	99.93	99.99	99.80	99.86

〈표 4〉 Ham[2]의 MIT-BIH 실험군

MIT/BIH	정상(개)	PVC(개)	합계(개)
116	2302	109	2411
208	1586	992	2578
210	2423	194	2617
221	2031	396	2427
228	1688	362	2050
233	2230	831	3061
합계	12260	2884	15144

〈표 5〉 Shyu, Ham, Shyu+Ham 실험군에 대한 NEWFM 분류성능 비교

MIT/BIH	SE(%)		SP(%)		Accuracy(%) (전체분류율)	
	특징입력 8개	특징입력 2개	특징입력 8개	특징입력 2개	특징입력 8개	특징입력 2개
Shyu Data Set	99.21	99.21	99.93	99.99	99.80	99.86
Ham Data Set	96.29	90.67	99.89	99.68	99.21	97.97
Shyu+Ham Data Set	93.53	-	99.62	-	98.78	-

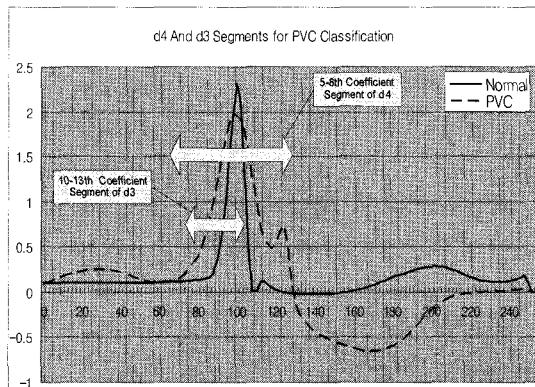


〈그림 5〉 8개 계수에 대한 기종 퍼지소속함수의 경계합(BSWFM)

5. 결 론

본 논문은 NEWFM과 웨이블릿 변환을 이용하여 PVC 자동 탐지를 위한 방안을 제안하고 있다. 실험에 특징입력으로 사용된 스케일 레벨 3(d3)과

4(d4)의 48개 웨이블릿 변환계수는 고주파 잡음, 기저선 변화, 인위적 잡음 등에 대한 영향을 현저히 줄여준다. 비중복면적 분산 측정법은 특징입력인 48개 웨이블릿 계수의 최소화를 위해 분류에 불필요하거나 악영향을 주는 특징입력을 제거하여 최소의 웨이블릿 계수 8개를 선택하여 준다. NEWFM으로 8개 계수에 대한 기종 퍼지소속함수의 경계합(BSWFM)을 구하여 PVC 분류에 사용하게 된다. 추출된 8개의 계수가 실험군에 따른 종속성 없이 PVC분류에 사용될 수 있음을 보이기 위해 Shyu, Ham, Shyu+Ham 실험군들을 8개의 계수를 이용하여 학습하였고, 각각 99.80%, 99.21%, 98.78%의 신뢰성 있는 전체분류율을 보여주고 있다. 또한 그림 5에서와 같이 Shyu+Ham 실험군에 대한 8개 계수의 퍼지소속함수를 제시함으로써 특징입력에 대한 해석을 가능하게 하였다.



〈그림 6〉 PVC 분류를 위한 d4와 d3 구간

최종적으로 NEWFM의 특징입력으로써 추출된 웨이블릿 계수는 스케일 레벨 4와 3의 detail 값들인 d4의 5-8번째와 d3의 10-13번째 계수이다. 이는 그림 6에서와 같이 100/360 초에 위치한 R파를 기준으로 할 때 d4의 65/360 - 128/360 초와 d3의 73/360 - 104/360 초 구간에 해당한다. 결과적으로 이 구간들은 QRS 콤플렉스 주변에 해당하며 PVC 분류를 위한 변별력이 가장 큰 구간이라고 할 수 있다. 또한 이 구간들은 R파를 기준으로 상대적으로 찾을 수

있으므로 QRS 콤플렉스 탐지와 동시에 PVC 분류를 가능하게 한다.

참 고 문 헌

- [1] M. Engin, "ECG beat classification using neuro-fuzzy network," Pattern Recognition Letters 25, pp. 1715-1722, 2004.
- [2] 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.
- [3] 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, Sep., 2004.
- [4] 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, March 2006.
- [5] J. S. Lim and S. Gupta, "Feature Selection Using Weighted Neuro-Fuzzy Membership Functions," The 2004 International Conference on Artificial Intelligence(IC-AI'04), June 21-24, 2004, VOL. 1, pp. 261-266, Las Vegas, Nevada, USA.
- [6] 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, Aug. 2005.
- [7] 임준식, "가중 퍼지 소속함수 기반 신경망을 이용한 Wisconsin Breast Cancer 예측 퍼지규칙의 추출," 한국정보처리학회, 제11-B권, 제6호 pp. 717-722, Oct., 2004.
- [8] R. Mark and G. Moody, "MIT-BIH arrhythmia database directory," Mass. Inst. of Tech. (MIT), 1988.
- [9] 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.
- [10] T. H. Linh, S. Osowski, and M. Stodolski, "On-Line Heart Beat Recognition Using Hermite Polynomials and Neuro-Fuzzy Networks," IEEE Trans. on Instrumentation and Measurement, VOL. 52, No. 4, pp. 1224-1231, 2003.
- [11] 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.
- [12] C. Ramirez-Rodriguez and M. Hernandaz-Silveria, "Multi-Thread Implementation of a Fuzzy Neural Network for Automatic ECG Arrhythmia Detection," Proceedings in Computers in Cardiology 2001, pp. 297-300, Sept., 2001.
- [13] 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.
- [14] 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.

● 저 자 소 개 ●



임 준 식 (Joon Shik Lim)

1986년 인하대학교 전자계산학과 졸업(학사)

1989년 Univ. of Alabama at Birmingham, Dept. of Computer Science 졸업(석사)

1994년 Louisiana State University, Dept. of Computer Science 졸업(박사)

1995년~현재 경원대학교 전자거래학부 부교수(현)

관심분야 : neuro-fuzzy systems, biomedical systems

E-mail : jslim@kyungwon.ac.kr