

# NEWFM을 이용한 자동 조기심실수축 탐지

## Automatic Premature Ventricular Contraction Detection Using NEWFM

임 준 식

Joon Shik Lim

경원대학교 전자거래학부

Department of E-Commerce Software, Kyungwon University

### 요 약

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 파형과 PVC 파형을 구분한다. 비중복면적 분산 측정법을 적용하여 중요도가 가장 높은 계수 2개를 추출하여 분류규칙을 최소화하였고, 이를 사용하여 99.90%의 PVC 분류성능을 나타내었다. 또한 추출된 두 계수의 R파를 기준으로 한 위치를 제시함으로써 두 위치의 정보만으로 PVC를 탐지할 수 있음을 보여주었다.

### 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 two most important coefficients are selected by the non-overlap area distribution measurement method to minimize the classification rules that show PVC classification rate of 99.90%. By presenting locations of the extracted two coefficients based on the R wave location, it is shown that PVC can be detected using only information of the two portions.

**Key words** : 조기심실수축(PVC), 퍼지신경망, 웨이블릿 변환, 가중 퍼지소속함수

## 1. 서 론

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 적응적 의사결정지원 툴(adaptive decision support tool)인 퍼지신경망(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 부정맥은 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 심실빈맥이나 심실세동 등 위급한 부정맥을 유발하게 한다. 이러한 PVC를 자동 탐지하는 방법으로 웨이블릿 변환 계수를 특징입력으로써 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 UCI repository of machine learning databases [<http://www.ics.uci.edu/~mllearn/MLRepository.html>]에서 신경망을 위한 벤치마킹으로 제공되는 있는 아이리스(iris)[3], 위스콘신 유방암[7], 포도주[5] 등에 대한 실험에서 현재 보고된 논문 중 가장 높은 분류성능을 보여주고 있을 뿐만 아니라 특징입력의 수를 최소화하여 분류를 위한 퍼지규칙을 단순하게 만들어준다. NEWFM은 MIT-BIH 데이터베이스[8]의 부정맥 심전도를 웨이블릿 변환한 특징입력으로부터 학습하여 정상 파형과 PVC 파형을 구분한다. 비중복면적 분산측정법[5]을 적용하여 중요도가 가장 높은 특징입력 2 개를 사용하여 학습된 가중 퍼지소속함수의 경계합을 이용하여 99.90%의 PVC 분류성능을 보여주고 있다.

접수일자 : 2006년 5월 4일

완료일자 : 2006년 6월 10일

감사의 글 : 이 논문은 2005년 산업자원부 Ubiquitous Healthcare 산업 클러스터 구축사업의 지원을 받아 수행된 연구임.

## 2. 웨이블릿 변환(Wavelet Transforms)

웨이블릿 변환은 신호처리에 있어서 시간상의 국소적인 특정 지점에서의 주파수 특성을 동시에 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 지난 신호는 그 길이가 반으로 감소하고,  $h(n)$  신호로 다시 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 변환을 통해 웨이블릿 계수를 얻어 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, 스케일 레벨 3과 4의 주파수 대역에서 d4, a4, d3의 웨이블릿 계수로 구성된 64개의 입력특징들을 선택하였다[14]. 심전도 파형의 윈도우 크기는 R파를 중심으로 100ms 전과 150ms 후까지의 250ms이다.

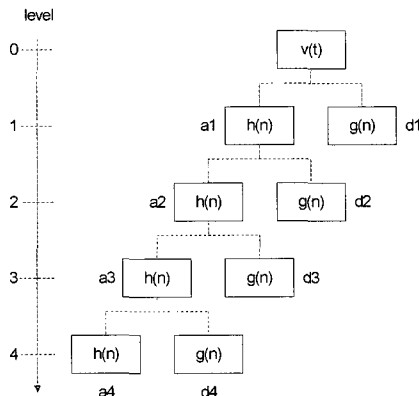


그림 1. 스케일 레벨 4인 이분 비연속 웨이블릿 변환  
Fig. 1 Dyadic Discrete Wavelet Transforms of Scale-Level 4

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

NEWFM은 입력으로부터 학습된 가중 퍼지소속함수의 경계함을 이용하여 클래스 분류를 하는 Supervised 퍼지 신경망이다. 가중 퍼지소속함수의 경계함은 가중치를 갖는 대, 중, 소의 3개 퍼지소속함수의 경계함을 하나의 퍼지소속함수로 합성한 것이다. NEWFM의 구조는 그림 2에서 보는 바와 같이 입력, 하이퍼박스, 클래스의 3개 계층으로 구성되어 있다. 입력 계층에는  $n$ 개의 입력노드들로 구성되며 각 입력노

드는 하나의 특징입력을 입력받게 된다. 하이퍼박스 계층은  $m$ 개의 하이퍼박스 노드로 구성되고,  $l$  번째 하이퍼박스 노드  $B_l$ 은 단 하나의 클래스 노드에 연결되며  $n$ 개의 퍼지집합을 갖는다.

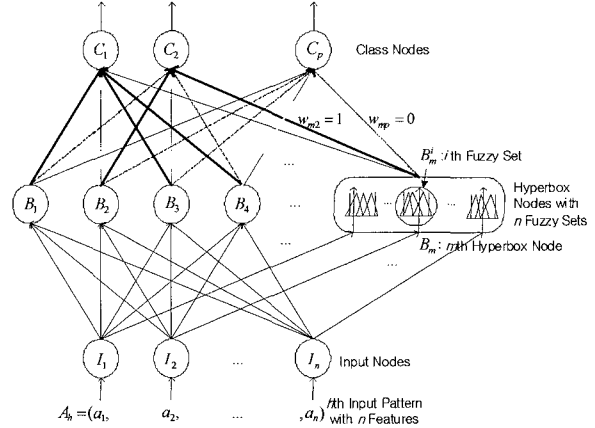


그림 2. 가중 퍼지소속함수 신경망(NEWFM)의 구조  
Fig. 2 Structure of Neural Network Weighted with Weighted Fuzzy Membership Function(NEWFM)

$B_i$ 의  $i$  번째 퍼지집합은  $B_i^j$ 로 표시되는데 대, 중, 소로 구성된 3 개의 가중 퍼지소속함수를 갖는다. 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 여기서 class는 분류값이고  $A_h$ 는  $n$ 개 특징입력으로 구성된다.

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

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

그림 3의  $v_1, v_2, v_3$ 는 대, 중, 소 퍼지소속함수의 중심위치이고 학습 수행 중에 좌우로 조정된다.  $v_0$ 와  $v_4$ 는 일정한 값으로 고정되어 있다. 입력  $a_i$ 는 그림 2의  $v_{min} \sim v_{max}$  범위 안에 있다.

$\mu_j$ 는  $B_i^j$ 의 가중 퍼지소속함수를 나타내며  $j=1, 2, 3$ 은 대, 중, 소 가중 퍼지소속함수의 인덱스를 각각 나타낸다. 각 가중 퍼지소속함수  $\mu_j$ 의 모양은  $(v_{j-1}, 0), (v_{j+1}, 0), (v_j, W_j)$ 의 3 점으로 표현되는 삼각형으로 되어있다. 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  $h$ 번째 입력패턴인  $A_h = (a_1, a_2, \dots, a_n)$ 에 의해  $B_i$  내의 대, 중, 소 퍼지소속함수와 그 가중치를 조정하는 함수이다. 입력  $a_i$ 를 받는  $B_i^j$ 의  $v_j$ 와  $W_j$ 는  $a_i$ 값에 의

하여 그림 3과 같이 입력값에 수렴하는 방향으로 조정 된다 ( $j = 1, 2, 3$ ).




그림 3.  $B_i^j$ 의 Adjust( $B_i$ ) 연산 전후의 예

Fig. 3 An Example Before and After Adjust( $B_i$ )for  $B_i^j$

학습을 거친 NEWFM은 입력패턴을 분류하기 위한 if-then 형식의 퍼지규칙으로 사용될 수 있다. 하이퍼박스노드  $B_i^j$ 의 각 퍼지집합에는 3개의 가중 퍼지소속함수 (weighted fuzzy memberships, WFM, 그림 3의 회색 부분)가 만들어진다.  $\mu_b^i(x)$ (그림 4의 굵은 선)로 표시된 WFM의 경계합(bounded sum of WFM, BSWFM)은 다음 식과같이 정의되며 그림 4에서와 같이 3개의 WFM의 퍼지 특성을 통합하게 된다. 학습된 BSWFM  $\mu_b^i(x)$ 은  $i$  번째 입력에 대한 퍼지규칙이 된다.

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




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

Fig. 4 An Example of Bounded Sum of 3 Weighted Fuzzy Membership Functions (BSWFM, Bold Line)

이와 같이  $n$ 개의 특징입력에 의해 생성된  $n$ 개의 BSWFM 들은 다시 비중복면적 분산 측정법[5]에 의하여 중요도가 낮은 특징입력을 제거함으로써 BSWFM의 수를 최소화할 수 있게 된다.

#### 4. 실험 결과 (Experimental Results)

분류 성능 평가를 위해 MIT-BIH 부정맥 데이터베이스에서 <표 1>에서와 같이 6명의 환자 레코드를 사용하였다. NEWFM의 특징입력으로 Haar 모함수를 이용해 웨이블릿

변환된 스케일 레벨 3과 4의 d4(16개), a4(16개), d3(32개)의 64개의 계수가 사용되었다. 다른 연구결과와 비교하기 위해 다음과 같이 fuzzy ARTMAP 사용한 Ham et. al.[2]의 실험 시나리오를 사용하였다. <표 2>는 NEWFM의 학습과 테스트를 위한 실험군을 나타내고 있으며, 각 실험군에 대해 세 가지 사례를 적용하여 15번의 실험을 하게 된다. 사례 1은 <표 1>에 있는 6개의 레코드 중 2개를 학습용 레코드로 선택하고 나머지 4개 레코드를 테스트용으로 사용하는 것이다. 사례 2는 3개를 학습용으로, 나머지 3개를 테스트용으로, 사례 3은 4개를 학습용, 나머지 2개를 테스트용으로 사용하는 것이다.

<표 1> MIT-BIH 부정맥 DB의 6명의 환자 레코드  
<Table 1> 6 Patient Records of MIT-BIH Arrhythmia Database

레코드 번호	정상(개)	PVC(개)	합계(개)
116	757	109	866
208	1586	992	2578
210	2423	194	2617
221	2031	396	2427
228	1688	362	2050
233	2230	831	3061
합계	10715	2884	13599

<표 2> 학습과 테스트를 위한 사례에 따른 5개 실험군  
<Table 2> 5 Sets for Each Case of Training and Test

	사례 1(레코드 번호)		사례 2(레코드 번호)		사례 3(레코드 번호)	
	Training	Test	Training	Test	Training	Test
실험군 1	208, 210	116, 221, 228, 233	208, 210, 228	116, 221, 233	208, 120, 228, 116	221, 233
실험군 2	210, 228	116, 208, 221, 233	210, 228, 221	116, 208, 233	210, 228, 221, 233	116, 208
실험군 3	228, 233	116, 208, 210, 221	228, 233, 210	116, 208, 221	228, 233, 210, 208	116, 221
실험군 4	116, 210	208, 221, 228, 233	116, 210, 228	208, 221, 233	116, 210, 228, 233	208, 221
실험군 5	116, 233	208, 210, 221, 228	116, 233, 228	208, 210, 233	116, 233, 228, 221	208, 210

아래의 식은 분류 성능 평가를 위해 사용되었으며 사용된 식들의 의미는 다음과 같다.

- NN: 정상에 대한 미분류
- NP: PVC에 대한 미분류
- FP: 정상을 PVC로 분류한 경우
- FN: PVC를 정상으로 분류한 경우
- Specificity: 정상을 올바르게 분류한 경우
- Sensitivity: PVC를 올바르게 분류한 경우

$$\text{총에러율} = \frac{FP + FN + NN + NP}{\text{No. of total tested beats}} * 100$$

$$\text{Specificity} = \frac{\text{No. of tested normal beats} - FP - NN}{\text{No. of tested normal beats}} * 100$$

$$\text{Sensitivity} = \frac{\text{No. of tested PVC beats} - FN - NP}{\text{No. of tested PVC beats}} * 100$$

$$\text{PVC분류율} = \frac{\text{No. of tested PVC beats} - FN - FP - NP}{\text{No. of tested PVC beats}} * 100$$

NEWFM을 이용한 실험에서는 먼저 64개의 웨이블릿 계수를 이용하여 실험 데이터들을 학습하게 된다. 64개의 웨이블릿 계수 중에서 비중복면적 분산측정법[5]을 통하여 점차 특징입력(웨이블릿 계수)의 수를 줄여가게 된다. 각각의 실험에서 학습이 끝난 뒤 2개의 웨이블릿 계수(d4의 4번째와 d3의 13번째 계수)에 대한 BSWFM을 이용하여 해당하는 실험군을 테스트하게 된다. 세 가지 사례에 따른 각 실험군의 분류 성능 평가 결과는 <표 3>과 같다.

<표 3> 분류 성능 평가 결과  
<Table 4> Classification Performance Results

사례	실험군	Specificity (%)	Sensitivity (%)	PVC 분류율 (%)	총 에러율 (%)
1	1	99.88	100.00	99.88	0.06
	2	100.00	100.00	100.00	0.00
	3	99.94	99.70	99.65	0.18
	4	100.00	99.96	99.96	0.02
	5	100.00	99.96	99.96	0.02
2	1	100.00	100.00	100.00	0.00
	2	100.00	100.00	100.00	0.00
	3	100.00	99.87	99.87	0.07
	4	99.86	100.00	99.86	0.07
	5	100.00	99.94	99.94	0.03
3	1	100.00	100.00	100.00	0.00
	2	99.91	99.91	99.82	0.09
	3	100.00	100.00	100.00	0.00
	4	99.93	100.00	99.93	0.04
	5	100.00	100.00	100.00	0.00

<표 4> NEWFM과 fuzzy ARTMAP과의 실험결과 비교  
<Table 4> Comparisons of Experimental Results for NEWFM with fuzzy ARTMAP

사례	Specificity(%)		Sensitivity(%)		PVC 분류율(%)		총 에러율(%)	
	NEWFM	fuzzy ARTMAP	NEWFM	fuzzy ARTMAP	NEWFM	fuzzy ARTMAP	NEWFM	fuzzy ARTMAP
1	99.96	98.994	99.92	95.773	99.89	92.030	0.06	1.605
2	99.99	99.734	99.92	96.294	99.91	95.629	0.04	1.050
3	99.99	99.875	99.92	97.425	99.91	96.995	0.04	1.671

NEWFM과 fuzzy ARTMAP의 실험결과 비교는 <표 4>에서와 같이 모든 항목에서 NEWFM이 fuzzy ARTMAP보다 우수한 성능을 보여주고 있다. 세 가지 사례에 대한 평균으로 specificity는 99.98%, sensitivity는 99.92%, PVC 분류율은 99.90%, 총 에러율은 0.05%를 나타냈다. 이는 fuzzy ARTMAP의 각각의 평균값인 99.868%, 96.497%, 94.885%, 1.442%와 비교하여 모두 향상된 결과를 보여준다.

PVC의 자동 탐지를 위해서 실험에 사용된 6개의 레코드 전체를 대상으로 탐지하는 퍼지규칙을 만들어 평가할 필요가 있다. <표 5>는 실험에 사용된 6개의 레코드 전체에 대해 정상과 PVC를 탐지한 결과를 보여주고 있다. 이를 위해 6개 레코드의 PVC 비트 2884개와, 정상 비트 중에서 임의로 2884개를 선택하여 총 5768개의 비트를 가지고 실험을 하였다. 임의로 정상 비트의 50%인 1442개와 PVC 1442개 비트를 합한 2884개 비트를 학습 데이터로 구성하였고 나머지 50%인 2884개를 테스트 데이터로 구성하였다. 실험 결과

99.86%의 PVC 분류 성능을 보여주고 있다. 이러한 <표 4>에서 보여준 99.90%와 거의 같으며 이는 다른 형태(morphology)의 환자에게도 적용될 수 있음을 보여준다.

<표 5> 전체 6개 레코드에 대한 NEWFM의 PVC 분류 성능 평가

<Table 5> Classification Performance Results of NEWFM for All 6 Records

레코드 수	Specificity (%)	Sensitivity (%)	PVC 분류율(%)	총 에러율(%)
6	99.86	100.00	99.86	0.07

#### 4. 결 론

본 논문은 NEWFM과 웨이블릿 변환을 이용하여 PVC 자동 탐지를 위한 방안을 제안하고 있다. 실험에 특징입력으로 사용된 스케일 레벨 3과 4의 웨이블릿 변환계수는 고주파 잡음, 기저선 변화, 인위적 잡음 등에 대한 영향을 현저히 줄여준다. NEWFM으로 추출된 가중 퍼지소속함수의 경계함(BSWFM)에 의한 분류율에 있어서 2개의 웨이블릿 계수만 사용하여 99.90%의 분류율을 보여주고 있다. 비중복면적 분산 측정법은 특징입력인 64개 웨이블릿 계수의 최소화를 위해 분류에 불필요하거나 악영향을 주는 특징입력을 제거하여 최적의 웨이블릿 계수 2개를 선택하여 준다.

최종적으로 NEWFM의 특징입력으로써 추출된 웨이블릿 계수는 스케일 레벨 4와 3의 detail 값들인 d4의 4번째와 d3의 13번째 계수이다. 이는 100ms에 위치한 R파를 기준으로 49-64ms와 97-104ms 해당하는 위치이다. 이 웨이블릿 계수들은 detail에 해당하므로 해당 구간들의 변동을 의미한다. 결과적으로 이 구간들은 각각 정상신호의 P파와 R파에 해당하며 PVC와의 변별력이 가장 큰 구간이라고 할 수 있다. 또한 이 구간들은 R파를 기준으로 상대적으로 찾을 수 있으므로 ECG의 환경이나 환자의 형태(morphology)에 따른 영향을 줄여준다. 또한 전체 레코드에 대한 99.86%의 분류율은 <표 4>에서 보여준 99.90%와 거의 같으므로 추출된 두 계수에 대한 BSWFM은 다른 다양한 형태(morphology)의 환자에게도 큰 차이 없이 적용될 수 있음을 나타낸다.

#### 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," FSKD 2005 (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. Hernandez-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



**임준식(Joon Shik Lim)**

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 전자거래학부 부교수(현)

관심분야 : neuro-fuzzy systems, biomedical systems

e-mail : jslim@kyungwon.ac.kr