

웨이블릿 변수화의 최적화를 통한 적응형 조기심실수축 검출 알고리즘

김진권, 강대훈, 이명호
연세대학교 전기전자공학과

An Adaptive Classification Algorithm of Premature Ventricular Beat With Optimization of Wavelet Parameterization

Jin-Kwon Kim, Dae-Hoon Kang, Myoung-ho Lee

Department of Electrical and Electronic Engineering, Yonsei University
(Received February 16, 2009. Accepted June 18, 2009)

Abstract

Abstract - The bio signals essentially have different characteristics in each person. And the main purpose of automatic diagnosis algorithm based on bio signals focuses on discriminating differences of abnormal state from personal differences. In this paper, we propose automatic ECG diagnosis algorithm which discriminates normal heart beats from premature ventricular contraction using optimization of wavelet parameterization to solve that problem. The proposed algorithm optimizes wavelet parameter to let energy of signal be concentrated on specific scale band. We can reduce the personal differences and consequently highlight the differences coming from arrhythmia via this process. The proposed algorithm using ELM as a classifier show high discrimination performance between normal beat and PVC. From the experimental results on MIT-BIH arrhythmia database the performances of the proposed algorithm are 98.1% in accuracy, 93.0% in sensitivity, 96.4% in positive predictivity, and 0.8% in false positive rate. This results are similar or higher then results of existing researches in spite of small human intervention.

Key words : Premature Ventricular Beat, Wavelet Parameterization, arrhythmia classification, ECG

1. 서론

생체 데이터를 기반으로 한 질병 자동진단에 관한 연구는 매우 오랜 역사를 가지고 있다. e-Health의 확산으로 인한 생활형 의료기기의 등장과 다양한 생체 데이터 획득 모듈의 보급은 생체 데이터 자동처리의 필요성을 높이고 있고[1,2], 특히 부정맥의 경우 장기간의 데이터를 기반으로 판독을 해야 하기에 자동 진단 알고리즘의 연구가 가장 활발한 분야이다. 심전도 기반의 부정맥 분류 알고리즘에 대한 연구는 지난 수십 년에 걸쳐 많은 방법으로 이루어져 왔으며, 다양한 신호처리 기법의 도입을 통해 높은 성능을 보이고 있다. 하지만 높은 성능을 보임에도 불구하고 연구의 결과들이 실용에 널리 적용되지 못하고 있다. 이는 생체 데이터의 고유한 특징인 개인 간의 차이가 매우 크기 때문이며, 이런 변동을

신뢰성 있게 처리해 줄 수 있는 자동진단 알고리즘이 아직 없기 때문이다.

생체데이터를 학습시켜 자동 진단을 수행하는 알고리즘 개발 연구에 있어서 알고리즘에 대한 성능 평가를 수행하는 것은 매우 중요한 작업이다. 심전도를 기반으로 한 부정맥 분류 알고리즘 연구 분야의 경우 지금까지의 대부분의 연구들이 알고리즘의 학습 데이터집합과 훈련데이터집합의 대상(환자) 분류를 하지 않고 알고리즘을 개발해왔다. 학습데이터집합과 훈련데이터집합에 서로 같은 데이터가 겹치지 않는다고 할지라도 같은 대상에서 나온 데이터를 포함시킬 경우 해당 대상의 정상 심박과 비정상 심박의 특징을 알고리즘이 학습하기 때문에 높은 성능을 나타낸다. 이와 같은 환경에서 최근 발표되고 있는 연구들의 결과는 95% 이상의 정확도를 보이고 있다[3-5]. 그러나 부정맥 분류 알고리즘을 실제 응용에서 개발하는 경우 모든 사람의 심전도 데이터베이스를 보유하고 개발할 수 없기 때문에 학습과정에 포함이 되지 않은 대상의 심전도를 분석하게 된다. 최근에 이르러 실제 환경과 유사한 조건에서 평가를 수행하기 위해 학습데이터그룹과 훈련데이터그룹 사이에 대상

Corresponding Author : 이명호
서울특별시 서대문구 신촌동 연세대학교 연세공학원 212C호
Tel : +82-2-2123-4947 / Fax : +82-2-312-2770
E-mail : mhlee@yonsei.ac.kr
본 연구는 지식경제부 및 정보통신연구진흥원의 IT핵심기술개발사업의 일환으로 수행하였음
[2005-S-093-04, 생체신호처리기반 Implantable System 개발]

을 구별하여 연구를 수행한 결과들이 발표되고 있다[6,7]. 표면적인 성능에 있어 이전 연구들과 비교해 상당히 낮은 성능을 나타내고 있으나 더 실제 환경에 적합한 평가를 거쳤다고 할 수 있다. 이와 같은 성능하락은 생체데이터의 특징에 기인한 것이다. 생체데이터는 대상에 따라 다양한 특징을 갖고 있으며, 특히 심전도의 경우 대상 인식[8]에 까지 사용될 만큼 사람 간의 파형 차이가 뚜렷한 생체데이터이다. 부정맥 분류 알고리즘은 사람의 차이로 인한 신호의 차이는 무시하고, 부정맥으로 인한 신호의 차이를 인식하여 판별해야하나 각 개인의 심전도가 워낙 다양하여 이로 인해 오분류가 발생하기 때문에 성능하락이 나타나게 된다. 심전도 분류 알고리즘은 부정맥의 진단 정확도와 다양한 사람에게의 사용 범용성 (일반화 성능, generalization performance) 사이에 교환관계를 갖고 있다.

성능하락을 보정하기 위해 다양한 방법들이 제시되고 있으며, 대표적인 접근방법이 적응 알고리즘이다. 적응 알고리즘은 개별 적용 대상에 알고리즘이 적응 단계를 거쳐 해당 환자에게 적합한 분류를 수행할 수 있도록 알고리즘을 수정한다. Philip de Chazal[7]은 환자에 특화된 local classifier를 도입하여 global classifier의 정확성을 높이하고자 했다. 이 방법의 경우 의사가 초기 환자의 데이터를 직접 검증하여 이를 기반으로 local classifier를 학습시켜 성능을 향상시켰다. Christov[9]의 역시 이와 같은 local classifier 방식을 도입해 78.3%의 specificity와 81.6%의 sensitivity를 갖는 global classifier의 성능을 각각 97.7%, 97.3%까지 개선시켰다.

본 연구에서는 웨이블릿 변수화(Wavelet Parameterization)를 기반으로 각 적용 대상에 분류알고리즘을 적응시키는 새로운 기법을 제안한다. 웨이블릿은 다양한 기본웨이블릿(wavelet)을 사용하여 시주파수 분석을 할 수 있도록 함을 장점으로 하는 신호처리 기법이다. 기본웨이블릿이 다양하기 때문에 응용에 따라 이미 최적 웨이블릿을 찾기 위한 평가연구들이 많이 진행이 되어왔으며 심전도 기반의 부정맥 분류 연구 분야도 마찬가지이다. 그러나 기존의 연구들은 널리 알려진 몇몇 특성이 좋은 기본웨이블릿을 대상으로 평가를 진행해왔다[10]. 반면 웨이블릿 변수화를 사용할 경우 특정 길이의 모든 직교기본웨이블릿을 대상으로 최적화를 수행할 수 있다. 웨이블릿 변수화를 이용한 생체데이터 처리에 관한 연구는 M.F. Lucas에 의한 2008년 근전도 분석 연구[11]와 Brechet에 의한 2007년 생체데이터 압축 연구[12]에 있어 수행되어 왔으나 심전도 기반의 부정맥 분류에 관한 연구는 수행된바 없다[13].

II. 이론적 배경

A. 웨이블릿 변수화(Wavelet Parameterization)

일반적으로 웨이블릿을 사용하여 부정맥을 분류하는 알고리즘의 경우 RR 간격 등의 시간 특징정보와 웨이블릿으로 분석한 심박

신호의 파형(morphology) 특징정보를 통하여 특징벡터를 구성한다. 본 연구에서는 대상에 따라 서로 다른 최적화된 기본웨이블릿을 사용하여 심박의 파형의 대상 간 차이를 줄이는 점을 특징으로 한다. 최적 기본웨이블릿을 탐색하기 위해 웨이블릿 변수화 기법을 사용하였다.

이산웨이블릿변환(Discrete Wavelet Transform : DWT)에서 신호는 기본웨이블릿 ψ 의 확장이나 수축 혹은 시간 영역에서의 이동으로 나타내어지는 기반함수(basis function)와의 내적으로 표현된다. 직교 다중해상도분석(MultiResolution Analysis : MRA)의 경우 어떤 신호와 기반함수의 내적은 scaling 함수 φ , 웨이블릿 함수 ψ 와 밀접한 연관을 갖는 저역통과필터(scaling 필터) h 와 고역통과필터 (웨이블릿 필터) g 를 사용하여 계산한다. Scaling 함수 φ 와 scaling 필터 h , 웨이블릿 함수 ψ 와 웨이블릿 필터 g 의 관계식은 Eq.[1], Eq[2]와 같다.

$$\varphi(t/2) = \sqrt{2} \sum_n h[n] \varphi(t-n) \tag{1}$$

$$\Psi(t/2) = \sqrt{2} \sum_n g[n] \varphi(t-n) \tag{2}$$

필터 g 는 필터 h 로부터 유도되며, 그 관계식은 $g[k] = (-1)^{1-k} h[1-k]$ 이다. 또한 재구성 필터 \tilde{h} 와 \tilde{g} 도 h 로부터 유도된다. 따라서 h 를 결정하면 전체 다중해상도분석 시스템을 결정할 수 있게 된다. Scaling 필터 h 의 계수의 수가 L 인 경우 scaling 함수의 존재성과 직교성을 보장하기 위해 아래의 식을 만족해야 한다. Equation [3]을 만족시키는 $L/2 - 1$ 개의 계수를 결정함으로써 직교기본웨이블릿을 결정한다.

$$\sum_{n=1}^L h[n] = \sqrt{2} \tag{3}$$

$$\sum_{n=1}^L h[n] \cdot h[n-2k] = 0, \quad \text{for } 1, \dots, L/2-1 \tag{4}$$

본 논문에서는 scaling 필터 h 의 길이 L 을 6으로 사용했으며, 이 경우 변수벡터 θ 는 두 변수 α 와 β 를 갖고 다음과 같은 형태로 h 를 유도한다[14].

$$\begin{aligned} h(0) &= [(1 + \cos(\alpha) + \sin(\alpha)) \\ &\quad (1 - \cos(\beta) - \sin(\beta)) + 2\sin(\beta)\cos(\beta)] / (4\sqrt{2}) \\ h(1) &= [(1 - \cos(\alpha) + \sin(\alpha)) \\ &\quad (1 + \cos(\beta) - \sin(\beta)) - 2\sin(\beta)\cos(\beta)] / (4\sqrt{2}) \\ h(2) &= [1 + \cos(\alpha - \beta) + \sin(\alpha - \beta)] / (2\sqrt{2}) \\ h(3) &= [1 + \cos(\alpha - \beta) - \sin(\alpha - \beta)] / (2\sqrt{2}) \\ h(4) &= 1/\sqrt{2} - h(0) - h(2) \\ h(5) &= 1/\sqrt{2} - h(1) - h(3) \end{aligned} \tag{5}$$




그림 1. 길이 6인 웨이블릿 변수화의 α, β 의 변화에 따른 기본웨이블릿의 예시, (a)는 Haar 웨이블릿, $\alpha=\beta$, (b)는 $\alpha=4.7124, \beta=0.94248$, (c)는 Daubechies 2와 유사한 기본웨이블릿, $\alpha=4.7124, \beta=5.3407$, (d)는 Daubechies 3와 유사한 기본 웨이블릿, $\alpha=1.3598, \beta=-0.7821$, (e)는 Coiflet과 유사한 기본 웨이블릿, $\alpha=5.3407, \beta=5.969$, (f)는 biorthogonal 1.3과 유사한 기본웨이블릿, $\alpha=4.0841, \beta=4.3982$, x축은 시간 축을 y축은 진폭을 의미.

Fig. 1. The examples of mother wavelet based upon changing α, β in wavelet parameterization, (a) is Haar wavelet, $\alpha=\beta$, (b) is $\alpha=4.7124, \beta=0.94248$, (c) is similar to Daubechies 2, $\alpha=4.7124, \beta=5.3407$, (d) is similar to Daubechies 3, $\alpha=1.3598, \beta=-0.7821$, (e) is similar to Coiflet, $\alpha=5.3407, \beta=5.969$, (f) is similar to biorthogonal 1.3, $\alpha=4.0841, \beta=4.3982$

위의 Eq.[5]에서 α 와 β 는 각도의 변수이므로 π 에서 $-\pi$ 범위의 탐색을 통해 다양한 직교기본웨이블릿을 얻을 수 있게 된다. 아래의 그림 1는 α 와 β 를 변경하며 얻어진 기본웨이블릿들의 예시이며, 흔히 사용되는 Haar, Daubechies, Coiflet 등의 기본웨이블릿도 웨이블릿 변수화 과정을 통해 얻을 수 있음을 보여준다. 최적의 기본웨이블릿의 선정은 해당 응용의 기준함수를 만족시키는 변수벡터 $\theta = [\alpha, \beta]$ 가 된다.

B. Extreme Learning Machine

일반적으로 다층신경망은 역전파학습법(Backpropagation algorithm)과 같은 경사강하기법에 기반을 둔 학습알고리즘으로 학습을 진행하나, 느린 학습 속도, 지역최소점(local minima)으로의 수렴 가능성, 초과학습으로 인한 일반적인 데이터 분류 성능의 저하 가능성을 단점으로 갖는다. G. B. Huang[15]의 Extreme Learning Machine(ELM)은 위의 경사강하기법의 학습알고리즘의 한계를 극복한 새로운 다층신경망의 학습기법이다. 은닉층을 하나만을 갖는 다층신경망(Single hidden Layer Feedforward Neural network : SLFN)에 특화된 학습알고리즘으로 훈련데이터를 기반으로 학습하지 않고 최적 연결강도와 바이어스를 계산해

내는 특징을 갖는다.

입력 데이터가 N sample을 갖고, 은닉층의 뉴런의 개수가 \tilde{N} 개 라면, SLFN의 인공 신경망 시스템에 대한 방정식 모델은 아래와 같다.

$$\sum_{i=1}^{\tilde{N}} \beta_i g_i(\bar{x}_j) = \sum_{i=1}^{\tilde{N}} \beta_i g(\bar{w}_i \cdot \bar{x}_j + b_i) = \bar{t}_j, \quad (6)$$

$$j = 1, \dots, N$$

위의 Eq.[6]에서 \bar{w}_i 은 입력층과 은닉층 i 번째 뉴런의 연결강도 벡터, b_i 는 은닉층 i 번째 뉴런의 바이어스 값, \bar{x}_j 가 j 번째 입력 데이터 벡터, $g(\cdot)$ 는 은닉층 뉴런의 활성화 함수, β_i 은 은닉층 i 번째 뉴런과 출력층의 연결강도 벡터, \bar{t}_j 은 j 번째 입력 데이터에 대한 목표 분류 값이다.

Equation[6]에서 $g(\bar{w}_i \cdot \bar{x}_j + b_i)$ 은 은닉층 i 번째 뉴런의 출력 값으로 \bar{w}_i 과 b_i 을 임의의 값으로 고정시킬 경우 각 입력 \bar{x}_j 에 대해서 상수 행렬을 얻게 된다. 이 은닉층 뉴런의 출력 행렬을 \bar{H}

로 대체하면 Eq.[6]을 아래의 Eq.[7]으로 변환할 수 있다.

$$\begin{aligned} \bar{H} \cdot \bar{\beta} &= \bar{T} \\ \bar{H}(\bar{w}_1, \dots, \bar{w}_{\tilde{N}}, b_1, \dots, b_{\tilde{N}}, \bar{x}_1, \dots, \bar{x}_N) &= \\ \begin{bmatrix} g(\bar{w}_1 \cdot \bar{x}_1 + b_1) \cdots g(\bar{w}_{\tilde{N}} \cdot \bar{x}_1 + b_{\tilde{N}}) \\ \vdots \cdots \vdots \\ g(\bar{w}_1 \cdot \bar{x}_N + b_1) \cdots g(\bar{w}_{\tilde{N}} \cdot \bar{x}_N + b_{\tilde{N}}) \end{bmatrix} & \quad (7) \\ \bar{\beta} = \begin{bmatrix} \bar{\beta}_1^T \\ \vdots \\ \bar{\beta}_N^T \end{bmatrix} \text{ and } \bar{T} = \begin{bmatrix} \bar{t}_1^T \\ \vdots \\ \bar{t}_N^T \end{bmatrix} \end{aligned}$$

Equation[7]에서 목표 분류 벡터 값 \bar{T} 와 은닉층 뉴런의 출력 행렬 \bar{H} 는 선형 시스템을 구성하고 있으며, 인공 신경망의 학습 과정이 최적 $\bar{\beta}$ 를 탐색하는 과정으로 축소된다.

일반적인 경사강하법을 이용한 인공신경망 학습 방식의 경우, 아래 Eq.[8]과 같이 목표 분류 벡터 값 \bar{T} 와 최소 거리를 갖는 $\bar{w}_i, \bar{b}_i, \bar{\beta}$ 를 탐색한다. Eq.[9]와 같이 탐색은 훈련 에러함수의 변화량을 뉴런사이의 연결강도에 반영하는 것으로 수행된다.

$$\begin{aligned} \|\bar{H}(\hat{w}_1, \dots, \hat{w}_{\tilde{N}}, \hat{b}_1, \dots, \hat{b}_{\tilde{N}}) \hat{\beta} - \bar{T}\| &= \\ \min_{\bar{w}_i, \bar{b}_i, \bar{\beta}} \|\bar{H}(\bar{w}_1, \dots, \bar{w}_{\tilde{N}}, b_1, \dots, b_{\tilde{N}}) \bar{\beta} - \bar{T}\| & \quad (8) \end{aligned}$$

$$\bar{W}_{k+1} = \bar{W}_k - \eta \frac{\partial J(\bar{W})}{\partial \bar{W}} \quad (9)$$

반면에, ELM은 Eq.[10]과 같이 $\bar{\beta}$ 의 탐색함으로써 목표 분류 벡터 값 \bar{T} 와 최소 거리를 찾고, 이 과정은 Eq.[11]과 같이 \bar{H} 의 Moor-Penrose Generalized Inverse를 사용하여 계산한다.

$$\begin{aligned} \|\bar{H}(\hat{w}_1, \dots, \hat{w}_{\tilde{N}}, \hat{b}_1, \dots, \hat{b}_{\tilde{N}}) \hat{\beta} - \bar{T}\| &= \\ \min_{\bar{\beta}} \|\bar{H}(\bar{w}_1, \dots, \bar{w}_{\tilde{N}}, b_1, \dots, b_{\tilde{N}}) \bar{\beta} - \bar{T}\| & \quad (10) \end{aligned}$$

$$\hat{\beta} = \bar{H}^\dagger \bar{T} \quad (11)$$

\bar{H} 의 Moor-Penrose Generalized Inverse를 사용하여 계산함으로써 은닉층과 출력층의 최적 연결강도 $\hat{\beta}$ 는 선형 시스템의 Minimum norm least-squares solution을 갖게 되는데 이를 통해서 얻을 수 있는 효과는 두 가지가 있다.

첫 번째는 일반적인 인공 신경망의 응용에서 훈련 데이터의 수 N 는 은닉 뉴런의 수 \tilde{N} 보다 훨씬 큰 경우가 대부분이다. 이때 $N \times \tilde{N}$ 행렬 형인 \bar{H} 은 비특이 행렬(singular matrix)이며, 정사각 행렬이 아니기 때문에 오차가 없는 $\bar{H} \cdot \bar{\beta} = \bar{T}$ 형의 해 $\hat{\beta}$ 을 유

도할 수 없다. 때문에, 오차 $\|\bar{H} \hat{\beta} - \bar{T}\|$ 을 최소화 하는 최적 $\hat{\beta}$ 을 유도하여야 한다. \bar{H} 의 Moor-Penrose Generalized Inverse를 통해 유도한 $\hat{\beta}$ 은 least-squares solution이기 때문에 최소 에러를 유도할 수 있다.

또한 Barlett[16]의 연구에 따르면, 연결 강도의 크기가 작을수록 일반적 데이터 분류 성능이 높은 것으로 나타났다. 이는 최적 $\hat{\beta}$ 값이 최소 에러를 갖는 least-squares solution 중 가장 최소의 연결 강도 크기를 갖는 minimum norm 값을 갖기 때문에 역전파 신경망 알고리즘 보다 높은 일반적 데이터 분류 성능을 갖게 된다.

III. 제안 알고리즘의 구성

제안 알고리즘은 심전도 신호의 분할(segmentation)을 수행하는 전처리단, 웨이블릿 변수화를 통해 최적 기본웨이블릿을 탐색하는 최적화단, 탐색된 기본 웨이블릿을 사용하여 심전도 판별의 특징벡터(feature vector)를 계산하는 특징점 추출단, 그리고 판별단으로 구성되어 있다. 전체 알고리즘의 구성은 아래의 그림 2에 제시하였다.

전처리단에서는 판별의 대상이 되는 심전도 신호의 부분을 선택하여 분할을 수행한다. 심전도는 주요 구성 요소로 P파, QRS파, S파로 한 박동을 구성하며, 이 각 구성파를 모두 포함하게 하기 위해 심전도 신호의 분할은 R peak를 중심으로 0.2초 이전 신호부터 0.3초 이후 신호까지 0.5초(180 sample) 신호를 추출하였다. R peak의 검출은 본 논문에서는 수행하지 않고 본 논문 개발의 데이터베이스로 사용한 MIT-BIH 부정맥 데이터베이스의 주석을 따랐다. 전처리단에서 주로 수행되는 필터링은 후의 특징점 추출단에서 웨이블릿 변환을 통해 관심 주파수 대역의 정보만을 활용하기 때문에 수행하지 않았다. 데이터베이스에서 판별 대상 심박은 정상심박과 PVC 만을 선정하였다. 위 두 대상 심박만을 선정한 이유는 두 가지이다. 첫 번째 이유는 PVC가 부정맥 중 가장 위험한 부류인 심실세동과 심실빈맥의 지표가 되는 비정상 심박이기 때문에 검출 필요성이 가장 높다. 또한, 지금까지의 심전도 기반 부정맥 자동분류 연구에서 웨이블릿 분석법은 웨이블릿 계수를 이용하여 심전도 파형의 특징을 잘 표현하는 방식을 찾는 것에 맞추어져 있었는데, 심방성 부정맥은 정상심박과 파형차이가 크지 않고, 심실성 부정맥은 정상심박과 차이가 크다. 즉, 웨이블릿 분석법은 부정맥 분류 연구에서 심실성 부정맥을 찾아내는 부분에 주로 사용된다. 본 연구의 목적이 파형의 특징 중 대상 차이에 의한 특징은 제거하고 부정맥 특징에 의한 것만 부각시키는 것이므로, 대표적인 심실성 부정맥인 PVC를 대상으로 하였다.

최적화 과정에는 최적화의 기준이 될 수 있는 조건(Optimization criterion function)이 필요하다. 본 연구에서는 웨이블릿 변수화를 통한 최적화 탐색 조건으로 6가지를 평가하였다. 우선 최적화에 들어가기 전에 각 환자에 대한 적응 알고리즘을 구성하기 위해 환자의 특징을 대표할 심박을 선정하여야 한다(Template 선정).

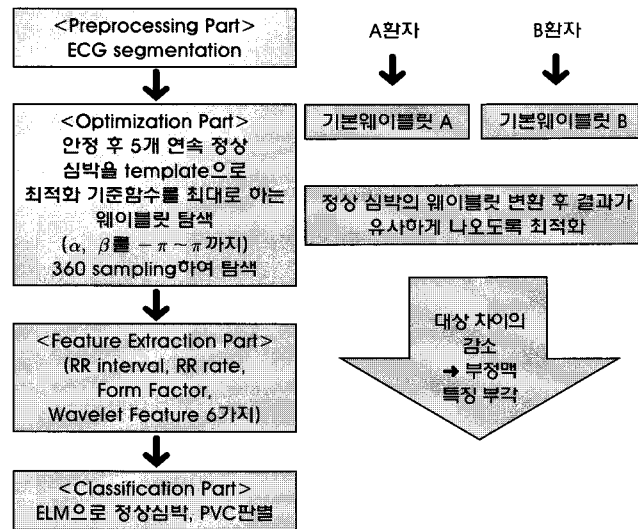


그림 2. 제안 알고리즘의 구성 블록선도
 Fig. 2. The block diagram of proposed algorithm

이는 환자의 특징을 대표할 심박을 대상으로 최적화 수행한 이후 그 결과를 환자에게서 나타난 신호에 적용하기 위함이다. 최적화의 대상이 될 심박은 신호 측정 후 안정상태에 들어가고 5개의 연속된 심박이 모두 정상일 경우 이를 template으로 사용하였다. 본 논문은 MIT-BIH 부정맥 데이터베이스를 기반으로 구현하였기 때문에 template은 환자의 신호 파일 중 50 개의 심박이 지나간 후 연속된 5개의 정상 심박이 발견된 경우 이를 사용하였다. 이 template을 대상으로 최적화 탐색을 수행하며, 위에서 언급한 6가

지 최적화 탐색 조건은 아래의 표 1에 요약하였다. 최적화 단계 및 특징점 추출 단계에서 웨이블릿 연산은 DWT, 5 scale로 분석하였다. 최적화 조건은 표 1에 나타낸 바와 같이 특정 scale band의 전체 신호에 대한 DWT 계수 제곱합의 비율을 최대화 하는 경우 (Cd3Max, Cd4Max, Cd5Max 조건)와 이 비율에 5번째 scale의 approximation band의 전체 신호에 대한 DWT 계수 제곱합의 비율의 차를 최대로 하는 경우(Cd3MaxCa5Min, Cd4MaxCa5Min, Cd5MaxCa5Min 조건)를 선정하였다. 이와 같이 선정한 이유는

표 1. 웨이블릿 변수화를 통한 최적화를 위한 제안 최적화 조건

Table 1. The proposed optimum conditions based on wavelet parameterization

명칭	제안 최적화 조건
Cd3Max	$\max(\alpha, \beta) : \sum_j C_{D3j}^2 / \sum_i \sum_j C_{ij}^2$
Cd4Max	$\max(\alpha, \beta) : \sum_j C_{D4j}^2 / \sum_i \sum_j C_{ij}^2$
Cd5Max	$\max(\alpha, \beta) : \sum_j C_{D5j}^2 / \sum_i \sum_j C_{ij}^2$
Cd3MaxCa5Min	$\max(\alpha, \beta) : \sum_j C_{D3j}^2 / \sum_i \sum_j C_{ij}^2 - \sum_j C_{A5j}^2 / \sum_i \sum_j C_{ij}^2$
Cd4MaxCa5Min	$\max(\alpha, \beta) : \sum_j C_{D4j}^2 / \sum_i \sum_j C_{ij}^2 - \sum_j C_{A5j}^2 / \sum_i \sum_j C_{ij}^2$
Cd5MaxCa5Min	$\max(\alpha, \beta) : \sum_j C_{D5j}^2 / \sum_i \sum_j C_{ij}^2 - \sum_j C_{A5j}^2 / \sum_i \sum_j C_{ij}^2$

PVC가 일반적으로 정상 심박과 비교하여 낮은 주파수 성분을 많이 갖고 있기 때문에 분석대상의 정상 심박이 5 번째 scale의 approximation band 보다 하위 scale에 에너지가 집중되게 하기 위해서이다. 첫 번째 조건부터 세 번째 조건까지는 이와 같은 특징을 정상심박의 웨이블릿 분석 계수가 5번째 scale의 approximation band보다 하위 scale band(3, 4, 5번째 detail band)에 집중된 경우를 찾는 것이다. 네 번째 조건부터 여섯 번째 조건까지는 위 조건과 함께 정상심박이 5번째 scale의 approximation band에 가능한 작게 웨이블릿 계수를 갖도록 하기 위함이다. 본 논문에서는 위의 6가지 최적화 조건 중 어느 조건이 가장 정상 심박과 PVC를 분리하는데 적절한지에 대해 평가해 보았다.

특징점 추출단에서는 심박의 시간 정보(temporal features)와 파형 정보(morphological features)를 특징벡터로 계산해서 표현한다. 본 논문에서는 2가지의 시간 정보와 7가지의 파형정보를 사용하여 총 9가지의 특징으로 정상 심박과 PVC를 구분한다. 9가지의 특징벡터는 시간 정보에 RR 간격, RR 비율(현재 R peak와 직전 R peak 사이의 간격 대비 현재 R peak와 직후 R peak 사이의 간격)이 있으며, 파형 정보에는 form factor와 최적 웨이블릿으로 분석된 각 scale band의 에너지의 비율 6가지가 있다. RR 비율의 경우 PVC가 일반적으로 정상심박보다 빨리 수축하고 이후 보상 기간(compensation period)를 갖기 때문에 이를 반영하기 위해 적용된 특징이다. Form factor는 M.H. Kadbi[17]의 연구에서 발표된 조기심실수축에 특징적으로 나타나는 정보이다. Form factor를 구하는 식은 다음의 Eq.[12]과 같다.

$$FF = \frac{\sigma_{x''} / \sigma_{x'}}{\sigma_{x'} / \sigma_x} \tag{12}$$

위 식에서 σ_x 은 신호의 표준편차, $\sigma_{x'}$ 은 1차 미분된 신호의 표준편차, $\sigma_{x''}$ 은 2차 미분된 신호의 표준편차이다. 최적 웨이블릿을 사용하여 얻은 특징들은 아래의 표 2에 정리되어 있는 바와 같이 d5/T, d4/T, a5/T, d5/a5, d4/d5, d4/a5이며, d는 detail band의 계수, T는 전체 계수, a는 approximation band의 계수, 숫자는 scale level을 나타낸다. 이와 같은 특징 계산은 웨이블릿 분석법을 사용하여 부정맥을 분류하는 대부분의 연구들이 사용하는 방식이며, 파형의 해당 scale의 에너지 정보를 얻는다. 역시 이전 최적화 과정과 마찬가지로 첫 번째부터 세 번째 특징은 전체 계수 대비 해당 scale band의 에너지를 나타내기 위함이며, 네 번째부터 여섯 번째 특징은 관심 scale band 대비 그보다 상위 scale band의 비율을 봄으로써 정상심박과 PVC간의 구성 주파수 분포 차이를 나타낼 수 있도록 하였다.

본 연구에서는 이전의 최적화단에서 각 대상의 정상 심박을 기준으로 특정 scale band에 에너지를 집중시키는 최적 웨이블릿을 선별하고, 이를 기본웨이블릿으로 심전도를 분석하여 각 scale band의 에너지를 특징벡터로 구성하였다. 이렇게 추출된 특징벡터를 ELM의 입력층에 대입하여 학습 및 평가하였다. ELM의 구조는 1개의 은닉층을 갖고, 50개의 은닉뉴론(hidden neuron)을 사용하였다.

표 2. 웨이블릿 변환 후 각 scale level의 에너지 분포를 나타내기 위한 특징들과 계산식

Table 2. The features and equations of the features for representing energy of each scale level after wavelet transform

명칭	특징 계산
d5/T	$\sum_j^{N_{D5}} C_{D5j}^2 / \sum_i \sum_j^{N_s N_c} C_{ij}^2$
d4/T	$\sum_j^{N_{D4}} C_{D4j}^2 / \sum_i \sum_j^{N_s N_c} C_{ij}^2$
a5/T	$\sum_j^{N_{A5}} C_{A5j}^2 / \sum_i \sum_j^{N_s N_c} C_{ij}^2$
d5/a5	$\sum_j^{N_{D5}} C_{D5j}^2 / \sum_j^{N_{A5}} C_{A5j}^2$
d4/d5	$\sum_j^{N_{D4}} C_{D4j}^2 / \sum_j^{N_{D5}} C_{D5j}^2$
d4/a5	$\sum_j^{N_{D4}} C_{D4j}^2 / \sum_j^{N_{A5}} C_{A5j}^2$

IV. 실험 결과

제안하는 알고리즘의 성능 평가를 위하여 본 논문은 부정맥 검출 알고리즘 평가에 주로 사용되는 MIT-BIH 부정맥 데이터베이스를 사용했다. MIT-BIH 부정맥 데이터베이스에는 여러 부정맥을 가지고 있는 환자의 심전도 파일 48개로 구성이 되어있다. 본 논문에서는 그 중 정상심박과 PVC가 각각 100 개 이상 포함된 환자의 기록을 대상으로 했다. 이렇게 선발된 MIT-BIH 부정맥 데이터베이스의 파일은 106, 116, 119, 200, 201, 203, 208, 210, 213, 215, 221, 223, 228, 233번으로 총 14개이다. 이 중 알고리즘을 학습시킬 훈련데이터와 평가할 평가데이터에 같은 환자의 데이터를 포함시키지 않기 위해 환자의 기록을 두 그룹으로 나누었다. 훈련 데이터그룹은 106, 116, 119, 201, 203, 208, 215, 223번 파일로 8명의 데이터를 가지고 있으며, 평가데이터그룹은 200, 210, 213, 221, 228, 233번 파일로 6명의 데이터를 기반으로 구성되어 있다. 이와 같은 구분은 기존 연구와의 성능 비교를 편리하게 하기 위해 Chazal의 2004년 연구[6], 2006년 연구[7]와 같은 데이터 구성을 한 것이다.

최적화 과정은 전술한 바와 같이 심전도 신호의 측정이 안정이 된 후 정상심박 5 개가 연속적으로 나온 것을 대상으로 수행하며, 웨이블릿 탐색 범위는 scaling 필터 h 의 길이 L 을 6인 경우로 해당 최적화 조건을 만족시키는 α 와 β 를 탐색했다. α 와 β 는 각도 성분으로 $0 \sim 2\pi$ 까지 $\pi/180$ 간격으로 총 360 sample로 탐색을 수행했다. 아래의 표 3과 그림3에 Cd4max 조건의 최적화 결과를 요약하여 제시하였다. 표 3의 결과를 보면, 106번 파일은 α 가 0.017이고 β 가 0.506인 경우에 비율이 0.302로 조건을 최대로 만족시키는 기본웨이블릿을 탐색한 반면 116번 파일의 경우 α 가 4.643, β 가 0.576, 비율은 0.526, 그리고 119번 파일의 경우 α 가 1.780, β 가 5.114, 비율은 0.431로 모두 다른 값을 갖는다는 것을 알 수 있다. 그림 3는 왼쪽 세 그림은 106, 116, 119의 α 와 β 를 변화시켜가며 조건의 비율이 어떻게 나타났는지를 나타내는 그래프이며, 오른쪽 세 그래프는 왼쪽 그래프에 표시된(흰 화살표) 최적 기본웨이블릿 함수의 모양이다. 그림 3의 탐색결과와 예시를 보면 심전도의 정상 파형임에도 불구하고 같은 조건에서 최대 비율을 갖는 최적 웨이블릿의 위치가 매우 상이하고, 해당 위치의 기본웨

이블릿의 모양 역시 상이한 것을 알 수 있다. 이는 대상 간의 파형 차이에 의한 것이며, 본 논문에서 제안하는 대상 별 최적화 단계의 필요성을 나타낸다.

최적화 과정의 효과를 평가하기 위해서 본 연구에서는 최적화를 통해 얻은 기본 웨이블릿으로 분석한 특징과 일반 범용 기본웨이블릿으로 분석한 특징의 분류 성능을 평가해 보았다. 분류 성능을 평가하기 위해 다음의 과정을 수행하였다. 최적화 단계를 거쳐 얻어진 각 대상에 대한 최적 기본웨이블릿을 사용하여 각 대상의 심박을 웨이블릿 변환한다. 변환한 결과에 대해 전술한 특징 벡터를 얻어내고, 특징벡터의 각 성분을 -1~1의 범위를 갖도록 선형이동 시킨다. 이렇게 선형이동 시킨 특징에 대해 Fisher Discriminant Ratio(FDR)을 측정하여 얻어진 특징이 정상 심박과 PVC 분류에 어느 정도 정보를 가지고 있는지 평가하였다. FDR은 특징의 그룹 간 선형 분류 비율을 평가하는 지표로서 클수록 그룹 간 분류 정보량이 많음을, 즉 분류 성능이 높음을 나타낸다. 본 논문과 같이 두 그룹 간 평가의 경우 Eq.[13]와 같이 얻어진다.

$$FDR = \frac{(\mu_{Nor} - \mu_{PVC})^2}{\sigma_{Nor}^2 + \sigma_{PVC}^2} \quad (13)$$

위 식의 $\mu_{Nor}, \mu_{PVC}, \sigma_{Nor}, \sigma_{PVC}$ 은 각각 정상 심박 특징의 평균, PVC 특징의 평균, 정상 심박 특징의 표준편차, PVC 특징의 표준편차를 나타낸다. 최적화를 통해 어느 정도의 성능향상을 기대할 수 있는지를 알아보기 위해 대조군으로 일반 범용 기본 웨이블릿으로 같은 과정을 거쳐 FDR를 평가해보았다. 일반 범용 기본 웨이블릿은 기존의 연구들에서 주로 사용되는 Daubechies(db3), Coiflet(coif1)을 사용하였다(두 기본 웨이블릿 모두 $L = 6$). 또한 웨이블릿 분석으로 얻어진 특징벡터가 아닌 RR 간격, RR 비율, form factor에 대해서도 어떤 FDR 분포를 갖는지 평가하였다. 아래의 표 4에 위의 표1에서 제시한 최적화 조건별로 표 2에서 제시한 각 특징들이 각 환자에 대해 어떤 FDR 분포를 갖는지 표시하였으며, 표 5에는 대조군으로 얻어진 특징들의 FDR과 RR 간격, RR 비율, form factor의 FDR을 나타내었다. 표 4와 5에 대한 데이터 이해의 편의를 위해 1보다 작은 FDR 값을 갖는 특징은 배경색을 다르게 처리하였다.

표 3. MIT-BIH 부정맥 데이터베이스 파일 별로 탐색된 최적 웨이블릿 변수, Cd4max 조건인 경우, rate는 표 1의 Cd4max 경우의 최적화 조건 값, α , β 는 최적화 조건을 만족하는 웨이블릿 변수

Table 3. The obtained optimum wavelet parameters with each files of MIT-BIH arrhythmia database in Cd4max condition case. The 'rate', α and β mean value of criterion and two wavelet parameters at optimal conditions.

file	106	116	119	201	203	208	215	223	200	210	213	221	228	233
rate	0.302	0.526	0.431	0.454	0.319	0.597	0.559	0.414	0.554	0.383	0.446	0.561	0.216	0.354
α	0.017	4.643	1.780	3.962	2.793	4.643	1.030	1.850	1.763	1.972	1.693	4.171	4.660	1.937
β	0.506	0.576	5.114	4.974	0.611	0.541	6.196	5.149	5.166	0.576	5.096	4.992	0.628	5.201




그림 3. 최적화 조건 탐색과정 그래프와 최적 기본웨이블릿 예시 그래프, (좌) 위에서부터 MIT-BIH 부정맥 데이터베이스 106, 116, 119 파일의 Cd4max 비율, 흰색 화살표가 최적화 조건을 만족시키는 α , β 의 위치 (우) 위에서부터 106, 116, 119번 파일의 최적 기본 웨이블릿 파형
Fig. 3. The graph of searching process for optimal condition and optimal mother wavelet graph, (left) The Cd4max rate of 106, 116, 119 file in MIT-BIH arrhythmia database. The white arrow is located at optimum α , β . (b) The waveform of optimal mother wavelet of 106, 116, 119 file

모든 파일에 걸쳐 높은 FDR을 보여야 그 특징을 근거로 신뢰성 있는 분류를 수행할 수 있으므로 좋은 분류 성능을 갖는 특징이란 모든 파일에 걸쳐 높은 FDR을 가져야 한다. 표 4의 FDR의 결과를 보면, Cd5maxCa5min 최적화 경우가 1보다 작은 FDR을 갖는 특징이 가장 적게 나타나 좋은 특징들을 보유하고 있는 것으로 나타났다. 그러나 Cd4max 최적화 경우 전체적인 FDR의 분포는 Cd5maxCa5min 보다 낮은 경우가 많지만, d4/T 특징이 모든 파일에 있어 높은 FDR 값을 가지고 있어 좋은 특징을 보유하고 있다. 또한 Cd5maxCa5min의 경우 가장 높은 FDR을 보이는 a5/T, d5/a5 특징도 213, 233번 파일에 있어서는 낮은 FDR을 갖기 때문에 이 환자에게 있어서는 이 특징을 기반으로 분류하기 어려운

반면, Cd4max의 경우 낮은 FDR이 d5/T, d5/a5특징에 몰려 d4/T 특징 뿐만 아니라 a5/T, d4/a5 특징도 Cd5maxCa5min의 a5/T, d5/a5 특징과 같이 높은 FDR을 많이 보유하고 있다. 이와 같은 특징의 분포로 미루어 Cd4max에 가장 높은 분류 정확도를 나타낼 것으로 예상되며, 실제 평가 결과도 Cd4max에서 가장 높은 분류 정확도를 나타내었다. 실제 분류기를 통과한 평가 결과는 다음 장에 기존 연구의 성능과 비교하여 제시하였다.

표 5의 대조군들과 비교해 보면, db3가 적은 수의 낮은 FDR을 보이고 있으나 역시 모든 대상에서 낮은 FDR을 유지하는 특징은 없었다. 기존 연구에서 많이 사용되는 특징요소인 RR 간격, RR 비율, form factor의 경우에도 일부 대상에서 낮은 FDR을 보였다.

표 4. 각 최적화 조건별 제안 특징요소의 FDR 분포, 배경색을 넣은 항목은 FDR이 1이 미만인 경우. FN은 MIT-BIH 부정맥 데이터베이스의 파일 번호
Table 4. The FDR value of proposed feature elements for each optimal condition. The gray backgrounds indicate that FDR is less than 1. FN stands for file number of MIT-BIH arrhythmia database.

최적화 조건 : Cd3Max							최적화 조건 : Cd4max						
FN	d5/T	d4/T	a5/T	d5/a5	d4/d5	d4/a5	FN	d5/T	d4/T	a5/T	d5/a5	d4/d5	d4/a5
106	1.70	0.63	1.27	0.10	0.30	0.11	106	0.032	2.88	2.219	0.433	0.537	0.781
116	37.90	1.77	2.36	0.19	7.34	1.29	116	2.06	28.38	32.81	7.84	3.28	2.98
119	2.45	1.76	56.94	8.16	7.51	8.67	119	0.01	146.86	73.43	5.43	93.33	11.41
201	1.33	49.76	197.93	3.84	19.77	3.79	201	27.57	70.01	132.56	9.89	0.37	9.33
203	1.57	0.05	0.70	0.32	0.67	0.54	203	0.91	2.01	0.66	0.08	1.82	1.06
208	6.45	1.88	7.62	0.01	1.36	0.61	208	2.07	27.36	15.15	0.72	12.68	5.39
215	11.34	2.47	0.12	1.11	1.03	0.31	215	6.02	15.02	2.19	0.86	18.19	9.36
223	7.65	0.33	1.76	0.07	8.43	0.41	223	0.41	9.42	6.42	4.30	0.74	8.13
200	2.88	0.42	6.48	1.91	5.20	2.05	200	0.28	15.38	11.87	2.54	1.73	5.65
210	1.13	0.00	1.79	0.49	1.57	0.69	210	0.04	5.73	4.19	1.23	0.10	6.22
213	11.23	2.52	0.28	0.43	3.71	0.01	213	0.64	27.92	6.82	0.28	16.42	9.95
221	12.07	0.45	17.76	5.52	31.18	11.91	221	0.20	75.16	62.63	12.67	16.47	14.27
228	6.58	1.77	0.32	1.17	2.81	0.16	228	0.04	2.75	1.66	0.08	1.56	0.90
233	0.19	0.44	0.18	0.02	0.54	0.09	233	0.16	1.16	1.29	0.55	0.05	0.80
최적화 조건 : Cd5max							최적화 조건 : Cd3maxCa5min						
FN	d5/T	d4/T	a5/T	d5/a5	d4/d5	d4/a5	FN	d5/T	d4/T	a5/T	d5/a5	d4/d5	d4/a5
106	1.73	3.34	2.97	1.69	0.66	1.73	106	1.19	0.38	1.58	0.22	0.30	0.22
116	3.32	5.32	14.41	4.73	1.48	1.78	116	63.50	12.56	1.39	0.67	5.73	0.14
119	19.98	30.31	81.24	30.58	0.02	22.24	119	89.09	6.36	80.08	3.66	9.63	4.11
201	66.16	9.96	69.82	11.59	0.34	5.08	201	34.18	23.99	186.97	2.50	11.71	2.76
203	4.44	0.73	4.26	2.51	0.07	0.59	203	1.59	0.05	0.70	0.31	0.63	0.53
208	16.39	5.85	32.03	9.07	0.06	2.70	208	67.50	2.70	3.84	0.06	9.74	0.93
215	3.22	0.41	10.47	6.24	1.09	1.73	215	0.35	10.86	2.30	0.91	0.68	0.28
223	5.15	0.02	7.51	5.09	0.81	0.94	223	9.12	0.03	1.41	0.01	3.54	0.09
200	11.06	3.14	12.62	5.10	0.25	1.38	200	5.72	0.01	6.38	1.29	3.28	1.63
210	5.11	1.61	4.94	3.58	0.05	1.26	210	1.20	0.14	1.94	0.59	0.45	0.58
213	0.01	3.60	0.35	0.04	0.59	1.39	213	3.47	10.70	0.55	0.09	0.62	0.01
221	50.64	4.56	67.95	28.42	0.04	4.55	221	24.10	0.11	20.47	4.33	19.20	4.85
228	0.14	0.52	0.10	0.01	0.39	0.28	228	8.42	10.96	0.98	1.85	0.35	0.57
233	0.86	0.48	0.58	0.01	1.71	0.09	233	0.66	0.74	0.09	0.08	2.03	0.14
최적화 조건 : Cd4maxCa5min							최적화 조건 : Cd5maxCa5min						
FN	d5/T	d4/T	a5/T	d5/a5	d4/d5	d4/a5	FN	d5/T	d4/T	a5/T	d5/a5	d4/d5	d4/a5
106	1.10	0.37	1.61	0.27	0.27	0.26	106	0.06	0.35	2.29	1.43	0.13	0.73
116	0.39	26.57	25.64	5.58	2.61	2.54	116	3.80	8.40	17.83	4.58	2.03	1.73
119	0.38	133.24	79.93	4.55	64.56	8.59	119	7.19	22.23	112.68	18.57	13.27	11.58
201	32.68	78.15	147.57	5.83	1.54	4.84	201	63.52	20.66	90.50	8.02	1.48	5.25
203	1.07	0.31	0.56	0.17	1.06	0.70	203	2.21	0.89	2.82	2.44	0.20	1.53
208	2.56	27.72	13.72	0.83	12.94	3.82	208	11.92	14.33	30.41	6.54	2.42	4.10
215	6.80	12.16	1.63	0.25	8.65	5.83	215	6.40	7.59	11.62	6.36	5.44	0.33
223	0.27	9.44	5.58	4.24	2.13	7.29	223	3.17	1.42	6.41	4.18	0.65	3.08
200	0.00	15.67	13.63	3.75	1.15	4.74	200	10.08	4.98	13.70	4.64	0.66	2.03
210	0.19	4.58	3.24	2.57	0.83	4.29	210	2.20	0.70	4.15	2.87	0.25	1.47
213	1.15	15.50	2.90	0.01	7.38	4.03	213	2.65	2.21	0.66	0.03	0.10	0.09
221	0.01	84.18	62.64	12.69	20.56	10.36	221	7.73	1.01	37.57	18.73	0.24	4.42
228	8.33	11.21	1.06	2.11	0.30	0.66	228	3.97	15.29	1.41	2.72	1.87	1.69
233	0.12	0.84	0.85	0.98	0.01	0.48	233	1.45	0.04	0.83	0.05	1.88	0.00

표 5. 제안 특징요소(대조군) 및 기타 특징요소의 FDR 비교, 배경색을 넣은 항목은 FDR이 1 미만인 경우. FN은 MIT-BIH 부정맥 데이터베이스의 파일 번호
Table 5. The FDR value of proposed feature element of control group and the others feature elements. The gray backgrounds indicate that FDR is less than 1. FN stands for file number of MIT-BIH arrhythmia database.

대조군 기본웨이블릿 1 : Coif1							대조군 기본웨이블릿 2 : db3						
FN	d5/T	d4/T	a5/T	d5/a5	d4/d5	d4/a5	FN	d5/T	d4/T	a5/T	d5/a5	d4/d5	d4/a5
106	0.302	2.945	3.019	0.632	1.641	1.755	106	0.759	3.016	3.225	1.083	1.724	1.973
116	17.634	14.347	20.367	4.045	0.106	3.855	116	20.242	11.971	17.524	4.679	0.931	4.031
119	0.001	31.914	56.352	2.889	14.369	16.544	119	5.243	41.479	89.62	11.237	17.643	25.22
201	13.681	31.794	48.183	14.928	8.729	17.11	201	10.189	18.261	27.378	11.457	4.579	13.199
203	0.548	0.53	0.079	0.151	1.161	0.176	203	0.017	0.235	0.076	0.004	0.254	0.101
208	0.056	9.514	12.683	1.277	5.507	5.524	208	2.691	11.764	14.143	4.159	6.674	5.783
215	5.479	4.802	18.863	9.697	0.283	9.666	215	2.819	3.899	17.493	7.246	0.312	7.543
223	0.442	7.028	3.623	0.638	2.747	4.817	223	0.269	1.326	1.412	0.368	0.668	1.142
200	0.042	8.561	4.988	0.663	3.477	3.873	200	1.582	4.348	5.373	1.868	1.199	3.035
210	0.121	3.458	0.969	0.027	4.194	1.794	210	0.134	1.697	0.885	0.054	1.173	0.958
213	0.496	14.015	13.98	1.856	0.668	10.191	213	6.367	16.12	24.575	9.145	1.751	13.282
221	6.892	27.377	49.084	15.161	10.227	15.348	221	23.934	21.03	47.317	22.207	6.167	14.53
228	0.15	1.375	1.665	0.244	0.034	0.758	228	0.154	1.196	1.15	0.199	0.567	0.607
233	0.915	0.61	0.002	0.297	6.079	0	233	0.009	0.231	0.023	0.048	1.555	0
공통 특징요소													
FN	RR 간격	RR 비율	FF										
106	9.843	3.71	7.528										
116	14.121	13.721	9.268										
119	6.187	26.844	198.86										
201	0.005	0.702	5.505										
203	1.782	0.522	0.336										
208	1.484	2.209	15.081										
215	3.677	1.598	7.943										
223	2.409	1.253	0.761										
200	2.175	3.511	3.441										
210	2.204	1.741	0										
213	0.439	0.366	24.886										
221	3.072	5.776	12.88										
228	4.764	12.055	7.849										
233	4.443	4.636	0.676										

V. 결과 고찰

제안 알고리즘은 웨이블릿 변수화 기법을 사용하여 대상 간의 차이로 인한 부정맥 분류 정확도 저하를 감소시키는 방법을 제안하였다. 웨이블릿 변수화를 통한 최적화 과정을 수행한 결과 각 대상이 같은 최적화 조건에서 다른 최적 웨이블릿을 나타내 최적화의 필요성을 확인했으며, 특징의 FDR 분포를 통하여 여러 최적화 조건 중 가장 적합한 조건을 확인하였다. 최적 성능을 보인 Cd4max를 기반으로 얻어진 특징벡터를 ELM에 학습시켜 얻어진 결과가 표 6에 다른 기존 논문의 결과와 비교되어 나타나 있다. 제안 알고리즘은 Chazal의 2004년 연구[6], 2006년 연구[7]와 Accuracy(Acc), Sensitivity(Se), Positive Predictivity(+P), False Positive Rate(FPR) 측면에서 평가하였다.

$$Accuracy(Acc) = \frac{(TP + TN)}{(TP + FN + TN + FP)} \times 100$$

$$Sensitivity(Se) = \frac{TP}{TP + FN} \times 100$$

$$Positive Predictivity(+P) = \frac{TP}{TP + FP} \times 100$$

$$False Positive Rate(FPR) = \frac{FP}{FP + TN} \times 100$$

(14)

위의 식에서 TP, TN, FP, FN은 각각 True positive, True

표 6. 제안 알고리즘과 기존 알고리즘의 성능평가비교

Table 6. The performance comparison between proposed algorithm and existing algorithms.

file	Chazal [6] (2004)				Chazal [7] (2006)				Proposed Algorithm (2009)			
	Acc	Se	+P	FPR	Acc	Se	+P	FPR	Acc	Se	+P	FPR
200	93.7	82.1	97.7	0.9	97.6	93.7	98.9	0.5	98.4	94.9	100.0	0.0
210	93.8	62.1	57.1	3.7	97.2	78.4	83.6	1.3	97.9	75.3	95.4	0.3
213	93.9	21.8	65.8	0.8	99.5	94.5	97.9	0.2	99.0	99.1	88.6	1.1
221	99.2	99.0	96.3	0.7	99.9	99.3	100.0	0.0	100.0	99.7	100.0	0.0
228	94.6	69.9	99.6	0.1	99.9	100.0	99.6	0.1	98.2	99.7	90.9	2.1
233	95.9	87.6	96.8	1.1	99.3	97.6	100.0	0.0	95.7	87.4	96.4	1.2
gross	97.4	77.7	81.9	1.2	99.2	94.3	96.2	0.3	98.1	93.0	96.4	0.8

negative, False positive, False negative이다. 제안 알고리즘은 모든 환자에 대해서 높은 성능을 보였으며, 전체적으로 98.1%의 Acc, 93.0%의 Se, 96.4%의 +P, 0.8%의 FPR을 나타내 높은 성능을 보였다. Chazal의 2004년 연구에 비교해서는 모든 부분에서 높은 성능을 보이며, 2006년 연구와 비교해 유사하거나 약간의 낮은 성능을 나타냈다. Chazal의 2004년 연구는 대상 적응형 알고리즘이 아닌 여러 특징벡터를 비교하여 가장 높은 성능을 내는 특징벡터를 제안하는 연구였으며, 2006년 연구는 대상 적응형 알고리즘으로써 환자 데이터의 앞쪽 일부 심박을 의료진이 진단하고 이를 local classifier가 학습하여 global classifier를 보완하는 형태를 갖고 있다. 본 연구에 비해 2006년 연구는 약간 높은 성능을 보이고 있으나, 2006년 연구의 결과는 약 500개의 심박을 사람이 진단하여 반영시켜 얻어진 결과이고, 본 제안 알고리즘의 경우 5개의 연속 정상심박 만으로도 거의 같은 성능을 나타냈다. 이는 알고리즘의 사용성에 있어 제안 알고리즘이 기존의 연구와 비교하여 높은 성능을 갖는다고 할 수 있다.

VI. 결론

본 논문에서는 웨이블릿 변수화 기법을 기반으로 심전도의 대상 간 차이를 감소시키는 최적화 기법을 제안하였다. 이와 같은 기법을 통해 심전도 기반 부정맥 분류 알고리즘의 범용성을 높일 수 있었으며, 기존의 연구와 비교하여 보다 적은 대상 정보로도 높은 성능과 안정성을 보였다. 특징벡터의 FDR 값을 기준으로 비교평가하여 제안하는 여러 가지의 최적화 조건 중 Cd4max 조건이 최대 성능이 나타남을 알아냈다. 웨이블릿 변수화를 기반으로 하는 최적화 기법은 몇 개의 변수를 조절하여 다양한 기본웨이블릿을 대상으로 탐색을 진행 할 수 있다는데 생체신호처리 분야에 있어 높은 가능성을 보이며, 본 논문은 심전도 기반 부정맥 분류 연구에의 적용에 시점이 될 것이다. 향후 조기심실수축 뿐만 아닌 다양한 부정맥의 검출에 적합한 최적화 조건에 관한 연구가 진행되어 다양한 부정맥을 검출해내는 연구가 필요하다.

참고자료

- [1] Youngbum Lee, MyoungHo Lee, Development of an Integrated Module Using a Wireless Accelerometer and ECG Sensor to Monitor Activities of Daily Living, *TELEMEDICINE JOURNAL AND E-HEALTH*, Volume 14, Issue 6, pp. 580-586 2008.
- [2] MyoungHo Lee, Se Dong Min, Hang Sik Shin, Byung Woo Lee, Jin Kwon Kim, The e-Health Landscape: Current Status and Future Prospects in Korea, *TELEMEDICINE JOURNAL AND E-HEALTH*, Volume 15, Issue 4, pp. 362-369 2009.
- [3] Jinkwon Kim, Hangsik Shin, Yonwook Lee, MyoungHo Lee, "Algorithm for Classifying Arrhythmia using Extreme Learning Machine and Principal Component Analysis", 2007. *EMBS*, pp. 3257-3260, 22-26 Aug. 2007.
- [4] S. Osowski, and T. H. Linh, "ECG beat recognition using fuzzy hybrid neural network," *IEEE Trans. Biomed. Eng.*, Vol. 48, pp. 1265-1271, 2001.
- [5] K. Minami, H. Nakajima, and T. Toyoshima, "Real-time discrimination of ventricular tachyarrhythmia with Fourier-transform neural network," *Biomedical Engineering, IEEE Trans.*, Volume 46, No. 2, pp. 179-185 1999.
- [6] Philip de Chazal, Oapos, M. Dwyer, R.B. Reilly, "Automatic classification of heartbeats using ECG morphology and heartbeat interval features", *Biomedical Engineering, IEEE Trans.*, Volume 51, Issue 7, pp. 1196-1206, 2004.
- [7] Philip de Chazal, RB Reilly, "A Patient-Adapting Heartbeat Classifier Using ECG Morphology and Heartbeat Interval Features", *Biomedical Engineering, IEEE Trans.*, Volume 53, No.12, pp. 2535-2543, 2006.
- [8] L Biel, O Pettersson, L Philipson, P Wide, "ECG analysis: a new approach in human identification", *Instrumentation and Measurement, IEEE Trans.*, Volume 50, Issue 3, pp. 808-812, 2001.
- [9] I.Christov, I.Jekova, and G.Bortolan, "Premature ventricular contraction classification by the kth nearest-neighbours rule", *Physiol. Meas.*, Vol. 26, pp. 123-130, 2005
- [10] J.S Sahambi, S.N. Tandon and R.K.P. Bhatt, "Using wavelet transforms for ECG characterization. An on-line digital signal processing system", *Engineering in Medicine and Biology Magazine, IEEE*, Volume 16, Issue 1, Page(s):77-83, 1997
- [11] Marie-Françoise Lucas, Adrien Gaufriau, Sylvain Pascual,

- Christian Doncarli and Dario Farina, "Multi-channel surface EMG classification using support vector machines and signal-based wavelet optimization", *Biomedical Signal Processing and Control*, Volume 3, Issue 2, pp. 169-174, 2008.
- [12] Brechet, L., Lucas, M.-F., Doncarli, C., Farina, D., "Compression of Biomedical Signals With Mother Wavelet Optimization and Best-Basis Wavelet Packet Selection", *Biomedical Engineering, IEEE Trans.*, Volume 54, Issue.12, pp. 2186-2192, 2007.
- [13] Jinkwon Kim, Byoungwoo Lee, MyoungHo Lee, "Optimization on arrhythmia classification algorithm using wavelet parameterization", *2008 Conference on Information and Control System, Gangwon, Korea*, Oct. 31, 2008.
- [14] Burrus, C.S., Gopinath, R.A., and Guo, H., Introduction to wavelets and wavelet transforms, *Prentice Hall*, 1997, pp.53-66
- [15] Guang-Bin Huang, Qin-Yu Zhu and Chee-Kheong Siew, "Extreme learning machine: Theory and applications" *Neurocomputing*, Volume 70, Issues 1-3, Pages 489-501, December 2006
- [16] P.L. Barlett, "The sample complexity of pattern classification with neural networks: The size of the weights is more important than the size of the network", *Information Theory, IEEE Trans.*, Volume 44, no. 2, pp. 525-536, 1998.
- [17] M.H.Kadbi, J.Hashemi, H.R.Mohseni and A.Maghsoudi, "Classification of ECG Arrhythmias Based on Statistical and Time-Frequency Features", *Advances in Medical, Signal and Information Processing*, MEDSIP, 2006.