

논문 2005-42SC-5-4

SVM 분류기를 통한 심실세동 검출

(SVM Classifier for the Detection of Ventricular Fibrillation)

송 미 혜*, 이 전**, 조 성 필*, 이 경 중**

(Mi Hye Song, Jeon Lee, Sung Pil Cho, and Kyoung Joungh Lee)

요약

심실세동은 심장의 무질서한 전기적 활동으로 인해 심근 수축이 동시에 이뤄지지 않게 되어 급성심장사에 이르게 하는 부정맥이다. 본 연구에서는 이러한 심실세동 검출을 위해 적은 양의 학습 데이터만으로 좋은 분류 성능을 보이는 SVM(Support Vector Machine) 분류기 기반의 심실세동 검출 알고리즘을 제안하였다. 심전도 신호로부터 SVM 분류기에 입력할 입력 특징을 추출하기 위하여 웨이브렛 변환기반의 대역통과 필터링, R점 검출, 입력 특징 추출구간 설정의 전처리 과정을 수행하였으며, 입력 특징으로는 리듬 기반의 정보 및 웨이브렛 변환 계수를 선택하였다. SVM 다원분류기는 정상리듬(NSR) 분류기, 심실세동과 유사한 심실빈맥(VT) 분류기, 심실세동(VF) 분류기 그리고 그 외 부정맥 분류기로 구성하였다. SVM 분류기의 파라미터 C 값과 α 값은 실험을 통하여 최고 성능을 나타내는 $C=10$, $\alpha=1$ 을 선택하였다. SVM 다원 분류기를 통한 정상리듬, 심실빈맥, 심실세동의 검출 평균값은 98.39%, 96.92%, 99.88%의 우수한 검출 성능을 나타냈다. 본 연구에서 제안된 동일 입력특징을 사용하여 SVM 분류기의 심실세동 검출 결과와 다층퍼셉트론 신경망 및 퍼지추론 방법에 의한 결과를 비교하였으며 SVM 분류기가 비슷하거나 우수한 결과를 보였다. 또한 기존 다른 알고리즘에 비하여도 우수한 결과를 보임으로써 제안된 입력 특징을 통한 SVM 분류기 기반의 심실세동 검출이 유용함을 확인할 수 있었다.

Abstract

Ventricular fibrillation(VF) is generally caused by chaotic behavior of electrical propagation in heart and may result in sudden cardiac death. In this study, we proposed a ventricular fibrillation detection algorithm based on support vector machine classifier, which could offer benefits to reduce the learning costs as well as good classification performance. Before the extraction of input features, raw ECG signal was applied to preprocessing procedures, as like wavelet transform based bandpass filtering, R peak detection and segment assignment for feature extraction. We selected input features which of some are related to the rhythm information and of others are related to wavelet coefficients that could describe the morphology of ventricular fibrillation well. Parameters for SVM classifier, C and α , were chosen as 10 and 1 respectively by trial and error experiments. Each average performance for normal sinus rhythm, ventricular tachycardia and VF, was 98.39%, 96.92% and 99.88%. And, when the VF detection performance of SVM classifier was compared to that of multi-layer perceptron and fuzzy inference methods, it showed similar or higher values. Consequently, we could find that the proposed input features and SVM classifier would one of the most useful algorithm for VF detection.

Keywords: SVM 분류기, 입력 특징, 웨이브렛 변환, 심실세동, 심실빈맥, 다층 퍼셉트론, 퍼지 추론

학생회원, 연세대학교 의공학과

(Department of Biomedical Engineering, Yonsei University)

* 정희원, 연세대학교 의공학과, 이동형 응급의료정보 시스템 개발 센터

(Department of Biomedical Engineering, Yonsei University, Center for Emergency Medical Informatics)

※ 본 연구는 보건복지부 보건의료기술진흥사업(02-PJ3 -PG6-EV08-0001)의 지원에 의하여 이루어진 것임.
접수일자: 2005년3월10일, 수정완료일: 2005년8월31일

I. 서 론

심전도 신호는 일반적으로 동방결절에서 발생하는 전기적인 신호에 의해 심장이 규칙적으로 수축과 이완 할 때 체표면에서 기록한 신호이다. 심전도 신호 중 정상적인 범위내의 빈도를 벗어나거나 정상빈도를 갖더라도 패턴상의 이상이 있을 때를 부정맥이라고 한다. 부정맥 중 심실세동(ventricular fibrillation: VF)은 심장의 무질서한 전기적 활동으로 인해 심근 수축이 동시에 이

뤄지지 않게 되어 발생한다. 이로 인해 심장의 혈액 공급이 중단되어, 신체 기관 및 뇌에 산소공급이 중단되게 된다. 뇌에 산소공급이 중단되면 뇌는 손상을 입게되고, 결국은 몇 분 안에 뇌의 기능이 정지하여 급성심장사(sudden cardiac death: SCD)에 이르게 된다^[1]. 즉, 심실세동은 환자의 생명을 위협하는 가장 치명적인 부정맥으로 즉각적인 치료를 하지 않을 경우 환자는 바로 사망하게 되므로 심실세동 검출은 매우 중요하다. 그럼 1은 정상리듬(normal sinus rhythms: NSR), 심실빈맥(ventricular tachycardia: VT), 심실세동(ventricular fibrillation: VF) 심전도의 예를 나타낸 것이다. 그럼에서 보는 바와 같이 심실세동 파형은 규칙성이 없는 기이한 양상을 보이며, QRS군이나 T파를 감별할 수 없이 불규칙한 진동파로 나타나는 특성이 있다. 한편 심실빈맥은 정상리듬과 심실세동의 중간 정도의 주기와 주파수 특성상 심실세동과 유사한 특성을 갖고 있다.

심실세동 검출을 위한 기존의 방법으로는 비선형 분석법^{[2]-[4]}, 시주파수 분석법^{[1],[7]}, 신경망^[5], 퍼지 추론^[6]을 이용한 방법 등이 있으며, 최근에는 검출의 정확성을 높이기 위한 알고리즘이 많이 연구되어지고 있다. 비선형 분석법과 시주파수 분석법은 시간 영역 알고리즘에 비해 연산이 복잡하지만, 심실세동과 같은 불규칙한 리듬 검출에 매우 안정적이고 효과적이다. 신경망은 패턴인식, 식별, 분류와 같은 다양한 분야에서 복잡한 함수를 실행 할 수 있도록 훈련되어 실용화되고 있는 시스템으로서 검출 성능은 좋으나 많은 양의 심전도를 학

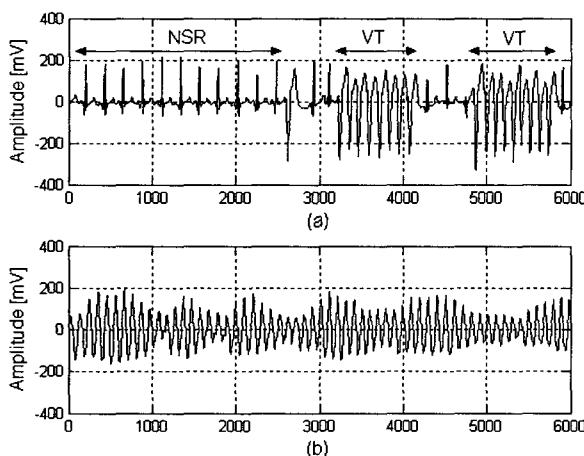


그림 1. 정상리듬과 심실빈맥 및 심실세동의 예
(a) 정상리듬과 심실빈맥 (c) 심실세동
Fig. 1. An example of normal sinus rhythm, ventricular tachycardia and ventricular fibrillation.
(a) NSR and VT (c) VF

습시켜야 하고 회로망의 구성이 복잡하다는 단점이 있다. 퍼지 추론은 비교적 연산이 간단하고 신경망 같은 초기학습을 요구하지 않은 장점이 있으나, 소속 함수를 선정할 때 전문가의 의견과 반복적인 실험을 통해 범위를 정해야 하기 때문에 주관성을 배제할 수 없다는 단점이 있다^[7].

이에 본 연구에서는 적은 양의 학습 데이터만으로 좋은 분류 성능을 보이는 SVM (Support Vector Machine)^[8]을 이용한 심실세동 검출 알고리즘을 제안하였다. 최근 우수한 분류 성능으로 각광받기 시작한 SVM은 신경망의 단점인 많은 양의 학습 데이터를 요구하지 않고 적은 수의 학습 데이터만으로도 우수한 검출 성능을 보이며, 음성인식과 패턴인식 등에 널리 활용되고 있다^{[9],[10]}.

II. 본 론

그림 2는 심실세동 검출 알고리즘의 블록도로서 전처리 과정 후 특징을 추출하고, SVM 분류기에 적용함으로써 심실세동을 검출하였다.

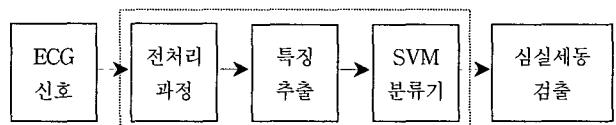


그림 2. 심실세동 검출 알고리즘 블록도

Fig. 2. Block diagram of ventricular fibrillation detection algorithm.

1. 전처리 과정

심전도 신호로부터 SVM 분류기에 입력할 입력 특징을 추출하기 위하여 웨이브렛 변환기반의 대역통과 필터링, R점 검출, 입력 특징 추출구간 설정의 전처리 과정을 수행한다.

가. 웨이브렛변환 기반의 대역통과 필터링

전처리 과정에는 coif5 웨이브렛을 사용하였으며, j 레벨로 웨이브렛 변환된 신호 $x(n)$ 은 식 (1)과 같이 표현할 수 있다.

$$x(n) = A_j[x(n)] + D_j[x(n)] \quad (1)$$

$A_j[x(n)]$ 은 j 레벨의 저주파 신호, $D_j[x(n)]$ 은 j 레벨의 고주파 신호를 의미한다. 360Hz로 샘플링 된 심전도 신호의 경우, 각 레벨에서의 저주파신호와 고주파신호

표 1. 웨이브렛 변환 레벨에 의한 주파수 분할 (단위: Hz)

Table 1. Frequency bands corresponding to using wavelet transform level (unit: Hz).

	... -2	-3	-4	... -8
An	... 0-45	0-22.8	0-11.4	... 0-0.7
Dn	... 45-90	22.8-45	11.4-22.8	... 0.7-1.4

의 주파수 대역은 표 1과 같다.

이에 기저선 변동 및 60Hz 잡음 제거를 위한 대역 통과필터는 식 (2)와 같이 간단히 구현가능하게 되며, 필터링 된 신호 $x_f(n)$ 의 주파수 대역은 0.7Hz에서 45Hz이다.

$$x_f(n) = A_2[x(n)] - A_8[x(n)] \quad (2)$$

나. R점 검출 및 입력 특징 추출구간 설정

본 연구에서는 R점 검출을 위해 웨이브렛 변환에 의해 얻은 계수(D3, D4)를 사용하였다. 전처리 과정을 통해 기저선 및 고주파 성분의 잡음을 제거한 심전도 신호를 제곱하여 QRS 콤플렉스를 부각시킨 후, QRS 콤플렉스가 포함되어 있는 3번째 레벨 고주파 신호(D3)와 4번째 레벨 고주파 신호(D4)의 신호를 더하여 합산신호 (D_{add})를 식 (3)과 같이 구성하였다. D_{add} 의 주파수 대역은 약 11.4Hz~45Hz으로 QRS 콤플렉스의 주파수 대역을 포함하고 있다. D_{add} 의 평균을 초기 문턱치로 설정하고, D_{add} 가 문턱치보다 크면 D_{add} 에 가중치 1, 작으면 0을 적용하였으며, 가중치가 적용된 D_{add} 의 전·후 값의 차로 차분신호(S_{sub})를 식 (4)과 같이 구성하였다.

$$D_{add} = D3 + D4 \quad (3)$$

$$S_{sub}(i) = D_{add}(i) - D_{add}(i+1) \quad (4)$$

S_{sub} 가 급격히 감소하는 구간에서부터 0이 연속적으로 200ms 이상 지속되는 구간까지를 QRS 콤플렉스가 존재할 예상 구간으로 설정하고 이 구간 내에서의 최대값 및 최소값을 R점으로 검출하였다. 검출 오차를 줄이기 위하여 R점의 규칙성을 확인하였으며, RR 간격이 평균 RR의 0.5배 미만인 경우나 1.5배 이상인 경우에는 문턱치를 1%씩 감소하여 조정한 후 다시 QRS 콤플렉스를 검출하였다. 문턱치를 90%까지 조정하여 예

려를 보정한 결과 RR 간격이 평균 RR 간격의 2~3배 이상인 경우에는 그 구간에 QRS 콤플렉스가 존재하지 않는 구간으로 간주하고, 웨이브렛의 5번째 레벨(A5)을 이용하여 신호의 peak을 검출하도록 하였다. 일반적으로 심실세동의 경우에는 R점이 존재하지 않기 때문에 본 연구에서는 구간 설정을 위해 신호의 피크점을 검출하였다^[11].

입력 특징 추출을 위해서는 R점을 기준으로 전·후의 200ms(=72 샘플)를 분석구간으로 설정하였다. 심실세동을 비롯한 다양한 부정맥은 R점을 기준으로 200ms 전·후의 구간에서 확인한 차이를 보이므로, 본 논문에서는 구간을 설정하여 심전도의 형태 및 주파수 성분을 분석하였다.

2. 입력 특징 추출

본 연구에서는 심실세동을 검출하기 위한 입력 특징으로 리듬 기반의 정보 및 웨이브렛 변환 계수를 선택하였다. 이를 위해서 MIT/BIH 부정맥 데이터베이스 중 심실세동 등 다양한 부정맥이 포함되어 있는 10개의 레코드를 사용하였다.

가. 리듬기반의 입력 특징

본 논문에서는 리듬기반의 입력 특징 추출을 위해 RR 간격을 활용하였다. 정상 파형의 경우 RR 간격은 대부분 R점 전·후 RR간격이 비슷하거나, 이전 RR 간격이 이후 RR 간격보다 더 긴 특성을 보이는 반면에 대부분의 비정상 파형의 경우에는 이전 RR 간격이 이후 RR 간격보다 짧거나, 특히 심실세동의 경우 R점 전·후의 RR 간격은 정상 파형의 평균 RR 간격에 비해 매우 짧은 특성이 있다^[12]. 따라서 RR 간격을 식(5), (6)에 적용하여 입력 특징으로 추출하였다. 이때 R(i)는 현재 R점과 이전 R점과의 간격을 의미하며, K는 표준

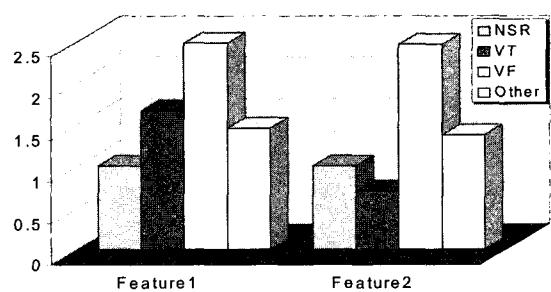


그림 3. 리듬 기반의 입력 특징

Fig. 3. Features based on rhythm.

화를 위한 상수 값으로 300 샘플로 설정하였다.

$$\text{Feature1} = \frac{K}{R(i)} \quad (5)$$

$$\text{Feature2} = \frac{K}{R(i+1)} \quad (6)$$

그림 3은 다양한 부정맥에 대하여 리듬 기반의 입력 특징을 그림으로 나타낸 것이다.

나. 웨이브렛 계수기반의 입력 특징

각 부정맥의 형태들을 시간 도메인 혹은 주파수 도메인 정보에만 의존하여 구분하는 것은 어렵기 때문에 시-주파수 특성을 모두 관찰할 수 있는 웨이브렛 변환을 활용하여 입력 특징을 구성하였다. QRS 콤플렉스의 형태 정보를 대변하는 입력 특징은 동일 클래스에 속하는 QRS 콤플렉스 간의 차이는 최소화함과 동시에 서로 다른 클래스에 속하는 QRS 콤플렉스에 대해서는 그 차이를 강조할 수 있어야 한다. 이를 위해 웨이브렛 변환 시 엔트로피가 0.01 이상이며 각 부정맥 클래스 간의 차이를 잘 대변하는 4, 5, 6, 7 레벨 고주파 신호의 웨이브렛 계수 cD4-cD7를 형태 정보를 대표하는 입력 특징으로 선택하였다. 각 웨이브렛계수의 수는 cD4의 경우 8개, cD5는 4개, cD6는 2개, cD7는 1개로 총 15개이며, 이들 웨이브렛 계수의 분포는 각 부정맥에 따라 서로 다른 특징을 갖고 있다. 그림 4는 다양한 부정맥에 대하여 웨이브렛 계수 기반의 입력 특징을 그림으로 나타낸 것이다.

한편, 이 웨이브렛 계수들에 주성분분석이나 선형판별분석과 같은 차원감소기법을 적용하면 각 부정맥 클

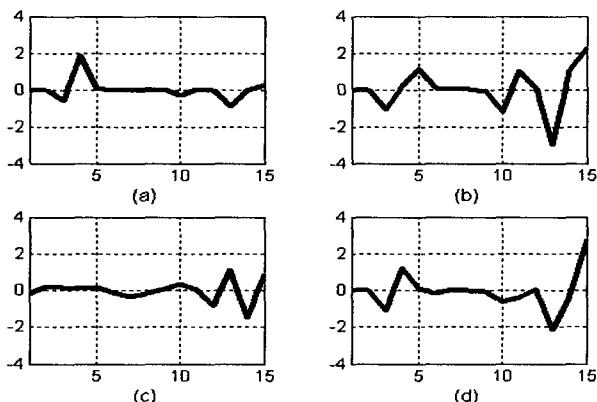


그림 4. 웨이브렛 계수 기반의 입력 특징

(a) 정상리듬 (b) 심실빈맥 (c) 심실세동 (d) 기타

Fig. 4. Features based on wavelet coefficient.
(a) NSR (b) VT (c) VF (d) Other arrhythmia

래스의 형태정보를 대변하는 최적의 입력 특징을 새로이 구성해 낼 가능성이 높기 때문에 웨이브렛 계수를 입력 특징으로 사용하는 것은 큰 장점을 갖는다.

3. SVM 다원 분류기

본 연구에서는 심실세동 검출을 위해 SVM 다원 분류기를 사용하였다. SVM 다원 분류기는 정상리듬(NSR) 분류기, 심실세동과 유사한 심실빈맥(VT) 분류기, 심실세동(VF) 분류기 그리고 그 외 부정맥 분류기로 구성하였다. 각 분류기는 입력 특징을 이용하여 해당 부정맥 여부를 판별하고, 만약 맞는다면 양의 값을 출력하고 다르다면 음의 값을 출력한다. 각 분류기의 출력 결과 중 최대값을 출력하는 분류기의 결과를 최종 결과로 결정한다.

SVM은 기본적으로 두 범주를 갖는 객체들을 분류하는 초평면(hyperplane)을 분석하는 것으로 객체들의 분리를 최대화 할 수 있는 최적 분리 경계면을 제공한다. 기존의 분류기들 대부분이 경험적 위험 최소화에 기초하는 반면에 SVM은 일반화 에러의 상한을 최소화하는 구조적 위험 최소화 기법에 그 기초를 두고 있다^{[13]-[15]}. 훈련 데이터가 식 (7)과 같이 주어졌을 때, 입력데이터 (x_i)는 두 클래스 중의 하나에 속하고, y_i 는 해당 클래스를 표시하는 라벨 역할을 한다. SVM은 각 클래스를 구분하는 최적의 분리경계면을 구하기 위해 분리 경계면과 분리 경계면에 가장 인접한 점(support vector)과의 거리를 최대화 한다. 만약, 두 클래스가 선형적으로 분리가 가능하다면, 두 클래스로 구분할 수 있는 최적의 선형 분리 경계면은 식(8)과 같이 정의할 수 있다.

$$[(x_1, y_1), \dots, (x_n, y_n)] \in \mathbb{R}^d \times \{\pm 1\} \quad (7)$$

$$f(x) = w^T x + b \quad (8)$$

식(8)에 의해, support vector와 $f(x)$ 의 거리를 $\frac{1}{\|w\|}$ 로 나타낼 수 있고, SVM은 w 를 최소화하여 분리 간격이 최대가 되도록 하는 최적의 분리면을 구하게 된다.

그림 5는 정상심전도와 비정상심전도의 특징점 2개를 x, y축으로 나타낸 것으로 최적 분리면이 정상심전도와 비정상심전도의 특징들을 최대 마진을 갖도록 분류한 결과이다. 이때 최적 분리면에 가장 가까운 특징

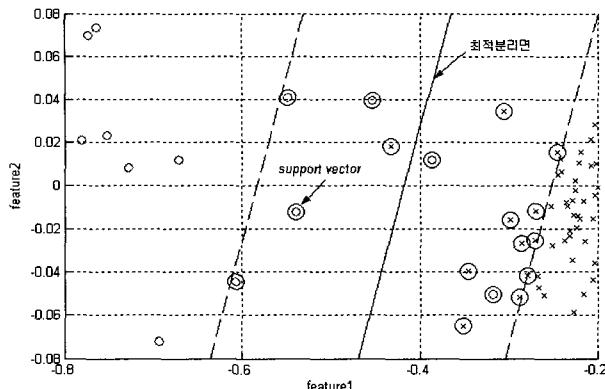


그림 5. SVM의 최적 분리면과 support vector의 예
(x : 정상심전도, o : 비정상심전도)

Fig. 5. An example of an optimal hyperplane of SVM and support vectors. (x : normal, o : abnormal)

들을 support vector라고 하며, 원으로 표시하였다.

본 연구에서는 SVM 분류기에 사용되는 커널 함수로 RBF(Radial-Basis Function) 커널을 사용하였다. 커널의 폭인 α 와 마진폭과 분류 오류 사이의 타협점을 결정하며, 분리 할 수 없는 데이터에 대한 오류 패널티 변수인 C 값은 실험적인 방법을 통해 결정하였다. SVM 다원 분류기의 학습을 위해 정상심전도, 심실세동 및 다양한 부정맥을 포함한 4135 비트의 심전도데이터를 사용하였다.

III. 결 과

본 연구에서는 SVM 파라미터에 따른 검출 성능을 확인하여 최적의 파라미터를 결정하고, 심실세동 및 부정맥 검출 알고리즘에서 널리 사용되어지고 있는 신경망과 퍼지 추론시스템의 검출 성능과 비교하였다. 검출 알고리즘 성능 평가를 위해 360Hz로 샘플링 된 MIT/BIH 부정맥 데이터베이스 및 250Hz로 샘플링 된 Creighton University Ventricular Tachyarrhythmia 데이터베이스, MIT/BIH Malignant Ventricular Arrhythmia 데이터베이스 중 심실세동이 포함된 심전도 신호를 360Hz로 재 샘플링하여 사용하였다. 검출 성능 평가를 위한 방법으로는 식 (9)-(11)에 정의된 민감도(sensitivity), 특이도(specificity), 정확도(accuracy)를 사용하였다.^{[16],[17]} 여기서 TP은 true positive, FN은 false negative, TN은 true negative, FP는 false positive를 의미한다.

$$\text{Sensitivity} = \frac{TP}{TP+FN} \times 100 \quad (9)$$

$$\text{Sensitivity} = \frac{TP}{TP+FP} \times 100 \quad (10)$$

$$\text{Accuracy} = \frac{(TP+TN)}{(TP+FN+TN+FP)} \times 100 \quad (11)$$

1. 파라미터에 따른 SVM 성능

본 논문에서는 학습 데이터가 정확히 두 범주로 나뉘지 않는 경우, 학습 데이터에 어느 정도의 오류를 허용하기 위한 임계치 C 값과 RBF 커널의 파라미터인 α 값에 따른 SVM의 성능을 평가하였다. 이를 위해 MIT/BIH 부정맥 데이터베이스 중 10개 레코드를 사용하여 정상심전도 분류를 수행하였다. 표 2는 C 값과 α 값에 의한 SVM 분류 성능을 비교해 놓은 결과로서, C 값이 0.1, 1, 10, 20일 때 α 값을 0.5, 1부터 3까지 변화시켜가며 성능을 비교하였다. α 값과 C 값의 조합에 따라 성능의 차이를 보였으며, C 값이 10이고 α 값이 1일 때 가장 좋은 성능을 보였다. 따라서 이 두 값을 최적의 SVM 파라미터로 설정하였다.

표 2. C 값과 α 값에 따른 평균 분류 성능 비교
(단위: %)

Table 2. Comparisons of the classifier performance for different combination of parameter (unit: %).

		α			
		0.5	1	2	3
C	0.1	70.00	95.94	95.20	86.97
	1	82.73	98.28	97.26	96.71
	10	85.71	98.69	98.39	98.21
	20	85.72	98.31	98.06	98.13

2. SVM의 부정맥 검출 성능

본 논문에서는 제안한 알고리즘을 실제 심전도 데이터에 적용하여 심실세동 및 다양한 부정맥을 검출하였다. MIT/BIH 부정맥 데이터베이스 중 심실세동을 포함한 다양한 부정맥이 포함되어 있는 22개의 레코드와 Creighton University Ventricular Tachyarrhythmia 데이터베이스, MIT/BIH Malignant Ventricular Arrhythmia 데이터베이스 중 심실세동 데이터가 포함된 각각 10개의 레코드를 사용하였으며, 테스트된 각 부정맥 비트 수는 NSR 67438 비트, VT 256 비트, VF 7175 비트, 그 외 부정맥 10761비트 (APC 2272 비트,

표 3. 제안한 알고리즘을 이용한 심실세동 및 다양한 부정맥의 검출 결과 (단위: %)

Table 3. Results of arrhythmia detection using the proposed algorithm (unit: %).

	Sensitivity	Specificity	Accuracy	평균
NSR	99.66	96.22	99.31	98.39
VT	91.70	99.63	99.44	96.92
VF	99.75	99.99	99.89	99.88

PVC 8361 비트, SVT 46 비트, 기타 82 비트)로 총 85630 비트였다. 표 3은 SVM 다원 분류기를 이용한 심실세동 및 다양한 부정맥에 대한 검출 결과로서, 정상 리듬, 심실빈맥, 심실세동의 검출 평균값은 98.39%, 96.92%, 99.88%의 우수한 검출 성능을 나타냈다.

3. 심실세동 검출 성능의 비교

제안된 알고리즘의 우수성 검증을 위하여 다층퍼셉트론 방법(MLP) 및 퍼지 추론 방법(FIS)과 성능을 비교하였다. 신경망은 오류 역전파(error back propagation) 학습 알고리즘을 사용하였으며, 입력층, 은닉층, 출력층을 각 하나씩 갖으며 입력층은 17개의 노드, 출력층은 4개의 노드를 갖도록 설계하였다. 은닉층은 시그모이드 함수를 적용하였으며 최적의 성능을 보이는 10개의 노드수를 사용하였다. 신경망 학습에는 26512 비트의 심전도 신호를 사용하였다. 한편, 입력된 특징들을 IF-THEN 규칙으로 구성된 지식기반을 바탕으로 추론값을 출력하는 퍼지 추론에는 가장 널리 사용되는 min-max 방법을 사용한 Mamdani 추론 방법을 사용하였으며, 비퍼지화 방법으로 무게중심 방법을 사용하였다. 퍼지 추론 시스템의 성능을 좌우하는 소속 함수는 가우시안 분포 곡선을 적용하여 반복적인 실험을 통해 획득하였다. 그림 6에는 각 방법의 심실세동 검출 성능을 비교한 결과를 나타내었다. SVM 분류기를 통한 심실세동 결과는 다른 방법들과 비교하여 비슷하거나 우수한 결과를 보였으며, 특히 민감도가 다른 방법에 비하여 우수하였다. 또한 기존의 다른 알고리즘에 비하여 우수한 결과를 보임으로써 제안된 입력 특징을 통한 SVM 분류기가 심실세동 검출에 적합함을 확인할 수 있었다.^{[2][6]}

IV. 결 론

본 연구에서는 리듬 기반의 입력특징과 웨이브렛 계

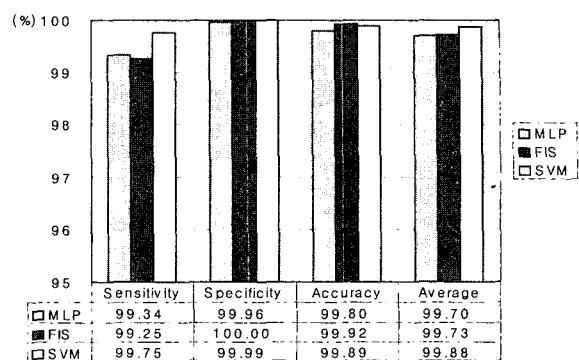


그림 6. 각 분류기에 의한 심실세동 검출성능 비교 (MLP: 다층퍼셉트론, FIS: 퍼지추론, SVM: SVM)

Fig. 6. Comparison of the efficiency with different classifiers(MLP: multi-layer perceptron, FIS: fuzzy inference system, SVM: SVM).

수 기반의 입력 특징을 SVM 분류기의 입력벡터로 사용하여 심실세동 검출을 검출하는 알고리즘을 제안하였다. SVM 검출기의 최대 성능을 위한 최적의 파라미터로는 C 값이 10, α 값이 1이었고, 평가를 위해 적용된 부정맥에 대해 우수한 검출 성능을 보였다. 심실세동 검출 성능에 대하여 다층퍼셉트론 방법 및 퍼지 추론 방법의 결과와 비교하였을 때, 민감도가 우수하게 나타났으며 다른 항목에 대하여도 비슷한 결과를 보였다. 그러나 다층퍼셉트론의 학습에는 26512 비트가 사용된 반면, SVM 분류기에서는 4135 비트만이 사용되었으며, 학습 시간 또한 각각 623.734와 85.923 초로 SVM 분류기가 다층 퍼셉트론에 비해 학습동안에 사용되는 데이터 및 학습시간이 짧은 장점이 있었다. 또한, 퍼지추론 방법의 경우에는 수차례 반복실험을 통하여 주관적으로 소속함수를 결정해야 하는데 비하여 SVM 분류기는 알고리즘 구현의 자동화 및 객관화 장점이 있었다.

결론적으로 제안된 알고리즘은 기존 알고리즘에 심실세동 검출 성능이 비슷하거나 우수하였으며, 학습시간 및 학습 데이터 양이 적고, 자동화 및 객관화 구현이 가능한 장점이 있는 것으로 사료된다. 제안된 알고리즘은 자동 부정맥 검출 시스템과 응급 환자 모니터링 시스템에 적용하여 실시간으로 환자의 상태의 심장 상태를 모니터링 할 수 있다. 또한 다양한 입력 특징 추출 연구 및 주성분분석이나 선형판별분석을 통한 입력 특징의 차원감소를 위한 연구분야에서 입력 특징의 유용성을 평가하는데 활용 가능하다.

참 고 문 현

- [1] V. X. Afonso and W. J. Tompkins, "Detection Ventricular Fibrillation", IEEE Engineering in Medicine and Biology Magazine, vol. 14, no. 2, pp. 152-159, March-April 1995.
- [2] H. X. Zhang, Y. S. Zhu and Z. M. Wang, "Complexity measure and complexity rate information based detection of ventricular tachycardia and fibrillation", Medical & Biological Engineering & Computing, vol. 38, no. 5, pp. 553-557, September 2000.
- [3] M. I. Oiws, A. H. Abou-Zied and A. M. Youssef, "Study of Features based on Nonlinear Dynamical Modeling in ECG Arrhythmia Detection and Classification", IEEE Trans. Biomedical Engineering, vol. 49, no. 7, pp. 733-736, July 2002.
- [4] N. Srinivasan, M. T. Wong and S. M. Krishnan, "A new Phase Space Analysis Algorithm for Cardiac Arrhythmia Detection", in Proc. of IEEE Conf. on Engineering in Medicine and Biology Society, vol. 1, pp. 82-85, Cancun, Mexico, September 2003.
- [5] K. I. Minami and H. Nakajima, "Real-Time Discrimination of Ventricular Tachyarrhythmia with Fourier-Transform Neural Network", IEEE Trans. Biomedical Engineering, vol. 46, no. 2, pp. 179-185, February 1999.
- [6] T. Sugiura, H. Hirata, Y. Harada and T. Kazui, "Automatic Discrimination of Arrhythmia Waveforms using Fuzzy Logic", in Proc. of IEEE Conf. on Engineering in Medicine and Biology Society, vol. 20, no. 1, pp. 108-111, Hong Kong, China, October-November 1998.
- [7] 박광리, "스트레스 심전도의 잡음 제거를 위한 WAF와 WIF의 설계", 연세대학교 박사학위논문, 2000년.
- [8] S. R. Gunn, "Support Vector Machines for Classification and Regression", Faculty of Engineering and Applied Science, Technical Report, pp.1-54, May 1998.
- [9] 어상준, "Support Vector Machines를 이용한 문서 정보 기반의 단백질 기능 분류", 서울대학교 석사 학위논문, 2003년.
- [10] W. Y. Choi, K. Lee and Y. Chung, "Support vector machines for robust speaker verification", in Proc. of the AICSST, pp.262-267, 2002.
- [11] R. H. Clayton, A. Murray, R and W. F. Campbell, "Comparison of four techniques for recognition of ventricular fibrillation from the surface ECG", Medical & Biological Engineering & Computing, vol. 31, no. 2, pp.111-117, March 1993.
- [12] 최진호, 초보자를 위한 심전도 가이드, 2000년.
- [13] C. M. Rocco and J. A. Moreno, "Fast Monte Carlo Reliability Evaluation Using Support Vector Machine", Reability Engineering and System Safety, vol.76, no. 3, pp.237-243, June 2002.
- [14] 최우용, 황병희, 이경희, 반성범, 정용화, 정상화, "에스 브이 엠을 이용한 화자인증 알고리즘의 하드웨어 구현 연구", 전자공학회논문지, 제41권 SP 편, 제3호, 365-372쪽, 2004년.
- [15] B. Scholkopf, C. J. C. Burges and A. J. Smola, "Advances in kernel methods", The MIT Press, 1999.
- [16] Y. K. Jung and W. J. Tompkins, "Detecting and classifying Life-Threatening ECG Ventricular Arrhythmia using wavelet Decomposition", in Proc. of IEEE Conf. on Engineering in Medicine and Biology Society, vol. 1, pp. 2390-2393, Cancun, Mexico, September 2003.
- [17] R. H. Clayton and A. Murray, "Comparison of techniques for time-frequency analysis of the ECG during human ventricular fibrillation", IEE Proc. -Sci. Meas. Technol., vol. 145, no. 6, pp. 301-306, November 1998.

저자소개



송 미 혜(학생회원)
 2003년 연세대학교
 의공학과 학사 졸업.
 2005년 연세대학교 대학원 의료
 공학협동과정 석사 졸업.
 2005년 ~ 현재 연세대학교
 의공학과 박사 과정.

<주관심분야 : 생체계측, 생체신호처리>



이 전(정회원)
 1996년 연세대학교
 의공학과 학사 졸업.
 1999년 연세대학교
 의공학과 석사 졸업.
 1999년 ~ 현재 연세대학교
 의공학과 박사 과정.
 2001년 ~ 현재 의용계측 및 재활공학연구센터
 연구원

<주관심분야 : 비선형 생체신호처리, 생체 임피던스, 생체시스템 모델링>



조 성 필(학생회원)
 2001년 연세대학교
 의공학과 학사 졸업.
 2003년 연세대학교 대학원 의료
 공학협동과정 석사 졸업.
 2003년 ~ 현재 연세대학교 대학원
 의료공학협동과정
 박사 과정.

<주관심분야 : 생체신호처리, 수면장애 진단 알고리즘>



이 경 중(학생회원)
 1981년 연세대학교 전기공학과
 학사 졸업.
 1983년 연세대학교 전기공학과
 석사 졸업.
 1988년 연세대학교 전기공학과
 박사 졸업.

1993년 미국 Case Western Reserve Univ.
 객원 교수.

1990년 ~ 현재 연세대학교 의공학과 교수

<주관심분야 : 의용계측, 보행분석, 비선형 생체
 신호분석, 생체시스템 모델링>