

# ECG 신호의 global curvature를 이용한 ST-T 에피소드 검출

論 文

50D-4-6

## Detection of ST-T Episode Based on the Global Curvature of Isoelectric Level in ECG

姜 東 遠\* · 全 大 根\*\* · 李 景 中\*\*\* · 尹 亨 老\*\*\*

(Dong-Won Kang · Dae-Gun Jun · Kyoung-Joung Lee · Hyung-Ro Yoon)

**Abstract** - This paper describes an automated detection algorithm of ST-T episodes using global curvature which can connect the isoelectric level in ECG and can eliminate not only the slope of ST segment, but also difference of the baseline and global curve. This above method of baseline correction is very faster than the classical baseline correction methods. The optimal values of parameters for baseline correction were found as the value having the highest detection rate of ST episode. The features as input of backpropagation Neural Network were extracted from the whole ST segment. The European ST-T database was used as training and test data. Finally, ST elevation, ST depression and normal ST were classified. The average ST episode sensitivity and predictivity were 85.42%, 80.29%, respectively. This result shows the high speed and reliability in ST episode detection. In conclusion, the proposed method showed the possibility in various applications for the Holter system.

**Key Words** : ST Episode, Global curvature, Backpropagation Neural Network, European ST-T database

### 1. 서 론

심근허혈은 심장 기능의 중요한 장애인 심근경색이나 부정맥의 주원인으로서 세포막 탈분극시 정상 세포와 허혈 조직간의 전위차에 의해 심전도의 ST 구간에서 상승 혹은 하강을 유발시킨다[1]. ST 구간의 상승과 하강은 심장의 해부학적 위치나 기록 전극에 의한 쌍극자의 위치에 따라 변하기 때문에 심근허혈을 정확히 진단하는 것은 매우 중요하다[2]. 특히 심장의 이상 유무를 진단하는 홀터 심전계는 부정맥 검출 기능과 더불어 최근에는 심근허혈 진단기능이 추가되는 경향이 있으므로 ST 세그먼트의 레벨이나 기울기의 상승, 하강에 대한 정확한 판단이 중요하다.

일정 기간동안 ST 세그먼트의 상승 혹은 하강이 지속되는 현상을 ST 에피소드라 하는데 이것을 자동 진단하기 위한 많은 방법이 연구되어 왔다. 심전도나 평균 심전도를 직접 이용한 방법, discrete cosine transform (DCT), discrete Fourier transform(DFT), Karhunen-Loeve transform(KLT) 등의 신호변환을 이용한 방법[3], 또한 artificial neural network[4], fuzzy-logic[5] 방법 등이 제시되어 왔다. 이런 다양한 방법들이 연구되었음에도 불구하고 정확한 진단이 어려운 점들로 ST 세그먼트가 갖고 있는 경사나 잡음, 기

저선 변동 등과 환자마다 여러 가지 패턴의 ST 세그먼트를 갖고 있으며, 같은 환자에서도 다양한 패턴의 ST 세그먼트를 가지고 있기 때문이다[6]. 상기의 문제점들 중 ST 세그먼트 측정시 기준이 되는 기저선의 변동을 제거하기 위한 연구들이 중점적으로 이루어졌으며 대표적인 방법으로 스플라인 방법이나 적응 필터, median 필터, 웨이블릿적용필터 등이 설계되었다[7][8][9][10]. 그러나 스플라인 방법은 저주파 신호인 경우에는 왜곡없이 기저선 변동을 제거할 수 있지만 기저선 변동이 심한 경우에는 문제점을 가지고 있다. 반면 디지털 필터들을 이용한 방법은 잡음제거 성능은 좋으나 연산 시간에 대한 제한성과 ST 세그먼트 부분에 왜곡을 유발시킬 수 있다. 또한 기저선 변동과 함께 ST 에피소드 자동 진단시 문제점으로 대두되는 다양한 패턴분류를 위한 방법으로 기저선 변동을 제거하지 않고 직접 신호를 이용하거나 심전도 신호로부터 얻은 특징점들을 신경망 입력으로 사용하여 분류하기도 하였다[11][12][13]. 상기의 방법에서는 2000개의 미리 지정한 훈련 데이터와 테스트 데이터를 신경망의 입력으로 사용하여 실험하였거나 제한된 테스트 데이터만을 사용하여 실험하였다. 많은 데이터를 신경망의 입력으로 사용할 경우 훈련시 오차 범위까지의 수렴시간이 길어지고 가중치 벡터에 대한 검출 시간도 길어지게 된다. 반면 한정된 훈련 데이터의 경우 테스트 데이터 외의 데이터 영역에는 검출 신뢰성을 제공하지 않는다. 특징점 검출을 이용한 신경망은 특징점 검출을 위해 많은 연산 시간과 더불어 ST 세그먼트 구간 선정을 위한 J점의 경우 검출률이 높지 못하다. 홀터 심전계의 경우 심전도 신호의 전처리 과정과 함께 검출과정에서도 빠른 결과를 얻을 수 있어야 하기

\* 準 會 員 : 延世大 保健科學大學 醫工學科 碩士課程

\*\* 準 會 員 : 延世大 保健科學大學 醫工學科 博士課程

\*\*\* 正 會 員 : 延世大 保健科學大學 醫工學科 教授 · 工博

接受日字 : 2001年 2月 2日

最終完了 : 2001年 3月 16日

때문에 본 논문에서는 심전도 데이터로부터 ST 세그먼트 에피소드를 자동 검출하기 위해 기저선 변동에 대한 보정과 ST 세그먼트가 갖는 경사를 없애기 위한 각 심전도의 등전위 레벨(isoelectric level) 점을 연결하는 global curvature를 제안하였다. 심전도 전 구간에 대한 기저선 보정 작업을 통한 연산 시간의 지연을 없애기 위해 ST 구간에서만 기저선 보정 작업을 수행하게 되고, ST 구간 선정을 위한 J점 검출 시 시간과 정확성에 문제점을 가지고 있기 때문에 European ST-T database에서 제시하는 R파를 사용하여 ST 구간을 선정하였다. 그리고 ST 세그먼트 검출시 문제점인 다양한 ST 세그먼트 패턴 분류를 위해 오류 역전파 신경망을 이용하였다. 이 신경망을 이용함으로써 적은 훈련 데이터를 통해 얻은 가중치 벡터와 입력 패턴의 곱을 통해 빠른 검출이 가능하였다. 최종적으로 검출 시스템의 성능을 평가하기 위해 European ST-T database를 이용하였다.

## 2. 본 론

### 2.1 훈련 데이터 선정

훈련 데이터는 European ST-T database로부터 얻은 ST 세그먼트 패턴(총 120개의 패턴으로 샘플링주파수는 250Hz 임)으로 구성하였다. European ST-T database에서 심근허혈 에피소드의 분류를 위해 사용하는 방법은 10개의 심전도 신호를 묶어 정상 신호와 비정상 신호의 개수를 비교하여 5개 이상을 갖는 진단 결과에 따라 ST 상승 혹은 하강으로 분류한다. 심근허혈 에피소드로 진단되는 것은 최소한 30초 동안 비정상 파형이 유지되어야 한다. 훈련데이터는 편평한 ST 세그먼트, 경사를 갖는 ST 세그먼트, 잡음을 포함하는 ST 세그먼트 등 다양한 패턴의 데이터를 이용하여 구성하였다. 표 1은 구성된 훈련 데이터의 심전도 전극별 구성을 나타낸다. European ST-T 데이터베이스는 2채널 데이터로서 서로 다른 전극의 데이터를 포함하고 있다. 따라서 정상 ST 세그먼트(Normal)와 상승(ST+) 혹은 하강(ST-) ST 세그먼트의 각 전극별 구성으로 분포를 고르게 할 수 있도록 하였다. European ST-T 데이터베이스내의 모든 전극별 데이터를 사용하지 않고 테스트 데이터내의 전극별 구성에 따라 선정하였다.

표 1 훈련 데이터 구성

Table 1 Train data

|        | V3    | V4    | V5    | MLIII |
|--------|-------|-------|-------|-------|
| Normal | 25%   | 25%   | 25%   | 25%   |
| ST+    | 23.3% | 26.7% | 20%   | 30%   |
| ST-    | 20%   | 33.3% | 23.3% | 23.4% |

### 2.2 심전도 신호 전처리

신경망의 입력 데이터를 구성하기 위해 심전도 신호를 적절하게 전처리 해야한다. 즉 입력된 심전도 데이터를 필터링 한 후 QRS 및 R점을 검출한 후 등전위 레벨 검출 및 기저선을 보정하여 ST 세그먼트를 추출하여 신경망의 입력으로 이용한다.

#### 2.2.1 R파 및 등전위 레벨 검출

기저선 변동 보정을 위해서는 정확하면서도 빠른 R파 검출을 필요로 한다. 이를 위한 R파 검출 알고리즘은 미분 파형의 영교차(zero-crossing)점을 이용한 가변 문턱치 방법 [14]을 사용하였다. 심전도 진단시 등전위 레벨은 일반적으로 PR 세그먼트로 간주하므로 기저선 보정시에도 이것을 기준으로 이용한다. 따라서 정확한 등전위 레벨의 검출은 ST 에피소드 검출의 정확성에 영향을 미치게 된다. 본 논문에서는 등전위 레벨을 검출하기 위한 방법으로 R파에서 80ms전의 미분 파형에서 10ms-20ms동안 0의 값을 갖는 구간으로 정의하여 검출하였다. 원 신호에서 ST 세그먼트의 각 샘플을  $x_1, x_2, \dots, x_n$ 라 하였을 때 이를 미분한 샘플을  $x'_1, x'_2, \dots, x'_n$ 로 표기하고 식 (1)을 통해 등전위 레벨을 구한다.




그림 1 심전도의 각 특징점 및 구간

Fig. 1 ECG signal

$$|x'_{r-k-i}| = 0, \quad i=1,2,\dots,0.01f \quad (1)$$

단  $x_r$ 은 R 첨두치 값,  $f$ 는 샘플링 주파수,  $k$ 는  $0.08f$

본 논문에서는 샘플링 주파수가 250Hz,  $k=20$ 으로 하였고, 식 (1)에서  $i$ 는 반올림하여 최소 3개의 샘플에 대해 만족하는 구간을 선택하였다. 즉  $k=20$ 이므로 R파에서 80ms전의 구간이고 이 구간내의 3점이 0의 값을 갖는 구간을 의미한다. 이 경우 원 신호의 값을 식 (2)를 통해 구했다.

$$Isoelectric\ level = \frac{\sum_{i=-1}^1 x_i}{3} \quad (2)$$

단  $i$  = 등전위 레벨 구간의 중앙 샘플값

2.2.2 기저선 변동 보정

본 논문에서는 각 심전도의 등전위 레벨을 연결하는 global curvature를 이용하여 ST 세그먼트에서의 경사와 기저선 변동을 제거할 수 있는 방법을 제시하였다. 그림 2와 같이 각 등전위 레벨(I<sub>c</sub>)을 연결하는 직선의 기울기를 slope(γ)이라 하고, 이 직선과 기저선으로 간주하는 global curvature와의 차이를 error(ε)로 한다. 또한 직선과 등전위 레벨 x(I<sub>c</sub>)와의 차를 distance(d)라 하며 식 (5)로 표현된다. RR interval은 심전도의 R과 사이의 간격으로 값이 600ms 이상의 경우와 이하일 경우로 구분하여 기저선 변동 보정에 사용된다. 식 (3)을 통해 얻은 두 점간의 직선을 통해 각 ST 세그먼트에서의 기저선에 의한 경사를 제거하게 된다.




그림 2 Global curvature  
Fig. 2 Global curvature

$$\gamma = \frac{s(I_{c-1}) - s(I_{c-2})}{m} \quad (3)$$

단 m : 등전위 레벨간의 샘플 수

s(·) : 등전위 레벨을 잇는 기울기 γ을 갖는 직선함수

slope의 값에 대한 평균(식(4))과 현재의 slope와의 차가 문턱치(λ)이상의 값을 가질 경우에는 식 (6)에 의한 error 보정을 하게 된다.

$$\bar{\gamma} = \frac{\sum_{k=1}^n \gamma_{c-k}}{n} \quad (4)$$

$$d = s(I_c) - x(I_c) \quad (5)$$

$$\text{단 } n = \begin{cases} 3 : RRinterval > 600ms \\ 2 : RRinterval < 600ms \end{cases}$$

$$\text{IF } \{ \lambda \geq | \bar{\gamma} - \gamma | \}, \text{ THEN } \{ \text{error} = \text{distance} / k \} \\ \text{ELSE } \{ \text{error} = 0 \} \quad (6)$$

상수 n은 R-R 간격에 따라 다른 값을 가지며 λ(문턱치 값)와 상수 k의 값은 반복적인 수행결과 오차를 최소화하도록 설정된 값들이다. 제안한 기저선 변동 보정 방법을 위해서는 R파 검출이 중요하다. R파 검출 방법인 적응문턱치 방법은 98.73%의 검출률을 가지고 있다[15]. 본 연구에서 제안한 방법에서는 R파 검출에 실패할 경우 slope의 값이나 distance값에 오류를 가져올 수 있기 때문에 R파 검출을 실패하였을 때에는 ST 세그먼트 추출에 포함시키지 않고

R-R 간격만큼의 시간 간격을 제외시키고 slope 값과 distance 값을 계산한다.

2.2.3 ST 세그먼트 추출

심전도 진단시 ST 세그먼트는 일반적으로 정상 리듬에서 R 점으로부터 60ms후부터 시작한다고 가정한다. 그러나 심전도의 R-R 간격이 600ms 이하인 빈맥일 경우 R 점으로부터 40ms후부터 ST 세그먼트의 시작이라 가정한다. ST 세그먼트의 시작부터 160ms동안을 ST 세그먼트 구간으로 하여 특징(feature)을 추출하게 된다.

데이터베이스내의 심전도 파형은 서로 다른 값의 크기를 가지고 있기 때문에 이를 정규화(normalization)하기 위해 기준 ST 세그먼트를 추출해야 한다. 처음 30초 동안의 정상 ST 세그먼트에 대한 평균을 통하여 기준 ST 세그먼트를 추출하였다.

2.3 신경망 구성

본 연구에서 사용한 신경망의 구성은 그림 3과 같다. 신경망 훈련부는 심전도 신호에 대한 ST 정상과 비정상을 구분하여 그에 대한 출력 데이터와 함께 오류 역전파 알고리즘을 사용하여 훈련시켰다. 훈련시 초기 학습률을 0.1로 하고 초기 가중치 벡터는 난수를 사용하여 생성하였고 최소 오차는 0.01로 하여 구성하였다. 사용된 신경망은 3층의 오류 역전파 신경망으로 각 층의 활성화 함수는 식 (7)과 같은 시그모이드 함수를 사용하였다. η와 β는 신경망의 변화에 의해 결정되는 상수로써 각각 신경망 층의 연결 강도와 초기치를 나타낸다. 각 층의 연결 강도인 η를 가변하여 학습이 잘 진행되는 구간에서는 구간 크기를 크게 하고 그렇지 못한 구간에서는 작게 하여 수렴시간을 줄여 준다.




그림 3 신경망 검출부 블록도

Fig. 3 Neural Network detection phase

$$f(x) = 1 / (1 + e^{-\eta + \beta}) \quad (7)$$

입력층의 노드수는 잡음의 영향과 훈련 시간을 줄여줄 수 있도록 20 노드로 선택하였고 은닉층의 경우는 가변하여 실험하였다. 출력층의 노드수는 2개의 뉴런으로 normal, elevation, depression, no classification으로 구성하였다.

3. 실험 결과 및 고찰

3.1 실험방법 및 평가 파라미터

ST-T 에피소드 검출성능을 평가하기 위한 실험데이터

는 European ST-T 데이터베이스를 이용하였다. 실험에 사용한 데이터는 총 90개의 2채널, 2시간의 홀터 심전도 데이터로 구성되어 있으며 368개의 ST 세그먼트 에피소드와 401개의 T파의 변화를 포함하고 있다. 성능 평가를 위한 파라미터로는 sensitivity와 predictivity를 사용하였으며 식(8)과(9)에 정의하였다. 에피소드에 대해 정확하게 검출한 것을 True Positive (TP)라 하고 에피소드를 검출하지 못한 것을 False Negative (FN), 에피소드로 잘못 검출한 것을 False Positive (FP), 정상을 정확하게 검출한 것을 True Negative(TN)로 하여 sensitivity와 predictivity를 구하게 된다.

$$sensitivity = \frac{TP}{TP+FN} \quad (8)$$

$$predictivity = \frac{TP}{TP+FP} \quad (9)$$

출력 데이터는 10개씩 그룹으로 묶어 10개 내의 정상과 비정상 ST 세그먼트 개수 중 많은 수의 출력에 따라 그룹 내의 모든 출력을 진단하게 된다.

### 3.2 Global curvature를 이용한 기저선 변동 보정

#### 3.2.1 최적 파라미터 선정

그림 4는 2.2.2절에서 제안한 방법에서 각 distance와 평균 기울기(slope)값  $\tilde{\gamma}$ 와 현재의 기울기 값  $\gamma$ 의 차인 문턱치 값( $\lambda$ )을 통해 검출률을 평가하여 ROC (Receiver Operation Characteristics) 그래프로 나타내었다. 오차 보정을 위한 상수 k와  $\lambda$ (문턱치값)에 대해 8회 실험했으며 그때의 값을 이용하여 기저선에 대한 보정 후 ST 세그먼트를 추출하여




그림 4 기저선 변동 보정을 위한 ROC 곡선  
Fig. 4 ROC curve for baseline correction

검출 성능 평가를 하였다. 그림 4를 통해 알 수 있듯이  $\lambda=20, k=4$ 일 때(A지점) sensitivity와 predictivity 모두 높은 검출률을 보였다. 상수 k와  $\lambda$ 가 커질수록 ST 에피소드 검출률의 sensitivity는 높아지고 predictivity는 낮아지게 된다. 등전위 레벨을 연결하는 직선과 기저선과의 차이를 보정하기 위한  $\lambda$ 가 커질수록 정상 신호를 비정상 ST 세그먼트로 검출하는 오류(FP)가 증가하게 되고 보정값이 커질수록 그에 따라 오류도 커진다. 반면 문턱치 값  $\lambda$ 가 작아질수록 비정상 ST 세그먼트에 대해 정상 진단을 내리는 오류(FN)가 증가하고 보정값이 커질수록 그 오류가 증가된다. 즉, distance에 의한 오차 보정을 위한 문턱치 값이 커질 경우 기저선 변동 보정이 필요함에도 불구하고 보정작업을 많이 하지 않게 되고 이로 인해 정상 ST 세그먼트에 대한 ST 상승 혹은 하강의 진단을 내리게 된다. 반대로 너무 많은 ST 세그먼트에 대한 보정 작업을 통해 적절하지 못한 ST 세그먼트의 상승 혹은 하강을 가져오게 되고 이로 인한 비정상 세그먼트를 정상으로 진단하는 오류를 범하게 된다.

#### 3.2.2 ST 레벨 비교

기저선 보정에 의한 ST 레벨을 비교하기 위해 일반적인 디지털 필터와 적응필터, cubic spline방법을 이용한 기저선 보정후의 레벨 값을 사용하였다. 실험을 위해 사용된 European ST-T 데이터베이스는 [10]에서 사용한 데이터와 일반적인 디지털 필터, 적응필터의 레벨 값을 사용하였다. 디지털 필터의 레벨 값은 0.5Hz의 차단 주파수를 갖는 고역 통과 필터를 통하여 기저선을 제거한 후의 값이며, Cubic spline의 경우에는 6개의 대표점을 이용한 보간법을 사용하였다. 표 2는 각 데이터에 대한 레벨 값을 나타낸다. 각 에피소드당 가장 높은 값을 갖는 ST 부분에서의 값으로 European ST-T 데이터베이스내에 이에 대한 값을 명시하

표 2 ST 세그먼트 레벨 비교  
Table 2 Peak levels of ST episode using European ST-T database

|                 | 적응필터 | 표준필터 | Cubic spline | 제안된 방법 |
|-----------------|------|------|--------------|--------|
| e0103(AST1+150) | 75   | 105  | 116          | 88     |
| e0105(AST1-150) | -60  | -120 | -110         | -127   |
| e0106(AST1-100) | 15   | -25  | -83          | -59    |
| e0108(AST1-200) | -75  | -130 | -158         | -162   |
| e0112(AST1-400) | -300 | -340 | -328         | -362   |
| e0113(AST1+250) | 155  | 215  | 242          | 263    |
| e0118(AST1+350) | 170  | 265  | 320          | 322    |
| e0119(AST1+200) | 30   | 65   | 180          | 165    |

었다. 한 예로 e0105(AST1-150)은 2채널 데이터 중 2번째 채널 데이터의 ST 세그먼트 레벨이 가장 작은 곳을 의미하며 레벨값은  $-150\mu V$ 로 제안된 방법에서의 레벨값은  $-127\mu V$ 임을 나타낸다. 적응필터와 표준필터의 경우 제안된 방법과 cubic spline을 이용한 방법보다 신호 왜곡이 크다. Cubic spline의 경우 제안된 방법과 비슷한 결과가 나왔는데 급작스런 기저선 변동에서는 ST 세그먼트에서의 신호 왜곡이 커진다.

### 3.2.3 검출 연산 속도 비교

표 3은 ST 레벨 검출을 위한 R파 검출과 기저선 보정 등의 전처리 과정까지의 연산 시간에 대한 cubic spline과 본 연구에서 제안한 방법에 대한 비교를 나타낸다. Cubic spline의 경우 6개의 등전위레벨을 이용한 parabolic runout cubic spline을 사용하였다. 심전도 신호의 전처리 과정은 본 연구에서 사용한 방법을 동일하게 적용하였고, 제안한 방법은 ST 구간에서만 기저선 보정을 하게 된다. Cubic spline의 경우 심전도의 모든 신호에 대해 적용되었기 때문에 전체적인 시간에서는 차이가 생기는데 ST 구간의 시간 간격을 전체 심전도 신호의 15%라고 생각했을 때의 연산 시간을 비교하였다. 연산 시간의 경우 본 연구에서 제시한 방법의 경우 cubic spline 방법보다 20.16배 빠른 성능을 보였다. 계산 속도의 비교를 위해 펜티엄III-450MHz PC를 사용하여 측정된 결과이다.

표 3 ST 세그먼트 추출 연산 속도 비교  
Table 3 comparison of computing time of ST segment extraction

|              | Recording No. | R파 개수 | R파 검출률(%) | 연산 시간(s) |
|--------------|---------------|-------|-----------|----------|
| Cubic spline | e0108         | 6597  | 99.79     | 38.71    |
| 제안된 방법       |               |       |           | 1.92     |

## 3.3 ST 에피소드 검출

### 3.3.1 테스트 데이터

European ST-T 데이터베이스내의 각 파일별 데이터를 사용하였다. 데이터베이스내의 총 90개의 파일중 30개의 파일을 선택하여 실험하였고 훈련 데이터에 사용하였던 심전도 신호를 기초로 선택하였다. 전체 테스트 데이터는 총 136개의 ST 상승 혹은 하강의 ST 에피소드와 176개의 T 에피소드를 포함한다. 실제 테스트 데이터에 사용된 심전도 전극은 V3, V4, V5, MLIII이다. 정확한 ST 에피소드 검출률 비교를 위해서는 사용한 데이터에 대한 R파 검출이 높아야 한다. 제안한 기저선 변동 보정 방법은 R파 검출에 의존하기 때문에 R파를 검출하지 못할 경우 오류가 생길 수 있다. 전체 테스트 데이터의 R파 검출률의 평균은 94.84%로 높지 않게 나왔는데 이는 테스트 데이터내의 잡음이 심하고

큰 기저선 변동을 가지는 신호를 사용하였기 때문이다. 등전위 레벨 검출률의 경우 평균 93.77%로 검출하지 못했을 때의 레벨 값은 등전위 레벨 구간의 3점에 대한 평균값을 사용하였다. 일반적으로 데이터베이스내에 많은 부정맥을 포함하는 경우에는 정확한 등전위 레벨에 대한 검출이 어렵고 결과적으로 낮은 ST 에피소드 검출률을 갖는다.

### 3.3.2 오류 역전파 신경망 구성

사용한 신경망은 입력층과 은닉층, 출력층으로 구성되어 있다. 학습률은 학습이 잘 진행되는 구간에서는 구간 크기를 증가시키는 방향으로, 학습이 빈약해지면 구간 크기를 감소시키는 방법으로 가변 할 수 있도록 하였으며 최초 학습률은 0.1로 하였다. 은닉층의 개수를 정하기 위해 은닉층의 개수를 가변하여 실험하여 가장 높은 검출률을 보이는 은닉층의 개수를 사용하였다. 그림 5는 사용한 은닉층의 개수에 따른 검출률을 나타내었다. 사용한 데이터는 European ST-T 데이터베이스내의 recording no. e0105를 사용하였고, 그래프의 횡축은 은닉층의 노드수이고 종축은 검출률을 나타낸다. 가장 높은 검출률을 보이는 은닉층의 노드수는 10개의 노드를 사용하였을 때로 sensitivity에서는 노드수가 14개일 때와 비슷하나 predictivity와 데이터 훈련 시간면에서 좋지 않은 성능을 보이므로 본 논문의 신경망 은닉층 노드의 개수는 10개를 사용하였다.




그림 5 은닉층 노드수에 따른 검출률

Fig. 5 Detection rate of ST episode varying number of hidden layer

### 3.3.3 검출 결과 및 고찰

제안된 방법에 의한 전체 평균 sensitivity와 predictivity는 각각 85.42%, 80.29%를 얻었다. 오류가 큰 데이터의 원인으로 R파 검출률이 낮거나 잡음을 많이 포함하는 데이터, 데이터내의 심전도에 상당한 수의 부정맥을 포함한 데이터 등이다. 심전도의 전처리 과정에서 필터의 사용이나 부정맥 검출을 하지 않기 때문에 이에 대한 오류를 가져 오게

된다. 잡음의 경우 일반적으로 심전도 전처리 과정으로 필터를 사용하지 않았고 데이터베이스 구성시 고주파 잡음을 없애기 위해 사용한 저역 통과 필터를 통과한 신호를 이용하였다. 따라서 통과 주파수내의 고주파 잡음이 존재한 상태에서 검출이 이뤄졌고 다양한 잡음성분에 대한 훈련 데이터가 부족하기 때문에 오류의 원인으로 작용된다. 부정맥의 경우 많은 부정맥이 발생할 시에는 이에 따른 등전위 레벨 검출이나 ST 세그먼트 추출에 문제를 주기 때문에 오류의 원인이 된다. 이러한 오류의 원인을 제거하기 위해서는 부

4. 결 론

본 연구에서는 심근허혈의 진단 파라미터인 심전도의 ST 에피소드의 검출을 위한 방법으로 global curvature를 이용한 기저선 보정, ST 세그먼트를 추출 및 신경망을 이용한 정상과 비정상에 대한 분류를 수행한 결과 얻은 결론은 다음과 같다.

1. 기존의 기저선 변동 제거 방법과는 달리 심전도의 기저선을 추적하여 기저선의 변동을 제거할 수 있는 방법을 제시하여 기저선 변동을 보정하였기 때문에 20.16배의 빠른 연산 시간과 함께 효과적으로 기저선 변동을 보정 할 수 있었다.
2. 신경망의 입력으로 직접 ST 세그먼트의 패턴을 이용하였기 때문에 신호변환을 통해 얻은 파라미터를 신경망의 입력으로 사용하던 기존 방식에 비해 처리시간이 빠르다.
3. 소량의 심전도 패턴을 훈련 데이터로 사용하여 sensitivity와 predictivity 각각 85.42%, 80.29%의 높은 검출률을 보였고 ST 에피소드의 검출시에는 간단한 곱셈을 통해 입력되는 패턴에 대한 실시간 검출 결과를 얻을 수 있기 때문에 필터 심전계와 같은 실시간 처리가 필요한 장비에 적용 가능함을 알 수 있다.

표 4 검출 성능 비교  
Table 4 comparison of detection rate

| 방법        | Sensitivity(%) | Predictivity(%) |
|-----------|----------------|-----------------|
| ANN[4]    | 77             | 86              |
| BP NN[16] | 88.62          | 78.38           |
| RMS[17]   | 84.7           | 86.1            |
| 제안된 방법    | 85.42          | 80.29           |

정맥에 대한 진단과 병행하여 R파 검출률을 높이기 위한 다양한 방법을 시도하여야 하고 잡음성분에 대한 충분한 훈련 데이터를 확보하여야 한다. 표 4는 European ST-T 데이터를 사용하여 ST 에피소드를 검출한 알고리즘에 대한 검출률 비교이다. ST 세그먼트를 대표하기 위해 Karhunen-Loeve 변환을 사용하여 데이터 전체에 대한 Karhunen-Loeve 계수를 구하고 이 계수를 이용하여 신경회로망(Artificial Neural Network)을 사용하여 검출하는 연구[4]와 오류 역전과 알고리즘을 사용하여 ST 세그먼트를 훈련시키고 이를 신경망의 입력으로 사용하여 검출한 방법[16], 각 ST 세그먼트의 차이의 RMS(Root Mean Square)를 이용한 방법으로 ST 세그먼트의 RMS값에 대한 median filtering을 통해 검출한 방법[17]에 대한 검출률을 나타낸다. 각 연구들은 모두 기저선 변동 보정을 위해 모두 cubic spline방법을 사용하였고 후처리를 필요로 하기도 한다. 따라서 검출에 따른 연산 시간에서는 다소 차이가 있겠지만 본 논문에서 제안한 방법과 비교하여 약 20배의 차이를 가져오고 홀터 데이터와 같이 많은 양의 데이터를 처리해야 하는 시스템에서는 시간상의 지연을 가지게 된다. 실제 본 논문에서의 ST 세그먼트의 진단에 대한 출력은 ST 세그먼트 구간에서만 기저선 변동 보정 작업을 수행하고 오류 역전과 알고리즘에 의해 저장된 가중치와 입력 데이터와의 곱셈을 통해 이뤄지기 때문에 빠른 결과를 얻을 수 있다. 검출률에서는 비슷한 결과를 가져 왔는데 보다 정확한 검출률을 위해서는 최적의 훈련 데이터의 선정과 훈련 데이터의 개수에 대한 문제 등에 대한 최적화 작업이 이뤄져야 한다. 또한 본 논문에서는 기저선 변동 보정을 위해서 European ST-T 데이터베이스를 사용하여 계수 선정을 하였는데 실제 임상 데이터에 대한 최적의 계수 선정을 위한 작업이 이뤄져야 한다.

감사의 글

본 연구는 1999년도 과학기술부, 한국과학재단 지정 지역협력연구센터(RRC)의 지원에 의하여 이루어진 연구로서, 관계부처에 감사 드립니다.

참 고 문 헌

- [1] L. S. Geddes and W. E. Cascio, "Effects of acute ischemia on cardiac electrophysiology," *The Heart and Cardiovascular system*, pp. 2021-2054, 1991.
- [2] A Gallino, S. Chierchia, G. Smith, M. Croom, M. Morgan, C. Marchesi and A. Maseri. "A computer system for analysis of ST segment changes on 24 hour Holter monitor tapes: Comparison with other available system," *J. Amer. Coll. Cardiol*, pp. 245-252, 1984.
- [3] F. Jager, G. B. Moody and R. G. Mark, "Detection of transient ST segment episodes during ambulatory ECG monitoring," *Comput. Biomed*, pp. 305-322, 1998.
- [4] R. Silpo, P. Laguna, C. Marchesi and R. G. Mark, "ST-T segment change recognition using artificial neural networks and principal component analysis," *Computers in Cardiology*, pp. 213-216, 1995.
- [5] J. Presedo, J. Vila, M. Delgado, S. Barro, F. Palacios and R. Ruiz, "A proposal for the fuzzy evaluation of ischemic episodes," *Computers in Cardiology*, pp. 709-712, 1995.

- [6] N. Maglaveras, T. Stamkopoulos, C. Pappas and M. G. Strintzis, "An adaptive backpropagation neural network for real-time ischemia episodes detection: development and performance analysis using the European ST-T database," *IEEE Trans. Biomed. Eng.*, 1998.
- [7] F. Badilini, A.J. Moss, E.L. Titlebaum, "Cubic spline baseline estimation in ambulatory ECG recordings for the measurement of ST segment displacements," *IEEE Medicine and biology*, 1991.
- [8] R. Jane, P. Laguna, N.V. Thakor, P. Caminal, "Adaptive baseline wander removal in t도 ECG: Comparative analysis with cubic spline technique," *Computers in cardiology*, pp. 143-146, 1992.
- [9] G.A. Williamson, P.M. Clarkson, W.A. Sethares, "Performance characteristics of the median LMS adaptive filter," *IEEE signal processing*, pp.667-680, 1993.
- [10] K.L. Park, K.J. Lee, H.R. Yoon, "Application of a wavelet adaptive filter to minimise distortion of the ST-segment," *Med. Biol. Eng. Comput.*, pp. 581-586, 1998.
- [11] F. Jager, G. B. Moody, A. Taddei and R. G. Mark, "Transient St segment changes during ambulatory monitoring," *Computers in Cardiology*, pp. 453-456 1991.
- [12] Y. Suzuki and K. Ono. "Personal computer system for ECG ST segment recognition based on neural networks," *Med, Biol. Eng., Comput.* 2-8, 1992.
- [13] L. Ebenbrandt, B. Devine and P. W. MacFarlane. "Neural networks for classification of ECG ST-T segments," *J. Electrocardiology*, pp. 25, 1992.
- [14] P. Laguna, N. V. Thakor, P. Caminal, R. Jane and Hyung-Ro Yoon, "New algorithm for QT interval analysis in 24-hour Holter ECG: performance and applications," *Med. & Bio. Eng. & Comput.*, 67-73, 1990.
- [15] 이정환, 정기삼, 이병채, 이명호, "심전도 신호의 위상학적 맵핑을 이용한 실시간 QRS 검출 알고리즘," *대한 전자공학회*, vol. 35, pp. 48-58, 1998.
- [16] N. Maglaveras, T. Stamkopoulos, C. Pappas and M. Strintzis, "Use of Neural networks in detection of ischemic episodes from ECG leads," *Computers in Cardiology*, 1994.
- [17] J. Garcia, L. Sornmo, S. Olmos and P. Laguna, "Automatic detection of ST-T complex changes on the ECG using filtered RMS difference series," *IEEE Trans. Biomed. Eng.*, 47, 2000.

## 저 자 소 개



강 동 원 (姜 東 遠)

1973년 7월 15일 생. 1999년 연대 의용전자공학과 졸업. 1999년~현재 동 대학원 의용전자공학과 석사과정

Tel : 033-760-2858, Fax : 033-763-1953

E-mail : jasmin@milab.yonsei.ac.kr



이 경 중 (李 景 中)

1958년 9월 17일 생. 1981년 연대 전기공학과 졸업. 1988년 동 대학원 전기공학과 졸업(공학). 1993년 미국 Case Western Reserve Univ. 객원 교수. 현재 연대 의용전자공학과 교수. 관심분야는 신호처리,

심장 진단 및 모델링.

Tel : 033-760-2432, Fax : 033-763-1953

E-mail : kjlee@dragon.yonsei.ac.kr



전 대 근 (全 大 根)

1971년 2월 25일 생. 1995년 연대 의용전자공학과 졸업. 1997년 동 대학원 의용전자공학과 졸업(석사). 현재 연대 의용전자공학과 박사과정. 관심분야는 신호처리, 심전도 진단 및 분석.

Tel : 033-760-2858, Fax : 033-763-1953

E-mail : wjseorms@milab.yonsei.ac.kr



윤 형 로 (尹 亨 老)

1949년 2월 17일 생. 1972년 연대 전기공학과 졸업. 1974년 동 대학원 전기공학과 졸업(석사). 1986년 2월 동 대학원 전자공학과 졸업(공학). 1974년~1979년 국방과학연구소 선임연구원. 현재 연대 의용전자공학과 교수. 관심분야는 생체 제측 제어, telemedicine

Tel : 033-760-2851, Fax : 033-763-1953

E-mail : hryoon@dragon.yonsei.ac.kr