

## BP알고리즘과 SVM을 이용한 심전도 신호의 패턴 분류

# Pattern Classification for Biomedical Signal using BP Algorithm and SVM

김만선\*<sup>1</sup>, 이상용\*\*

Man-Sun Kim and Sang-Yong Lee

\* 한국표준과학연구원 인간정보그룹

\*\* 공주대학교 컴퓨터공학과

### 요 약

심전도 데이터는 심장의 전기적인 신호의 다양한 파형으로 이루어지며, 이와 같은 파형을 분석하고 분류하기 위하여 데이터마이닝 기법을 이용할 수 있다. 심전도신호를 분류하기 위한 기존의 연구들은 왜곡된 특징추출과 과적합 등 문제점을 가지고 있다.

본 연구에서는 이와 같은 문제점들을 해결하기 위하여 BP 알고리즘과 SVM을 이용하여 심전도 신호를 분류해 보았다. 그 결과 SVM이 신경망에서 발생하는 과적합을 효과적으로 방지하고, 유일한 전역해를 보장함으로써, 일반화 성능에서 우수함을 보이고 있다는 사실을 확인하였다.

키워드 : 심전도, 데이터마이닝, BP 알고리즘, SVM, 신경망

### Abstract

ECG consists of various waveforms of electric signals of heart. Data mining can be used for analyzing and classifying the waveforms. Conventional studies classifying electrocardiogram have problems like extraction of distorted characteristics, overfitting, etc.

This study classifies electrocardiograms by using BP algorithm and SVM to solve the problems. As results, this study finds that SVM provides an effective prohibition of overfitting in neural networks and guarantees a sole global solution, showing excellence in generalization performance.

**Key words** : ECG, Data mining, BP algorithm, SVM, Neural Networks

## 1. 서 론

심전도(ECG : electrocardiogram), 뇌전도(EEG : electroencephalogram), 근전도(EMG:electromyograph) 등의 다양한 생체 신호를 분석하기 위해 여러 가지 방법들이 연구되고 있다. 그 중에서 심전도 데이터는 심장의 전기적인 신호의 다양한 파형으로 이루어진다. 이와 같은 파형을 분석하고 분류하기 위해서 데이터마이닝의 기법을 이용할 수 있다.

데이터마이닝의 기법 중 패턴 분류는 주어진 데이터로부터 특정 정보를 자동적으로 찾아내는 문제(특징 추출)와 주어진 데이터를 2개 이상의 그룹으로 분리하여 특성을 파악하는 문제(분류)로 크게 나뉘어진다. 이러한 패턴 분류 문제는 의료 이미지 정보의 자동해석(MRI, NMI, X-ray 등), 자동생산시스템의 품질검사, 컴퓨터 음성인식, 물질 분류, 지질 변화 예측, 지문 인식, 홍채 인식, 문자 인식 등의 다양한 응용분야를 가지고 있다. 그리고 이러한 패턴 분류 문제를 해결하기 위한 방법으로 전통적인 통계적 패턴 분류와 구문론적 패턴 분류 기법이 사용되고 있었으나, 점차 신경망의 활

용이 확대되어 가고 있다.

신경망을 이용하여 패턴 분류 문제를 해결하려 할 경우 일반적으로 BP(backpropagation) 알고리즘이 가장 많이 쓰인다. 그러나 BP 알고리즘을 쓸 경우 복잡한 입력 패턴의 분포를 추정하기가 어려우므로 학습 단계에서 더 많은 양의 학습 데이터가 필요하게 된다. 지역적 최소값(local minimum)을 피하기 위한 초기화 작업이 거의 경험적으로 이루어지며, 수렴속도의 지연 그리고 근사화 및 수렴율에 영향을 미치는 커널 함수(kernel function)의 선택 등이 여전히 어려운 문제로 남아 있다. 또한 수렴성을 증명하는 문제도 풀어야 할 과제로 남아있다.

이러한 문제들은 1995년 Vapnik에 의해 제안된 범용 퍼드 포워드 네트워크의 한 종류인 SVM(Support Vector Machine) 방법으로 인하여 새로운 연구의 전환기를 맞고 있다. SVM[1]의 특징으로는 첫째, 명료한 이론적 근거에 기반하고 있다. 이는 입력으로부터 어떠한 학습 방법을 이용하는가에 대한 직관적인 해석을 제공해 준다. 즉, 간단하고 명료한 알고리즘을 통하여, 학습을 성공적으로 수행하는데 영향을 미치는 요소들을 규명할 수 있다. 둘째, 실제 응용 문제에서 높은 인식 성능을 나타낸다. 그러나 실제 응용에서는 신경망과 같이 보다 복잡한 구조의 패턴 분류기를 요구한다. SVM 기법은 이런 분류기를 이용하여 입력 공간의 비선형적

접수일자 : 2003년 11월 27일

완료일자 : 2004년 1월 26일

인 높은 차수를 특징 공간에서 선형적으로 투영하여 해석할 수 있도록 하며, 각 특징 사이의 최적의 경계(최적분리면)를 제시한다. 이러한 특성으로 인해 SVM은 비선형 패턴 분류 문제, 데이터마이닝, HCI(Human Computer Interaction), 웹마이닝, 컴퓨터 비전, 인공지능, 예측, 의학진단 등의 분야에서 크게 활용될 것으로 보여, 최근 매우 활발하게 연구가 진행되고 있다.

본 논문에서는 심전도 신호의 패턴을 분류하기 위하여 심전도 패턴의 특징으로부터 추출된 파라미터들을 BP 알고리즘과 SVM에 적용하여 패턴 분류를 효과적으로 수행하는지 성능을 비교하였다.

## 2. 심전도 신호의 패턴 분류

심전도 신호, 기존의 연구, 패턴을 분류하기 위한 전처리 과정인 특징을 추출하는 방법, 패턴을 분류하는 신경망 기반의 BP 알고리즘과 SVM에 대하여 설명한다.

### 2.1 심전도 신호

심전도(ECG)는 심장의 상태를 비관혈적(non invasive)으로 진단하는 매우 중요한 수단으로 활용되며, 진폭은 수 mV 이고 주파수는 250Hz이내의 생체전위 신호 중 하나이다. 심전도 시스템의 설계와 신호처리에 관한 연구는 1960년 초부터 미국을 중심으로 연구가 시작되어, 자동진단 다채널 심전계를 비롯하여 24시간동안 심장질환 환자를 모니터링하는 홀터 심전계, 운동부하 상태에서 심장 이상을 진단하는 스트레스 심전계 등의 하드웨어 설계와 정확한 알고리즘 개발을 위한 연구가 지속적으로 이루어져 왔다. 국내의 심전도 시스템의 설계와 신호처리에 관한 연구는 1980년 초부터 시작되었다. 대략 10년 동안의 기반기술 축적으로 1990년 초반부터 본격적인 심전계의 개발에 들어갔으며, 현재 12채널 진단 심전계, 홀터 심전계, 스트레스 심전계, 그리고 환자감시 장치 등의 심장관련 진단기에 대한 연구가 활발히 이루어지고 있다. 여러 연구에도 불구하고 심근허혈, 심근경색에 대해서는 아직도 오진이 자주 있는 상황이다. 이러한 병의 진단은 심전도 신호의 ST 세그먼트의 레벨이나 기울기가 상승 혹은 하강되었는지에 대한 여부를 파악하는 것이다.

아래의 [그림 1]은 ST 세그먼트의 위치를 보여준다. 이 ST 세그먼트는 1Hz미만의 주파수 대역을 가지고 있으므로 저주파신호의 기저선(baseline) 변동 잡음, 전 주파수 대역에 존재하는 근잡음(muscle artifact)과 같은 주파수 대역에 존재하므로 정확한 잡음을 제거하지 못하면 신호의 왜곡이 발생하므로 오진을 하게 된다. 기저선 변동 잡음 제거를 위한 전처리 필터로는 현재 스플라인 보간법, FIR 필터, 적응필터, 신경망, 웨이블릿 변환 방법들로 신호의 왜곡을 최소화하여 기저선 변동 잡음을 제거한다. 그 중 웨이블릿 변환 방법은 신호를 다중 해상도로 처리하며 변환된 신호는 시간과 주파수 영역에서 해상도가 뛰어나므로 비정상(non-stationary)적인 신호 분석에 유리한 방법으로 제시되고 있다. 이 웨이블릿 변환은 모함수(mother wavelet)를 통해 모든 과정이 이루어지므로, 동일한 웨이블릿 변환 방법을 사용한다고 하여도 모함수의 잘못된 선택으로 신호의 심한 왜곡을 가지고 오는 실수를 범할 수 있게 된다.

심전도 데이터를 분류하기 위한 기존의 여러 가지 방법들 [2][3][4]이 있으나, 오분류율의 감소 및 학습시간의 단축에서 성능이 우수한 BP 알고리즘과 SVM을 적용하여 비교

분석할 필요가 있다.




그림 1. 심전도 파형의 ST 세그먼트

### 2.2 심전도 신호를 분류하기 위한 기존의 연구

일반적으로 심전도 신호를 분류하기 위한 기존의 연구들은 신경망 기반의 연구와 신호처리 기반의 연구로 분류할 수 있다.

신경망 기반의 연구로는 HEDEN[5]의 BP 알고리즘을 이용한 연구가 이에 해당되며 초기 학습률( $\mu$ )을 0.5로 설정하고, 연결강도의 변화량을 조정하는 상수인 학습률을 점차적으로 감소하도록 훈련을 진행하였다. 다음과 같이 수식 (1)은 점차적으로 변화하는 학습률의 방정식이다.

$$\mu = k\mu \quad (k=0.998) \quad \text{수식 (1)}$$

k-fold 교차검증을 사용하여 성능 검증을 시행하였으며, 오버 트레이닝을 막기 위해 k를 3개로 설정하였다. 그러나 측정 프로그램의 데이터에서 심각한 에러가 발생하여 네트워크가 적절하게 표현되지 못하였다.

Silipo[6]의 연구에서는 통계적인 분류 방법과 신경망을 이용한 분류 방법과의 성능을 비교하였다. Ambulatory ECG(AECG)를 분석하였으며 유럽인 데이터베이스를 사용하였으며, 통계적인 분류 방법중 최단거리법(single linkage method)을 사용하였는데 최종 오차를 RMS(mean square error)로 산출하였다. RMS값이 0.6보다 작을 때 훈련을 멈추도록 설계하였다. 그러나 오차의 범위를 너무 크게 잡아서 정확한 결과를 얻었다고 볼 수 없으며, 최소 0.001 정도는 되어야 한다.

신호처리 기반의 연구로는 sternickel[7]의 심전도 시계열 데이터의 패턴을 자동 탐지 기술을 소개한바 있다. 웨이블릿 변환을 이용해 다해상도를 표현하였으며, 시계열 데이터의 신뢰성을 주기 위해 홀터 심전도 기록기로 테스트하였다. P 파 검출에서는 웨이블릿 모함수로 coiflet6을 QRS Complex를 찾기 위해 모함수로 Haar를 사용하였다. 웨이블릿 모함수 결정은 매우 중요한 요인으로 잘못 설정하면 심전도의 진단 파라미터까지 왜곡시키므로 사용할 수 없게 된다.

### 2.3 특징 추출

본 논문에서는 원신호의 왜곡을 최소화하여 기저선을 제거할 수 있는 웨이블릿 모함수를 결정하기 위하여, 다양한 웨이블릿 모함수를 적용하여 기저선을 제거하였다.

ST 분절 구간 설정은 RR 간격이 600ms보다 클 경우는 R-peak에서 60ms 후부터, 그렇지 않은 경우는 40ms 후부터 160ms 동안으로 하였다. ST 분절의 특징을 추출하기 위하여 RR 간격이 600ms보다 클 경우 또는 그렇지 않을 경우에 대하여, ST0[ST 분절이 시작되는 지점(R+60 또는 R+40ms)에서의 진폭], ST60, ST80[R+140 또는 R+120ms 지점

에서의 진폭], ST 분절의 기울기, ST 분절의 면적(ST 분절의 구간에서 ST 분절과 isoelectric level로 둘러싸여진 면적)을 ST 분절의 특징을 나타내는 파라미터의 후보로 설정하였다.

2.4 분류

본 논문의 분류 방법으로는 BP 알고리즘과 SVM이 사용된다.

2.3.1 BP 알고리즘

다층 퍼셉트론(Multi Layer Perceptron)에 일반화된 델타 규칙(Generalization Delta Rule)을 학습 규칙으로 사용한 알고리즘을 BP 알고리즘이라 한다.

만일, 어떤 신경세포의 활성이 다른 신경세포의 잘못된 출력에 공헌을 하였다면, 두 신경세포 간의 연결 가중치를 그것에 비례하여 조절해 주어야 한다. 그리고, 그러한 과정은 그 아래에 있는 신경세포들까지 계속된다는 점이다. 이렇게 출력 층에서 발생한 에러를 위층으로 역전파시키므로, 오류 역전파 알고리즘이라 한다. [그림 2]는 일반적인 BP 알고리즘의 모형이다. 복잡함을 피하기 위해 1개의 은닉층에 5개의 은닉노드가 있는 경우를 고려하였다.




그림 2. BP 알고리즘 모델

목적 패턴에서 출력 신경세포의 활성값을 뺀 값이 바로 해당 출력 신경세포의 에러가 된다.

[그림 2]에서 e7, e8, e9, e10, e11로 나타낸 것이 각 출력 신경세포들의 에러이다. 에러를 여러번 가공하여 출력층 각각의 신경세포에 대해 델타( $\delta$ )라는 것을 구하게 된다. 그리고,  $f'(S)$ 는 활성함수의 미분 값을 말하며, 여기에서는 시그모이드 함수를 사용하였다.

2.3.2 SVM

SVM은 문제를 해결하기 위한 최적 분리 경계면을 제공한다. 훈련데이터  $\{(x_i, d_i), i = 1, \dots, N\}$ 가 주어졌을 때,  $x_i$ 는  $\{-1, 1\}$ 는 해 두 class 중 하나에 속하며,  $d_i \in \{-1, 1\}$ 는 해당 class를 표시하는 라벨의 역할을 한다. SVM은 각 class를 구분하는 최적의 분리경계면(separating hyper-plane)을 구하기 위해 분리경계면과 가장 분리경계면에 인접한 점(support vector)과의 거리를 최대화한다. 최적의 선형 분리경계면을  $f(x)=w^T x + b$ 로 놓으면, support vector와  $f(x)$ 의 거리를  $\frac{1}{\|w\|}$ 로 나타낼 수 있다.

SVM은  $\|w\|_2$ 를 최소화하여 분리 간격을 최대화하도록 하여 최적 분리면을 찾아낸다.

이 문제는 다음 수식 (2)과 같은 볼록 최적화(convex optimization) 문제가 된다.

$$\text{Min } \frac{1}{2} w^T w \tag{수식 (2)}$$

$$\text{s.t. } d_i (w^T x_i + b) \geq 1 \text{ for } i=1..,N$$

이 문제를 라그랑주 배수(Lagrange multiplier)로써 쌍대화 시키면 아래의 수식 (3)과 같은 Quadratic 문제가 된다.

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j x_i^T x_j$$

$$\text{s.t. } \sum_{i=1}^N \alpha_i d_i = 0, \alpha_i \geq 0 \tag{수식 (3)}$$

선형 분리경계면으로 완전히 구분할 수 없는 서로 겹쳐져 있는 패턴의 경우에는 slack variable( $\xi$ )를 사용한다. 수식 (1)로부터 아래의 수식 (4)과 같이 표현된다.

$$\text{Min } \frac{1}{2} w^T w + C \sum_{i=1}^N \xi_i \tag{수식 (4)}$$

$$\text{s.t. } d_i (w^T x_i + b) \geq 1 - \xi_i \text{ for } i=1..,N$$

$$\xi_i \geq 0 \text{ for all } i$$

수식 (4)의  $d_i (w^T x_i + b) \geq 1 - \xi_i$ 에서  $\xi_i = 0 (\forall i)$ 이면 모든 패턴을 완전하게 분리할 수 있다는 것을 의미한다.

그러나 대부분의 패턴은 선형적으로 분리가 가능하지 않다. 따라서 비선형 패턴을 분리하기 위하여 비선형 패턴의 입력 공간을 선형 패턴의 특징 공간(feature space)으로 전환한다.

(즉,  $x_i \Rightarrow \phi(x_i)$ ) 여기서 커널 함수  $K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ 를 정의하면 비선형 패턴을 분리하기 위한 모델은 수식 (2), 수식 (3), 수식 (4)으로부터 아래 수식 (5)와 같이 표현된다.

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j K(x_i, x_j)$$

$$\text{s.t. } \sum_{i=1}^N \alpha_i d_i = 0, 0 \leq \alpha_i \leq C \tag{수식 (5)}$$

여기서 C는 수식 (3)에서의 Penalty parameter이다. 위의 모델에서 라그랑주 배수  $\alpha_i$ 를 구하면 특징 공간에서 가장 평평한 함수인 수식 (6)를 구할 수 있다.

$$f(x, \alpha^*) = \sum_{i=1}^N d_i \alpha_i^* K(x, x_i)$$

$$= \sum_{i=1}^N d_i \alpha_i^* K(x, x_i) \tag{수식 (6)}$$

$d_i$ 는 학습데이터의 레이블,  $\alpha_i^*$ 는 라그랑주 승수,  $K(x, x_i)$ 는 커널 함수,  $x$ 는 입력데이터,  $x_i$ 는 SV(Support Vector)이다. 한편, 일반적인 커널 함수로는 아래의 세가지가 주로 사용한다.

커널 함수	분류기 형태
$k(x, x_i) = (x^T x_i + 1)^p$	degree p의 다항식
$k(x, x_i) = \exp(-\frac{1}{2\sigma^2} \ x - x_i\ ^2)$	RBF
$k(x, x_i) = \tanh(x \cdot y - \theta)$	다층퍼셉트론

여기서  $p, \sigma^2, \beta_0, \beta_1$ 은 모수(parameter)이다.

### 3. 실험 및 결과

#### 3.1 실험 환경 및 데이터

실험을 위한 시스템의 운영체제는 Windows XP, CPU는 Pentium 4 2.5GHz, RAM은 256 Mb이다. 이런 사양에서 Matlab 6.5로 실험하였다.

European ST-T database의 e0103, e0105, e0111을 선택하였으며, 유럽인 ST-T 데이터베이스로부터 ST 분절에서 임상소견 중 정상(normal)과 비정상(ST episode를 갖는 데이터)으로 분류하였다.

아래의 [그림 3] [그림 4]는 훈련데이터와 검증데이터이다.

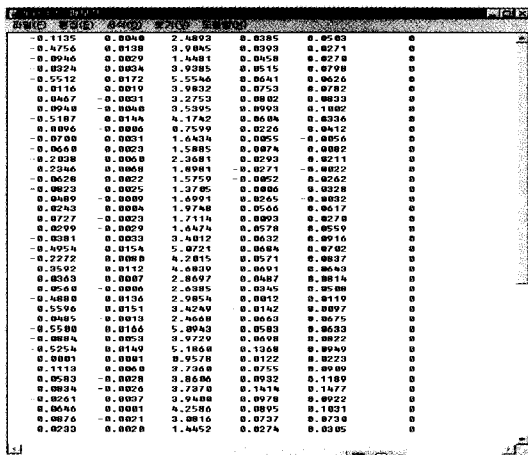


그림 3. 훈련데이터

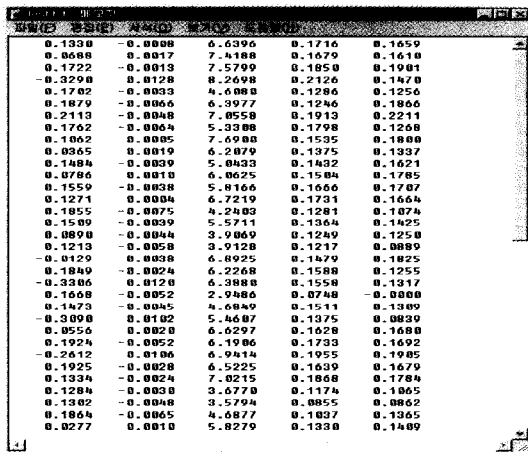


그림 4. 검증데이터

[그림 3]의 훈련 데이터 1열부터 5열까지는 특징 추출된 ST0, ST60, ST80, ST 분절의 기울기, ST 분절의 면적을 의미한다. 마지막 6열은 정상(0)인지 비정상(1)인지를 미리 결과값을 알려준다.

[그림 4]는 검증 데이터 1열부터 5열까지는 특징 추출된 ST0, ST60, ST80, ST 분절의 기울기, ST 분절의 면적을 의미하며, 정상인지 비정상인지에 관한 정보를 알려주지 않는다.

#### 3.2 특징 추출

원신호의 왜곡을 최소화하여 기저선을 제거 할 수 있는 웨이브렛 모함수를 결정하기 위하여, 다양한 웨이브렛 모함수를 적용하여 기저선을 제거하였다.

실험결과 가장 우수했던 웨이브렛 모함수는 db8(diff. : 27.12), coif5(diff : 25.32), sym7(diff : 25.13) 이었으며, diff(meanSNR - meanRSE)의 값이 23미만으로는 심전도의 진단 파라미터까지 왜곡 시키므로 사용할 수 없다는 것을 알 수 있었다.

#### 3.3 분류

##### 3.3.1 BP 알고리즘

(1) BP 알고리즘의 학습 방법과 수렴 결과

MATLAB6.5에서 제공하는 BP 알고리즘의 학습 방법 중 속도와 메모리를 비교한 결과 우수한 4가지를 선택하여 심전도 데이터에 적용해보았다. traincgf는 Fletcher Powell Conjugate Gradient, trainlm은 Levenberg Marquardt, trainbfg는 BFGS Quasi Newton, trainrp는 Resilient Backpropagation이다. 아래의 [그림 5]과 같이 수렴 결과를 보여준다. (b)는 (a)에서처럼 10-5에서 근사하게 수렴하는 모습을 보였으나 (b)나 (d)는 언더피팅, 오버피팅을 하기 때문에 적용하고자 하는 문제에 적합하지 못하다는 것을 실험을 통해서 알 수 있다.

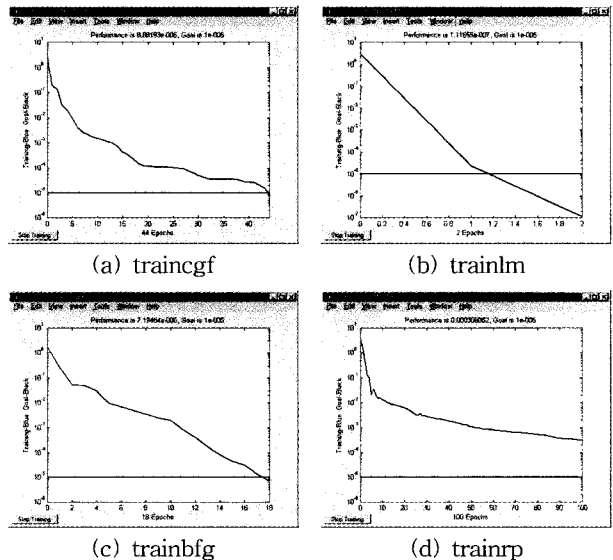


그림 5. 4가지 학습 방법의 수렴 결과

실험 결과 BP 알고리즘의 학습 방법 중에서 traincgf를 적용한 것이 가장 적절히 수렴하는 것을 알 수 있었다.

(2) 학습 횟수의 변화가 MSE에 미치는 영향




그림 6. 학습 횟수와 MSE값 비교

학습 횟수가 많아질수록 학습하는 과정에서 많은 시간이 소요되기 때문에 오차가 더 이상 줄어들지 않는 시점에서 학습을 멈추게 할 수 있도록 학습 횟수를 지정해 줄 필요가 있다.

[그림 6]에서는 학습 횟수의 증가에 따라 MSE는 지수 함수적으로 감소함을 볼 수 있으며, 10,000회 이상에서는 MSE가 느리게 감소함을 알 수 있었다.

(3) 학습률의 변화가 MSE에 미치는 영향

학습률은 대개 0.01~1 범위의 값을 사용한다. 그러나 신경망을 적용하는 문제의 특징에 따라서 각기 다른 결과를 보이기 때문에 적용하고자 하는 심전도 신호의 특징에 맞는 최적의 학습률을 찾는 실험이 필요하다. 그래서 학습률을 0.1부터 0.7까지 0.2의 간격으로 실험한 결과 MSE의 분포가 0.1 부근에서 가장 작게 나타나서 다시 0.01부터 0.01간격으로 0.1까지 실험해 보았다. 아래의 [표 1]은 e0105와 e0111 데이터를 학습횟수 5,000회, 10,000회, 15,000회에서 다양한 학습률로 실험한 결과이다.

[그림 7]과 [그림 8]은 학습률에 따른 MSE를 e0105와 e0111에 대해서 그래프로 보여준다.

e0105 데이터에서는 학습을 5,000회 반복시킨 경우 MSE는 학습률 0.1지점에서 최소값을 보였고, 10,000회에서는 0.05에서 15,000회에서는 0.04에서 각각 최소값을 보였으며, e0111 데이터에서 이에 상응하는 최적학습률은 각각 0.08, 0.07, 0.05로 나타났다.




그림 7. e0105 경우 학습률에 따른 MSE




그림 8. e0111 경우 학습률에 따른 MSE

표 1. 학습률과 MSE값 비교

학습률	E0105			E0111		
	5,000회	10,000회	15,000회	5,000회	10,000회	15,000회
0.01	1.69	1.68	1.68	8.69	8.55	8.24
0.02	1.68	1.66	1.60	8.55	7.62	6.42
0.03	1.65	1.49	1.17	8.10	6.20	4.93
0.04	1.57	1.21	0.89	7.37	6.09	4.50
0.05	1.47	0.97	0.90	6.65	4.89	4.30
0.06	1.35	1.00	0.90	6.18	4.84	4.30
0.07	1.27	1.00	0.91	5.98	4.67	4.33
0.08	1.23	1.10	0.92	5.88	4.71	4.36
0.09	1.22	1.04	0.95	6.02	4.80	4.52
0.10	1.21	1.06	0.97	6.28	4.98	4.56
0.15	3.25	1.41	1.18	6.79	6.91	6.80
0.20	7.45	6.03	5.79	7.49	7.09	6.81
0.25	11.44	9.24	9.12	10.09	7.78	7.04
0.30	19.27	11.74	10.99	13.00	13.0	14.26

3.3.2 SVM

SVM 분류기의 커널 함수는 다항식(polynomial)을 사용하였다. 다항식의 차수는 3으로 주었다. 마진폭과 분류 오류 사이의 타협점을 찾아주는 역할을 담당하며, 분리할 수 없는 데이터에 대한 오류 패널티 변수인 C값은 1로 주었다. 실험 내용은 [표 2]에서와 같이 2가지 방법에 대해 특정 추출된 심전도 신호를 분류하여 성능을 비교해 보았다.

표 2. 분류 성능 비교(분류율(%))

Classifier	BP 알고리즘	SVM
e0103	66%	55%
e0105	35%	75%
e0111	53%	76%

e0103 에서만 BP 알고리즘이 SVM보다 근소한 차이로 우수하나 SVM이 전체 최적치(global optimum)를 위한 정확한 파라미터들을 학습하지 못 할 수도 있으며 또한 학습을 통하여 얻어진 Support Vector들이 미지의 테스트 데이터를 완전히 분류하는데 충분하지 못한 경우라고 사료된다. e0105에서는 BP 알고리즘이 35%, SVM 75%를 분류율을 나타내

며 e0111에서도 BP 알고리즘이 53%, SVM 76%의 결과를 나타내므로 BP 알고리즘이 과적합에 따른 일반화 성능이 떨어짐을 보여준다. SVM이 신경망에서 발생하는 과적합을 효과적으로 막아 주고, 또한 유일한 전역해를 보장함으로써 일반화 성능에서 우수함을 보이고 있다.

### 5. 결론 및 향후 과제

본 논문에서는 심전도 신호의 패턴을 분류하기 위하여, 심전도 패턴의 특징으로부터 추출된 파라미터들을 기계학습의 입력으로 설정하였다.

BP 알고리즘을 적용한 실험에서는 traincgf를 사용했을 때 원하는 지점에서 적절히 수렴하는 것을 보였으며, 학습횟수의 증가에 따른 최종에러 즉, MSE는 지수 함수적으로 감소함을 볼 수 있으며, 10,000회 이상에서는 MSE가 느리게 감소함을 알 수 있다. 학습률과 MSE가 미치는 영향에서는 각각의 데이터에 따라서 최적의 학습률이 모두 다르게 나타났으나, 대략적으로 0.04에서 0.1사이에서 좋은 결과를 보였다.

SVM과 BP알고리즘의 분류 성능을 비교한 결과 SVM이 더 좋은 분류 성능을 보였다. SVM이 이진 분류하는 문제에 있어서 보다 간단하고 효율적인 방법이라고 평가되었다. 하지만 90% 이상의 분류율을 보이려면 더 많은 훈련 데이터로 학습을 시켜야하며, 일반화 성능도 높아질 것이라 사료된다.

향후 연구 과제로는 SVM의 속도와 메모리의 한계점을 극복하기 위해 단일 SVM보다는 앙상블 구성이나 다중 SVM을 접목하여 이러한 문제점들에 대해 연구할 계획이다.

### 참고문헌

[1] www.support vector.ws/html/downloads.html.  
 [2] Z. Dokur and T. Olmez, "ECG beat classification by a novel hybrid neural network", Computer Methods and Programs in Biomedicine, Volume 66, Issues 2 3, pp. 167 181, September 2001.  
 [3] P.M. Rautaharju, S.H. Zhou, E.W. Hancock, B. Milan Horvath, Dirk Q. Feild, James M. Lindauer, Galen S. Wagner, O. Pahlm and Charles L. Feldman, "Comparability of 12-lead ECGs derived from EASI leads with standard 12-lead ECGs in the classification of acute myocardial ischemia and old myocardial infarction", Journal of Electrocardiology, Volume 35, Issue 4, Part 2, pp. 35 39, October 2002.  
 [4] U. Rajendra Acharya, P. Subbanna Bhat, S. S. Iyengar, A. Rao and S. Dua, "Classification of heart rate data using artificial neural network and fuzzy equivalence relation, Pattern Recognition", Volume 36, Issue 1, pp. 61-68, January 2003.

[5] B. HEDEN, "Agreement Between Artificial Neural Networks and Experienced Electro cardiographer on Electrocardiographic Diagnosis of Healed Myocardial Infarction", JACC, Vol.28, No.4, pp. 1012 1016, October 1996.  
 [6] R. Silipo, M. Goru, A. Taddei, M. Varanini, C. Marchesi, "Classification of Arrhythmic Events in Ambulatory Electrocardiogram, Using Artificial Neural Networks", Computers and Biomedical research Vol.28, pp. 305 318, 1995.  
 [7] K. Sternickel, "Automatic pattern recognition in ECG time series", Computer Methods and Programs in Biomedicine, Vol.68, pp. 109 115, 2002.  
 [8] <http://www.kernel-machines.org>.

### 저 자 소 개



김만선(Man-Sun Kim)

2000년 홍익대학교 전자전기컴퓨터공학부 (공학사)  
 2002년 공주대학교 대학원 전자계산학과 (이학석사)  
 2002년~현재 공주대학교 대학원 컴퓨터공학과 박사과정

관심분야 : 데이터마이닝, 신경망, 애니메이션, 기계학습  
 e mail : mansun@kongju.ac.kr



이상용(Sang-Yong Lee)

1984년 중앙대학교 전자계산학과(공학사)  
 1988년 일본동경공업대학 총합이공학연구과 (공학석사)  
 1988년~1989년 일본 NEC 중앙연구소 연구원  
 1993년 중앙대학교 일반대학원 전자계산학과(공학박사)

1993년~현재 공주대학교 정보통신공학부 교수  
 1996년~1997년 University of Central Florida 방문교수

관심분야 : 인공지능, 기계학습, 에이전트, 바이오인포매틱스  
 e mail : sylee@kongju.ac.kr