

심전도를 이용한 통증자각 패턴분류기 설계

임현준[†], 유선국^{††}

Design of a Pattern Classifier for Pain Awareness using Electrocardiogram

Hyunjun Lim[†], Sun Kook Yoo^{††}

ABSTRACT

Although several methods have been used to assess the pain levels, few practical methods for classifying presence or absence of the pain using pattern classifiers have been suggested. The aim of this study is to design a pattern classifier that classifies the presence or absence of the pain using electrocardiogram (ECG). We measured the ECG signal from 10 subjects with the painless state and the pain state(Induced by mechanical stimulation). The 10 features of heart rate variability (HRV) were extracted from ECG - MeanRRI, SDNN, rMSSD, NN50, pNN50 in the time domain; VLF, LF, HF, Total Power, LF/HF in the frequency domain; and we used the features as input vector of the pattern classifier's artificial neural network (ANN) / support vector machine (SVM) for classifying the presence or absence of the pain. The study results showed that the classifiers using ANN / SVM could classify the presence or absence of the pain with accuracies of 81.58% / 81.84%. The proposed classifiers can be applied to the objective assessment of pain level.

Key words: Bio-Signal, Electrocardiogram, Pain, Artificial Neural Network, Support Vector Machine

1. 서 론

사람들이 살아가면서 느끼는 통증은 원인과 아픈 정도가 매우 다양하다. 같은 자극이라도 어떤 사람은 엄청난 통증을 느끼기도 하고 어떤 사람은 참을 정도로 일상생활을 유지하기도 한다. 이는 개인의 체질과 성향에 따라 자극에 대한 민감성이 서로 다르기 때문이다. 대부분의 통증은 의학적 상태에서 나타나는 주된 증상이지만 어떠한 자극 또는 병적 원인이 없음에도 불구하고 통증이 일어나는 경우도 있다[1]. 이러한 통증이 지속될 경우 신체에서 복잡한 스트레스

반응이 일어나는데 스트레스가 지속되면 인간이 삶을 영위하고 기본적인 기능을 해가는 데 심각한 영향을 줄 수 있다[2-3].

따라서 병원 내 뿐만 아니라 외부 환경에서 통증을 관리하기 위해서는 통증 수준을 객관적이고 정확하게 측정·평가할 수 있는 기술이 필요하다. 실제 병원에서는 환자의 통증 수준을 측정·평가하기 위해 여러 방법이 사용되고 있다. 일반적으로 사용되고 있는 것은 수치적으로 통증을 측정할 수 있는 숫자 척도 등급(Numeric Rating Scale; NRS)이다. NRS는 수평선상에 자신이 느끼고 있는 통증 수준을 0-10점

※ Corresponding Author: Sun Kook Yoo, Address: (03722) Yonsei-ro 50, Seodaemun-gu, Seoul, Korea, TEL: +82-2-2228-1919, FAX: +82-2-363-9923, E-mail: SUNKYOO@yuhs.ac

Receipt date: May 31, 2017, Revision date: Jul. 28, 2017
Approval date: Aug. 22, 2017

[†] Dept. of Medical Engineering, Yonsei University College of Medicine (E-mail: hhyunjjun@naver.com)

^{††} Dept. of Medical Engineering, Yonsei University College of Medicine

※ This work was supported by R&D Program of ministry of Trade, industry and Energy/korea Evaluation institute of industrial Technology(Grant No, MOTIE/KEIT 10047988, Development of depth of anesthesia and nociception monitoring device based on fronto-parietal functional connectivity in human brain)

까지의 숫자로 계량화한 것으로, 0점(전혀 통증을 느끼지 않는다), 10점(극히 심한 통증을 느낀다)을 표기하여 통증 없음(0점), 경도의 통증(1-3점), 중간 정도의 통증(4-6점), 심한 통증(7-10점)으로 구분된다[4-5]. 하지만 인지 장애로 인해 의사소통에 문제가 있거나 마취를 하여 의식이 없는 환자의 경우에는 NRS를 사용할 수 없고, 통증에 대하여 사람마다 느끼는 정도가 다르기 때문에 이는 주관적 판단이다.

이에 따라 본 연구에서는 사람의 통증 정도를 객관적으로 측정하기 위해 심장박동을 나타내는 심전도(Electrocardiogram; ECG) 신호를 기반으로 자율신경계의 활성을 반영하는 심박변이도(Heart Rate Variability; HRV)를 분석하였다. 그리고 통증자극에 따른 HRV의 특징을 추출하였고, 패턴 분류 알고리즘인 인공 신경망(Artificial Neural Network; ANN)과 서포트 벡터 머신(Support Vector Machine; SVM)을 사용하여 통증 수준을 이분법적으로 분류하는 통증자각 분류기를 설계하였다. 제안한 알고리즘의 유효성을 평가하기 위해 통증이 없는 상태와 기계적 자극법을 통한 통증이 있는 상태 총 2가지 상태를 유발하여 심전도 데이터를 획득하였다. 이로부터 HRV의 특징을 추출하여 패턴 분류기를 학습함으로써 통증자각 유무 분류 정확도를 계산하였다.

본 논문의 구성은 다음과 같다. 2장에서 본 논문에서 사용된 패턴 분류 알고리즘인 ANN, SVM에 대하여 정의한 다음, 3장에서 제안하는 통증자각 분류 알고리즘을 설명한다. 그리고 4장에서는 제안한 알고리즘으로 통증 유발 실험한 결과를 분류 정확도 분석을 통해 성능을 평가하고 5장에서 고찰과 결론을 맺는다.

2. 이 론

2.1 인공신경망

ANN은 일반적으로 계층 구조에 따라 크게 단층 신경망(Single-Layer Perceptron)과 다층 신경망(Multi-Layer Perceptron; MLP)의 2가지로 구분된다. 단층 신경망은 입력층(Input layer), 출력층(Output layer)으로만 이루어진 신경회로망이고, 다층 신경망은 일반적으로 입력층, 출력층 이외의 하나 이상의 은닉층(Hidden layer)으로 구성된 신경회로망을 의미한다. 입력층과 출력층은 각각 외부로부터의 입력을 받아들이는 역할과 결과를 출력하는 역할을 수행하며, 은닉층은 입력층으로부터 출력층으로의 계산과정에 이용된다. 각 층 사이에는 연결가중치(Weight)가 존재하며 이들은 두 성분 사이의 연결 정도를 나타내는데, 주어지는 입력에 따라 학습 알고리즘인 역전파(Back-Propagation) 알고리즘을 이용하여 출력값과 설정된 목표값 간의 오차가 감소하는 방향으로 연결가중치를 수정하면서 학습해나간다. 따라서 본 논문에서는 Fig. 1과 같이 심전도와 통증자각 간의 복잡한 비선형 분류 문제를 해결하기 위해 입력층, 1개의 은닉층, 출력층으로 구성된 전방향(Feedforward) 다층 신경망을 이용하였다[6]. 역전파(Back-Propagation) 알고리즘에서의 학습은 Scaled Conjugate Gradient 알고리즘을 사용하였고, 활성화 함수에 대하여 은닉층에는 Sigmoid 함수, 출력층에는 Softmax 함수를 사용하였다.

2.2 서포트 벡터 머신

SVM은 Vapnik에 의해 이원 패턴 분류 문제를 해결하기 위해 고안된 지도학습 알고리즘으로, 주로 분

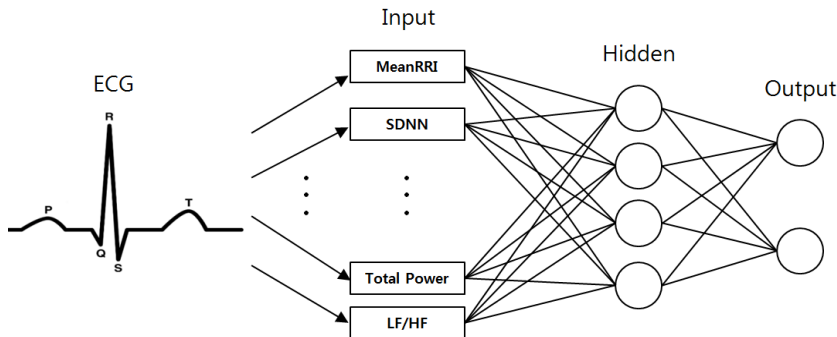


Fig. 1. The proposed back-propagation neural network.

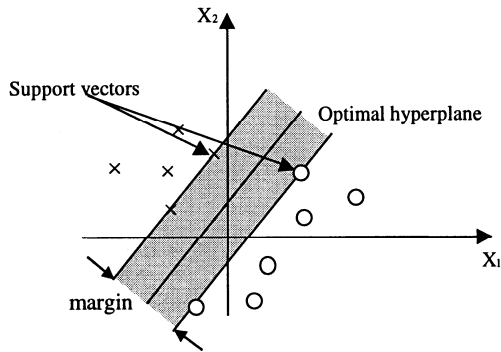


Fig. 2. Support vector machine structure.

류와 회귀분석에 응용되고 있는 이진 분류기이다[7]. Fig. 2에서와 같이 각 분류의 경계선에 가장 가까이 있는 데이터를 Support Vector라고 하며, 두 그룹의 데이터를 분류할 수 있는 최적의 초평면(Hyperplane)을 찾는 분류 모델이다[8]. 기존의 주로 사용되었던 ANN을 비롯한 다른 신경망들은 분류 오차를 최소화해 기반을 둔 반면, SVM은 초평면과 직교방향으로 가장 가까이 있는 Support Vector 간의 거리(Margin)를 최대화하여 일반화 능력을 극대화하고자 한다[9].

SVM에서는 학습 과정 전에 사용자가 직접 파라미터 값을 결정해야 하며, 파라미터 값에 따라 SVM의 성능이 달라진다. 미리 결정해야 하는 파라미터는 학습 과정에서 마진폭과 분류 오류 사이의 타협점(Trade-off)을 찾아주는 오류 패널티(penalty) 변수 C와 SVM에 적용되는 커널 함수(Kernel function)의 파라미터이다. C는 작을수록 모델을 간단히 하고 마진폭을 극대화시켜 일반화하려는 경향이 있고, 커질수록 모델은 복잡하지만 최적의 초평면을 생성하여 입력데이터에 대하여 분류 오류를 최소화시키려는 경향이 있다. 커널 함수는 선형분리가 불가능한 경우에 입력벡터를 고차원 공간으로 사상시킴으로써 선형분리가 가능하게 하는 역할을 한다. 따라서 주어진 입력데이터에 대하여 모델의 복잡성과 분류 성능을 고려하여 최적의 C값과 커널 함수를 찾는 것이 중요하다. 본 논문에서 사용된 대표적인 커널 함수는 Table 1과 같다.

3. 연구 방법

3.1 제안한 알고리즘의 개요

Table 1. Typical SVM kernel functions

Type	Expression
Linear Function	xy
Polynomial Function	$(xy+1)^d$
Radial Basis Function	$\exp(-\gamma \ x-y\ ^2)$

x : Training vector, y : Support vector,
 d : Degree, γ : Gamma

본 논문에서는 심전도를 이용하여 통증자각 유무를 분류하기 위한 알고리즘을 제안한다. Fig. 3에 제안하는 통증자각 분류 알고리즘의 전체적인 흐름도를 나타내었다.

통증 자극 실험을 통하여 측정된 심전도 데이터에 대하여 노이즈 제거 등 신호 처리 과정을 거친다. 그리고 심전도에서 R-peak를 정확히 검출하여 HRV를 구성한다. 구성된 HRV부터 통증 자극에 따른 HRV의 변화 특성을 반영하는 특징을 추출한다. 추출된 특징을 패턴 분류기의 입력으로 사용하기 위해 정규화 과정을 거쳐 입력벡터를 생성하고, 패턴 분류 알고리즘인 ANN과 SVM을 이용하여 통증자각 유무를 분류한다.

3.2 실험 과정 및 데이터 획득

본 연구에서는 특별한 의학적 병력이 없는 성인 남성 10명을 피험자 대상으로 실험을 진행하였다. 피험자의 연령은 24~30세 이고 평균연령은 26.7(±2.0)세 이다. 통증 유발 실험에 앞서 피험자의 질병 여부, 자율신경계에 영향을 줄 수 있는 약물 복용 여부, 음주 여부 등에 대한 질문을 실시했으며, 통증자각 이외의 감정의 안정 상태 유지를 위해 의자를 이용해 최대한 편안한 앉은 자세에서 실험을 진행하였다. 실험은 정상 상태에 대해 통증자각을 유발하는데 목적을 두고, 각 상태에 따른 심전도 신호를 측정하였다. 구성하고자 하는 상태는 통증이 없는 상태, 통증이




Fig. 3. Overview of proposed pain classification algorithm.

있는 상태로 총 2가지 상태이며, 통증자각 유발은 기계적 자극법을 이용하였다[10]. 먼저 피험자는 어떠한 외부 자극이 없는 휴식 상태로 현재 통증 수준을 확인하기 위한 NRS 설문과 14분 동안의 심전도 신호를 측정하였다. 이후 검지와 중지 사이에 막대를 이용해서 손가락뼈에 압력을 가하는 방식으로 설정된 통증 유발 시간(14분) 동안 참을 수 있을 정도의 통증을 지속적으로 유발하여 현재 통증 수준을 확인하기 위한 NRS 설문과 14분 동안 심전도 신호를 측정하였다. 획득된 신호의 표본화 주파수(Sampling frequency)는 300Hz이고, 분석은 MATLAB 프로그램(R2016a release, MathWorks Inc, USA)을 이용하였다.

3.3 신호 처리 과정

심전도는 심장의 활동 상태를 반영하는 전기적 신호로서 P-QRS[11] complex-T파로 이루어져 있다. 이러한 심전도 신호 측정 시, 호흡에 의한 기저선 변동, 측정 장치의 전원 노이즈 등이 발생하여 R-peak 검출의 오류를 발생한다. 따라서 정확한 심전도 분석을 위해 전처리 과정이 필요하다. 실제 심전도 신호는 1Hz-40Hz 사이의 주파수 대역을 나타냄에 따라, 본 논문에서는 1Hz-40Hz 대역 필터(Band filter)를 이용하여 노이즈 및 기저선 변동을 제거하였다. 그




Fig. 4. ECG signal and heart rate variability.

후, R-peak를 정확히 검출하여 R-R 간격(R-R Interval; RRI)을 통한 HRV를 구성하기 위해서 Pan and Tompkins의 QRS 검출 알고리즘을 이용하였다 [12].

3.4 심박 변이도 구성 및 특징 추출

HRV는 심전도 신호에서 R-peak 간 간격을 분당 심박 수로 환산하여 연속적으로 표시함으로써 시간에 따라 심장박동의 주기적인 변화를 나타낸 것이다. Fig. 5와 같이 심전도의 R-R 간격(혹은 N-N 간격)로부터 구성된 HRV는 자율신경계의 활성도를 나타

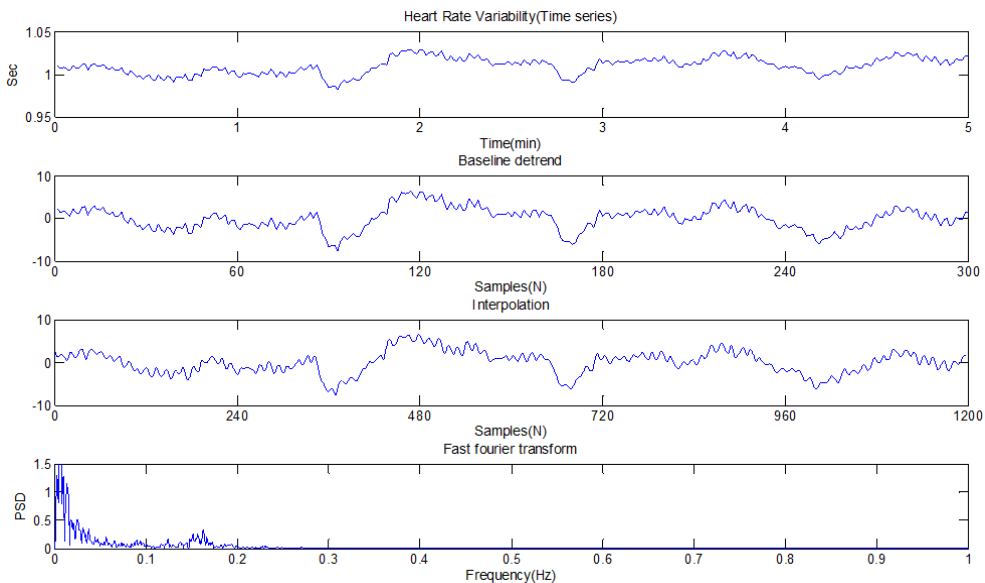


Fig. 5. Power spectrum analysis of heart rate variability.

Table 2. Features of heart rate variability for classification of presence or absence of pain

Feature		Description
Time Domain	MeanRRI	Mean of all RR intervals
	SDNN	Standard deviation of all RR intervals
	RMSSD	The square root of the mean of the sum of the squares of differences between adjacent RR intervals
	NN50	Number of pairs of adjacent RR intervals differing by more than 50ms in the entire recording
	pNN50	NN50 count divided by the total number of all RR intervals
Frequency Domain	VLF	Power in very low frequency range
	LF	Power in low frequency range
	HF	Power in high frequency range
	Total power	Variance of all RR intervals
	LF/HF	Ratio LF / HF

내는데, 시간 및 주파수 영역에서 해석을 통하여 통증에 따른 신체 내 변화를 평가할 수 있다[13]. 연속적인 HRV의 특징을 추출하기 위해 단기간 HRV 분석의 적합한 시간인 5분 동안의 신호를 기본으로 30초 Sliding window 방식을 적용하였다[14]. 따라서 피험자 1명당 휴식 상태 19개 data, 통증 있는 상태 19개 data가 생성된다. 각 data에서 추출된 시간 영역, 주파수 영역에서의 HRV 특징은 Table 2과 같다.

시간 영역의 특징으로, MeanRRI는 전체 R-R 간격의 평균값으로, 심박 수와 관련된 특징이고, SDNN은 전체 R-R 간격의 표준편차, rMSSD는 연속되는 R-R 간격의 차이의 제곱 평균에 대한 제곱근, NN50은 전체 R-R 간격 중 연속되는 R-R 간격의 차이가 50ms를 초과하는 개수, pNN50은 전체 R-R 간격 중 NN50 값의 비율을 나타낸다. 시간영역의 각 특징들은 수식 (1)-(5)로부터 구할 수 있으며, RR은 R-R 간격, N은 R-R 간격의 개수, duration(RR)은 연속되는 R-R 간격 간의 차이, sampleCOUNT()는 조건에 만족하는 개수를 나타낸다.

$$MeanRRI = \overline{RR} = \sqrt{\frac{1}{N} \sum_{j=1}^N (RR_j)} \quad (1)$$

$$SDNN = \sqrt{\frac{1}{N} \sum_{j=1}^N (RR_j - \overline{RR})^2} \quad (2)$$

$$r.MSSD = \sqrt{\frac{1}{N} \sum_{j=1}^N (RR_j - RR_{j-1})^2} \quad (3)$$

$$NN50 = sample\ COUNT(duration(RR) > 50msec) \quad (4)$$

$$pNN50 = \frac{NN50}{N} \times 100\% \quad (5)$$

주파수 영역에서의 HRV를 분석하기 위해서는 HRV의 시계열 데이터를 주파수 영역으로 변환해야 한다. 변환 과정은 Fig. 5과 같다. 먼저, R-R 간격 수열 데이터의 DC 성분을 제거하기 위한 기저선 보정(Detrend) 과정을 거쳤다. 그리고 주파수 분해능을 높이기 위하여 수열 데이터 4Hz 보간(Interpolation) 과정을 거친 후 주파수 누출 효과를 약화시키기 위해 50% overlapped Hamming 윈도우를 적용한 후에 고속 푸리에 변환(Fast Fourier Transform: FFT)에 의하여 주파수 영역으로 변환하였다. 특정 주파수 대역에 대한 스펙트럼 분포를 분석하여 주파수 영역의 특징을 추출하였다. 주파수 영역의 특징으로, 초저주파수인 VLF는 0.003-0.04Hz 범위의 스펙트럼 파워 합, 저주파수인 LF는 0.04-0.15Hz 범위의 스펙트럼 파워 합, 고주파수 HF는 0.15-0.4Hz 범위의 스펙트럼 파워 합, Total power는 0.003-0.4Hz 범위의 스펙트럼 파워의 합, LF/HF는 HF 스펙트럼 파워에 대한 LF 스펙트럼 파워의 비율이다.

3.5 정규화

HRV로부터 추출된 특징은 사람마다 편차가 존재하며, 서로 다른 크기의 값들을 가지고 있다. 이를 통증자각 유무 분류기의 입력 벡터로 사용하여 패턴 분류기를 효율적으로 학습하기 위해서는 특징들을 0-1 사이의 값으로 정규화하는 과정이 필요하다. 정규화 방법 중 흔히 사용되는 방법으로는 최대-최소 정규화 방법, 평균-분산 정규화 방법, 히스토그램 평활화(Histogram Equalization) 방법 등이 있다[15-

Table 3. NRS results for the subjects

Subject	NRS results	
	Relaxed	Pain induction
1	0	8
2	0	8
3	0	8
4	0	10
5	0	7
6	0	8
7	0	8
8	0	7
9	0	9
10	0	8

16]. 본 논문에서는 그 중 수식 (6)과 같이. 가장 간단 하면서 일반적인 최소-최대 정규화 방법을 이용하였다. D 는 특징별 입력 데이터이고, i 는 데이터 수, j 는 특징 수를 나타낸다.

$$D_{i,j}^{Normalized} = \frac{D_{i,j} - \min(D_{i,j})}{\max(D_{i,j}) - \min(D_{i,j})} \quad (6)$$

정규화된 입력벡터들은 통증이 없는 휴식 상태는 0, 통증이 있는 상태를 1로 라벨링하였다. 통증자각 분류를 위해 사용된 ANN과 SVM의 분류기 성능 평가는 10-fold cross validation을 통해 10명의 피험자에 대한 10개의 데이터 세트를 생성하여 분류 정확도 (Accuracy)로 평가하였다. 정확도는 식 (7)과 같이 계산된다. TP(True Positive)는 실제로 양성을 양성으로 분류한 개수, TN(True Negative)는 실제로 음성을 음성으로 분류한 개수, Total은 전체 데이터 개수를 나타낸다.

$$Accuracy = \frac{TP + TN}{Total} \times 100 \quad (7)$$

4. 결 과

4.1 피험자의 NRS 결과

실험에 따라 피험자의 통증 수준을 확인하기 위해 NRS 설문을 진행하였다. 피험자의 NRS 설문 결과는 Table 3과 같다. 피험자 모두 휴식 시 통증 없음 (NRS 0점)을 보였고, 통증을 유도했을 시 심한 통증 (NRS ≥ 7 점)을 보였다. 따라서 실험에 따라 피험자 모두 통증이 없는 상태, 통증이 있는 상태에 대해 통증이 적절히 유도되었다고 할 수 있다.

4.2 각 상황에 따른 특징별 통계적 유의성 평가

Table 4는 피험자들의 심전도 신호로부터 추출된 MeanRRI, SDNN, rMSSD, NN50, pNN50, VLF, LF, HF, Total Power, LF/HF 총 10개의 특징들의 휴식 (통증이 없는 상태)와 통증 유발(통증이 있는 상태) 상황에 대한 두 집단 간 평균값 차이를 비교하기 위해 비모수 검정인 Wilcoxon signed rank test를 통해 통계 분석한 결과이다. 검정 결과 유의 수준 95%에서 유의 확률이 0.0001 미만으로 통증 유무 상태 간의 통계적 유의미한 차이가 있음을 확인하였다.

4.3 ANN을 이용한 통증 유무 판별

추출된 특징 파라미터를 입력 벡터로 하고 ANN을 이용하여 통증자각 유무를 판별하였다. ANN의 최적의 은닉층 뉴런 개수를 찾기 위해 추출된 10개의 특징을 고정하고 은닉층 뉴런 개수들을 4-16개로 변

Table 4. Statistical analysis results by extracted features

Features	Relaxed [Mean \pm STD]	Pain induction [Mean \pm STD]	p-value
MeanRRI	1.01 \pm 0.15	0.84 \pm 0.09	<0.0001
SDNN	0.13 \pm 0.05	0.08 \pm 0.05	<0.0001
rMSSD	0.08 \pm 0.03	0.04 \pm 0.02	<0.0001
NN50	14.61 \pm 18.08	1.55 \pm 2.87	<0.0001
pNN50	4.87 \pm 6.03	0.52 \pm 0.96	<0.0001
VLF	28.64 \pm 24.19	17.98 \pm 33.37	<0.0001
LF	21.85 \pm 14.88	7.49 \pm 6.76	<0.0001
HF	24.89 \pm 18.06	5.14 \pm 5.36	<0.0001
Total Power	75.39 \pm 45.07	30.61 \pm 40.07	<0.0001
LF/HF	1.05 \pm 0.78	3.22 \pm 4.30	<0.0001

경하여 성능 비교하였다. Table 5의 결과를 통해 제안하는 ANN을 이용한 최적의 은닉층 뉴런 개수는 가장 높은 정확도를 보인 8개로 하였다.

Table 6에서는 최적의 은닉층 뉴런 개수인 8개를 적용한 ANN을 이용하여 통증자각 유무 분류에 적합한 특징을 찾기 위해 각각의 특징에 대한 성능을 비교하였다. rMSSD, NN50, pNN50, LF, HF, Total Power의 경우 나머지 6개의 특징들 보다 비교적 높은 정확도를 보였다. 73% 이상의 높은 정확도를 보인 상위 6개의 특징을 통증자각 유무 분류에 적합한 특징이라 하였다. 또한, 분류기의 입력으로 사용되는 특징 파라미터를 어떻게 조합하느냐에 따라 분류 정확도가 변한다. 따라서 최적의 은닉층 뉴런 개수인 8개를 적용한 ANN을 이용하여 최적의 특징 파라미터 조합을 찾고자 하였다. Table 7에서는 HRV 시간 영역의 특징들, HRV 주파수 영역의 특징들, HRV 모든 특징들, 적합하다고 설정한 특징들 이렇게 4개의 조합을 설정하여 성능을 평가하였다. 평가 결과, HRV 주파수 영역의 특징을 사용한 경우 81.58%의

Table 5. The classification results according to the number of hidden neurons

Number of Hidden Neurons	Accuracy(%)
4	79.21
6	75.26
8	81.32
10	76.58
12	73.42
14	77.37
16	79.21

Table 6. The classification results according to the number of hidden neurons

Features	Accuracy(%)
MeanRRI	67.11
SDNN	70.00
rMSSD	81.58
NN50	74.47
pNN50	74.47
VLF	66.32
LF	73.95
HF	81.58
Total Power	76.84
LF/HF	60.79

Table 7. The classification results according to the feature combinations when using ANN

Feature Combinations	Accuracy(%)
HRV Time domain features	71.05
HRV Frequency domain features	81.58
HRV Time domain features + Frequency domain features	81.32
HRV selected features	81.05

가장 높은 정확도를 보였다.

4.3 SVM을 이용한 통증 유무 판별

추출된 특징 파라미터를 입력 벡터로 하고 SVM을 이용하여 통증자각 유무를 분류하였다. 오류 패널티 변수인 C와 커널 함수에 대하여 최적의 조합을 찾고자 했다.

먼저, 추출된 10개의 특징을 고정하고 커널 함수로 Linear Function을 이용하여 C값을 0.1-1000으로 변경해가며 성능 비교하였다. Table 8 결과, Linear Function 커널 함수에서 C값이 1일 때 가장 높은 정확도를 보였다.

Table 9는 Polynomial Function을 이용하여 C값과 d값을 변경해가며 성능 비교한 결과이다. 그 결

Table 8. The classification results according to the penalty(C) when using SVM (Linear Function)

C	Accuracy(%)
0.1	80.79
1	81.58
10	77.63
50	76.58
100	75.79
500	75.00
1000	74.74

Table 9. The classification results according to the penalty(C) and degree(d) when using SVM (Polynomial Function)

C	d	Accuracy(%)
0.1	2	70.79
	3	74.21
	4	69.21
	5	68.16
	6	76.32

과, Polynomial Function 커널 함수에서 C값이 0.1, d값이 6일 때 가장 높은 정확도를 보였다.

Table 10은 Radial Basis Function (RBF)을 이용하여 C값과 γ 값을 변경해가며 성능 비교한 결과이다. 그 결과, RBF 커널 함수에서 C값이 100, γ 값이 0.001일 때 가장 높은 정확도를 보였다.

커널 함수별 성능 비교 결과, RBF 커널 함수 사용시 81.84%의 가장 높은 정확도를 보였다. 이에 따라, 위에서 설정한 4개의 특징 조합에 따라 RBF 커널 함수를 사용한 SVM 성능을 평가하였다(Table 11). 평가 결과, HRV 주파수 영역만을 이용하거나 추출된 모든 특징을 사용한 경우 81.84%의 가장 높은 정확도를 보였다. Table 12는 사용된 2가지 분류기 중 가장 높은 정확도를 보인 경우를 비교한 결과이다. HRV 주파수 영역의 특징과 SVM의 RBF 커널 함수

Table 10. The classification results according to the penalty(C) and gamma(γ) when using SVM (RBF)

C	γ	Accuracy(%)
100	0.001	81.84
	0.005	71.58
	0.01	74.21
	0.05	69.21
	0.1	66.32
	0.5	66.84
	1	73.68

Table 11. The classification results according to the feature combinations when using SVM (RBF)

Features Combinations	Accuracy(%)
HRV Time domain features	79.21
HRV Frequency domain features	81.84
HRV Time domain features + Frequency domain features	81.84
HRV selected features	80.00

Table 12. Comparison of the classification results of Pain classifiers

Classifiers	Features	Accuracy (%)
ANN (20 Hidden neurons)	HRV Frequency domain features	81.58
SVM (RBF)	HRV Frequency domain features	81.84

를 선택했을 때 가장 높은 분류 결과를 나타내었다.

5. 고찰 및 결론

본 연구에서는 심전도를 이용한 통증자각 유무 분류기 설계하는데 목적이 있다. 이는 자율신경계의 활성을 반영하는 HRV로부터 특징을 추출하여 자동으로 통증자각 유무를 분류해준다는 점에서 의미가 있다. NRS 설문을 이용하여 통증 수준을 수치적으로 표현하는 기존의 방법은 피험자의 주관적인 요소가 들어가 통증 수준을 판단 결과가 불확실하다는 한계가 있다. 이를 극복하고자 통증 수준 평가에 간단하고 객관적인 판단을 돕고자 패턴 분류 알고리즘인 ANN과 SVM을 이용하여 통증자각 유무를 이분법적 판단으로 나눠 분류하였다. 이때, 각 알고리즘의 최적의 파라미터를 선정하기 위해서 ANN의 은닉층 뉴런 개수, SVM의 오류 페널티 변수인 C값 및 각 커널 함수의 파라미터 값을 변경해가며 분류 결과를 비교하였다. 최적의 파라미터를 찾아내 통증자각 유무 분류 결과, ANN을 이용했을 때 81.58%, SVM (RBF)을 이용했을 때 81.84%의 분류 정확도를 보였다. 이 결과는 사람의 통증 상태에 따른 심전도 신호를 기반으로 통증자각 유무 분류에 있어 객관적으로 가능성을 나타내 향후 자동 통증 평가 시스템 개발시 유용하게 활용될 것이라 사료된다. 그리고 통증 수준 평가시스템에 대해 병원 뿐 만 아니라 일상으로의 확대를 통해 일상생활, 수면 등에서 발생할 수 있는 통증에 따른 위급상황에 대비 할 수 있을 것이라 생각된다. 이를 위해 향후 실시간 심전도 측정 기반 통증자각 유무 분류기 개발에 대한 연구가 필요할 것이다. 또한 대상자 수 확대를 통해 학습 데이터의 수를 증가시킴으로써 본 연구의 일반화 연구와 통증 수준을 이분법적이 아닌 NRS와 같이 더 많은 단계별(통증 없음, 약한 통증, 중간 정도의 통증, 심한 통증 등)로 구분하는 방법에 대한 연구가 필요하다.

REFERENCE

[1] Raj, P. Prithvi., *Taxonomy and Classification of Pain*, The Handbook of Chronic Pain, Nova Science Publishers, New York, pp. 41-56, 2007.
 [2] C.R. Chapman, R.P. Tuckett, and C.W. Song,

- "Pain and Stress in a Systems Perspective: Reciprocal Neural, Endocrine, and Immune Interactions," *The Journal of Pain*, Vol. 9, No. 2, pp. 122-145, 2008.
- [3] H. Breivik, P.C. Borchgrevink, S.M. Allen, L.A. Rosseland, L. Romundstad, and E.K. Breivik Hals, et al., "Assessment of Pain," *British Journal of Anaesthesia*, Vol. 101, No. 1, pp. 17-24, 2008.
- [4] C.T. Hartrick, J.P. Kovan, and S. Shapiro, "The Numeric Rating Scale for Clinical Pain Measurement: A Ratio Measure?," *Pain Practice*, Vol. 3, No. 4, pp. 310-316, 2003.
- [5] A. Williamson and B. Hoggart, "Pain: A Review of Three Commonly Used Pain Rating Scales," *Journal of Clinical Nursing*, Vol. 14, No. 7, pp. 798-804, 2005.
- [6] K. Hornik, M. Stinchcombe, and H. White, "Multilayer Feedforward Networks are Universal Approximators," *Neural Networks*, Vol. 2, No. 5, pp. 359-366, 1989.
- [7] C. Cortes and V. Vapnik, "Support-vector Network," *Machine Learning*, Vol. 20, pp. 273-297, 1995.
- [8] I. El-Naqa, Y. Yang, M.N. Wernick, N.P. Galatsanos, and R.M. Nishikawa, "A Support Vector Machine Approach for Detection of Microcalcifications," *IEEE Transactions on Medical Imaging*, Vol. 21, No. 12, pp. 1552-1563, 2002.
- [9] C.J.C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition," *Data Mining and Knowledge Discovery*, Vol. 2, No. 2, pp. 121-167, 1998.
- [10] M.H. Hyun and C.S. Kim, "Experimental Pain Induction and Subjective Pain Assessments," *Korean Journal of Stress Research*, Vol. 10, No. 2, pp. 51-58, 2002.
- [11] J.H. Kim, S.M. Lee and K.H. Park, "P-Waves and T-Wave Detection Algorithm in the ECG Signals Using Step-by-Step Baseline Alignment," *Journal of Korea Multimedia Society*, Vol. 19, No. 6, pp. 1034-1042, 2016.
- [12] J. Pan and W.J. Tompkins, "A Real-Time QRS Detection Algorithm," *IEEE Transactions on Biomedical Engineering*, Vol. 3, pp. 230-236, 1985.
- [13] G.G. Berntson, J.T. Bigger, D.L. Eckberg, P. Grossman, P.G. Kaufmann, M. Malik, et al., "Heart Rate Variability: Origins, Methods, and Interpretive Caveats," *Psychophysiology*, Vol. 34, No. 6, pp. 623-648, 1997.
- [14] A.J. Camm, M. Malik, J.T. Bigger, G. Breithardt, S. Cerutti, R.J. Cohen, et al., "Heart Rate Variability: Standards of Measurement, Physiological Interpretation and Clinical Use. Task Force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology," *Circulation*, Vol. 93, pp. 1043-1065, 1996.
- [15] F. Keinosuke, *Introduction to Statistical Pattern Recognition*, Academic Press, San Diego. 2013.
- [16] R.C. Gonzalez, R.E. Woods, and S.L. Eddins, *Digital Image Processing Using MATLAB*, McGraw Hill, New York. 2011.



임 현 준

2015년 동국대학교 의생명공학/
융합소프트웨어 학사
2015년~2017년 연세대학교 생체
공학협동과정 전기전자공
학전공 석사과정
관심분야: 생체신호처리, 기계학
습 등



유 선 국

1981년 연세대학교 전기공학과
학사
1985년 연세대학교 전기공학과
석사
1989년 연세대학교 전기공학과
박사

1995년~현재 대학교 연세대학교 의과대학 의학공학교
실 교수

관심분야: u-Health, 의료영상, 스마트 디바이스, 생체신
호처리 및 패턴 인식, 감성공학