

# 준 지도학습 알고리즘을 이용한 뇌파 감정 분석을 위한 학습데이터 선택 방법에 관한 연구

## A Study on Training Data Selection Method for EEG Emotion Analysis using Semi-supervised Learning Algorithm

윤 종 섭\*, 김 진 현\*

Jong-Seob Yun\*, Jin Heon Kim\*

### Abstract

Recently, machine learning algorithms based on artificial neural networks started to be used widely as classifiers in the field of EEG research for emotion analysis and disease diagnosis. When a machine learning model is used to classify EEG data, if training data is composed of only data having similar characteristics, classification performance may be deteriorated when applied to data of another group. In this paper, we propose a method to construct training data set by selecting several groups of data using semi-supervised learning algorithm to improve these problems. We then compared the performance of the two models by training the model with a training data set consisting of data with similar characteristics to the training data set constructed using the proposed method.

### 요 약

최근 감정 분석 및 질병 진단을 위한 뇌파 연구 분야에서 인공 신경망을 기반으로 한 기계학습 알고리즘이 분류기로 널리 사용되기 시작했다. 뇌파 데이터 분류를 위해 기계학습 모델을 사용하는 경우 유사한 특성을 가지는 데이터만으로 학습데이터가 구성되면 다른 그룹의 데이터에 적용했을 때 분류 성능이 떨어질 수 있다. 본 논문에서는 이러한 문제점을 개선하기 위해 준 지도학습 알고리즘을 사용해 여러 그룹의 데이터를 선택하여 학습데이터 세트를 구성하는 방법을 제안한다. 이후 제안하는 방법을 사용하여 구성한 학습데이터 세트와 유사한 특성을 가지는 데이터로 구성된 학습데이터 세트로 모델을 학습하여 두 모델의 성능을 비교하였다.

*Key words* : DEAP, EEG, Emotion Analysis, FFT, Machine Learning

\* Dept. of Computer Engineering, Seokyeong University

★ Corresponding author

E-mail : jinheon@skuniv.ac.kr, Tel : +82-2-940-7747

※ Acknowledgment

This research is supported by Ministry of Culture, Sports and Tourism(MCST) and Korea Creative Content Agency(KOCCA) in the Culture Technology(CT) Research & Development Program 2017.

Manuscript received Sep. 10, 2018; revised Sep. 19, 2018; accepted Sep. 20, 2018

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

### 1. 서론

뇌파(Electroencephalography, EEG)는 뇌 신경 사이의 신호 전달에 의해 생성되는 미세한 전류로 두피를 따라 배치된 전극에서 관찰된 신호를 증폭하여 전기적 신호로 관찰할 수 있다. 뇌파 측정은 MRI 및 CT와 같은 측정 방법보다 가벼운 장비를 사용하고, 가격이 저렴한 데 반해 다른 두 방법과 비교했을 때 시간 분해능이 뛰어나다는 장점이 있다. 이러한 장점 때문에 뇌 활동 분석 연구를 위한 도구로 널리 활용되고 있다. 뇌파를 이용한 연구 분야로는 인간의 감정 인식에 관한 연구[1]-[4], 발작

감지[5]-[7], 우울증 진단[8], 및 BCI(Brain Computer Interface)[9]-[11] 등이 있다.

감정 분류 연구를 위해 뇌파 데이터를 활용하는 경우 영상, 사진 등의 매체를 이용하여 감정을 자극할 때 피험자의 성격이나 성향에 따라 같은 자극 매체에 대해 감정을 느끼는 정도가 다르므로 뇌파의 변화에도 차이가 있어 정확한 분류가 어렵다는 문제가 있다. 이러한 문제로 인하여 여러 피험자에게 대응하기 위한 피험자 독립 모델은 피험자들의 성향의 다양성으로 인하여 피험자 종속 모델과 비교했을 때 분류가 어렵다[12]. 이러한 문제에 대응하기 위해 뇌파를 이용한 감정 분석 연구 분야에서는 뇌파 데이터와 피험자가 감정 자극 매체를 시청한 직후 자가진단 테스트를 진행하여 얻은 피험자 주관적인 데이터를 함께 사용한다.

본 논문에서는 이와 같은 피험자 간 성향의 차이로 인해 발생하는 기계학습모델의 분류 성능 하락 문제를 개선하기 위해 준 지도학습 알고리즘을 활용하여 학습데이터 중 분류 성능을 하락시킬 것으로 보이는 데이터를 제외함으로써 학습데이터를 재구성하여 분류 성능을 개선하는 방법을 제시하였다. 이후 새로 구성된 학습데이터를 이용하여 인공 신경망 모델을 학습시켜 제안한 방법을 사용하지 않은 학습데이터를 이용하여 학습시킨 모델과 감정 분류 성능을 비교 분석하였다.

본 논문에서는 감정 분석 연구를 하기 위한 뇌파 데이터로 공개 뇌파 데이터베이스인 DEAP(Database for Emotion Analysis using Physiological Signals)의 데이터를 사용하였다. DEAP 데이터베이스에서는 피험자들로부터 뇌파 측정용 마친 후 자가진단 테스트 방법의 하나인 SAM(Self-Assessment Manikin)을 이용하여 기록한 기쁨(Valence), 각성(Arousal), 감정 크기(Dominance) 값을 뇌파 데이터와 함께 제공한다[13].

본 논문의 구성은 다음과 같다. 2장에서는 제안하는 학습데이터 선택 방법의 처리 절차를 설명하고 3장에서는 실험에 사용한 뇌파 데이터 세트인 DEAP 데이터베이스에 대한 소개와 제안한 방법을 사용하여 선택한 뇌파 데이터를 이용하여 모델링 한 인공 신경망 모델과 제안한 방법을 사용하지 않은 인공 신경망 모델의 성능을 비교 실험하여 제안한 방법이 인공 신경망 성능에 끼치는 영향을 확인한다. 마지막으로 4장에서는 결과를 분석하고 결론을 맺는다.

## II. 제안기법

본 논문에서는 뇌파 데이터 중 인공 신경망 모델의 성능을 감소시킬 것으로 예상되는 데이터들인 준 지도학습 알고리즘을 활용하여 학습데이터에서 제외함으로써 모델의 분류 성능을 개선하는 방법을 제시한다.

그림 1은 블록다이어그램을 통해 제안하는 방법을 사용하여 학습데이터를 구성하고 인공 신경망을 모델링 하는 과정을 보인다.

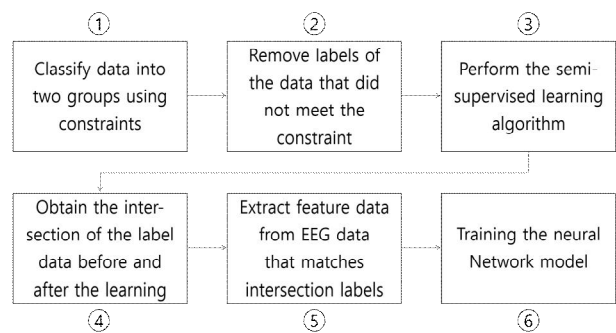


Fig. 1. Block diagram for the proposed method.

그림 1. 제안한 방법의 블록다이어그램

그림 1의 ①과정에서는 준 지도학습 알고리즘을 이용한 학습데이터 구성작업을 진행하기 전 먼저 제약조건을 설정하여 전체 데이터들을 두 그룹으로 분류한다. 뇌파 데이터 분류를 위한 제약조건으로는 감정 자극 매체 시청 중 느낀 감정에 대한 피험자들의 자가진단 테스트 결과인 Valence, Arousal 값을 이용하였다[14]. Valence, Arousal 값들 중 같은 자극 매체를 시청한 피험자들이 기록한 자가진단 결과값들을 같은 그룹으로 묶고 각 그룹의 Valence, Arousal 수치들의 평균, 표준편차를 계산한다. 이후 데이터들을 해당 데이터에 대응하는 Valence, Arousal 값의 편차의 크기가 표준편차보다 큰 그룹과 작은 그룹으로 분류한다. 이후 ②과정에서는 ①에서 분류한 두 데이터 그룹 중 편차의 크기가 표준편차보다 큰 그룹에 속한 데이터의 레이블을 제거하여 데이터들을 레이블 있는 데이터와 레이블 없는 데이터로 나누었다.

③과정에서는 ②과정에서 레이블이 제거된 데이터들에 레이블을 재정의하기 위해 레이블이 주어진 데이터와 레이블이 주어지지 않은 데이터 모두를 학습에 사용하는 준 지도학습 알고리즘을 적용

하였다. 본 논문에서는 준 지도학습 알고리즘 중 분류기로 확률적 분류기를 사용하는 알고리즘을 활용하였다[15]. 이후 ④과정에서는 준 지도학습 알고리즘을 적용하기 전, 후의 레이블을 비교하여 레이블이 변한 데이터들을 학습데이터에서 제외하여 최종 학습데이터를 구성한다.

⑤과정에서는 인공 신경망을 학습시키기 위한 입력 데이터를 구성하기 위해 ④과정 이후 최종적으로 구성된 학습데이터로부터 특징값을 추출한다. 뇌파 데이터의 특징값으로는 데이터의 PSD(Power Spectral Density) 값을 사용한다. 원시 뇌파 데이터로부터 PSD 값을 구하기 위해서는 먼저 시간 영역의 데이터인 뇌파 데이터에 고속 푸리에 변환(Fast Fourier Transform, FFT)과 같은 주파수 변환 알고리즘을 적용하여 주파수 영역의 데이터로 변환해야 한다. 고속 푸리에 변환 알고리즘은 주파수 변환 알고리즘인 DFT(Discrete Fourier Transform)의 연산 과정에서 같은 수치를 계산하기 위해 사용되는 불필요한 연산을 줄여 주파수 변환 및 역변환 시간을 줄이도록 고안된 알고리즘이다.  $x_0, \dots, x_{n-1}$ 을 복소수 값들이라고 가정했을 때 이산 푸리에 변환 공식은 다음과 같이 정의된다.

$$X(f_k) = \sum_{n=0}^{N-1} x_n e^{-\frac{j2\pi nk}{N}} \quad k = 0, 1, \dots, N-1 \quad (1)$$

식 (1)에서 DFT 변환을 적용한 신호 함수  $f_k$ 가  $x_n$ 을 계수로 갖는 여러 주파수 성분들의 합으로 표현됨을 보인다. DFT 변환으로 인해 신호 함수  $f_k$ 를 구성하고 있는 주파수 성분들을 분석할 수 있다. 이후 주파수 영역으로 변환된 뇌파 데이터에 식 (2)를 적용하여 PSD 지표를 구할 수 있다. 뇌파 연구 분야에서 관심을 가지는 주파수 대역들은 델타(0-4Hz), 세타(4-8Hz), 알파(8-13Hz), 베타(13-30Hz), 감마(<30Hz) 등이 있으며 본 논문에서는 델타를 제외한 나머지 4개 대역에 식 (2)를 적용하여 하나의 뇌파 신호에서 4개의 특징값을 추출한다.

$$P(f_k) = \frac{1}{N} |X(f_k)|^2 \quad (2)$$

이후 ⑥과정에서는 뇌파 데이터의 PSD 값을 입력 값으로 사용하여 인공 신경망을 학습시킨다. 이후 학습된 인공 신경망 모델은 특정 뇌파 데이터에 대한 감정을 분석하기 위한 예측 모델로 활용된다.

### III. 실험결과 및 고찰

#### 1. DEAP 데이터베이스

본 논문에서는 감정 분석 연구를 위한 뇌파 데이터로 영국 퀸 메리 대학에서 공개한 DEAP 데이터베이스를 사용하였다. DEAP 데이터베이스는 감정 분석 연구를 위해 만들어진 데이터베이스로 뇌파 데이터 외에 체온, 체적, 근전도(Electromyograph, EMG), 전류 피부 저항(Galvanic Skin Response, GSR) 등의 생체 신호 정보를 함께 제공한다. 모든 생체 데이터들은 32명의 피험자에게 감정을 유발하기 위한 40개의 1분 길이의 뮤직비디오 클립을 시청하게 하는 동안 기록되었다.

DEAP 데이터베이스의 뇌파 데이터는 뇌파 전극 배치를 위해 널리 알려진 10-20 System을 사용하여 총 32개 채널의 전극을 부착한 뒤 뇌파를 기록하였다. 뇌파 데이터는 512Hz 샘플링 주파수를 가지는 장비를 이용하여 기록되었고 이후 128Hz 주파수로 다운 샘플링 하여 제공된다. 그리고 원시 뇌파 데이터와 함께 제공되는 전처리 된 뇌파 데이터의 경우 눈 깜빡임 잡음 제거, 대역 통과 필터 적용 등의 처리 이후 제공된다. 그리고 각 영상에 대한 피험자의 생체 데이터와 함께 영상 시청 후 감정 자가진단 방법의 하나인 SAM 방법을 이용하여 기록된 Valence, Arousal, Dominance 값을 함께 제공한다.

본 논문에서는 DEAP 데이터베이스의 뇌파 데이터 중 각각 즐거움, 슬픔, 충격 감정을 유발하는 영상을 시청하는 동안 기록된 데이터들을 사용하였다. 그리고 해당 영상에 대한 뇌파 데이터 중 F3, F4 두 개 채널에서 기록된 데이터를 사용하였다[13].

#### 2. 실험방법

먼저 본 논문에서 제안하는 방법을 사용하여 인공 신경망 모델 학습을 위한 학습데이터를 구성한다. 그림 2의 그래프들은 본 논문에서 제안하는 방법을 진행함에 따라 데이터들의 레이블이 변화하는 모습을 보인다. 그림 2의 가로축 세로축은 각각 뇌파 데이터에 대응하는 Valence, Arousal 나타낸다. 그리고 좌표평면에 표현된 점들은 해당 좌표의 Valence, Arousal 값에 대응하는 뇌파 데이터를 나타내고 해당 데이터의 레이블은 점의 모양으로 나타낸다.

그림 2의 (a)는 원본 데이터와 레이블을 나타내

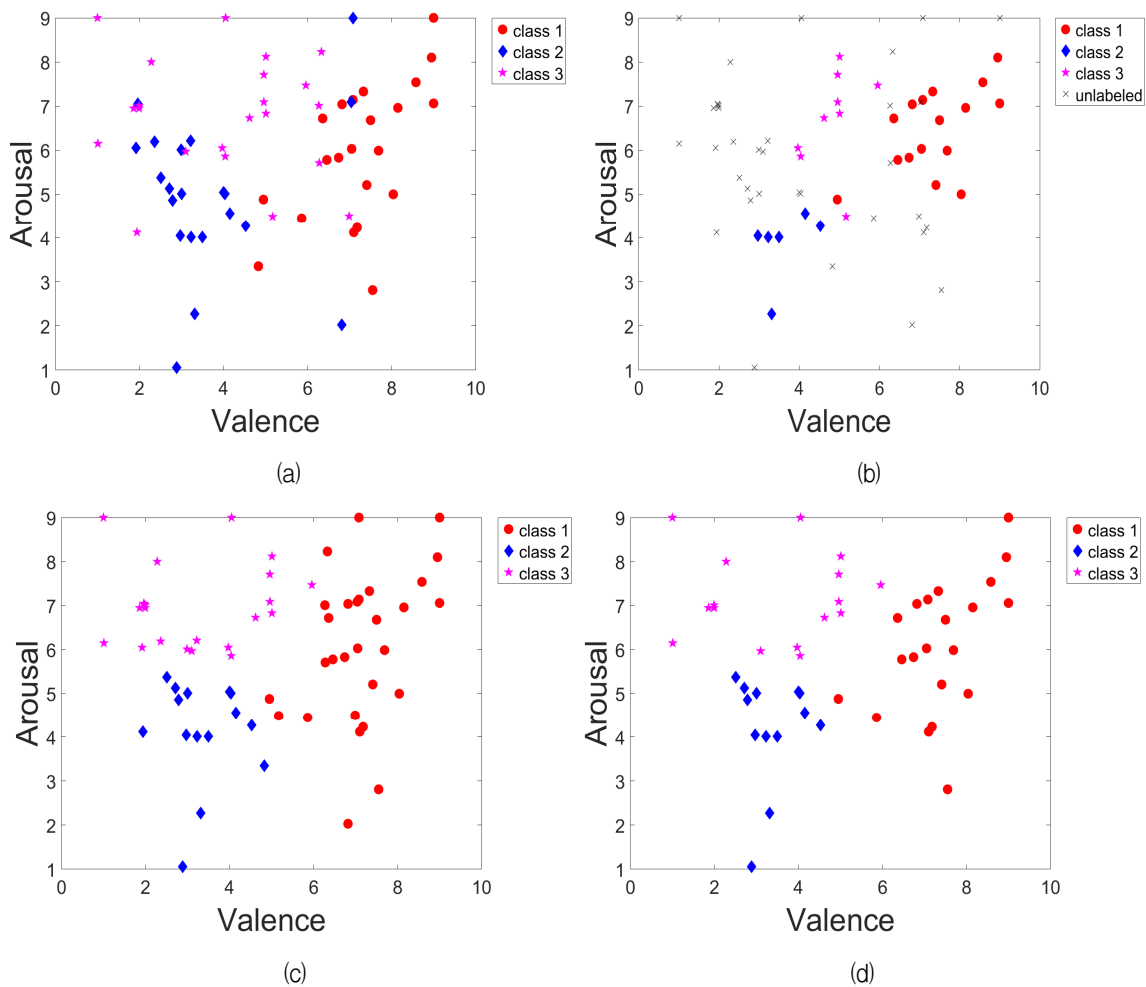


Fig. 2. The process of changing the data label according to the progress of data selection. (a) Original Label Data, (b) Label data after applying constraints, (c) Label data after perform the semi-supervised learning algorithm, and (d) The intersection of the label after performing semi-supervised learning algorithm and the original data label.

그림 2. 데이터 선택 진행에 따른 데이터 레이블 변화 과정. (a) 원본 레이블 데이터, (b) 제약조건 적용 후의 레이블 데이터, (c) 준 지도학습 알고리즘을 적용한 후의 레이블 데이터, (d) 준 지도학습 전, 후 레이블의 교집합

고 (b), (c), (d)는 각각 그림 1에서 보인 블록다이어그램의 ②, ③, ④ 과정 이후의 레이블을 나타낸다. 그래프 (a)와 (c)의 비교를 통해 (a)와 달리 (c)는 각 레이블에 대한 데이터들의 영역이 명확하게 구분됨을 확인할 수 있다. 그리고 (a)와 (d)를 비교하였을 때 (a)에서 다른 레이블 영역에 존재하던 데이터들이 (d)에서는 사라졌음을 확인할 수 있다.

이후 학습데이터에 식 (1)과 (2)를 적용하여 원시 뇌파 신호의 PSD 값을 계산할 수 있다. 본 논문에서는 한 채널의 뇌파 데이터에 대해 주파수 대역 세타, 알파, 베타, 감마 각각에 대해 PSD 값을 구하고 각 대역에 대한 PSD 값의 기댓값을 계산하여 4개의 특징값을 얻는다. 이러한 과정을 F3, F4 두 개 채널에서 수행하여 8개의 특징값을 구하고 이

값들을 인공 신경망 모델을 위한 입력 데이터로 사용하여 인공 신경망 학습에 사용하였다.

이후 2장에서 소개한 학습데이터 선택 방법이 인공 신경망의 성능에 끼치는 영향을 확인하기 위해 제안한 방법을 사용하여 구성된 학습데이터 세트와 제안한 방법을 사용하지 않은 학습데이터 세트를 구성하였다. 이후 같은 구조의 두 인공 신경망 모델을 각 데이터 세트를 이용하여 학습시킨 후 두 모델에 테스트 데이터를 입력했을 때의 결과를 확인하여 성능을 비교하였다. 인공 신경망 모델은 하나의 은닉층을 가지는 MLP(Multi-Layer Perceptron) 구조를 사용하였고, 은닉층의 노드 수는 25개로 설정하였다. 그리고 인공 신경망 모델의 특성상 초기 가중치에 따라 모델의 성능이 달라지므로 각 데이

터 세트마다 5개의 모델을 생성하여 최대 정확도를 비교하였다.

### 3. 실험결과

표 1은 제안한 알고리즘을 적용한 데이터 세트와 적용하지 않은 데이터 세트를 이용하여 학습시킨 모델에 같은 테스트 데이터를 입력하여 결과를 예측했을 때의 정확도 차이를 표로 보인다. 같은 학습데이터를 사용하더라도 인공 신경망 모델의 초기 가중치 값에 따라 모델의 성능이 달라지므로 각 학습데이터에 대해 5개의 인공 신경망 모델을 생성하여 학습시킨 뒤 결과를 비교하였다.

실험결과 제안한 알고리즘을 사용하여 선택한 학습데이터를 이용하여 인공 신경망 모델을 학습시켰을 때 그렇지 않은 데이터를 사용한 모델보다 최대 정확도가 10%가량 높음을 확인할 수 있다.

Table 1. Accuracy of Artificial Neural Network Models for Two Dataset.

표 1. 두 데이터 집합에 대한 인공 신경망 모델들의 정확도

Models	Dataset	Dataset with proposed method	Dataset without proposed method
1		53.3%	33.3%
2		53.3%	40.0%
3		<b>60.0%</b>	36.7%
4		36.7%	33.3%
5		33.3%	<b>50.0%</b>

### IV. 결론

본 논문에서는 다양한 피험자 성향으로 인해 같은 감정 유발 매체에 대해 다르게 발생하는 뇌파 데이터의 차이 때문에 발생하는 인공 신경망 모델 성능의 감소 문제를 개선하기 위해 SAM 방법을 이용한 자가진단 테스트 결과인 Valence, Arousal 값에 대한 제약조건과 준 지도학습 알고리즘을 이용하여 학습데이터를 선택하는 방법을 제시하였다. 제안한 방법을 이용하여 구성한 학습데이터 세트와 제안한 방법을 사용하지 않은 학습데이터 세트를 각각 다른 인공 신경망 모델에 적용하여 수차례 학습을 진행했을 때 테스트 데이터 입력에 대해 가장 높게 나타난 정확도를 비교하였다. 실험결과 제안한 방법을 사용했을 때 제안한 방법을 사용하지

않은 경우보다 최대 정확도가 10%가량 높음을 확인하였다.

두 개 이상의 레이블이 포함된 데이터 세트에서 유사한 값을 가진 데이터들이 섞여 있을 때 기계학습 모델의 성능 감소에 영향을 끼치는 데이터를 구분해내는 쉽지 않다. 본 논문에서는 이러한 데이터 세트에서 성능 감소에 영향을 끼치는 데이터를 구분하기 위해 준 지도학습 알고리즘을 이용하여 각 레이블을 가지는 데이터들의 영역을 명확하게 구분하여 다른 레이블의 영역에 존재하는 데이터들을 학습데이터에서 제외하였다.

이러한 데이터 유사성에 따른 문제는 뇌파 데이터가 아닌 여러 레이블을 가지고 있는 다른 형태의 데이터에서도 존재할 수 있다. 유사한 상황에서 데이터들의 영역 구분이 어려운 경우 본 논문에 제안한 방법을 활용할 수 있을 것으로 보인다.

### References

- [1] W. Zheng, "Multichannel EEG-Based Emotion Recognition via Group Sparse Canonical Correlation Analysis," *IEEE Trans. Cogn. Develop. Syst.*, vol.9, no.3, pp.281-290, 2017. DOI:10.1109/TCDS.2016.2587290
- [2] A. Jalilifard, E. B. Pizzolato and M. K. Islam, "Emotion classification using single-channel scalp-EEG recording," in *Proc. of the 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp.845-849, 2016. DOI:10.1109/EMBC.2016.7590833
- [3] M. Li and B. L. Lu, "Emotion classification based on gamma-band EEG," in *Proc. of the 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp.1223-1226, 2009. DOI:10.1109/IEMBS.2009.5334139
- [4] B. Krisnandhika, A. Faqih, P. D. Pumamasari and B. Kusumoputro, "Emotion recognition system based on EEG signals using relative wavelet energy features and a modified radial basis function neural networks," in *Proc. of the 2017 International Conference on Consumer Electronics and Devices (ICCED)*, pp.50-54, 2017.

DOI:10.1109/ICCED.2017.8019990

[5] M. Z. Ahmad, M. Saeed, S. Saleem and A. M. Kamboh, "Seizure detection using EEG: A survey of different techniques," in *Proc. of the 2016 International Conference on Emerging Technologies (ICET)*, pp.1-6, 2016.

DOI:10.1109/ICET.2016.7813209

[6] Y. Yuan, G. Xun, F. Ma, Q. Suo, H. Xue, K. Jia and A. Zhang, "A novel channel-aware attention framework for multi-channel EEG seizure detection via multi-view deep learning," in *Proc. of the 2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, pp.206-209, 2018.

DOI:10.1109/BHI.2018.8333405

[7] L. Boubchir, B. Daachi and V. Pangracious, "A review of feature extraction for EEG epileptic seizure detection and classification," in *Proc. of the 2017 40th International Conference on Telecommunications and Signal Processing (TSP)*, pp.456-460, 2017.

DOI:10.1109/TSP.2017.8076027

[8] M. Bachmann, J. Lass and H. Hinrikus, "Single channel EEG analysis for detection of depression," *Biomed Signal Process Control*, vol.31, pp.391-397, 2017. DOI:10.1016/j.bspc.2016.09.010

[9] M. Z. Ilyas, P. Saad, M. I. Ahmad and A. R. I. Ghani, "Classification of EEG signals for brain-computer interface applications: Performance comparison," in *Proc. of the 2016 International Conference on Robotics, Automation and Sciences (ICORAS)*, pp.1-4, 2016.

DOI:10.1109/ICORAS.2016.7872610

[10] B. Abibullaev, "Learning suite of kernel feature spaces enhances SMR-based EEG-BCI classification," in *Proc. of the 2017 5th International Winter Conference on Brain-Computer Interface (BCI)*, pp.55-59, 2017. DOI:10.1109/IWW-BCI.2017.7858158

[11] P. Tan, W. S. and L. Yu, "Applying Extreme Learning Machine to classification of EEG BCI," in *Proc. of the 2016 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems*

(CYBER), pp.228-232, 2016.

DOI:10.1109/CYBER.2016.7574827

[12] N. Jatupaiboon, S. P. Ngum and P. Israsena, "Real-Time EEG-Based Happiness Detection System," *Sci. World J.*, pp.1-12, 2013.

DOI:10.1155/2013/618649

[13] S. Koelstra, C. Muhl, M. Soleymani, J. S. Lee, A. Yazdani, T. Ebrahimi, T. Pun, A. Nijholt and I. Patras, "DEAP: A Database for Emotion Analysis ;Using Physiological Signals," *IEEE Trans. Affect. Comput.*, vol.3, no.1, pp.18-31, 2012.


DOI:10.1109/T-AFFC.2011.15

[14] J. S. Yun and J. H. Kim, "A Study on Training Data Selection Method for EEG Emotion Analysis Using Artificial Neural Network," *Int. J. Hyb. Inf. Technol.*, vol.11, no.1, pp.7-12, 2018.

[15] G. Niu, W. Jitkrittum, B. Dai, H. Hachiya, and M. Sugiyama, "Squared-loss Mutual Information Regularization: A Novel Information-theoretic Approach to Semi-supervised Learning," in *Proc. of the 30th International Conference on International Conference on Machine Learning*, pp.310-318, 2013.

## BIOGRAPHY

### Jong-Seob Yung (Member)



2017 : BS degree in Computer Engineering, Seokyeong University.  
2017~Present : MS course in Electronics & Computer Engineering, Seokyeong University.

### Jin Heon Kim (Member)



1982 : BS degree in Electrical Engineering, Korea University.  
1984 : MS degree in Electrical Engineering, Korea University.  
1994 : PhD degree in Electrical Engineering, Korea University.

1995~Present : Associate Professor, Seokyeong University.