

심박변이도를 이용한 인공신경망 기반 감정예측 모형에 관한 융복합 연구

박성수, 이진창*
성균관대학교 경영대학

Convergence Implementing Emotion Prediction Neural Network Based on Heart Rate Variability (HRV)

Sung Soo Park, Kun Chang Lee*
SKK Business School, Sungkyunkwan University

요 약 본 연구는 심박변이도(HRV)와 인공신경망을 이용하여 강건하고 정확한 융복합 감정예측 모형인 EPNN (Emotion Prediction Neural Network)을 개발하는 것을 주요 연구목적으로 한다. 본 연구에서 제안하는 EPNN은 기존 유사연구와는 달리 은닉노드의 활성화함수로서 하이퍼볼릭 탄젠트, 선형, 가우시안 함수를 융복합적으로 이용하여 모형의 정확도를 향상시킨다. 본 연구에서는 EPNN의 타당성을 검증하기 위하여 20명의 실험자를 대상으로 머니게임으로 감정을 유도한 후에 해당 실험자의 심박변이도 측정값을 입력자료로 사용하였다. 아울러 그들의 Valence와 Arousal을 EPNN의 출력값으로 사용하였다. 실험결과 Valence에 대한 F-Measure는 80%이고, Arousal의 경우 95%로 나타났다. 한편 EPNN의 타당성을 측정하기 위하여 기존 감정예측 연구에 사용된 경쟁모형인 인공신경망, 로지스틱 회귀분석, 서포트 벡터 머신, 랜덤 포레스트 모형과 성과를 비교하였다. 그 결과 본 연구에서 제안하는 EPNN이 더 우수한 감정예측 결과를 보였다. 본 연구의 결과는 향후 웨어러블 디지털 헬스 환경에서 사용되는 다양한 웨어러블 기기에 적용되어 사용자들의 일상생활 속에서 시시각각 변하는 감정을 정확히 예측하고 적절하게 관리하는데 적용될 수 있을 것이다.

주제어 : 융복합 감정 예측, 심박변이도, 인공신경망, 융합, 활성화함수

Abstract The purpose of this study is to develop more accurate and robust emotion prediction neural network (EPNN) model by combining heart rate variability (HRV) and neural network. For the sake of improving the prediction performance more reliably, the proposed EPNN model is based on various types of activation functions like hyperbolic tangent, linear, and Gaussian functions, all of which are embedded in hidden nodes to improve its performance. In order to verify the validity of the proposed EPNN model, a number of HRV metrics were calculated from 20 valid and qualified participants whose emotions were induced by using money game. To add more rigor to the experiment, the participants' valence and arousal were checked and used as output node of the EPNN. The experiment results reveal that the F-Measure for Valence and Arousal is 80% and 95%, respectively, proving that the EPNN yields very robust and well-balanced performance. The EPNN performance was compared with competing models like neural network, logistic regression, support vector machine, and random forest. The EPNN was more accurate and reliable than those of the competing models. The results of this study can be effectively applied to many types of wearable computing devices when ubiquitous digital health environment becomes feasible and permeating into our everyday lives.

Key Words : convergence emotion prediction, heart rate variability, HRV, artificial neural network, activation function

*This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government (MSIP; Ministry of Science, ICT & Future Planning) (No. 2017R1A2B4010956).

*Corresponding Author : Kun Chang Lee (kunchanglee@gmail.com)

Received September 24, 2017

Revised May 10, 2018

Accepted May 20, 2018

Published May 28, 2018

1. 서론

내부감각 수용 능력(Interoceptive Ability)이 뛰어난 개인은 리스크와 불확실성이 높은 상황에서 더 효과적인 의사결정을 하는 것으로 알려져 있다[1]. 쉽게 말하면, 마음의 내면에 발생하는 직관(Gut feeling)을 민감하게 알아채는 개인이 더 높은 성과와 장기적인 생존에 유리하다는 것이다. 감정은 신체적 변화, 인지 반응, 행동 및 사고를 비롯한 수많은 구성 요소로 구성된 복잡한 과정이다. 감정예측 시스템의 목표가 감정예측 지원을 통한 사용자 경험의 향상이라는 점에서 개인의 감정을 정확하게 인식하는 것은 중요하지만[2-4], 감정 예측 모델은 인간과 컴퓨터가 융합하는 분야에서 많은 관심을 끌고 있는 매우 어려운 문제이다[5].

감정예측방법은 개인이 작성한 텍스트에서 감정을 분류하는 연구가 다수 수행되었다[6]. 최근의 감정예측법은 얼굴 표정, 말, 행동 등을 이용한 방법과 사람의 심장박동, 뇌파, 피부전도도와 같은 생체신호를 계측한 신호에서 추출한 특징 정보로부터 감정을 인식하는 방법으로 나눌 수 있다. 생체신호를 사용한 감정예측 모형은 생체신호 변수를 입력으로 하고, 개인이 자기 보고한 감정 상태를 예측하는 모형을 의미한다. 최근 IT기술의 발달로 간편하게 생체신호를 수집할 수 있는 기기들이 속속 개발되고, 이를 이용한 개인의 생체신호 기반의 감정예측 연구가 활발하게 진행되고 있다[7]. 이중 간단하게 수집이 가능한 심장 박동으로부터 계산되는 심박변이도(Heart Rate Variability; HRV)를 사용한 감정예측에 대한 다양한 연구가 이루어지고 있다[8].

한편, 본 연구에서처럼 인공신경망과 심박변이도를 이용한 감정예측에 관한 기존연구와 본연구의 차별점은 다음과 같다. 첫째, 23명의 실험참가자들에게 시각자료를 이용하여 감정자극을 한후에 유도된 감정을 추정하기 위하여 인공신경망 모델과 심박변이도 측정값을 입력자료로 하여 감정을 추론한 바 있다 [9]. 해당 연구의 공헌점은 Valence를 출력값으로 하고 Mean RR, SDNN, RMSSD, VLF, LF, HF, LF/HF 등 7개의 심박변이도 값을 입력으로 한 이른바 7x3x1 인공신경망 모형을 (입력노드 7개, 은닉노드 3개, 출력노드 1개) 구축한 후 해당 Valence 추정값을 구성하는 구체적인 수학적 함수를 유도한 것이다 [9]. 둘째, 64명의 참가자들을 대상으로 음악으로 감정을 유도한 후에 이들로부터 11개의 심박변이도 값을 측정하고 Valence와 Arousal을 출력값으로 하는 인

공신경망을 구축한 후에 이들 심박변이도 변수들간의 상대적 중요도를 계산하는 과정을 주요공헌으로 하는 연구도 있다 [10]. 이들 연구들과 달리 본 연구에서는 머니게임이라는 보다 정교한 게임방식으로 20명 참가자들의 감정을 유발한 후에 11개의 심박변이도 측정값을 계산한 후에 유도된 감정을 Valence와 Arousal로 측정하므로써 기존연구와 차별화 하였다. 그리고 Valence 및 Arousal 별로 별도의 11x6x1 (11개 입력노드, 6개 은닉노드, 1개 출력노드) 인공신경망 모형을 구축하여 이를 이용한 감정예측 메커니즘을 제시한다. 그리고 해당 감정예측 모형의 타당성을 입증하기 위하여 여타 경쟁모형을 따로 만들어서 이들 경쟁모형과 성과를 비교하므로써 본 연구에서 제안한 감정예측 모형의 타당성을 입증하였다.

일반적으로, 생체신호를 사용하는 감정예측 모형은 생체신호와 감정 간의 비선형적인 관계를 학습하기 위한 랜덤 포레스트(Random Forest), 인공신경망(Artificial Neural Network), 서포트 벡터 머신(Support Vector Machine) 등의 방법을 적용한다. 하지만, 현재까지 보편적으로 수용 할 수 있는 단일한 감정예측 방법은 존재하지 않고, 이에 대한 지속적인 연구가 필요한 실정이다. Asaduzzaman[11]은 은닉노드에 다양한 유형의 활성화함수를 복합적으로 사용하는 것이 인공신경망의 성능에 효과적이라는 연구 결과를 제시하였다. 은닉노드의 활성화함수는 S형 함수(Sigmoid), 가우시안(Gaussian), 선형(Linear) 등과 같이 다양한 함수를 적용하는 연구가 수행되었지만[12] 이러한 활성화함수를 복합적으로 사용하는 감정예측 모형에 대한 연구는 수행되지 않았다. 따라서, 본 연구는 효율적인 개인 감정예측 모형의 개발에 초점을 두고 인공신경망의 은닉층 내의 활성화함수로 하이퍼볼릭 탄젠트, 선형, 가우시안 함수를 융복합적으로 사용하는 EPNN (Emotion Prediction Neural Network)를 제시하고, 다음과 같은 연구 문제를 다룬다.

RQ1: 심박변이도로부터 도출된 데이터로 인공신경망을 이용하는 EPNN 적합성을 평가한다.

RQ2: EPNN과 기존의 감정예측 모형 간의 정확성을 비교한다.

2. 이론적 배경

2.1 심박변이도와 감정

심장박동 사이의 간격(RR interval)은 체내 또는 외부 환경적 자극으로 인해 끊임없이 변화한다. 이러한 심장박동의 변화가 심박변이도이다[11]. 심박변이도는 크게 두 가지 방식으로 분석이 이루어진다. 시간 영역 분석(Time Domain Analysis)은 Mean RR, SDNN, RMSSD 등의 지표를 활용하고, 주파수 영역 분석(Frequency Domain Analysis)은 VLF, LF, HF, LF/HF 등의 지표를 활용한다[14]. 각 지표들의 구체적인 의미는 다음과 같다. 시간 영역 분석에서 MeanRR은 심장박동 최고치(R peak) 사이 간격의 평균값으로, 값이 작을수록 간격이 좁다는 것을 의미한다. 따라서 MeanRR 값이 클수록 안정된 상태라고 할 수 있다. SDNN은 심장박동 간격의 표준편차 값으로, 값이 클수록 외부 환경 변화에 대한 자율신경계의 적응 능력이 높아 건강하고 스트레스에 대한 저항력이 뛰어난 것을 의미한다. RMSSD는 인접한 심장박동 간격 차이의 평균 편차를 나타내는 값으로, 값이 높아지면 부교감신경이 활성화되었음을 나타낸다. 주파수 영역 분석은 심전도를 전력 스펙트럼 밀도(Power Spectrum Density; PSD)의 구간 신호를 토대로 나눈다. VLF는 초저주파 구간(0.0033~0.04 Hz), LF는 저주파대 구간(0.04~0.15 Hz), HF는 고주파대 구간(0.15~0.4 Hz)의 전력을 나타낸다. VLF는 교감신경계의 정보를 반영하고, LF는 교감신경계와 부교감신경계의 정보를 가지는데 주로 교감신경계의 활성도를 반영한다. HF는 부교감신경계의 활성도를 나타낸다. LF/HF 지표는 자율신경계의 교감신경 및 부교감신경의 균형 정도를 나타낸다.

심박변이도는 스트레스와 심리적 안정성의 정도를 잘 나타내는 자율신경계, 즉 교감 신경과 부교감 신경의 활

동 양상과 밀접한 관련이 있다. 일반적으로 행복, 기쁨 등의 긍정 감정을 느끼는 경우 심장 박동이 느려져 심장박동 간격이 커진다. 분노, 공포 등의 부정 감정을 느끼는 경우 심장 박동이 빨라져 심장박동의 간격이 작아진다[15]. 또한, 부정 감정은 교감 신경을 활성화하고 부교감 신경의 활동을 감소시킨다[16]. 또한 업무에서의 스트레스가 높을수록 부교감 신경의 상태를 나타내는 RMSSD 지표가 감소하였다[17].

본 연구에서는 추가적으로 주파수 영역 분석의 VLF, LF, HF의 총합인 Total Power를 계산하였다. 또한, Total Power에 대한 비중인 VLF(%), LF(%), HF(%)를 추가적으로 계산하여 사용하였다.

2.2 인공신경망과 감정예측

인공신경망은 인간의 두뇌를 구성하는 뉴런(neuron)이 연결된 다른 뉴런들과 일을 처리하는 것을 모방하여 수학적인 모형으로 만든 것이다[18]. 인공신경망은 회귀 분석 모형과 다르게 엄정한 통계적 가정을 적용하지 않고, 복잡한 데이터에 대해 뛰어난 학습성과 추론성이 장점이다. 이러한 특징으로 인공신경망은 심전도 패턴 분석에서 가장 많이 사용되는 알고리즘이다[19].

Haag는 개인 감정예측 시스템의 관점에서 인공신경망을 사용한 감정예측 모형에 대한 연구를 수행하였다[20]. 연구자들은 감정자극 사진(IAPS)으로 피험자들의 감정을 자극하고 6가지 생체신호 - 혈액량 펄스(Blood Volume Pulse; BVP), 심전도(Electrocardiogram; ECG), 피부전도도(Electrodermal Response; EDR), 호흡활동(Respiration Activity; RSP), 피부 온도(Skin Temperature;

Table 1. Previous studies for neural network-based emotion prediction with HRV

Authors	Year	Emotions	Predictive Model	Activation Function	Model Performance
Nicolaou et al.	2011	valence and arousal	Bidirectional Long Short-Term Memory Neural Networks	Sigmoidal	V 85 A 87
Swangnetr et al.	2013	3 level valence and arousal	Artificial Neural Network	Hyperbolic tangent	V 73 A 82
Singh et al.	2013	stress level	7 neural network architectures	Modified hyperbolic tangent	92.1
Russo et al.	2013	valence and arousal	Artificial Neural Network	Sigmoidal	V 89.7 A 88.9
Valenza et al.	2014	3 level valence and arousal	Artificial Neural Network	Sigmoidal	V 79.1 A 83.5
Kukolja et al.	2014	Sadness, Disgust, Fear, Happiness, Neutral	Artificial Neural Network	Logsig	60.3
Ringeval et al.	2015	Valence and Arousal	Long Short-Term Memory Recurrent Neural Networks	sigmoid and hyperbolic tangent	V 80.4 A 52.8

ST), 근전도(Electromyogram; EMG) - 를 수집하여 감정예측에 인공신경망의 입력변수로 하고, 출력변수는 측정된 감정점수로 하여 감정예측 정확도 80%이상을 달성하였다. 또한, 인공신경망 기반의 감정예측 모형은 Valence에 비해 Arousal더 잘 예측하는 것으로 나타났다. 이후 인공신경망을 이용한 다양한 감정 예측 모형에 대한 연구가 수행되었다.

2011년 이후에 심박변이도와 인공신경망을 사용한 감정예측 모형에 대한 연구를 Table 1에 정리하였다. Swangnetr et al.[21], Russo et al.[22], Valenza et al.[8]과 Kukulja et al.[23]은 입력-은닉-출력으로 순차적인 처리가 이루어지는 Feed-Forward 인공신경망을 사용한 감정예측 모형을 연구하였다. Singh et al.[24]은 4가지 다른 유형의 Feed-forward 신경망과 3가지의 Recurrent 신경망으로 운전자의 스트레스 수준 예측 모형을 생성하고 비교하였다. 결과는 Layer recurrent neural network (LRNN)가 가장 높은 예측률을 나타냈다. Nicolaou et al.[25]과 Ringeval et al.[26]은 Long Short-Term Memory신경망을 사용하여 맥락을 포함하는 감정예측 모형에 대한 연구를 수행하였다. 연구자들은 인공신경망 모형이 시간의 흐름을 인식해서 사용자의 감정을 예측하는 모형을 제시하였다. 인공신경망 감성예측 모형의 은닉노드에 사용된 활성화함수는 대부분 S자 형태의 로지스틱이나 유사한 형태의 함수를 사용하였다.

이전의 인공신경망 감정예측 모형 연구들은 입력-은닉-출력노드로 연결되는 신경망 구조에 중점을 둔 연구가 주로 수행되었고, 은닉노드에 대표적으로 사용되는 활성화함수는 S자 형태의 로지스틱, 시그모이드, 하이퍼볼릭 탄젠트 함수 등이다. 하지만, 감정예측 모형에 복합적인 활성화함수를 사용하는 연구는 찾아볼 수 없다.

3. 연구 방법

본 연구에 필요한 데이터는 실험을 통하여 수집하였다. 실험 참가자들에게 간단한 게임으로 감정을 유발하고, 감정유발 수준 및 감정 유발 전후의 심전도데이터를 측정하여 분석에 사용하였다.(IRB No.2015-05-007-008)

3.1 연구 대상

본 연구는 서울소재 대학교에 재학중인 학생 총 25명

의 피험자를 대상으로 하였다. 실험에 참가한 피험자는 모두 남성으로 연령대는 19~26세이고, 평균연령은 23.0(SD=2.2)이다. 어떤 실험 참가자도 의학적 병력이나 항정신성 약물 및 심혈 관계, 호흡기, 중추 신경계에 영향을 미치는 약물의 복용이 없음을 밝혔다.

3.2 감정자극

본 연구는 게임의 현실감이 게임 플레이어의 인지과정에서 영향을 미칠 수 있다는 점을 고려하여[27], 피험자들의 현실감이 확실히 지각될 수 있도록 머니 게임을 설계하였다. 머니 게임이란 피험자가 빈 화면을 주목하면서, 화면에 네모(■) 표시가 나타날 때 키보드의 스페이스 바(Space Bar)를 눌러 반응 속도를 측정한다. 이 때, 피험자가 게임에 몰입할 수 있도록 반응 속도가 일정 기준을 만족할 시 보상을 지급하고 그렇지 못할 경우 손해를 보도록 설계되었다. 이 게임을 통해 피험자에게 긍정 감정 또는 스트레스와 같은 부정감정을 유도하기 위함이다. 피험자에게는 게임의 의도가 마치 순발력으로 보상을 얻는 것처럼 보이지만, 이미 실험 참가자 마다 게임 중 감정조작이 가능하도록 보상 혹은 손해에 관한 결과가 예정되어있다.

3.3 측정 도구

3.3.1 감정측정

본 연구의 감정측정에 적용한 감정모형은 감정 연구에서 일반적으로 통용되는 러셀의 원형모형(Circumplex Model)을 사용하였다[28]. 원형모형은 감정을 직교하는 2차원의 Valence와 Arousal로 개념화해 나타낸다. Valence는 감정의 긍·부정 수준을 의미하고, Arousal은 감정이 느껴지는 강도를 의미한다.

본 연구는 자극이 주어지는 동안에 피험자가 지각하는 Valence와 Arousal의 정도를 측정하기 위해 자기보고 방식인 Self-Assessment Manikin(SAM)로 측정하였다[29]. 측정 척도는 Valence는 1(불쾌한)에서 9(기분 좋은)까지, Arousal은 1(평온한)에서 9(흥분되는)의 숫자로 나타내도록 했다.

측정된 연속형 감정점수를 범주형으로 변환하기 위하여, Valence와 Arousal의 가장 높은 두 개의 점수를 “H”(높음), 가장 낮은 두 개의 점수를 “L”(낮음)으로 하고, 나머지 중간점수를 “M”(중간)으로 변경하였다[30].

3.3.2 심전도 측정

심전도는 Einthoven의 표준사지유도법에 따라 전극을 왼쪽 발목과 양쪽 손목에 부착하고 약간의 안정을 취한 뒤 측정을 시작하였다[31]. 표준사지유도에서 왼손과 오른손의 전위차는 유도 I, 오른손과 왼발의 전위차는 유도 II, 왼발과 왼손의 전위차는 유도 III으로 기록된다. 실험시작 후 5분간 실험 참가자의 표준 상태의 심박을 측정하였으며, 감정 유도를 위한 음악을 청취하면서 5분간 감정 상태의 심박데이터를 수집하였다. 심전도 신호는 BIOPAC MP150를 통해 수집하고, MP150 A/D 변환기와 Acq Knowledge v4.1 프로그램을 이용하여 저장하였다. 1 Hz ~ 35 Hz 대역의 주파수는 밴드 패스 필터로 노이즈를 제거하여 안정적인 심전도 데이터를 얻었다.

3.4 실험과정

실험은 피험자의 집중력을 방해하지 않기 위해 방음이 확보된 독립 공간에 실험용 장비만 배치하여 수행하였다. 피험자로부터 고품질의 심박 데이터를 확보하기 위해 실험전 금주 및 숙면하도록 하였다. 심전도 센서를 부착 후 신호 왜곡과 노이즈의 발생을 방지하기 위하여 불필요한 얼굴과 몸의 움직임을 제한한 상태에서 실험이 진행 되었고, 실험완료 후 실험 참가자들에게 실험에 대한 설명 및 소정의 문화상품권을 지급하였다. 본 연구의 실험 과정은 6단계이며, Fig. 1과 같다.

- ① 실험 설명: 실험 참가자에게 실험에 대한 사전 안내 및 실험 진행 과정에서 필요한 사항을 충분히 숙지하도록 한 후 실험 동의서를 작성해 참가자의 자발적인 동의를 확인하였다.
- ② 심전도 센서 부착: 실험 참가자의 양쪽 손목과 왼쪽 발목에 각각 심전도 센서를 부착하였다.
- ③ 표준 상태 심박 측정: 실험참여자 21인치 모니터 상에 ‘+’표시가 되어있는 검은색 화면을 바라보며 안정을 취하도록 한 상태에서 5분간 표준 상태의 심박을 측정하였다.
- ④ 머니 게임 : 행동실험 소프트웨어인 E-Prime 2.0 (Psychology Software Tools, Inc.)을 이용하여 미리 실험에 맞춰 설계한 프로그램(머니 게임)을 실행

하여 프로그램의 통제 하에서 실험 참가자로 하여금 연습을 통해 게임의 규칙을 충분히 숙지하도록 한 후 머니 게임을 실시하도록 하였다. 게임을 실시하는 동안 감정 상태의 심박을 측정하였다.

- ⑤ 감정 유발 확인: 감정 자극 직후 유발된 감정의 정도를 SAM으로 Valence와 Arousal을 측정하였다.
- ⑥ 사후 설명: 실험이 종료된 직후 실험의 목적과 자극물에 대한 사후 설명을 수행하였다.

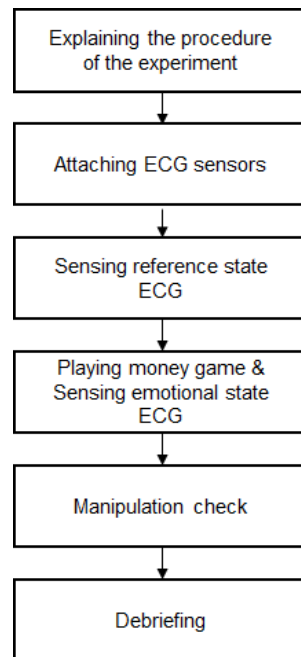


Fig. 1. Procedure of the experiment

전체 25명의 피험자 중에서 실험도중 심전도 센서가 탈락한 3명과 감정유도가 충분히 되지 않은 2명의 데이터를 제외하고 최종적으로 20명의 심박데이터를 획득하여 감정예측 모형 개발에 사용하였다.

3.5 데이터 처리

실험에서 수집된 심박데이터에서 표준상태와 감정유발 상태의 RR interval을 text파일 형태로 추출하여 각각 저장하고, 이를 Kubios를 사용하여 심박변이도를 계산하였다[32]. 시간 영역 지표인 mean RR, SDNN, RMSSD와 주파수 영역 지표인 VLF(ms²), LF(ms²), HF(ms²),

Total Power, LF/HF(ms2)와 VLF(%), LF(%), HF(%)의 11가지 표준 및 감정 상태의 심박변이도를 추출하고, 심박변이도의 변동비를 식 (1)과 같이 계산하였다[33].

$$HRV_{ratio} = \frac{HRV_{emotion} - HRV_{reference}}{HRV_{reference}}$$

3.6 감정예측 모형

감정예측 모형을 개발하기 위해 11가지 심박변이도의 변동비를 입력으로 하고, Valence와 Arousal을 출력으로 하는 인공신경망 모형을 개발하였다. 인공신경망의 은닉층의 최적의 노드를 찾기 위해 은닉노드 수는 최적 노드 수를 찾기 위해 1~2n+1(n: 입력노드의 수)개 사이로 설정하여, 최종 은닉노드 수를 6개로 설정하였다[34]. 본 연구의 인공신경망 모형은 Fig. 2와 같다.

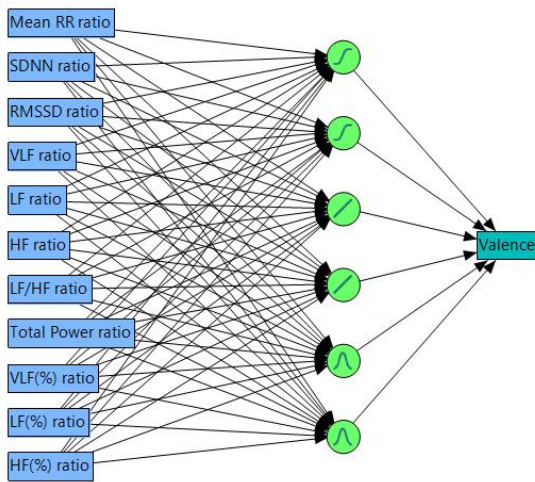


Fig. 2. EPNN model diagram for Valence

다양하고 복잡한 심박변이도를 입력으로 효과적인 감정예측이 가능하도록 은닉노드의 활성화함수는 하이퍼탄젠트(노드1~2), 선형(노드3~4), 가우시안(노드5~6)로 하여 하였다. 출력노드에 Valence를 넣은 모형과 Arousal을 넣은 모형을 각각 생성하였다. 모형의 과적합 방지 및 타당성을 확보하도록 5 Fold 교차 타당도 방식으로 모형을 학습하였다.

4. 연구결과 및 분석

본 연구는 심박변이도로부터 효과적으로 개인의 감정을 인식하는 것을 목적으로 EPNN의 적합성을 평가하고, 다른 감정예측 모형과 EPNN간의 감정예측 정확도를 비교하는 것이다.

4.1 감정예측 모형 적합성 평가

Table 2과 Table 3는 본 연구의 EPNN이 예측한 Valence와 Arousal에 대한 혼동행렬(Confusion matrix)을 각각 나타내었다. 행렬의 세로축은 감정예측에 사용된 입력데이터를 나타내고, 가로축은 예측된 결과를 의미한다. 대각선 방향의 셀의 값이 100%에 근접할수록 예측정확도가 높은 것을 의미한다. EPNN의 Valence 예측 정확도는 71.4%에서 100%사이이고, Arousal은 88.9%~100%로 나타났다. Valence와 Arousal의 높음(H)에 대한 정확도는 100%이다. 중간(M)은 Valence, Arousal에 각각 71.4%와 88.9%이고, 낮음(L)는 Valence가 81.8%, Arousal이 100%로 나타났다.

Table 2. Performance of EPNN for Valence

Actual \ Predicted	Predicted		
	H	M	L
H	100	0	0
M	0	71.4	28.6
L	0	18.2	81.8

Table 3. Performance of EPNN for Arousal

Actual \ Predicted	Predicted		
	H	M	L
H	100	0	0
M	11.1	88.9	0
L	0	0	100

4.2 감정예측 모형간의 정확도 비교

본 연구에서 제시하는 EPNN과 다른 감정예측 모형의 비교를 위하여, 동일한 연구 데이터를 데이터 마이닝 도구인 웨카(WEKA)에서 분석 하였다. 비교 대상인 감정예측 모형 생성을 위해 단일 활성화함수를 사용하는 인공신경망(Artificial Neural Network; ANN)과 로지스틱 회귀분석(Logistic Regression; LR), 서포트 벡터 머신(Support Vector Machine; SVM), 랜덤 포레스트(Random

Forest; RF)를 사용하였다. 각 학습모형의 파라미터와 옵션은 웨카의 기본 설정을 선택하였다.

분석 결과는 Table 4와 같다. 본 연구에서 제안한 EPNN의 TP Rate는 Valence와 Arousal이 각각 0.8, 0.95로 가장 높게 나왔고, FP Rate는 각각 0.18, 0.03으로 가장 낮게 나타났다. EPNN 이외의 다른 감정예측 모형에서 SVM이 가장 높은 정확도를 나타냈다. SVM의 TP Rate는 Valence가 0.55, Arousal이 0.65로 EPNN보다 0.25~0.3 정도 낮게 나타나고 있다.

Table 4. Comparisons with other relevant methods

Target	Index	EPNN	ANN	LR	SVM	RF
Valence	MAE	0.30	0.50	0.47	0.34	0.43
	RMSE	0.36	0.68	0.68	0.44	0.51
	TP Rate	0.80	0.25	0.30	0.55	0.45
	FP Rate	0.18	0.60	0.52	0.55	0.48
	Precision	0.80	0.25	0.31	0.30	0.41
	Recall	0.80	0.25	0.30	0.55	0.45
Arousal	F-Measure	0.80	0.25	0.30	0.39	0.43
	MAE	0.22	0.35	0.30	0.32	0.40
	RMSE	0.15	0.55	0.55	0.42	0.48
	TP Rate	0.95	0.50	0.55	0.65	0.50
	FP Rate	0.03	0.30	0.30	0.26	0.32
	Precision	0.96	0.51	0.56	0.55	0.47
Arousal	Recall	0.95	0.50	0.55	0.65	0.50
	F-Measure	0.95	0.50	0.55	0.59	0.48

감정예측 모형의 Precision과 Recall를 조화 평균하여 모형의 정확도를 한 번에 나타내는 지표인 F-Measure[35]를 사용하여 EPNN와 SVM모형을 비교하였다. Valence에 대한 EPNN의 F-Measure는 0.8이고, SVM은 0.39로 EPNN이 약 2배 정도 더 높게 나타났다. Arousal의 경우 EPNN은 0.95, SVM은 0.59로 EPNN이 1.6배 높게 나타났다.

5. 결론

본 연구는 생체신호로부터 개인의 감정을 효과적으로 인식하는 것을 목적으로 첫째, 심박변이도와 새로운 인공신경망을 사용하는 감정예측 방법인 EPNN에 대한 적합성을 평가한다. EPNN은 인공신경망의 은닉노드의 활성화함수에 하이퍼탄젠트, 선형, 가우시안 함수를 적용한 감정예측 모형으로 F-Measure로 판단할 때, Valence의 예측 정확도는 80%, Arousal은 95%의 정확도를 보였다.

둘째, EPNN과 기존의 감정예측 모형 간의 정확성을 비교한다. 본 연구에서 제안한 EPNN이 다른 학습모형의 성능에 비하여, 약 1.6~2배 정도의 정확도 향상을 확인하였다.

본 연구의 시사점은 다음과 같다. 첫째, 본 연구에서 제시한 방법으로 정확하고 신뢰성 높은 감정인식 시스템을 구축하는데 활용할 수 있다. 최근 많은 주목을 받고 있는 사물 인터넷과 웨어러블 컴퓨팅 환경에서 사용자와 상호작용을 하는 시점에 사용자의 감정을 정확하게 예측하고 대응할 수 있다. 둘째, 보다 간단한 시스템으로 감정의 예측이 가능하다. 이전의 연구들은 표정, 음성, 뇌파 등을 복합적으로 사용하여 감정을 인식하였는데, 본 연구는 간단하게 수집이 가능한 심장박동을 활용한 감정예측 시스템의 구현이 가능하다.

본 연구를 통하여 얻은 결과로부터 다음과 같은 추가 연구가 필요하다. 심박변이도는 시간 영역 지표인 Mean HR, NN50, pNN50, HRV triangular index 등과 Wavelet 변환을 통한 주파수 영역 지표가 있다. 본 연구는 이러한 다양한 심박변이도 중 일부를 사용하여 감정예측에 활용하였다. 향후 다양한 심박변이도 변수에 효과와 영향력에 대한 연구가 필요하다. 또한, 더욱더 가속화 되어 발전하는 IOT, 웨어러블 컴퓨팅 관점에서 본 연구의 사용한 심전도 외에도 피부전도도, 호흡량, 뇌파 등의 복합적인 생체신호를 사용하는 감정예측 모형으로 확장하여 보다 정교하고 정확한 감정예측에 대한 연구가 필요하다.

REFERENCES

- [1] N. Kandasamy, S. N. Garfinkel, L. Page, B. Hardy, H. D. Critchley, M. umell & J. M. Coates. (2016). Interoceptive ability predicts survival on a London trading floor, *Scientific Reports*, 6, 32986. DOI : 10.1038/srep32986
- [2] R. W. Picard, E. Vyzas & J. Healey. (2001). Toward machine emotional intelligence: Analysis of affective physiological state. *IEEE transactions on pattern analysis and machine intelligence*, 23(10), 1175-1191. DOI : 10.1109/34.954607
- [3] I. K. Kwon, S. Y. Lee. (2012). Personalized Service Based on Context Awareness through User Emotional Perception in Mobile Environment. *Journal of Digital Convergence*, 10(2), 287-292.
- [4] K. J. Kim. (2018). A conversation training program that

- combines reason and sensitivity - Using the P-A-C technique of Transactional analysis -. *Journal of Convergence for Information Technology*, 8(2), 149-155.
- [5] F. Agrafioti, D. Hatzinakos & A. K. Anderson. (2012). ECG pattern analysis for emotion detection. *IEEE Transactions on Affective Computing*, 3(1), 102-115. DOI : 10.1109/T-AFFC.2011.28
- [6] J. Kim. (2016). Emotion Prediction of Paragraph using Big Data Analysis. *Journal of Digital Convergence*, 14(11), 267-273. DOI : 10.14400/JDC.2016.14.11.267
- [7] A. Hariharan & M. T. P. Adam. (2015). Blended emotion detection for decision support. *IEEE Transactions on Human-Machine Systems*, 45(4), 510-517. DOI : 10.1109/THMS.2015.2418231
- [8] G. Valenza, L. Citi, A. Lanata, E. P. Scilingo & R. Barbieri. (2014). Revealing real-time emotional responses: a personalized assessment based on heartbeat dynamics. *Scientific reports*, 4, 4998. DOI : 10.1038/srep04998
- [9] S. S. Park & K. C. Lee. (2017). Emotion prediction neural network to understand how emotion is predicted by using heart rate variability measurements. *Journal of The Korea Society of Computer and Information*, 22(7), 75-82. DOI: 10.9708/jksoci.2017.22.07.075
- [10] S. S. Park & K. C. Lee. (2018). Analysis of the Relative Importance of HRV Metrics to Predict Emotion by Using Valence-Arousal driven Neural Network. under review in *Journal of Korean Institute of Information Technology*.
- [11] M. D. Asaduzzaman, M. Shahjahan & K. Murase. (2009). Faster training using fusion of activation functions for feed forward neural networks. *International journal of neural systems*, 19(6), 437-448. DOI : 10.1142/S0129065709002130
- [12] M. Dorofki, A. H. Elshafe, O. Jaafar, O. A. Karim & S. Mastura. (2012). Comparison of artificial neural network transfer functions abilities to simulate extreme runoff data. *International Proceedings of Chemical, Biological and Environmental Engineering*, 33, 39-44.
- [13] M. J. Song, M. Y. Kim, I. S. Sim & W. S. Kim. (2010). Evaluation of Horticultural Therapy on the Emotional Improvement of Depressed Patients by Using Heart Rate Variability. *Korean Journal of Horticultural Science & Technology*, 28(6), 1066-1071.
- [14] M. S. Kim, Y. N. Kim & Y. C. Cho. (2015). Electrocardiographic characteristics of significant factors of detected atrial fibrillation using WEMS. *Journal of the Korea Industrial Information Systems Research*, 20(6), 37-46. DOI : 10.9723/jksis.2015.20.6.037
- [15] N. Ravaja. (2014). Contributions of psychophysiology to media research: Review and recommendations. *Media Psychology*, 6(2), 193-235. DOI : 10.1207/s1532785xmep0602_4
- [16] T. Kageyama, N. Nishikido, T. Kobayashi, Y. Kurokawa, T. Kaneko & M. Kabuto. (1998). Self-Reported Sleep Quality, Job Stress, and Daytime Autonomic Activities Assessed in Terms of Short-Term Heart Rate Variability among Male White-Collar Workers. *Industrial Health*, 36(3), 263-272. DOI : 10.2486/indhealth.36.263
- [17] T. G. M. Vrijkotte, L. J. P. van Doomen & E. J. C. de Geus. (2000). Effects of Work Stress on Ambulatory Blood Pressure, Heart Rate, and Heart Rate Variability. *Hypertension*, 35, 880-886. DOI : 10.1161/01.HYP.35.4.880
- [18] C. M. Bishop. (1995). *Neural networks for pattern recognition*. Oxford university press.
- [19] M. Sansone, R. Fusco, A. Pepino & C. Sansone. (2013). Electrocardiogram pattern recognition and analysis based on artificial neural networks and support vector machines: A review. *Journal of Healthcare Engineering*, 4(4), 465 - 504. DOI : 10.1260/2040-2295.4.4.465
- [20] A. Haag, S. Goronzy, P. Schaich & J. Williams. (2004). Emotion recognition using bio-sensors: First steps towards an automatic system. *Affective dialogue systems*, Springer, 36-48.
- [21] M. Swangnetr & D. B. Kaber. (2013). Emotional state classification in patient-robot interaction using wavelet analysis and statistics-based feature selection. *IEEE Transactions on Human-Machine Systems*, 43(1), 63-75. DOI : 10.1109/TSMCA.2012.2210408
- [22] F. A. Russo, N. N. Vempala & G. M. Sandstrom. (2013). Predicting musically induced emotions from physiological inputs: Linear and neural network models. *Frontiers in Psychology*, 4-468. DOI : 10.3389/fpsyg.2013.00468
- [23] D. Kukolja, S. Popovi, M. Horvat, B. Kova & K. osi. (2014). Comparative analysis of emotion estimation methods based on physiological measurements for real-time applications. *International Journal of Human-Computer Studies*, 72(10), 717-727. DOI : 10.1016/j.ijhcs.2014.05.006
- [24] R. R. Singh, S. Conjeti & R. Banerjee. (2013). A comparative evaluation of neural network classifiers for stress level analysis of automotive drivers using physiological signals. *Biomedical Signal Processing and*

Control, 8(6), 740-754. DOI : 10.1016/j.bspc.2013.06.014

[25] M. A. Nicolaou, H. Gunes & M. Pantic. (2011). Continuous prediction of spontaneous affect from multiple cues and modalities in valence-arousal space. *IEEE Transactions on Affective Computing*, 2(2), 92-105. DOI : 10.1109/T-AFFC.2011.9

[26] F. Ringeval, F. Eyben, E. Kroupi, A. Yuce, J. P. Thiran, T. Ebrahimi, D. Lalanne & B. Schuller. (2015). Prediction of asynchronous dimensional emotion ratings from audiovisual and physiological data. *Pattern Recognition Letters*, 66, 22-30. DOI : 10.1016/j.patrec.2014.11.007

[27] H. Hwang & S. Park. (2011). The Impact of User's Psychological Experience on Online Game Addiction: Perceived Reality and Sense of Presence. *Journal of communication science*, 11(1), 471-505.

[28] J. Posner, J. Russell & B. Peterson, (2005). The circumplex model of affect: An integrative approach to affective neuroscience, cognitive development, and psychopathology. *Development and psychopathology*, 17(3), 715-734. DOI : 10.1017/S0954579405050340

[29] M. M. Bradley & P. J. Lang. (1994). Measuring emotion: the self-assessment manikin and the semantic differential. *Journal of behavior therapy and experimental psychiatry*, 25(1), 49-59.
DOI : 10.1016/0005-7916(94)90063-9

[30] S. M. Ahn, M. C. Whang, D K. Kim, J H. Kim & S. I. Park. (2012). Real-time emotion recognition technology using individualization processemotional technology. *Korean Journal of the Science of Emotion and Sensibility*, 15(1), 133-140.

[31] U. R. Acharya, K. P. Joseph, N. Kannathal, C. M. Lim & J. S. Suri. (2006). Heart rate variability: a review. *Medical and biological engineering and computing*, 44(12), 1031-1051. DOI : 10.1007/s11517-006-0119-0

[32] M. P. Tarvainen, J. P. Niskanen, J. A. Lipponen, P. O. Ranta-Aho & P. A. Karjalainen. (2014). Kubios HRV - heart rate variability analysis software. *Computer methods and programs in biomedicine*, 113(1), 210-220. DOI : 10.1016/j.cmpb.2013.07.024

[33] S. N. Yu & S. F. Chen. (2015). Emotion state identification based on heart rate variability and genetic algorithm. *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*, 538-541.
DOI : 10.1109/EMBC.2015.7318418

[34] R. Hecht-Nielsen. (1989). Theory of the Back Propagation Neural Network. In *Proceeding of the International Joint Conference on Neural Networks(IJCNN), New*

York, 593-605.

DOI : 10.1016/B978-0-12-741252-8.50010-8

[35] M. Sokolova & G. Lapalme. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437. DOI : 10.1016/j.ipm.2009.03.002

박 성 수(Park, Sung Soo)


[정회원]



- 2010년 8월 : 성균관대학교 경영대학원 (경영학석사)
- 2010년 9월 ~ 현재 : 성균관대학교 경영대 박사과정
- 관심분야 : 인공지능, 빅데이터, 감성분석
- E-Mail : volf74@empas.com

이 건 창(Lee, Kun Chang)

[정회원]



- 1984년 : 카이스트 경영과학과 (공학석사-의사결정지원)
- 1988년 : 카이스트 경영과학과 (공학박사-인공지능)
- 1988년 ~ 1990년 : 보람투자자문(주)
- 1990년 ~ 1995년 : 경기대학교 경영정보학과 교수
- 1995년 ~ 현재 : 성균관대학교 경영대학 및 삼성융합의과학원 (SAIHST) 융합의과학과 교수
- 관심분야 : 창의성과학, 인공지능, 헬스 인포매틱스, 빅데이터 분석, 감성분석 등
- E-Mail : kunchanglee@gmail.com