

## 긴장과 이완상태의 자동인식을 위한 SOM의 적용

정찬순\*, 함준석\*, 고일주\*, 장대식\*\*

### Applying of SOM for Automatic Recognition of Tension and Relaxation

Chan-Soon Jeong\*, Jun-Seok Ham\*, Il-Ju Ko\*, Dae-Sik Jang\*\*

#### 요약

본 연구에서는 비행슈팅게임을 플레이하는 피험자의 긴장 또는 이완상태를 자동으로 인식하는 시스템을 제안한다. 기존 연구에서는 피험자에게 자극원을 제시하여 나타난 변화 값을 비교하기 때문에 자동으로 분류하는데 한계가 있었다. 본 연구에서는 피험자의 상태 변화를 자동으로 분류하여 인식할 수 있도록 비지도학습의 SOM을 적용한다. 긴장과 이완상태의 자동인식을 위한 SOM의 적용은 두 가지 단계로 구성된다. 첫 번째 단계는 ECG측정 및 분석으로 피험자에게 게임을 플레이하게 한 후 ECG를 측정하여 HRV 분석으로 특징벡터를 추출한다. 두 번째 단계는 SOM 학습 및 인식으로 특징이 추출된 심박신호의 입력벡터들을 SOM으로 학습하여 피험자의 긴장과 이완상태를 분류하여 인식 한다. 실험 결과는 세 가지로 나누어진다. 첫 번째, HRV의 주파수변화와 두 번째 심박신호의 SOM 학습결과를 나타냈다. 세 번째 단계는 SOM학습의 성능을 알기 위해서 매칭율을 분석했다. HRV의 주파수분석의 LF/HF 비율을 1.5 기준으로 SOM의 승자뉴런 거리와 매칭한 결과 평균 72%의 매칭율을 보였다.

#### Abstract

We propose a system that automatically recognizes the tense or relaxed condition of scrolling-shooting game subject that plays. Existing study compares the changed values of source of stimulation to the player by suggesting the source, and thus involves limitation in automatic classification. This study applies SOM of unsupervised learning for automatic classification and recognition of player's condition change. Application of SOM for automatic recognition of tense and relaxed condition is composed of two steps. First, ECG measurement and analysis, is to extract characteristic vector through HRV analysis by measuring ECG after having the player play the game. Secondly, SOM learning and recognition, is to classify and recognize the tense and relaxed conditions of player through SOM learning of the input vectors of heart beat signals that the characteristic extracted. Experiment results are divided into three groups. The first is HRV frequency change and the second the SOM learning results of heart beat signal. The third is the analysis of match rate to identify SOM learning performance. As a result of matching the LF/HF ratio of HRV frequency analysis to the distance of winner neuron of SOM based on 1.5, a match rate of 72% performance in average was shown.

• 제1저자 : 정찬순 책임저자 : 고일주 교신저자 : 장대식

• 투고일 : 2009. 12. 29, 심사일 : 2010. 02. 01, 게재확정일 : 2010. 02. 22.

\* 숭실대학교 미디어학과 \*\* 군산대학교 컴퓨터정보공학과

※ 이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(2009-0076126).

▶ Keyword : 심전도(ECG), 자기조직화지도(SOM), 게임(Game), 자동인식(Automatic recognition)

## I. 서론

최근 게임들은 사용자와 상호작용성을 중요시하고 있다. 사용자는 게임방식에 따라 게임의 인터페이스들이 반영된 게임을 플레이한다. 사용자가 직접 참여하고 즐길 수 있는 요소로 게임시장은 변화하고 있다. 닌텐도의 Wii는 위모트 컨트롤러를 이용하여 사용자의 움직임 인식한다. 예를 들어 테니스 게임을 할 때, 사용자가 잡고 있는 위모트 컨트롤러는 테니스 라켓과 같은 역할을 한다. 손목의 기울기와 방향, 회전속도를 감지하여 사용자가 만족을 느끼면서 게임을 진행할 수 있다.

앞으로 출시될 Microsoft의 Natal은 사용자의 움직임과 음성인식 컨트롤러 역할을 하면서 게임을 플레이 할 수 있다. 사용자의 움직임은 카메라로 인식되며, 사용자의 얼굴은 자동으로 로그인되어 인식된다. 사용자의 얼굴표정에 따라서 캐릭터의 표정이 변하고, 사용자의 음성은 마이크를 통해서 명령으로 인식된다. 사용자의 동작과 음성은 외부의 설치된 카메라, 센서들을 통해서 인식되고 있다.

앞으로는 사용자가 참여하고 즐길 수 있는 게임들로 사용자의 신체 상태에 따라 자동으로 맞춰지는 게임을 할 수 있게 될 것이다. 앞으로 출시될 Wii 바이탈리티 센서는 사용자의 몸 상태에 따라서 자동으로 밸런스가 조절된다. 센서를 손가락에 꽂아 사용자의 맥박을 측정하여 신체정보를 확인할 수 있다. 제공된 정보는 사용자가 긴장상태일 경우 안정될 때까지 게임의 진행속도가 조절된다.

기존의 ECG(Electrocardiogram) 연구는 심박동률의 변화값으로 감정을 분류하였다[1]. 피험자의 감정은 자극원을 준 후 측정된 심박신호의 변화값을 비교하여 분류하였다. 하지만, 사용자의 감정을 자동으로 분류하고 인식하는 것에는 한계가 있었다.

본 연구에서는 피험자의 상태를 자동으로 인식하기 위해서 측정된 심박신호의 특징을 추출한 후 SOM(Self-Organizing Map)의 적용을 제안한다.

본 연구는 일정시간동안 긴장과 이완 상태가 변화되는 상황의 생체신호 데이터를 SOM으로 학습하고, 학습된 SOM 데이터를 이용해서 입력되는 생체신호 데이터의 긴장과 이완상태를 자동으로 분류하는 것을 목표로 한다.

긴장과 이완상태가 변화되는 상황을 주기 위해서 본 논문에서는 비행슈팅게임을 이용한다. 비행슈팅게임은 진행이 단순하고, 진행시간이 한정되어 있으며, 긴장도가 반복적이고 지속적으로 변화하기 때문이다.

긴장과 이완상태가 변화되는 상황은 생체신호 중 ECG를

이용한다. 건강한 사람의 심박수는 긴장도에 따라 민감하고 탄력적으로 변화하기 때문에 게임을 하는 사용자를 측정하기에 적합하다. 또한 심박신호는 인체의 항상성을 유지하기 위해서 자율신경계에 의해 끊임없이 변화하며, 자율신경계의 변화는 교감신경과 부교감신경의 활동을 정량적으로 나타낼 수 있기 때문에 피험자의 상태를 알 수 있다[2][3].

긴장과 이완 상태를 자동으로 인식하기 위한 SOM의 적용은 두 단계로 구성된다. 첫 번째는 ECG 측정 및 분석 단계로, 비행슈팅게임을 플레이하는 피험자를 ECG로 측정하고 분석하는 단계이다. 두 번째는 SOM 학습 및 인식 단계로 긴장과 이완상태를 학습하고 인식하는 단계이다.

SOM은 심박신호의 입력벡터들을 입력하면 연결강도가 조정되면서 스스로 학습하여 긴장과 이완상태의 결과를 보여준다. SOM 학습의 결과는 주파수 분석과 SOM 인식에서 선택된 승자뉴런의 거리와 비교하여 성능을 평가하였다.

본 논문은 다음과 같이 구성된다. 2장에서는 ECG와 SOM의 이론적 배경을 설명하고, 3장에서는 긴장과 이완상태의 자동인식을 위한 SOM 학습을 적용한 시스템을 단계별로 설명한다. 4장에서는 실험 및 분석으로 주파수 분석과 SOM의 학습결과, 그리고 SOM의 성능평가를 매칭한 결과를 보여준다. 마지막 장에서는 향후 연구 방안을 제시한다.

## II. ECG와 SOM

본 연구에서는 측정된 ECG에서 HRV의 시간 분석과 주파수 분석을 통해서 SOM 학습에 입력될 특징벡터들을 추출하였다. ECG와 SOM의 이론적 배경을 살펴보고자 한다.

### 2.1 ECG

심전도(ECG; Electrocardiogram)는 심장의 수축과 이완이 일어날 때 그림 1과 같이 P파, QRS파, T파 등의 전기적인 신호가 연속적으로 발생한 것을 기록한 것이다.




그림 1. 심박신호 파형  
Fig. 1. Signal of ECG

P파는 심방의 수축시에 형성되며, QRS파는 심실의 수축시

에 형성된다. T파는 심실의 이완에 의해 발생한다. 심전도 신호의 각 파형은 비교적 일정한 모양과 주기를 가지고 발생하며 심장의 상태를 간접적으로 측정할 수 있다[4].

심박변이도(HRV: Heart Rate Variability)는 그림 1과 같이 R파형 다음에 나타난 R파형 간격의 변이를 측정하는 것이다. 다른 말로는 R-R간격이라고 부르기도 한다. 본 논문에서는 HRV라고 하겠다. HRV는 교감신경과 부교감신경의 균형상태를 평가하는 방법으로서 시간 분석과 주파수 분석으로 나누어진다.

시간 분석은 심박신호가 변화하는 정도를 시간적으로 평가하는 것으로, HRV의 전체적인 특성을 알 수 있다. 시간 분석의 종류는 HRV의 변화를 평균, 분산, SDNN, 변이계수, RMSSD, pNN50 등이 있다. 평균은 전체 HRV의 평균을 나타내며, SDNN은 HRV의 표준편차를 말한다. 변이계수값은 (SDNN/평균값) × 100을 한 것으로 심박의 규칙성을 알 수 있다. RMSSD는 HRV의 제곱평균값으로 HRV의 단시간 변화를 알 수 있다. 그리고 pNN50은 전체 HRV 간격에서 인접한 두 HRV간격의 차이가 50ms 보다 큰 비율을 나타낸다. RMSSD와 pNN50은 부교감 신경의 조절을 알 수 있다. 시간 분석은 계산하기는 쉽지만, 자율신경계의 균형을 정량화하는 방법이 없다.

하지만, 주파수 분석은 주파수 영역별로 정량화하여 분석할 수 있다. 주파수 분석의 종류는 FFT(Fast Fourier Transform), AR(Auto Regressive) 모델 등이 있다. 주파수 대역별로 나타나는 형태는 FFT의 경우 뾰족한 형태가 나타나지만, AR 모델은 부드러운 모양이 나타난다. 일반적으로 FFT는 초기에 주파수 분석으로 사용하였으나, 최근에는 AR 모델을 사용한다. AR모델은 FFT 비해서 스펙트럼의 해상도가 크며, 신호 잡음이 덜 민감하기 때문이다. 처리속도는 FFT의 경우 고속으로 계산할 수 있는 장점이 있지만, 5분의 데이터가 제공되어야만 주파수별로 분석이 가능하다. 하지만, AR모델은 FFT에 비해 계산 속도는 느리지만, 짧은 시간 데이터의 분석이 가능하다. 본 논문에서 심박데이터를 2분으로 분석하기 위해서 AR모델을 사용하였다[2][5].

주파수대역은 LF(Low Frequency : 0.1 Hz 이하), MF(Medium Frequency : 0.1 ~ 0.15Hz), 그리고 HF(High Frequency : 0.15 ~ 0.4Hz) 영역으로 구분될 수 있다. 주파수 영역의 LF 성분은 체온조절의 변화를 나타내며, MF성분은 교감, 부교감 신경에 지배 받으며, HF 성분은 호흡주기, 부교감신경의 변화를 나타낸다[6]. LF/HF 비율은 자율신경의 활동성의 균형을 알 수 있다. Mallini와 Pagani는 피험자의 자율신경평가를 위해서 LF는 교감신경으로, HF는 부교감신경으로 사용하여 연구하였다[7]. 본 논문에서는 LF와 HF 영역을 구한 후, LF/HF 비율을 사용하였다.

## 2.2 SOM

신경망(Neural Network)을 McCulloch와 Pitts는 인간의 뇌를 수많은 신경세포들로 이루어진 컴퓨터라고 정의하였다[8]. 학습방법에는 지도학습(Supervised Learning)과 비지도 학습(Unsupervised Learning)으로 분류할 수 있다. 지도 학습은 사용자가 임계값을 지정하여 학습을 시키는 방법으로 Hopfield 신경망, 다층 퍼셉트론(MLP: Multi-Layer Perceptron) 등이 있다. 반대로 비지도 학습은 스스로 학습을 하면서 비슷한 패턴끼리 군집화 되면서 결과값을 나타내는 방법을 말하며, ART(Adaptive Resonance Theory), SOM 등이 있다.

Hopfield 신경망은 최적의 분류결과를 얻기 위해서 패턴인식에서 사용되고 있다. 유사한 패턴일 경우에는 분류 결과가 좋지만, 정확하지 않은 패턴일 때는 다른 패턴으로 분류가 될 수 있는 문제가 있으며, 수행속도가 느다[9]. MLP는 학습능력이 뛰어나 음성 인식 및 합성 문제, 시각 패턴 인식 문제 등에 이용되고 있다. 그러나 일반적으로 사용되고 있는 오류역전파 알고리즘은 학습시간이 오래 걸리고, 입력벡터의 차원이 크거나 입력벡터의 유사성이 클 경우 비슷한 패턴을 분류할 때 한계가 있다[10][11].

ART 신경망은 자동 학습 시스템으로 사용되며 ART1과 ART2로 분류가 된다[12]. ART1은 입력벡터가 2진수로 입력되기 때문에 전처리 작업이 필요하며, 입력벡터가 연속적인 수는 적절하지 못하다. 이것을 보완하여 ART2는 이진수 입력 벡터 또는 아날로그 입력벡터로 자율 학습이 가능하다[13]. ART1은 임계값 설정에 따라서 패턴들이 다르게 분류될 수 있다. 예를 들면, 서로 다른 패턴들이 같은 패턴으로 분류되거나, 같은 패턴들이 다른 패턴들로 분류가 되는 한계가 있다[14]. ART2는 모든 입력벡터의 평균값으로 연결강도를 계산한다. 새로운 입력벡터가 입력이 되면 평균값의 연결강도는 입력패턴의 특징을 감소시킴으로써 다른 패턴으로 분류되는 문제가 있다[15][16].

SOM은 시간에 따라 변하는 입력벡터를 이용하여 연속적으로 학습할 수 있다. 또한 입력층에서 출력층으로 한 방향으로 흐르기 때문에 수행속도가 빠르다. SOM은 자율학습과 경쟁학습의 특징이 있다. 자율학습은 가르쳐 주는 사람이 없어도 스스로 학습을 하면서 최소 거리의 뉴런으로 답을 찾는 학습법이다. 경쟁학습은 주어진 입력벡터와 최소 거리의 뉴런을 찾아서 승자뉴런이라고 정하고, 승자뉴런과 승자 뉴런 주위의 이웃 뉴런에만 가중치를 적용하는 학습방법이다. 이러한 점을 이용하여 본 연구에서는 SOM으로 학습하였다.

그림 2와 같이 SOM은 입력층과 출력층으로 나누어져 완

전연결 되어 있다. 입력층은  $X_1$ 부터  $X_m$ 으로  $m$ 개의 갯수 만큼 입력데이터가 있다. 출력층은 2차원 벡터방식으로  $n$ 개로 구성된다.

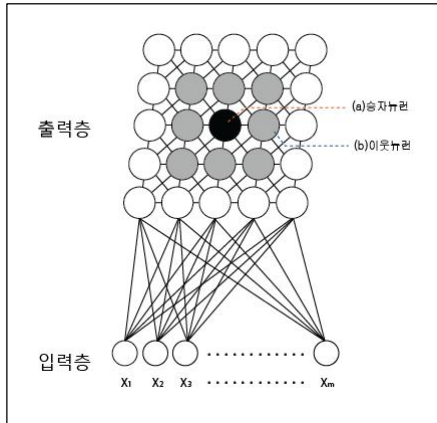


그림 2. SOM 구조  
Fig. 2. SOM of Structure

SOM 학습의 단계는 네 단계로 나누어진다. 첫 번째 단계에서는 모든 뉴런들이 포함될 수 있도록 연결강도를 랜덤하게 초기화된다. 두 번째 단계에서는 정규화된 데이터를 입력벡터로 입력된다. 세 번째 단계에서는 주어진 입력벡터와 모든 뉴런들과의 거리를 계산된다. 이때 가장 최소거리의 뉴런을 찾아서 그림 2의 (a)승자뉴런으로 지정하게 된다. 승자뉴런은 주어진 입력벡터와 가장 비슷한 패턴을 가진 뉴런이다. (b)이웃 뉴런은 학습율에 영향을 받아서 선택된다. 네 번째 단계에서는 승자뉴런과 이웃뉴런들의 연결강도가 재조정된다. 승자뉴런과 이웃뉴런 이외의 뉴런들은 연결강도가 재조정되지 않고 이전의 값을 갖으면서 학습을 한다[17].

3장에서는 측정된 심박신호를 긴장과 이완상태의 자동인식을 할 수 있도록 SOM 학습에 적용한다.

### III. 긴장과 이완상태의 자동인식을 위한 SOM의 적용

피험자의 긴장과 이완상태의 자동인식을 위한 SOM의 적용은 그림 3과 같이 크게 두 단계로 구성된다. (가)ECG 측정 및 분석 단계에서는 비행슈팅게임을 하는 피험자의 ECG를 측정하고, 심박신호의 특징을 추출한다. (나)SOM 학습 및 인식 단계에서는 심박신호의 입력벡터들을 SOM으로 학습을 한다. 학습된 결과는 긴장과 이완상태로 분류하여 자동 인식할 수

있도록 시스템을 적용한다.

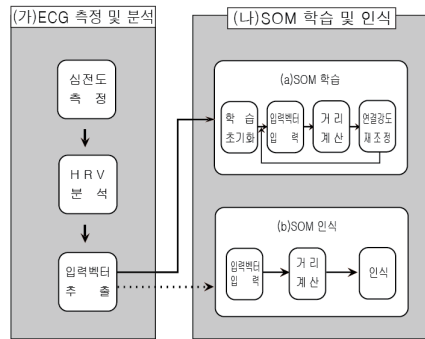


그림 3. 긴장과 이완상태의 자동인식을 위한 SOM의 적용 시스템  
Fig. 3. System Applying of SOM for Automatic Recognition of Tension and Relaxation

#### 3.1 ECG 측정 및 분석

그림 3의 (가)ECG 측정 및 분석 단계는 심전도 측정, HRV 분석, 입력벡터 추출의 세 단계로 나누어져 구성된다.

심전도 측정단계는 피험자에게 심전도 센서를 부착한 후 게임을 플레이하게 한 후 ECG로 측정한다. 심박파형의 P,Q,R,S,T의 값은 컴퓨터로 입력받는다.

HRV분석 단계는 심박신호 중 R파형을 추출한다. R파형은 가장 높은 값을 갖고 있기 때문에 정확하게 추출된다는 장점이 있다. HRV를 이용하여 시간 분석과 주파수 분석으로 나누어서 분석할 수 있다. 일반적으로 시간 분석과 주파수 분석은 자율신경계가 심장박동에 미치는 영향을 연구에서 많이 사용되고 있다[18]. 시간 분석은 심박수 변화에 대한 전반적인 특징을 알 수 있고, 주파수 분석은 주파수 대역에 따라서 교감신경계와 부교감신경계의 활동을 정량적으로 나타내어 자율신경계의 균형 상태를 알 수 있기 때문이다[19].

입력벡터추출 단계는 심박신호의 분석으로 SOM학습에서 사용할 특징벡터를 추출한다. 피험자의 긴장과 이완 상태를 자동인식하기 위한 SOM 학습에서 입력벡터로 이용된다. SOM의 입력벡터는 시간분석의 최대값, SDNN, 변이계수값, RMSSD, 주파수 분석의 LF/HF 비율로 구성하였다.

최대값으로는 신체의 각성도를 확인할 수 있다. 최대값이 클수록 피험자의 상태가 이완상태임을 알 수 있다. SDNN은 HRV의 표준편차로 평균과의 차이를 나타낸 것으로 심박신호의 변화도를 알 수 있다. SDNN의 값이 클수록 평균과의 차이가 크다는 것을 알 수 있다. 변이계수값으로는 심박의 규칙성

을 알 수 있으며, RMSSD는 부교감 신경의 영향을 평가할 수 있다[20]. 값이 클수록 피험자가 이완상태라는 것을 확인할 수 있다. 주파수 분석으로는 LF/HF 비율을 계산하여 고주파의 영역 HF에 대한 저주파의 영역 LF의 비율을 알 수 있으므로 교감 신경의 증가를 확인할 수 있다[21]. 비율의 값이 클수록 피험자는 긴장상태이다. 반대로 값이 작을수록 이완상태임을 알 수 있다.

피험자마다 측정된 값은 다르기 때문에 추출된 특징벡터를 정규화하여 입력벡터에 사용한다.

### 3.2. SOM 학습과 인식

그림 3의 (나)SOM 학습 및 인식에서 (a)SOM 학습단계는 (가)ECG 측정 및 분석에서 추출된 심박신호를 긴장과 이완상태로 학습하는 과정으로 4단계로 구성된다. 첫 번째 단계에서는 모든 심박신호가 입력될 수 있도록 임의의 값을 랜덤하게 초기화하여 구성한다. 두 번째 단계에서는 심박신호의 입력벡터를 입력한다. 세 번째 단계에서는 심박신호의 입력벡터와 모든 뉴런들간의 거리를 계산한다. 최소 거리에 있는 뉴런을 승자뉴런으로 선택한다. 승자뉴런은 피험자의 긴장과 이완 상태에 가장 비슷한 심박신호의 패턴을 찾아서 보여준다. 네 번째 단계에서는 식(1)처럼 학습율이 적용되어 승자뉴런과 이웃 뉴런들의 연결강도를 재조정하게 된다[22].

$$m_i(t+1) = \begin{cases} m_i(t) + \alpha(t)[x(t) - m_i(t)] & \text{if } i \in N_c(t), \\ m_i(t) & \text{if } i \notin N_c(t), \end{cases} \dots\dots\dots(1)$$

식(1)의  $x(t)$ 는 심박신호의 특징이 추출된 입력벡터이며,  $m_i(t)$ 은 출력벡터로 피험자 상태를 긴장과 이완상태를 나타낸다.  $\alpha(t)$ 는 학습률로 0과 1사이의 값을 갖는다. 학습이 진행됨에 따라 학습율은 감소되고 출력벡터의 범위가 좁혀지면서 줄어든다.  $N_c(t)$ 는 승자뉴런 주변에 있는 이웃뉴런이다.

승자뉴런과 이웃뉴런 이외의 뉴런들에 대한 학습은 학습율이 적용되지 않아서 이전의 값을 그대로 갖게 된다. 이 과정은 입력벡터 양만큼 학습되면서 반복된다.




그림 4. SOM 인식  
Fig. 4. SOM Recognition

그림 3 (나)SOM 학습 및 인식의 (b)SOM 인식단계는 SOM학습된 결과에서 입력벡터를 입력하여 피험자의 상태를 자동 분류하여 인식하게 된다. 그림 4와 같이 심박신호의 입력벡터가 입력되면 가장 비슷한 패턴의 심박신호를 그림 4의 (a) 승자뉴런으로 선택된다. 비슷한 패턴이란 거리 계산을 했을 때 가장 가깝게 나온 패턴으로 뉴런 안에 입력벡터의 모형이 비슷하게 구분되어 군집화 되어 있다.

승자뉴런이 선택된 후에 승자뉴런 주위에 (b)이웃뉴런들이 분포되어 나타나게 된다. 이웃뉴런 이외의 뉴런들은 SOM 학습의 영향을 받지 않고 그대로 있게 된다.

SOM 인식은 (가)ECG 측정 및 분석에서 추출된 심박신호의 입력벡터가 입력되면 (c)긴장상태 영역이 선택되고, 그 외의 영역은 (d)이완상태 영역이 선택되어서 사용자에게 인식하도록 제시 된다.

## IV. 실험 및 분석

### 4.1 실험

실험의 피험자는 대학생 남자 5명으로 구성하였다. 측정이 잘 될 수 있도록 전날 피험자에게 숙면을 취하도록 요구했다. 측정하는 날은 실험에 영향을 줄 수 있는 담배와 커피는 하지 않고 실험하였다. 측정장비는 Biopac의 MP36으로 측정하였다.

생체신호 자극원으로는 게임 중 비행슈팅게임으로 하였다. 비행슈팅게임은 플레이하면 할수록 다른 게임에 비해 단순하기 때문에 쉽게 익숙해진다. 그리고 게임횟수에 따라 실력이 향상될 수 있기 때문이다. 비행슈팅게임의 종류 중 그림 5와 같이 라이덴Ⅲ로 실험을 하였다[23].

게임 방식은 자신의 비행 캐릭터를 조정하여 적의 비행기를 총알로 격추시키면서 진행된다. 아이템의 색깔 별로 획득

한 충알이 다양하게 발사되며, 적을 빨리 격추시킬수록 점수의 배율이 높아진다.




그림 5. 라이덴III 게임화면  
Fig. 5. Game Interface of RaidenIII

ECG 측정은 첫 스테이지만 30회 반복 플레이하였다. 피험자의 심박신호는 같은 스테이지를 플레이하는 동안 비슷한 패턴의 변화를 볼 수 있기 때문이다. 측정 시간은 2분 30초로 하였다. 심박신호의 분석은 2분동안 HRV 분석을 한 후에 1초씩 이동하면서 분석하였다. 주파수분석의 AR모델은 짧은 시간의 심박신호에서도 분석이 가능하기 때문에 2분 간격의 주기로 데이터를 분석하였다. 1초씩 이동하면서 분석한 것은 피험자의 상태 변화를 볼 수 있기 때문이다. 분석된 데이터는 한번의 게임에서 30개씩 SOM에 사용할 수 있는 입력벡터를 추출했다. SOM으로 학습을 하기 위해서는 일정한 양의 입력벡터가 제공되어 학습을 해야만 유의미한 결과가 나올 수 있기 때문이다.


#### 4.2 분석

실험 결과는 세 가지로 나누어서 분석했다. 첫 번째는 피험자의 게임 횟수에 따른 HRV의 주파수 변화, 두 번째는 심박신호의 SOM 학습한 결과, 그리고 세 번째는 SOM 학습 결과와 주파수 분석을 비교하여 매칭율을 분석한다. 그림 6은 게임 횟수에 따른 HRV의 주파수 변화를 각 피험자 별로 나타낸 그래프이다.


그림 6에서 그래프의 가로축은 피험자의 게임 횟수를 말하며, 세로축은 주파수 분석의 LF/HF 비율을 나타낸다. LF/HF 비율은 자율신경에 대한 활동성의 균형을 확인할 때 일반적으로 사용되며 정상 상태의 경우 LF/HF 비율은 1.5 전후를 나타낸다[24]. 따라서 본 논문에서도 피험자의 LF/HF 비율이 1.5 이상인 경우를 긴장 상태로, 1.5 미만인 경우를 이완 상태로 정의하여 분석하였다.




(가) 피험자 A




(나) 피험자 B



(다) 피험자 C



(라) 피험자 D



(마) 피험자 E

그림 6. 피험자의 게임 횟수에 따른 주파수의 변화  
Fig. 6. Change of the Frequency for the Number of Times Being Played Game

HRV의 주파수 변화는 게임의 횟수에 따라서 피험자마다 다르게 나타났다. 그림 6의 피험자 A의 경우 게임을 처음 했을 때와 게임이 끝날 때에 긴장을 느끼는 것으로 나타났으며 그 외에는 전체적으로 이완된 상태를 나타냈다. 반면 피험자 B의 경우는 게임하는 동안 긴장과 이완이 규칙적으로 반복되는 결과가 나왔으며, 피험자 C의 경우는 게임을 하는 동안 지속적인 긴장 상태를 유지하는 결과를 나타냈다. 그리고 피험자 D, E의 경우 피험자 A와 달리 게임이 시작된 후 일정 횟수 동안 긴장과 이완 상태가 반복되는 결과를 얻었다. 따라서 피험자들 중 지속적인 이완 상태를 나타낸 피험자는 A였으며, 큰 폭으로 긴장과 이완 상태로 변화하는 피험자는 C, 그리고 그 밖에 피험자들은 게임 횟수에 따라 긴장과 이완 상태가 일정 간격으로 변화를 알 수 있었다.

심박신호의 SOM 학습 결과는 그림 7처럼 나타났다. 그림 7의 (가)SOM학습 초기상태는 SOM 학습전의 모습으로 10×10으로 구성했다. 모든 심박신호의 입력벡터들이 포함될 수 있도록 연결강도를 랜덤으로 초기화하였다.

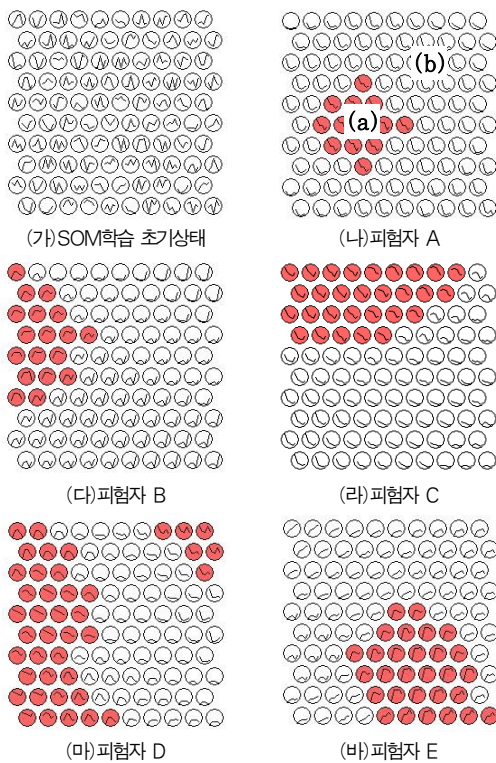


그림 7. 피험자의 SOM 학습 결과  
Fig. 7. Result of Learning SOM

그림 7의 (나)~(바)는 SOM학습 결과로 심박신호의 입력벡터를 입력시켰을 때 학습이 완료된 상태이다. 직관적으로 분류를 하기 위해서 클러스터링을 이용하여 긴장과 이완상태를 시각적으로 표현하여 분류하였다. 피험자의 학습 결과는 (a)긴장상태와 (b)이완상태로 서로 다른 형태가 분류되어 나타났다.

그림 7의 SOM학습 후의 피험자 A, B의 경우는 (a)긴장상태가 적게 분포되었다. 그림 6의 주파수 변화를 보았을 때 전체적으로 이완상태가 많이 분포되어 있어서 이완상태가 긴장상태에 비해서 많이 나타나 있음을 알 수 있다. 피험자 C, D, E의 경우는 (a)긴장상태의 영역이 A와 B에 비해서 넓게 분포되어 있다. 그림 6의 주파수 변화를 보았을 때 전체적으로 긴장상태가 높아진 것을 알 수 있었다. 이것으로 본 논문에서 제안했던 피험자의 긴장과 이완상태를 자동으로 인식하기 위해 SOM으로 학습할 수 있음을 확인할 수 있었다.

마지막으로 SOM학습의 성능을 확인하기 위해서 피험자 E를 그림 8처럼 게임횟수에 따른 매칭을 그래프로 나타냈다. 가로축은 게임횟수를 말하며, 세로축은 피험자의 긴장과 이완상태를 나타낸다. 그림 8의 (가)주파수 분석을 통해 LF/HF 비율 1.5를 기준으로 긴장과 이완상태를 알 수 있는 그래프이다. (나)SOM의 승자뉴런 거리는 SOM으로 학습한 결과에서 심박신호의 입력벡터를 넣었을 때 승자뉴런의 거리값을 이용하여 긴장과 이완상태를 나타낸 것이다. (다)게임횟수에 따른 매칭영역은 (가)주파수 분석의 LF/HF와 (나)SOM 학습의 승자뉴런 거리를 순차적으로 비교하면서 매칭영역의 결과를 그래프로 나타내어 피험자의 긴장과 이완상태를 알 수 있다.

그림 8에서 (a)로 지정된 7번째 게임은 주파수 분석의 LF/HF 비율 값이 1.5보다 낮은 이완상태를 나타냈으며, SOM의 승자뉴런 거리는 이완상태가 나타났다. 그 결과 그래프는 매칭영역으로 나타났으며, 피험자는 이완상태를 보였다.

그림 8에서 (b)의 10번째 게임은 주파수 분석의 LF/HF가 전체적으로 긴장상태이고, 중간이후부터는 주기적으로 긴장과 이완상태가 나타났다. 승자뉴런 거리는 긴장상태를 나타냈다. 이것은 비슷한 패턴끼리 군집화되는 SOM의 특성 때문에 주파수 분석의 LF/HF 그래프보다 뭉쳐져서 나타나고 있다. 10번째 게임의 경우 매칭된 영역의 결과는 (a)7번째보다는 낮게 나타났으며, 피험자는 전체적으로 긴장상태를 보였다. 결과적으로, 피험자 E는 게임을 하는 동안 주기적으로 긴장과 이완이 나타났으며, 전체적으로 긴장보다는 이완상태의 결과를 나타냈다.

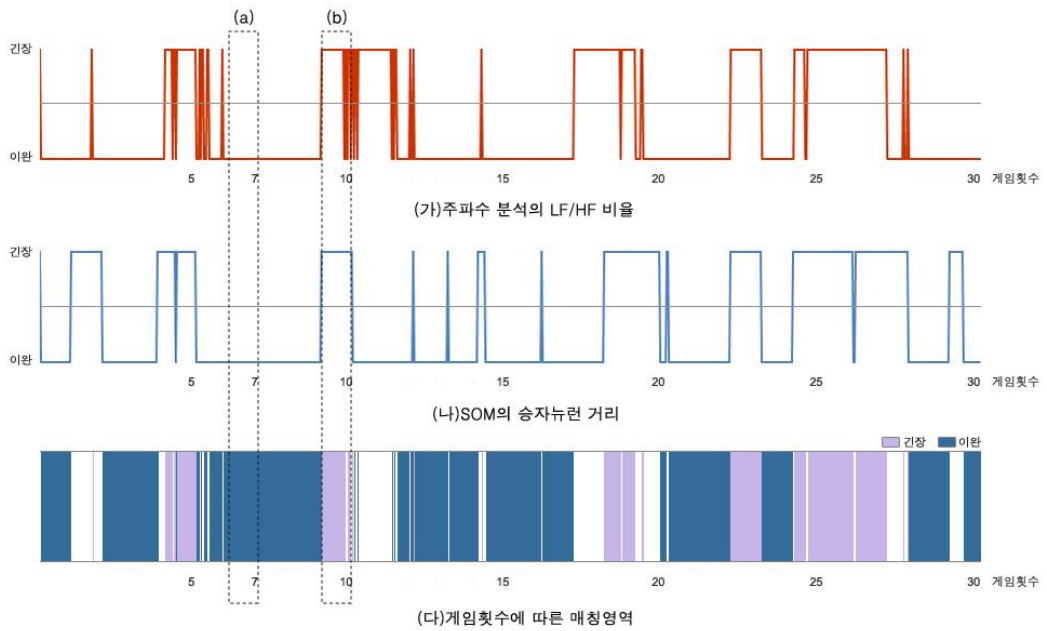


그림 8. 게임 횟수에 따른 매칭  
Fig. 8. the Matching for the Number of Times Being Played Game

게임횟수에 따른 매칭 영역을 각 피험자마다 비교한 결과는 표 1처럼 SOM의 매칭율로 나타났다.

표 1. SOM의 매칭율  
Table 1. SOM of Matching Rate

피험자	매칭율
A	79%
B	75%
C	62%
D	65%
E	79%
평균	72%

SOM의 매칭율은 피험자 A와 E의 경우 79% 성능으로 가장 높게 나타났으며, 피험자 C는 62% 성능으로 가장 낮게 나타났다. 피험자 B는 75%의 성능으로 나타났다. SOM의 매칭율 평균은 72%로 분석되었다.

SOM 학습의 매칭율을 분석한 결과는 유의미한 결과를 보여주었다. 피험자의 상태를 긴장과 이완으로 자동인식 할 수 있도록 SOM의 적용이 가능함을 확인할 수 있었다.

## V. 결론

본 연구에서는 측정된 심박신호를 긴장과 이완상태로 분류하여 자동인식 할 수 있도록 SOM의 적용을 제안하였다. SOM 학습의 성능을 확인하기 위해서 주파수 분석의 LF/HF 비율을 1.5을 기준으로 해서 SOM 학습의 선택된 승자누런을 순차적으로 비교하여 매칭을 하였다. SOM의 매칭율은 72%의 성능이 나왔다.

본 연구는 생체신호로 측정된 피험자의 상태 변화를 자동으로 감지할 수 있는 의의가 있다. 본 연구에서 제안했던 피험자의 긴장과 이완상태를 자동으로 인식하기 위해서 특징이 추출된 심박신호를 SOM으로 학습한 결과는 유의미한 결과를 보여주었다.

본 연구의 매칭율 성능은 72%로 정확성과 실용성에 한계가 있었다. 하지만 심박신호의 특징벡터 차원을 높여서 SOM으로 학습하면 매칭율의 성능이 향상 될 것이다. 피험자의 측정시간을 5분 이상의 심박데이터를 분석하여 특징벡터를 추가하거나, ECG 외에 GSR(Galvanic Skin Response)과 SKT(Skin Temperatures) 등의 다른 생체신호를 특징벡터로 함께 이용한다면 매칭율이 높아질 것이다.

향후 연구방향은 SOM 학습을 이용하여 실시간으로 긴장과 이완상태를 인식할 예정이다. 게임을 플레이하는 피험자의



상태에 따라 게임 환경에 적용할 수 있으며, 게임을 플레이하는 피험자의 이완 상태를 찾아서 게임의 비행속도와 아이템 수의 레벨이 조절을 할 수 있을 것이다. 이를 통해, 게임을 플레이하는 피험자의 몰입도 향상을 기대할 수 있다.

### 참고문헌

[1] Paul Ekman, Robert W. Levenson, Wallace V. Friesen, "Autonomic Nervous System Activity Distinguishes among Emotions," *Science*, Vol. 221, No. 4616, pp. 1208-1210, September 1983.

[2] 최병문, 노규정, "심박변이도(Heart Rate Variability, HRV)," *정맥마취*, 제 8권, 제 2호, 45-86쪽, 2004년.

[3] Rollin M. MA, Mike A., Wiliam A. Tiler, "The Effects of Emotions on Short-Term Power Spectrum Analysis of Heart Rate Variability," *The American Journal of Cardiology*, Vol. 76, pp. 1089-1093, November 1995.

[4] 지중철, "System Generator를 이용한 FPGA 기반의 실시간 심전도 디지털 필터의 연구 연세대학교 대학원 석사논문, 2006년 2월.

[5] 김낙환, 이은실, 민홍기, 이영혁, 홍승홍, "AR 모델을 이용한 심전도와 맥파의 심박변동 스펙트럼해석," *한국 신호처리·시스템 학회 논문지*, 제 1권, 제 1호, 15-22쪽, 2000년.

[6] Ventura, A. G., Reisman, S., "A Study of Factors Affecting Cardiovascular Reactivity," *Proceedings of the IEEE Annual Northeast Bioengineering Conference*, Vol. 26, pp. 53-54, 2000.

[7] Alberto Malliani, Federico Lombardi, Massimo Pagani, "Power Spectrum Analysis of Heart Rate Variability: A Tool to Explore Neural Regulatory Mechanisms," *British Heart Journal*, Vol.71, pp. 1-2, January 1994.

[8] 조영임, "인공지능시스템," *홍릉과학출판사*, 2009년.

[9] A. Murat Tekalp, "Digital Video Processing," Prentice Hall, 1995.

[10] 이대중, 최기선, 조재훈, 전명근, "LDA와 Local MLP를 이용한 얼굴 인식," *퍼지 및 지능시스템학회 논문지*, 제 16권, 제 3호, 367-371쪽, 2006년 6월.

[11] 강선경, 김영운, 소인미, 정성태, "인공신경망을 이용한 마커 검출 및 인식의 정확도 개선," *한국컴퓨터정보학회 논문지*, 제 13권, 제 1호, 89-97쪽, 2008년 1월.

[12] Gail A. Carpenter, Stephen Grossberg, "The ART of Adaptive Pattern Recognition by a Self-Organizing Neural Networks," *Computer*, Vol. 21, No. 3, pp. 77-88, Mar. 1998.

[13] Gail A. Carpenter, Stephen Grossberg, "ART2: Self-Organization of Stable Category Recognition Code for Analog Input Patterns," *Applied Optics*, Vol. 26, No. 23, pp. 4919-4930, Dec. 1987.

[14] 김광백, 김영주, "동적인 임계화 방법과 개선된 학습 알고리즘의 신경망을 이용한 차량 번호판 인식," *정보처리학회 논문지B*, 제 9-B권, 제 1호, 119-128쪽, 2002년 2월.

[15] 김광백, 김영주, "명암도 변화 및 HSI 정보와 개선된 ART2 알고리즘을 이용한 차량번호판 인식," *퍼지 및 지능시스템학회 논문지*, 제 11권, 제 5호, 379-387쪽, 2001년 10월.

[16] 김광백, 우영운, 조재현, "형태학적 특징과 퍼지 ART 알고리즘을 이용한 신 차량 번호판 인식에 관한 연구," *한국컴퓨터정보학회 논문지*, 제 13권, 제 6호, 273-278쪽, 2008년 11월.

[17] T. Kohonen, "Self-Organizing Maps," Springer Verlag, 1995.

[18] Akselrod S, Gordon D, Ubel FA, Shannon DC, Barger AC, Conen RJ, "Power Spectrum Analysis of Heart Rate Fluctuation: A Quantitative Probe of Beat-To-Beat Cardiovascular Control," *Science*, Vol. 213, No. 4504, pp. 220-222, July 1981.

[19] Ireland N, Meagher J, Sleigh J.W, Henderson J.D, "Heart Rate Variability in Patients Recovering from General Anaesthesia," *British Journal of Anaesthesia*, Vol. 76, pp. 657-662, 1996.

[20] Casolo G.C, Stroder P, Signorini C, Calzolari F, Zucchini M, Balli E, Sulla A, Lazzerini S., "Heart Rate Variability During the Acute Phase of Myocardial Infarction," *Circulation*, Vol. 85, pp. 2073-2079, 1992.

[21] Berger RD, Akselrod S., "An Efficient Algorithm for Spectral Analysis of Heart Rate Variability," *IEEE Transactions On Biomedical Engineering*, pp. 900-904, September 1986.

[22] Teuvo Kohonen, "The Self-Organizing Map," *Proceedings of the IEEE*, Vol. 78, No. 9, pp. 1464-1480, September 1990.

[23] Raiden 3, Moss, 2006.

[24] Marek Malik, "Heart Rate Variability: Standards of Measurement, Physiological Interpretation, and Clinical Use," *European Heart Journal*, Vol. 17, pp. 354-381, Mar. 1996.

## 저 자 소 개




### 정 찬 순

2007 : 숭실대학교 정보과학대학원  
정보미디어학과 공학석사.

현 재 : 숭실대학교 미디어학과 박사  
과정

관심분야 : 감성공학



### 함 준 석

2005 : 숭실대학교 미디어학부 공학  
학사.

현 재 : 숭실대학교  
미디어학과 석박사통합과정

관심분야 : 감성공학



### 고 일 주

1992 : 숭실대학교 전산학과 공학사.  
1994 : 숭실대학교 전산학과 공학석사.  
1997 : 숭실대학교 전산학과 공학박사

현 재 : 숭실대학교 미디어학과 조교수

관심분야 : 감성공학, 영상처리



### 장 대 식

1994 : 숭실대학교 전산학과 공학사.  
1996 : 숭실대학교 전산학과 공학석사.  
1999 : 숭실대학교 전산학과 공학박사

현 재 : 군산대학교 컴퓨터정보공학  
과 조교수

관심분야 : 로봇 비전, 영상 처리