

## Deep Belief Network를 이용한 뇌파의 음성 상상 모음 분류

# Vowel Classification of Imagined Speech in an Electroencephalogram using the Deep Belief Network

이 태 주, 심 귀 보\*  
(Tae-Ju Lee<sup>1</sup> and Kwee-Bo Sim<sup>1,\*</sup>)

<sup>1</sup>School of Electrical and Electronics Engineering, Chung-Ang University

**Abstract:** In this paper, we found the usefulness of the deep belief network (DBN) in the fields of brain-computer interface (BCI), especially in relation to imagined speech. In recent years, the growth of interest in the BCI field has led to the development of a number of useful applications, such as robot control, game interfaces, exoskeleton limbs, and so on. However, while imagined speech, which could be used for communication or military purpose devices, is one of the most exciting BCI applications, there are some problems in implementing the system. In the previous paper, we already handled some of the issues of imagined speech when using the International Phonetic Alphabet (IPA), although it required complementation for multi class classification problems. In view of this point, this paper could provide a suitable solution for vowel classification for imagined speech. We used the DBN algorithm, which is known as a deep learning algorithm for multi-class vowel classification, and selected four vowel pronunciations: /a/, /i/, /o/, /u/ from IPA. For the experiment, we obtained the required 32 channel raw electroencephalogram (EEG) data from three male subjects, and electrodes were placed on the scalp of the frontal lobe and both temporal lobes which are related to thinking and verbal function. Eigenvalues of the covariance matrix of the EEG data were used as the feature vector of each vowel. In the analysis, we provided the classification results of the back propagation artificial neural network (BP-ANN) for making a comparison with DBN. As a result, the classification results from the BP-ANN were 52.04%, and the DBN was 87.96%. This means the DBN showed 35.92% better classification results in multi class imagined speech classification. In addition, the DBN spent much less time in whole computation time. In conclusion, the DBN algorithm is efficient in BCI system implementation.

**Keywords:** deep belief network, electroencephalogram, imagined speech, vowel recognition

### I. 서론

사람의 뇌파를 이용하여 사물이나 로봇 혹은 컴퓨터와 같은 장비들을 제어하는 BCI (Brain-Computer Interface)에 대한 관심과 연구가 지속적으로 늘어나고 있다. 몸이 불편한 환자를 위한 문자 입력 시스템이나 휠체어 제어에 국한되었던 BCI의 활용방안이 게임 인터페이스, 로봇 제어, 외골격근 로봇과 같은 다양한 연구방향으로 확장되고 있다 [1-5]. BCI 기술을 사람의 커뮤니케이션에 적용하고자 하는 연구 역시 주목을 받고 있는데, BCI의 대표적인 응용 분야인 BCI keyboard부터 사람이 상상하는 언어를 패턴 학습을 통해 예상하는 imagined speech까지 다방면에서 연구가 진행되고 있다. 언어 상상시 발생하는 뇌파를 습득, 분석하는 시스템의 개발은 사람과 사람사이의 커뮤니케이션을 마치 텔레파시처럼 실현시켜줄 수 있을 뿐만 아니라, 군사용 목적으로도 충분히 활용 가능하다[6].

그러나 비침습적 뇌파 신호인 electroencephalogram (EEG)를 이용하는데 있어서 가장 문제점인 낮은 SNR (Signal to Noise Ratio)에서 오는 어려움들을 차지하더라도 언어 상상시 발생하는 뇌파를 활용하는데 몇 가지 주요한 어려움이 존재한다. 첫 번째는 인간이 사용하는 언어가 한 종류가 아니라는 것이다. 국제적으로 영어가 주류가 되어 많이 사용되긴 하나, BCI를 이용한 언어 시스템이 전세계 보편적으로 이용되기 위해서는 문맹자 및 단일 언어만을 사용하는 사람에 대해서도 편의성을 고려 할 필요가 있다. 한편, 영어 혹은 보편적인 다른 외국어를 사용할 수 있는 사람이라 하더라도 타언어가 완벽하게 체화되지 않는 이상, 해당 언어 위주로 개발된 시스템에서 목표로 하는 장비의 동작을 정상적으로 구현하기에는 힘든 점이 있을 것이다. 두 번째 어려움은 실제 사람이 표현하는 음성 언어가 매우 많은 클래스로 분류 된다는 것이다. 영어는 26개의 알파벳을 사용해 글을 표현하나, 실제 발음은 49 종류의 자음, 모음으로 나타나고, 강세 및 자음, 모음의 조합을 통해 더 많은 발음을 표현한다. 많은 클래스를 분류하게 될 때, 시스템의 복잡도가 증가하고 입력 데이터의 분류성공률이 낮아지게 된다. 우리가 이전에 진행하였던 연구[7]에서는 위와 같은 문제점을 해결하고자 국제음성기호(IPA: International phonetic alphabet)를 이용하여 다른 언어라 할지라도 동일한 발음을

\* Corresponding Author

Manuscript received June 30, 2014 / revised November 12, 2014 / accepted November 14, 2014

이태주, 심귀보: 중앙대학교 전자전기공학과

(bindaman@cau.ac.kr/kbsim@cau.ac.kr)

※ 본 논문은 한국연구재단 중견연구지원사업(No. 2012-000872)에서 지원하여 연구하였으며 연구비 지원에 감사드립니다.

할 때 생기는 공통적인 뇌파 데이터의 분석에 초점을 잡고 SVM (Support Vector Machine)을 이용하여 분류를 수행하였다. 그러나 해당 논문에서 결론내린 것처럼, SVM은 2개의 클래스 사이의 비교만 가능했기 때문에 여러 음소를 구분해야 하는 BCI를 이용한 언어 시스템에 적합하지 못하다는 단점이 있었다.

본 논문에서는 다중 클래스에 대응하지 못하는 기존의 알고리즘을 보완하고자, 인공 신경망을 기반으로 빠른 학습 및 분류 성능을 보이는 DBN (Deep Belief Network)를 이용해 4 종류의 모음을 학습하고 분류하는 실험을 수행하였다. II 장에서는 본 실험에 앞서 필요한 이론적 배경을 간단히 살펴보고, III 장에서는 실험 방법을 설명한다. 이어지는 IV 장과 V장에서는 실험 결과와 고찰을 통해 결론을 얻는다.

## II. 이론적 배경

### 1. 특징추출

EEG raw data의 특징을 추출을 위해서 우리는 covariance matrix의 고유 값을 이용하였다.  $t$  샘플링 시간 동안  $n$ 개의 채널에서 한 epoch동안 얻은 뇌파 데이터  $t \times n$  크기의  $X$ 라 할 때 covariance matrix  $\Sigma$ 는 (1)과 같이 구할 수 있다.

$$\Sigma = \text{EXP}[(X - \text{EXP}[X])(X - \text{EXP}[X])^T] \quad (1)$$

이 때,  $\text{EXP}[\cdot]$ 는  $X$ 의 평균값을 의미하고 위첨자  $T$ 는 transpose를 의미한다. 고유 값은 식 (2)를 만족하는 고유 벡터  $v$ 가 존재할 때, 그 때의 계수  $\lambda$ 를 통해 구할 수 있다.

$$\Sigma v = \lambda v \quad (2)$$

여기서  $\Sigma$ 와  $v$ 가  $n \times n$  크기의 행렬이 되어,  $\lambda$ 는 대각 성분만을 갖고 나머지 성분은 0인  $n \times n$  행렬이 된다. 본 논문에서는  $\lambda$ 의 대각 성분만을 취해  $n \times 1$  벡터로 만들어 뇌파의 특징 벡터로 사용한다.

### 2. Back propagation artificial neural network

역전파 인공 신경망으로도 불리는 BP-ANN (Back Propagation Artificial Neural Network)은 multi-layer perceptron의 학습 방법 중 하나이다. ANN 모델을 통과하여 얻어진 출력 값을 사용자가 원하는 타겟과 비교해 오차를 구하고, 오차를 역전파 해 각 층 사이의 연결강도를 조정하는 방법이다[8]. 연결강도의 변화량은 기울기 탐색을 통해 구한다. output layer에 존재하는  $j$ 번째 출력 노드와 연결된  $i$ 번째 입력 노드사이의 연결강도를  $w_{ji}$ 라고 할 때, 연결강도  $w_{ji}$  변화에 따른 전체 에러  $E_{total}$ 의 변화는 chain rule을 이용하여 다음과 같이 표현할 수 있다.

$$\frac{\partial E_{total}}{\partial w_{ji}} = \frac{\partial E_{total}}{\partial e_j} \frac{\partial e_j}{\partial y_j} \frac{\partial y_j}{\partial \nu_j} \frac{\partial \nu_j}{\partial w_{ji}} \quad (3)$$

$$\text{where, } E_{total} = \frac{1}{2} \sum e_j^2$$

여기서  $e_j$ 는  $j$ 번째 출력 노드의 에러,  $y_j$ 는  $j$ 번째 출력 노드의 출력,  $\nu_j$ 는  $j$ 번째 출력 노드로 들어오는 입력과 연결강도의 곱들을 전부 더한 값이다.

은닉 층 사이의 연결강도의 업데이트도 유사한 방식으로

구할 수 있으나, 은닉 층은 여러 출력노드로부터 동시에 역전파를 받기 때문에 에러를 다루는데 있어 차이점이 발생한다. 모든 출력 노드에서 발생하는 에러를 고려하여 합해야 하므로  $j$ 번째 은닉 노드의 출력  $y_j$  변화에 따른 전체 에러  $E_{total}$ 의 변화는 식 (4)와 같이 체인룰을 이용하여 나타낼 수 있다.

$$\frac{\partial E_{total}}{\partial w_{ji}} = \frac{\partial E_{total}}{\partial y_j} \frac{\partial y_j}{\partial \nu_j} \frac{\partial \nu_j}{\partial w_{ji}} \quad (4)$$

$$\text{where, } \frac{\partial E_{total}}{\partial y_j} = \sum_k e_k \frac{\partial e_k}{\partial y_j} = \sum_k e_k \frac{\partial e_k}{\partial \nu_k} \frac{\partial \nu_k}{\partial y_j}$$

여기서 노드  $i$ 는 다음 은닉 층의 노드  $j$ 로 가는 입력 노드 혹은 은닉 노드이고,  $j$ 는 출력노드  $k$ 와 연결되어 있다.

연결강도의 업데이트에 사용하는 기울기 탐색은 초기 연결강도에 따라 지역 해에 빠지는 경우가 발생하므로 초기 값에 따라 원하는 결과를 얻는데 어려움이 발생할 수 있다.

### 3. Deep belief network

DBN은 볼츠만 머신의 일종인 restricted Boltzmann machine (RBM)을 층층이 쌓아 학습하는 deep learning 기법의 일종이다. DBN을 적용하기 위해서는 각 층을 구성하는 RBM에 대해 먼저 살펴 봐야한다. RBM은 볼츠만 머신의 특수한 경우로, 그림 1에서 볼 수 있는 것처럼, 일반적인 볼츠만 머신과 달리 visible unit layer와 hidden unit layer 각각의 내부에는 연결강도가 0인 제한이 있는 것을 말한다 [9]. 홉필드 네트워크를 기반으로 한 볼츠만 머신과 RBM은 에너지 함수에서 홉필드 네트워크와 유사성을 보이는데, visible unit과 hidden unit이 따로 존재하고, 확률적으로 unit의 값을 얻을 수 있으며 이때의 확률이 볼츠만 분포처럼 에너지를 통해 결정 된다는 점에서 차이를 지니고 있다. 볼츠만 머신 및 RBM의 에너지 함수는 식 (5)로 쓸 수 있다.

$$E(V, H) = - \sum_{i,j} w_{ij} v_i h_j - \sum_{i \in V} a_i v_i - \sum_{j \in H} b_j h_j \quad (5)$$

여기서  $v_i$ 와  $h_j$ 는 각각  $i$ 번째 visible unit과  $j$ 번째 hidden




그림 1. RBM의 hidden layer와 visible layer.

Fig. 1. Hidden layer and visible layer of RBM.

unit의 binary 값을 나타내고,  $a_i$ 와  $b_j$ 는  $i$ 번째 visible unit과  $j$ 번째 hidden unit의 bias를 나타낸다. 볼츠만 머신에서 연결강도 행렬  $W$ 는 대각 성분이 0인 대칭행렬이기 때문에 bias가 없는 볼츠만 머신 및 RBM의 에너지 함수는 다음 식 (6)처럼 간단히 나타낼 수 있다.

$$E(V, H) = -\frac{1}{2} \sum_{i,j} w_{ij} v_i h_j = -\frac{1}{2} V^T W H \quad (6)$$

이때, 네트워크의  $V$ 와  $H$ 벡터는 식 (7)의 확률을 따른다.

$$p(V, H) = \frac{1}{Z} e^{-E(V, H)} \quad (7)$$

여기서  $Z$ 는 partition function이라 하여,  $V$ 와  $H$ 벡터가 가질 수 있는 모든 경우에 대하여 값을 더한 것으로,  $Z$ 로 나누어 주는 것으로  $p$ 는 0과 1사이의 확률 값을 만족한다.

$$Z = \sum_{V, H} e^{-E(V, H)} \quad (8)$$

확률  $p(V, H)$ 를  $H$ 에 대해 전부 더하여 marginal probability를 구하면 visible 벡터  $V$ 의 확률을 구할 수 있다.

$$p(v) = \frac{1}{Z} \sum_h e^{-E(V, H)} \quad (9)$$

연결강도의 업데이트는 연결강도의 변화에 따른 log-likelihood의 변화를 이용하는  $k$ -step contrastive divergence (CD- $k$ )를 이용하여 업데이트 한다[8].

$$\frac{\partial \ln P(V)}{\partial w_{ij}} = -\frac{\partial E(V)}{\partial w_{ij}} - \frac{\partial \ln Z}{\partial w_{ij}} = \langle v_i h_j \rangle_{data} - \langle v_i h_j \rangle_{model} \quad (10)$$

여기서  $\langle v_i h_j \rangle_{data}$ 는  $i$ 번째 visible unit과  $j$ 번째 hidden 유닛에 대한 주어진 입력 패턴들의 평균값이고,  $\langle v_i h_j \rangle_{model}$ 은 네트워크의 평균값을 나타낸다. 따라서 연결강도는 식 (11)에 따라 업데이트 된다.

$$w_{ij} \leftarrow w_{ij} + \eta (\langle v_i h_j \rangle_{data} - \langle v_i h_j \rangle_{model}) \quad (11)$$

여기서  $\eta$ 는 네트워크의 학습 계수를 나타낸다.

RBM은 유닛 사이의 연결이 hidden-visible unit 사이에만 존재하기 때문에, 주어진 hidden vector  $H$ 에 대하여 visible vector  $V$ 가 나올 확률  $p(V|H)$ 는 식 (12)과 같이  $H$ 에 대한 모든  $v_i$ 의 확률들의 곱셈으로 표현되어 진다.

$$p(V|H) = \prod_i p(v_i|H) \quad (12)$$

여기서 주어진  $H$ 에 대한  $i$ 번째 visible unit이 1이 되는 확률은 식 (13)와 같다.

$$p(v_i = 1|H) = \sigma(a_i + \sum_j h_j w_{ij}) \quad (13)$$

여기서  $\sigma$ 는 activation function이고, 일반적으로 sigmoid 함수를 사용한다. DBN은 그림 2에서 볼 수 있는 것처럼 RBM 구조들이 차례대로 연결된 것으로, 앞 단의 hidden unit layer가 뒷단의 visible unit layer 역할을 하는 구조를 의

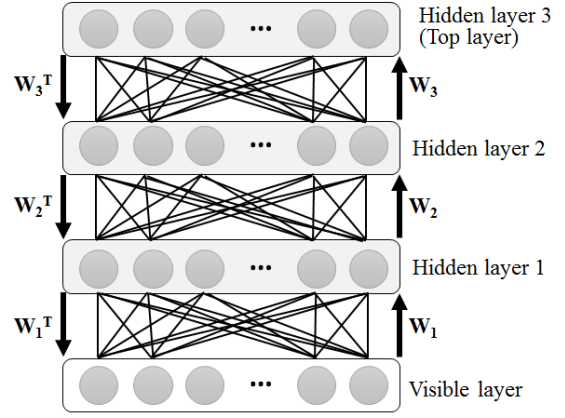


그림 2. Deep belief network의 구조.

Fig. 2. Structure of deep belief network.

미한다[10]. 그림 2를 통해 DBN의 학습 방식을 설명하면, 먼저 visible layer와 hidden layer1을 하나의 RBM으로 생각하고 RBM을 학습시키고, 학습이 종료되면 hidden layer 1의 값을 새로운 입력으로 하여 hidden layer 1과 2를 RBM으로 학습한다. 이렇게 단계적으로 올라가면서 마지막 층까지 학습을 시키는 것을 통해 결과를 얻을 수 있다. DBN을 이용한 분류 기법에는 back propagation DBN (BP-DBN)과 associate memory DBN이 있는데, 전자의 경우 DBN의 최상단에 출력단을 덧붙여 BP-ANN처럼 작동시키는 것으로, 임의로 선택된 연결강도를 사용하는 전통적인 ANN보다 더 나은 결과를 보여주고, 후자의 연상 기억을 이용하는 방법은 최상단에 label layer를 사용해 학습을 시키는 방법이다 [11]. 본 논문에서는 BP-DBN을 이용하여 분류를 수행하였고[12], 앞서 설명한 BP-ANN과 결과 비교를 통하여 기존 방법에 비해 BP-DBN이 갖는 장점에 대해 알아보았다.

### III. 실험 방법

#### 1. 실험 환경 및 자극

본 논문에서 제안한 방법을 적용하기 위해 실험을 통하여 뇌파의 데이터를 습득하였다. 실험 과정 및 방법은 다음과 같다. 실험에 참가한 피험자는 만 25세에서 27세 사이의 건강한 남성 3명에 대해 실험을 수행하였고, 모든 피험자는 이전에 운동 영역 상상에 관한 뇌파 실험에 참여한 경험이 있다. 피험자들은 모두 오른손잡이이며, 피험자 중 한 명의 모국어는 중국어이고, 나머지 피험자들은 한국어이다. 실험이 진행되는 동안, 피험자들은 움직임을 최소화하여 편안한 자세로 의자에 앉아 60 Hz로 주사되는 LCD 모니터를 바라보았다. 실험에 사용된 장비는 상용 장비로 판매되는 Neuroscan사의 Synamps2를 사용하였고, international 10-20 system을 따르는 64 채널 EEG 캡을 이용하여 뇌파를 습득하였다. 뇌파는 EEG 캡에서 측정할 수 있는 64 채널 전 지역에서 측정해, 그림 3에 나타난 위치에 존재하는 전극의 값만을 상용 소프트웨어 Curry7을 이용해 추출, 분석에 사용하였다. 눈의 깜빡임 및 근육의 움직임에서 발생할 수 있는 노이즈는 추가적인 전극을 이용하여 제거하였다. 실험동안 피험자에게는 피드백이 주어지지 않으며, 실험이 모두

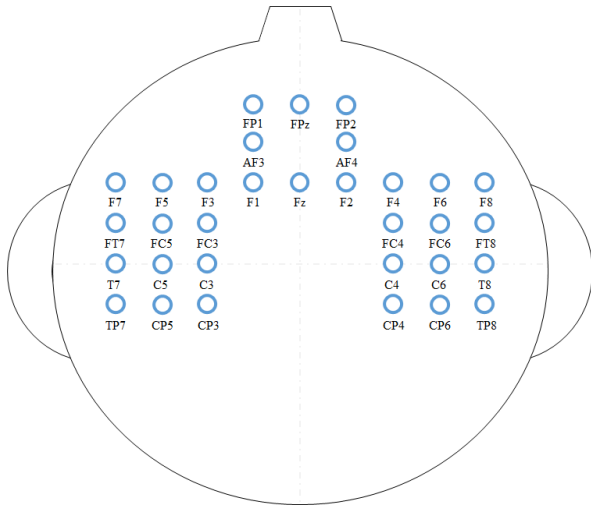


그림 3. 전극의 위치 및 명칭.

Fig. 3. The location and name of electrode.

끝난 후, 오프라인으로 EEG 데이터를 분석하는 과정을 거쳤다. 실험에 사용된 sampling rate는 250 Hz였고, 자극 제시 후 1초간의 데이터를 사용하였다.

실험에 사용된 자극은 IPA에서 제시한 /a/, /i/, /o/, /u/ 네 가지 모음이며, 이를 선택한 것은 발음 구조상 가장 멀리 떨어져 있는 네 모음을 선택해 시스템 구성시 명확하게 구분할 수 있기 위함이다. 실험 자극은 그림 4(b)에서 나타난 대로 구성하였는데, 처음 1초간은 소리와 함께 화면에 얻고자 하는 모음에 대한 기호가 노란색 글씨로 나오고, 1초간의 검은 화면이 지나가면 2초 동안 소리를 제시하지 않고 노란색 글자만으로 사용자에게 자극을 주어 2초 동안 모음을 상상하도록 한다. 그 후 다시 1초 동안 검은 화면이 나가게 하여 총 5초를 한 epoch으로 구성하였다. 1번 실험 할 때마다, 4개의 모음이 임의의 순서대로 각각 9번씩 제시된다. 이러한 실험을 5번 수행하여 각 개인당 모음별로 45개의 데이터를 얻었고 피험자 세 명에 대해서 135개의 데이터를 얻었다. 따라서 모든 데이터의 개수는 540개이다.

2. 분석 알고리즘

실험 후의 분석과정에서 Mathworks사의 Matlab을 사용하였으며, 분석은 5-fold cross validation을 통하여 80%의 데이터는 학습을 위해 사용하고 20%의 데이터는 테스트를 위해 사용되었다. 학습 및 테스트의 데이터 선택은 각각의 모음별로 골고루 선택되었으며, 선택 순서는 임의로 정하였다. 알고리즘을 통한 분석은 10회 반복해, 지역 해에 조기 수렴하는 과정에서 발생할 수 있는 오차를 줄였다. 특징 추출 과정을 거친 뇌파 데이터는 0과 1사이의 값으로 normalize하여 ANN 및 DBN에 사용할 수 있도록 하였다. DBN은 input layer부터 output layer까지 32-100-1000-100-4개의 node들로 이루어진 5층 구성의 DBN을 사용하였고, 같은 수의 노드를 사용하도록 조건을 맞추기 위해 BP-ANN 역시 32-1200-4 크기의 구조를 사용하였다. BP-ANN이 충분히 학습하고 최적 값에 수렴할 수 있도록 학습 회수는 15000회로 지정하였으며, 27회마다 평균적인 gradient를 취하는 batch 방식의 업데이트를 하였다. 반면 DBN의 RBM은 1회

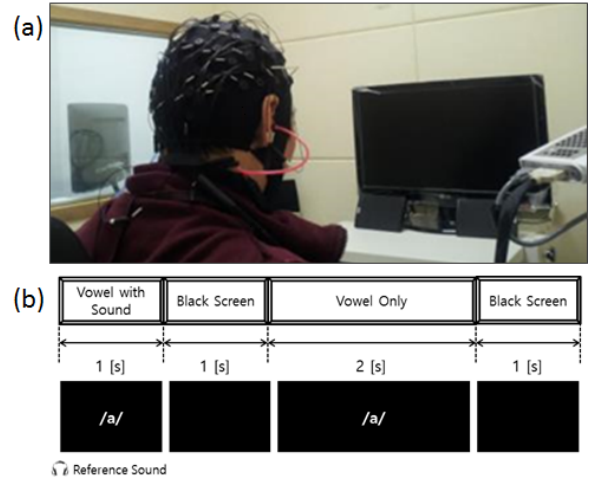


그림 4. (a) 실험 환경, (b) 실험 자극 예시.

Fig. 4. (a)Experimental environment, (b) Example of stimulus.

의 학습 과정을 거치도록 하였고, weight 업데이트시, momentum 방법을 사용해, 기존 값을 보존하는 계수를 0.2, 학습 계수를 0.8로 하여 RBM을 학습하였다. 이후 BP-DBN으로 구조를 변환하여, 1500회 학습하도록 했으며, 역시 27회마다 batch 업데이트를 하도록 하였다. 모든 경우에서 activation function은 sigmoid 함수를 사용하였다.

IV. 실험 결과

실험의 결과는 그림 5 및 표 1을 통해 나타내었다. 그림 5는 실험을 10회 반복했을 때, 각 회차별 분류 성공률의 값 변화 경향을 그래프로 나타낸 것이다. BP-ANN의 경우 1회 차에 다른 회차보다 값이 두드러지게 낮은 값을 갖고있다. 2에서 9회차까지의 결과가 일정한 값으로 수렴한 것으로 보아, 1회차에서 값이 지역해에 빠진 것을 알 수 있다. BP-ANN은 업데이트가 수학적으로 이루어지기 때문에 수렴 결과는 초기값에 의해 영향을 받는다. 대체적으로 잘 수렴하나, 낮은 확률로 지역해에 빠질 수 있음을 알 수 있다.




그림 5. BP-ANN과 BP-DBN의 결과 경향.

Fig. 5. Classification tendency of comparison BP-ANN to BP-DBN.

표 1. 분류 결과값 및 평균.

Table 1. Classification result and mean.

회차	BP-ANN	BP-DBN	비고
1	0.2741	0.8981	제외
2	0.5204	0.8796	제외
3	0.5204	0.8796	
4	0.5204	0.8796	
5	0.5204	0.8796	
6	0.5204	0.8796	
7	0.5204	0.8796	
8	0.5204	0.8796	
9	0.5204	0.8796	
10	0.5204	0.8796	
평균	0.5204	0.8796	

또한, 1회차에서 근소하게 값이 높게 나온 BP-DBN 역시 다른 결과와 달리 전역해에 더 가깝게 수렴하였음을 알 수 있다. 결과적으로, 값이 수렴하는데 있어 두 방식 모두 지역해에 빠지는 문제점을 안고 있으나, BP-ANN의 수렴시 정확도와 지역해에서의 정확도 차이가 BP-DBN에서의 차이보다 훨씬 작은 것을 볼 수 있어, 지역해에 빠짐으로 발생하는 문제점이 훨씬 줄어든 것을 볼 수 있다.

표 1의 분류 결과를 살펴보면, 같은 입력 및 역전파 알고리즘을 사용할 경우, 주어진 실험 조건하에서, 평균적으로 BP-DBN이 35% 이상 더 우수한 분류 결과를 보여주고 있다. 여기서 구한 평균은 가장 큰 값과 가장 작은 값을 제외한 나머지 8개의 값을 이용하여 구한 결과이다. 4개의 클래스를 구분하므로, 분류율 25%가 분류기가 올바르게 동작하는지 결정하는 경계가 되는데, 두 알고리즘 모두 52%, 87%의 결과로 이를 만족하고 있다. 그러나 BP-DBN이 4개의 클래스에 대해 약 88%의 분류율을 보이므로, 일반적인 ANN보다 훨씬 효율적으로 사용될 수 있다. 이는 BP-DBN이 기존의 ANN보다 초기 값 선정이 우수하기 때문이다.

학습 조건에 있어서도, BP-DBN이 BP-ANN보다 더 적은 학습 회수를 갖고 있으면서도 더 높은 분류 성공 결과를 보이고 있으며, 계산에 들어가는 시간 역시 월등히 절약할 수 있음을 알 수 있다. 같은 성공률이라면, 훨씬 빠른 속도로 계산을 수행할 수 있고, 같은 속도라면 더 높은 분류 성공률을 보일 수 있다는 것이다. 대략적인 시간 비교를 위해 1회 학습할 때 걸리는 시간을 25회 반복하여 구하여 평균을 내었다. 이 때, DBN은 RBM 구조들의 연결강도를 구하고 BP를 1회 수행하도록 하였다. 이때 걸린 시간은 ANN이 평균 0.0500초, DBN은 평균 0.0956으로 구조 자체를 학습하는 시간은 DBN이 2배 정도 더 많이 걸리는 것을 볼 수 있다. 그러나 학습하는 횟수가 10배 정도 더 많아야 수렴하게 되므로, 결과적으로는 ANN이 더 많은 시간이 걸린다는 것을 알 수 있다. 또한 노드의 숫자가 1000개가 되는 층을 갖고 있음에도 좋은 결과를 보이고 있다. 고차원의 데이터를 다루기에 유리하다고 볼 수 있는데, 기존에 딥러닝 알고리즘이 활발히 적용된 분야가 많은 데이터를 처리해야 하는 영상처리분야나 음성 언어 인식 분야인 것을 고려할 때 [13,14], 많은 채널을 다뤄야 하는 BCI의 많은 차원 데이터에도 역시 적용이 수월하다고 생각할 수 있다. 특히 높은




그림 6. 한 folding group 1회 학습에 걸리는 시간.

Fig. 6. One learning time delay of one folding group.

시간해상도를 갖고 있는 EEG 데이터에 대해서도 적절한 특징 추출 과정을 거친다면 유용하게 사용할 수 있다.

### V. 결론

본 논문에서 우리는 음성 언어 상상시 발생하는 뇌파를 딥러닝 기법 중 하나인 DBN을 이용하여 분류하는 방법에 대해 살펴보았다. 기존 음성 언어 상상시 발생할 수 있는 문제점을 극복하기 위해 IPA를 사용하였으나, BCI영역에서 분류목적으로 많이 사용하였던 SVM과 같은 방식은 멀티클래스에 대응하기가 어려웠다. 그러나 본 논문에서 살펴본 것과 같이 ANN 기반의 알고리즘을 이용하여 멀티 클래스에 적용해 음성 언어 상상을 구분 할 수 있음을 확인하였다. 특히 일반적인 ANN이 초기값에 따라 지역해에 빠져 좋은 분류 결과를 얻는데 어려움이 있었으나, ANN에 비해 개선된 DBN과 같은 딥러닝 기법들을 사용할 때, 일반적인 ANN에 비해 평균적으로 35% 이상의 좋은 분류 결과를 얻을 수 있었다. 이러한 연구 결과는 비단 언어 인식 시스템에만 국한 될 것이 아니라, 다양한 클래스 분석을 필요로 하는 뇌파 분석에 있어 여러 방면으로 접목될 수 있을 것이다. 예를 들어 DBN과 같은 기법에 기반을 둔 방식의 BCI시스템으로 로봇을 컨트롤 한다면, 사용자가 원하는 동작을 더 자연스럽게 정확하게 수행 할 수 있을 것이다.

추후 연구에서는 더 많은 클래스의 언어들을 분석하고 그에 적합하게 설계, 개선된 딥러닝 알고리즘을 이용해 언어 음성 상상시 발생하는 뇌파 분석의 정확도를 개선할 수 있는 연구를 진행하고자 한다.

### REFERENCES

- [1] D. Marshall, D. Coyle, S. Wilson, and M. Callaghan, "Games, Gameplay, and BCI: The state of the art," *IEEE trans. on computational intelligence ans AI in games*, vol. 5, no. 2, pp. 82-99, Jun. 2013.
- [2] Y. Chae, J. Jeong, and S. Jo, "Toward brain-actuated humanoid robots: asynchronous direct control using an EEG-based BCI," *IEEE Trans. on Robotics*, vol. 28, no.

- 5, pp. 1131-1144, Oct. 2012.
- [3] A. Frisoli, C. Loconsole, F. Banno, M. Barsotti, C. Chisari, and M. Bergamasco, "A new gaze-BCI-driven control of an upper limb exoskeleton for rehabilitation in real-world tasks," *IEEE Trans. on Systems, Man, and Cybernetics- Part C: Applications and Reviews*, vol. 42, no. 6, pp. 1169-1179, Nov. 2012.
- [4] D.-E. Kim, S.-M. Park, and K.-B. Sim, "Study on the correlation between grip strength and EEG," *Journal of Institute of Control, Robotics and Systems*, vol. 19, no. 9, pp. 853-859, 2013.
- [5] Y.-H. Kim, K.-E. Ko, S.-M. Park, and K.-B. Sim, "Practical use technology for robot control in BCI environment based on motor imagery-P300," *Journal of Institute of Control, Robotics and Systems*, vol. 19, no. 3, pp. 227-232, 2013.
- [6] R. Bogue "Brain-computer interfaces: control by thought," *Industrial Robot: An International Journal*, vol. 37, no. 2, pp. 126-132, 2010.
- [7] T. J. Lee and K. B. Sim, "EEG based vowel feature extraction for speech recognition system using international phonetic alphabet," *Journal of Korean Institute of Intelligent Systems*, vol. 24, no. 1, pp. 90-95, Feb. 2014.
- [8] J. A. Freeman and D. M. Skapura, *Neural Networks Algorithms, Applications, and Programming Techniques*, Addison-Wesley, Massachusetts, 1991.
- [9] G. Hinton, *A practical Guide to Training Restricted Boltzmann Machines*, Version 1, Toronto, 2010.
- [10] G. Hinton and R. R. Salakhutdinov, "Reducing the dimensionality of data with neural networks," *Science*, vol. 313, no. 5786, pp. 504-507, Jul. 2006.
- [11] M. A. Salama, A. E. Hassanien, and A. A. Fahmy, "Deep belief network for clustering and classification of a continuous data," *Signal Processing and Information Technology (ISSPIT)*, Luxor, Egypt, pp. 473-477, Dec. 2010.
- [12] R. B. Palm, *Prediction as a Candidate for Learning Deep Hierarchical Models of Data*, Technical University of Denmark, Lyngby, Denmark, 2012.
- [13] H. Lee, P. Pham, Y. Largman, and A. Y. Ng, "Unsupervised feature learning for audio classification using convolution deep belief networks," *Advances in Neural Information Processing Systems 22 (NIPS 2009)*, Vancouver, Canada pp. 1-9, Dec. 2010.
- [14] G. E. Hinton, "To recognize shapes, first learn to generate images," *Computational Neuroscience: Theoretical Insights into Brain Function*, vol. 165, pp. 535-547, 2007.



### 이 태 주

2013년 중앙대학교 전자전기공학부(공학사). 2013년~현재 중앙대학교 대학원 전자전기공학부 석사 과정. 관심분야는 Brain-computer Interface, Neuro-Robotics, Machine Learning 등.



### 심 귀 보

1984년 중앙대학교 전자공학과(공학사). 1986년 중앙대학교 전자공학과(공학석사). 1990년 The University of Tokyo 전자공학과(공학박사). 1991년~현재 중앙대학교 전자전기공학부 교수. 2002년~현재 중앙대학교 중소기업산학협력센터 센터장. 2006년~2007년 한국지능시스템학회 회장. 2007년~현재 (사)한국산학연합회 서울지역협회 회장. 2009년~2010년 중앙대학교 중앙도서관장 및 박물관장. 2011년~현재 중앙대학교 스마트지능로봇연구센터 센터장. 관심분야는 인공지능, 뇌-컴퓨터 인터페이스, 의도 인식, 감성 인식, 유비쿼터스 지능형로봇, 지능시스템, 컴퓨테이션 인텔리전스, 지능형 홈 및 홈 네트워크, 유비쿼터스 컴퓨팅 및 센서 네트워크, 소프트 컴퓨팅(신경망, 퍼지, 진화연산), 다개체 및 자율분산로봇시스템, 인공 면역시스템, 지능형 감시시스템 등. ICROS Fellow.