

# 비선형 반복 패턴과 스펙트럼 분석을 이용한 집중-비집중 분류기의 성능 평가

Performance Evaluation of Attention-inattention Classifiers using Non-linear Recurrence  
Pattern and Spectrum Analysis

이지은\* · 유선국\*\*† · 이병채\*\*\*  
Jee-Eun Lee\* · Sun-Kook Yoo\*\*† · Byung-Chae Lee\*\*\*

\*연세대학교 생체공학협동과정  
\*Graduate School of Biomedical Engineering, Yonsei University

\*\*연세대학교 의과대학 의학공학교실  
\*\*Department of Medical Engineering, Yonsei University College of Medicine

\*\*\*용인송담대학교 의료정보과  
\*\*\*Department of Medical Information System, Yongin Songdam College

## Abstract

Attention is one of important cognitive functions in human affecting on the selectional concentration of relevant events and ignorance of irrelevant events. The discrimination of attentional and inattentional status is the first step to manage human's attentional capability using computer assisted device. In this paper, we newly combine the non-linear recurrence pattern analysis and spectrum analysis to effectively extract features(total number of 13) from the electroencephalographic signal used in the input to classifiers. The performance of diverse types of attention-inattention classifiers, including supporting vector machine, back-propagation algorithm, linear discrimination, gradient decent, and logistic regression classifiers were evaluated. Among them, the support vector machine classifier shows the best performance with the classification accuracy of 81 %. The use of spectral band feature set alone(accuracy of 76 %) shows better performance than that of non-linear recurrence pattern feature set alone(accuracy of 67 %). The support vector machine classifier with hybrid combination of non-linear and spectral analysis can be used in later designing attention-related devices.

**Key words** : attention, classifier, non-linear analysis, spectrum analysis

---

- 본 연구는 2012년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행되었음(No.2010-0026833).

† 교신저자 : 유선국 (연세대학교 의과대학 의학공학교실)

E-mail : sunkyoo@yuhs.ac

TEL : 02-2228-1919

FAX : 02-363-9923

## 요약

집중은 관련된 사건을 선택적으로 주의하고, 관련 없는 사건을 무시하는 인간의 중요한 인지 기능중의 하나이다. 인간의 집중 능력을 관리 이용하는 컴퓨터 기반 장치에 있어서 집중과 비집중 상태를 구분하는 것은 필수적으로 요구되는 조건이다. 본 논문에서는, 뇌파신호로부터 분류기의 입력으로 사용되는 특징을 효율적으로 추출하기 위하여 비선형 반복 패턴 분석기법과 스펙트럼 분석 기법을 새로이 결합하였고(13개 특징 추출), 서포트벡터머신, 역전파 알고리즘, 선형분리, 로지스틱 회귀 분류 기반 분류기들을 포함하는 집중-비집중 분류기들의 성능을 분석하였다. 그중에서 81 %의 정확도를 보이는 서포트벡터머신 분류기가 가장 좋은 성능을 보였다. 또한 스펙트럼 분석으로 추출한 특징만을 사용하였을 경우(76 % 정확도)가 비선형 분석 방법으로 추출한 특징만을 사용했을 경우(67 % 정확도)보다 좀 더 우수한 성능을 보였다. 비선형-스펙트럼 분석법을 복합 적용한 서포트벡터머신 분류기가 추후 집중 관련 장비 설계에 있어서 효율적으로 적용될 수 있을 것이다.

**주제어 :** 집중, 분류기, 비선형분석, 스펙트럼분석

## 1. 서론

집중력은 어떠한 선택적인 것에 모든 주의를 주는 인지과정으로서 뇌에서 일어나는 처리능력에 따라 나타나는 영역 중 하나이다(Anderson & John R. 2004). 집중력을 유발시키기 위한 뉴런의 변화에 따라 다른 여러 영역에도 영향을 미치기 때문에 이를 연구함으로써 뇌 손상뿐만 아니라 몸의 이상여부까지 판단을 가능하게 해준다(Chavajay, P., & Rogoff, B. 1999).

집중유발은 시각자극과 청각자극으로부터 실험이 가능하다. 이 중 시각자극은 2단계의 과정을 거치는데 먼저 외부로부터 오는 영상자극으로부터 정보를 받아들이는 것이고, 다음으로 이 시각적 영상에 얼마나 집중을 했는지 보는 것이다(Jonides, J. 1980).

집중력은 자극으로부터 변화하는 뇌신경을 분석함으로써 추측할 수 있다. 뇌는 뉴런 간의 동시적이고 반복적인 동작을 통해 뇌파신호를 만들며 우리는 만들어진 뇌파신호를 분석함으로써 뇌에서 일어나는 활동을 추측할 수 있다(Stam, C. J. 2005). 그러나 뇌파신호는 잡음이나 주의 환경에 민감할 뿐만 아니라 집중 시 뇌파신호의 전압은 매우 작고 무작위로 변하기 때문에 해석이 어렵다. 따라서 뇌파를 시간에 따라 선형적으로 분석하기에 어려움이 따르기 때문에 뇌파신호의 분석을 위하여 고속 푸리에 변환(FFT; Fast Fourier transform)을 이용하여 주파수파워를 구하는 방법을 주로 이용한다. 뇌는 활성화되는 상태에 따라 다양한 주파수파워를 보여준다. 특히 집중 시에는  $\theta$ 파의 주파수파워가 많이 나오는 것을 확인할 수 있다(Murugappan, M., Ramachandran, N., & Sazali, Y.

2010).

뇌파신호를 분석하는 다른 방법으로는 비선형 방법인 카오스방법이 있다. 카오스방법은 선형적으로 무작위로 변화하는 신호가 보이지는 않지만 규칙이 있음을 가정하고 해석하는 방법이다. 카오스방법은 데이터를 벡터로 표현하는 것을 기초로 두며 상관차원, Lyapunov 지수와 같은 여러 가지 방법이 있다. 그러나 이 방법들은 순간적인 짧은 신호를 해석하는데 어려움을 가진다(Faure, P., & Korn, H. 2001). 따라서 본 논문에서는 순간적인 신호에도 유효한 분석을 가능하게 하는 정량적 반복 형태 분석(RQA; Recurrence quantification analysis) 방식을 사용하여 뇌파신호를 분석하였다. 이는 반복되는 신호의 형태를 분석할 수 있으므로 자극에 따라 뇌에서 유발되는 유발전위(EP; Evoked potential)의 분석 및 실시간분석을 가능하게 해준다(Webber Jr, C. L., & Zbilut, J. P. 2005).

실시간분석을 위해서는 뇌파신호로부터 분석된 특징들을 빠르고 정확하게 분류하는 것도 중요하다. 생체신호는 개인마다 다른 특성을 가지고 있기 때문에 분류기의 정확도를 높이는 것만큼 분류기를 일반화시키는 것 역시 중요한 이슈이다. 본 연구와 같이 집중, 비집중과 같은 이분법적 분류에서는 빠르고 간편한 분류기의 사용 가능성은 분류기의 선택에 중요한 변수이다. 따라서 다양한 분류기를 설계하고 비교하므로 성능이 높은 분류기를 설계하는 것은 실시간분석을 하는데 큰 역할을 할 것이다.

집중력은 학습능력에도 많은 영향을 끼칠 뿐만 아니라 더 나아가 자동차 운전과 같은 일상생활에도 영향을 주어 안전사고를 유발시킬 가능성을 가진다. 특

히 주의력결핍 과다행동장애(ADHD; Attention deficit hyperactivity disorder)와 같은 질병은 집중력과 크게 상관관계를 가지며, 조기의 발견이 되면 병의 지속성을 막을 수 있다. 따라서 뇌파신호로부터의 집중력관별을 위하여 많은 연구들이 진행되고 있으며 기술이 발전함으로부터 질병 및 사고예방을 할 수 있을 것으로 사료되어진다(National Institute of Neurological Disorders and Stroke, 2012).

이에 따라 본 논문에서는 피험자에게 시각자극을 이용하여 주의집중에 관한 인지과정을 거치게 하고 그때의 뇌파신호를 획득하였으며, 획득된 뇌파신호로부터 얻은 비선형특징과 주파수특징을 이용하여 집중과 비집중을 판별하는 분류기를 설계하고자 하였다.

## 2. 실험 및 방법

### 2.1. 실험 및 데이터추출

#### 2.1.1. 실험

본 실험은 주의집중에 대한 데이터 신호 추출을 위하여 설계되었다. 실험은 주의반응과 운동반응으로 구성되어 있었으며, 시각자극을 이용하여 주의반응을 유발하였으며 자극에 따라 버튼을 누르는 운동반응을 하도록 하였다.

실험은 숫자자극에 대하여 버튼을 누르는 주의집중 상태와 단순한 자극(‘+’)을 시각자극으로 주고 아무런 반응을 하지 않는 비집중 상태로 구성하여 집중상태와 이완상태를 반복하도록 하였다. 실험은 약 7분간 진행되어지며 각 자극은 1500ms동안 나타난다.

실험은 아무런 자극도 없는 상태로 10분간 휴식을 취한 후에 진행되었으며, 평균 연령 30세의 건강한 피험자 19명을 대상으로 실험을 진행하였다. 모든 피험자들은 실험 전 동의서를 작성하였다.

피험자의 생체신호는 BIOPAC MP 150TM에 의해 측정되었고, 측정신호는 저주파통과필터 0.1 Hz, 고주파통과필터 100Hz, 노치필터 60Hz를 이용하여 전원잡음을 제거하여 주었으며, 1kHz로 샘플링하여 주었다.

피험자들의 뇌파신호는 10-20 시스템은 기준으로 전두엽에 비하여 눈 깜박임의 영향을 덜 받는 두정엽에서 측정되었으며 귀를 기준전극으로 사용하였다.

Figure 1은 실험프로토콜을 나타낸 것이다. 단순한 자극(‘+’)가 1500ms 나온 후 숫자자극이 1500ms 나타난다. 총 3000ms의 자극이 연속적으로 나타나며, 단순한 자극(‘+’) 시에는 비집중 상태로 숫자자극 시에는 집중상태로 분류한다. 시각자극으로 숫자자극이 나올 때 1 1 2와 같이 나온다면, 피험자는 나머지 숫자와 다른 버튼 2를 누르는 운동반응을 보여야 한다. 이러한 방법으로 실험은 약 7분간 진행되었다.




Figure 1. Experiment Protocol

#### 2.1.2. 데이터 추출

데이터 추출은 시각자극의 시작시점을 기준으로 앞의 500ms, 뒤의 1000ms를 잘라 총 1500ms동안의 뇌파신호를 특징추출을 위한 구간으로 사용하였다. 따라서 맨 처음 시각자극은 앞의 500ms가 존재하지 않으므로 사용하지 않았다.

비선형 특징 추출을 위해 정량적 반복 형태 분석방식을 이용하여 카오스 분석을 하였다. 이는 분석 구간이 짧은 경우 시간에 따라 반복되는 형태를 분석하는 방법으로 짧은 구간의 신호분석에 유용하다(Webber Jr, C. L., & Zbilut, J. P. 2005; Eckmann, J. P., Kamphorst, S. O., & Ruelle, D. 1987).

비선형적으로 신호를 해석하기 위해서는 차원과 샘플 벡터 간격을 정해주어야 하며, 이를 위상공간에서 재구성하여야 한다. 반복 궤적은  $m$ -차원 위상공간의 궤적  $\vec{x}_i \in R^m (i = 1, 2, \dots, N)$ 의 리커런스를 2차원 공간에 표현한 것이다. 여기서  $\vec{x}_i \in (t_i, t_{i+\tau}, \dots, t_{i+(m-1)\tau})$ 는 1차원 시계열 데이터를  $m$ -차원 공간으로 Takens 재구성한 벡터이다. 반복행렬을 만들기 위해서는 위상공간을 구성하는  $N$ 개의 위상공간을 구성하는  $N$ 개의 벡터를  $N \times N$ 행렬로 나타낸다(Webber Jr, C. L., & Zbilut, J. P. 2005).

$$R_{i,j}(\epsilon) = \begin{cases} 1: \|\vec{x}_i - \vec{x}_j\| \leq \epsilon \\ 0: \text{위의 조건과 다른 경우} \end{cases} \quad \vec{x}_i \in R^m, i, j = 1, 2, \dots, N \quad (1)$$

여기서  $\epsilon$  는 문턱치 거리이며,  $\|\cdot\|$  는 유클리디안 또는 최대 놈(norm)이다.

만약 임베딩 된 벡터  $\vec{x}_i$ 와  $\vec{x}_j$ 의 거리가  $\epsilon$ 보다 작거나 같다면  $R_{i,j} = 1$ , 그렇지 않은 경우는 0으로 행렬을 구성한다. 반복 궤적에서는 일반적으로 1인 경우 검은 점(RP; Recurrence point)으로 이를 나타낸다. 동역학 특성의 변화에 따라 특정한 패턴을 보이며 서로 다른 궤적의 벡터변화에 따라 대각선, 수평선, 수직선의 구조변화도 나타난다. 이러한 방법의 정량화 분석을 RQA라고 한다(Webber Jr, C. L., & Zbilut, J. P. 2005).

즉, RQA 카오스 분석을 이용하여 추출된 특징들은 RP의 개수(NRP; Number of Recurrence Point), 반복 궤적에 나타나는 NRP의 비율(REC; Recurrence ratio), 대각선 구조를 형성하는 점들의 비율(DET; Determinism ratio), 수직선들(VLs; Vertical lines), 시스템 안정성 척도(TND; Trend), 대각선 길이의 분포에 대한 bits/bin으로 표준화 된 히스토그램에서 bin확률(ENT; Entropy), 수직선 구조를 형성하는 점들의 비율(LAM; Laminarity ratio), 수직선 구조의 길이(TT; Trapping time)로 총 8개이다(Webber Jr, C. L., & Zbilut, J. P. 2005).

뇌는 입력되는 자극에 따라 다른 주파수특징을 가지고, 이는 인지자극별로 뚜렷한 특징을 가진다. 따라서 주파수특징은 뇌기능 판별을 위한 분석요소로 사용되어진다(Murugappan, M., Ramachandran, N., & Sazali, Y. 2010). 따라서 본 연구에서는 스펙트럼 분석을 사용한 주파수 특징 추출을 위해 1Hz의 고주파통과필터로 전원잡음을 제거한 후, 1500ms 구간에 해밍 윈도우를 씌워 고속 푸리에 변환을 이용하여 두정엽 영역 뇌파신호의  $\delta, \theta, \alpha, \beta, \gamma$ 파의 주파수 파워를 추출하였다.

본 연구에서 추출된 특징은 비선형특징과 주파수 특징을 가지고 있으며 총 13개로 구성된다. 추출된 각 특징들(NRP, REC, DET, VLs, TND, ENT, LAM, TT,  $\delta, \theta, \alpha, \beta, \gamma$ 파의 주파수 파워)은 다양한 범위를 가지고 있으므로 아래 식 2와 같이 정규화 시켜 0~1사이의 범위를 가지도록 만들어 주었다. 정규화 된 특징 벡터들은 집중/비집중 판별을 위한 분류기의 입력벡터로 사용되었다.

$$N/D = \frac{O/D - \text{Min}(O/D.S)}{\text{Max}(O/D.S) - \text{Min}(O/D.S)} \quad (2)$$

*N/D*: Normalized Data

*O/D*: Original Data

*O/D.S*: Original Data set

데이터는 교사학습을 하기 위하여 집중을 했을 때와 안했을 때 총 2부류로 나누어 각각의 입력특징을 추출하였으며, 총 데이터의 50%를 분류기의 훈련을 위해 사용하였고, 나머지 50%는 분류기의 테스트를 위하여 사용하였다.

## 2.2. 분류기

### 2.2.1. 서포트벡터머신(SVM; Support vector machine)

SVM은 분류기의 데이터의 분류능력 뿐만 아니라 일반화 능력을 향상시켜준다는 장점을 가진다. 또한 커널함수를 사용하여 데이터의 고차원 매핑을 가능하게 하기 때문에 복잡한 데이터의 사용 시 분류를 용이하게 해준다(Osuna, E., Freund, R., & Girosi, F. 1997). 따라서 앞에서 추출된 특징벡터들을 SVM의 입력으로 사용하여 집중과 비집중 상태를 판별하고자 하였다.

### 2.2.2. 역전파 알고리즘(BP: Back-propagation algorithm)

역전파 알고리즘은 불충분한 입력데이터에 대해서도 분류를 가능하게 한다. 또한 데이터의 병렬처리 기능을 가지고 있어 복잡한 입력에도 충분한 분류기 훈련을 통하여 적절한 출력을 낼 수 있다. 이 중에서도 역전파 알고리즘을 이용하여 신경망 연결 층간의 가중치를 조정하였다(Bishop, C. M. 1995).

### 2.2.3. 선형분류기(LDA; Linear discriminant analysis)

선형분류기는 부류가 2개일 때 사용이 가능하다. 입력벡터와 부류를 통한 최소제곱에러 방식으로 가중치 계산이 간편하기 때문에 알고리즘이 빠르게 동작한다는 장점을 가지므로 본 연구의 목적인 집중, 비집

중 판별에 있어 유용하게 사용된다(Duda, R. O., Hart, P. E., & Stork, D. G. 2012).

### 2.2.4. 경사하강법(GDA; Gradient descent analysis)

경사하강법은 최적화 알고리즘으로 최적화 할 함수의 기울기를 구해가며 기울기가 낮은 쪽으로 이동시켜 가는 쪽으로 가중치를 변화시켜준다. 이 알고리즘은 모든 차원에서 적용이 가능하지만 많은 반복을 거치지 않으면 지역 최적해로 수렴할 가능성이 있다(Snyman, J. A. (2005).

### 2.2.5. 로지스틱회귀분석(LR; Logistic regression analysis)

로지스틱 회귀분석은 확률로 표현되며 입력특징 중 어느 특징이 집중을 판별하는데 의미가 있는지 추정하기가 쉽다(Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. 2013). 본 연구에서는 부류를 집중, 비집중 부류를 각각 1과 0의 값으로 놓았고, 0.5 이상은 1, 0.5 미만은 0의 값으로 부류를 설정하였다.

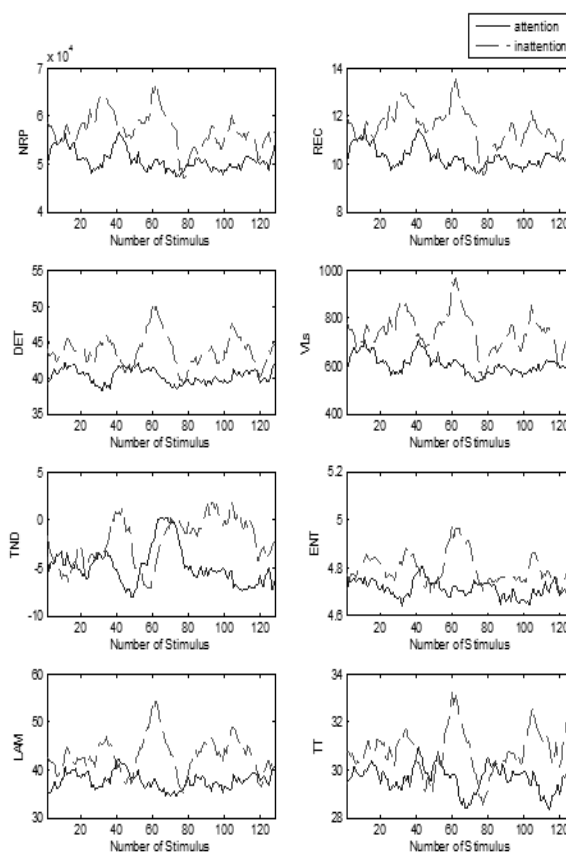


Figure 2. Extracted Non-linear Features

## 3. 결과 및 토의

### 3.1. 추출된 특징

본 연구에서 비선형 분석과 스펙트럼 분석을 통하여 추출된 RQA 특징과 주파수 특징은 각각 Figure 2와 Figure 3과 같다. 각각의 그래프는 특징의 차를 뚜렷하게 확인하기 위하여 15구간 씩 이동평균 시켜주어 그려주었다. 그래프의 가로축은 자극구간의 수를 나타내어 준다. Figure 2는 NRP, REC, DET, VLs, TND, ENT, LAM, TT의 특징 값들을 나타내며, Figure 3은  $\delta, \theta, \alpha, \beta, \gamma$ 의 주파수 파워를 나타낸다. Figure 2와 Figure 3에서 그래프의 가로축은 자극에 따른 샘플을 나타낸다. 파란 실선은 집중상태를 나타내고, 빨간 점선은 비집중 상태를 나타내며 각각의 그래프들은 집중과 비집중 상태에 따른 특징 값들의 경향을 보여준다. 따라서 그래프에서 볼 수 있듯이  $\alpha$ 의 주파수 파워를 제외하고는 집중과 비집중 상태 시 서로 다른 범위의 값들이 특징으로 추출되어짐을 알 수 있다.

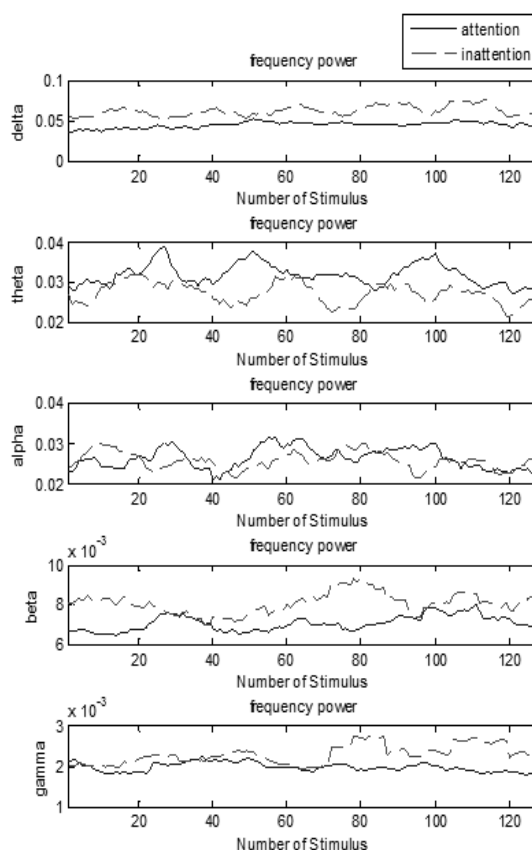


Figure 3. Extracted Spectrum Features

### 3.2. 분류기 평가

집중을 판별함에 있어 가장 좋은 성능을 내는 분류기를 선택하기 위하여 5가지 분류기(SVM, BP, LDA, GDA, LR)을 사용하여 정확도를 비교하였다. 분류기의 입력으로는 추출된 특징(NRP, REC, DET, VLs, TND, ENT, LAM, TT,  $\delta, \theta, \alpha, \beta, \gamma$ 파의 주파수 파워)을 모두 사용하였다. 데이터의 부류는 집중상태 시 1, 비집중 상태 시 0으로 주었다.

Table 1에서 TP(True positive)는 집중상태를 바르게 분류한 데이터의 개수, FN(False negative)는 비집중 상태를 틀리게 분류한 데이터의 개수, TN(Trun negative)은 비집중 상태를 바르게 분류한 데이터의 개수, FP(False positive)는 비집중 상태를 집중상태로 틀리게 분류한 데이터의 개수이다. 민감도(Sensitivity)는 집중상태를 집중으로 바르게 분류한 확률이고 특이성(Specificity)은 비집중 상태를 비집중 상태로 바르게 분류한 확률로 식 3과 식 4를 통하여 계산되었고, 정확도는 식 5를 통하여 계산되었다(Duda, R. O., Hart, P. E., & Stork, D. G. 2012).

$$Sensitibity(\%) = \frac{TP}{TP+FN} \times 100 \quad - (3)$$

$$Specificity(\%) = \frac{TN}{TN+FP} \times 100 \quad - (4)$$

$$Accuracy(\%) = \left( \frac{TP+TN}{TP+FN+FP+TN} \right) \times 100 \quad - (5)$$

Table 1의 All은 비선형특징과 주파수특징 모두를 입력으로 사용한 것이다. 이때의 결과를 보면 SVM의 정확도가 81.12%로 다른 분류기들에 비하여 가장 높은 정확도를 보인다. 또한 SVM을 사용하였을 때 민감도와 특이성이 모두 70%이상의 값을 가지므로 다른 분류기들보다 비교적 안정적으로 분류를 해주는 것을 확인할 수 있다. 역전파 알고리즘과 선형분류기는 70% 이상의 정확도를 보였으나 SVM과 비교하였을 때 약 8~9%의 정도의 차이가 나기 때문에 본 데이터를 사용하였을 때 좋은 분류기라고 정의할 수 없다. 그러나 특이성이 약 80%정도로 비집중 상태 시 판별력이 다른 분류기들보다 높은 값을 가지므로 ADHD 환자를 판별하는 데 응용할 수 있을 것으로 추측된다. 그에 비하여 GDA와 LR은 본 연구에서 낮은 정확도 및 낮은 민감도와 특이성을 가지는 것을 확인할 수 있다. 두 분류기 모두 10000번 이상의 충분한 반복을

거쳤음에도 다른 분류기들에 비하여 낮은 성능을 보이며 오랜 시간이 걸린다는 단점을 가지므로 실시간 사용을 위해서는 부적합함을 알 수 있다.

### 3.3. 특징벡터 평가

입력특징 별 분류기의 성능을 보기위하여 입력특징을 각각 비선형특징(NRP, REC, DET, VLs, TND, ENT, LAM, TT) 8개와 주파수특징( $\delta, \theta, \alpha, \beta, \gamma$ 파의 주파수 파워) 5개로 나누어 주었다. 나누어진 특징들을 각각 분류기의 입력으로 사용하여 Table 1을 도출하였다.

Table 1에서 볼 수 있듯이 모든 경우 뇌파신호의 주파수특징이 비선형성분보다 높은 정확도를 가지고 SVM이 가장 높은 정확도를 가짐을 확인할 수 있다. 그러나 비선형특징을 입력으로 넣었을 때 분류기 모두 70%이하의 정확도를 가지고, 특히 선형분류기를 사용하였을 때는 약 55%의 정확도를 가짐을 보인다.

Table 1. Compare of Classifiers based on Features

		SVM	BP	LDA	GDA	LR
TP	All	65	48	46	46	46
	Non-linear	62	57	39	54	58
	Spectrum	59	40	33	48	49
FN	All	7	24	26	26	26
	Non-linear	10	15	33	18	14
	Spectrum	13	32	39	24	23
TN	All	51	57	57	50	52
	Non-linear	34	36	39	41	31
	Spectrum	50	56	50	50	45
FP	All	20	14	14	21	19
	Non-linear	37	35	32	30	40
	Spectrum	21	15	21	21	26
Sensitivity (%)	All	90.28	66.67	63.89	63.89	63.89
	Non-linear	86.11	79.17	54.17	75	80.56
	Spectrum	81.94	55.56	45.83	66.67	68.06
Specificity (%)	All	71.83	80.28	80.28	70.42	73.24
	Non-linear	47.89	50.70	54.93	57.75	43.66
	Spectrum	70.42	78.87	70.42	70.42	63.38
Accuracy (%)	All	81.12	73.43	72.03	67.13	68.53
	Non-linear	67.13	65.03	54.55	66.43	62.24
	Spectrum	76.22	67.13	58.04	68.53	65.73

이를 통하여 비선형특징이 집중을 판별하는데 역할이 제한적임을 알 수 있다. 또한 주파수특징 역시 SVM을 사용하였을 때를 제외하고는 모두 70% 미만의 정확도를 보였다.

따라서 분류기의 성능을 75%이상으로 설정하고자 할 때는 뇌파의 주파수영역특징만을 사용하여 특징추출에 있어 계산효율을 낮추어 줄 수 있다. 또한 이때의 민감도와 특이성 모두 70%이상의 값을 가지므로 집중과 비집중 상태를 안정적으로 분류해주는 것을 알 수 있다.

비선형특징을 사용하였을 때 특이성이 대부분 50%에서 웃도는 것을 보이며 이는 분류기가 비집중 상태를 분류하는 성능이 좋지 않다는 것을 의미한다. 그러나 주파수특징을 입력으로 사용할 때는 SVM과 로지스틱 회귀분석을 제외하고는 특이성이 민감도보다 높음을 확인할 수 있다.

#### 4. 결론

본 논문은 집중, 비집중 상태를 판별해주는 분류기를 설계하는데 목적이 있으며, 이를 위하여 짧은 구간의 뇌파신호로부터 비선형, 주파수 특징을 추출하였다.

SVM을 사용하였을 때 집중, 비집중을 판별하는 정확도가 약 81%로 가장 높았으며, 비선형특징 및 주파수특징을 모두 사용하였을 때 집중상태 분별이 비선형특징만 사용하였을 때보다 약 14%, 주파수특징만 사용하였을 때보다 약 5% 높은 것을 확인할 수 있었다. 이 결과를 토대로 뇌파의 주파수영역특징을 입력으로 사용하는 SVM 알고리즘이 집중, 비집중 판별기로서 동작하는 가능성을 볼 수 있었다.

본 연구는 비선형분석을 통한 입력벡터 추출로 특징을 다양화시킴에 의의를 두며, 향후 추출된 입력벡터들 중 유효한 특징을 찾아 분류 성능을 향상시킬 수 있을 것으로 사료된다. 또한 단순한 판별기가 아닌 여러 판별기의 조합으로 집중판별의 정확도를 높이는 연구가 필요할 것으로 생각된다. 본 연구에서는 간단한 SVM 동작으로 집중상태의 빠른 판별을 가능하게 해주므로 진단 및 자동인식 기기 개발에 응용될 수 있을 것으로 사료된다.

#### REFERENCES

- Anderson, John R. (2004). *Cognitive psychology and its implications* (6th ed.), Worth Publishers, 519, ISBN 978-0-7167-0110-1.
- Bishop, C. M. (1995), *Neural networks for pattern recognition*, Oxford university press.
- Chavajay, P., & Rogoff, B. (1999). Cultural variation in management of attention by children and their caregivers, *Developmental Psychology*, 35(4), 1079.
- Duda, R. O., Hart, P. E., & Stork, D. G. (2012). *Pattern classification*, John Wiley & Sons.
- Eckmann, J. P., Kamphorst, S. O., & Ruelle, D. (1987). Recurrence plots of dynamical systems, *Europhys. Lett*, 4(9), 973-977.
- Faure, P., & Korn, H. (2001). Is there chaos in the brain? I. Concepts of nonlinear dynamics and methods of investigation, *Comptes Rendus de l'Académie des Sciences-Series III-Sciences de la Vie*, 324(9), 773-793.
- Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression*. Wiley. com.
- Jonides, J. (1980). Towards a model of the mind's eye's movement, *Canadian Journal of Psychology/Revue canadienne de psychologie*, 34(2), 103.
- Murugappan, M., Ramachandran, N., & Sazali, Y. (2010). Classification of human emotion from EEG using discrete wavelet transform, *Journal of Biomedical Science and Engineering*, 3(4), 390-396.
- National Institute of Neurological Disorders and Stroke (2012). Attention Deficit-Hyperactivity Disorder Information Page, *National Institute of Health*.
- Osuna, E., Freund, R., & Girosi, F. (1997). *Support vector machines: Training and applications*.
- Snyman, J. A. (2005). *Practical mathematical optimization: an introduction to basic optimization theory and classical and new gradient-based algorithms*, 97, Springer.
- Stam, C. J. (2005). Nonlinear dynamical analysis of EEG and MEG: review of an emerging field, *Clinical Neurophysiology*, 116(10), 2266-2301.
- Webber Jr, C. L., & Zbilut, J. P. (2005). Recurrence quantification analysis of nonlinear dynamical

systems, *Tutorials in contemporary nonlinear methods for the behavioral sciences*, 26-94.

원고접수: 2013.08.06

수정접수: 2013.09.17

게재확정: 2013.09.23