

점증적 증가를 이용한 침점 기반의 간질 검출

이상홍
안양대학교 컴퓨터공학과

Detection of Epileptic Seizure Based on Peak Using Sequential Increment Method

Sang-Hong Lee

Department of Computer Science & Engineering, Anyang University

요약 본 논문에서는 신호 처리 기술과 가중 퍼지소속함수 기반 신경망 (Neural Network with Weighted Fuzzy Membership Functions; NEWFM)을 이용하여 간질을 검출하는 방안을 제안하였다. 신호 처리 기술로는 웨이블릿 변환(Wavelet Transform), 점증적 증가 방법, 위상공간 재구성(Phase Space Reconstruction)을 이용하였다. 신호 처리 기술의 첫 번째 단계에서는 웨이블릿 변환을 이용하여 뇌파로부터 웨이블릿 계수를 추출하였다. 두 번째 단계에서는 점증적 증가 방법을 이용하여 웨이블릿 계수로부터 침점(Peak)을 추출하였다. 세 번째 단계에서는 위상공간 재구성을 이용하여 추출된 침점으로부터 3차원 다이어그램을 생성하였다. NEWFM의 입력으로 사용할 16개의 특징을 추출하기 위하여 유클리드 거리와 통계적 방법을 이용하였다. 이들 16개의 특징을 NEWFM의 입력으로 사용하여 97.5%, 100%, 95%의 정확도, 특이도, 민감도를 각각 구하였다.

주제어 : 간질, 퍼지신경망, 웨이블릿 변환, 위상공간 재구성

Abstract This study proposed signal processing techniques and neural network with weighted fuzzy membership functions(NEWFM) to detect epileptic seizure from EEG signals. This study used wavelet transform(WT), sequential increment method, and phase space reconstruction(PSR) as signal processing techniques. In the first step of signal processing techniques, wavelet coefficients were extracted from EEG signals using the WT. In the second step, sequential increment method was used to extract peaks from the wavelet coefficients. In the third step, 3D diagram was produced from the extracted peaks using the PSR. The Euclidean distances and statistical methods were used to extract 16 features used as inputs for NEWFM. The proposed methodology shows that accuracy, specificity, and sensitivity are 97.5%, 100%, 95% with 16 features, respectively.

Key Words : Epilepsy, Fuzzy Neural Networks, Wavelet Transforms, Phase Space Reconstruction

1. 서론

간질이란 고열 등의 특별한 유발 인자가 없이 장기간

반복적으로 발작을 하는 만성적인 질환이다[1]. 간질 발작 중 과도한 발작과가 뇌의 한 부분에서 국한적으로 발생할 때를 부분 간질, 뇌의 전체에서 발생할 때 전신 간

Received 20 August 2015, Revised 27 September 2015
Accepted 20 October 2015
Corresponding Author: Sang-Hong Lee (Anyang University)
Email: shleedosa@gmail.com, shleedosa@anyang.ac.kr

© The Society of Digital Policy & Management. All rights reserved. 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.

ISSN: 1738-1916

질이라 한다. 간질의 증상은 여러 가지로 표출될 수 있는데, 의식의 혼탁이 없이 간단한 자각 증상이나 국소적인 경련이 있을 때를 단순 부분 발작이라 한다[2]. 뇌에 발작 파가 동반되는 발작이 특별한 유발 요인 없이 장기간 반복적으로 발생할 때 간질로 진단한다.

간질을 검출하기 위하여 위상공간 재구성(phase space reconstruction) 기법이 뇌파를 시각적인 측면에서 분석하는 데 사용되었다[3,4]. 또한 푸리에 변환(Fourier transform)을 이용하여 뇌파를 주파수 영역으로 분해하였다[5]. 웨이블릿 변환(wavelet transform)은 뇌파를 시간-주파수 영역으로 분해하였다[6,7,8]. 리아프노프 지수와 상관 차원 등의 비선형 기법은 뇌파로부터 복잡성을 추출하는 데 사용되었다[9,10].

웨이블릿 변환에 의해 생성된 계수들이 mixture of expert[11]라는 분류기의 입력으로 사용되거나 적응 뉴로 퍼지 추론 시스템(adaptive neuro-fuzzy inference system, ANFIS)의 입력으로 사용되었다[12]. 엔트로피와 feed-forward neural network를 혼합한 모델도 개발되었다[13].

앞에서 설명한 간질 검출을 위한 모델들은 퍼지 규칙이나 간질 파형 분류에 대한 해석이 가능한 일반적인 규칙을 제공할 수 없다. 또한 본 논문에서 비교하고 있는 [11]은 웨이블릿 변환을 통하여 생성된 특징을 mixture of expert의 입력으로 사용하였지만 각각의 특징에 대한 해석을 제공하지 못하고 있다.

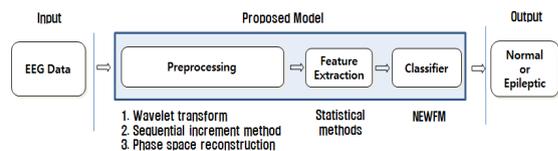
본 논문에서는 기존의 가중 퍼지소속함수 기반 신경망(Neural Network with Weighted Fuzzy Membership Functions; NEWFM)[4,14,15]과 신호 처리 기술을 이용하여 뇌파로부터 간질을 검출하는 방안을 제안하였다. 본 논문은 크게 두 개의 부분으로 구성되어 있는데 첫 번째 부분은 뇌파를 처리하는 신호처리 부분과 특징을 추출하는 부분이고 두 번째 부분은 간질을 검출하는 분류기로 사용하는 NEWFM에 대한 부분이다. 신호처리 부분에서는 뇌파가 웨이블릿 변환에 의하여 뇌파로부터 잡음 등을 제거한 웨이블릿 계수를 생성하였다. 이렇게 생성된 웨이블릿 계수로부터 점증적 증가를 이용하여 침점(Peak)을 추출하였다. 추출된 침점을 위상공간 재구성을 이용하여 3차원 다이어그램을 생성하였다. 마지막으로 원점과 3차원 좌표간의 유클리드 거리를 구하고 통계적 기법을 이용하여 NEWFM의 입력으로 사용할 특징을 추

출하였다. NEWFM에 대한 부분에서는 앞에서 추출된 특징을 NEWFM의 입력으로 사용하여 간질을 검출하였다.

본 논문은 다음과 같이 구성되었다. 2 장에서는 실험 데이터, 웨이블릿 변환, 점증적 증가를 이용한 침점 추출, 위상공간 재구성, 유클리드 거리와 통계적 방법에 의한 특징 추출을 설명한다. 또한 NEWFM에 대해서 설명한다. 3 장에서는 실험 결과로써 분류 성능에 대해서 설명한다. 마지막으로 4장에서는 결론으로 끝을 맺는다.

2. 간질 검출 모델의 개요

본 논문에서는 [Fig. 1]의 간질 검출 모델에서 알 수 있듯이 전처리 과정인 웨이블릿 변환, 점증적 증가를 이용한 침점 추출, 위상공간 재구성에 의해 변환된 뇌파를 통계적 방법인 주파수 분포와 주파수 변화량을 이용하여 특징을 추출하였다. 이렇게 추출한 특징을 NEWFM의 입력으로 사용하여 간질을 검출하였다. 웨이블릿 변환은 뇌파로부터 잡음을 제거하는 역할을 수행한다. 점증적 증가를 이용한 침점(Peak) 추출은 많은 침점들 중에서 비교적 상승폭이 큰 침점을 추출하는데 사용되어진다. 위상공간 재구성은 뇌파의 규칙성과 불규칙성을 3차원 다이어그램을 이용하여 시각적인 확인을 위해 사용되어진다.



[Fig. 1] Model of epilepsy detection

2.1 실험 데이터

본 논문에서는 Subasi[11]가 사용한 뇌파를 사용하여 정상 파형과 간질 파형을 분류하였다. Subasi가 사용한 실험데이터는 5개의 실험군(A, B, C, D, E)으로 나누어져 있다. 각각의 실험군은 100개의 단일채널 뇌파를 포함하고 있다. 본 논문에서는 Subasi[11]가 사용한 A와 E의 실험군을 사용하여 실험을 하였다. 실험군 A는 건강한 피실험자를 통하여 수집된 정상 파형이고 실험군 E는 간질

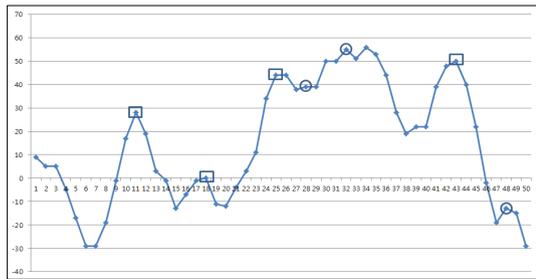
증상이 있는 피실험자를 통하여 수집된 간질 파형이다. 본 논문에서 사용한 실험군을 <Table 1>에서 설명하고 있다.

<Table 1> Numbers of training and test sets

Class	Train set	Test set	Total set
Epileptic	500	300	800
Normal	500	300	800
Total	1000	600	1600

2.2 웨이블릿 변환(wavelet transforms)

본 논문은 Subasi가 사용한 실험데이터를 이용하여 512개의 연속된 점들을 하나의 파형으로 구성하였다[11]. 이렇게 구성된 파형을 뇌파 분석에 많이 사용되는 Daubechies 4 웨이블릿 변환을 이용하여 변환을 수행하였다. 본 논문에서는 스케일 레벨 2까지 Daubechies 4 웨이블릿 변환을 수행하여 웨이블릿 계수인 detail 계수 (D1, D2)와 approximation 계수(A1, A2)를 추출하였다.



[Fig. 2] Example of epilepsy waveform

2.3 점증적 증가를 이용한 첨점 추출

첨점(peak)란 신호가 상승하다가 하락하는 지점을 일컫는다. 웨이블릿 변환을 수행하여 추출한 웨이블릿 계수에는 [Fig. 2]와 같이 많은 첨점들이 존재한다. 하지만 [Fig. 2]를 보면 알 수 있듯이 첨점 중에는 한번만 상승하다 하락하는 첨점이 있음을 알 수가 있다. 이러한 첨점은 [Fig. 2]에서 동그라미(○)로 표시되어 있다. 반면에 첨점 중에는 두 번 이상 상승하다 하락하는 첨점이 있음을 알 수가 있다. 이러한 첨점은 [Fig. 2]에서 네모(□)로 표시되어 있다. 본 논문에서 제안하는 점증적 증가를 이용한 첨점 추출 방식은 첨점 중에서 한번만 상승하다 하락하는 첨점은 무시하고 연속적으로 두 번 이상 상승하다가 하락하는 첨점만 추출하는 방법이다.

2.4 위상공간 재구성

(phase space reconstruction)

위상공간 재구성기법은 위상공간을 기반으로 동적인 파형이나 무작위적인 신호를 분석하기 위한 기법이다. 점증적 증가에 의해 추출된 첨점을 $x(t)$, $x(t+1)$, $x(t+2)$ 라고 할 때 위상공간의 x축에는 $x(t)$, y축에는 $x(t+1)$, z축에는 $x(t+2)$ 를 사상시켜 3차원 다이어그램을 생성하였다. [Fig. 3]에서 보면 정상 파형의 첨점에 대한 위상공간 재구성과 간질 파형의 첨점에 대한 위상공간 재구성의 차이점을 보여주고 있다. 정상 파형의 첨점에 대한 위상공간 재구성이 간질 파형의 첨점에 대한 위상공간 재구성에 비하여 한군데로 집중되어 있음을 알 수가 있다. 이러한 결과를 토대로 정상 파형의 첨점을 위상공간 재구성에 적용하였을 때 위상공간 재구성은 규칙적인 형태를 보이며 적은 공간을 차지하나 간질 파형의 첨점을 위상공간 재구성에 적용하였을 때 위상공간 재구성은 불규칙적인 형태를 보이며 많은 공간을 차지하게 된다.

2.5 유클리드 거리와 통계적 방법에 의한

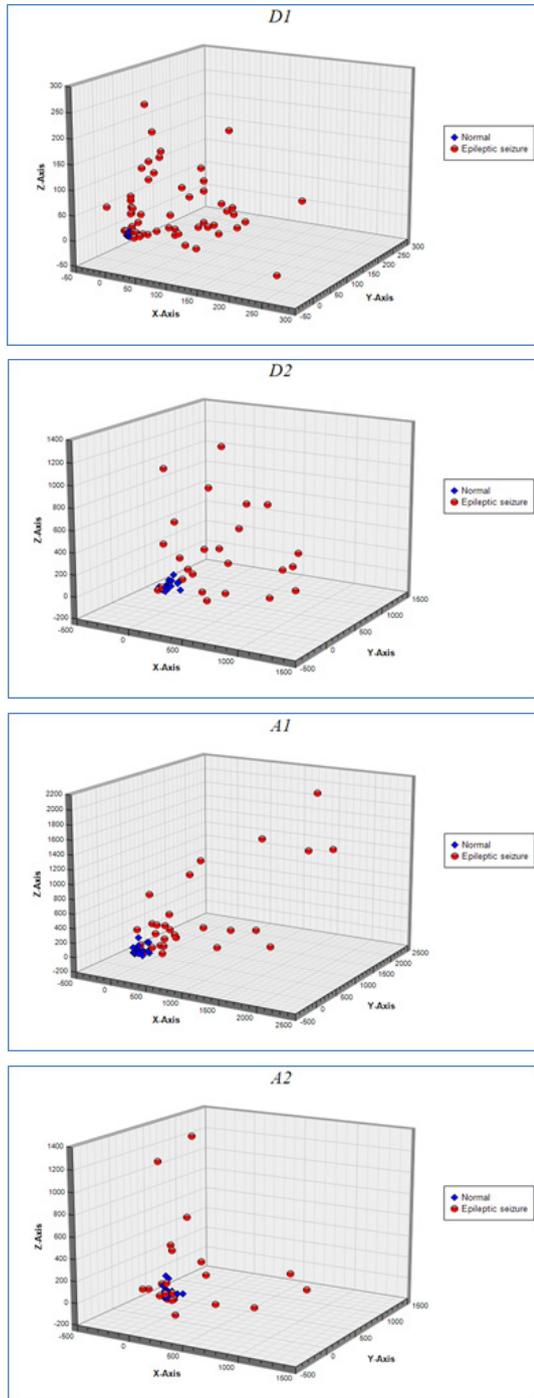
특징 추출

본 논문에서는 NEWFM의 입력으로 사용할 특징을 추출하기 위해서 [Fig. 3]에서 원점 (0, 0, 0)과 3차원 좌표상의 점 ($X(i)$, $X(i+1)$, $X(i+2)$) 사이의 유클리드 거리를 이용하였다($X(i)$ 은 첨점을 의미한다). 유클리드 거리 ($E(i)$) 식은 (1)과 같이 정의된다. 이렇게 구한 유클리드 거리를 <Table 2>의 통계적 기법을 이용하여 본 논문에서 입력으로 사용할 16개의 특징(웨이블릿 계수 D1, D2, A1, A2로부터 각각 4개씩의 특징)을 추출하였다. <Table 2>에서 언급한 통계적 기법 (1), (2), (3)는 뇌파에 대한 주파수 분포를 의미한다[14]. 또한 통계적 기법 (4)는 뇌파에 대한 주파수 변화량을 의미한다[14].

$$E(i) = \sqrt{X(i)^2 + X(i+1)^2 + X(i+2)^2} \quad (1)$$

<Table 2> Feature description

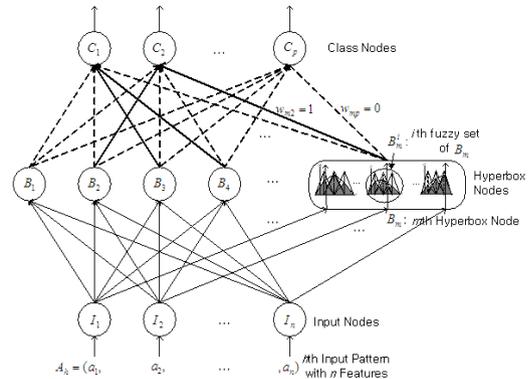
No	Description of the features
1	Mean of the Euclidean distances in each sub-band
2	Median of the Euclidean distances in each sub-band
3	Average power of the Euclidean distances in each sub-band
4	Standard deviation of the Euclidean distances in each sub-band



[Fig. 3] Examples of phase space reconstruction

2.6 가중 퍼지소속함수 기반 신경망

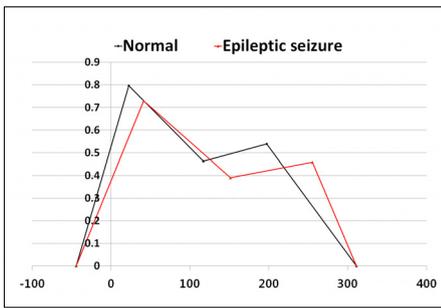
가중 퍼지소속함수 기반 신경망(Neural Network with Weighted Fuzzy Membership Function, NEWFM)은 입력으로부터 학습된 가중 퍼지소속함수의 경계합(bounded sum of weighted fuzzy membership functions)을 이용하여 클래스 분류를 하는 지도학습(supervised) 퍼지 신경망이다[4,14,15]. 가중 퍼지소속함수의 경계합은 가중치를 갖는 대, 중, 소의 3개 퍼지소속함수의 경계합을 하나의 퍼지소속함수로 합성한 것이다. NEWFM의 구조는 [Fig. 4]에서 보는 바와 같이 입력, 하이퍼박스, 클래스의 3개 계층으로 구성되어 있다. 입력 계층에는 n 개의 입력노드들로 구성되며 각 입력노드는 하나의 특징을 입력받게 된다. 하이퍼박스 계층은 m 개의 하이퍼박스 노드로 구성되고, l 번째 하이퍼박스 노드 B_l 은 단 하나의 클래스 노드에 연결되며 n 개의 퍼지집합을 갖는다. 본 논문에서는 <Table 2>에서 설명하고 있는 통계적 기법에 의해 추출한 16개의 특징을 갖는 h 번째 입력 $A_h = (a_1, a_2, \dots, a_n)$ 에 대한 NEWFM의 입력으로 사용되어진다.



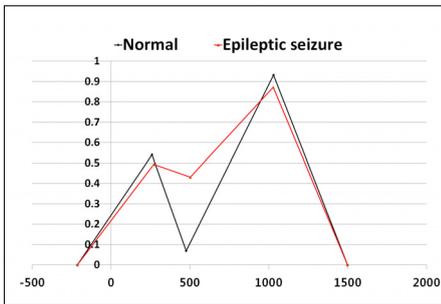
[Fig. 4] Structure of NEWFM

3. 실험 결과

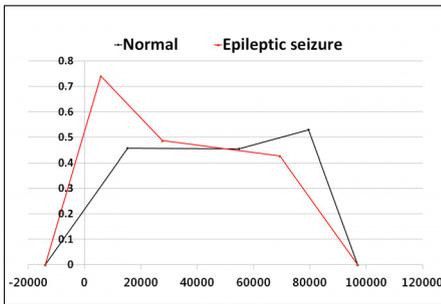
[Fig. 5]는 16개의 특징 중에서 웨이블릿 계수 D1에 대한 가중 퍼지소속함수의 경계합의 예를 보여주고 있다. 또한 본 논문에서 비교하고 있는 Subasi[11]의 분류 모델인 mixture of expert(ME)는 [Fig. 5]의 경우처럼 퍼지규칙과 같은 해석이 가능한 일반적인 규칙을 제공하지 않고 있다.



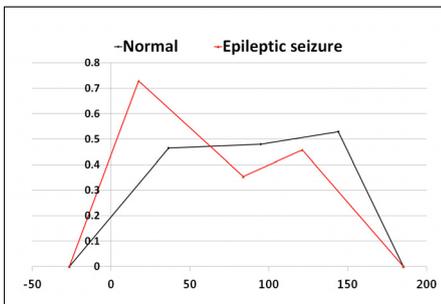
(a) No. 1 in <Table 2> of wavelet coefficient D1



(b) No. 2 in <Table 2> of wavelet coefficient D1



(c) No. 3 in <Table 2> of wavelet coefficient D1



(d) No. 4 in <Table 2> of wavelet coefficient D1

[Fig. 5] Examples of bounded sum of weighted fuzzy membership functions

본 논문에서는 분류 성능을 평가하기 위해 분류 알고리즘의 성능 평가 기준으로 정확도(accuracy), 특이도(specificity), 민감도(sensitivity)를 사용하였다. 식은 (2)와 같이 정의된다. 여기서, TP(true positive)는 간질 파형을 간질 파형으로 분류되는 것, FN(false negative)은 간질 파형을 정상 파형으로 분류되는 것, FP(false positive)는 정상 파형을 간질 파형으로 분류되는 것, TN(true negative)은 정상 파형을 정상 파형으로 분류되는 것을 의미한다.

$$\text{정확도} = \frac{TP + TN}{TP + FN + TN + FP} \times 100$$

$$\text{특이도} = \frac{TN}{TN + FP} \times 100 \tag{2}$$

$$\text{민감도} = \frac{TP}{TP + FN} \times 100$$

본 논문에서는 16개의 특징으로부터 구한 분류 성능을 <Table 3>, <Table 4>에서 보여주고 있다. 또한 <Table 4>에서는 Subasi[11]의 분류 성능과 비교하였다. NEWFM의 분류 성능인 정확도, 특이도에 있어서 Subasi[11]보다 3%, 6%가 각각 높게 나타났다.

<Table 3> Number of instances for performance results without feature selection

Class	Results	
	Epileptic seizure signals (300)	TP 285
Normal signals (300)	FP 0	TN 300

<Table 4> Comparisons of performance results

	Accuracy	Specificity	Sensitivity
Subasi[11]	94.5%	94%	95%
NEWFM	97.5%	100%	95%

4. 결론

본 논문에서는 웨이블릿 변환, 점증적 증가를 이용한 점점 추출, 위상공간 재구성을 이용하여 생성한 값을 유클리드 거리와 통계적 방법을 이용하여 NEWFM의 입력

으로 사용할 16개의 특징을 추출하였다. 이렇게 생성한 16개의 특징을 이용하여 NEWFM 기반의 뇌파로부터 간질을 검출하기 위한 방법을 제안하고 있다. 웨이블릿 변환은 뇌파로부터 잡음을 제거하여 침점 추출 이전에 작은 침점들을 미리 제거하는 효과가 있다. 점증적 증가를 이용한 침점 추출은 많은 침점들 중에서 비교적 상승폭이 큰 침점을 추출하는 효과가 있다. 위상공간 재구성은 뇌파의 규칙성과 불규칙성을 3차원 다이어그램을 이용하여 시각적인 확인을 가능하게 한다. NEWFM은 16개 특징에 대한 가중 퍼지소속 함수의 경계 합을 구하여 16개의 특징에 대한 퍼지소속 함수를 [Fig. 5]와 같이 보여주고 있다. 이러한 퍼지소속 함수는 뇌파로부터 정상 파형과 간질 파형의 분류에 사용하게 된다. 16개의 특징으로 Subasi[11]의 결과보다 정확도, 특이도가 향상된 97.5%, 100%의 분류결과를 보여주었고 민감도에 있어서는 95%로 동일하였다. 본 논문에서 제안하는 방법을 통해서 실시간으로 뇌파를 측정하여 정상 파형과 간질 파형을 분류할 수 있는 시스템을 구현할 수 있다. 또한 정확도를 높이기 위해서 다양한 신호처리 기술을 도입이 필요시 되고 NEWFM에서 제공하는 특징 선택 알고리즘을 사용하여 최소의 특징으로 최고의 정확도를 구하는 연구가 추가 될 것이다.

REFERENCES

- [1] Admi, H. and Shaham, B., Living with epilepsy: ordinary people coping with extraordinary situations, *Qualitative Health Research*, Vol.17, pp.1178-1187, 2007.
- [2] Korean Neurological Association. *Neurology*, Seoul: Koonja Publishing Co., 2007.
- [3] R. Sharma, R. B. Pachori, Classification of epileptic seizures in EEG signals based on phase space representation of intrinsic mode functions, *Expert Systems with Applications*, Vol.42, pp.1106-1117, 2015.
- [4] S. -H. Lee, J. S. Lim, J. -K. Kim, J. Yang, Y. Lee, Classification of normal and epileptic seizure EEG signals using wavelet transform, phase-space reconstruction, and Euclidean distance, *Computer Methods and Programs in Biomedicine*, Vol.116, pp.10 - 25, 2014.
- [5] Kemal Polat and Salih Güneş, Artificial immune recognition system with fuzzy resource allocation mechanism classifier, principal component analysis and FFT method based new hybrid automated identification system for classification of EEG signals, *Expert Systems with Applications*, Vol.34, Issue 3, pp.2039-2048, 2008
- [6] Avci E, Hanbay D, Varol A. An expert discrete wavelet adaptive network based fuzzy inference system for digital modulation recognition, *Expert Syst Appl*, Vol.33, pp.582-589, 2007.
- [7] Güler İ, Übeyli ED. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients, *J Neurosci Methods*, Vol.148, pp.113-121, 2005.
- [8] M. E. Menshawy, A. Benharref, M. Serhani, An automatic mobile-health based approach for EEG epileptic seizures detection, *Expert Systems with Applications*, Vol.42, 7157 - 7174, 2015
- [9] F Shayegha, S Sadria, R Amirfattahia, K Ansari-Aslb. A model-based method for computation of correlation dimension, Lyapunov exponents and synchronization from depth-EEG signals, *COMPUT METH PROG BIO*, Vol.113, pp.323-337, 2014.
- [10] Güler NH, Übeyli ED, Güler İ. Recurrent neural networks employing Lyapunov exponents for EEG signal classification, *Expert Sys Appl*, Vol.25, pp.506-514, 2005.
- [11] Abdulhamit Subasi, EEG signal classification using wavelet feature extraction and a mixture of expert model, *Expert Systems with Applications*, Vol.32, Issue 4, pp.1084 - 1093, 2007.
- [12] Güler İ, Übeyli ED. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients, *J Neurosci Methods*, Vol.148, pp.113-121, 2005.
- [13] Y. Songa, J. Crowcroft, J. Zhang, Automatic

- epileptic seizure detection in EEGs based on optimized sample entropy and extreme learning machine, Journal of Neuroscience Methods, Vol.210, pp.132-146, 2012.
- [14] S. -H. Lee and J. S. Lim, Extracting Input Features and Fuzzy Rules for Classifying Epilepsy Based on NEWFM, Journal of Internet Computing and Services, Vol.10, No.5, pp.127-133, 2009.
- [15] J. S. Lim, Finding Features for Real-Time Premature Ventricular Contraction Detection Using a Fuzzy Neural Network System, IEEE Transactions on Neural Networks, Vol.20, No.3, pp.522-527, 2009.

이 상 홍(Lee, Sang Hong)



- 1999년 2월 : 경원대학교 전자계산학과(공학사)
- 2001년 2월 : 경원대학교 일반대학원 전자계산학과(공학석사)
- 2012년 2월 : 경원대학교 일반대학원 전자계산학과(공학박사)
- 2013년 3월 ~ 현재 : 안양대학교 컴퓨터공학과 조교수

- 관심분야 : neuro-fuzzy system을 이용한 전문가 시스템
- E-Mail : shleedosa@gmail.com, shleedosa@anyang.ac.kr