

거리 기반의 특징 선택을 이용한 간질 분류

이상홍
안양대학교 컴퓨터공학과

Classification of Epilepsy Using Distance-Based Feature Selection

Sang-Hong Lee

Department of Computer Science & Engineering, Anyang University

요약 특징 선택은 중복 또는 서로간의 관련이 없는 특징을 제거하여 분류 성능을 향상시키는 기술이다. 본 논문에서는 가중 퍼지소속함수 기반 신경망 (Neural Network with Weighted Fuzzy Membership Functions; NEWFM)에서 제공하는 가중 퍼지소속함수의 경계합 (Bounded Sum of Weighted Fuzzy Membership functions, BSWFM)의 무게중심간의 거리를 이용한 새로운 특징 선택을 제안하여 분류 성능을 향상시켰다. 이러한 거리 기반의 특징 선택을 이용하여 초기 24개의 특징으로부터 무게중심간의 거리가 짧은 특징을 하나씩 제거되면서 분류 성능이 가능 높은 22개의 최소 특징을 선택하였다. 이들 22개의 최소 특징을 NEWFM의 입력으로 사용하여 97.7%, 99.7%, 98.7%의 민감도, 특이도, 정확도를 각각 구하였다.

주제어 : 특징 선택, 간질, 퍼지신경망, 웨이블릿 변환, 특징 추출

Abstract Feature selection is the technique to improve the classification performance by using a minimal set by removing features that are not related with each other and characterized by redundancy. This study proposed new feature selection using the distance between the center of gravity of the bounded sum of weighted fuzzy membership functions (BSWFMs) provided by the neural network with weighted fuzzy membership functions (NEWFM) in order to improve the classification performance. The distance-based feature selection selects the minimum features by removing the worst features with the shortest distance between the center of gravity of BSWFMs from the 24 initial features one by one, and then 22 minimum features are selected with the highest performance result. The proposed methodology shows that sensitivity, specificity, and accuracy are 97.7%, 99.7%, and 98.7% with 22 minimum features, respectively.

Key Words : Feature Selection, Epilepsy, Fuzzy Neural Networks, Wavelet Transforms, Feature Extraction

1. 서론

간질은 인간의 뇌를 구성하고 있는 신경세포의 일부가 손상되어 대뇌피질에서 과도한 전기 방전으로 인해 발작이 반복적으로 일어나는 질환으로 전체 인구의

0.6-1%에 해당한다[1]. 우리나라에서는 인구 중 최소한 25-35만 명 이상이 간질에 이환되어 있는 것으로 알려져 있으며, 연령을 보정한 유병률은 5세 이전에는 1000명당 1.41명이었다가 서서히 증가하여 10세 이후부터는 1000

Received 8 June 2014, Revised 28 July 2014
Accepted 20 August 2014
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

명당 6-8명으로 보고되고 있다[2]. 간질 발작 중 과도한 발작과가 뇌의 한 부분에서 국한 적으로 발생할 때를 부분 간질, 뇌의 전체에서 발생할 때 전신 간질이라 한다. 뇌에 발작과가 동반되는 발작이 특별한 유발 요인 없이 장기간 반복적으로 발생할 때 간질로 진단한다. 이러한 발작과를 탐지하기 위해서 뇌파(electroencephalogram, EEG)로 부터 추출한 특징과 인공지능 기법들이 연구되어지고 있다[11-17].

리아프노프 지수와 상관 차원 등의 비선형 기법은 EEG 데이터로부터 복잡성을 추출하는 데 사용되었다 [11][12][13]. EEG 데이터는 이산 웨이블릿 변환(discrete wavelet transform, DWT)에 의하여 시간-주파수 영역으로 분해되었다[14][15]. 또한 웨이블릿 변환에 의해 생성된 계수들이 적응 뉴로 퍼지 추론 시스템(adaptive neuro-fuzzy inference system, ANFIS)의 입력으로 사용되었다[15]. 웨이블릿 계수로부터 통계적 기법에 의해서 특징을 추출한 기법[3]과 artificial neural network(ANN)[17], support vector machine(SVM)[16], mixture of expert model(ME)[3]을 혼합한 모델이 개발되었다.

Polat[19]은 푸리에 변환을 사용하여 간질 파형을 분류하였다. Polat은 푸리에 변환 통해 추출한 129개의 인자 값을 주성분분석(principal component analysis, PCA)을 이용하여 5개로 차원을 낮추어 이 값들을 특징으로 사용하였다. Subasi[3]는 웨이블릿 변환을 통하여 생성된 계수들을 기반으로 특징을 추출하였다. 이렇게 추출된 특징은 mixture of expert(ME)라는 분류모델을 사용하였다. 그러나 이러한 두 모델의 단점은 초기의 특징을 특징 선택 없이 그대로 사용하였고 또한 간질 파형 분류에 대한 퍼지규칙과 같은 해석이 가능한 일반적인 규칙을 제공할 수 없다.


본 논문에서는 기존의 가중 퍼지소속함수 기반 신경망(Neural Network with Weighted Fuzzy Membership Functions: NEWFM)[4][5]에 새로운 거리 기반의 특징 선택을 제안하여 정상 파형과 간질 파형의 분류 성능을 향상시키고자 하였다. 본 논문은 크게 두 개의 부분으로 구성되어 있는데 첫 번째 부분은 EEG 데이터를 처리하는 신호처리 부분이고 두 번째 부분은 특징을 선택하여 정상 파형과 간질 파형을 분류하는 부분이다. 신호처리 부분에서는 EEG 데이터가 웨이블릿 변환에 의하여 EEG

데이터로부터 잡음 등을 제거한 웨이블릿 계수를 생성하였다. 이렇게 생성된 웨이블릿 계수를 통계적 기법을 이용하여 입력으로 사용할 특징을 추출하였다. 특징 선택 부분에서는 NEWFM의 학습 과정에서 생성되는 BSWFM의 무게중심간의 거리를 이용하여 최고의 분류 성능을 나타내는 최소의 특징을 구하게 된다.

본 논문은 다음과 같이 구성되었다. 2 장에서는 실험 데이터, 웨이블릿 변환, 통계적 기법을 설명한다. 또한 NEWFM에 대해서 설명한다. 3 장에서는 본 논문에서 제안하는 NEWFM 기반의 특징 선택 기법에 대해서 설명한다. 4 장에서는 특징 선택을 이용하여 구한 분류 성능에 대해서 설명하면서 특징 선택 전/후의 분류 성능에 대해서 비교한다. 마지막으로 5장에서는 결론으로 끝을 맺는다.

2. 간질 분류 모델의 개요

본 논문에서는 [Fig. 1]의 간질 분류 모델에서 알 수 있듯이 웨이블릿 변환(wavelet transforms, WT)에 의해 변환된 EEG 데이터를 주파수 분포와 주파수 변화량에 의해서 특징을 추출하였다. 이렇게 추출한 특징으로부터 무게중심 간의 거리 기반의 특징 선택 기법을 이용하여 최고의 분류 성능을 나타내는 최소의 특징을 선택하였다.



[Fig. 1] Model of epilepsy classification

2.1 실험 데이터(Experimental Data)

본 논문에서는 Andrzejak[6]이 사용한 EEG 데이터를 사용하여 정상 파형과 간질 파형을 분류하였다. Andrzejak이 사용한 실험데이터는 5개의 실험군(A, B, C, D, E)으로 나누어져있다. 각각의 실험군은 100개의 단일채널 EEG 부분을 포함하고 있다. 본 논문에서는 Subasi[3]가 사용한 A와 E의 실험군을 사용하여 실험을 하였다. 실험군 A는 건강한 피실험자를 통하여 수집된


정상 파형이고 실험군 E는 간질증상이 있는 피실험자를 통하여 수집된 간질 파형이다. 본 논문에서 사용한 실험군을 <Table 1>에서 설명하고 있다. 실험군을 구성하고 있는 각각의 파형은 512개의 점으로 이루어져있다.

<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)과 통계적 기법을 이용한 특징 추출

본 논문은 Andrzejak과 Subasi가 사용한 실험데이터를 이용하여 512개의 점으로 구성되어있는 하나의 파형을 [Fig. 2]에서 설명하고 있는 스케일 레벨 5인 Haar 웨이블릿 변환을 수행하여 웨이블릿 계수인 detail 계수 $g[n]$ 와 approximation 계수 $a[n]$ 를 추출하였다[4].



[Fig. 2] Dyadic wavelet transforms at level 5

Haar 웨이블릿 변환에 의해 추출된 웨이블릿 계수들을 [4]에서 사용한 <Table 2>의 통계적 기법을 동일하게 이용하여 본 논문에서 입력으로 사용할 24개의 특징을 추출하였다. 이렇게 추출한 24개의 초기 특징은 <Table 3>에서 확인할 수가 있다. <Table 2>에서 언급한 통계적 기법 (1), (2), (5)는 EEG 파형에 대한 주파수 분포를 의미한다[3]. 또한 통계적 기법 (3), (4)는 EEG 파형에 대한 주파수 변화량을 의미한다[3].

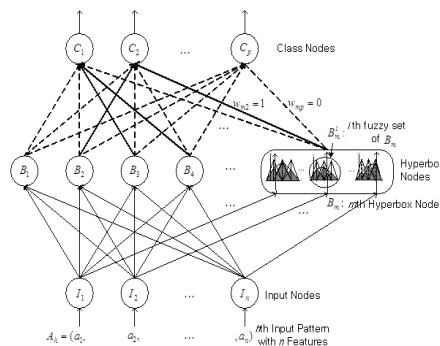
<Table 2> Feature description

No	Description of the features
1	Mean of the absolute values of the coefficients in each sub-band
2	Average power of the coefficients in each sub-band
3	Standard deviation of the coefficients in each sub-band
4	Ratio of the absolute mean values of adjacent sub-bands
5	Median of the coefficients in each sub-band

2.3 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, BSWFM)을 이용하여 클래스 분류를 하는 지도학습(supervised) 퍼지 신경망이다[4][5]. 가중 퍼지소속함수의 경계합은 가중치를 갖는 대, 중, 소의 3개 퍼지소속함수의 경계합을 하나의 퍼지소속함수로 합성한 것이다. NEWFM의 구조는 [Fig. 3]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 24개의 특징은 [Fig. 3]의 n 개의 특징을 갖는 h 번째 입력 $A_h = (a_1, a_2, \dots, a_n)$ 에 대한 NEWFM의 입력으로 사용되어진다.

[Fig. 3]에서 학습을 거친 하이퍼박스노드 B_l 은 입력패턴을 분류하기 위한 if-then 형식의 퍼지규칙으로 사용될 수 있다. B_l^j 는 3개의 가중 퍼지소속함수($\mu_j(\cdot)$, where $j=1,2,3$, Weighted Fuzzy Membership functions, WFM, [Fig. 4]의 회색 부분)로 구성된다. [Fig. 4]의 굵은 선으로 표시된 $\mu_b^i(\cdot)$ 은 WFM의 경계합(Bounded Sum of WFM, BSWFM)으로써 다음 식과같이 정의되며 3개의 WFM의 퍼지 특성을 통합하게 된다. 학습된 BSWFM $\mu_b^i(\cdot)$ 은 i 번째 입력에 대한 퍼지규칙으로 이용된다[5].



[Fig. 3] structure of NEWFM

$$\mu_b^i(x) = \sum_{j=1}^3 B_j^i(\mu_j(x)) \quad (1)$$



[Fig. 4] Example of BSWFMs (Bold Line)

3. 특징 선택 (Feature Selection)

퍼지규칙이나 중요한 특징을 선택하는 것은 최근 논문에서 언급되어지고 있다[18]. 특징 선택은 패턴인식 분야와 기계 학습 분야에 있어서 중요한 연구주제가 되었다[7-10]. 좋은 특징 선택은 불필요한 특징이나 잡음이 있는 특징을 제거함으로써 연산비용의 감소나 성능의 향상과 같은 이점을 얻을 수가 있게 한다. 또한 최근에는 학습을 통하여 어떠한 사실을 분류하는데 이용되는 데이터가 급속히 증가됨에 따라 학습을 하는 과정에서의 문제점도 발생되고 있다[7-10]. 대표적인 문제점으로 많은 양의 데이터에는 서로간의 관련성이 적어서 잘못된 분류를 하는 경우가 빈번이 발생하고 또한 좋지 않은 데이터를 이용한 학습의 결과로 분류 오류가 높아지고 있다는 것이다[9-10].


이러한 문제점을 극복하고 분류 성능을 향상시키기 위해서 NEWFWM에서는 BSWFM의 무게중심 간의 거리를 이용하여 많은 양의 데이터로부터 서로 간의 관련성이 적은 데이터를 제거하는 특징 선택을 제공하고 있다. 본 논문에서는 초기 24개의 특징으로부터 NEWFWM을 이용하여 1000번의 학습을 수행하였다. 이러한 학습을 통하여 생성된 BSWFM의 무게중심 간의 거리를 이용하여 다음과 같이 4가지 단계로 특징 선택을 수행하였다.

<Table 3> Result of distance between center of gravity

wavelet coefficients	No in Table 1	Mean	Standard deviation	Maximum	Minimum
ac(5)	1	20.11	0.11	20.44	19.78
ac(5)	5	13.41	0.10	13.53	12.98
ac(5)	2	11.17	0.52	12.56	10.39
dc(2)	2	8.81	0.10	8.94	8.51
dc(4)	4	8.29	0.26	8.67	7.75
dc(3)	4	8.28	0.52	9.46	7.58
dc(4)	1	7.68	0.09	7.80	7.46
dc(5)	4	7.58	0.18	7.86	7.31
dc(5)	2	6.87	0.53	7.93	6.44
dc(2)	1	6.80	0.17	7.27	6.55
dc(5)	1	6.40	0.27	6.77	5.99
dc(3)	1	6.31	0.03	6.38	6.26
dc(2)	3	6.26	0.09	6.37	6.12
dc(4)	3	4.72	0.09	5.00	4.54
dc(3)	3	4.67	0.06	4.81	4.50
dc(2)	5	4.57	0.90	6.15	3.32
dc(5)	3	4.52	0.32	5.36	3.90
dc(4)	5	4.23	1.27	6.70	2.61
ac(5)	3	4.02	0.07	4.11	3.88
dc(4)	2	1.87	0.05	1.97	1.81
dc(3)	5	0.66	0.08	0.82	0.56
dc(3)	2	0.57	0.00	0.57	0.56
dc(5)	5	0.49	0.25	0.80	0.23
dc(2)	2	0.24	0.00	0.24	0.23

The numbers in parentheses indicate the level of wavelet coefficients. For examples, ac(5) indicates approximation coefficients at level 5 and dc(5) indicates detail coefficients at level 5.

- [단계 1] 학습 과정에서 생성된 [Fig. 4]의 BSWFM의 v_0 와 v_4 을 각각 0과 100으로 정규화 시킨다.
- [단계 2] 정규화된 BSWFM을 이용하여 [Fig. 5]와 같이 간질 파형의 BSWFM과 간질 파형의 BSWFM의 무게중심을 각각 구한다.
- [단계 3] 두 개의 BSWFM 무게중심간의 거리를 구하고 24개의 특징들에 대한 무게중심간의 거리를 <Table 3>과 같이 정렬한다.
- [단계 4] <Table 3>에서 무게중심간의 거리의 평균이 가장 짧은 특징부터 하나씩 제거하면서 분류 성능을 비교하였다.



[Fig. 5] The example of distance between center of gravity in BSWFMs

단계 1에서 정규화 단계가 필요한 이유는 NEWFM의 입력으로 사용된 24개의 특징들은 각자가 가지는 값들의 범위가 전부 다르다. 예를 들어, 어떤 특징은 0과 1사이의 값을 가질 수도 있고 어떤 특징은 0과 10,000사이의 값을 가질 수도 있다. 따라서 학습이 완료된 후에 [Fig. 4]의 BSWFM의 x축의 범위 또한 특징에 따라 v_i 가 1의 값을 가질 수가 있고 10,000의 값을 가질 수도 있다. 정규화를 하지 않는다면 x축의 범위가 큰 특징일수록 무게중심간의 거리는 x축의 범위가 작은 특징보다는 크게 구해될 것이다. 이러한 오류를 없애기 위해서 정규화 과정이 필요시 된다. 단계 2에서는 0과 100사이의 값으로 정규화된 BSWFM을 이용하여 [Fig. 5]와 같이 간질 파형에 대한 BSWFM의 무게중심과 간질 파형에 대한 BSWFM의 무게중심을 각각 구한다. 단계 3에서는 이렇게 구한 무게중심을 이용하여 [Fig. 5]에서의 무게중심 간의 거리를 구하게 된다. 무게 중심 간의 거리가 멀수록 두 개의 클래스를 분류할 수 있는 특징을 더 많이 가지고 있다고 볼 수 있다. 또한 24개의 특징들에 대한 무게중심의 거리에 대한 평균값, 표준편차, 최댓값, 최솟값을 <Table 3>과 같이 구하게 된다. 단계 4에서는 <Table 3>의 결과를 기반으로 하여 평균값이 가장 낮은 특징들을 하나씩 제거해 가면 분류 성능을 구하게 된다. 결과적으로 본 논문에서는 초기 24개의 특징 중에서 특징 dc(2)와 dc(5)를 제거한 22개의 특징으로 분류 성능이 가장 높게 나타났다.

4. 실험 결과 (Experimental Results)

통계학에서는 통계적 결정 기법의 오류를 설명하기

위해 타입 I 오류(type I error, error, or false positive)와 타입 II 오류(type II error, error, or false negative)를 사용한다. 타입 I 오류는 '올바른' 가설을 '거부하는' 오류를 뜻하고, 타입 II 오류는 '거짓' 가설을 '거부하지 못하는' 오류를 뜻한다. 이러한 통계학의 타입 오류는 일반적인 분류 알고리즘의 분야에서 분류율의 성능 평가 기준으로 다양한 표현 방식으로 사용되었다. '입력된 파형은 간질이다.'라는 가설의 예를 들면, 타입 I 오류는 '올바른' 가설(간질)을 '거부하는'(정상으로 판단) 오류를 의미하고, 타입 II 오류는 '거짓' 가설(정상)을 '거부하지 못하는'(간질로 판단) 오류를 의미한다.

본 논문에서는 분류 성능을 평가하기 위해 분류 알고리즘의 성능 평가 기준으로 민감도(sensitivity), 특이도(specificity), 정확도(accuracy)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.

$$\begin{aligned} \text{민감도} &= \frac{TP}{TP+FN} \times 100 \\ \text{특이도} &= \frac{TN}{TN+FP} \times 100 \\ \text{정확도} &= \frac{TP+TN}{TP+FN+TN+FP} \times 100 \end{aligned} \quad (2)$$

본 논문에서는 BSWFM의 무게중심간의 거리를 기반으로 한 특징 선택에 의해 선택된 22개의 최소 특징으로부터 구한 분류 성능과 초기의 24개의 특징으로부터 구한 분류 성능을 <Table 4>, <Table 5>, <Table 6>에서 비교하였다. 비록 특이도에 있어서는 0.3%가 낮게 나타났지만 민감도, 정확도에 있어서는 각각 1.7%, 0.7%가 높게 나타났다.

<Table 4> Number of instances for performance results without feature selection

Class	Results	
	Epileptic seizure signals (300)	TP 288
Normal signals (300)	FP 0	TN 300

<Table 5> Number of instances for performance results with feature selection

Class	Results	
	TP	FP
Epileptic seizure signals (300)	293	7
Normal signals (300)	FN	TN
	1	299

<Table 6> Comparisons of performance results

	Sensitivity	Specificity	Accuracy
Subasi[3]	95%	94%	94.5%
Without feature selection[4]	96%	100%	98%
With feature selection	97.7%	99.7%	98.7%

5. 결론

본 논문에서는 NEWFM의 학습 과정에서 생성되는 BSWFM의 무계중심간의 거리를 기반으로 한 특징 선택을 이용하여 중요도가 가장 낮은 특징을 하나씩 제거하였다. 이렇게 중요도가 가장 낮은 특징을 하나씩 제거하면서 간질 분류를 위한 최소의 특징을 선택하여 최고의 분류 성능을 구하는 방안을 제안하고 있다. 이러한 특징 선택에 이용하여 24개의 초기 특징으로부터 구한 22개의 최소 특징을 NEWFM의 입력으로 사용하여 분류 성능에 있어서 최고의 분류 성능 구하였다. 본 논문에서 제안하는 무계중심간의 거리에 의한 특징 선택은 불필요하거나 분류 결과에 악영향을 주는 특징을 제거함으로써 특징의 수를 최소화 시켜주고 가장 높은 분류 성능을 구할 수 있게 해준다. NEWFM에서 제공하는 BSWFM의 무계중심간의 거리 기반의 특징 선택을 이용한 민감도, 특이도, 정확도의 분류 성능에 있어서 각각 97.7%, 99.7%, 98.7%를 보여주었다. 이러한 분류 성능은 특징 선택을 이용하지 않고 구한 민감도, 특이도, 정확도의 분류 성능에 있어서 각각 96%, 100%, 98% 보다 비록 특이도에 있어서는 0.3%가 낮게 나타났지만 민감도, 정확도에 있어서는 각각 1.7%, 0.7%가 높게 나타났다. 본 연구에서는 무계중심간의 거리의 평균만을 특징 선택에 이용하였지만 향후에는 <Table 3>의 결과를 기반으로 표준편차, 최댓값, 최솟값 등을 이용한 정규분포와 같은 통계적 방법을 접목한 연구가 필요시 된다.

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] 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.
- [4] Sang-Hong Lee and Joon 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.
- [5] Joon 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.
- [6] Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., and Elger, C. E., Indications of nonlinear deterministic and finite dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state, *Physical Review E*, 64, 061907, 2001.
- [7] Minh Hoai Nguyen and Fernando de la Torre, Optimal feature selection for support vector machines, *Pattern Recognition*, Vol.43, pp.584-591, 2010.
- [8] Patricia E.N. Lutu and Andries P. Engelbrecht, A decision rule-based method for feature selection in predictive data mining, *Expert Systems with Applications*, Vol.37, pp.602-609, 2010.
- [9] Kabir M, Shahjahan, and Murase K, A new local search based hybrid genetic algorithm for feature selection, *Neurocomputing*, Vol.74, pp.2914-2928, 2011.
- [10] Lee CP and Leu Y, A novel hybrid feature selection method for microarray data analysis,

- Applied Soft Computing, Vol.11, pp.208-213, 2011.
- [11] 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.
- [12] 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.
- [13] Lehnertz K, Elger CE. Spatio-temporal dynamics of the primary epileptogenic area in temporal lobe epilepsy characterized by neuronal complexity loss, Electroencephalogr Clin Neurophysiol, Vol.95, pp.108-117, 1995.
- [14] 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.
- [15] 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.
- [16] Chandaka S, Chatterjee A, Munshi S. Cross-correlation aided support vector machine classifier for classification of EEG signals, Expert Syst Appl, Vol.36, pp.1329-1336, 2009.
- [17] Ling G., Daniel R., Jose A.S., Alejandro P. Classification of EEG Signals Using Relative Wavelet Energy and Artificial Neural Networks, GEC (June), pp.177-183, 2009.
- [18] M. Setnes and H. Roubos, GA-Fuzzy Modeling and Classification : Complexity and Performance, IEEE Trans., Fuzzy Systems, Vol.8, No.5, pp.509-522, 2000.
- [19] 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

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