

측두엽 간질 예측과 분류시스템

김민수 · 서희돈[†]

Prediction and Classification System for Temporal lobe Epilepsy

Min-Soo Kim and Hee-Don Seo[†]

Abstract

Epileptic seizures result from a temporary electrical disturbance of the brain. In this paper, a method of discriminating EEG for diagnoses of temporal lobe epilepsy is proposed. The proposed method for classification of epilepsy and sleep EEG is based on the wavelet transform and the fuzzy c-means. The magnitude and mean of wavelet coefficients for each EEG band are applied to the cluster of the FCM classifier. The proposed system show a little more accurate diagnosis for EEG by analysis of frequency for Wavelet and the success rate of 95% classification using FCM. From the simulation results by the implemented system, we demonstrated this research can be reduce doctor's labors and realize quantitative diagnosis of EEG.

Key Words : epileptic, sleep EEG, FCM, wavelet transform

1. 서 론

EEG(electroencephalogram)는 피질막 신경세포의 전기적 방전의 변화에 의해 발생하며, 뇌의 기능 및 뇌와 관련된 질병을 진단하는데 광범위하게 사용된다. 간질은 중추신경계의 돌발적인 기능부전에 의해 일어나는 의식, 정신적 기능, 운동성, 감각과 자율활동 등의 갑작스러운 장애이다. 신경세포의 일부가 짧은 시간동안 과도한 전기를 발생시킴으로써 일어나는 신경계의 발작적 증상으로 국부적 영역 또는 전역적으로 발생할 수 있다. 이러한 환자의 EEG 특성은 배경 활동 파형과 구별되는 극파(spike), 예파(sharp)와 서파를 동반한 복합파(sharp and slow complexes)로 대표된다¹⁾.

전세계적으로 간질병을 앓고 있는 인구는 600만명 이상이라고 한다. 이중 2/3정도는 약물 치료로 치료를 받고, 일부는 간질제거 수술에 의해 치료를 받는다. 그러나 일부는 치료가 되지 않는다. 그러므로 간질성 발작(epileptic seizure) 뇌파를 분석하여 간질의 발생원리를 이해하고 어떻게 하면 치료 가능한지, 간질발생 위

치를 어떻게 하면 정확히 찾아낼 수 있는지, 간질발작을 어떻게 하면 예측 할 수 있는지 또는 예측시간은 얼마나 빨리 할 수 있는지에 대한 연구 등이 이루어지고 있다²⁻⁴⁾.

현재 병원에서 주로 사용되는 뇌파해석 방법은 뇌파 전문의가 뇌파 기록지로부터 육안에 의해 특정뇌파를 찾아내는 것이다. 따라서 뇌파 해석을 위해서는 전문적인 지식뿐만 아니라 단순 반복작업에 필요한 많은 시간과 노력이 소요되는 문제점이 있다. 또한 해석의 주관성으로 인하여 같은 뇌파 기록일지라도 일관성 없는 결과가 얻어질 수 있다. 그러므로 컴퓨터를 이용한 뇌파의 자동검출은 객관성을 높이거나 정량적 해석을 위해서는 필수적인 작업이다. 그러나 이러한 실험을 하기 위해서는 고가의 특수장비들과 난해한 장비 사용법의 이해가 필수적으로 수반되어야 하는 문제점이 뒤따른다. 따라서 저가의 장비 사용과 사용법이 용이한 프로그램의 개발을 통해 비전문가도 뇌기능 검사와 주파수 해석을 손쉽게 이용할 수 있게 할 필요가 있다.

본 논문에서는 측두엽 간질파와 수면뇌파에 대해 웨이블릿 변환(wavelet transform)과 FCM(fuzzy c-means)을 통한 분류방법을 연구하였다. 웨이블릿 변환을 통한 신호의 주파수 해석에서는 기존의 모 웨이블릿 중에서 시간 영역과 주파수 영역에서의 특성이 우수한 것으로

영남대학교 전자공학과(Department of Electronic Engineering, Yeungnam University)

[†]Corresponding author: hdseo@yu.ac.kr

(Received : February 10, 2004, Accepted : March 2, 2004)

알려진 Daubechies 웨이블릿 변환^[5,6]을 이용하였으며, Daubechies family 중 db10을 사용하였다. 뇌파는 5단계의 주파수 대역신호 즉, 이산 웨이블릿 변환을 이용하여 저역통과 필터를 통해서 뇌파신호(A1~A5)와 고역통과 필터를 통과한 신호(D1~D5)로 각각 분할하여 처리하였다.

본 연구에서 제안한 뇌파의 분류법은 신경 전문의로 하여금 측두엽 뇌파의 발생부위와 어디로 전위되는지를 예측할 수 있고 뇌파의 정량적 해석과 진단의 객관성을 높일 수 있다. 또 진단에 소요되는 시간과 노력을 크게 절감시키는 이점을 기대할 수 있고 분류알고리즘으로 쉽게 구현이 가능한 FCM 방법을 이용하였기 때문에 정확한 분류가 가능하였다.

2. 간질파형과 데이터 획득

EEG 극파는 20~70 ms의 지속시간을 가진 파형으로, 정상 파형과 쉽게 구분이 가능하다. 극파는 독립적으로 일어날 수 있으나 종종 150~300 ms 지속되는 서파가 동반하여 극파와 예파의 복합파를 형성한다. 그리고 간질파와 다른 특성을 가진 수면뇌파는 뇌의 발달에 따라 변화하기도 하지만 각성시의 뇌 성숙도에 따른 변화보다는 상대적으로 덜 복잡하기 때문에 수면뇌파에서는 개인차가 감소하며 모든 사람이 유사한 수면뇌파를 보인다.

본 연구에서 사용된 EEG 데이터는 영남의료원 획득한 뇌파로서 임상실험을 통해서 획득된 데이터이며, 신경정신과 전문의에 의해 측두엽성 간질파와 수면뇌파로 판정된 것이다. 뇌파획득을 위한 전극법은 10-20 시스템이며, 그림 1에서 나타내고있다. 그림 2에서 간질파와 수면뇌파를 얻기 위해 (주)Stellate 시스템에서 개발한 하모닉 시스템을 사용하였다. 16채널에서 뇌파를 수집하였으며, IIR 필터와 노치 필터의 주파수 대역







그림 1. 10-20 전극 배치법
Fig. 1. Electrodes according in 10-20.




(a) Fp1



(b) O1



(c) T5



(d) 수면4단계 뇌파

그림 2. 간질파와 수면뇌파
Fig. 2. Epileptic seizures and sleep EEG.

범위는 각각 0.5~25 Hz와 57~63 Hz의 주파수 범위를 두어서 필터링(filtering)했다. 샘플링 시간은 200 Hz을 사용하였다. 뇌파획득을 위한 전극의 위치는 전두엽, 두정부, 측두엽과 후두엽 부분의 뇌파를 이용하였다.

3. 신호분석과 분류법

웨이블릿 해석은 연속신호와 이산신호의 경우에 모

두 적용될 수 있으며 다양한 분야에서 그 응용 가능성을 인정받고 있다. 웨이블릿 변환이 고전적인 푸리에 변환과 구별되는 근본적인 차이점은 단구간 푸리에 변환의 경우 모든 주파수 대역에 대하여 동일한 크기의 필터 윈도우를 사용하는 반면 웨이블릿 변환은 고주파 대역에서는 폭이 좁은 윈도우를, 저주파 대역에서는 폭이 넓은 윈도우를 사용한다는 것이다. 따라서 웨이블릿 해석은 상대 대역폭 불변해석이라고도 말하며, 주파수 대역의 변화 폭은 항상 주파수 값에 비례한다.

푸리에 변환이 주어진 신호를 사인(sine)과 코사인(cosine) 기저함수(basic function)를 이용하여 표현하는 것과는 달리 웨이블릿 변환은 일정한 시간-주파수 정보를 가지는 기저함수로 표현한다. 그래서 푸리에 변환이 정제된 신호(stationary signal) 해석에 유리한 반면에 웨이블릿 변환은 간질과와 같은 비 정제적 신호(non-stationary signal) 해석에 이점이 있다. 웨이블릿 변환에 사용되는 기저함수로는 스케일링(scaling) 함수와 마더 웨이블릿(mother wavelet)이 있으며 마더 웨이블릿은 다음 식 (1)과 같이 표현된다.

$$\Psi_{\alpha, \tau} = \Psi\left(\frac{t-\tau}{\alpha}\right) \tag{1}$$

여기서, α 는 스케일링 파라미터(scaling parameter)이며, τ 는 천이 파라미터(translation parameter)이며, $\alpha^{1/2}$ 은 정규화 인자(normalization factor)이다.

웨이블릿 변환은 연속 웨이블릿 변환(CWT: continuous wavelet transform)과 이산 웨이블릿 변환(DWT: discrete wavelet transform)으로 분류한다.

이산신호(discrete signal) $s(t)$ 에 대한 연속시간 영역에서 연속 웨이블릿 변환은 다음 식 (2)과 같이 주어진다.

$$CWT(\alpha, \tau) = \frac{1}{\sqrt{\alpha}} \int s(t) \Psi^* \left(\frac{t-\tau}{\alpha} \right) dt \tag{2}$$

식 (2)에서 스케일 파라미터와 천이 파라미터가 각각 $\alpha = 2^m$, $\tau = n 2^m$, $m, n \in$ 정수로 주어질 때 이산 웨이블릿 변환은 식 (3)과 같이 얻어진다.

$$DWT(m, n) = 2^{-\frac{m}{2}} \sum s(k) \Psi \left(2^{-\frac{m}{2}} k - n \right) \tag{3}$$

위의 식에서 알 수 있듯이 이산 웨이블릿은 연속 웨이블릿을 샘플화하여 변형시킨 형태로 표현된다.

웨이블릿 변환을 이용한 간질 파형 검출 연구는 주로 신경망(neural network)으로 많은 연구¹⁷⁾가 이루어지고 있다. 신경망을 이용한 분류과정으로는 입력층, 은닉층, 출력층과 BP 알고리즘으로 구현된다. 계산과




그림 3. 웨이블릿의 시간-주파수영역 window
Fig. 3. Time-frequency domain window of wavelet.

정이 복잡하고 초기설정과정에 잘못 설정되면 학습시간이 많이 소용되고, 오류 등이 발생할 수 있다. 따라서 구현방법이 까다롭고, 학습시간이 많이 소요되는 단점을 가지고 있다. 반면에 웨이블릿을 이용한 FCM 클러스터링(clustering) 방법은 각각의 데이터 점을 소속 정도에 의해서 클러스터에 대한 데이터의 소속 정도를 일일이 열거한 데이터 분류 알고리즘으로서 정확도와 구현방법이 간단하다는 장점을 가지고 있다.

아래 그림 3은 본 연구에서 사용된 웨이블릿의 시간-주파수영역에 사용한 window이다.

3.1. FCM(Fuzzy C-Means) Clustering Method

클러스터링 방법(clustering method)은 데이터 분류를 위해서 사용되는 것으로 데이터의 내부가 비슷한 패턴, 속성, 형태 등의 기준을 통해 데이터를 분류하여 내부의 구조를 찾아내는 것이다. 클러스터링에서 가장 먼저 결정해야 될 것이 클러스터 개수이다. 일반적으로 n 개의 데이터로 구성된 집합 안의 클러스터개수는 클러스터가 2개 이상 n 개 미만이어야 한다. 클러스터의 개수는 데이터에 따라 적절한 개수를 선택해 주어야 한다. 본 연구의 클러스터 수는 5개를 사용한다.

FCM(Fuzzy C-Means) 클러스터링(clustering) 방법은 하나의 클러스터에 속해져 있는 각각의 데이터 점을 소속 정도에 의해서 클러스터에 대한 데이터의 소속 정도를 일일이 열거한 데이터 분류 알고리즘이다. Bezdk^{18,9)}은 초기 HCM(Hard C-Means) clustering을 개선하기 위해서 $i = 1, \dots, n$ 의 집합을 c 개의 퍼지 그룹들로 분할하고, 비유사성 측정의 비용함수가 최소가 되는 것과 같은 각각의 그룹 안에서 클러스터의 중심을 찾

는다. FCM 클러스터링 방법은 0과 1 사이의 소속정도에 의해서 나타난 소속감의 정도를 가지고 주어진 데이터 점이 몇 개의 그룹에 속할 수 있다는 퍼지 분할을 사용한다는 점이다. 즉 퍼지 분할을 적용하기 위해서 소속함수는 0과 1 사이의 값을 가지는 요소들을 가진다. 그러나 데이터 집합에 대한 소속감 정도의 합은 식 (4)와 같이 항상 1이다.

$$\sum_{i=1}^c U_{ik}, \forall k=1, \dots, n \quad (4)$$

$$0 < \sum_{k=1}^n U_{ik} < n \quad (5)$$

FCM 클러스터링에 대한 비용함수는 다음과 같이 식 (6)의 형태를 가진다.

$$J(U_{ik}, V_i) = \sum_{i=1}^c \sum_{k=1}^n U_{ik}^m (d_{ik})^2 \quad (6)$$

$$d_{ik} = d(X_k - V_i) = \left[\sum_{j=1}^L (X_{kj} - V_{ij})^2 \right]^{1/2} \quad (7)$$

$$V_i = \{V_{i1}, V_{i2}, \dots, V_{ij}, \dots, V_{iL}\} \quad (8)$$

여기서, U_{ik} 는 0과 1 사이의 수적인 값으로 i 번째 클러스터에 속해져 있는 X_k 의 k 번째 데이터의 소속정도를 나타낸다. V_i 는 i 번째 클러스터 중심 벡터이다. $j(j = 1, 2, \dots, L)$ 는 특성 공간상의 변수이다. m 은 소속함수의 퍼지성(애매함)의 정도에 대한 영향을 나타내는 지수의 가중치이다. 이 값은 $m \in (1, \infty)$ 와 같은 범위를 가지고 있으며, 분류공정에서 퍼지성의 양을 제어하는 파라미터이다. 보통 m 은 2로 설정한다. 식 (6)의 목적함수를 최소화하기 위해서 먼저 V_i 와 U_{ik} 와 관련된 식 (6)의 목적함수를 분화시켜야 한다.

$$V_{ij} = \frac{\sum_{k=1}^n (U_{ik})^m X_{kj}}{\sum_{k=1}^n (U_{ik})^m} \quad (9)$$

$$U_{ik} = \frac{(1/\|X_k - V_i\|^2)^{1/m-1}}{\sum_{j=1}^c (1/\|X_k - V_j\|^2)^{1/m-1}} \quad (10)$$

식 (9)와 (10)에 의해서 묘사되어진 시스템은 분석적으로 해결할 수 없다. 그러나 FCM 클러스터링 알고리즘은 주어진 위치로부터 시작해서 목적함수의 최소로 접근하기 위해서 반복적으로 접근한다. FCM 클러스터

링 알고리즘을 요약하면 다음과 같다.

3.2. FCM 클러스터링 알고리즘

[단계 1] 클러스터의 개수 $c(2 \leq c < n)$ 을 정하고 지수의 가중 $m(1 < m < \infty)$ 을 선택한다. 초기 소속함수를 초기화한다. 알고리즘 반복횟수를 $r(r=0, 1, 2, \dots)$ 로 표시한다.

[단계 2] 식 (6)을 이용하여 퍼지 클러스터 중심 $\{V_i | i=1, 2, \dots, c\}$ 을 계산한다.

[단계 3] 다음과 같이 새로운 소속함수 $U^{(r+1)}$ 을 계산한다.

$$U_{ik}^{(r+1)} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}^{(r)}}{d_{jk}^{(r)}} \right)^{2/m-1}} \quad \text{for } I_k = \Phi$$

여기서, $I_k = \{i | 2 \leq c < n; d_{ik}^{(r)} = 0\}$ 이고 $\bar{I}_k = \{1, 2, \dots, c\} - I_k$ 이다. 그리고 $\sum_{i \in I_k} U_{ik}^{(r+1)} = 1$ 이다.

[단계 4] 다음 식을 계산하면 만일 $\Delta > \epsilon$ 이면 $r=r+1$ 로 정하고 [단계 2]로 가서 다시 알고리즘을 반복 수행하고 그렇지 않고 $\Delta \leq \epsilon$ 이면 알고리즘을 종료한다.

여기서 ϵ 는 임계값

$$\Delta = \|U^{(r+1)} - U^{(r)}\| = \max_{i,k} |U_{ik}^{(r+1)} - U_{ik}^r|$$

본 연구의 FCM 클러스터링 방법은 가장먼저 초기 소속함수를 정의해야 하며 다음으로 각 클러스터에 대한 중심 벡터를 계산한다. 세 번째로는 각 데이터들과 클러스터 중심과의 거리를 구한 후 새로운 퍼지 소속도함수를 구함으로써 차이를 비교할 수 있다. 마지막으로 주어진 임계값과의 크기를 비교함으로써 종료한다. 모의실험결과 학습률이 높으면 분류성공률이 높음을 실험을 통해서 확인하였다.

4. 실험결과 및 고찰

본 연구에서 사용된 EEG 데이터는 영남의료원에서 측두엽성 간질 판정을 받은 31세 성인환자를 기준으로 실험했다. 간질의 출현부위를 예측하기 위해서 뇌의 전두엽, 두정부, 측두엽과 후두엽 부위의 극파 발생전의 주파수와 극파 발생후의 주파수를 비교 분석하여 간질의 시작부위와 진행방향을 예측한다. 그리고 간질파와 다른 특성을 가진 뇌파를 비교할 수 있는 수면뇌파 등을 이용하여 본 연구에서 제안된 FCM 클러스터 분류 실험을 한다. FCM에 필요한 클러스터는 간질뇌파 패턴을 4개, 수면뇌파 패턴을 1개 설정하여 전체 5개로





그림 4. 간질파와 수면뇌파의 주파수영역비교


Fig. 4. Compare of frequency domain for epileptic seizures and sleep EEG.

정하여 실험한다. 그림 4는 각 전극부위의 간질파를 주파수영역으로 분석한 것인데 극파가 발생하기 전의 주파수와 발생후의 주파수를 비교한 것이다. 극파가 발생하기전의 주파수는 서파(slow wave)의 특성을 나타냈으며, 진폭은 측두엽 부분의 T5에서 가장 크게 나타남을 알 수 있다. 그리고 간질의 진행방향은 극부적으로 나타남을 확인할 수 있다. 그림 5는 측두엽 부분의 뇌


파를 웨이블릿 분해 해석한 것으로서 본 연구의 다비치 family중 db10을 이용하여 시간-주파수 영역으로 5레벨로 해석한 결과이다. 뇌파는 5단계의 주파수 대역 신호 즉, 이산 웨이블릿 변환을 이용하여 저역통과 필터를 통해서 뇌파신호(A1~A5)와 고역통과필터를 통과한 신호(D1~D5)로 각각 분할하여 처리한 결과이다. 본 논문에서 가장 상세한 주파수 범위는 3.0625~6.125 Hz




(a) T5 웨이블릿 분해




(g) T5 D3




(b) T5 A1




(h) T5 A4




(c) T5 D1




(i) T5 D4




(d) T5 A2




(j) T5 A5



(e) T5 D2



(k) T5 D5



(f) T5 A3

그림 5. 웨이블릿 분해해석
Fig. 5. Analysis of wavelet decomposition.




그림 6. 간질과 수면뇌파의 D5 비교
Fig. 6. Compare of D5 epileptic seizures and sleep EEG.

를 가진다. 그림 6은 웨이블릿 변환을 고주파영역으로 D5로 분할한 것으로서, 패턴을 기준으로 전두엽, 측두엽과 후두엽 부분을 분석한 결과이며 각 패턴은 FCM 클러스터링 소속도 함수로 사용하였다. 그림 7은 수면 1단계 뇌파를 이용한 웨이블릿 주파수 분할한 결과로서 간질파와 비교 시 현격한 차이를 구별할 수 있었다. 표 1은 FCM 알고리즘을 이용한 실험결과로서 각 패턴에 대한 소속도함수의 각 cluster의 overlap 정도를

나타낸 결과이며, m 을 2로 설정했을 때에 패턴에 대한 클러스터의 값이 1에 가장 가까울수록 그 패턴은 클러스터에 속하게됨을 알 수 있다. 또 m 의 값에 따라서 각 클러스터에 대한 overlap의 정도의 차이로 값이 바뀔 수 있다. 그림 8은 각 전극에 대한 간질파 패턴을 가지고 FCM 분류실험 한 결과이며 각 클러스터에 대한 분류실험결과는 유사한 결과를 나타내었으며 분류성공률이 평균 95% 이상 정확도를 나타내었다. 표 1의 소속도 함수에서 나타낸 결과에서와 같이 각 클러




그림 7. 수면 1단계 웨이블릿 분해
Fig. 7. Sleep stage1 of wavelet decomposition.

표 1. $m=2$ 소속도 함수

Table 1. Membership function of $m=2$

Pattern #	Cluster 1	Cluster 2	Cluster 3	Cluster 4	Cluster 5
0	0.97	0.00	0.02	0.01	0.00
1	0.01	0.96	0.02	0.00	0.01
2	0.97	0.01	0.00	0.02	0.00
3	0.00	0.01	0.97	0.02	0.01
4	0.01	0.02	0.00	0.96	0.01
5	0.98	0.00	0.02	0.00	0.00
6	0.00	0.00	0.97	0.02	0.01
7	0.00	0.95	0.02	0.03	0.00
8	0.00	0.01	0.98	0.01	0.00
9	0.03	0.01	0.00	0.001	0.96
10	0.00	0.97	0.01	0.02	0.00




그림 8. FCM 분류실험결과

Fig. 8. Result of FCM classification experiment.

스터에 결과치가 만족한 학습률을 기록하였기 때문에 측두엽에서 발생한 간질을 이용한 실험에서 간질뇌파가 어떤 부위에서 발생한 뇌파인지 또는 다른 특성을 가진 뇌파와 간질파의 정량적 해석과 진단의 객관성을 높일 수 있다. 또 진단에 소요되는 시간과 노력을 크게 절감시키는 이점을 기대할 수 있다.

5. 결 론

본 연구는 간질뇌파를 가지고 간질의 출현부위와 진행될 부위를 예측하는 알고리즘을 개발하였다. 간질파와 다른 특성을 가진 수면뇌파와의 비교를 통해서 간질파의 특성을 분석한다. 분석법과 분류법은 웨이블릿 변환법과 FCM 클러스터링을 이용하여 분류한다. 분석한 결과 신호의 파형 모양과 주파수 특성이 다른 것을 알 수 있었다. 따라서 간질파와 다른파를 구분하기 위해서 FCM을 이용해서 분류하는 실험을 하였다. 제안된 시스템은 웨이블릿에 의한 주파수 해석의 정확한 분석과 FCM을 이용한 분류가 95% 이상 가능함을 보였다. 임상전문가들이 이 방법을 이용한다면 손쉽게 간질파와 다른 파형을 분류하는데 도움이 될 것을 생각

된다. 또한 모의실험결과를 통해서 의사의 노동력을 줄일 수 있고 뇌파를 정량적으로 해석이 가능하며 쉽게 분류가능 할 것으로 생각된다. 본 연구를 통해서 뇌파 특성이 워낙 다양함을 알 수 있었고, 다양한 형태의 뇌파데이터를 이용한 알고리즘이 개발되어야 할 것이다.

참고 문헌

- [1] D. J. Koffler and J. Gotman, "Automatic detection of spike-and-wave bursts in ambulatory EEG recordings", *Electroenceph and Clin Neuroph*, vol. 76, pp. 317-324, 1985.
- [2] J. Gotman, "Automatic seizure detection: Improvements and evaluation", *Electroenceph and Clin Neuroph*, vol. 76, pp. 317-324, 1990.
- [3] L. D. Iasemidis, "Epileptic seizure prediction and control", *IEEE Trans. Biomedical Eng.*, vol. 50, pp. 549-558, 2003.
- [4] M. D. Alessandro and R. Esteller, "Epileptic seizure prediction using hybrid feature selection over multiple intracranial EEG electrode contacts", *IEEE Trans. Biomedical Eng.*, vol. 50, pp. 603-615, 2003.
- [5] M. Vetterli and C. Herley, "Wavelets and filter: Theory and design", *IEEE Trans. Signal Proce.*, vol. 40, pp. 2207-2231, 1992.
- [6] I. Daubechies, "Orthogonal bases of compactly supported wavelets", *Comm. Pure Appl. Math.*, vol. XLT, pp. 909-996, 1988.
- [7] 박현석, 이두수, 김광일, "웨이브렛과 신경 회로망을 이용한 EEG의 간질 파형 검출", *대한전자공학회*, 제35권, 제3호, pp. 70-78, 1998.
- [8] L. Bobrowski and J. C. Bezdek, "C-means clustering with the L1 and L ∞ norms", *IEEE Trans. on Systems Man and Cybernetics*, vol. 21, pp. 545-554, 1991.
- [9] T. A. Runkler and J. C. Bezdek, "Alternating cluster estimation: a new tool for clustering and function approximation", *IEEE Trans. on Fuzzy Systems*, vol. 7, pp. 377-393, 1999.

김민수

- [센서학회지 제12권 제6호] 논문 2003-12-6-08, p. 297 참조
- 1967년 2월 10일생
- 1996년 영남대학교 전자공학과(공학석사)
- 1996 ~ 1998년 (주)효성근무
- 2004년 영남대학교 전자공학과(공학박사)
- 주관심분야 : 생체신호처리, 신경망, 퍼지

서희돈

- [센서학회지 제5권 제1호] 논문 95-5-1-07, p. 43 참조
- 1946년 9월 25일생
- 1973년 영남대학교 전자공학과(공학사)
- 1987년 일본 동북대학교 졸업(공학박사)
- 1973 ~ 1980년 삼성전자
- 1987년 ~ 현재 영남대 전자정보공학부 교수
- 주관심분야 : 집적화 가속도 센서
- 센서의 집적화 의공학(DNA칩, Bio-MEMS), 식각기술