

# 시스템잡음에 강건한 SOM-TVC 기법을 이용한 근전도 패턴 인식에 관한 연구

論 文  
54D-6-10

## A Study on the EMG Pattern Recognition Using SOM-TVC Method Robust to System Noise

金仁洙\* · 李眞\*\* · 金成煥†  
(In-Soo Kim · Jin-Lee · Sung-Hwan Kim)

**Abstract** - This paper presents an EMG pattern classification method to identify motion commands for the control of the artificial arm by SOM-TVC(self organizing map - tracking Voronoi cell) based on neural network with a feature parameter. The eigenvalue is extracted as a feature parameter from the EMG signals and Voronoi cells is used to define each pattern boundary in the pattern recognition space. And a TVC algorithm is designed to track the movement of the Voronoi cell varying as the condition of additive noise. Results are presented to support the efficiency of the proposed SOM-TVC algorithm for EMG pattern recognition and compared with the conventional EDM and BPNN methods.

**Key Words** : EMG Pattern Recognition, Neural Network, Eigenvalue, Additive Nnoise and SOM-TVC

### 1. 서 론

신체 동작 기능의 일부를 대신하는 인공 보장구(artificial prosthesis)를 위한 제어기의 설계를 위해서는 근육에서 취득한 근전도 신호를 해석하여 인간의 행동의사를 알아내는 동작 인식(motion recognition) 알고리즘(algorithm)이 핵심적인 역할을 담당한다. 이러한 동작인식 알고리즘은 근전도 신호로부터 추출한 특정 파라미터(feature parameter)로 서로 다른 동작 패턴(pattern)을 표현한 다음 적절한 패턴 인식 기법을 적용하여 이들 패턴들 간의 차이를 구별하여 각각의 동작에 해당되는 출력 패턴을 결정하는 방법으로 구성된다. 그러므로 인공 보장구 시스템의 성능은 위의 알고리즘에 의해 결정된 제어신호에 의해 결정적으로 좌우되며 최근 들어 이에 대한 연구가 활발히 진행되고 있다[1]-[6].

지금까지 이러한 동작인식을 위한 특정 파라미터로는 AR(auto-regressive) 계수나 쉐스트럼(cepstrum) 계수[1]-[3], 시간-주파수 변환 계수[4] 및 분산, 영점교차와 같은 시간평균 계수[5][6] 등이 일반적으로 사용되었다. 그러나 이러한 파라미터들은 잡음에 상당히 취약한 특징을 가지고 있으며 실제

인공 보장구를 인체에 부착하여 사용할 때 많은 잡음에 노출됨을 감안하면 특정한 환경에서만 적용 가능하다는 단점이 있다. 또한 서로 다른 동작 패턴을 표현하는 특정 파라미터를 입력으로 하여 각 동작에 대한 패턴을 구별해주는 대표적인 인식 알고리즘으로는 K-NN(K-Nearest Neighborhood)[8]과 신경회로망(neural network)을 적용한 BPNN(backpropagation neural network)[2][10] 및 SOM(Self Organizing Maps)-BPNN[9]을 들 수 있다. 그러나 K-NN은 알고리즘이 단순한 구조를 가지는 장점이 있지만 복잡한 파라미터 분포에 대해서는 성능이 떨어지는 단점이 있으며[2], BPNN은 입력 특징 파라미터 공간의 차원이 증가하면 신경 회로망의 복잡도가 기하급수적으로 증가하게 되기 때문에 성능과 속도 면에서 상당한 저하를 가져온다는 단점이 있다[10]. 또한 이러한 문제의 해결을 위해 Huang[9]등이 제안한 SOM-BPNN은 입력 파라미터의 차원이 증가하더라도 성능과 속도 면에서 좋은 결과를 보여주었지만 특정 파라미터가 외부 잡음에 의해 그 특징이 변하게 되면 인식이 현저하게 저하되는 특성을 나타내었다.

본 연구에서는 팔목 절단환자를 위한 인공의수(prosthetic hand) 제어를 위해 새로운 동작 인식 알고리즘을 제안하였다. 기존의 특정 파라미터들과 패턴 분류 알고리즘이 잡음에 취약하다는 공통된 단점을 해결하기 위하여, 제안된 알고리즘은 고유값(eigenvalue)을 특정 파라미터로 하여 각 동작 신호 패턴에 대한 보로노이셀(Voronoi cell)[15]을 패턴 인식 공간에서 정의한 다음, 잡음에 노출되어 보로노이셀의 공간상의 위치가 변할 때에도 그 양상을 추적하여 분류할 수 있도록 고안

† 교신저자, 正會員 : 서울시립대학 전자전기컴퓨터공학부 교수  
E-mail : shkim1@uos.ac.kr

\* 學生會員 : 서울시립대학 전자전기컴퓨터공학부 석사과정

\*\* 正會員 : 삼척대학교 제어계측공학과 교수

接受日字 : 2005年 3月 31日

最終完了 : 2005年 4月 15日

한 SOM-TVC (Tracking Voronoi Cells) 신경회로망 알고리즘으로 구성되었다.

제안한 알고리즘의 평가를 위하여 아래팔에 위치한 4개의 근육에서 6가지 손목 관절 동작 시 취득한 근전도 신호를 가지고 수행한 동작인식 실험의 결과를 타 연구자의 방법과 비교하여 나타내었다.

2. 새로운 SOM-TVC 패턴인식 알고리즘 제안

본 연구에서는 인공의수 제어를 위한 동작 인식 기법으로 다음과 같이 근전도 신호의 고유값(eigenvalue)을 특징 파라미터(feature parameter)로 하여 SOM-TVC 신경회로망으로 패턴의 위치를 추적하는 새로운 알고리즘을 제안 하였다.

먼저 가우시안(Gaussian) 분포를 갖는 확률과정(random process)이며, 평균 0 인 근전도 신호 행렬  $\mathbf{x}$ 를 식 (1)로 정의하자.

$$\mathbf{x} = \begin{bmatrix} x(k) & x(k-1) & \dots & x(k-m+1) \\ x(k-1) & x(k-2) & \dots & x(k-m) \\ \vdots & \vdots & \ddots & \vdots \\ x(k-n+1) & x(k-n) & \dots & x(k-n-m+2) \end{bmatrix} \quad (1)$$

여기서  $k$ 는 시간 인덱스,  $m$ 은 샘플 수,  $n$ 는 샘플 함수의 개수를 각각 나타낸다. 식 (1)을 바탕으로 고유값 분해(eigenvalue decomposition)[7]를 통해 식(2)와 같이 근전도 신호 행렬  $\mathbf{x}$ 의 공분산 행렬,  $\mathbf{C}_x$ 를 구할 수 있다.

$$\mathbf{C}_x = E[\mathbf{xx}^T] = \mathbf{E}\mathbf{D}\mathbf{E}^T = \sum_{i=1}^n \lambda_i \mathbf{e}_i \mathbf{e}_i^T \quad (2)$$

여기서  $E$ 는 기댓값(expectation) 연산자,  $\mathbf{E}$ 는  $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_n$ 을 갖는 직교 행렬(orthogonal matrix),  $\mathbf{D} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$ 인 대각 행렬(diagonal matrix),  $\lambda_i$ 는 고유값을 각각 나타낸다.

본 연구에서는 식(2)와 같이 구한 고유값이 기존의 인공의수 제어를 위해 사용되었던 특징 파라미터인 AR 계수[2][10]나 캡스트럼 계수[1][3] 등에 비하여 부가 잡음에 대해 효율적으로 동작 패턴을 표현할 수 있음을 실험을 통해 확인하였고, 이를 특징 파라미터로 패턴인식을 시도하였다.

다음으로 이렇게 구한 고유값을 특징 파라미터로 하여 패턴인식을 위한 신경회로망으로 SOM(Self Organizing Maps) 학습 알고리즘을 적용하였다. Kohonen[12]이 제안한 SOM은 비지도 학습 알고리즘으로 승자 뉴런(neuron)을 중심으로 1, 2차원 혹은 그 이상의 차원으로 정돈된 이웃뉴런으로 구성된 신경회로망이다. 일반적인 신경회로망의 경쟁학습에서 뉴런들은 승자뉴런을 결정하고, 승자뉴런의 가중치 값만을 갱신하는 winner-takes-all 방식을 취하는 반면, SOM은 승자 뉴런의

가중치 벡터 뿐 아니라 이웃뉴런의 가중치 벡터까지 갱신한다. 학습이 진행되는 동안 승자뉴런과 이웃하는 뉴런들은 비슷한 가중치 벡터를 갖게 되고 결과적으로 유사한 입력 벡터에 반응하게 된다는 특징을 갖는다.

이와 같은 SOM을 학습시키기 위해서는 분류할 신호로부터 추출한 특징 파라미터들을 군집화하여 특징 파라미터 공간에서 각 동작 패턴에 대해 경계 영역(pattern boundary)을 정의해 주어야한다. 이를 위하여 본 연구에서는 각 동작 패턴의 특징 파라미터 공간상의 분포 영역을 보로노이 셀[15]을 이용해 정의하였다.

그림 1에 본 연구에서 분류를 시도한 손목 관절 운동의 6개 동작 신호에 대해 특징 파라미터인 고유값의 분포와 이를 군집화시켜 각 동작 패턴의 경계영역을 정의한 보로노이 셀의 모양을 각각 나타내었다.

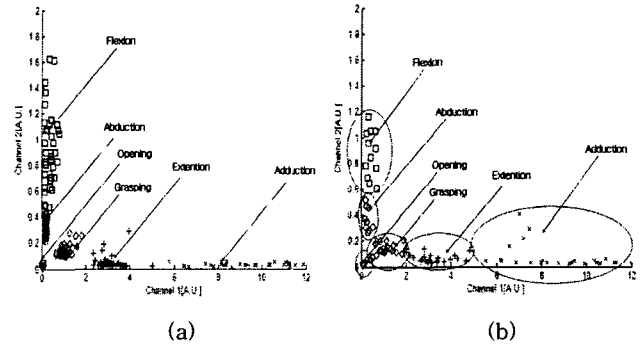


그림 1. 패턴인식 평면에서 6개 동작에 대한 근전도 신호 패턴 분포(모음:adduction, 벌림:abduction, 굽힘:flexion, 폼: extension, 찮:grasping, 펼침:opening의 손목 관절 동작) (a) 특징 파라미터 분포 (b) 보로노이 셀로 구성한 패턴 경계

Fig 1. Distribution of EMG signal patterns from the 6 movements in the pattern plane (Movement of wrist joint of the adduction, abduction, flexion, extension, grasping and opening) (a) Distribution of feature parameters (b)Pattern boundary by Voronoi cells

그림 1(a)는 근전도 수집시스템의 채널 1과 채널 2에서 출력된 6개 동작에 대해 각 100번씩 총 600번의 근전도 신호를 실험하여 각각의 고유값( $\lambda_i$ )을 구하고, 이를 x축과 y축 좌표로 하여 구성한 패턴인식 평면에서 특징 파라미터의 분포를 나타낸 것이다. 서로 다른 동작에 대해 고유값의 분포가 특정한 영역에 형성됨을 알 수 있다.

그림 1(b)는 이러한 특징 파라미터의 분포를 바탕으로 각 동작 패턴에 대한 경계영역을 정의해주기 위하여 그림 1(a)의 값을 입력으로 하여 SOM을 학습시킨 후 가중치 벡터(weighting vector)[15]를 구하여 형성한 보로노이 셀의 모양

을 나타내었다. 이와 같이 형성한 보로노이 셀은 패턴인식 공간에서 각 동작 패턴의 영역을 나타내는 기준으로 적용된다.

다음으로 이렇게 정의한 보로노이 셀을 바탕으로 근전도 신호가 잡음에 노출되어 셀의 공간상의 위치가 변하였을 때 적응적으로 기준 동작을 찾아가도록 하는 추적 알고리즘을 고안 하였으며 이를 TVC (Tracking -Voronoi Cell) 알고리즘이라 명명 하였다.

TVC 알고리즘의 개발은 수차례의 실험을 통해 근전도 신호로부터 추출하여 각 동작 패턴에 대한 특징 파라미터로 고유값을 사용하여 구성한 보로노이셀의 위치가 잡음의 오염 정도에 따라 일정한 방향으로 변화한다는 사실의 발견으로부터 이루어졌다. 즉 보로노이 셀의 패턴인식 공간에서의 위치가 부가 잡음의 오염 정도에 따라 일정한 방향으로 이동하며, 각 동작에 대한 공간상의 상대적인 위치는 일정하게 유지됨을 반복된 실험을 통하여 알 수 있었다. 이러한 보로노이 셀의 위치 변화에 대한 발견을 토대로 잡음에 강건하게 동작 패턴을 추적할 수 있도록 새롭게 고안된 TVC 알고리즘은 다음 단계로 이루어졌다.

- 1) 비교 패턴과 가중치 벡터들과의 공간상의 거리를 구한다.
- 2) 비교 패턴을 추적률( $\alpha=0.5$ )만큼 공간상의 위치를 옮긴다.
- 3) 1)과 2)번을 M번 반복하여 각각의 결과 값을 저장한다.
- 4) 3)에서 얻은 결과 값에서 공간상의 거리가 가장 짧은 가중치 벡터를 찾는다.
- 5) 4)에서 찾은 가중치 벡터의 보로노이셀을 비교패턴의 출력으로 결정한다.

### 3. 실험 방법

본 연구에서는 실험을 위해 제작한 개인용 컴퓨터 기반 근전도 시스템을 통해 4 채널 근전도 신호를 동시에 기록하였다. 손목 관절을 움직이는데 중요하게 관여하는 아래팔에 위치하는 4개의 근육을 선정하여[13], 채널 1은 손가락폄근(Extensor digitorum muscle), 채널 2는 자쪽손목폄근(Extensor carpi ulnaris muscle), 채널 3은 자쪽손목굽힘근(Flexor carpi ulnaris muscle), 채널 4는 노쪽손목굽힘근(Flexor carpi radialis muscle)에 각각 표면전극을 부착하였다. 그리고 손바닥의 모음(adduction)과 벌림(abduction) 운동, 굽힘(flexion)과 폄(extention) 운동, 손바닥 쥐(grasping)과 펼침(opening) 운동의 6개 동작 시에 근전도 신호를 각각 수집하였다. 실험을 위한 피검자는 20대 후반의 건강한 성인남자 3인(JCK:29세, KWH:28세, KIS:28세)을 대상으로 하였으며, 하나의 동작을 15초간 유지하며 각각 10번 실험, 기록하였다. 또한 각 동작 사이에 충분한 휴식을 취해 근육의 피로에 의해 발생될 수 있는 패턴의 변화를 최소화 하였다.

표면전극 으로부터 취득된 근전도 신호는 15-450[Hz] 대역 통과 필터를 거친 후, 1000배 증폭하였으며, 4096[Hz]의 샘플링 주파수로 A/D 변환 한 후 USB를 통해 PC의 하드디스크에 저장하였다. 이렇게 15초씩 수집된 근전도 데이터는 앞부분에 3초 뒷부분에 2초를 제거하여 안정된 상태일 때의 데이터만을 취한 다음, 250[ms]의 구간 신호를 1개의 시험 패턴으로 하여 각 패턴들이 어떤 동작에 해당되는지 판단하는 패턴인식에 적용하였다. 그러므로 각 동작에 대해 1번 실험 시도 시 40개의 시험 패턴이 생성되며, 10번의 반복된 실험으로 총 400개(6개 동작, 총 2400개)의 패턴인식을 위한 시험 패턴을 취득하였다.

### 4. 실험 결과 및 고찰

그림 2에 6가지의 손목 운동 동작 시 4채널로 동시에 기록한 근전도 신호의 일부분을 예로 나타내었다. 이 그림은 15초간 각 동작을 유지하며 4-ch로 기록한 6가지 손목 운동 동작 시의 근전도 신호를 1초 부분만으로 조합하여 구성한 것이다.




그림 2. 6개 손목 관절 동작에 대한 4-채널 근전도 신호 (AB:벌림, AD:모음, EX:폄, FL:굽힘, GR:쥐, OP:펼침)

Fig. 2. 4-ch EMG signal recorded during 6 movements of the wrist joint (AB:abduction, AD:adduction, EX:extension, FL:flexion, GR:grasping, OP:opening)

위 그림을 통해 각 동작을 위해 사용되는 근육과 그들의 기여도가 다르기 때문에 근전도 신호의 진폭이 다르게 나타나며, 하나의 동작을 위해 1개 또는 2개 이상의 근육이 서로 조합되어 사용됨을 알 수 있다.

이렇게 수집한 근전도 신호를 대상으로 고유값을 특징 파라미터로 추출하여 새롭게 제안한 SOM-TVC 알고리즘으로 6개의 손목관절 운동을 구별하기 위한 패턴인식을 시도하였다.

먼저 본 연구에서 인공의수를 위한 근전도 신호 인식을 위해 특징 파라미터로 적용한 고유값의 부가 잡음에 대한 특성

을 분석하였다. 다음 표 1에 기준에 주로 사용된 특징 파라미터인 LPC[2][10], 켈스트럼 계수[1][3]와 본 연구에서 사용한 고유값의 잡음 크기에 따른 인식률(recognition rate)을 나타내었다. 이 결과는 피검자, KWH로부터 취득한 6개 동작에 대한 근전도 신호를 대상으로 각 동작 마다 400개 시험 패턴의 인식 실험을 각각 실시하여 평균 인식률을 나타낸 것이다. 또한 특징 파라미터만의 객관적인 비교 평가를 위해 패턴분류 알고리즘은 가장 기본적인 패턴 공간에서의 거리측정법인 EDM(Euclidean distance measure)[15]을 사용하였다. 잡음은 평균 0인 백색 가우시안 잡음(white Gaussian noise)을 발생시켜 부가하였으며, 신호 대 잡음 비(SNR : signal to noise ratio)는  $SNR = 20\log(\text{신호 분산/잡음 분산})$ 으로 정의하고, 부가 잡음의 편차( $\sigma$ )를 이용해 조절하였다

표 1. 3개 특징 파라미터의 부가잡음에 대한 인식률 비교(패턴분류 알고리즘 : EDM)

Table 1. Comparison of the recognition rate of 3 feature parameters to the additive noise (used pattern classification algorithm : EDM)

$\sigma$ (SNR[dB])	LPC(%)	Cepstrum(%)	Eigenvalue(%)
0.1(35)	99.9	99.2	96.1
0.2(22)	64.9	70.5	95.9
0.5(6.8)	20.5	40.1	95.3
1(-5.2)	16.7	16.7	64.0
2(-17)	16.7	16.7	33.3

위 실험 결과에서 보면  $\sigma=0.1$ 로 하여 발생시킨 잡음을 부가한, 즉 SNR=35[dB] 이상의 잡음에 대해서는 기존 특징 파라미터인 LPC나 켈스트럼 계수가 고유값 보다 약간 높은(약 2-3%) 인식률을 나타낸다. 하지만 SNR이 감소할수록 기존 파라미터들은 본 연구에서 시도한 고유값에 비해 인식률이 현저하게(약 25-75%) 떨어지는 것을 알 수 있다. 이러한 결과는 나머지 2명 피검자(JCK, KIS)의 실험 결과에서도 유사하게 나타났으며, 이는 고유값 자체가 인공의수를 위한 근전도 신호의 패턴 인식 시 기존의 특징 파라미터들보다 부가잡음에 강건한 특성을 갖는다는 것을 증명하는 결과이다. 그러나 SNR=-5[dB] 이하의 잡음에 대해서는 고유값과 EDM 알고리즘을 적용한 인식률이 많이 떨어지는 현상에 주목하자.

다음으로 표 2와 3에 본 연구에서 제안한 SOM-TVC 방법에 의해 6개 각 동작에 대해 패턴 인식하여 타 연구자의 방법과 비교한 실험 결과의 일부를 나타내었다.

표 2. EDM[13], BPNN[2][10], SOM-TVC[본 연구]의 패턴인식 결과( SNR=35[dB] )

Table 2. Pattern recognition result by EDM[13], BPNN[2] [10] and SOM-TVC[this paper] respectively.( SNR = 35[dB])

		EDM(%)						BPNN(%)						SOM-TVC(%)					
		AB	AD	EX	FL	GR	OP	AB	AD	EX	FL	GR	OP	AB	AD	EX	FL	GR	OP
AB	89	0	1.3	0	0	9.8	100	0	0	0	0	0	99.5	0	0	0	0	0	0.5
AD	1.8	92.8	5.5	0	0	0	0	97.5	2.5	0	0	0	0	97	3	0	0	0	0
EX	7.3	2.8	90	0	0	0	0	10	90	0	0	0	0	6.3	93.8	0	0	0	0
FL	0.3	0	0	68.8	0	31	0	0	0	90.3	6.8	3	0	0	0	94.5	3	2.5	0
GR	0	0	0	0	97	3	0	0	0	0	100	0	0	0	0	0	0	100	0
OP	0.3	0	0	0	0	99.8	0.3	0	0	0	0	0	99.8	1	0	0	0	0	99

표 3. EDM[13], BPNN[2][10], SOM-TVC[본 연구]의 패턴인식 결과 ( SNR=-5.2[dB] )

Table 3. Pattern recognition result by EDM[13], BPNN[2] [10] and SOM-TVC[this paper] respectively(SNR=-5.2[dB] )

		EDM(%)						BPNN(%)						SOM-TVC(%)					
		AB	AD	EX	FL	GR	OP	AB	AD	EX	FL	GR	OP	AB	AD	EX	FL	OP	OP
AB	91.8	0	8	0.3	0	0	100	0	0	0	0	0	98.8	0	0	0.3	0	1	
AD	0.3	96	3.8	0	0	0	4.5	95.5	0	0	0	0	0	97	3	0	0	0	
EX	1.5	5.3	93.3	0	0	0	62.8	5	32.3	0	0	0	0.3	6.3	93.5	0	0	0	
FL	6	0	0	83	7.3	3.8	0	0	0	100	0	0	0	0	0	90.7	2.3	0	
GR	0	0	0	0	100	0	0	0	0	0	100	0	0	0	0	0	0	100	0
OP	75.5	0	0	0	0	24.5	73.8	0	0	26.3	0	0	5.8	0	0	1	0	93.2	

이 결과는 각 채널에서 수집한 근전도 신호의 고유값( $\lambda_1$ )을 특징 파라미터로 추출한 다음 이를 분류 알고리즘의 입력으로 하여 EDM[13], BPNN[2][10], SOM-TVC[본 연구] 알고리즘으로 각 동작에 대해 패턴 인식하여 구성한 것이다. 객관적인 성능의 비교, 평가를 위해 수차례의 학습 실험을 반복하

여 근전도 패턴 인식에 최적의 성능을 내도록 각 알고리즘의 동작 초기조건을 선정하였으며 이를 실험 결과표의 상단에 표시하였다. 또한 각 표는 상단에 나타난 실험 조건을 바탕으로 SNR을 변화시키며 수행한 결과이며, BPNN과 SOM의 신경 회로망은 100개의 학습 파일을 이용해 학습시킨 후 각 동작에 대해 400개 시험패턴을 가지고 인식 실험한 것이다.

표 2의 결과는 편차,  $\sigma=0.1$ 로 발생시킨 잡음을 부가하여 실험한 400개의 시험패턴에 대한 인식률을 각 동작별로 타 연구자의 결과와 비교하여 나타낸 것이다. 즉 SNR=35[dB]의 부가 잡음 조건으로 신호전력의 크기가 잡음의 전력의 크기보다 약 100배 큰, 거의 부가잡음의 영향이 없는 경우로 볼 수 있다. 이 경우 EDM의 인식률은 많이 떨어지나, BPNN과 본 연구의 SOM-TVC는 유사하게 모든 동작에 대해 평균 95%이상의 인식률을 보인다는 사실을 알 수 있다. 또한 표 3의 결과는 SNR=-5.2[dB]의 부가 잡음 조건으로 실험한 것으로 EDM, BPNN의 경우는 모두 0% - 24.5%까지 인식률이 저하되나 SOM-TVC는 모든 동작 패턴에 대해 90% 이상의 높은 인식률을 유지하고 있음을 볼 수 있다.

위 표에 일부 결과를 나타낸 바와 같이 본 연구에서는 다양한 경우의 잡음 조건에 대해 3명의 피검자를 대상으로 동작 패턴 인식 실험을 실시하여 타 연구자의 결과와 비교해 보았다. 그 결과 부가 잡음이 없는 조건에서는 EDM, BPNN, SOM-TVC 모두 95% 이상의 인식률을 나타내었지만, 일정량 이상의 부가 잡음 조건에서는 EDM, BPNN의 성능은 현저하게 저하되나 본 연구에서 제안한 SOM-TVC 알고리즘은 일정한 성능을 유지함을 증명할 수 있었다.

다음으로 그림 3-5에 3명의 피검자 모두에 대해 실험한 패턴 인식 실험의 전체 결과를 EDM[13], BPNN[2][10], SOM-TVC[본 연구]와 비교하여 그래프로 나타내었다.

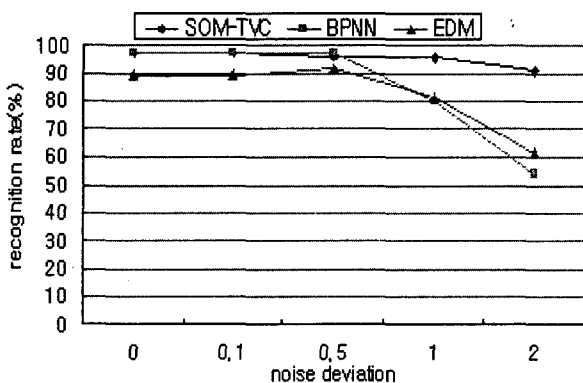


그림 3. 부가잡음의 크기에 따른 평균 패턴 인식률 비교 (피검자 : KIS)

Fig. 3. Comparison of mean pattern recognition rate according to additive noise deviation (subject : KIS)

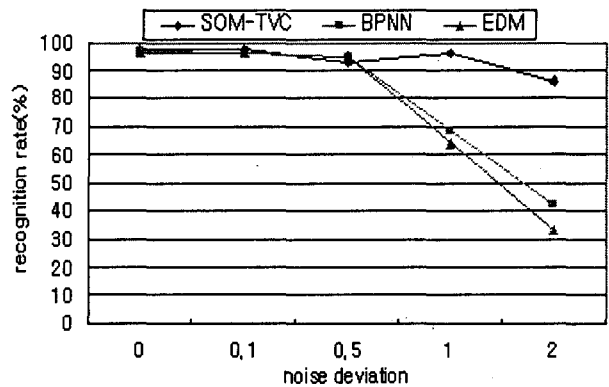


그림 4. 부가잡음의 크기에 따른 평균 패턴 인식률 비교 (피검자 : KWH)

Fig. 4. Comparison of mean pattern recognition rate according to additive noise deviation (subject : KWH)

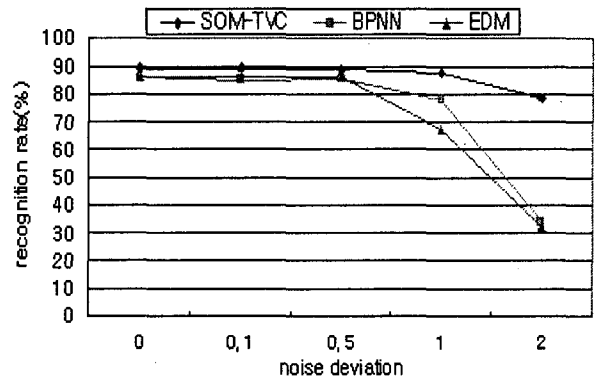


그림 5. 부가잡음의 크기에 따른 평균 패턴 인식률 비교 (피검자 : JCK)

Fig. 5. Comparison of mean pattern recognition rate according to additive noise deviation (subject : JCK)

위 결과들은 손목 관절 운동의 6개 동작 시에 기록한 근전도 신호에 대해 표 2, 3에서의 실험 조건과 동일하게 5가지 경우의 부가잡음 조건에 대해 패턴 인식 실험하여 6개 동작에 대한 평균 인식률을 나타낸 그림이다. 잡음 편차,  $\sigma=0.5$  이하의 비교적 작은 부가잡음 조건에서도 본 연구의 SOM-TVC 알고리즘이 타 연구자의 방법에 비해 약 5%이상의 높은 인식률을 나타낸다는 것을 알 수 있으며, 그이상의 부가 잡음에 대해서는 EDM이나 BPNN의 경우 인공 의수의 제어를 위한 적절한 패턴 인식기로 사용하기에 부적합함을 위 실험 결과를 통해 입증할 수 있다.

### 5. 결 론

본 연구에서는 인공의수 제어를 위해 새로운 근전도 신

호의 패턴인식 기법을 제안하였다. 고유값을 특징 파라메타로 하여 패턴을 표현하고 SOM-TVC 알고리즘으로 각각의 패턴을 인식하는 본 연구의 새로운 시도는 기존에 주로 사용된 AR 계수나 캡스트럼 계수의 특징 파라미터와 EDM, BPNN의 분류 알고리즘을 결합한 방법에 비해 부가잡음에 대해 뛰어난 성능을 나타냄을 실험을 통해 제시하였다.

제시한 6가지 손목 관절 운동 시 취득한 근전도 신호의 패턴 인식 실험 결과는 본 연구의 방법이 다양한 부가 잡음의 조건에서 기존의 방법들을 비해 약 5% - 40%의 높은 인식 성능으로 적용할 수 있음을 증명하였다.

인공의수의 기능적 특성상 잡음환경에 노출될 가능성이 크며, 잡음에 강건함 정도가 패턴인식의 성능을 결정하는 중요한 요소가 됨을 감안하면, 본 연구에서 제시한 방법을 기본으로 차후 부가 잡음에 따른 패턴의 변화를 효과적으로 모델링 하여 이를 추적한다면 좀더 좋은 인식률을 보일 것이라 사료된다.

### 참 고 문 헌

[1] C.L. Lin, W.J. Kang, C.T. Hu and S.T. Young, "Improved EMG pattern recognition using the distribution plot of cepstrum", in proc. of Int. conf. of IEEE Eng. in Medicine and Biology Society, vol. 20, pp. 2620-2622, 1998.

[2] A. Asres, H. Dou, Z. Zhou, Y. Zhang and S. Zhu, "A combination of AR and neural network technique for EMG pattern identification," int. conf. of IEEE Eng. in Medicine and Biology Society, pp. 1464-1465. 1996.

[3] W.J. Kang, J.R. Shiu, C.K. Cheng, J.S. Lai. H.W. Tsao and T.S. Kuo, "The application of cepstral coefficients and maximum likelihood method in EMG pattern recognition," IEEE Trans. on Biomed. Eng., vol. 42, no. 8, Aug., 1995.

[4] K. Englehart, B. Hudgins and P.A. Parker, "A wavelet-based continuous classification scheme for multifunction myoelectric control," IEEE Trans. on Biomed. Eng., vol. 48, pp. 302-311, Mar. 2001.

[5] H.P. Huang and C.Y. Chen, "Development of a myoelectric discrimination system for a multi-degree prosthetic hand," IEEE International Conf. on Robotics & Automation, vol. 3, pp. 2392-2397, May, 1999.

[6] K. Kuribayashi, S. Shimizu, A. Kawachi and T. Taniguchi, "A discrimination system using neural network for SMA prosthesis," in proc. of int. conf. of IEEE on Intelligent Robots and Systems, vol. 3, 1994.

[7] K. I. Diamantaras, S. Y. Kung, "Principal Component Neural Networks : Theory and Application", Wiley, 1996.

[8] J. M. Killer, M. R. Gray, and J. A. Givens, JR, " A fuzzy k-nearest neighbor algorithm", IEEE Transactions On Systems, Man, and Cybernetics, Vol. 15, no. 4, 1986

[9] Han-Pang Huang, Yi-hung Lju, Li-Wei Lju and Chun-Shin Wong "EMG Classificaton for Prehensile Postures Using Cascaed Architecture of Neural

Networks with Self-Organizing maps", IEEE International Conf. on Robotics & Automation, 2003.

[10] Ainisheet Asres, Huifang Dou, "A Combination of AR and neural network Technique for EMG Pattern Identification",EEE International Conf. Engineering in Medicine and biology Society, 1996.

[11] K. Ito, T. Tsuji, A. Kato and M. Ito, "EMG pattern classification for a prosthetic forearm with three degrees of freedom," in proc. of int. workshop of IEEE on robot and human communication, pp. 69-74, 1992.

[12] T. Kohonen, "The self-organizing map" Proc. IEEE, vol. 78, pp. 1464~1480, 1990

[13] 전창익, "인공의수 제어를 위한 근전도 신호의 진폭 추정과 패턴 인식 기법에 관한 연구", 서울 시립대학교 박사 논문.

[14] 임중규, "EMG 신호의 패턴 분류를 위한 간단한 SOM 방식", 전자공학회논문지, 제 38권 4호, 2001.

[15] Simon Haykin, "Neural Networks A comprehensive foundation", Prentice-Hall, 1999.

### 저 자 소 개



#### 김 인 수 (金仁洙)

2003년 한림대학교 전자공학과 졸업  
2003년 3월~현재 서울시립대학교  
전자전기컴퓨터 공학부 석사과정  
e-mail : bigstone77@korea.com



#### 이 진 (李眞)

1964년 8월 11일생. 1987년 연세대학교 의  
용공학과 졸업. 1999년 서울시립대학교 전  
자공학과 졸업(공학). 1997년 3월~1999년  
8월 : 한려대학교 의용공학과 전임강사.  
1999년 8월~현재 : 삼척대학교, 컴퓨터용  
용 제어공학과 조교수. 2003년 1월~현재 :  
Boston nuiv. NeuroMuscular Research  
Center 연구교수  
e-mail : jlee3206@yahoo.co.kr



#### 김 성 환 (金成煥)

1952년 6월 12일 생. 1975년 2월 연세대  
전기공학과 졸업. 1980년 2월 동 대학원  
전기공학과(공학). 1977~1982년 대전 기  
계창. 1982년~현재 서울시립대 전자·전  
기공학부 교수. 현재 서울시립대학교 전  
자전기컴퓨터공학부 교수  
Tel : 2210-2449, Fax : 2249-6802  
E-mail : shkim1@uoscc.uos.ac.kr