

---

# 혼합형 신경회로망을 이용한 근전도 패턴 분류에 의한 가상 로봇팔 제어 방식

정경권\* · 김주웅\* · 엄기환\*

The Virtual Robot Arm Control Method by EMG Pattern Recognition using the Hybrid Neural Network System

Kyung Kwon Jung\* · Joo Woong Kim\* · Ki Hwan Eom

## 요 약

본 논문은 근전도 패턴 인식에 의한 가상 로봇팔 제어 방식을 제안한다. 고차원의 근전도 신호를 정밀하게 분류하기 위하여 혼합형 신경회로망 방식을 사용한다. 혼합형 신경회로망은 SOFM과 LVQ로 구성되고, 고차원의 EMG 신호를 2차원 데이터로 변환한다. 3개의 표면 전극을 이용하여 EMG 신호를 측정한다. 제안한 혼합 시스템을 이용하여 한글 자음 6개의 수화 신호를 분류한다. 가상 로봇팔 실험을 통해서 제안한 혼합 시스템을 이용한 수신호의 EMG 패턴 인식의 유용성을 확인하였다.

## ABSTRACT

This paper presents a method of virtual robot arm control by EMG pattern recognition using the proposed hybrid system. The proposed hybrid system is composed of the LVQ and the SOFM, and the SOFM is used for the preprocessing of the LVQ. The SOFM converts the high dimensional EMG signals to 2-dimensional data. The EMG measurement system uses three surface electrodes to acquire the EMG signal from operator. Six hand gestures can be classified sufficiently by the proposed hybrid system. Experimental results are presented that show the effectiveness of the virtual robot arm control by the proposed hybrid system based classifier for the recognition of hand gestures from EMG signal patterns.

## 키워드

LVQ; SOFM; EMG; Pattern recognition; Virtual robot arm

## I. 서 론

2차 대전 이후 외부의 동력을 사용하여 인공사지 (artificial limb)를 동작시키려는 연구가 활발해 지면서 다양한 보철제어 방식이 연구되었다. 현재까지의 일반적인 의수제어는 기계적 언어로 프로그램된 일련의 동작순서

로 구동시키는 방식, 스위치의 조작에 의한 방식과 음성 인식에 의한 방식 등이 있으나, 이들은 인간의 제어방식이 갖는 임의성, 실시간 동작 및 편의성을 만족시키는 문제에 많은 한계점이 있다. 의수 뿐 아니라 로봇 팔의 제어에 있어서 인간의 행동을 외부로 전달하는 가장 자연스러운 방식은 팔의 근육에 잔존하는 근전도를 해석하여 제어하는

방식이다. 1924년 인간의 뇌파(EEG, Electroencephalogram)를 측정한 H. Berger의 실험을 기점으로 전기생리학의 대상은 심전도(ECG, Electrocardiogram), 근전도(EMG, Electromyogram), 안구전도(EOG, Electrooculogram) 등으로 그 범위가 확대되어 왔다. 이들 생체신호는 인체의 상태를 나타내는 지표로서 대부분 진단의학에 사용되었으며, 최근 들어 인간의 의사를 외부로 전달하는 인터페이스 장치의 신호원으로 연구되고 있다. 이중 EMG 신호는 근육의 활동 시에 발생하는 전기적 신호로서, 척수에서 신경임펄스가 발생되어 운동뉴런을 활성화시키고, 이에 따라 운동단위(motor unit)내의 근섬유가 활성화되면서 발생하는 전위차이다. 인간과 외부간의 인터페이스를 위한 근전도 신호처리에 관한 연구는 시계열 분석을 이용한 기능분리, 패턴인식을 이용한 기능분리, 자기상관함수(auto correlation function)와 상호 상관함수(cross correlation function)를 이용한 근전도 해석 및 비례제어에 의한 근전도 신호처리 방식이 있으며, 최근 들어 신경회로망, 퍼지 등의 인공지능을 이용한 근전도 신호의 패턴분류에 관한 연구가 활발히 진행되고 있다. 이러한 연구들은 진단의학을 위한 근전도 신호의 분석을 포함하여 특정한 전처리 과정(pre-processing)을 통해 EMG 신호의 지속시간, 진폭, 주파수를 추출하거나 근력 강도를 계산하는 단계가 필요하므로 시스템의 계산량 증가와 시간적 지연은 불가피 하다[1-5].

본 논문에서는 고차원의 근전도 신호를 정밀하게 분류하기 위하여 혼합형 신경회로망 방식을 제안한다. SOFM(Self-Organizing Feature Map)과 LVQ(Learning Vector Quantization)를 이용하여 근전도 신호의 패턴을 인식하고, 가상 로봇 팔을 제어하는 방식을 제안한다. 제안하는 방식은 근전도 신호를 측정하여 SOFM으로 근전도 신호의 특징추출을 추출하고 LVQ를 이용하여 최종 분류 및 인식을 수행한다. 제안한 방식의 유용성을 확인하기 위하여 측정한 수화 동작의 근전도 신호의 패턴 인식 성능을 시뮬레이션을 통해서 검토하고, 분류한 정보를 이용하여 컴퓨터상에 가상으로 제작된 로봇 팔을 제어한다.

## II. 근전도 신호

일반적으로 근전도 신호는 전기적으로  $10[\mu\text{V}] \sim 15[\text{mV}]$ 의 전압과,  $10 \sim 2000[\text{Hz}]$ 의 주파수 특성을 가진다. 이와 같은 근전도 신호를 처리 가능한 데이터로 만들고 분석하기

위해서는 300~500,000배 증폭을 해야하고, 외부 노이즈를 제거하기 위해 필터를 사용해야만 한다. 그림 1은 근전도 신호를 측정하기 위한 시스템이다.

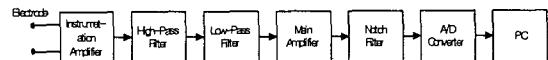


그림 1. 근전도 신호 측정 시스템의 블록선도  
Fig. 1. Block diagram of EMG signal measurement system

근전도 신호의 측정을 위해 1회용의 Ag/AgCl 표면 전극을 사용하며, 한글 자음 수화의 측정은 2초간 시행하고, 4개의 채널을 사용하였다. 각 채널에서 신호를 측정할 때, 두 개의 Ag/AgCl 전극이 한쌍으로 사용되며, 두 점간의 전위차를 차동 증폭기로 측정하게 되며, 두 전극과 함께 접지 전극이 필요하다. 전극의 위치는 측정하려는 근육의 중간 지점에서 근육의 중심선을 따라 배치하며, 두 전극의 간격은 약 1cm정도로 한다. 접지 전극은 측정하려는 근육에서 되도록 멀리 배치하며 뼈와 같이 전기적으로 중성인 조직위에 위치시킨다. 그림 2는 근전도 신호를 측정하기 위한 전극의 위치를 나타낸 것이다.

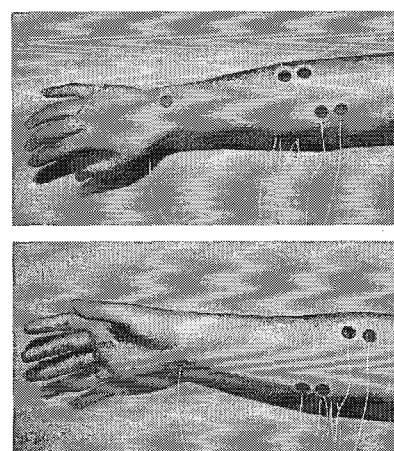


그림 2. 전극 위치  
Fig. 2 Electrode locations

## III. 제안한 혼합형 SOFM-LVQ 시스템

본 논문에서는 SOFM-LVQ 시스템을 이용한 근전도 패턴 인식 방법을 제안한다. 제안한 방식은 비지도 학습과 지도 학습을 사용하는 혼합 방식으로, SOFM을 이용하

여 고차원의 근전도 신호를 2차원 데이터로 변환한 후에 LVQ로 정밀하게 분류하여 동작을 인식하는 방법이다. SOFM과 LVQ는 Kohonen이 제안한 방식으로 훈련 데이터의 클러스터링(clustering)을 수행하는데, SOFM은 비지도 학습을 수행하고, LVQ는 경쟁 학습과 지도 학습을 수행하는 혼합형 신경회로망으로 패턴 분류나 패턴 인식에 많이 사용되고 있다.

본 논문에서는 입력 벡터를  $\mathbf{P} = [p_1, p_2, \dots, p_n]$  이라고 하고, 입력 벡터  $\mathbf{P}$ 의 원소를 그림 3과 같이 각 채널의 EMG 신호로 한다.

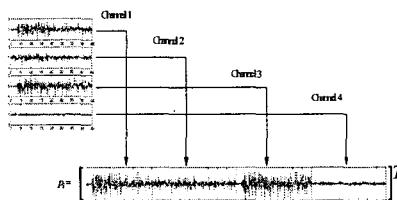


그림 3. 입력 신호  
Fig. 3 Input signal

제안하는 SOFM-LVQ 시스템은 그림 4와 같다. 입력되는 근전도 신호의 차원을 줄이기 위해서 SOFM을 적용하였다. 경쟁학습을 통해서 승자뉴런  $a_{xy}$ 를 결정한다. 여기서  $x, y$ 는 특징지도(feature map)의 승자뉴런의 좌표로 다음 단의 LVQ에서 입력으로 사용하는 값이다. SOFM의 연결강도는 식(1)과 같이 조정된다[6-7].

$$w_{xy}^{new} = w_{xy}^{old} + \alpha(\mathbf{p} - w_{xy}^{old}) \quad xy \in N(d) \quad (1)$$

여기서  $N(d)$ 는 이웃반경이고,  $\alpha$ 는 학습률이다.

그림 4에서 고차원의 근전도 신호를 입력 받아서  $20 \times 20$  크기의 2-차원 특징지도를 만들게 되며, 승자뉴런의 좌표를 이용해서 최종적으로 LVQ를 학습시킨다.

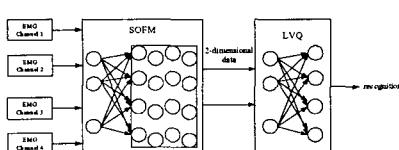


그림 4. 제안한 근전도 패턴 분류 방식의 블록선도  
Fig. 4 The block diagram of proposed EMG pattern classification

LVQ는 식(2)와 같은 훈련 데이터를 이용하여 학습을 수행한다.

$$\{\mathbf{q}_1, t_1\}, \{\mathbf{q}_2, t_2\}, \dots, \{\mathbf{q}_n, t_n\} \quad (2)$$

여기서  $\mathbf{q}_i = [x_i \ y_i]^T$ 는 LVQ의 입력 벡터로 SOFM에서 얻어진 승자뉴런의 좌표이고,  $t_i$ 는 목표값이다. 주어진 훈련 데이터를 이용하여 식(3)으로 학습을 수행한다.

$$\begin{aligned} m_i^{new} &= m_i^{old} + \beta \cdot (\mathbf{q}_i - m_i^{old}), \text{ if } C_i = t_i \\ m_i^{new} &= m_i^{old} - \beta \cdot (\mathbf{q}_i - m_i^{old}), \text{ if } C_i \neq t_i \end{aligned} \quad (3)$$

$m_i$ 는 LVQ의 기준벡터이고,  $C_i$ 는 입력 벡터가 속한 클래스를 나타낸다.  $\beta$ 는 LVQ의 학습률이다.

제안한 방식의 알고리즘은 다음과 같다.

Step 1. SOFM 연결강도 초기화한다.  
Step 2. 종료조건이 만족할 때까지 Step 3-7 수행.  
Step 3. 각 입력벡터  $\mathbf{p}$ 에 대해서  $\|\mathbf{p} - \mathbf{w}_{xy}\|$  가 최소가 되는 승자뉴런을 찾는다.

Step 4. 이웃반경만큼 연결강도를 조정한다.

$$w_{xy}^{new} = w_{xy}^{old} + \alpha(\mathbf{p} - w_{xy}^{old})$$

Step 5. 학습률을 갱신한다.

Step 6. 이웃반경을 갱신한다.

Step 7. 종료조건을 확인한다.

Step 8. SOFM 승자뉴런의 좌표를 LVQ의 입력 벡터  $\mathbf{q}$ 로 구성한다.

Step 9. LVQ 기준벡터를 초기화한다.

Step 10. 종료조건이 만족할 때까지 Step 11-14 수행.

Step 11. 각 입력벡터  $\mathbf{q}$ 에 대해서  $\|\mathbf{q} - \mathbf{m}_i\|$  가 최소가 되는 출력뉴런을 찾는다.

Step 12. 출력뉴런이 속한 클래스  $C_i$ 와 목표값

$t_i$ 에 따라 기준벡터를 조정한다.

$$m_i^{new} = m_i^{old} + \beta \cdot (\mathbf{q}_i - m_i^{old}), \text{ if } C_i = t_i$$

$$m_i^{new} = m_i^{old} - \beta \cdot (\mathbf{q}_i - m_i^{old}), \text{ if } C_i \neq t_i$$

Step 13. 학습률을 갱신한다.

Step 14. 종료조건을 확인한다.

#### IV. 실험

근전도 신호를 측정하기 위한 시스템의 구성은 그림 5에 나타나 있으며, 그림 6은 근전도 신호를 측정하는 시스템에 대한 실제 제작된 그림이다.

그림 5에서 계측(instrumentation) 증폭기는 스위치를 사용하여 10, 100, 200, 400까지 단계적으로 이득을 조정할 수 있도록 하였다. 고역 필터는 계측 증폭기의 직류 잔류(DC-offset) 및 전극과 피부사이의 화학작용에 의한 직류 성분을 제거하기 위하여, 저역 필터는 근전도 신호 범위를 초과하는 고주파 노이즈를 차단하기 위하여 사용되었으며, 두 개의 필터가 5~1200[Hz]의 대역 필터를 구성하게 된다.

주 증폭기는 가변저항을 사용하여 8~1,600까지 연속적으로 이득을 조정할 수 있으며, 계측 증폭기와 연계하여 시스템 전체의 이득을 80~640,000까지 조정할 수 있다. 또한 증폭된 근전도 신호가 A/D 변환기의 입력 제한 범위(-5~+5[V])를 초과하지 않도록 주 증폭기를 이용해 조정한다. 최종적인 노치(notch) 필터는 60[Hz]의 전원 잡음을 제거하도록 설계한다. 필터를 통과한 신호는 A/D 변환기에 의해 샘플링 되어 디지털화된 데이터를 얻게 된다.

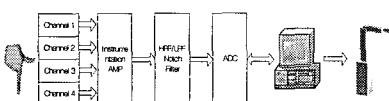


그림 5. 실험 장치 블록 선도

Fig. 5 The block diagram of an experimental set up

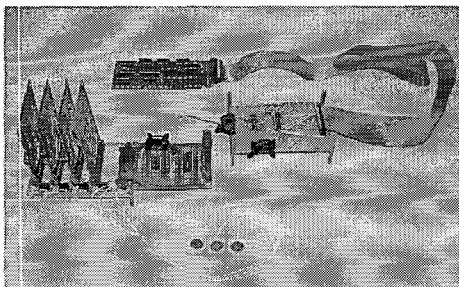


그림 6. 실험 장치 사진

Fig. 6 The picture of the experimental set-up

논문에서는 그림 7과 같은 3차원 GUI 프로그램을 제작하였으며, 인터페이스 카드를 통해 측정한 근전도 신

호를 이용하여 가상 로봇팔을 제어한다. 가상 로봇팔은 어깨, 팔꿈치, 손목의 세부분으로 구성된다.

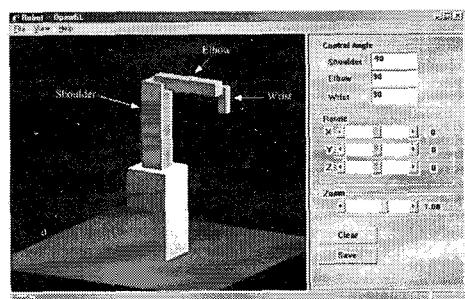
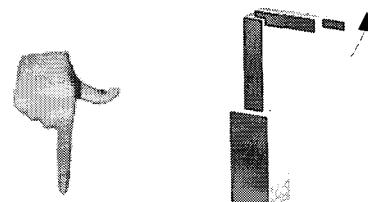
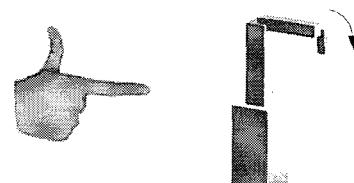


그림 7. 가상 로봇팔 제어 프로그램  
Fig. 7 The virtual robot arm control program

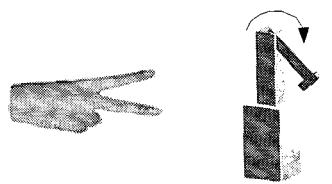
측정한 근전도 신호는 그림 8과 같은 한글 자음을 수화로 표현할 때 발생되는 신호로서 14개의 자음 중에서 ‘ㄱ’, ‘ㄴ’, ‘ㄷ’, ‘ㅁ’, ‘ㅂ’, ‘ㅅ’의 6개의 자음을 측정하였다. 그림 8은 6개의 자음 수화에 대한 로봇팔의 동작을 나타낸다. 한글 자음 수화 ‘ㄱ’은 로봇팔의 wrist를 위로 90° 올리는 동작이고, ‘ㄴ’은 wrist를 90° 내리는 동작이다. ‘ㄷ’은 로봇팔의 elbow를 위로 90° 내리는 동작이고, ‘ㅁ’은 90° 올리는 동작이다. ‘ㅂ’과 ‘ㅅ’은 로봇팔의 shoulder를 90° 내리고, 90° 올리는 동작과 연결된다.



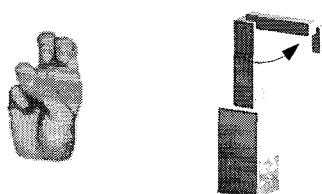
(a) “ㄱ” - a wrist up



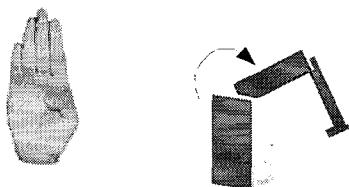
(b) “ㄷ” - an elbow down



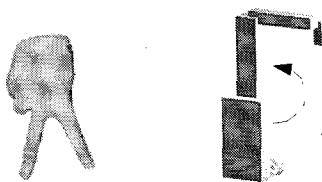
(c) “ㄷ” - an elbow down



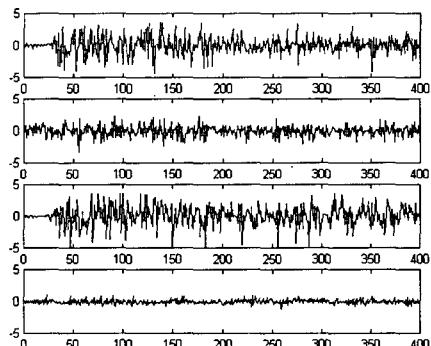
(d) “ㅁ” - an elbow up



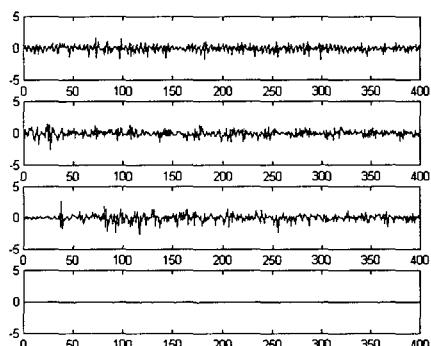
(e) “ㅂ” - a shoulder down



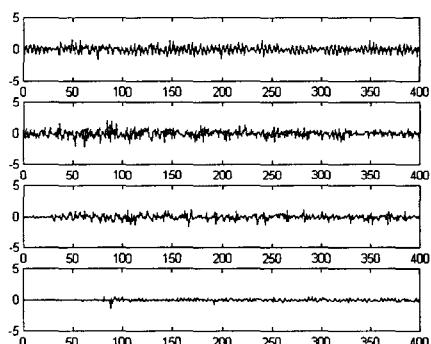
(f) “ㅅ” - a shoulder up



(a) “ㄱ”



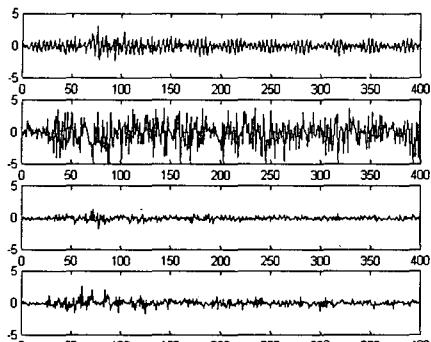
(b) “ㄴ”



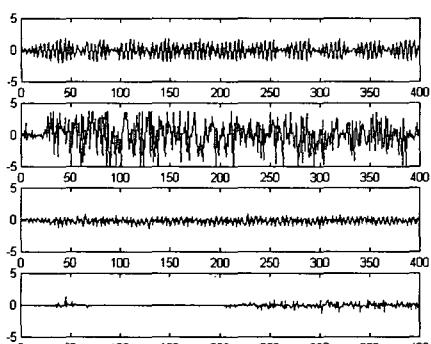
(c) “ㄷ”

그림 8. 한글 수화와 가상 로봇팔의 동작  
Fig. 8 The hand gestures of Korean characters and movements of the virtual robot arm

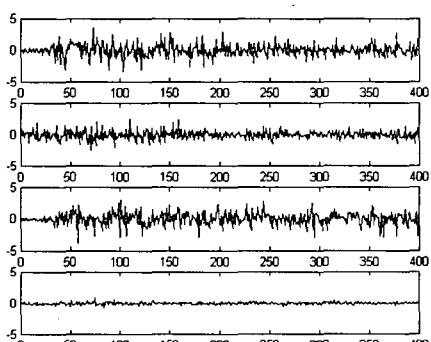
근전도 신호의 측정은 표면 전극을 통해 측정하였으며, 실험을 위한 근전도 신호의 측정은 각 자음에 대해 50번 실행하였다. 근전도 데이터는 각 채널당 400개의 데이터로 구성되어 있으므로 총  $4 \times 400$ 의 데이터가 된다. 6개의 자음 글자에 대한 근전도 신호의 예는 그림 9와 같다.



(d) “ㅁ”



(e) “ㅂ”



(f) “ㅅ”

그림 9. 근전도 신호  
Fig. 9. The EMG signals.

한글 수화 자음 6개의 동작에서 각각 30개씩 180개의 데이터를 사용하여 학습을 하였고, 테스트는 6개의 동작에서 각각 20개씩 120개의 데이터를 가지고 수행하였다.

SOFM은 입력 뉴런은 400개, 출력뉴런은  $20 \times 20$ 의 2차원 특징지도로 구성하고, 이웃반경은 멕시칸 모자 (Mexican-hat) 함수를 사용하여 사각형 형태로 축소시키는 방법을 사용하였으며 이웃반경의 크기는 5에서 학습을 수행하면서 1로 감소하게 하였다. LVQ는 SOFM의 승자뉴런의 좌표를 입력을 하여 6가지 자음을 분류한다. LVQ는 입력 뉴런 2개, 출력 뉴런 30개로 클래스 당 5개의 서브 클래스로 구성하였다. 1000번의 학습을 수행하였으며, 학습률은 0.9에서 감소하게 하였다.

그림 10은 제안한 시스템의 출력을 2차원으로 나타낸 것이다. ‘o’ 표시는 SOFM의 승자뉴런을 나타낸 것이고, ‘ㄱ’, ‘ㄴ’, ‘ㄷ’, ‘ㅁ’, ‘ㅂ’, ‘ㅅ’은 LVQ가 분류한 그룹을 나타낸다.

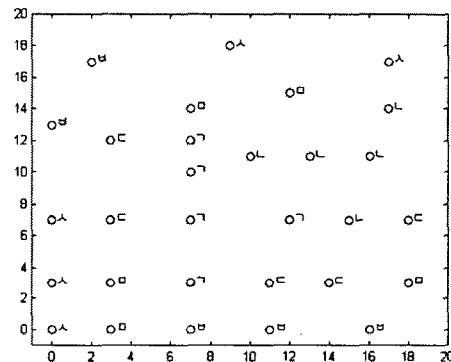
그림 10. 제안한 시스템의 출력  
Fig. 10 The output of the proposed system

표 1은 분류 결과를 나타낸 것으로 훈련 데이터는 100%의 인식률을 얻었으며, 테스트 데이터는 95%의 인식률을 얻었다.

표 1. 실험 결과

Table 1. Experimental results

수신호	훈련 데이터 인식률	실험 데이터 인식률
‘ㄱ’	100% (30/30)	95% (19/20)
‘ㄴ’	100% (30/30)	100% (20/20)
‘ㄷ’	100% (30/30)	90% (18/20)
‘ㅁ’	100% (30/30)	95% (19/20)
‘ㅂ’	100% (30/30)	100% (20/20)
‘ㅅ’	100% (30/30)	90% (18/20)

훈련 데이터에서는 모든 수신호 동작에 대해서 정확한 동작 인식을 하였으나 실험 데이터에서는 ‘ㄱ’과 ‘ㄴ’, ‘ㄷ’과 ‘ㅅ’의 수신호 동작에서는 손동작이 유사하기 때문에 인식에 있어서 오차가 발생한 것으로 생각된다.

## V. 결 론

본 논문에서는 근전도 신호를 이용한 가상 로봇팔 제어를 위해 혼합 신경회로망 방식을 이용한 근전도 패턴 분류를 제안하였다. 제안한 혼합 방식은 고차원의 근전도 신호를 정밀하게 분류하기 위하여 SOFM과 LVQ로 구성되며, SOFM을 입력 데이터의 차원을 줄이는 전처리기로 사용하고, LVQ로 최종 분류를 수행하는 방식이다. 고차원의 근전도 데이터를 2-차원의 특징지도 좌표로 변환하여 LVQ에 입력한다. 어깨, 팔꿈치, 손목으로 구성되는 가상 로봇팔을 제어하기 위해서 한글 자음의 수화에 대한 근전도 신호를 로봇팔의 동작과 대응시키고 SOFM-LVQ 혼합 시스템을 이용하여 학습을 하였다.

제안한 방식의 유용성을 확인하기 위해서 훈련 데이터와 테스트 데이터를 가지고 실험한 결과 SOFM-LVQ 혼합 시스템을 이용하는 제안한 방식이 97.5%의 인식률을 얻을 수 있었다.

## 참고문헌

- [1] F. H. Y. Chan, Y. S. Yang, F. K. Lam, Y. T. Zhang, P. A. Parker, "Fuzzy EMG classification for prosthesis control," *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 3, pp. 305-311, 2000.
- [2] C. I. Christodoulou, C. S. Pattichis, "Unsupervised pattern recognition for the classification of EMG signals," *IEEE Transactions on Biomedical Engineering*, vol. 46, no. 2, pp. 169-178, 1999.
- [3] J. Duchene, J. Y. Hogrel, "A model of EMG generation," *IEEE Transactions on Biomedical Engineering*, vol. 47, no. 2, pp. 192-201, 2000.
- [4] A. Merlo, D. Farina, R. Merletti, "A fast and reliable technique for muscle activity detection from surface EMG signals," *IEEE Transactions on Biomedical Engineering*, vol. 50, no. 3, pp. 316-323, 2003.
- [5] D. Nishikawa, W. Yu, H. Yokoi, Y. Kakazu, "On-Line Learning Method for EMG Prosthetic Hand Control," *Electronics and Communications in Japan*, vol. 84, no. 10, pp. 35-46, 2001.
- [6] Haganm Demuth Beale, "Neural Network Design", PWS Publishing Company, 1995.
- [7] T. Kohonen, "The self-organizing map," Springer, 2000

## 저자소개



정 경 권(Kyung Kwon Jung)

1998년 동국대학교 전자공학과  
공학사  
2000년 동국대학교 전자공학과  
공학석사

2003년 동국대학교 전자공학과 공학박사  
2006년 현재 동국대학교 밀리미터파신기술연구센터 연구원  
※관심분야: 인공지능, 센서 네트워크, 밀리미터파 수동  
이미징



김 주 웅(Joo Woong Kim)

1999년 동국대학교 전자공학과  
공학사  
1998년 동국대학교 전자공학과  
공학석사

2003년 동국대학교 전자공학과 공학박사  
1997-현재 뉴파워전자  
※관심분야: 전력전자, 계측제어, 인공지능



엄 기 환(Ki Hwan Eom)

1972년 동국대학교 전자공학과  
공학사  
1986년 동국대학교 전자공학과  
공학박사

1989-1990 Toho University Post Doc.  
2000-2001 Univ. of Canterbury Visiting Professor.  
1994-현재 동국대학교 전자공학과 교수  
※관심분야: 시스템 응용, 흡 네트워크