

論文2000-37SC-6-7

## 소프트 컴퓨팅 기법을 이용한 근전도 신호의 패턴 분류와 재활 로봇 팔 제어에의 응용

(EMG Pattern Classification using Soft Computing  
Techniques and Its Application to the Control of a  
Rehabilitation Robotic Arm)

韓政秀\*, 金鍾成\*\*, 宋原慶\*, 方遠喆\*, 李熙暎\*\*\*,  
卞增男\*

(Jeong-Su Han, Jong-Sung Kim, Won-Kyung Song, Won-Chul Bang,  
Heyoung Lee, and Zeungnam Bien)

### 요 약

본 논문에서는 소프트 컴퓨팅 기법을 이용한 새로운 근전도 신호 패턴 분류 방법을 제안한다. 재활 로봇 시스템에서 기존에 사용되었던 여러 가지 입력 장치(음성, 레이저 포인터, 키패드, 3차원 입력기 등)에 비해 근전도 신호를 이용한 방식이 가지는 장점을 서술한다. 기존의 근전도 신호 분류 방법의 문제점인 사용자 의존성을 줄이기 위해 제안한 사용자 독립적인 특징 선택 방법에 대해 상술한다. 선택된 특징 집합을 이용하여 퍼지 패턴 분류기 및 퍼지 최대-최소 신경망을 구성하여 학습 전(퍼지 패턴 분류기)과 학습 후(퍼지 최대-최소 신경망)에 각각 83%와 90%의 분류 성공률을 얻어 제안된 방법의 유용성을 확인할 수 있었다.

### Abstract

In this paper, a new EMG pattern classification method based on soft computing techniques is proposed to help the disabled and the elderly handle rehabilitation robotic arm systems. First, it is shown that EMG is more useful than existing input devices such as voice, a laser pointer and a keypad in view of naturality, extensibility, and applicability. Then, a new procedure is proposed to select the minimal feature set. As methods of classifying the pre-defined motions, a fuzzy pattern classification and fuzzy min-max neural networks (FMMNN) are designed using the selected features. As results, the motions are recognized with success rates of 83 percent and 90 percent using fuzzy pattern classification and FMMNN, respectively.

\* 正會員, 韓國科學技術院 電子電算學科

(Department of Electrical Engineering and Computer  
Science, KAIST)

\*\* 正會員, ETRI 인터넷 情報家電 硏究部

(Internet Appliance Department, ETRI)

\*\*\* 正會員, 全南大學校 電子工學科

(Department of Electrical Engineering, Chonnam  
National University)

接受日字:2000年6月20日, 수정완료일:2000年9月20日

### I. 서 론

의료기술의 발달로 전 세계적으로 노인인구가 급증하고 있다. 하지만 대부분의 노인들은 한 가지 이상의 만성질환으로 일상생활에 동작장애를 받고 있다(표 1). 또한 선천적인 장애인 외에도 최근에는 산업 및 환경 재해, 교통사고 등으로 인한 후천적 장애 인구가 증가하고 있다. 장애인의 고용을 증대시키고 삶의 질과 만족도를 향상시킨다는 측면에서도 과학 기술을 이용하

여 장애인과 노약자의 상실된 감각을 보충해 주거나 불완전한 활동을 도와주는 재활공학(rehabilitation engineering) 시스템은 필요하며 이미 구미 선진국을 중심으로 노약자 및 장애인을 돕기 위한 재활 공학 시스템이 개발되고 있다<sup>[2,3,4]</sup>. 우리 나라의 경우, KARES (KAIST Rehabilitation Engineering Service system)가 한국과학기술원(KAIST) 연구팀에 의해 개발된 바 있다<sup>[20]</sup>.

표 1. 만성질환에 의한 일상생활 장애 노인의 비율<sup>[1]</sup>  
Table 1. The ratio of the elderly with chronic disease<sup>[1]</sup>.

연령	구성비율
60 - 64세	67.5 %
65 - 69세	72.6 %
70 - 74세	74.4 %
75세 이상	77.5 %

장애인 및 노약자를 돕기 위한 재활 로봇은 손을 자유롭게 사용할 수 없는 사용자를 위해 다양한 방법을 사용하여 사용자의 명령을 로봇에게 전달한다. 사용자 명령을 전달하기 위한 대표적인 입력 수단으로는 음성<sup>[2]</sup>, 레이저 포인터<sup>[3]</sup>, 키패드<sup>[4]</sup>, 3차원 입력기<sup>[5]</sup> 등이 있다. 음성을 이용할 경우 부가적인 정보(비전 정보, 레이저 포인터 정보 등)가 필요하며, 레이저 포인터는 많은 계산량으로 인해 작업 속도가 느다는 단점이 있다. 키패드나 3차원 입력기는 비 구조화된 환경에서도 사용할 수 있는 장점이 있지만, 사용 대상자가 제한적이다<sup>[5]</sup>.

이런 문제점을 해결하기 위해서 본 논문에서는 사용자의 명령을 적절히 로봇에게 전달해 줄 수 있는 근전도(EMG; electromyogram) 신호를 이용하는 방법에 대해 서술한다. 근전도 신호를 이용하여 사용자의 명령을 로봇에게 전달해 주는 방법은 사용하기에 자연스럽다는 점, 시스템 명령어에 대한 부가적인 학습이 필요 없다는 점, 비 구조화된 환경에서 사용 가능한 조이스틱, 키패드, 3차원 입력기 등을 사용할 수 없는 중증 장애인에게도 적용 가능하다는 점, 다른 입력 장치에서 쉽게 추출할 수 없는 유용한 정보(팔의 움직임 속도<sup>[6]</sup>, 근육의 피로도<sup>[7]</sup>) 등을 이용할 수 있다는 점 등의 장점을 가지고 있다.

본 논문의 구성은 다음과 같다. II장에서는 근전도 신

호의 발생과정 및 특징에 대해 서술한다. 그리고 선행 연구결과 및 문제점을 지적하고 본 논문에서 풀고자 하는 문제를 정의한다. III장에서는 제시된 문제를 해결하기 위해 소프트 컴퓨팅 기법을 이용하여 제안한 근전도 신호 분류 알고리즘에 대해 설명한다. 사용자의 명령을 전달하기 위한 8가지 팔 동작을 분류하기 위해 사용한 특징들과 그 특징들 중에서 사용자 독립적인 특징을 찾는 방법에 대해 서술하고 찾아진 특징을 사용하여 퍼지 패턴 분류기와 퍼지 최대-최소 신경망을 구성하여 동작을 분류하는 과정을 설명한다. 또한 분류 결과의 확신도를 계산할 수 있는 방법에 대해 서술한다. IV장에서는 제안된 방법을 검증하기 위해 행해진 두 가지 분류 실험 결과 및 결과고찰에 대해 서술한다. 그리고, 분류된 결과를 이용하여 6 자유도 로봇 팔을 구동시킨 결과를 언급하고 V장에서는 결론 및 추후과제에 대해 서술한다.

## II. 근전도 신호

근전도 신호는 근육의 수축시에 발생하는 전기적 신호이며<sup>[8]</sup>, 다음과 같은 과정을 거쳐 생성된다. 뇌의 운동피질(motor cortex)에서 신경 임펄스열(impulse train)이 발생하여 척수를 통하여 각 운동단위에 연결된 신경에 연속적으로 전달된다. 그리고 신경 임펄스 열이 운동단위에 가해질 때 운동 단위열이라는 운동 활동 전위열(MUAPT; motor unit action potential train)을 발생시키며, 이 활동 전위열의 시간에 대한 공간적 합이 근전도 신호를 이루게 된다<sup>[8]</sup>. 이 때 근육의 수축력은 운동신경 펄스의 발생 비율의 변화와 작용하는 운동단위 수의 변화에 의해 조정된다.

근전도 신호의 특징은 다음과 같다<sup>[9~11]</sup>. 첫째, 근전도 신호는 불안정(nonstationary)하다. 따라서 근전도 신호의 기준 패턴 및 모델의 신뢰성이 제한되며 시간에 따라 변하는 근전도 신호의 특징을 잘 반영할 수 있는 방법이 필요하다. 둘째, 하나의 운동 단위를 이루는 근섬유의 수가 사람마다 달라 사용자마다 동일한 동작에 대한 근전도 신호가 다르다. 셋째, 근전도 신호를 측정하기 위한 위치의 피부 두께의 차이나 다른 근육 조직들로 인해 사용자마다 근전도 신호가 다르다. 넷째, 근전도 신호의 크기는 보통 수십  $\mu V$ 에서 수  $mV$  정도로 주변 환경의 잡음의 영향을 많이 받아 측

정된 신호에 잡음이 많다.

근전도 신호를 이용하여 팔 동작 분리를 한 연구는 의수의 제어가 그 주된 응용 대상이었다. 팔 동작을 분류하기 위해 근전도 신호의 크기를 이용하는 방법<sup>[12]</sup>, 자기회귀(autoregressive) 모델링을 이용하는 방법<sup>[13]</sup>, 확률 모델을 이용한 방법<sup>[9]</sup>, 신경망<sup>[14]</sup>이나 퍼지 이론<sup>[15]</sup>을 이용한 방법 등이 있다.

1970년대 초반에 근전도 신호의 크기를 이용해 팔 동작을 분류하려는 시도가 있었지만, 피험자가 특정 동작을 위한 근육의 수축정도를 학습해야 한다는 단점이 있다. 1975년에 Graupe 등은 자기회귀 모델링을 이용하여 근전도 신호에 따른 동작 분류를 제안하였다<sup>[13]</sup>. 근전도 신호를 안정한 시계열(time series)로 모델링하여 얻어진 매개변수를 바탕으로 미리 정해진 동작에 대하여 기준이 되는 매개변수와의 비교를 통해 팔 동작을 분류하여, 약 85%정도의 성공률을 보였다. 1982년에 Saridis<sup>[9]</sup> 등은 영교차수(zero crossing)와 분산 등을 이용한 확률 모델을 이용한 방법을 제안하였다. 영교차수와 분산의 확률적 변수를 이용하여 각 동작 기능에 해당하는 변수들을 2차원 평면상의 일정 영역으로 표시하여 학습형 선형 분리를 이용한 팔 동작 분리를 시도하였다. 최근에는 피험자별, 시간별, 피로나 땀, 전극 위치의 변화 때문에 생기는 근전도 신호의 변화 특성을 학습할 수 있다는 장점 때문에 신경회로망을 이용해 다양한 손동작에 대한 근전도 신호의 패턴 분류<sup>[14]</sup>를 하려는 연구가 있다. 퍼지 이론을 사용한 패턴 분류

방법 역시 최근에 제안<sup>[15]</sup>되었는데 이 방법은 생체 신호가 각 동작에 대해 매번 완전히 동일하게 반복되지 않는다는 점과 분류 동작들의 클래스 경계의 불명확성 등을 처리할 수 있는 장점이 있으며 전문가의 지식을 쉽게 시스템에 포함시킬 수 있다.

선행 연구의 결과들은 의수의 제어에서 실질적이거나 이론적인 성과를 보였지만 사용자에게 의존한다는 가장 큰 단점을 가지고 있다. 동작을 분류하기 위해 사용자마다 다른 임계값을 사용한다든지 신경망 학습 후에 사용하는 방법 등은 실제 적용할 때 반드시 해결해야 되는 문제점이다. 사용자 의존적인 분류 방법 문제를 해결하기 위해 온라인 학습 기능(on-line learning)을 가지는 신경회로망을 이용하는 방법<sup>[11]</sup>이 최근에 제안되었으나 이 방법 역시 어떤 특징(feature)들을 학습시키는 것이 사용자 차이에 의한 영향을 감소시킬 수 있을 것인가에 대해서는 언급하고 있지 않다. 즉, 학습을 위한 특징 선택의 일반적인 방법이 없다.

본 논문에서 인식하고자하는 그림 1의 8가지 팔 동작은 장애인(특히, 척수 손상 장애인 C5, C6, C7) 및 노약자가 일상생활에서 필요한 작업을 하는데 요구되어지는 기본적인 동작들을 조사하여 선정하였다. 본 논문에서는 앞서 언급된 선행 연구의 문제점인 사용자 의존성을 해결하기 위해 사용자 독립적인 특징을 선택할 수 있는 방법을 제안한다. 선택된 특징을 이용하여 퍼지 패턴 분류기와 퍼지 최대-최소 신경망(FMMNN)을 구성하여 그림 1의 8가지 동작을 분류하며 그 결과



좌 상단부터 손목 안으로 회전(1번 동작), 손목 밖으로 회전(2번 동작), 팔꿈치 굽히기(3번 동작), 팔꿈치 펴기(4번 동작), 삼박골 위로 움직이기(5번 동작), 삼박골 아래래로 움직이기(6번 동작), 삼박골 안으로 움직이기(7번 동작), 삼박골 밖으로 움직이기(8번 동작).

그림 1. 기본 동작

Fig. 1. Primitive Motions.

를 6 자유도 재활 로봇 팔 구동에 적용한다.

### III. 근전도 신호의 패턴 분류

#### 1. 근전도 측정 위치의 선정

근전도 신호를 측정하는 채널의 수가 많아질수록 동작을 분류하는데 필요한 정보를 많이 얻을 수 있어서 동작 분류에 유리하다. 하지만, 채널이 많아질수록 사용하는 사용상에 불편함을 느끼게 된다. 따라서 제한된 수의 채널을 이용하여 정의된 동작을 구분하기 위해서는 전극 위치의 선정이 중요하다.

인체의 골격근은 길항근(拮抗筋, antagonistic muscle)으로 구성이 되어 있다. 길항근이란 서로 반대되는 작용을 동시에 하는 근육이며 한쪽 근육이 수축할 때 다른 쪽 근육은 늘어나게 되는 한 쌍의 근육이다. 정의된 8가지 동작은 팔의 회전축에 따라 4개의 클래스로 구분할 수 있다(클래스 1(동작 1과 동작 2), 클래스 2(동작 3과 동작 4), 클래스 3(동작 5와 동작 6), 클래스 4(동작 7과 동작 8)). 각각의 클래스 내의 동작은 인체의 골격근이 길항근이라는 사실에 바탕을 두어 다음절에서 설명될 절대적분치의 평균기울기를 이용하면 쉽게 분류 가능하다. 따라서, 잘 선정된 근전도 측정 위치에서의 절대적분치의 평균기울기를 이용하면 8가지 동작

의 분류 문제를 4개의 클래스 분류 문제로 바꿀 수 있으며 근전도 신호 측정을 위해 4개의 채널이 필요하다는 것을 알 수 있다.

선정된 근전도 측정 위치는 그림 2와 같다. 측정 위치는 각 동작의 움직임에 관여하는 여러 근육들 중에서 실험을 통하여 각각의 동작을 행할 때 근전도 신호의 크기가 가장 크게 측정된 곳을 선정하였다.

#### 2. 패턴 분류를 위해 사용한 특징들

근전도 패턴 인식과 관련된 연구에서 많은 특징들이 사용되었고<sup>[6,9,13]</sup>, 클래스(class)간의 분리도가 뛰어난 특징을 찾기 위한 연구가 현재에도 활발히 진행중이다<sup>[17]</sup>. 본 논문에서는 다음의 5가지를 패턴 인식을 위한 특징으로 선택하였다.

1) 절대적분치(IAV; integral absolute value)<sup>[6]</sup>: 근전도 신호의 절대 적분치를 나타내는 특징으로서, 일정시간 동안의 신호의 절대값을 적분한 것이며 식 (1)으로 정의된다.


$$\bar{X}_j = \frac{1}{N} \sum_{i=1}^N |x_j(i\Delta t)| \quad (1)$$

여기에서  $j$ 는 채널 번호,  $x_j$ 는 채널  $j$ 에서 측정된 근전도 신호이며,  $i$ 는 샘플의 순서,  $\Delta t$ 는 샘플링 시간 간격,  $N$ 은 샘플의 수를 나타낸다.

2) 절대적분치의 평균기울기(ASIAV; average slope of IAV): 각 동작의 근전도 신호에 대해서 일정시간(32msec) 간격으로 절대적분치를 구한다. 구해진 절대적분치 값을 직선 회귀(line regression) 방법을 이용하여 평균 기울기를 구한다.

근전도 신호는 근육의 수축 정도에 비례하여 발생하므로 절대적분치의 평균기울기를 이용하면 근육이 수축하고 있는 상태(절대적분치의 평균기울기가 양)인지, 근육이 이완되고 있는 상태(절대적분치의 평균기울기가 음)인지를 알 수 있다. 예를 들어, 채널 1의 원회내근에서 측정된 근전도 신호의 절대적분치의 평균기울기를 이용하면 손목 안으로 회전(동작1)인지 손목 밖으로 회전(동작2)인지를 알 수 있다. 따라서 절대적분치의 평균기울기를 이용하여 각각의 클래스 내의 각 동작을 구분할 수 있다.

3) 분산(VAR; variance)<sup>[9]</sup>: 근전도 신호가 평균값에서 얼마나 떨어져 분포되어 있는가를 나타내는 특징으로서 식 (2)로 표현된다.



채널 1(1c): 원회내근(pronator teres m.),  
 채널 2(2b): 상완근(brachialis m.),  
 채널 3(3a): 삼각근(deltoid m.),  
 채널 4(3c): 견갑거근(levator scapulae m.)

그림 2. 선정된 근전도 측정 위치  
 Fig. 2. The locations of channels to measure EMG.

$$\sigma_j^2 = E[x_j^2] - \{E[x_j]\}^2 = \frac{1}{N} \sum_{i=1}^N (x_j(i\Delta t))^2 \quad (2)$$

여기에서  $E[x_j] = \frac{1}{N} \sum_{i=1}^N (x_j(i\Delta t))$ 이며,  $x_j$ 의 평균값을 나타낸다.

4) 영교차수(ZC; zerocrossing)<sup>[9]</sup>: 근전도 신호가 영점을 지나는 횟수로 식 (3)과 같이 구할 수 있다.

$$ZC_j = \sum_{i=0}^N q[x_j(i\Delta t)x_j((i+1)\Delta t)] \quad (3)$$

이 때,  $q(x) = \begin{cases} 1, & x < 0 \text{ 인 경우} \\ 0, & \text{그 외} \end{cases}$  이다.

5) 주파수 성분비(FR; frequency ratio): 근전도 신호를 주파수 변환하여 저주파성분의 전체전력과 고주파성분의 전체전력의 비를 구한 것이다.

$$Freq. Ratio_j = \frac{|F(\cdot)|_{j(low\ freq)}}{|F(\cdot)|_{j(high\ freq)}} = \frac{|F(\cdot)|_{j(30Hz-250Hz)}}{|F(\cdot)|_{j(250Hz-1kHz)}} \quad (4)$$

이 때,  $|F(\cdot)|_j$ 는 채널  $j$ 에서 측정된 근전도 신호의 푸리에 변환이며, 저주파 신호와 고주파 신호를 구분하기 위한 임계값은 실험을 통해 결정되었다.

주파수 성분비는 근육이 수축할 때와 수축하지 않을 때 나타나는 근전도 신호의 차이를 보고 새롭게 제안한 특징이다.




그림 3. 팔꿈치 굽히기/펴기 동작을 할 때 시간 영역에서의 각 채널 근전도 신호(참고: 약 50% MVC에서 측정된 근전도 신호임)

Fig. 3. EMG signals of elbow flexion/extension in the time domain.(note: Measured EMG signals at about 50% MVC.)

그림 3과 그림 4는 팔꿈치를 굽혔다 펴는 동작에서 측정된 근전도 신호와 이를 변환하여 주파수 영역에서 나타낸 것이다. 시간 영역에서 채널 1과 채널 2에서 근전도 신호의 크기가 크게 측정되고 있음을 알 수 있다. 근전도 신호는 근육의 수축 정도에 비례하여 발생하는 신호이므로, 채널 1과 채널 2의 근육의 수축정도가 채널 3과 채널 4보다 크다는 것을 알 수 있다. 이 신호를 주파수 변환한 결과를 보면, 채널 1과 채널 2에서의 저주파 성분의 전체전력이 다른 채널의 저주파 성분의 전체전력에 비해 크기가 크다. 따라서, 주파수 성분비가 크다는 것은 근육의 수축 정도가 크다는 것을 의미한다. 즉, 주파수 성분비를 이용하여 근육의 상대적인 수축 정도를 알 수 있다.

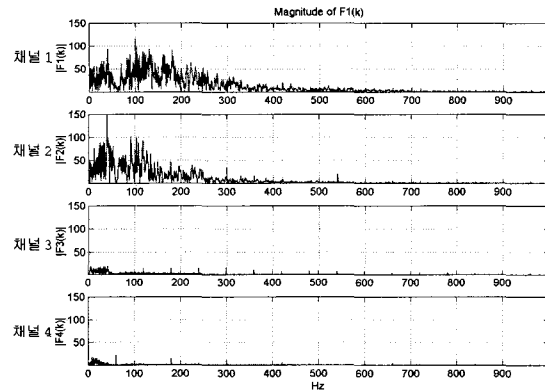


그림 4. 팔꿈치 굽히기/펴기 동작을 할 때 주파수영역에서의 각 채널 근전도 신호

Fig. 4. EMG signals of elbow flexion/extension in the frequency domain.

### 3. 제안한 최소 특징 집합 선택 알고리즘

1) 데이터 획득(data acquisition): 각 피험자 별로 기본 동작 근전도 신호 데이터를 획득한다.

2) 전처리(preprocessing): A/D 변환된 근전도 신호에서 저주파 잡음의 일종인 동잡음(motion artifact)을 제거하기 위해서 30Hz의 차단 주파수를 가지는 2차 고역통과 필터를 사용한다.

3) 특징 추출(feature extraction): 앞 절에서 설명된 특징들(ASIAV는 제외)을 추출한다. ASIAV는 각각의 클래스 내에서 각 동작을 분류하는데 필요하므로 4개의 클래스를 분류하는 최소 특징 집합을 선택하는 과정에서 제외된다.

4) 특징 클러스터링(feature clustering): 다음의 세 가지 과정을 거친다.

- ① 정규화(normalization): 구분하려는 8가지 동작에 대해서 추출된 각 특징(feature) 값을 식 (5)를 이용해 각 채널을 기준으로 정규화 한다.

$$X'_k = \frac{X_k}{\sum_{i=1}^N X_i} \quad (5)$$

여기에서,  $X_i$ 는 각 채널에서 측정된 특징값이고  $N$ 은 채널 수이다.

- ② 선형 사상(linear mapping): 정규화된 후의 각 특징값을 식 (6)을 이용하여 선형 사상한다. 선형 사상 후에는 모든 특징값이  $[0, 1]$  사이에 있게 되어 추후 퍼지 패턴 분류기를 설계할 때 용이하다.

$$Y_k = \frac{X'_k - (X'_{\min})_k}{(X'_{\max})_k - (X'_{\min})_k} \quad (6)$$

여기에서,  $X'_k$ 는 채널  $k$ 에서 정규화된 특징값,  $(X'_{\min})_k$ 는 선형 사상전에 채널  $k$ 에서 정규화된 특징값의 최소값,  $(X'_{\max})_k$ 는 선형 사상전에 채널  $k$ 에서 정규화된 특징값의 최대값을 나타낸다.

- ③ 각 피험자에 대한 특징값의 클러스터링(clustering of features for each subject): Fuzzy C-means Algorithm을 이용하여 선형 사상 후에 얻어진 특징값들의 각 동작에 대한 평균값을 각 피험자별로 2개, 3개, 4개의 그룹으로 각각 클러스터링한다(표 2). 4개 그룹으로 클러스터링 수를 제한한 이유는 8가지 기본 동작을 분류하는 문제가 절대적분치의 평균기울기를 이용하여 4개의 클래스를

분류하는 문제로 바뀌었기 때문이다. 즉, 절대적분치의 평균기울기를 제외한 특징들을 이용하여 8가지 기본 동작을 4개의 클래스로 분류하면 되도록 클러스터링 수를 4개까지로 제한하였다.

특징값 클러스터링 과정은 각 피험자별로 행하여지므로 피험자마다 4개의 클래스를 분류해주는 클러스터 집합들을 찾을 수 있으나 이 클러스터 집합은 사용자에게 의존적이다. 따라서, 사용자마다 다른 클러스터 집합에서 다음에 설명될 공통 클러스터 집합을 선택한 후, 최소 특징 집합을 선택하면 사용자 독립적인 특징 집합을 선택할 수 있다.

- 5) 공통 클러스터 집합 선택(common cluster set selection): 각 피험자에 대한 특징값의 클러스터링 결과(표 2를 포함한 총 16개의 표(4개의 채널, 4개의 특징))로부터 피험자에 독립적인 클러스터에 속성값을 할당하여 표 3과 같이 하나의 표로 만든다. 표를 만드는 과정은 다음과 같다.

피험자 독립적인 클러스터는 피험자에 관계없이 동일한 소속도 함수 값을 가지는 클러스터를 의미한다. 속성값을 할당하는 방법은 동일한 클러스터에 있는 동작들에는 동일한 속성값을 할당하는 방식을 이용한다. 예를 들어, 채널 1의 주파수 성분비를 2개로 클러스터링한 결과를 보면 모든 피험자에 대해 {동작1, 동작2, 동작3, 동작4}, {동작5, 동작6, 동작7, 동작8}로 나누어져 있음을 알 수 있다. 따라서 각 클러스터의 속성값은 {동작1, 동작2, 동작3, 동작4}에 특징값의 분포경향에 따라 임의의 한 값(big)을 할당하고, {동작5, 동작6, 동작7, 동작8}에 또 다른 임의의 한 값(small)을 할당하면 된다. 이는  $a_0$ 라는 속성으로 {동작1, 동작2, 동작3, 동작4}와 {동작5, 동작6, 동작7, 동작8}의 두 종류로 분류

표 2. 채널 1의 주파수성분비에 대한 각 피험자별 특징값의 클러스터링 결과  
Table 2. Clustering Results of Frequency Ratio for each subject in channel 1.

주파수성분비 clustering수	채널 1			
	피험자 1	피험자 2	피험자 3	피험자 4
2	{m1,m2,m3,m4} {m5,m6,m7,m8}	{m1,m2,m3,m4} {m5,m6,m7,m8}	{m1,m2,m3,m4} {m5,m6,m7,m8}	{m1,m2,m3,m4} {m5,m6,m7,m8}
3	{m1,m2}{m3,m4} {m5,m6,m7,m8}	{m1,m2}{m3,m4} {m5,m6,m7,m8}	{m1,m2,m3}{m4} {m5,m6,m7,m8}	{m1,m2,m3,m4} {m5,m6}{m7,m8}
4	{m1,m2}{m3,m4} {m5,m6,m7}{m8}	{m1,m2}{m3,m4} {m5,m6,m8}{m7}	{m1,m2}{m3}{m4} {m5,m6,m7,m8}	{m1,m2,m3,m4} {m5}{m6,m7}{m8}

할 수 있다는 의미이다.

채널 1의 주파수 성분비를 이용하여 8가지 동작을 3개의 그룹으로 클러스터링한 결과에서 피험자 독립적인 클러스터의 집합은 {{동작1, 동작2}, {동작5, 동작6}}, 또는 {{동작1, 동작2}, {동작7, 동작8}}이다. 왜냐하면, 피험자 3의 경우에는 {동작1, 동작2, 동작3}이 하나의 클러스터이지만, 다른 피험자의 경우 {동작1, 동작2}만이 하나의 클러스터이므로 동작3을 {동작1, 동작2} 클러스터 안에 포함할 수 없기 때문이다. 동작4의 경우도 마찬가지로 설명할 수 있다. 따라서 동작3, 동작4는 무관심항(don't care term)으로 처리한다. 즉, 동작3, 동작4는 채널 1의 주파수 성분비를 3개로 클러스터링한 속성을 사용해서 다른 동작과 분류할 수 없다는 뜻이다.

이런 과정을 추출된 각 채널의 4가지 특징에 대해서 반복 수행하면 4개의 클래스를 분류해주는 공통 클러스터 집합들을 찾을 수 있다.

6) 최소 특징 집합 선택(minimal feature set selection): 선택된 공통 클러스터 집합에 러프집합이론<sup>[21]</sup>과 바타케리어 거리(Bhattacharyya distance)<sup>[16]</sup>를 적용하여 각 클래스 사이의 분리도가 가장 좋은 최소 특징 집합을 선택할 수 있다. 러프집합이론은 표 3과 같이 횡축으로 여러 개의 속성들로 구성된 조건부와 결정부를 갖고, 종축으로 여러 개의 객체들을 갖는 의사 결정표로부터 결정부의 속성을 가려낼 수 있는 조건부 속성과 속성값으로 이루어진 최소의 규칙을 제공해준다. 표 3의 의사결정표로부터 러프집합이론을 이용하여 8

가지 동작을 4개의 클래스로 분류해 줄 수 있는 리덕트를 찾는다. 리덕트란 러프집합이론의 용어로서 결정부의 속성을 구별해 낼 수 있는 최소의 조건부 속성들의 집합을 말하며, 주어진 의사결정표에 대해 여러 개의 리덕트가 존재할 수 있다.

표 3의 속성을 정의할 때 각 동작의 특징값의 평균값만을 이용하여 클러스터링한 결과를 이용하였다. 따라서, 분류하려는 동작의 특징값들이 미리 구해둔 각 동작의 특징 값의 평균값과 비슷할 때에만 각 리덕트는 8가지 동작을 4개의 클래스로 잘 분류해 줄 수 있다. 구해진 21개의 리덕트를 각각 구성하는 속성(attribute)들의 분산 정보를 이용하여 최적의 리덕트를 선정할 수 있다. 분리의 관점에서 보면, 다른 클래스간에는 거리가 멀수록, 동일한 클래스 안에는 거리가 작을수록 분리가 용이하다. 바타케리어 거리를 이용하여 분리도가 가장 높은 최적의 리덕트를 선정할 수 있으며 식 (7)로 정의된다.

$$\mu(1/2) = \frac{1}{8} (\mathbf{M}_2 - \mathbf{M}_1)^T \left\{ \frac{\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2}{2} \right\}^{-1} (\mathbf{M}_2 - \mathbf{M}_1) + \frac{1}{2} \ln \frac{\left| \frac{\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2}{2} \right|}{\sqrt{|\boldsymbol{\Sigma}_1| |\boldsymbol{\Sigma}_2|}} \quad (7)$$

여기서,  $\mathbf{M}_1, \mathbf{M}_2$ 는 클래스 1, 2의 평균(mean),  $\boldsymbol{\Sigma}_1, \boldsymbol{\Sigma}_2$ 는 클래스 1, 2의 공분산(covariance),  $|\cdot|$ 는 행렬식을 나타낸다. 분리도가 가장 높은 두 개의 리덕트를 표시하면 표 4와 같다.

표 3. 의사결정표  
Table 3. Decision Table.

특징 (feature)	조건부					결정부	
	주파수 성분비 (채널 1)					...	절대적분치 (채널4)
속성번호	$a_0$	$a_1$	$a_2$	$a_3$	...	$a_{80}$	$a_{81}$
동작	cluster 2	cluster 3		cluster 4	...	cluster 4	
동작 1	Big	Big	Big	Big	...	Small	클래스 1
동작 2	Big	Big	Big	Big	...	Small	클래스 1
동작 3	Big	×	×	×	...	×	클래스 2
동작 4	Big	×	×	×	...	×	클래스 2
동작 5	Small	Small	×	×	...	Big	클래스 3
동작 6	Small	Small	×	×	...	×	클래스 3
동작 7	Small	×	Small	×	...	Medium	클래스 4
동작 8	Small	×	Small	Small	...	×	클래스 4

표 4. 분리도가 가장 높은 두 개의 리덕트  
Table 4. The two reducts with the highest separability.

속성 번호	속성(attribute)	클래스 1		클래스 2		클래스 3		클래스 4	
		동작1	동작2	동작3	동작4	동작5	동작6	동작7	동작8
a9	주파수성분비, 채널3, clu3	×	×	Small	Small	×	Med.	Big	Big
a65	절대적분치, 채널2, clu3	Med.	Med.	Big	Big	Small	Small	Small	Small
a73	절대적분치, 채널3, clu4	×	×	Small	Small	Med.	×	Big	Big
a9	주파수성분비, 채널3, clu3	×	×	Small	Small	×	Med.	Big	Big
a38	분산, 채널4, clu3	×	×	Small	Small	Big	×	Med.	Med.
a65	절대적분치, 채널2, clu3	Med.	Med.	Big	Big	Small	Small	Small	Small

4. 8가지 기본 동작 분류

3절에서 설명된 최소 특징 집합과 절대적분치의 평균기울기를 이용하면 새로 측정된 근전도 신호에서 8 가지 기본 동작을 분류할 수 있다. 새로 측정된 근전도 신호에서 전처리 과정을 거친 후 3절에서 제안한 방법을 이용하여 최소 특징 집합을 추출한다. 추출된 최소 특징 집합을 학습된 퍼지 최대-최소 신경망을 이용하면 4개의 클래스로 분류가 가능하며 각 클래스 안에서 절대적분치의 평균기울기를 이용하면 각각의 동작을 분류할 수 있다. 추출된 최소 특징 집합을 이용하여 퍼지 최대-최소 신경망을 학습하는 과정은 다음과 같다.

1) 퍼지 최대-최소 신경망을 이용한 학습: 퍼지 최대-최소 신경망(FMMNN)<sup>[19]</sup>은 지도 학습(supervised learning) 신경망 패턴 분류기이다. 각 클래스는 퍼지 집합으로 표현되는 초상자(hyperbox)의 합집합에 의해 표현되며 초상자는 n차의 최대-최소값에 의하여 결정되며 소속 함수는 식 (8)로 나타난다.

$$b_j(A_h) = \frac{1}{2N} \sum_{i=1}^N [\max(0, 1 - \max(0, \gamma \times \min(1, a_{hi} - w_{ji}))) + \max(0, 1 - \max(0, \gamma \times \min(1, v_{ji} - a_{hi})))] \quad (8)$$

여기서,  $A_h = (a_{h1}, a_{h2}, \dots, a_{hn}) \in I^n$  이고,  $h$  번째 입력 패턴이다.  $V_j = \{v_{j1}, v_{j2}, \dots, v_{jn}\}$ 는  $j$  번째 초상자(hyperbox)인  $B_j$ 를 위한 최소값들이고,  $W_j = \{w_{j1}, w_{j2}, \dots, w_{jn}\}$ 은  $B_j$ 를 위한 최대값들이다.  $\gamma$ 는 민감도 계수(sensitivity parameter)로 얼마나 급하게 소속 함수를 감소해 갈 것인가를 결정한다.

FMMNN은 온라인 학습 기능이 있다. 즉, 새로운 데이터에 의하여 초상자의 크기를 변화시켜 적응성을 가지도록 구성되어 있다. 온라인 학습 기능은 근전도 패턴 분류기에서 아주 중요하다. 왜냐하면 근전도 신호는 시간에 따라 변하는 비정상적인 성질을 가지고 있기 때문이다. 또한 FMMNN은 비선형 분리(nonlinear separability)가 가능하고 클래스의 중복(overlapping classes) 기능을 가졌다.

FMMNN에서 학습 데이터에 대하여 여러 개의 초상자의 최대와 최소에 대한 학습 기능은 다음의 세 가지 단계로 이루어진다.

- 확장(expansion): 어떤 초상자가 확장될 수 있는지를 확인하고, 만약 확장될 수 있는 초상자가 없다면 새로운 초상자를 생성한다.
- 중복(overlap): 다른 클래스에 속하는 초상자끼리 겹침이 있는지 확인한다.
- 축소(contraction): 다른 클래스를 나타내는 초상자 사이에 겹침이 있으면, 각 초상자를 최소로 변화시키면서 겹침을 제거한다.

앞서 언급한 세 가지 단계에 의하여 주어진 데이터를 학습한다. 확장할 때에는 확장 범주(expansion criterion)인 식 (9)를 만족할 경우에만 확장한다.

$$\theta \geq \sum_{i=1}^N (\max(w_{ji}, x_{hi}) - \min(v_{ji}, x_{hi})) / n \quad (9)$$

즉, 확장된 뒤에도 초상자의 크기는 항상 일정한 범위 내에 들어올 수 있도록 확장될 수 있는 초상자의 크기를 제한한다. 여기에서  $X_k = (x_{k1}, x_{k2}, \dots, x_{kn})$



$\in I^m$ 이고,  $k$  번째 입력 패턴이다.

8가지 동작 근전도 데이터에서 제안한 방법으로 결정된 표 4의 최소특징집합을 추출한 뒤에 다음의 매개 변수를 이용하여 퍼지 최대-최소 신경망(FMMNN)을 학습하였다.  $\gamma$ 는 민감도 계수(sensitivity parameter)로 4를 사용하였다. 각 클래스의 초상자 개수는 500개로 제한하였으며 초상자의 증가정도는 0.005로 하였다.

그림 5는 새로 측정된 임의의 동작을 8가지 동작으로 분류하는 흐름도이다.




그림 5. 8가지 동작을 분류하는 흐름도  
Fig. 5. Flowchart for classifying the primitive motions.

5. 분류결과에의 확신도

재활 로봇은 인간과 공존하는 환경에서 작업을 수행하기 때문에 로봇 제어의 안전성이 아주 중요하다. 동작이 잘못 분류되었을 때 사용자가 원하지 않는 작업을 로봇이 수행하게 된다면 사용자는 시스템을 신뢰하기 힘들다. 어떤 분류기라도 100%의 분류 성공률을 기대하기 힘들기 때문에 분류된 결과에 확신도를 계산할 필요가 있다. 즉, 확신도가 낮은 분류 결과에 대해서는 작업을 수행하지 않는 방식을 택하는 것이 사용자에게 시스템에 대한 신뢰성을 줄 수 있다.

FMMNN의 출력은 최종 분류 클래스의 소속도 함수

값으로 [0, 1]사이의 값을 갖는다. 최종 분류 결과가 클래스  $k$ 로 분류되었을 때 분류 결과의 확신도( $P_k$ )는 식 (10)을 이용하여 구하였다.

$$P_k = \frac{m(c_k)}{\sum_{j=1}^k m(c_j)} \times 100 \tag{10}$$

여기서,  $m(c_j)$ 는 클래스  $j$ 의 출력 소속도 함수 값,  $m(c_k)$ 는  $k$ 번째 클래스의 출력 소속도 함수 값을 나타낸다. 예를 들어, 4개의 출력 클래스를 가지는 패턴 분류기에서 최종 소속도 함수 값이 (1, 0, 0, 0)와 (0.7, 0.5, 0.3, 0.2)인 두 가지 경우에 대해 생각해 보자. 두 경우 모두 최종 분류 결과는 클래스 1이지만, (1, 0, 0, 0)의 경우는 100%의 확신도를 (0.7, 0.5, 0.3, 0.2)는 41%의 확신도를 나타낸다. 따라서 식 (10)을 이용하여 분류결과에의 확신도를 계산할 수 있다. 본 논문에서는 실험을 통해 확신도가 50%미만인 결과에 대해서는 동일한 동작을 피험자에게 다시 요구하도록 시스템을 구현하였다.

IV. 실험 및 결과 고찰

- 1. 실험
- 1) 실험환경

본 논문에서는 8명의 정상인을 대상으로 차폐룸이 아닌 일상 생활 공간에서 실험하였다. 왜냐하면 본 시스템의 사용대상자인 장애인 및 노약자는 차폐룸이 아닌 일상 생활 공간에서 생활하기 때문이다. 외부 실험 환경에 대해서 특별한 제약을 가하지 않았으며 피험자들은 특별한 훈련을 거치지 않았다. 근전도 신호를 측정하기 위해 전극용 전도젤이 발라져 있는 1회용 Ag/AgCl 전극을 사용하였고, 쉴드 케이블(shield cable)을 이용하여 주위 환경 잡음의 영향을 감소시켰다. 측정된 근전도 신호는 생체 신호 증폭기인 GRASS사의 LINK-15에 의해 5000배 증폭된다. 신호를 측정할 때 생체 신호 증폭기에 하드웨어적으로 구현되어 있는 10Hz-1kHz의 대역통과필터를 이용하였고 60Hz 전원 잡음을 제거하기 위하여 노치 필터(notch filter)를 사용하였다. 10Hz-1kHz의 대역통과필터를 사용한 이유는 팔 운동시 근전도 신호의 유용한 정보가 10Hz-1kHz 사이에 있기 때문이다<sup>[13][18]</sup>. 필터를 통과한 근전도 신호

는 Analog Devices사의 AD976을 이용하여 A/D 변환시켰다. 이 때 샘플링 주파수는 2kHz이고 16bit로 이산화 하였다. A/D 변환된 근전도 신호는 컴퓨터의 입력 신호로 들어가 저주파 잡음인 동잡음을 제거하기 위해서 30Hz의 차단 주파수를 가지는 2차 고역통과 필터에 통과하게 되며, 이 신호를 이용하여 패턴 인식 과정 및 재활 로봇 팔을 구동한다. 그림 6은 근전도 신호의 측정 및 재활 로봇 팔 시스템을 제어하는 전체적인 시스템의 개략도이다.




그림 6. 근전도 신호의 측정 및 재활 로봇 팔 제어의 전체적인 개략도  
 Fig. 6. Overall system configuration to measure EMG and to control a rehabilitation robotic arm.




그림 7. 동작 1에서의 절대적분치의 평균기울기  
 Fig. 7. ASIIV of motion 1.

2) 동작 분류를 위한 데이터의 획득

피험자들을 두 그룹으로 나누어 실험을 하였다. 그룹 A의 4명에 대해서 3장에서 제안한 근전도 패턴 분류

과정을 설계 및 테스트하기 위한 근전도 신호 획득을 위해 정의된 8가지 동작을 20회씩 측정하였다. 그룹 B의 4명에 대해서는 제안한 방법으로 선택된 최소특징 집합이 사용자 독립적인지를 알아보기 위하여 8가지 동작을 10회씩 측정하여 테스트 데이터로 사용하였다.

3) 근전도 신호의 패턴 분류 실험

① 절대적분치의 평균기울기를 이용한 각각의 클래스내의 각 동작의 분류: 채널 1의 절대적분치의 평균기울기를 이용하면 동작1과 동작2를 분류할 수 있다(그림 7, 그림 8). 나머지 동작들도 채널2, 채널3, 채널4의 절대적분치의 평균 기울기를 이용하면 된다.




그림 8. 동작 2에서의 절대적분치의 평균기울기  
 Fig. 8. ASIIV of motion 2.

그림 7, 그림 8에서 x축은 실험횟수를, y축은 절대적분치의 평균기울기를 나타낸다.

② 8가지 동작 분류 실험

i) 새로운 피험자에 대한 8가지 동작의 분류: 제안된 방법으로 선택한 특징의 사용자 독립성을 검증하기 위해 그룹 A의 피험자의 데이터로 구성된 퍼지 패턴 분류기와 학습된 퍼지 최대-최소 신경망에 새로운 피험자(그룹 B) 4명으로부터의 근전도 신호를 테스트 데이터로 하여 8가지 동작을 분류하였다.

표 5에서 알 수 있는 것처럼 새로운 피험자(그룹 B)에 대해서 퍼지 패턴 분류기는 83%의 성공률을, FMMNN은 90%의 성공률을 나타내고 있음을 알 수 있다. 즉, 제안된 방법으로 선택된 특징은 사용자 독립

적인 특징이라고 할 수 있다.

여기서 퍼지 패턴 분류기는 다음의 과정을 거쳐 설계하였다. 표 4에서 선정된 최소특징집합을 이용하여 퍼지 규칙을 구성하였으며 가우시안 형태의 퍼지 함수를 사용하였다. 각 함수의 중심값과 중심값에서 퍼진 정도를 나타내는 분산값을 정하는 방법을 a9(주파수 성분비, 채널2, cluster3)를 예로 설명해 보면 다음과 같다. 네 명의 피험자들로부터 구해진 8가지 동작에 대한 데이터에서 a9를 추출한 뒤에 Fuzzy C-means Algorithm을 이용하여 3개로 클러스터링한다. 3개로 클러스터링 한 이유는 a9가 8가지 동작을 세 그룹으로

나누어주기 때문이다. 클러스터링 된 3개의 그룹에서 각 그룹의 평균값을 각 퍼지 멤버십 함수의 중심값으로, 각 그룹의 분산값을 각 퍼지 멤버십 함수의 분산값으로 정하였다. 추론 방법은 Product-Sum 방법(Mizumoto's method)을 사용하였으며 최대치 평균법(mean of maxima method)을 이용하여 비퍼지화 하였다.

표 6은 새로운 피험자 4에 대해서 FMMNN을 이용하여 8가지 동작을 분류한 결과이다. 동작7과 동작8(클래스4)을 동작5, 동작6(클래스3)으로 잘 못 인식하는 경우가 가끔 발생하였는데, 이는 클래스3과 클래스4의 움직임에 관여하는 근육들이 보다 밀접하게 서로에게 영향을 미치기 때문이다. 즉, 삼박골의 움직임을 측정하기 위해 선정된 삼각근은 위팔을 벌리는 운동과 관련이 있으며 이는 클래스3, 클래스4에 속해 있는 동작5, 동작6, 동작7, 동작8의 모든 움직임과 관련이 있다.

ii) 선택된 특징에 따른 분류 성능 비교 표 7은 퍼지 최대-최소 신경망을 학습함에 있어서 특징의 수를 다르게 하면서 8가지 동작을 분류한 결과이다. 특징 선택에 대한 특별한 기준이 없어 추출된 모든 특징들을 사용하는 경우(A)와 추출된 특징들을 보고 피험자 독립적이라고 생각되어지는 특징을 경험적으로 선택한 경우(B)와 제안된 방법으로 특징을 선택된 경우(C)에 대해서 퍼지 최대-최소 신경망을 이용하여 학습을 하고 난 뒤에 그 분류

표 5. 새로운 피험자의 8가지 동작 분류 성공률

Table 5. Comparison of EMG recognition rates in group B by fuzzy classifier (without learning) and FMMNN(with learning) composed by the feature sets of group A.

피험자 번호	퍼지 패턴 분류기	퍼지 최대-최소 신경망
새로운 피험자 1	83 %	90 %
새로운 피험자 2	83 %	89 %
새로운 피험자 3	80 %	88 %
새로운 피험자 4	85 %	91 %
평균 성공률	83 %	90 %

표 6. 새로운 피험자4의 FMMNN을 이용한 8가지 동작에 따른 분류 성공률

Table 6. EMG recognition rates in new subject ID 4 according to 8 primitive motions using FMMNN.

분류동작 인식결과	동작							
	동작 1	동작 2	동작 3	동작 4	동작 5	동작 6	동작 7	동작 8
동작 1	10	0	0	0	0	0	0	0
동작 2	0	10	0	2	0	0	0	0
동작 3	0	0	10	0	0	0	0	0
동작 4	0	0	0	0	0	0	0	0
동작 5	0	0	0	0	10	0	3	1
동작 6	0	0	0	0	0	10	0	1
동작 7	0	0	0	0	0	0	7	0
동작 8	0	0	0	0	0	0	0	8
성공률	100%	100%	100%	80%	100%	100%	70%	80%

표 7. 특징 집합의 선택에 따른 분류 성공률

Table 7. Comparison of EMG recognition rates according to feature sets.

피험자 번호	16개의 모든 특징 사용시(A)	휴리스틱하게 택한 6개의 특징을 사용시(B)	제안된 방법으로 선택된 4개의 특징을 사용시(C)
피험자 1	90 %	96 %	94 %
피험자 2	91 %	83 %	93 %
피험자 3	93 %	96 %	98 %
피험자 4	85 %	89 %	94 %
평균 성공률	90 %	91 %	95 %

성공률을 살펴보았다.

피험자 1의 경우에 경험적으로 선택된 특징으로 분류한 결과가 가장 좋게 나타나지만, 피험자 2의 경우에 있어서는 그 결과가 좋지 않음을 알 수 있다. 이에 비해 제안된 방법으로 선택된 특징의 경우에는 4명의 피험자 모두 좋은 결과를 나타내고 있음을 알 수 있다.

4) 로봇 팔 구동 실험

근전도 패턴 분류 실험의 결과를 이용하여 6축 로봇 팔 구동 실험을 하였다. 실험에 사용한 로봇은 독일 AMTEC사에서 제작된 PowerCube로 선형 모듈(linear module), 회전 모듈(rotary module), 손목 모듈(wrist module), 그리퍼 모듈(gripper module)로 구성된다. Powercube의 외관과 실험에 이용된 로봇 구조는 그림 9와 같다.




그림 9. PowerCube의 외관과 실험에 이용된 로봇 구조

Fig. 9. The experiment configuration with Power-Cube.

로봇 팔 구동 실험에서는 정의된 8가지 동작을 표 8과 같이 일대일 대응을 시켜 실험하였다. 즉, 근전도 신호를 측정, 분류하여 분류된 동작에 대응하는 로봇 구동 신호를 만들어 주었다. 표 8에서 각 축의 이동 각도는

로봇의 구조에 의해 제한된다. 실험 결과 피험자의 팔 동작에 대응하는 로봇의 움직임을 관찰할 수 있었다.

표 8. 기본 동작과 로봇 팔의 대응관계

Table 8. The relationship between primitive motions and the movement of a robotic arm.

동작 번호	기본 동작	로봇 팔 회전축	회전 각도
1번	손목 안으로 회전	6번	+90도
2번	손목 밖으로 회전	6번	-90도
3번	팔꿈치 굽히기	4번	+120도
4번	팔꿈치 펴기	4번	0도
5번	상박골 위로 움직이기	1번	-90도
6번	상박골 아래로 움직이기	1번	0도
7번	상박골 안으로 움직이기	2번	-30도
8번	상박골 밖으로 움직이기	2번	30도

V. 결론 및 추후과제

본 논문에서는 기존의 재활 로봇 시스템이 가지는 입력 수단의 단점을 해결하기 위하여 사용자의 팔에서 측정된 근전도 신호를 이용하여 정의된 8가지 동작을 분류하는 패턴 인식기를 설계하였다. 근전도 신호를 이용하는 경우 비 구조화된 환경 하에서 다른 입력 방법을 사용할 수 없는 중증 장애인에게로의 시스템 확장이 가능하며, 다른 입력 방법에 비해 자연스럽게 사용자의 입력 명령을 전달해 줄 수 있다.

근전도 신호를 분류하는 기존의 방법들이 가지는 가장 큰 단점인 사용자 의존적인 면을 해결하기 위해 사용자 독립적인 특징(feature)을 찾을 수 있는 방법을 제안하였다. 즉, 사용자마다 다른 근전도 신호에서 사용자

독립적인 특징을 찾고, 이를 이용하여 설계한 패턴 인식기의 분류 결과로부터 제안한 방법의 유용성을 검증하였다. 제안한 방법으로 추출된 특징을 이용하여 퍼지 패턴 분류기를 설계하여 83%의 분류 성공률을 얻었다. 퍼지 최대-최소 신경망을 이용하여 학습을 한 후에는 90%의 분류 성공률을 얻었다. 또한 최종 분류된 결과와 그 결과의 확신도를 함께 고려하여 보다 인간 친화적인 시스템을 구현하였다.


사용자가 보다 자유롭게 재활 로봇 팔을 사용하기 위해서는 사람 팔이 가지는 7 자유도의 모든 동작(14가지 동작)으로의 기본 동작 확장이 필요하며, 또한 근전도 신호를 이용하여 연속적으로 로봇 팔을 제어하기 위해서 연속 동작에서 단위 동작을 분리해 인식하는 것이 필요하다. 또한 사용자가 위급한 상황에서 갑자기 긴장했을 때의 근전도 신호를 이용하여 로봇 팔에 정지할 수 있도록 긴급 정지 스위치(emergency stop switch)의 구현이 필요하다.

#### 참 고 문 헌

- [1] 한국보건사회연구원, 노인생활실태 분석 및 정책 과제, 한국보건사회연구원, 1995
- [2] Kazuhiko Kawamura, Sugato Bagchi, Moenes Iskarous, and Maged Bishay, "Intelligent Robotic Systems in Service of the Disabled," *IEEE Tr. on Rehab. Eng.*, Vol. 3, No. 1, pp. 14- 21, March, 1995.
- [3] Kazi, Z. Salganicoff M, Beitler, Chen S., Chester D. and Foulds R., "Direct Manipulation of 3-D objects Through Multimodal Control: Towards a Robotic Assistant for People with Physical Disabilities," *ASEL technical Report #ROB9509*, AI duPont Institute, Univ. of Delaware.
- [4] Carol A. Stanger, Carolyn Anglin, William S. Harwin, and Douglas P. Romilly, "Devices for Assisting Manipulation: A Summary of User Task Priorities," *IEEE Tr. on Rehab. Eng.*, Vol. 2, No. 4, pp. 256-265, Dec., 1994.
- [5] Jin-Woo Jung, Won-Kyung Song, Heyoung Lee, Jong-Sung Kim, Zeungnam Bien, "A Study on the Enhancement of Manipulation Performance of Wheelchair-mounted Rehabilitation Service Robot", *Proc. of ICORR 99*, pp. 42-49, Stanford, California, U.S.A. July 1-2, 1999.
- [6] Brenda Bigland and O. C. J. Lippold, "The relation between force, velocity and integrated electrical activity in Human Muscles," *J. Physiology*. Vol. 123, pp. 214-224, 1954.
- [7] 김성환 외, "팔격근의 근전도 신호 분석을 위한 디지털 신호처리 시스템의 설계," *의공학회지*, 제 17권, 제 2호, pp. 155-164, 1996
- [8] Arnon Cohen, *Biomedical (vol 2)*, CRC Press Inc., 1986.
- [9] G. N. Saridis and T. Gootee, "EMG pattern analysis and classification for a prosthetic arm," *IEEE Tr. Biomed. Eng.*, Vol. BME-29, pp. 403-409, June 1982.
- [10] 장영진, 권장우, 한영환, 장원석, 홍승홍, "신경회로망과 확률모델을 이용한 근전도 신호의 패턴 분류에 관한 연구," *전자공학회지*, 제 28권, 제 10호, pp. 85-95, 1991
- [11] Daisuke Nishikawa, Wenwei Yu, Hiroshi Yokoi and Yukinori Kakazu, "EMG Prosthetic Hand Controller Discriminating Ten Motions using Real-Time Learning Method," *IROS '99*, Vol. 3, pp. 1592-1597, Kyungju, Korea, 1999.
- [12] D. S. Dorcas, V. A. Dunfield and R. M. Scott, "Improved myoelectric control system," *Med. Biol. Eng.*, Vol. 8, pp. 333-341, 1970
- [13] Daniel Graupe and William K. Cline, "Functional Separation of EMG Signals via ARMA Identification Methods for Prosthesis Control Purposes," *IEEE Tr. on Systems, Man, and Cybernetics*, Vol. SMC-5, No. 2, pp. 252-259, March 1975.
- [14] Osamu Fukuda, Toshio Tsuji, Akira Otsuka and Makoto Kaneko, "An EMG-based Rehabilitation Aid for Prosthetic Control," *IEEE Int'l Workshop on Robot and Human Communication*, Vol. 1, pp. 214-219, Takamutsu, Kagawa, Japan, Sep.30- Oct.2, 1998.
- [15] Yong-Sheng Yang, F. K. Lam, Francis H. Y.

- Chan, Yuan-Ting Zhang, Philip. A. Parker, "A New Fuzzy Approach for Pattern Recognition with Application to EMG classification," *The 1996 IEEE Int'l Conf. on Neural Networks*, Vol. 2, pp. 1107- 1114, New York, USA, 1996.
- [16] Keinosuke Fukunaga, *Introduction to statistical pattern recognition*, Academic Press, first edition, 1972.
- [17] Seok-Pil Lee, Jung-sub Kim, and Sang-hui Park, "An Enhanced Feature Extraction Algorithm for EMG Pattern Classification," *IEEE Tr. on Rehab. Eng.*, Vol. 4, No. 4, pp. 439-443, Dec. 1996.
- [18] John V. Basmajian and Carlo J. De Luca, *Muscle Alive*, Williams & Wilkins, fifth edition, 1985.
- [19] P. Simpson, Fuzzy Min-Max Neural Networks- Part 1: Classification, *IEEE Tr. on Neural Networks*, Vol. 3, pp. 776- 786, Sep., 1992
- [20] W.-K. Song, H. Lee, and Z. Bien, "KARES: Intelligent wheelchair-mounted robotic arm system using vision and force sensor", *Robotics and Autonomous Systems*, Vol. 28, No. 1, pp. 83-94, 1999.
- [21] Pawlak, Z., *Rough Sets: Theoretical Aspects and Reasoning about Data*, Kluwer Academic Publishers, 1991.

저 자 소 개



韓 政 秀(正會員)

1975년 4월 5일생, 1998년 2월 경북대학교 공과대학 전자공학과 졸업(학사). 2000년 2월 한국과학기술원 전기 및 전자공학과 졸업(석사). 2000년 3월~현재 한국과학기술원 전자전산학과 전기및전자공학전공

박사과정 재학 중. 주관심 분야는 생체신호 처리 및 응용, 패턴 인식, 소프트웨어 컴퓨팅(Soft Computing), 재활공학 시스템 등임



方 遠 喆(正會員)

1969년 4월 1일생, 1994년 2월 한양대학교 공과대학 전자공학과 졸업(학사). 1996년 2월 한국과학기술원 전기 및 전자공학과 졸업(석사). 1996년 3월~현재 한국과학기술원 전자전산학과 전기및전자공학전공

박사과정 재학 중. 주관심 분야는 지능제어(Intelligent Control), 러프 집합 이론(rough set theory), 소프트웨어 컴퓨팅(Soft Computing), Knowledge Discovery, Machine Learning 등임

宋 原 慶(正會員) 第 35卷 S編 第 3號 參照

1996년 3월~현재 한국과학기술원 전자전산학과 전기 및전자공학전공 박사과정 재학 중. 주관심 분야는 로봇 시각 제어(Visual Servoing), 재활 공학 시스템, 서비스 로봇, 인간-로봇 상호작용, 소프트웨어 컴퓨팅(Soft Computing), 실시간 비전 등임

李 熙 暎(正會員) 第 35卷 S編 第 11號 參照

전남대학교 전자공학과 교수

金 鍾 成(正會員) 第 36卷 C編 第 6號 參照

卞 增 男(正會員) 第 36卷 C編 第 6號 參照

한국과학기술원 전자전산학과 교수, 인간친화 복지 로봇시스템 연구센터 소장