

## 신경회로망과 퍼지필터를 사용한 근전도신호의 기능변별에 관한 연구

장영건·홍승홍

=Abstract=

### A Study on Function Discrimination for EMG Signals Using Neural Network and Fuzzy Filter

Young Gun Jang\*, Seung Hong Hong

The most important requirement for the controller of a prosthetic arm is that it has a high fidelity discriminator where the motion control may be performed open loop using EMG signals as a control source<sup>20)</sup>. Therefore, it is very effective method to reduce the influence of misclassification of classifier for the total system performance.

This paper presents the new function discrimination method which combines MLP classifier and fuzzy filter by stages for the requirement. The major advantage of MLP is a consistent learning capability for the easy adaptation to environments. The fuzzy filter uses all informations of MLP outputs and prior EMG activity informations which increase as the experience increases. That property is superior to one which uses maximum output of MLP in view of information amounts and quality.

Simulation result shows that proposed method is superior to the probabilistic model, MLP model and the combined model of both<sup>1~4)</sup> in the respect of discrimination quality.

**Key words** : Discriminator, Neural Network, Fuzzy filter, EMG.

### 서 론

근전도신호는 근육의 수축시에 발생하는 전기적 신호로서, 척수에서 신경임펄스가 발생되어 운동뉴런을 활성화시키고, 이에 따라 운동단위 (motor unit) 내의 근섬유가 활성화되면서 전위차 (motor unit action potential)가 발생하는데, 이 현상은 표면전극에 의한 공간적 합으로서 추출이 가능하다. 힘이나 속도의 추정을 위한, 표면전극에 의한 근전도 (electromyogram)의 측정은 근육내의 운동뉴런에 직접 침투시키는 침형태의 전극에 의한 것보다 좀 더 분명

하고 신뢰성이 있다. 보철제어를 위한 신호 처리에 대한 연구로서 아티팩트 (artifact)를 줄이거나 신호 대 잡음비를 높이는 방식에 관한 연구<sup>2, 19)</sup>, 기능분리의 신뢰도 및 정도를 높이는 방식에 관한 연구<sup>1, 4~7, 9~11, 13~14, 16)</sup>와 실시간 처리에 관한 연구<sup>3)</sup> 등이 있다. Hefftner<sup>13)</sup> 등은 FNS (functional neuromuscular stimulation)를 하기 위한 제어신호로서 EMG신호를 해석하는 데 있어 4차 AR (autoregressive) 모델을 도입하였고, 첫번째 AR 파라미터값이 비교적 여러 가지 아티팩트에 둔감하다는 것을 밝혀냈다. Scott 등은 로그증폭기와 칼만필터 (Kalman filter)를 도입하여 0.8초

까지의 신호에 대해 탐지 레벨로서 0.15 정도의 오확률을 보였다. 기능분리에 대한 연구로서는 Graupe<sup>9)</sup> 등이 ARMA 모델을 적용하여 마이크로프로세서로 구현하였으며, 0.15~0.2초 이내에 완전한 분리를 할 수 있었고, 85% 정도의 성공율을 보였다. Saridis<sup>10)</sup> 등은 영교차수와 분산을 이용하여, 6개의 기본운동으로 구성된 27가지 운동에 대해, 85~90%의 운동이 최대오분류확률추정이 10%미만으로 분리될 수 있었다. Triolo<sup>14)</sup> 등은 기능분리에 탁월한 병렬필터링 팔기능분류기와 신호대잡음비에서 우수한 다중채널근전처리기를 결합한, 완벽하고 견고한 다중채널 시계열근전처리기를 제안하였다.

그러나 언급한 연구들은 주로 기능분리, 잡음제거 및 부분적인 제어방식에 치중하여, 근전도를 신호원으로 사용하는 보철제어를 위한 신호처리 및 제어에 통합적으로 접근하지 못하였다. 특히, 기능분리에 관한 연구는 제어에 연결시키는 방식에 대한 언급이 거의 없으며, 오인식한 경우나 불확실한 경우, 그것을 어떻게 제어에 반영하느냐에 대한 연구가 미약하였다. 일반적으로 결정방식에 있어 출력치에 대한 문턱치를 도입하거나, 엔트로피에 대한 문턱치를 적용하여 다단계결정을 하는 방식을 취하나, 행위에 대한 반응시간이 지연되는 문제가 남는다<sup>6)</sup>. 인공 팔의 보철 제어는 1) 인간의 눈에 입력되는 목표물 및 현재 인공팔에 대한 시각정보를 뇌에서 처리하여, 현재위치 정보를 계산시키고, 2) 팔의 운동궤적을 계산하여, 오차에 따른 운동벡터를 발생시켜, 해당 근육에 전기의 펄스열로 전달시키며, 3) 근육에서 발생된 전기활동인 근전도신호를 취득하여, 근육에서 의도된 운동방향 및 힘을 추정하고 4) 추정된 신호로부터 인공팔이 움직일 궤적을 계획하여 제어신호를 발생시키는 시스템으로 구성된다. 따라서 다단계 결정에 의한 반응시간의 지연은 제어계에 매우 큰 악영향을 가져올 가능성을 내포한다.

본 논문에선 이러한 문제점을 줄이는 방식으로, 신경회로망과 퍼지필터 및 매퍼로 결합된 단계적 변별기(Discriminator)를 제안하였다.

신경회로망만으로 제어출력을 만드는 방식은 첫번째 회로망내에 정의된 각 층(Layer) 및 노드의 물리적 의미를 알기 어렵고, 두번째 회로망의 강한 비선형성 및 흡인력때문에, 학습시킨 패턴의 사이값들이 입력될 경우 전혀 관계 없는 값으로 매핑되거나, 학습된 패턴값에 대한 출력으로 매핑되는 경향에 대해 대처할 방법이 없다. 또한 뉴로퍼지 회로망(Neuro-Fuzzy Network)의 경우, 귀속도함수의 형태 등 제한사항을 도입하기 어렵고, 역전파알고리즘을 사용하여 학습하는 경우 모든 가중치(weight)가 규칙기반과

는 무관하게 유사하게 갱신되어, 마지막층에서 첫번째 층으로의 전파가 비효율적이다<sup>18)</sup>. 퍼지로지만을 사용하는 경우엔 복잡한 시스템의 경우, 입출력관계에 대한 통찰력을 얻기가 어렵고, 경험과 적용의 반복으로 귀속도함수를 조절하여야 하며, 기계적 학습이 불가능하여 특히 온라인 학습에 의한 지속적 조절이 어렵다. 또한 경험규칙 및 사전지식을 입력특징에 대해 적용하여야 하므로, 적용하기가 비교적 애매한 경우가 많다. 따라서 본 논문에서 제안한 변별기로서의 신경회로망과 필터 및 매퍼의 역할을 담당하는 퍼지로지의 단계적 결합형은, 중간단계로서의 신경회로망의 출력의 의미가 분명하여 경험법칙 및 사전지식을 도입하기가 용이하며, 신경회로망의 학습능력과 퍼지로지의 지식기반 및 경험법칙의 적용의 용이성을 최대한 활용할 수 있는 장점이 있다.

### MLP 분류기

1958년 Rosenblatt에 의해 Perceptron의 개념이 도입된 이래, 수십년에 걸쳐 간헐적으로 패턴인식에 있어, Perceptron의 구조 및 학습알고리즘에 대한 연구가 진행되어 왔다<sup>8)</sup>. 1986년 Rumelhart 등에 의해 Perceptron을 효율적으로 학습시킬 수 있는 오차의 역전파알고리즘(error backpropagation)이란 델타규칙을 일반화시킨 학습프로시저가 만들어짐에 따라, 패턴인식분야에 MLP의 적용이 활발히 이뤄지고 있다<sup>7, 11)</sup>.

다층퍼셉트론은 가중화된 연결을 사용해 상호반응하는 신경들 또는 2상태 시그모이드 처리요소들의 층으로 이루어 졌으며, 입력층, 은닉층, 출력층으로 구성된다. 이에 대한 구조 및 구성은 그림 1에 표시하였다. 은닉층(Hidden Layer)은 다층으로 구성될 수 있다. 외부 입력벡터는 입력층에 있는 노드에 연결되어 회로망에 공급되며, 회로망을 지도학습(Supervised Learning)방식에 의해 훈련되는 분류기로 사용할 시 해당출력을 1상태로, 나머지는 0상태로 고정하여, 연결가중치를 훈련시킨다. 신경은 활성함수로서 작용하며, 임의의 시간 t에 비제한적 활성입력  $x_i^h(t)$ 를 제한된 출력신호  $y_j^h(x(t))$ 로 변환시킨다. 보통 변환은 시그모이드 함수(Sigmoidal Function)를 사용하며, 제한된 단조증가함수의 형태를 갖는다.

$$y_j^h = \frac{1}{1 + \exp^{-cx_j^h}}, \quad c: \text{양의 상수} \quad (1)$$

따라서 c가 증가함에 따라 문턱함수로 점근적으로 접근한




그림 1. 다층퍼셉트론의 기본적 구성도  
Fig. 1. Basic Configuration of Multilayer Perceptron

다.  
h+1 층에 있는 신경 j에 수신되는 전체입력  $x_j^{h+1}$ 은

$$x_j^{h+1} = \sum_i y_i^h w_{ji}^h - \theta_j^{h+1} \quad (2)$$

- $y_i^h$  : 이전 h번째 층의 i번째 신경의 상태
- $w_{ji}^h$  : h번째 층의 i번째 신경에서 h+1번째 층의 j번째 신경으로 연결되는 가중치
- $\theta_j^{h+1}$  : h+1번째 층에 있는 j번째 신경의 문턱치

로 정의될 수 있다. 학습프로시저는 입력에 대한 지식과 원하는 출력에 의거한 은닉유니트의 내부 매개변수를 결정하는 것이다. 주어진 회로망 가중치벡터 w에 대해

$$E(w) = \frac{1}{2} \sum_{j,c} (y_{j,c}^h(w) - d_{j,c})^2 \quad (3)$$

- $y_{j,c}^h$  : H층에서의 출력노드 j에 대해 얻어진 값
- $d_{j,c}$  : 원하는 지도출력상태

가 성립하며, E(w)를 최소화하는 한가지 방법은 가중치의 셋트에 대해 시작하여 Gradient descent방법을 적용해 가면서 각 가중치를

$$\Delta w_{ji}^h(t) = -\epsilon \frac{\partial E}{\partial w_{ji}^h} + \alpha \Delta w_{ji}^h(t-1) - hdec w_{ji}^h(t-1) \quad (4)$$

$\epsilon$ : 양의 상수

$\alpha$ : 모멘텀  $0 \leq \alpha \leq 1$

hdec: 감쇄계수

t: 반복회수

의 양만큼 반복해서 갱신하는 것이다.

잘 훈련된 MLP의 출력이 특징벡터의 확률이 크다면, 베이즈 최적 변별기능(Bayes optimal discriminant function)을 근사적으로 모사한다는 것<sup>12)</sup>과 후확률의 추정<sup>12)</sup>이라는 것은 이전의 여러 연구에서 증명되었다. 따라서 MLP의 출력을 F(W<sub>i</sub>/X)라 하면

$$F(W_i/X) \cong P(W_i/X) \quad (5)$$

X: feature vector, W<sub>i</sub>: i번째 class

의 식이 성립한다. 또한 베이즈 프로세스(Bayesian process)에서 최대후확률(Maximum A Posteriori probability)은 오분류확률을 최소화하는 최대 변별기능(discriminant function)에 대응한다는 것이 밝혀져 있다. 그러나 이러한 결과는 국부적 결정에 국한된 것으로 1개의 샘플에 의한 판단으로 신뢰도가 부족할 땐 다단계결정법(multi stage decision method)을 사용하는 것이 오분류율을 순차적 샘플링에 의한 다수의 샘플로서 제어할 수 있는 잇점을 갖는다<sup>15, 16)</sup>. 연속된 EMG샘플을 서로 독립적이라고 가정하면, k개의 연속된 샘플(X<sub>1</sub>, X<sub>2</sub>, ..., X<sub>k</sub>)에서 오분류율을 최소화하는 분류를 행할 확률 P<sub>k</sub>(U<sub>j</sub>)는

$$P_k(U_j) = \prod_{i=1}^k P_i(u_j) \cong \max_j \prod_{i=1}^k F_i(W_j/X_i) \quad (6)$$

로 정의된다.

### 퍼지필터 및 매퍼

퍼지집합은 1965년 Lotfi Zadeh<sup>57, 58)</sup>에 의해 처음 도입되었으며, 애매함을 수학적으로 접근하는 새로운 방식을 제시하였다. 이 집합은 전통적 집합론의 일반화이며, 계산적 수학과 모델들을 포함하는 기본적인 구조중의 하나이다.

퍼지론에서 사용되는 기본적 수학적 전개는 다음과 같다. X를 대상공간이라 하고 X의 요소를 x라 표시하면 X = {x}이다. 퍼지집합 A는 귀속도함수  $\mu_A$ 에 의해서 특성화되며, X내에서 [0, 1]범위내의 값을 갖는다. 이는 A내의 x값의 귀속의 정도를 표현한다.

$$\mu_A(x) = [0, 1] \quad (7)$$

$$A = \{x, \mu_A(x) | x \in X\}$$

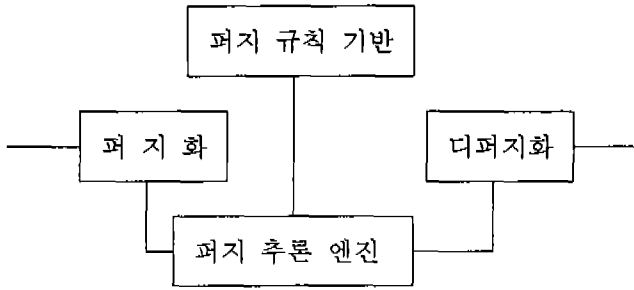


그림 2. 퍼지화기 및 디퍼지화기를 갖는 퍼지논리시스템의 기본적 구성

Fig. 2. Basic configuration of fuzzy logic system with fuzzifier & defuzzifier

일반적인 퍼지집합의 표현은 다음 식으로 표현한다.

$$A = \frac{\mu_A(x_1)}{x_1} + \frac{\mu_A(x_2)}{x_2} + \dots = \sum_i \frac{\mu_A(x_i)}{x_i} \quad (8)$$

위의 표현에서 더하기기호는 대수적 더하기가 아니라, 퍼지합을 의미한다. 본 시스템에서 사용된 퍼지로지시스템의 구조는 그림 2와 같다.

퍼지화를 위해 삼각형형태의 귀속도함수를 사용하였고, 다음 식으로 정의한다.

$$\begin{aligned} \mu_A(x) &= 0 & x < a_1 \\ &= \frac{x-a_1}{a_2-a_1} & a_1 \leq x \leq a_2 \\ &= \frac{a_3-x}{a_2-a_3} & a_2 \leq x \leq a_3 \\ &= 0 & x > a_3 \end{aligned} \quad (9)$$

$a_1, a_2, a_3$ 는 상수

퍼지추론엔진으로서 인간의 언어로 표현가능한 사전전문 지식을 규칙의 형태로 사용하였으며, 가정과 결과라는 식 10과 같은 관계식으로 표현하였다.

- R1 : If  $k_1$  is  $A_{11}, k_2$  is  $A_{12}, \dots, k_m$  is  $A_{1m}$  then  $x$  is  $B_1$
- or
- R2 : If  $k_1$  is  $A_{21}, k_2$  is  $A_{22}, \dots, k_m$  is  $A_{2m}$  then  $x$  is  $B_2$
- or
- ⋮
- Rn : If  $k_1$  is  $A_{n1}, k_2$  is  $A_{n2}, \dots, k_m$  is  $A_{nm}$  then  $x$  is  $B_n$

(10)




그림 3. 퍼지 필터 및 매퍼의 시스템 블럭도

Fig. 3. System Block Diagram of Fuzzy Filter & Mapper

or

Rp: If  $k_1$  is  $A_{p1}, k_2$  is  $A_{p2}, \dots, k_m$  is  $A_{pm}$  then  $y$  is  $B_p$

$k_i$ 는  $i=1,2,\dots,m$ 에 대한 입력퍼지변수,  $x, y$ 는 출력퍼지변수  $A_{ij}$  및  $B_j$ 는 각각  $i=1,2,\dots,m$  및  $j=1, 2,\dots,p$ 에 대한 입력출력값


$\mu_i^A(x)$ 과  $\mu_i^B(y)$ 을  $A_{ij}$ 과  $B_i$ 에 대한 귀속도함수라 할 때, 한 입력 ( $k_1, k_2, \dots, k_m$ )에 대한 출력퍼지집합  $B$ 는 다음 식과 같은 최대적 퍼지추론방식(Max Product Fuzzy inference Method)에 의해 계산될 수 있다.

$$\begin{aligned} \mu^B(x) &= \max_n \{ \mu_i^B(x) \min(\mu_{i1}^A, \mu_{i2}^A, \dots, \mu_{im}^A) \mid i=1,2,\dots,n \} \quad (11) \\ \mu^B(y) &= \max_p \{ \mu_i^B(y) \min(\mu_{i1}^A, \mu_{i2}^A, \dots, \mu_{im}^A) \mid i=1,2,\dots,n \} \end{aligned}$$


디퍼지화를 위한 기법으로서, 출력 귀속도함수에 대한 무게중심법(Center of centroid of mass)을 사용하였다.

$$x = \frac{\int x \mu^B(x) dx}{\int \mu^B(x) dx} \quad (12)$$

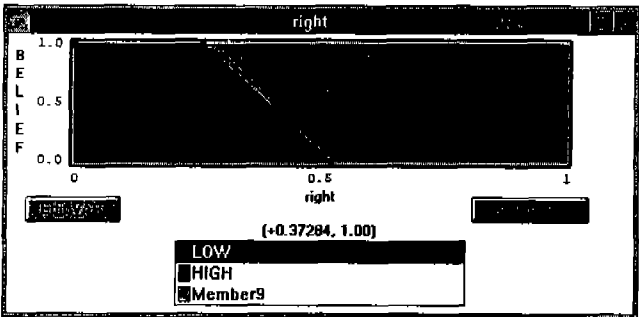
필터는 정보의 프로세서이다. 정보는 보통 2개의 정보원으로 부터 얻어지며, 숫자적 데이터를 제공하는 센서와, 정보에 대한 전문지식에 대해 언어표현을 이용하는 전문가이다. 기존의 필터는 주로 숫자적 데이터만을 처리할 수 있었으나, 본 논문에선 여러가지 경험법칙과 전문지식을 지식기반으로 이용한 적응퍼지필터를 이용하였다. 여기서 적응적이란 용어는 가정과 결과의 형식을 갖는 규칙들로 이루어진 추론기관에 적응적 해석을 포함하고 있다는 의



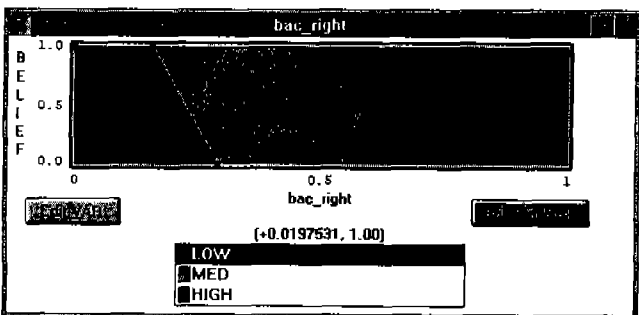
(a)



(b)

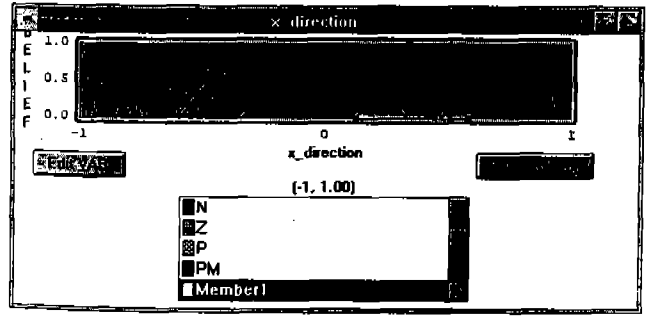


(c)

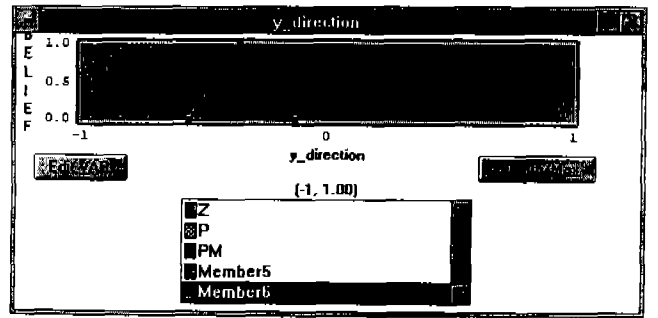


(d)

그림 4. 입력퍼지변수 및 귀속도함수  
 (a) 전향 (b) 전우향 (c) 우향 (d) 후우향  
 Fig. 4 Input Fuzzy Variables & Its membership functions  
 (a) forward (b) for-right (c) right (d) back-right



(a)



(b)

그림 5. 출력변수 및 귀속도함수 (a) x방향 (b) y방향  
 Fig. 5. Output Fuzzy Variables & its membership functions  
 (a) x-direction (b) y-direction

미이다.

퍼지필터와 맷퍼의 전체적 시스템은 그림 3에 표현하였다. 입력변수로서 분류기인 MLP의 출력을 이용하며, 조이스틱을 8개의 방향으로 구분하여, 그 방향들을 변수로 선정하였다(그림 4). 출력변수로서 2차원 카테시안좌표로 X방향 및 Y방향의 단위벡터의 컴포넌트를 지정하였다(그림 5). 사용된 귀속도함수는 각 변수의 성질에 따라 3~7개로 지정하였고, 그림 4, 5에 나타내었다.

기본적 규칙기반으로서

1. 신경망의 출력중 가장 큰 출력이 매우 크고, 두번째 큰 출력과의 차이가 크면 신뢰성이 있다.
2. 신경망의 출력중 가장 큰 출력이 중간값을 갖을 때 두번째 큰 출력과의 차이가 크면 신뢰성이 있다.
3. 전우향명령과 후우향명령은 상관관계가 크며, 두 명령이 다 클 때는 우향명령만이 확실한 것으로 정한다.
4. 전우향명령이나 후우향명령의 크기가 중간값을 갖고, 우향명령과 크기가 유사하면, 두 명령사이의 중간값에 해당하는 방향으로 매핑한다.




그림 6. 최대적추론방식의 그래픽표현  
 Fig. 6. Graphic Representation of Max Product Inference Method

Rule3	0%	31	E	W:100%	L:0	H:1
Rule5	0%	31	E	W:100%	L:0	H:1
Rule6	0%	25	E	W:100%	L:0	H:1
Rule7	0%	23	E	W:100%	L:0	H:1
Rule8	100%	22	E	W:100%	L:0	H:1
Rule2	0%	16	E	W:100%	L:0	H:1
Rule4	0%	13	E	W:100%	L:0	H:1
Rule1	0%	10	E	W:100%	L:0	H:1
Rule12	0%	8	E	W:80%	L:0	H:1
Rule11	0%	4	E	W:70%	L:0	H:1
Rule25	0%	4	E	W:100%	L:0	H:0.5031
Rule16	0%	3	E	W:100%	L:0	H:0.631407
Rule19	0%	2	E	W:100%	L:0	H:1
Rule14	0%	2	E	W:100%	L:0	H:0.677740
Rule27	0%	2	E	W:100%	L:0	H:0.921714
Rule28	0%	2	E	W:100%	L:0	H:1
Rule33	0%	2	E	W:100%	L:0	H:1
Rule22	0%	1	E	W:100%	L:0	H:1

그림 8. 효과가 큰 순으로 배열한 규칙기반  
 Fig. 8. Effectiveness of Rule Representation with Decreasing Order

하였고 그림 6에 그래픽표현을 나타내었다. 디퍼지화과정으로서, 일종의 무게중심법인 센트로이드방식을 사용하였다. 각 변수들과 출력퍼지변수와의 관계인 제어표면(Control Surface)을 그림 7에 3차원적으로 표현하였으며, 효과가 큰 규칙순으로 배열하여 처리속도를 높였다(그림 8).

순차적 샘플에 의한 다단 결정법을 사용할 경우, 확장되는 퍼지규칙기반의 기본규칙은 다음과 같다.

1. 현재의 결정이 과거의 결정과 같으면, 현재 결정의 신뢰도는 증가하며, 출력변수는 지도된 표준방향을 선택하는 경향이 커진다.
2. 현재의 결정이 과거의 결정과 다르면, 적용된 규칙을 만족하는 정도가 큰 결정을 선택한다. 또한 과거의 결정에 많이 참조할수록 과거결정에 대한 가중치는 증가한다.

### 시험 및 결과

#### 1. 신호의 취득 및 특징점 추출

##### A. 신호의 취득

제안한 시스템의 타당성검증을 위해, 모사장애자가 2차원 평면인 조이스틱평면을 조종공간으로 하여 운전을 행하고, 운전을 행하는 팔로부터 근전도신호를 획득하여 시뮬레이션(simulation)을 행하였다. 시험시스템의 구성은 그림 11과 같이 구성하였다. 실험대상자는 실제의 팔장애자대신에, 팔의 불필요한 운동을 못하게 고안된 절단모사기(amputation simulator)를 사용한 정상인(simulated amputee)을 선택하여 실험하였다. 증폭기는 Nihon Kohden사의 생체증폭기인 AB-621G를 사용하였으며, 시간상수는 피부와 전극사이에 움직임으로 유기되는 포텐셜 및 극포





그림 7. 2개 입력퍼지변수와 출력변수사이의 제어표면  
 Fig. 7. Control Surface Between 2 Input Variables & Output Variable

지식기반에 사용된 규칙은 모두 30개이다. 추론 규칙은 최대적추론방식(Max-Product Inference Method)을 사용

텐셀등이 원인인 저주파잡음제거 등을 고려하여, 0.01초로 하였고, 감도는 0.2mV/Dev를 사용하여 A/D변환기의 입력범위를 충분히 사용할 수 있게 하였다. 실제로 EMG신호의 유효성분을 가진 주파수영역은 참조하는 근육에 따라 다르다<sup>2)</sup>. 획득하는 정보의 한 프레임길이는 80ms이고, 샘플링주파수는 10 khz로 하였다.

전극은 일회용 전극을 사용하였으며, 어깨의 삼각근의 중심부와 끝부분에 각기 2개씩의 전극(쌍극법)을, 어깨뼈 부분에 집지전극을 부착하여, 시험하였다. 전극 부착위치로서 어깨의 삼각근영역을 선택한 것은, 2차원 조이스틱을 조정하는 동안 가장 근육활동이 활발한 부분을 찾는 과정에서 선정하였다. 삼각근영역에서의 전극의 위치의 최적 선정은 매우 까다로운 문제로서, 일반적으로 실험에 의해 결정되며<sup>25-26)</sup>, 잡음을 최소화하도록 선정되었다. 모사장애자가 조이스틱을 움직이기 시작하면, 그것을 동기신호로 EMG신호의 획득이 시작되며, 240ms 동안 지속되고, 그 신호를 저장한다. 조이스틱의 운동은 2차원 평면을 45°각도로 나누어, 그림 12와 같이 8가지 운동형태로 구성되며, 각각의 운동에 대해 10회의 반복실험을 하였으며, 매회마다 획득된 데이터를 CRT화면에 파형 및 매핑된 특징벡터를 그래픽으로 표시하여, 잡음이나 아티팩트가 심하게 섞여 있는 정도와 특징벡터의 군집성을 판단하여, 그 신호의 저장여부를 결정한다. 매회의 실험에서 각각의 운동마다 3개 프레임의 데이터가 획득되어, 10회 전부를 성공적으로 마치면, 30세트(sets)씩의 특징벡터군이 획득된다. 그 중 10세트의 특징벡터군을 설계샘플로 취해, MLP의 훈련을 위한 입력값으로 사용하였다.

근전도신호의 특징으로서 절대적분치 (IAV), 영교차수 (Zero Crossing Number)를 선정하였다. 선정된 설계샘플의 분포는 다음 그림 9, 10과 같다.

2. 분류기학습 및 파라미터 선정

MLP모델의 구조는 입력층, 은닉층, 출력층의 3개층을 사용하였다. 입력층은 근육의 두 위치로부터 취득되는 각각의 절대적분치와 영교차수를 입력으로 사용하여 4개로 정의하였고, 출력층은 조이스틱의 이동방향의 종류로서 8개로 정의하였다. 은닉층은 12개의 노드(node)로 정의하였다. 은닉층의 노드수를 10개 미만으로 잡을 경우는 인식이 현저히 저하되었다. MLP모델의 학습시 학습문턱치(learning threshold)는 0.2, 역전달학습율(Back propagation learning rate)는 0.9, 역전달스무딩펙터는 0.6으로 선정하였고 모든 클래스에 대해 학습이 완료되었다.

또한 학습알고리즘의 단점으로서, 회로망이 조기포화




그림 9. 설계샘플의 절대적분치의 채널별 분포  
Fig. 9. The Distribution of IAV of Design Samples in Two Channels




그림 10. 설계샘플의 영교차수의 채널별 분포  
Fig. 10. The Distribution of Zero Crossing Numbers in Two Channels

(premature)상태에 빠져, 훈련량이 증가하는데, 이는 훈련 상태를 중간에 확인하여, 역전달학습율과 역전달스무딩펙터(smoothing factor)를 변화시켜, 빠져 나올 수 있었다.

학습이 완료된 MLP 모델을 사용하여, 설계샘플, 시험샘플(validation sample), 혼합샘플에 대해 시뮬레이션을 행한 다음, 그 출력을 화일로 만들고, 평가를 행해 평가화일을 만든다. 설계된 분류기의 성능을 평가하는 데 있어, 최소오분류확률추정(lower bound error estimate)에는 재치환법(resubstitution method)을 사용하였으며, 최대오분류확률추정(upper bound error estimate)에는 LOOM(leaving one out method)을 사용하였다<sup>22, 28)</sup>. 설계샘플로서 사용한 영교차수 및 평균절대적분치는 그림 9와 그림 10에 표시하였는데, 몇 개의 클래스는 클래스간 분리가 매우 낮았다. 설계샘플과 시험샘플을 혼합한 혼합샘플에 대해, MLP모델 및 MLP와 퍼지필터를 결합한 모델을 이용해, 단계별 결정을 한 결과는 그림 13에 표시하였다. MLP모




그림 11. 시험시스템 구성도  
Fig. 11. Test System Configuration




그림 12. 조이스틱 좌표계의 클래스 설정  
Fig. 12. Class Definition in the Joystick Coordinate

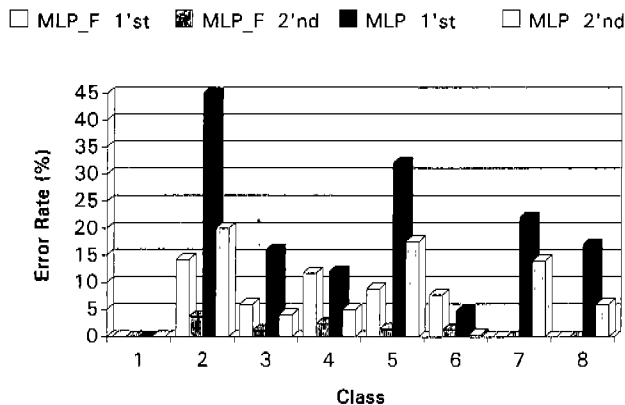


그림 13. 혼합샘플에 대한 MLP 및 MLP/퍼지필터의 단계별 오분류률 비교  
Fig. 13. Comparison of Error Rate between MLP & MLP/Fuzzy Filter Model for Mixed Samples

표 1. MLP모델과 MLP와 퍼지필터결합형의 오차크기누적치비교

Table 1. Comparison of Accumulation of Error Magnitude between MLP and MLP/Fuzzy model

구분	모델	MLP 모델	MLP/Fuzzy Filer 합성모델	크리오차감소율 (%)
단위벡터 오차의 누적치	Class 1	0	0	0
	Class 2	7.76	3.56	54.1
	Class 3	1.52	1.52	0
	Class 4	4.64	3.45	25.6
	Class 5	4.28	2.71	36.7
	Class 6	1.52	0.80	47.4
	Class 7	0	0	0
	Class 8	4.14	0	100
Total		23.86	12.04	49.5

표 2. 각모델의 단계별 오분류확률 추정결과

Table 2. Error Probability Estimate of Each model (단위:%)


단계	모델 오분류 추정방식	MLP 모델	확률모델	합성모델 (MLP/확률모델)	합성모델 (MLP/FUZZY FILTER)
1	최소추정	5.00	2.50	1.25	0.85
	최대추정	32.04	29.76	25.72	12.04
	대표추정	18.08	20.38	18.06	6.05
2	최소추정	3.33	0.00	0.00	0.00
	최대추정	18.76	14.09	14.29	6.28
	대표추정	8.88	7.11	6.33	1.25
3	최소추정	1.25	0.00	0.00	0.00
	최대추정	15.25	8.30	8.57	1.82
	대표추정	5.58	3.43	2.02	0.03

델 및 MLP와 퍼지필터 결합형에 대하여 각각 결정된 단위방향벡터들과 원하는 방향과의 오차벡터를 구하여, 그 절대값을 누적시켰고, 그 누적치를 표 1에 표시하였다. 표 2에는 각 모델의 단계별 오분류확률추정결과를 표시하였다.


### 3. 퍼지필터 및 매퍼의 튜닝

퍼지필터 및 매퍼의 설계에 있어, 튜닝대상은 귀속도함





(a)



(b)

그림 14. 퍼지필터 및 매퍼와 Crisp매퍼의 성능비교  
 (a) Crisp 매퍼 출력차트 (b) 퍼지필터 및 매퍼의 출력차트  
**Fig. 14.** Performance Comparison between Crisp Mapper & Fuzzy filter and Mapper  
 (a) Crisp Mapper Output Chart (b) Fuzzy Filter & Mapper Output Chart

수와 규칙기반의 2가지 대상이 있다. 귀속도함수의 튜닝은 통계적 기법에 근거하며, 신경회로망출력들을 각 입력퍼지변수로 보고, 빈도함수화하였다. 빈도함수는 전체입력공간을 0.1단위로 균등하게 분배하여 처리하였고, 모든 신경회로망의 출력의 분포를 대상으로 하였다. 귀속도함수의 선정은 원칙적으로 Dempster-Shafer Theory에 근거하여 신뢰구간(Belief interval), 비신뢰구간(Disbelief Interval)과 불확실구간(Uncertainty Interval)으로 구분하였으며, 변수간에 상관관계가 큰 클래스에 대해선 특성구분을 할 수 있는 좀 더 세분화된 귀속도함수의 분할이 필요하였다. 빈도함수는 정분류(Correct Classification)의 경우와 오분류(Misclassification)의 경우를 별도로 구분하였으며, 입력공간에서 정분류빈도와 오분류빈도가 유사한 구간을 불확실구간으로 선정하였다.

규칙의 튜닝은 기본적 성질에 근거한 규칙들을 근간으로 제어표면(Control Surface)을 만들고, 제어표면상에 입

력값들을 대입해가는 모의실험을 통해 얻은 통찰력에 근거해, 세부적 규칙들과 가정부위의 귀속도함수를 튜닝해가는 방식을 취하였다. 만들어진 규칙기반의 유용성, 규칙의 가중치, 귀속도함수의  $\alpha$  cut값의 튜닝은 입력데이터기반을 구성된 퍼지필터에 입력시켜, 시뮬레이션을 행하면서, 효과가 큰 규칙순으로 규칙들을 재배열하면서 수행하였다. 시뮬레이션결과는 신경회로망의 최대출력을 뚜렷하게 맵핑한 경우를 그림 14의 (a)에 표시하였고 퍼지필터를 사용해 맵핑한 결과를 그림 (b)에 표시하였다. 결과에서 나타나듯이 오분류빈도가 작은 클래스에선 대부분 오분류된 경우가 정정되었으며, 그 오차벡터의 크기가 현저히 작아졌음을 알 수 있다.

## 결 론

지속적 학습능력을 갖는 MLP와, 인간의 경험 및 지식을 반영하기가 쉬운, 퍼지추론을 이용한 퍼지필터를 단계적으로 결합시킨 변별기는, MLP만의 경우에 비해 변별능력이 크게 향상되었으며, 결정벡터의 오차의 크기도 크게 감소됨을 확인할 수 있었다. 또한 자동적 학습방식과 인간의 통찰력을 결합하므로써, 환경변화에 대한 적응속도가 증가하며, 변별기능에 대한 튜닝이 쉬운 장점이 있다. 모의시험결과, 일단결정시 방향기준명령에 해당되는 제어공간에서 오차의 크기가 MLP에 의한 것에 비해 49.5%정도 감소하였으며, 이단결정시 99%정도의 정분류율을 갖는 효과를 나타내었다. 이는 90%정도의 MLP모델, 93%정도의 확률모델, 94%정도의 확률모델과 MLP모델의 합성모델의 정분류율결과에 비해, 매우 신뢰성이 향상되었다.

## 참 고 문 헌

1. 장영진, 권장우, 홍승홍, "신경회로망과 확률모델을 이용한 근전도신호의 패턴분류에 관한 논문", 전자공학회지, 91-28B-10-10, pp 85-95, 1991. 10
2. 권장우, 장영진, 홍승홍, "근전도의 패턴분류와 근력 추정에 관한 연구", 의공학회지, 제13권 1호, pp 1-8, 1992. 3
3. Younggun Jang & Seunghong Hong et al, "The Muscle Force Estimation and the Hybrid Pattern Classifier considering Signal Dynamics", Proceedings JTC-CSCC '93, pp 1045-1050, 1993. 7
4. Young gun Jang & Seunghong Hong et al, "Probabilistic Neural Pattern Classifier and Muscle Force Estimation", Proceedings of the 15th Annual International Conference of the IEEE EMBS, pp 1045-1046, 1993. 10
5. Younggun Jang & Seunghong Hong et al, "EMG Pattern Analysis for Prosthesis Arm Control", RESNA '94 Conference, Neshville, Tennessee, 1994. 6

6. Young gun Jang & Seunghong Hong, "A Study on the Fuzzy Controller for Prosthesis Arm Control using EMG Signals", Proceedings JTC-CSCC '94, pp 260-263, 1994. 7
7. Jangwoo Kwon, Younggun Jang & Seunghong Hong, "The Application of Counterpropagation Neural Networks for EMG pattern Classification", World Congress on Medical Physics & Biomedical Engineering, pp 919, Aug 1994, Rio de Janeiro Brazil
8. F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain" Psychological Review, Vol 65, pp 386-408, 1958
9. Daniel Graupe et al, "Functional Separation of EMG signals via ARMA identification methods for prosthesis control purposes", IEEE Trans on SMC, vol 5, No 2, pp 252-pp259, March 1975
10. George N. Saridis et al, "EMG pattern analysis and classification for a prosthetic arm", IEEE Trans on BME, Vol 29, No 6, pp403-412, June 1982
11. Tony Khoshaba, Kambiz Badie et al, "EMG pattern classification based on Back propagation neural network for prosthesis control", Annual International Conference of the IEEE Engineering in MBS. Vol 12, No 3, 1990
12. D. W. Ruck, S. K. Rogers et al "The Multilayer Perceptron as an Approximation to a Bayes Optimal Discriminant Function" IEEE Trans on Neural Networks Vol 1 No 4 pp 296-pp297 Dec. 1990
13. Gisela Hefftner, Walter Zucchini, George G. Jaros "The Electromyogram (EMG) as a control signal for Functional Neuromuscular Stimulation-Part I: Autoregressive Modelling as a Means of EMG Signature Discrimination" IEEE Trans on BME, Vol. 35, No. 4, April 1988
14. Ronald J. Triolo, Gordon D. Moskowicz, "The Development of a Multichannel Time Series Myoprocessor for Simultaneous Limb Function Detection and Muscle Force Estimation", IEEE Trans on BME Vol. 36, No. 10, pp 1004-1017, Oct 1989
15. Fukunaga K. S., Sequential Methods in Pattern Recognition and Machine Learning, Academic Press, New York, 1968
16. Bharathi B. Devi et al, "A Fuzzy Approximation Scheme for Sequential Learning in Pattern Recognition", IEEE Trans on SMC, Vol. 16, No. 5, pp 668-679, Sep 1986
17. L. A. Zadeh, "Fuzzy Sets", Inform. Control, Vol. 8, pp. 338-353, 1965
18. Abraham Kandel et al, "Fuzzy Control Systems", CRC Press, 1994
19. Edward A. Clancy and Neville Hogan, "Single Site Electromyograph Amplitude Estimation", IEEE Trans on BME, Vol 41, No 2, pp 168-180, Feb. 1994
20. Neville Hogan, "Mechanical Impedance Control in Assistive Devices and Manipulators", Preceedings of the 1980 Joint Automatic Control Conference, San Francisco, pp. TA10-B