

의수 제어를 위한 HMM-MLP 근전도 신호 인식 기법

권 장 우·홍 승 홍

=Abstract=

An EMG Signals Discrimination Using Hybrid HMM and MLP Classifier for Prosthetic Arm Control Purpose

Jangwoo Kwon, Seunghong Hong

This paper describes an approach for classifying myoelectric patterns using a multilayer perceptrons (MLP's) and hidden Markov models (HMM's) hybrid classifier.

The dynamic aspects of EMG are important for tasks such as continuous prosthetic control or various time length EMG signal recognition, which have not been successfully mastered by the most neural approaches.

It is known that the hidden Markov model (HMM) is suitable for modeling temporal patterns. In contrast, the multilayer feedforward networks are suitable for static patterns. And, a lot of investigators have shown that the HMM's to be an excellent tool for handling the dynamical problems.

Considering these facts, we suggest the combination of MLP and HMM algorithms that might lead to further improved EMG recognition systems.

Key words : EMG, Recognition, HMM-MLP Classifier

서 론

근전도 신호의 인식과 패턴 인식에 사용되는 일반적인 신경회로망은 영상 인식이나 문자 인식 등의 정적인 신호의 인식에는 뛰어나지만 근전 신호나 음성 신호처럼 시간적으로 변하는 동적인 신호의 처리에는 적합하지 못하다는 단점을 가지고 있다[1].

근전도 신호들은 시변성이 강한 일종의 불규칙 신호라 볼 수 있으므로 확률 모델의 적용이 가능하다. 확률 모델(stochastic model)은 시변적 신호의 패턴 인식에 있어 효율적이며, 이러한 확률 모델들 중 대표적인 예는 마르코브 상태 천이 함수에 그 수학적 기초를 두고 있는 마르코브 모델(Markov model)과 히든 마르코브 모델(hidden Markov model, HMM)이다.

일반적으로 HMM은 음성 연구 분야에서 활발한 연구

가 진행되어오고 있으며[1] 신경회로망과의 결합을 통하여 상호간의 장점을 증대시키기 위한 시도가 이루어져 오고 있다[2]. 그러나 생체 신호가 가지고 있는 특성이 다른 분야에서 제안하고 있는 합성 인식기에 적합하지 못하므로, 생체 신호의 특성을 잘 반영하는 인식기의 구성이 필요하다.

본 논문에서는 이러한 단점을 해결하기 위하여 2개의 채널에서 얻어지는 근전신호의 시간적 영역의 특징 벡터들인 영교차수과 절대적분치들로 연속 운동신호에서 기본 운동의 구간을 구분하고, 구분된 기본 운동들에서 얻어진 특징 벡터들을 HMM에 적용하여 일차적 인식을 행한다. HMM의 출력치인 확률적 누계치를 정규화한 값과 절대적분치와 영교차수을 특징 벡터로 하여 다층 퍼셉트론(multilayer perceptron, MLP)에서 이차 분류를 행하여 기능 인식의 신뢰도 향상을 얻었다.

〈속보논문〉
인하대학교 전자공학과

Dept. of Electronic Eng. Inha Univ.

통신저자 : 권장우, (402-751) 인천시 남구 용현동 인하대학교 전자공학과 생체정보공학연구실, Tel.(032)868-4691,
Fax.(032)868-3654

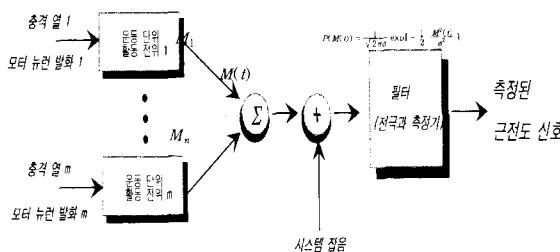


그림 1. 근전도 신호 발생의 모델

Fig. 1. Mechanism of the EMG Signal Formation

근전도 신호의 수학적 모델링

근전도 신호 발생의 정확한 수학적 모델과 구조는 근육의 수축시 발생하는 복잡성 때문에 구하기가 용이하지 않다[3]

근전도를 영평균 가우시안 분포인 랜덤 프로세스(random process)라고 하면 근전도의 발생될 확률은 식 (1)과 같이 나타낼 수 있다[4].

$$P(M(t)) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{1}{2} \frac{M^2(t)}{\sigma^2}\right] \quad (1)$$

$$E[M(t)] = 0$$

여기서 $M(t)$: 근전도, $E[M(t)]$ 는 근전도의 평균 근전도의 발생 모델이 그림 1에 나타나 있다[4].

특징 추출 및 선택

신호로부터 어떤 특징 벡터를 추출하고 선택하느냐에 따라 패턴 인식의 성공 여부가 달려 있다. 패턴 인식에서, 특징 벡터 추출 및 선택의 목표는 패턴 표현의 차원(dimensionality)을 줄이고 그 신호들의 분류도를 향상시킴에 있는데, 인식기의 성능적 관점에서 보면, 차원의 축소는 오인식율을 줄이는 데도 기여할 수 있다. 즉 불필요한 특징의 추가는 인식의 효율을 저하시키며, 인식율을 저하시키는 데도 기여하기 때문이다. 본 논문에서 추출한 특징 벡터는 영교차수와 절대적분·평균치 그리고 LPC 계수이다[5-6].

근전도 신호 인식을 위한 합성 인식기

HMM을 구성하는 요소는 N개의 상태와 시간에 따른 상태의 변화를 결정하는 상태 천이 확률 분포, 각 상태에서의 관측치의 분포를 결정하는 관측 확률 분포이다. 이

상의 세가지 요소에 의하여 구성되는 HMM의 설명에 필요한 기호를 다음과 같이 정의한다.

$$O = O_1, O_2, O_3, \dots, O_T \text{ 관측열}$$

$$T = \text{관측열의 지속 시간}$$

$$N = \text{상태의 수}$$

$$L = \text{관측 심볼의 수}$$

$$Q = \{q_1, q_2, \dots, q_N\}, \text{ 상태의 집합}$$

$$V = \{v_1, v_2, v_3, \dots, v_L\}, \text{ 관측 심볼의 집합}$$

$$A = \{a_{ij} | a_{ij} = P(q_{t+1} = j | q_t = i)\}, \text{ 상태 천이 확률 행렬}$$

여기서 a_{ij} 는 상태 i 에서 j 로의 천이 확률을 나타냄

$$B = \{b(O_i) | b(O_i) = P(O_i | q_i = j)\}, \text{ 관측 심볼 확률 분포}$$

$$\pi = \{\pi_i | \pi_i = P(q_i = i)\}, \text{ 초기 상태 확률 분포}$$

HMM λ 는 $\lambda = (A, B, \pi)$ 로 표시되며, 관측열은 $O = O_1, O_2, O_3, \dots, O_T$ 로 표시된다. HMM에 대한 상세한 설명은 본연구의 범위를 벗어나므로 자세한 내용은 참고문헌을 참고하기 바란다[5].

다층퍼셉트론(MLP)은 가중화된 연결을 사용하여 상호 반응하는 신경들의 층으로 이루어 졌으며, 입력층, 은닉층 및 출력층으로 구성되며, 은닉층은 다층으로 구성될 수 있다. 외부 입력벡터는 입력층에 있는 노드에 연결되어 회로망에 공급되며, 회로망을 지도학습(supervised learning)방식에 의해 훈련되는 분류기로 사용할 때, 해당 출력을 1 상태로, 나머지는 0 상태로 고정하여, 연결가중치를 훈련시킨다. 신경은 활성함수로서 작용하며, 임의의 시간 t 에 비제한적 활성입력 $o_j^h(t)$ 를 제한된 출력신호 $p_j^h(o(t))$ 로 변환시킨다. 보통 변환은 시그모이드 함수를 사용하며, 제한된 단조증가함수의 형태를 갖는다.

잘 훈련된 MLP의 출력이 특징베타의 확률이 크다면, 베이즈 최적 변별기능을 극사적으로 모사한다는 것과 후 확률의 추정이라는 것은 이전의 연구에서 증명되었다[9].

모델 파라미터 λ 가 주어졌을 때 관측 심볼열 O 에 대한 확률, $P(O | \lambda)$ 는 전향 알고리즘을 이용하면 식 (2)처럼 주어진다.

$$P(O | \lambda) = \sum_{i=1}^N \alpha_i(i) \quad (2)$$

여기서

$$\alpha_i(t) = \pi_i b(o_i) 1 \leq i \leq N$$

$$\alpha_i(i) = P(o_1, o_2, \dots, o_t ; i_t = q_i | \lambda)$$

$$\alpha_{i+1}(j) = [\sum_{i=1}^N \alpha_i(i) a_{ij}] b(o_{t+1})$$

$$t=1, 2, \dots, T-1, 1 \leq j \leq N$$

N개의 모델 각각에 대한 $P(O | \lambda_i)$ 는 다음과 같이 나타낼 수 있다.

$$B = [P(O | \lambda_1), P(O | \lambda_2), \dots, P(O | \lambda_N)] \quad (3)$$

$$a = \frac{\sum_{i=1}^N P(O | \lambda_i)}{N} \quad (4)$$

$$C = a/B = [a/P(O | \lambda_1), a/P(O | \lambda_2), \dots, a/P(O | \lambda_N)] \quad (5)$$

여기서 $C = c_1, c_2, \dots, c_N$

식(5)로 HMM의 출력치는 주어지고 C 를 입력으로 하는 MLP의 은닉층의 출력 값은 식(6)처럼 주어지며

$$y_j = f(v_j^T c), \text{ for } j=1, 2, \dots, J \quad (6)$$

여기서 v_j 는 V 의 j 번째 행에 해당하는 열벡터이다. 출력층의 출력은 식(7)처럼 주어진다.

$$o_k = f(w_k^T y), \text{ for } k=1, 2, \dots, K \quad (7)$$

여기서 w_k 는 W 의 k 번째 행에 해당하는 열벡터이다. 따라서 정수형 연속 함수인 경우 출력층에서의 오차 신호 항은 식(8)과 은닉층에서의 오차 신호 항은 식(9)로 주어진다.

$$\delta_o = \frac{\partial}{\partial o} (d_o - o_k)(1 - o_k^2), \text{ for } k=1, 2, \dots, K \quad (8)$$

$$\delta_w = \frac{1}{2}(1 - o_k^2) \cdot \sum_{k=1}^K \delta_o w_{kj}, \text{ for } k=1, 2, \dots, L \quad (8)$$

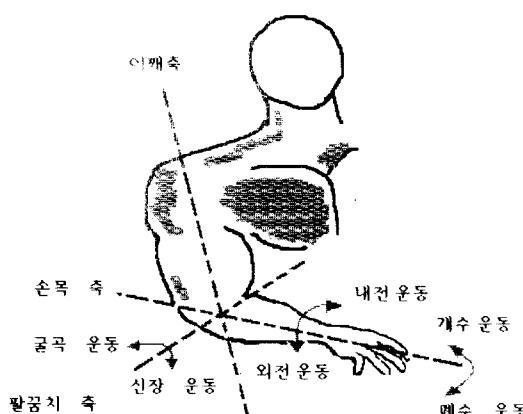


그림 2. 기본 동작의 구성.

Fig. 2. The Primitive Motions

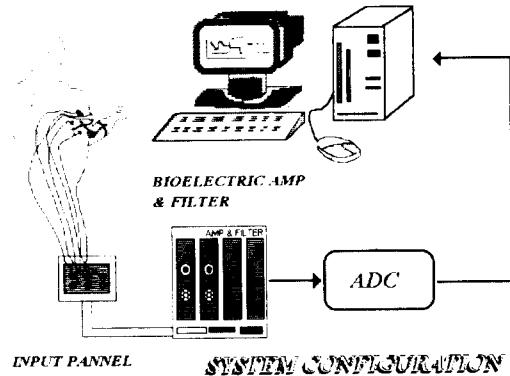


그림 3. 시험시스템 구성도

Fig. 3. Test system configuration

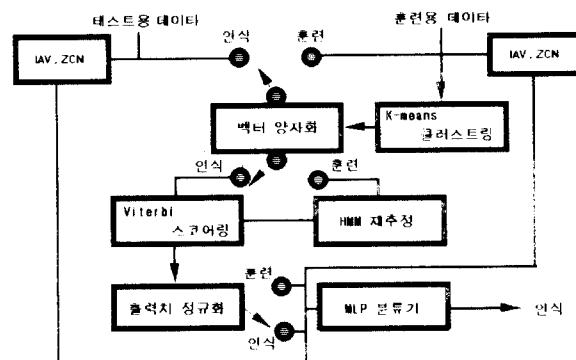


그림 4. HMM-MLP 합성 인식기의 학습 및 인식 시스템

Fig. 4. Learning and recognition procedure in HMM-MLP hybrid classifier

실험 및 검토

1. 신호의 획득

실험은 우선 의수 제어를 위한 기본 기능을 6가지의 기본 운동으로 제한한다. 그림 2에 설정한 팔의 기본 기능이 나타나 있다. 그림처럼 6가지 기본 운동에 대한 신호를 장기간에 걸쳐 개별적으로 수집하였다. 시험 시스템의 구성은 그림 3과 같이 구성하였으며, 20대 후반의 정상인(simulated amputee)을 실험 대상으로 선택하였다.

증폭기는 Nihon Kohden사의 생체 증폭기인 AB-621G를 사용하였으며, 시간 상수는 피부와 전극사이에 움직임으로 유기되는 포텐셜 및 극포텐셜등이 원인인 저주파 잡음 제거등을 고려하여 0.01초로 하였고, 감도는 0.2mV/div를 사용하여 A/D변환기의 입력 범위를 충분히 사용할 수 있게 하였다. 실제로 EMG 신호의 유효 성분을 가진 주파수 영역은 참조하는 근육에 따라 다르다[7]. 전극은 Ag-Cl 일회용 전극을 사용하였으며, 이두박근과 삼두

표 1. 기본 운동과 심볼표

Table 1. Primitive Motion and Symbol Table

번호	심볼	기본 운동
1	IN	굴곡(屈曲) 운동
2	OUT	신장(伸張) 운동
3	WI	내전(內轉) 운동
4	WO	외전(外轉) 운동
5	G	폐수(閉手) 운동
6	S	개수(開手) 운동

박근의 중심부와 끝부분에 각기 2개씩의 전곡(쌍곡법)을, 그 중앙에 접지전곡을 부착하여 시험하였다. 이중 이 두박근을 채널 1로 삼두박근을 채널 2로 정하였다. 전곡의 최적위치의 설정은 매우 까다로운 문제로서 일반적으로 실험에 의해 결정되며[8] 잡음을 최소화하도록 설정하였다. 그림 2와 같이 6가지 방향에 따라 운동을 행하였고, 각각의 운동에 대해 30회의 반복 실험을 하였다. 30회의 반복 실험한 데이터 중 10세트의 특징 벡터군을 설계 샘플로 취해 제안한 HMM-MLP 합성 모델의 훈련을 위한 입력값으로 사용하였다. 그림 4에는 제안한 HMM-MLP 합성 인식기의 학습 및 훈련과정이 나타나 있다. 학습과정에서는 우선 모든 실험 데이터에 대하여 벡터 양자화를 행하여 코드북을 만든다. 구성된 코드북을 사용하여 훈련용 데이터에 대하여 벡터 양자화를 적용한 후, 그 결과로 얻어지는 관측 심볼열(observation symbol sequence)을 이용하여 각 기본 운동에 대한 개별적인 HMM을 만들게 된다. HMM의 훈련이 끝나면 훈련용 데이터에 대한 HMM의 출력치 즉, $P(O|\lambda)$ 을 정규화한 값과 검출된 기본 운동 구간의 영교차수와 절대적분치를 MLP의 훈련에 사용되게 된다. 본 연구에서는 이산형 HMM을 사용하였다. 기능 분류는 기본 운동 구간 검출을 거친 데이터가 입력되면 훈련 과정중에 학습된 코드북을 가지고 벡터 양자화를 행하고 Viterbi 탐색 알고리즘을 사용하여 인식 결과를 1차적으로 출력하면 각 HMM 모델에 대한 확률치를 계산하고 이를 출력치를 정규화 시켜 절대적분치, 영교차수와 함께 MLP의 입력값으로 사용된다.

별도의 언급이 없는한 그림 2에 나타난 기본운동은 표 1의 심볼로써 나타낸다.

표 2. 실험 1의 인식 결과표

Table 2. Recognition Rates of Experiment 1 System

모션	IN	OUT	WI	WO	G	S	전체인식율(%)
데이터수	30	30	30	30	30	30	총데이터 : 180
오인식수	7	9	5	8	7	5	총인식 : 139
인식율(%)	76.7	70	83.3	73.3	76.7	83.3	77.3

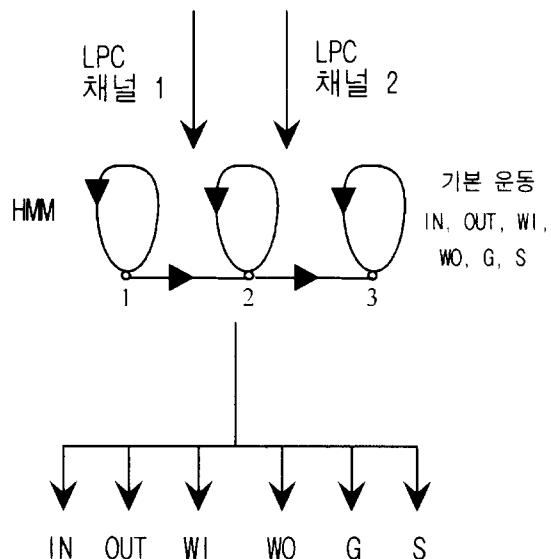


그림 5. 실험 1의 인식 시스템 개략도

Fig. 5. Overall view of experiment 1 recognition system

2. HMM-MLP 합성 인식기의 인식

본 논문에서 제안하는 인식기의 성능을 비교하기 위하여 다음과 같은 3종류의 실험을 행하였다.

실험 1 : HMM 알고리즘만으로 구성된 인식기

실험 2 : HMM-MLP 합성 인식기 (1단의 MLP)

실험 3 : HMM-MLP 합성 인식기 (2단의 MLP)

실험 1의 경우는 HMM 알고리즘만으로 학습 및 가능 인식을 행하였으며, 실험 2의 경우는 HMM-MLP 합성 인식기이지만 1단의 MLP만을 가지는 구조이며, 실험 3의 경우가 본 연구에서 제안하는 구조로 HMM과 직렬 연결된 2단의 MLP를 포함하는 구조이다. HMM의 각 모델은 좌우진행형(left-to right) 모델을 사용하고 근전도 신호에 의한 근육의 수축이 solomonow의 실험 결과를 근거로[7] 발화 상태(firing state)-수축의 과도기 상태(contraction transition state)-수축의 정상 상태(contraction steady state) 유지의 3단계를 갖는다고 가정하고 각 모델에 3개의 상태를 할당하였다.

1) 실험 1

그림 5에 실험 1에 사용한 전체 인식 시스템이 나타나 있다. 각 채널의 추출된 LPC 특징 계수만을 특징 벡터로

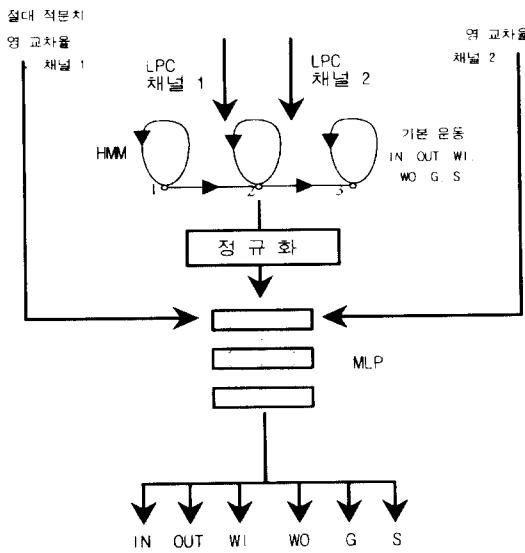


그림 6. 실험 2의 인식 시스템 개략도

Fig. 6. Overall view of experiment 2 recognition system

사용하여 HMM 알고리즘만으로 학습 및 인식을 수행한다. 이 구조의 전체 인식율은 80% 미만으로 저조하다.

2) 실험 2

그림 6에 실험 2에 사용한 전체 인식 시스템이 나타나 있다. 이 구조는 HMM 알고리즘과 1단의 MLP를 직렬 연결한 형태를 갖는다.

인식 과정은 실험 1과 유사하다. 인식율을 실험 1과 비교하면 전체 인식율이 실험 1의 경우에는 77.3%이고 실험 2의 경우에는 88.3 %로 11%가 향상되었는데 이는 LPC 계수만으로 인식이 어려운 경우에도, 각 채널에서 얻은 절대적분치와 영교차수가 각 기본 운동에 대하여 중첩이 심하지 않고 정규화된 HMM 출력 결과가 각 모델에 대하여 특정한 패턴을 갖고 있기 때문이다. 그림 7를 살펴보면 훈련 과정에서는 채널 1과 2를 통해서 입력된 데이터에서 추출한 LPC계수가 벡터 양자화된 후 기본 운동별로 6개의 HMM을 생성한다. 훈련에 사용한 데이터에 대한 6가지 HMM모델의 Viterbi 스코어링을 한 결과치를 정규화하고 추정된 기본 운동 구간에서 계산한 절대적분치와 영교차수와 함께 MLP 훈련을 위한 입력 벡터로 사용한다.

실험 2의 경우 기본 운동 IN과 OUT에서는 오인식은

WI, WO, G, S의 오인식 분포

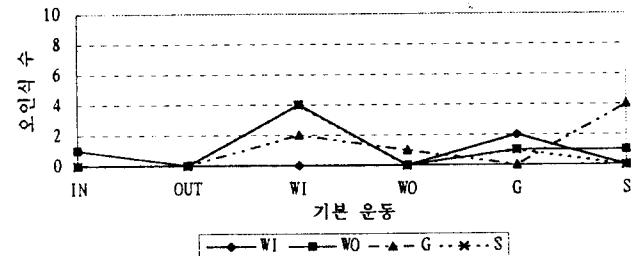


그림 7. 기본 운동 WI, WO, G, S의 오인식 분포

Fig. 7. Error distribution of primitive motion WI, WO, G and S

없으나 WI, WO, G, S에서는 상호간에 오인식이 발생되었으며 오인식 분포 형태를 그림 8에 나 타내었다. 이 그림에서 x축은 각 기본 운동들을 y축은 각 기본 운동에 대한 오인식 데이터 수를 나타낸다. 그림에서 살펴보았듯이 실험 3은 본 논문에서 제안하는 구조, 즉 실험 3의 구조를 발생시킨 정보를 포함하고 있다. WI, WO, G, S의 인식율을 향상시키기 위하여 실험 3에서는 IN과 OUT를 한 그룹으로 WI, WO, G, S를 다른 한 그룹으로 1차 분류하고 상호간의 오인식이 겹쳐있는 WI, WO, G, S의 인식율을 향상시키기 위하여 3개의 MLP를 연결 시키는 구조를 보인다.

3) 실험 3

그림 8에 실험 3에 사용한 전체 인식 시스템이 나타나 있다. 실험 3은 본 연구에서 제안하는 기능 인식 시스템으로 실험 3의 확장된 형태로 HMM의 동적인 신호에 대한 적용 특성과 MLP의 탁월한 분류력을 결합시킨 형태이다. 실험 2의 결과에서 알 수 있듯이 기본 운동 WI, WO, G, S의 중첩이 심하므로 별도의 MLP를 두고 이를 세분하여 훈련시키므로써 오인식율을 줄이려는 의도이다. 이 구조는 1단의 HMM과 2단의 MLP를 직렬 연결한 형태를 갖는다. 인식율이 대체적으로 실험 2의 인식율보다 우수하지만 기본 운동 WO의 경우는 실험 2의 구조에서 와 동일한 인식율을 보임으로서 실험 3의 구조에서도 향상되지 못하였다. 이는 WO의 균전신호가 LPC 특징벡터와 영교차수와 절대적분치의 특징벡터 공간상에서도 다른 기본운동들과 분류되지 못할 만큼 특징벡터 공간 상에서의

표 3. 실험 2의 인식 결과표

Table 3. Recognition Rates of Experiment 2 System

모션	IN	OUT	WI	WO	G	S	전체인식율(%)
데이터수	30	30	30	30	30	30	총데이터 : 180
오인식수	0	0	2	7	7	5	총인식 : 159
인식율(%)	100	100	93.3	76.7	76.7	83.3	88.3

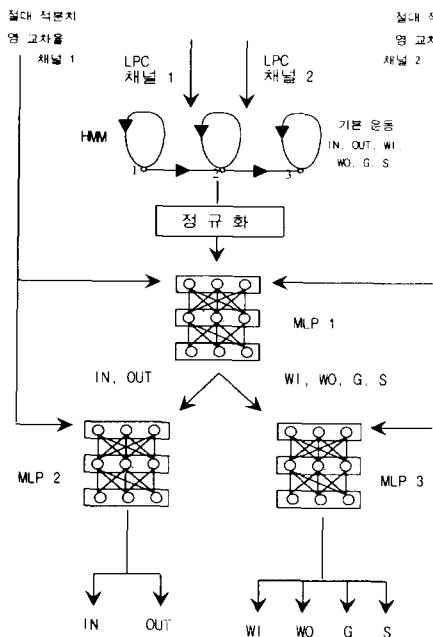


그림 8. 실험 3의 인식시스템개략도

Fig. 8. Overall view of experiment 3 recognition system

군집성이 양호하지 않기 때문이다. 표 4에는 실험 3의 방법을 이용하여 구한 총 인식율이 나타나 있다. 총 분류율은 전체 데이터 개수 180개중 오인식이 일어나지 않은 데이터수 164에 대한 백분율이며 실험 3의 인식 기법을 이용한 전체 인식율은 91.1%이다. 그림 9는 실험 1, 실험 2와 실험 3의 총 인식율을 각 기본운동별로 나타낸 그림이다. x축은 기본 운동을 y축은 인식율을 나타낸다. 그림에 나타나 있듯이 실험 3의 경우에 가장적은 오인식율을 보임을 알 수 있다.

결 론

본 논문에서는 의수의 연속 제어를 위한 기능 인식율을 향상시키기 위하여 정적인 신호의 인식에 탁월한 효과를 보이는 MLP와 신호의 동적 특성을 잘 반영하고 있는 HMM의 합성 모델을 제안하였다. 본 연구에서 제안한 HMM- MLP 합성 인식기는 근전도 신호의 기능 인식율을 향상시켰으며 HMM 특성으로 입력벡터의 크기에 영향을 받지 않는 인식기의 구성을 이룩할 수 있었다. 본

표 4. 실험 3의 인식 결과표

Table 4. Recognition Rates of Experiment 3 System

모션	IN	OUT	WI	WO	G	S	전체인식율(%)
데이터수	30	30	30	30	30	30	총데이터 : 180
오인식수	0	0	1	7	5	3	총인식 : 164
인식율(%)	100	100	96.7	76.7	83.3	90	91.1

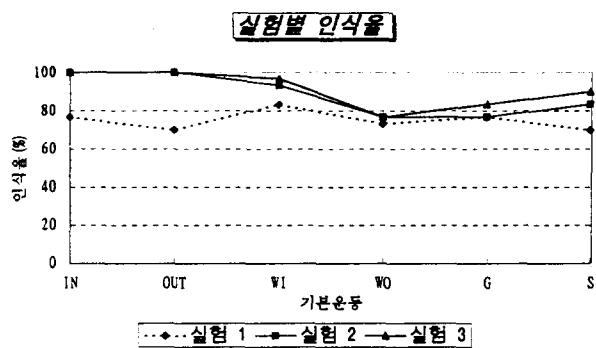


그림 9. 실험별 기본운동의 인식율

Fig. 9. Classification rates in each experiments

연구에서 제안하는 구조, 즉, HMM과 2단의 MLP를 결합한 구조에서는 91.1%의 인식율을 보였으며 이는 동일한 데이터를 가지고 여러 가지 구조의 인식기에 대하여 적용한 결과보다 우수한 것이다. HMM 단일 구조만을 사용하였을 경우 근전도 신호의 동적 특성을 고려하는 형태로 연속 근전도 신호의 인식에 적용 시킬 수는 있었으나 인식율은 전체 데이터에 대하여 77.3%로 저조했다. 이는 생체 신호의 특성이 단일 HMM 알고리즘에 적합하지 않기 때문이다. HMM 알고리즘과 1단의 MLP를 합성한 구조에서는 인식율이 88.3%로 HMM 알고리즘만을 사용한 경우에 비하여 인식율의 향상을 보였는데 이는 HMM의 인식 출력치를 정규화하여 HMM의 오인식 분포 특성을 MLP로 하여금 학습하게하여 2차 인식을 행하였기 때문이다. 제안한 구조의 인식기가 가장 좋은 인식율을 보이는 이유는 HMM과 1단의 MLP를 합성한 구조에서 갖고 있는 오인식 분포 특성을 MLP로 하여금 재학습도록 하였기 때문에 가능하였다. 본 연구에서 제안한 근전도 신호 인식 기법은 음성 신호와 같은 동적 특성이 강한 신호의 처리에 응용될 수 있으며 제안한 처리 기법의 단일 장애인 종속성을 최소화하기 위한 연구가 진행중에 있다.

참 고 문 헌

1. Keh-Yih Su, Chin-Hui Lee, "Speech Recognition Using Weighted HMM and Subspace Projection Approaches", IEEE Trans on Speech and Audio Processing, Vol.2. No.1, part I, January, 1994.

2. Lalit R.Bahl, Peter F.Brown, Peter V. de Souza, and Robert L.Mercer, "Estimating Hidden Markov Model Parameters So As To Maximize Speech Recognition Accuracy", IEEE Trans on Speech and Audio Processing, Vol.1, No.1, January 1993.
3. Willis J. Tonpkins, "Biomedical Digital Signal Processing" Prentice Hall International Editions, 1993.
4. S.K Lee, George N. saridis "Intelligent control of a prosthetic arm by EMG pattern recognition", Robotics and automation LAB., Rensseler Polytechnic Institute, Troy, N.C. 12801.
5. L.R.Rabiner / R.W.Schafer, "Digital Processing of Speech Signals" Prentice-Hall, Inc., 1978.
6. Lawrence Rabiner/Riing-Hwang Juang, "Fundamentals of Speech Recognition", Prentice-Hall International, Inc. 1993.
7. Moshe Solomonow et al, "The EMG-Force Model of Electrically Stimulated Muscle: Dependence on Control Strategy and Predominant Fiber Composition", IEEE Trans on BME, Vol. 34, No. 9, pp692-703, Sep. 1987.
8. Ronald J.Triolo and Gordon D.Moskowitz, "The Theoretical Development of a Multichannel Time-Series Myoeocessor for Simultaneous Limb Function Detection and Muscle Force Estimation", IEEE Trans on Biomedical Engineering, vol.36, No.10, October 1989.
9. 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, pp296-pp297 Dec. 1990.

= 국문초록 =

본 연구는 hidden Markov model (HMM)과 다층 퍼셉트론 (multilayer perceptron, MLP) 합성 분류기를 이용한 근전 신호의 인식에 관한 연구이다.

근전 신호의 동적 특성은 연속 운동 인식처럼 신호의 길이 및 시작점과 끝점이 일정치 않고 시변성이 큰 경우에 반드시 고려되어야 하며, 일반 신경회로망에서는 이의 적용이 용이하지 않다. 따라서, 본 연구에서는 신호의 동적 특성에 대한 적응성을 갖는 HMM과 다층 퍼셉트론 신경회로망을 결합시킨 구조를 갖는 인식기를 제안한다. 이러한 구조는 인식기의 입장에서 볼 때 HMM의 신호의 동적 특성에 대한 적응성과, MLP의 정적인 신호에 대한 우수한 분류력이 결합되어 동적인 신호에도 높은 인식율을 갖는 특성을 갖는다.