

# 유전 알고리즘이 결합된 MLP와 HMM 합성 분류기를 이용한 근전도 신호 인식 기법

정정수<sup>†</sup> · 권장우<sup>\*\*</sup> · 류길수<sup>\*\*\*</sup>

## 요 약

본 연구는 hidden Markov model(HMM)과 유전알고리즘을 갖는 MLP(multilayer perceptron) 합성 분류기를 이용한 근전도 신호의 인식에 관한 연구이다. 제안된 기법에서 유전알고리즘은 전역적인 탐색으로 신경회로망의 최적의 초기 연결강도를 선택하는데, 이로 인하여 학습속도 및 인식률이 향상되게 된다. 근전도 신호의 동적 특성은 연속 운동 인식처럼 신호의 길이 및 시작점과 끝점이 일정치 않고 시변성이 큰 경우에 반드시 고려되어야 하나, 일반 신경회로망에서는 이의 적용이 용이하지 않다. 따라서, 본 연구에서는 신호의 동적 특성에 대한 적응성을 갖는 HMM과 MLP 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.

## An EMG Signals Classification using Hybrid HMM and MLP Classifier with Genetic Algorithms

Jungsu Jung<sup>†</sup>, Jangwoo Kwon<sup>\*\*</sup> and KeelSoo Rhyu<sup>\*\*\*</sup>

## ABSTRACT

This paper describes an approach for classifying myoelectric patterns using a multilayer perceptrons (MLP's) with genetic algorithm and hidden Markov models (HMM's) hybrid classifier. Genetic Algorithms play a role of selecting Multilayer Perceptron's optimized initial connection weights by its typical global search. 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 ANN and HMM algorithms that might lead to further improved EMG recognition systems.

**Key words:** MLP, GA, HMM, EMG, Recognition

## 1. 서 론

생체 신호 중의 하나인 근전도 신호의 인식과 패턴 인식에 사용되는 일반적인 신경회로망은 영상 인

식이나 문자 인식 등의 정적인 신호의 인식에는 뛰어나지만 근전도 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

접수일 : 2002년 8월 5일, 완료일 : 2002년 10월 7일

<sup>†</sup> 동명정보대학교 정보공학부 컴퓨터공학과 부교수

<sup>\*\*</sup> 중신회원, 동명정보대학교 컴퓨터공학과 조교수

<sup>\*\*\*</sup> 한국해양대학교 컴퓨터공학과 교수

함수에 그 수학적 기초를 두고 있는 Markov model과 HMM(hidden Markov model)이다. 일반적으로 HMM은 음성 연구 분야에서 활발한 연구가 진행되어 오고 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 영교차수와 절대 적분치들로 연속 운동신호에서 기본 운동의 구간을 구분하고, 구분된 기본 운동들에서 얻어진 특징 벡터들을 HMM에 적용하여 일차적 인식을 행한다. HMM의 출력치인 확률적 무게치를 정규화한 값과 절대적분치와 영교차수를 특징 벡터로 하여 MLP(multilayer perceptron)에서 이차 분류를 행하여 기능 인식의 신뢰도 향상을 얻었으며 학습속도를 향상시키기 위하여 신경회로망과 최적화 알고리즘인 유전알고리즘을 결합하여 근전신호를 인식한다. 유전알고리즘 (genetic algorithms, GAs)은 생태계의 적자생존의 원리를 이용한 최적화 알고리즘으로, 제안된 인식기법에서 신경회로망의 초기 연결강도를 설정하는데 사용되었다. 이 방법은 유전알고리즘으로 신경회로망의 연결강도의 초기해를 빠르게 찾고, 이 초기해를 신경회로망 네트워크에 적용함으로써 학습시간을 단축시키는데 중점을 두었다. 그리고 유전알고리즘의 돌연변이 연산자는 신경회로망이 국부 최소점(local mimimum)으로 수렴하는 것을 효과적으로 피할 수 있게 해주어

학습시간 단축과 인식기의 안정화, 두 가지 문제점을 동시에 해결할 수 있는 장점이 있다.

### 2. 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 근전도가 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].

### 3. 특징 추출 및 선택

신호로부터 어떤 특징 벡터를 추출하고 선택하는냐에 따라 패턴 인식의 성공 여부가 달려 있다. 패턴 인식에서, 특징 벡터 추출 및 선택의 목표는 패턴 표현의 차원(dimensionality)을 줄이고 그 신호들의 분류도를 향상시키에 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 절대적분평균치 그리고 LPC 계수이다[5,6].




그림 1. 근전신호 발생의 모델.

### 4. 근전도 신호 인식을 위한 합성 인식기

#### 4.1 HMM과 신경회로망의 결합

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

이상의 세 가지 요소에 의하여 구성되는 HMM의 설명에 필요한 기호를 다음과 같이 정의한다.

- $O = O_1, O_2, O_3, \dots, O_T$  관측열
- $T =$  관측열의 지속 시간
- $N =$  상태의 수
- $L =$  관측 심볼의 수
- $Q = \{ q_1, q_2, \dots, q_N \}$ , 상태의 집합
- $V = \{ v_1, v_2, v_3, \dots, v_L \}$ , 관측 심볼의 집합
- $A = \{ a_{ij} \mid a_{ij} = P(q_{t+1} = j \mid q_t = i) \}$ , 상태 천이 확률 행렬

여기서  $a_{ij}$  는 상태  $i$ 에서  $j$ 로의 천이 확률을 나타냄

$B = \{ b_j(O_t) \mid b_j(O_t) = P(O_t \mid q_t = j) \}$ , 관측 심볼 확률 분포

$\pi = \{ \pi_i \mid \pi_i = P(q_1 = i) \}$ , 초기 상태 확률 분포

HMM  $\lambda$ 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, 해당출력을 1 상태로, 나머지는 0 상태로 고정하여, 연결가중치를 훈련시킨다. 신경은 활성화 함수로서 작용하며, 임의의 시간  $t$ 에 비제한적 활성화 입력  $o_k^i(t)$ 를 제한된 출력신호  $p_k^i(o(t))$ 로 변환시킨다. 보통 변환은 시그모이드 함수를 사용하며, 제한된 단조증가함수의 형태를 갖는다.

잘 훈련된 MLP의 출력은 특징 벡터의 확률이 크다면, 베이스 최적 변별기능을 근사적으로 모사한다는 것과 후확률의 추정이라는 것은 이전의 연구에서 증명되었다[9].

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

$$P(O \mid \lambda) = \sum_{i=1}^N a_T(i) \tag{2}$$

여기서

$$a_1(t) = \pi_i b_i(o_{1t}) \quad 1 \leq i \leq N$$

$$a_t(i) = P(o_{1t}, o_{2t}, \dots, o_{jt} = q_i \mid \lambda)$$

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

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

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

$$B \cong [ P(O \mid \lambda_1), P(O \mid \lambda_2), \dots, P(O \mid \lambda_N) ] \tag{3}$$

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

$$C = a/B = [ a/P(O \mid \lambda_1), a/P(O \mid \lambda_2), \dots, a/P(O \mid \lambda_N) ] \tag{5}$$

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

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

여기서  $v_j$  는  $V$ 의  $j$ 번째 행에 해당하는 열벡터이다.

출력층의 출력은 식(7)처럼 주어진다.

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

여기서  $w_k$  는  $W$ 의  $k$  번째 행에 해당하는 열벡터이다.

따라서 쌍극성 연속 함수인 경우 출력층에서의 오차 신호항은 식 (8)로 은닉층에서의 오차 신호항은 식 (9)로 주어진다.

$$\delta_{ok} = \frac{1}{2}(d_k - o_k)(1 - o_k^2), \text{ for } k=1,2,\dots,K \tag{8}$$

$$\delta_{yj} = \frac{1}{2}(1 - y_j^2) \sum_{k=1}^K \delta_{ok} w_{kj}, \text{ for } j=1,2,\dots,J \tag{9}$$

#### 4.2 신경회로망 및 유전알고리즘

본 논문에서는 유전알고리즘을 이용하여 신경회로망이 가진 단점을 보완하고자한다. 이를 위해서 유전알고리즘을 이용하여 네트워크의 초기 연결강도를 구하고, 이 초기연결강도를 이용하여 네트워크를 학습시킴으로서 학습시간을 단축시키는 방법을 사용하였다. 신경회로망 네트워크의 최적 연결강도를 유전알고리즘을 이용하여 직접 구하는 방법도 있으나, 이 방법은 마지막 단계에서 해의 정확한 근사값을 찾아내는 미세 조정 기능이 부족하기 때문에 알고리즘 수행시간 면에서 큰 이점을 얻지 못한다[6]. 따라서 본 논문에서는 2진 표현법을 사용하여, 개체를 표현할 때 문제의 크기에 제한을 받으나, 유전알고리즘을 사용하여 뉴런의 최적의 가중치들과 활성화 함수의 적절한 기울기를 선택함으로써, 신경회로망의 조기포화를 방지하고, 학습속도를 향상시킬 수 있다. 이 방법은 2진 개체표현법으로 네트워크의 연결강도 및 구조를 쉽게 표현할 수 있고, 신경회로망에서 사용되는 오차의 제곱합(sum of the squared error)을 평가함수로 사용할 수 있기 때문에 적용이 용이하다. 신경회로망에서 오차의 제곱합은 출력패턴과 출력기대 패턴의 차이를 나타낼 때 사용하는데, 유전알고리즘을 적용하더라도 결과적으로 구하고자하는 것은 네트워크의 적절한 뉴런 값이다. 그러므로 적절한 뉴런 값이 선택되었다면 오차의 제곱합은 적을 것이고, 그렇지 않다면 클 것이다. 이를 이용하면 별도의 평가함수를 만들지 않아도 적합도를 판정할 수 있다.

다음 그림 2에서 제안된 인식기법 중 오류역전파에 유전알고리즘을 적용하였을 때의 흐름도를 나타냈다.

그림 2의 제안된 알고리즘은 다음과 같은 순서를 갖는다. 유전알고리즘의 모집단으로 신경회로망의 연결강도를 2진 표현법을 사용하여 나타낸다. 그리고 교배, 돌연변이 등의 연산자를 거친 염색체를 네트워크를 이용해 평가한 후, 그 평가순위에 따라 재

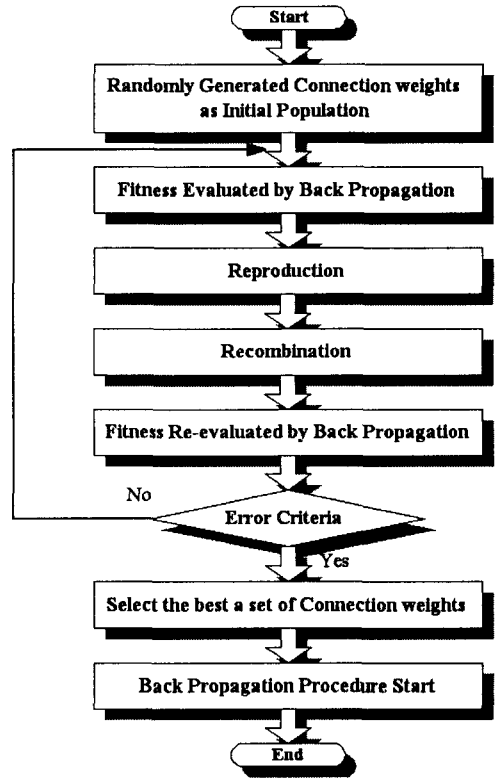


그림 2. 오류역전파에 유전알고리즘을 적용시켰을 때의 흐름도

결합 및 재생산을 수행한다. 이때 평가함수로는 출력 뉴런과 출력기대 패턴과의 오차의 제곱합을 사용하였다. 이런 과정을 오차허용기준을 만족시킬 때까지 반복한다.

본 논문에서 제안한 인식기법에서는 출력층의 연결강도를 설정할 때에만 유전알고리즘을 사용한다. 프로토타입으로는 입력패턴의 전체 평균값을 사용하여 입력패턴과 연결강도 사이에 직교성의 확보해 준다. 입력패턴의 구성은 26개의 뉴런으로 되어있다. 6개의 HMM 파라미터와 각각 10개씩의 절대 적분치와 영교차수 파라미터로 되어있으며, 전체적으로 오류역전파에 유전알고리즘을 결합한 인식기법의 경우 26-30-6 뉴런으로 구성되어있다. 그리고 카운터 프로퍼게이션에 유전알고리즘을 적용한 경우는 26-60-6 뉴런으로 구성되었다. 유전알고리즘의 염색체는 네트워크의 각 초기연결강도에 해당하며 그 크기는 5비트이다. 따라서 모집단 1개의 크기는 4800비트가 되고 이러한 모집단이 30개 존재한다. 적합도가 높은 염색체의 선택은 최근에 많이 사용되는 토너먼트

트 방식과 엘리트 방식을 혼용하여 신뢰도를 높였으며, 유전 연산자로는 균일교배(uniform crossover), 돌연변이를 사용하였다. 유전알고리즘은 이와 같은 최적화과정을 통해 적합도가 높은 모집단 한 개를 선택하게 된다.

5. 실험 및 검토

5.1 신호의 획득

실험은 우선 의수 제어를 위한 기본 기능을 6가지의 기본 운동으로 제한한다. 그림 3에 설정한 팔의 기본 기능이 나타나 있다. 그림처럼 6가지 기본 운동에 대한 신호를 장기간에 걸쳐 개별적으로 수집하였다. 시험 시스템의 구성은 그림 4와 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 삼두박근의 중심부와 끝부분에 각기 2개씩의 전극(쌍극법)을, 그 중앙에 접지전극을 부착하여 시험하였다. 이중 이두박근을 채널 1로 삼두박근을 채널 2로 정하였다. 전극의 최적위치의 선정은 매우 까다로운 문제로서 일반적으로 실험에 의해 결정되며[8] 잡음을 최소화하도




그림 4. 시험시스템 구성도

록 선정하였다. 그림 3과 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 입력 값으로 사용하였다. 그림 5에는 제안한 HMM-GA-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,  $P(O_i)$ 을 정규화한 값과 검출된 기본 운동 구간의 영교차수와 절대 적분치를 MLP의 훈련에 사용되게 된다. 본 연구에서는 이산형 HMM을 사용하였다. 기능 분류는 기본 운동 구간 검출을 거친 데이터가 입력되면 훈련

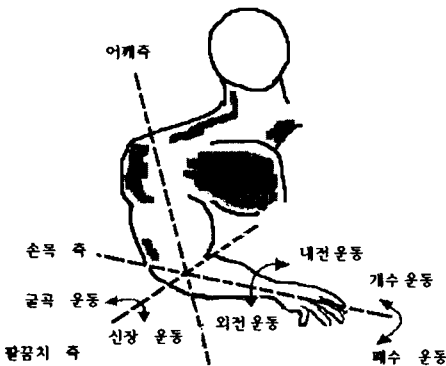


그림 3. 기본 동작의 구성

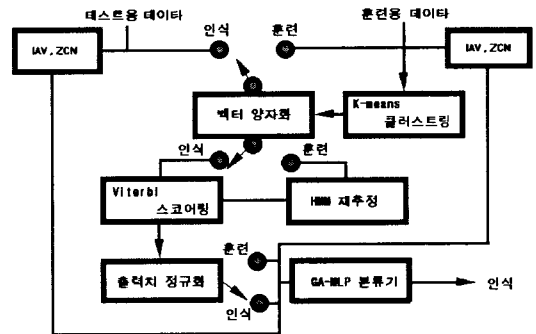


그림 5. HMM-GA-MLP 합성 인식기의 학습 및 인식 시스템.

과정중에 학습된 코드북을 가지고 벡터 양자화를 행하고 Viterbi 탐색 알고리즘을 사용하여 인식 결과를 1차적으로 출력하면 각 HMM 모델에 대한 확률치를 계산하고 이들 출력치를 정규화 시켜 절대적분치, 영교차수와함께 MLP의 입력값으로 사용된다.

별도의 언급이 없는한 그림 3에 나타난 기본운동은 표 1의 심볼로써 나타낸다.

표 1. 기본 운동과 심볼표

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

### 5.2 HMM-GA-MLP 합성 인식기의 인식

본 논문에서 제안하는 인식기의 성능을 비교하기 위하여 다음과 같은 4종류의 실험을 행하였다.

실험 1 : HMM 알고리즘만으로 구성된 인식기

실험 2 : HMM-MLP 합성 인식기 (1단의 MLP)

실험 3 : HMM-GA-MLP 합성 인식기 (1단의 MLP)

실험 4 : HMM-GA-MLP 합성 인식기 (2단의 MLP)

실험 1의 경우는 HMM 알고리즘만으로 학습 및 기능 인식을 행하였으며, 실험 2의 경우는 HMM-MLP 합성 인식기이지만 1단의 MLP만을 가지는 구조이며, 실험 3의 경우가 유전자 알고리즘을 갖는 HMM-MLP 합성 인식기이지만 1단의 MLP만을 가지는 구조이다. 실험 4의 경우가 본 연구에서 제안하는 구조로 HMM과 유전자 알고리즘을 갖는 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.

#### 5.2.1 실험 1

그림 6에 실험 1에 사용한 전체 인식 시스템이 나타나 있다. 각 채널의 추출된 LPC 특징 계수만을 특징 벡터로 사용하며 HMM 알고리즘만으로 학습 및 인식을 수행한다. 이 구조의 전체 인식율은 74.45% 미만으로 저조하다.




그림 6. 실험 1의 인식 시스템 개략도.




그림 7. 실험 1의 인식 결과표

#### 5.2.2 실험 2와 실험3

그림 8에 실험 2 및 3에 사용한 전체 인식 시스템이 나타나 있다. 이 구조는 HMM 알고리즘과 1단의 MLP를 직렬 연결한 형태를 갖는다. 실험3의 경우는 실험2의 것과 동일하나 MLP의 학습에 유전자 알고리즘을 적용한 것이 실험2와 구별된다. 인식 과정은 실험 1과 유사하다. 인식율을 실험 1과 비교하면 전체 인식율이 실험 1의 경우에는 74.45% 이고 실험




그림 8. 실험 2의 인식 시스템 개략도

2의 경우에는 76.9%로 2.45%가 향상되었고 실험 3의 경우에는 87.7%로 13.25%가 향상되었으며 특히 실험3의 경우에는 실험2에 비하여 그림 9에서처럼 학습속도가 향상되었음을 알 수 있다. LPC 계수만으로 인식이 어려운 경우에도, 각 채널에서 얻은 절대 적분치와 영교차수가 각 기본 운동에 대하여 중첩이 심하지 않고 정규화된 HMM 출력 결과가 각 모델에 대하여 특정한 패턴을 갖고 있기 때문이다. 그림 7를 살펴보면 훈련 과정에서 채널 1과 2를 통해서 입력된 데이터에서 추출한 LPC계수가 벡터 양자화된후 기본 운동별로 6개의 HMM을 생성한다. 훈련에 사용한 데이터에 대한 6가지 HMM모델의 Viterbi 스코 어링을 한 결과치를 정규화하고 추정된 기본 운동 구간에서 계산한 절대 적분치와 영교차수와 함께 MLP 훈련을 위한 입력 벡터로 사용한다.




그림 9. 실험 2(HMM-MLP)와 실험 3(HMM-GA-MLP)의 인식 결과

실험 2와 3의 오인식 분포 형태를 그림 9에 나타내었다. 이 그림에서 x축은 각 기본 운동들을 y축은 각 기본 운동에 대한 인식률을 나타낸다. 그림에서 살펴보았듯이 실험 3은 본 논문에서 제안하는 구조, 즉 실험 4의 구조를 발생시킨 정보를 포함하고 있다. WI, WO, G, S의 인식율을 향상시키기 위하여 실험 4에서는 IN과 OUT를 한그룹으로 WI, WO, G, S를 다른 한그룹으로 1차 분류하고 상호간의 오인식이 겹쳐있는 WI, WO, G, S의 인식율을 향상시키기 위하여 3개의 MLP를 연결시키는 구조를 보인다.

실험 2와 실험3의 인식결과, 제안된 인식기법을 사용한 인식기가 모든 기본운동에 대해서 높은 인식률을 보이고, 전체적으로는 11%가량 인식률이 향상되었다. 실험 2에서 58.3% 정도의 낮은 인식률을 보이는 경우는 학습시 국부 최소점으로 수렴하여 학습에 실패한 것이다. 아래의 그림 10은 실험 2와 실험 3에서의 학습시 오차 수렴속도이다. HMM-GA-MLP의 경우 유전 알고리즘에 의한 계산량이 증가될 수 있는 단점을 가지고 있으나 실험 3의 오차수렴 곡선을 보면 100번 정도 학습하기 이전에 오차가 급격히 줄어들고, 그 후에는 경사가 완만한 곡선을 그리며 수렴한다. 이는 일반적인 오류역전과 학습알고리즘은 경사탐색 방법이기 때문에 오차가 급격히 줄어들 수는 없는 반면, 유전알고리즘을 적용하였을 경우는 돌연변이 연산자 등에 의해 연결강도의 급격한 변화가 가능하고, 이런 변화가 학습과정에서 국부 최소점으로 수렴하는 것을 방지해 주는 등의 역할을 해주기 때문에 빠른 학습이 가능하게 된다.




그림 10. 실험 2(HMM-MLP)와 실험 3(HMM-GA-MLP)의 오차수렴 속도

### 5.2.3 실험 4

그림 11에 실험 4에 사용한 전체 인식 시스템이




그림 11. 실험 4의 인식시스템개략도.

나타나 있다. 실험 4는 본 연구에서 제안하는 기능 인식 시스템으로 실험 3의 확장된 형태로 HMM의 동적인 신호에 대한 적응 특성과 MLP의 탁월한 분류력을 결합시키고 학습속도의 향상을 위해 유전자 알고리즘을 결합시킨 형태이다. 실험 2와 3의 결과에서 알 수 있듯이 기본 운동 WI, WO, G, S의 중첩이 심하므로 별도의 MLP를 두고 이를 세분하여 훈련시킴으로써 오인식율을 줄이려는 의도이다. 이 구조는 1단의 HMM과 2단의 MLP를 직렬 연결한 형태를 갖는다. 각각의 MLP는 학습속도의 향상을 위해서 유전자 알고리즘과 결합되었다. 인식율이 대체적으로 실험 2와 3의 인식율보다 우수하지만 기본 운동 WO의 경우는 실험 2와 3의 구조에서 보다 실험 4의 구조에서도 향상되지 못하였다. 이는 WO의 근전신호가 LPC 특징벡터와 영교차수와 절대적분치의 특징벡터 공간상에서도 다른 기본운동들과 분류되지 못할만큼 특징벡터 공간상에서의 군집성이 양호하지 않기 때문이다. 그림 12에는 실험 4의 방법을 이용하여 구한 총 인식율이 나타나 있다. 실험 4의 인식 기법을 이용한 전체 인식율은 89.5%이다. 그림 13은 실험 1, 실험 2와 실험 3의 총 인식율을 각 기본운동별로 나타낸 그림이다. x축은 기본 운동을 y축은 인식율을 나타낸다.

그림에 나타나 있듯이 실험 4의 경우에 가장적인 오인식율을 보임을 알 수 있다.

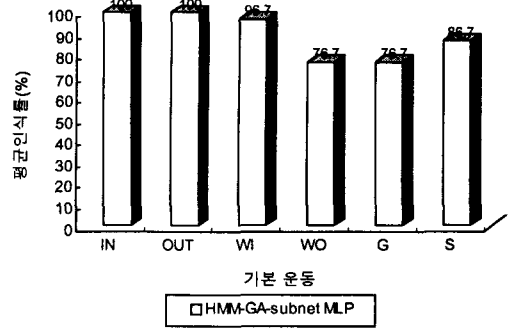


그림 12. 실험 4의 인식 결과표

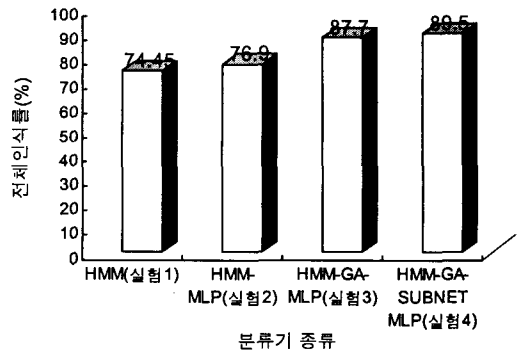


그림 13. 실험별 전체인식율 비교.

### 5. 결 론

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

개발된 분류기는 근전신호를 대상으로 하고 있으나 랜덤한 다른 생체신호의 인식에도 적용가능하리라 판단된다. 본 연구에서 제안하는 구조, 즉, HMM과 2단의 GA-MLP를 결합한 구조에서는 89.5%의 인식율을 보였으며 유전자 알고리즘을 적용시 학습 속도도 개선이 됨을 알 수 있었다. 이는 동일한 데이



터를 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 74.45%로 저조했다. 이는 생체 신호의 특성이 단일 HMM 알고리즘에 적합하지 않기 때문이다. HMM 알고리즘과 1단의 MLP를 합성한 구조에서는 인식율이 76.9%로 HMM 알고리즘만을 사용한 경우에 비하여 인식율의 향상을 보였는데 이는 HMM의 인식 출력치를 정규화하여 HMM의 오인식 분포 특성을 MLP로 하여금 학습하게 하여 2차 인식을 행하였기 때문이었다. 제안한 구조의 인식기가 가장 좋은 인식율을 보이는 이유는 HMM과 1단의 MLP를 합성한 구조에서 갖고 있는 오인식 분포 특성을 MLP로 하여금 재학습토록 하였기 때문에 가능하였다. 또한 유전알고리즘을 신경회로망의 초기 연결강도를 결정하는데 사용하여 학습속도를 향상시켰다. 실험 결과 기존의 학습알고리즘만을 사용한 네트워크보다 유전알고리즘을 적용해 초기 연결강도를 적절하게 조정하면 네트워크가 오류역전파의 경우 동일한 환경에서 인식률이 최대 11% 정도 우수함을 보였다. 또한 실험 중 학습에 실패하는 경우는 없었는데 이는 제안된 인식기가 국부 최소점으로 수렴하지 않기 때문이며, 따라서 안정적이고, 평균적으로 높은 인식률을 가진다. 본 연구는 6가지의 간단한 기본운동에 대한 근전도 신호를 대상으로 하였으나 인식대상으로 좀 더 복잡한 팔운동으로 확장할 필요성이 있고, 이때 추출된 근전도 신호의 특징을 효과적으로 반영할 수 있는 더욱 정교한 파라미터의 개발과 카운터 프로퍼게이션을 이용한 근전도 신호 인식기의 인식률을 좀더 향상시킬 수 있는 기법이 요구된다.

## 참 고 문 헌

- [ 1 ] G. Zavaliagkos, et al., "A Hybrid Segmental Neural Net/Hidden Markov Model System for Continuous Speech Recognition", *IEEE Trans. Speech and Audio Processing*, vol. 2, no. 1, part II, pp. 151-152, 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. Speech and Audio Processing*, vol. 1, no. 1, pp. 77-78, 1993.
- [ 3 ] Willis J. Tonpkins, *Biomedical Digital Signal Processing*, Prentice Hall International Editions, pp. 43-44, 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*, pp. 4-7, 1985.
- [ 5 ] L.R.Rabiner, R.W.Schafer, *Digital Processing of Speech Signals*, Prentice-Hall, Inc., pp. 359-362, 1978.
- [ 6 ] Lawrence Rabiner, Riing-Hwang Juang, *Fundamentals of Speech Recognition*, Prentice-Hall International, Inc. pp. 333-357, 1993.
- [ 7 ] Moshe Solomonow et al, "The EMG-Force Model of Electrically Stimulated Muscle: Dependence on Control Strategy and Predominant Fiber Composition", *IEEE Trans. Biomed. Eng.*, vol. 34, no. 9, pp. 692-703, 1987.
- [ 8 ] Ronald J.Triolo and Gordon D.Moskowitz, "The Theoretical Development of a Multi-channel Time-Series Myoeoprocessor for Simultaneous Limb Function Detection and Muscle Force Estimation", *IEEE Trans. Biomed. Eng.*, vol. 36, no. 10, pp 1004-1009, 1989.
- [ 9 ] D.W.Ruck, S.K.Rogers et al "The Multilayer Perceptron as an Approximation to a Bayes Optimal Discriminant Function" *IEEE Trans. Neural Networks*, vol. 1, no. 4, pp. 296-297, 1990.
- [ 10 ] David E. Goldberg, "Genetic Algorithm in Search, Optimization, and Machine Learning", Addison-Wesley Publishing, 1989.



정 정 수

1981년 경북대학교 전자공학과  
공학사  
1984년 부산대학교 전자공학과  
컴퓨터공학전공 공학석사  
1993년 한국해양대학교 전자통  
신공학과 컴퓨터공학전  
공 박사과정 수료


현재 동명정보대학교 정보공학부 컴퓨터공학과  
부교수  
관심분야 : 전문가시스템, 데이터베이스, 멀티미디어



류 길 수

1976년 한국해양대학교 기관학  
과 공학사  
1979년 한국해양대학교 제어계  
측학과 공학석사  
1986년 일본동경공업대학원 정보  
공학과 공학석사  
1989년 일본동경공업대학원 정보  
공학과 공학박사

현재 한국해양대학교 컴퓨터공학과 교수  
관심분야 : 전문가시스템



권 장 우

1990년 2월 인하대학교 전자공학  
과 졸업(공학사)  
1992년 2월 인하대학원 전자공학  
과 (정보공학 전공)  
공학 석사  
1996년 8월 인하대학원 전자공학  
과 (정보공학 전공)

공학 박사

1996년 10월~1998년 2월 특허청 심사관  
2000년 4월~현재 컴퓨터 범죄수사 자문위원  
2000년 3월~현재 하이테크 시스템(주) 기술 자문 위원  
1999년 10월~현재 한독 전산(주) 기술 자문 위원  
1999년 10월~현재 한국 장애인 재활 협회 ICTA 분과  
위원  
2002년 2월~현재 동명정보대학교 컴퓨터공학과 조교수  
관심분야 : 재활공학, 뉴럴네트워크, 신호처리, Embedded  
Micro-controller 시스템등  
저서 : 마이크로 프로세서 원리 및 응용, 디지털공학-이  
론 및 PLD 실습, 컴퓨터 기초 활용외 다수

교 신 저 자

권 장 우 (608-711) 부산시 남구 용당동 535 동명정보대학  
교 정보공학부 컴퓨터공학과