

# 근전도 신호인식을 위한 HMM과 GA-MLP의 합성에 관한 연구

신 철규, 이 동훈, 이 상민, \*권 장우, 홍 승홍  
인하대학교 전자공학과, \*특허청

## A Study on the Synthesis of HMM and GA-MLP for EMG Signal Recognition

C.K. Shin, D.H. Lee, S.M. Lee, \*J.W Kwon, S.H Hong  
Department of Electronic Engineering, Inha University  
\*Korea Industrial Property Office

### ABSTRACT

*In this paper, we suggested the combination of HMM(Hidden Markov Model) and MLP (Multi-Layer Perceptron) with GA(genetic algorithm) for a recognition of EMG signals.*

*To describe EMG signal's dynamic properties, HMM algorithm was adapted and due to its outstanding abilities in static signal classification MLP was connected as a real processor.*

*We also used GA(Genetic Algorithm) for improving MLP's learning rate.*

*Experimental results showed that the suggested classifier gave higher EMG signal recognition rates with faster learning time than other one.*

### 1. 서론

근전도 신호의 인식과 패턴인식에 사용되는 일반적인 신경회로망 (Neural Network)은 영상인식이나 문자인식등의 정적인 신호의 인식에는 뛰어나지만 근전신호나 음성신호처럼 시간적으로 변하는 동적인 신호의 처리에는 적합하지 못하다는 단점이있다.

확률 모델(stochastic model)은 시변적 신호의 인식에 효율적인데, 히든 마르코브모델(Hidden Markov Model, HMM)이라는 확률모델을 적용하면 근전도 신호의 동적인 특성을 잘 반영할 수 있다.

본 논문에서는 연속된 운동신호인 근전도 신호를 6개의 기본 운동영역으로 구분하고, 구분된 운동영역들에서 얻어진 특징벡터들에 HMM을 적용하여 일차적 인식을 수행한다. 그리고 HMM의 출력치를 입력으로해서 다층 퍼셉트론 (Multi-Layer Perceptron, MLP)에서 이차적인 인식을 행한다. 이때 MLP의 느린 학습속도를 보완하기 위해서 최적화 알고리즘인 유전알고리즘(Genetic Algorithm, GA)을 적용한다.

실험 결과 HMM과 MLP라는 두 처리기의 효율적인 결합과 유전알고리즘의 적용으로 비교적 짧은 시간에 보다 높은 인식률을 얻을 수 있었다.

### 2. 근전도 신호 인식을 위한 인식기

#### 2.1 HMM과 MLP의 합성

일반적으로 HMM은 음성 연구 분야에서 활발한 연구가 이루어지고 있으며 신경회로망과의 결합을 통하여 상호간의 장점을 증대시키기 위한 연구가 진행되고 있다.

HMM을 구성하는 요소는 N개의 상태와 시간에 따른 상태의 변화를 결정하는 상태전이 확률분포, 각 상태에서의 관측치의 분포를 결정하는 관측 분포 확률이다. 이상의 세가지 요소에 의해서 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 전이 확률 행렬, 여기서  $a_{ij}$  는 상태  $i$  에서  $j$ 로의 전이 확률을 나타냄

$B = \{ b_j(O_t) \mid b_j(O_t) = P(O_t \mid q_t = j) \}$ ,

관측 심볼 확률 분포

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

이와 같은 정의를 통해 앞에서처럼 HMM  $\lambda$ 는  $\lambda = (A, B, \pi)$ 로 표시되며, 관측열은  $O = O_1, O_2, O_3, \dots, O_T$ 로 표시된다.

모델 파라미터  $\lambda$ 가 주어졌을때 관측 심볼열  $O$ 에 대한 확률,  $P(O \mid \lambda)$ 는 전향 알고리즘을 이용하면 식 (1)처럼 주어진다.

$$P(O \mid \lambda) = \sum_{i=1}^N \alpha \tau(i) \quad (1)$$

여기서

$$\begin{aligned} a_1(t) &= \pi_i b_i(o_1) \quad 1 \leq i \leq N \\ \alpha_t(i) &= P(o_1, o_2, \dots, o_t | i_t = q_i | \lambda) \\ \alpha_{t+1}(j) &= \left[ \sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(o_{t+1}) \\ t &= 1, 2, \dots, T-1, \quad 1 \leq j \leq N \end{aligned}$$

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

$$B \triangleq [P(O | \lambda_1), P(O | \lambda_2), \dots, P(O | \lambda_N)] \quad (2)$$

$$a = \frac{\sum_{i=1}^N P(O | \lambda_i)}{N} \quad (3)$$

$$C = \frac{a}{B} = \left[ \frac{a}{P(O | \lambda_1)}, \frac{a}{P(O | \lambda_2)}, \dots, \frac{a}{P(O | \lambda_N)} \right] \quad (4)$$

여기서  $C = c_1, c_2, \dots, c_N$

식(4)로 HMM의 출력치는 주어지고

C를 입력으로 하는 MLP의 은닉층의 출력 값은 식(5)처럼 주어지며

$$y_j = f(v_j^i c), \text{ for } j=1, 2, \dots, J \quad (5)$$

여기서  $v_j$ 는 V의 j번째 행에 해당하는 열벡터이다.

출력층의 출력은 식(6)처럼 주어진다.

$$o_k = f(w_k^j y), \text{ for } k=1, 2, \dots, K \quad (6)$$

여기서  $w_k$ 는 W의 k번째 행에 해당하는 열벡터이다.

따라서 쌍극성 연속 함수인 경우 출력층에서의 오차 신호항은 식(7)로 은닉층에서의 오차 신호항은 식(8)로 주어진다.

$$\delta_{ok} = \frac{1}{2} (d_k - o_k) (1 - o_k^2) \quad \text{for } k=1, 2, \dots, K \quad (7)$$

$$\delta_{yj} = \frac{1}{2} (1 - y_j^2) \sum_{k=1}^K \delta_{ok} w_{kj} \quad \text{for } j=1, 2, \dots, J \quad (8)$$

## 2.2 MLP와 GA의 합성

유전알고리즘은 1970년대초 John Holland에 의해 제안된 자연생태계를 모방한 모의진화 형태의 최적화 알고리즘이다. 유전알고리즘의 수렴해석에 관한 연구는 schema이론에 기초하고 있으며, 그 성능은 실제 파라미터의 부호화 기법(encoding), 재생산(reproduction), 교배(crossover), 돌연변이(mutation) 등의 유전연산자와 평가함수 설정등에 크게 의존한다. 유전알고리즘에 관한 자세한 내용은 [2]에 잘 나와있다.

본 논문에서는 신경회로망이 학습시 많은 시간을 필요로 하는 단점을 보완하기 위해서 유전알고리즘을 이용해서 신경회로망의 초기 연결강도를 구하고, 이 초기 연결강도를 이용해서 네트워크를 학습시킴으로써 학습시간을 단축시키는 방법을 사용하였다.

유전알고리즘의 모집단으로 신경회로망의 연결강도를 2진표현법으로 나타내고, 각 염색체를 네트워크

에 적용시켜 적합도를 평가한다. 그리고 교배, 돌연변이 등의 연산자를 거친 염색체를 재평가한다. 이 과정을 오차가 임계값보다 작아질 때까지 계속 반복한다.

다음 그림은 신경회로망의 연결강도를 2진 표현법으로 나타낸 예와 신경회로망에 유전알고리즘을 적용시켰을 때의 전체 흐름도이다.




그림.1. 2진 표현법으로 나타낸 네트워크구조  
Fig.1. Network structure designed with bit-string

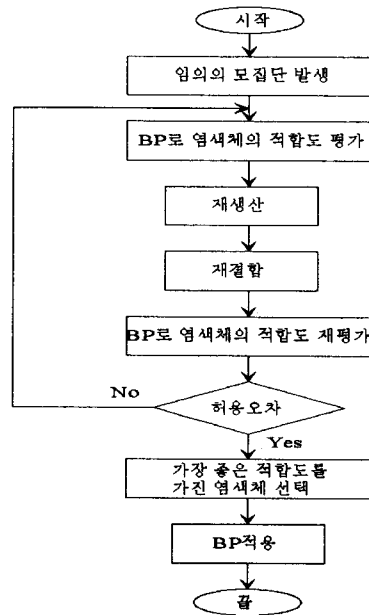


그림.2. MLP에 GA를 적용시켰을 때의 흐름도  
Fig.2. Flow chart of MLP with GA

## 3. 실험 및 결과

### 3.1 실험 데이터

인식에 사용한 근전도 신호는 20대 후반의 정상인을 대상으로 이두박근과 삼두박근의 중심부와 끝부분에 각각 2개씩의 전극을, 그 중앙에 접지전극을 부착하여 6가지의 기본운동에 대한 신호를 장기간에 걸쳐 수집한것을 사용하였다. 이때, 이두박근을 채널 1로 삼두박근을 채널2로 정하였다.

표.1.과 같이 6가지의 기본운동을 행하였고, 각각의 운동에 대해서 30회의 반복실험을 행하였다. 30회의 반복 실험한 데이터 중 10세트의 특징 벡터군을 샘플로 해서 제안한 인식기의 훈련을 위한 입력값으로 사용하였다.

## 근전도 신호 인식을 위한 HMM과 GA-MLP의 합성에 관한 연구

표.1. 기본운동과 심볼

Table.1. Primitive Motion and Symbol

| 번호 | 심볼  | 기본운동     |
|----|-----|----------|
| 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 |

### 3.2 신경회로망 구조 및 GA 파라미터

본 논문에서 제안한 인식기에서는 가장 일반적인 신경회로망 중의 하나인 오류역전파 신경회로망(error back-propagation, BP)을 사용하였다. 그리고 그 구성은 26-30-6 뉴런으로 하였다.

유전알고리즘의 염색체는 BP네트워크의 각 연결강도에 해당하며 그 크기는 5비트이다. 따라서 모집단 1개의 크기는 4800비트가 된다. 염색체의 적합도 평가함수로는 BP의 오차의 제곱합(sum of the squared error)을 사용하였고, 적합도가 높은 염색체의 선택은 토너먼트 방식으로 하였다. 유전 연산자로는 균일교배(uniform crossover), 돌연변이를 사용하였으며, 그 확률(pmut)은 0.009이다.

### 3.3 실험결과

실험은 제안하는 인식기의 성능을 비교하기 위해서 다음과 같은 2종류의 실험을 행하였다.

실험 1 : HMM - MLP 합성인식기

실험 2 : HMM - GA-MLP 합성인식기

실험 1에서는 HMM-MLP합성인식기만을 사용하였고, 실험 2에서는 MLP에 유전알고리즘을 적용한 HMM - GA-MLP 합성인식기를 사용하여 학습 및 인식을 수행하였다.

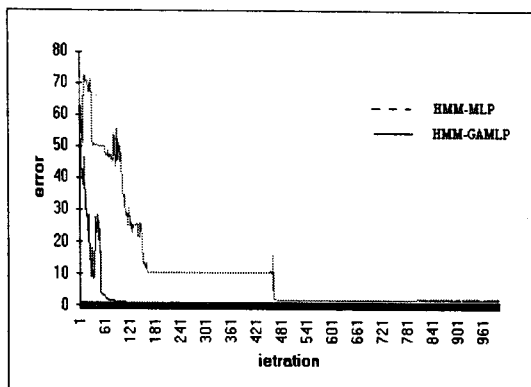


그림.3. 각 실험의 학습시간

Fig.3. Each Experiment's learning rate

각 실험은 학습반복횟수를 1000번으로 동일하게 하여 실행하였다. 실험결과, MLP에 GA를 적용한 인식기의 학습속도가 2배정도 빠르게 나타났다. 인식률은 개수운동 한 가지에서만 오인식률이 높을 뿐 전

체인식률에서 90%를 나타내 GA를 적용한 인식기가 우수한 것을 알 수 있었다.

표.2. 실험1의 인식 결과표

Table.2. Recognition Rates of Experiment 1

|          | 데이터수 | 오인식수 | 인식률(%) |
|----------|------|------|--------|
| IN       | 30   | 0    | 100    |
| OUT      | 30   | 1    | 96.7   |
| WI       | 30   | 2    | 93.3   |
| WO       | 30   | 9    | 70.0   |
| G        | 30   | 8    | 73.3   |
| S        | 30   | 3    | 90     |
| 전체인식률(%) | 180  | 23   | 87.2   |

표.3. 실험2의 인식 결과표

Table.3. Recognition Rates of Experiment 2

|          | 데이터수 | 오인식수 | 인식률(%) |
|----------|------|------|--------|
| IN       | 30   | 0    | 100    |
| OUT      | 30   | 0    | 100    |
| WI       | 30   | 2    | 93.3   |
| WO       | 30   | 6    | 80     |
| G        | 30   | 6    | 80     |
| S        | 30   | 4    | 86.7   |
| 전체인식률(%) | 180  | 18   | 90     |

## 4. 결론

본 논문에서는 정적인 신호의 인식에 탁월한 MLP와 시변적 신호의 특성을 잘 반영하는 HMM을 결합한 HMM-MLP 합성인식기를 이용하여 근전도 신호 인식을 행하였다. 이때 MLP의 느린 학습속도를 보완하기 위해서 유전알고리즘을 적용하였다.

실험 결과 실험에 사용한 일반적인 BP보다 GA를 적용해 초기 연결강도를 적절하게 조정된 BP가 학습속도도 빠르고, 인식률면에서도 우수함을 알 수 있었다. 그러나 GA 적용시에 개체표현을 2진표현법을 사용하기 때문에 네트워크의 크기에 제약이 받는 단점이 있었다.

추후 연구과제로는 인식에 사용하는 MLP를 일반적인 BP뿐 아니라 신호의 동적인 특성도 반영할 수 있는 시간지연 신경회로망(TDNN)이나 시간지연 쌍전파 신경회로망(TDCPN)으로 바꾸어서 인식을 행해보고, 또 적용하는 GA 유전연산자의 성능을 향상시켜 학습속도 및 인식률을 개선하는 연구를 행할 예정이다.

## 참고문헌

- [1] 권장우, "의수의 궤적제어를 위한 근전신호의 인식기법에 관한 연구", 인하대학교 박사학위 청구논문, 1996
- [2] David E. Goldberg, "Genetic Algorithm in Search, Optimization, and Machine Learning", Addison-Wesley Publishing, 1989
- [3] 김정룡, "Backpropagation에 유전알고리즘의 응용", 전남대학교 석사학위 청구논문, 1994

- [4] Jose L. Ribero Filho, Philip C. Treleaven, "Genetic-Algorithm Programming Environments", IEEE Computer Society, pp 28 - 43, 1994
- [5] 伊庭齊志, "遺傳的アルゴリズムの基礎", オーム社, 1994
- [6] M. Srinivas, Lalit M. Patnaik, "Genetic Algorithms: A Survey", IEEE Computer Society, pp 17 - 26, 1994
- [7] Whitley. D , T.Hanson, "Optimizing Neural Networks using Faster, More Accurate Genetic Search", Proceedings of ICGA, pp 391 - 396, 1989