

論文98-35S-11-19

신경회로망과 유전알고리즘을 이용한 근전신호 인식기법

(A Study on Electromyogram Signals Recognition Technique using Neural Network and Genetic Algorithms)

申徹圭*, 李相旻*, 李殷實*, 權章禹**, 張永健***,
洪勝弘*

(Chulkyu Shin, Sangmin Lee, Eunsil Lee, Jangwoo Kwon, Younggun Jang,
and Seunghong Hong)

요약

본 논문에서는 근전신호를 효과적으로 인식하기 위해 신경회로망에 유전알고리즘을 결합하여 근전신호를 인식하는 기법을 제안한다. 본 기법은 신경회로망이 내재한 단점들을 개선하여 근전신호의 인식률을 높이고 안정적인 인식을 행하는 것을 목표로 한다. 제안된 기법에서 유전알고리즘은 전역적인 탐색으로 신경회로망의 최적의 초기 연결강도를 선택하는데, 이로 인하여 학습속도 및 인식률이 향상되게 된다. 그리고 절대 적분치, 영교차수등의 특징벡터 이외에 히든 마르코프 모델로 전처리를 하여 시간적으로 변하는 근전신호의 특성을 입력패턴에 반영하였다. 6가지의 기본운동을 대상으로 행한 실험결과, 제안된 인식기법은 기존의 일반적인 신경회로망의 학습규칙을 이용하여 인식했을 때보다 학습속도와 인식률이 향상되었고, 국부최소점으로 수렴하는 경우가 없어 실험에 실패하지 않고 안정적으로 근전신호의 패턴을 인식하였다.

Abstract

A new recognition technique using neural network coupled with Genetic Algorithms (GAs) was proposed. This technique concentrate on efficient Electromyography signal recognition through out improving neural network's several demerits. GAs play a role of selecting Multilayer Perceptron's optimized initial connection weights by its typical global search. Electro Myography signal was pre-processed with Hidden Markov Model (HMM) in order to reflect its time-varying property into input pattern except other features such as Zero Crossing Number (ZCN) and Integral Absolute Value (IAV). Results for 6 primitive motions show that the suggested technique has better performance in learning time and recognition rates than already established ordinary methods. Moreover, it performed stable recognition without convergence into a local minimum.

I. 서론

근전신호는 근육의 수축 또는 이완시 표면전극을 통해서 얻어지는 생체전기신호이다. 의수를 제어하기 위

한 명령어로 근전신호를 사용할 수 있다고 제안된 이래, 이 신호를 의수등의 제어원으로 사용하려는 시도가 많이 이루어졌다. 그러나, 근전신호는 잡음을 많이 포함하고, 시간에 따라 변하는 시변성을 갖고 있어 신

* 正會員, 仁何大學校 電子工學科

(Dept. of Electronic Eng., Inha Univ.)

** 正會員, 東明情報大學校 情報工學部 컴퓨터工學科

(Dept. of Computer Eng. School of Info. Eng.,

Tongmyong Univ. of Information Technology)

*** 正會員, 清州大學校 컴퓨터情報工學科

(Dept. of Computer Info. & Eng., Chonju Univ.)

接受日字: 1998年2月3日, 수정완료일: 1998年8月7日

호의 해석이 쉽지 않기 때문에 근전신호를 제어원으로 사용하기 위해서는 근전신호인식의 신뢰도 및 정도를 높이는 것이 중요하다.

이를 위해서 신경회로망을 적용하여 근전신호의 기능을 분리하는 연구결과가 1990년대 초부터 나타나기 시작하였다. 그러나, 동적인 신호의 인식에서는 그 신호의 시간적 특성을 잘 반영하지 못하는 신경회로망 자체의 문제점으로 인해서 매우 제한적이고 인식률이 저조하여 실제로 적용하기에는 어렵다^{[1], [2]}.

본 논문에서는 이러한 특성을 갖는 근전신호를 효과적으로 인식하는 기법을 제안한다. 제안된 기법은 신경회로망과 최적화 알고리즘인 유전알고리즘을 결합하여 근전신호를 인식한다.

유전알고리즘 (Genetic Algorithms, GAs)은 생태계의 적자생존의 원리를 이용한 최적화 알고리즘^[3]으로, 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 국부최소점 (local minimum)으로 수렴하는 것을 효과적으로 피할 수 있게 해주어 학습시간 단축과 인식기의 안정화, 두 가지 문제점을 동시에 해결할 수 있는 장점이 있다.

또한 제안된 방법은 근전신호의 특징을 추출해내는 전처리 부분에서 절대 적분치, 영교차율과 같은 특징 벡터 외에도 히든마르코프 모델(Hidden Markov Model: HMM)을 적용하여 추출된 파라미터를 신경회로망의 입력패턴으로 사용함으로써 근전신호의 동적 특성을 나타낼 수 있도록 하였다.

실험은 20대 후반의 남성을 대상으로 추출한 근전신호를 대상으로 6가지의 기본운동을 설정하여 두 종류의 신경회로망에 대해서 네 가지 실험을 수행하였다.

본 논문은 2장에서 근전신호로부터 특징벡터를 추출해내는 전처리과정을, 3장에서 제안된 인식기법을 설명한다. 4장에서는 제안된 인식기법을 사용한 근전신호 인식기의 모의 실험결과를 보여주며, 이 결과를 기존의 인식기법과 비교·분석하고, 5장에서 본 연구에 대한 결론을 맺는다.

II. 전처리 과정

신호로부터 어떤 특징벡터를 추출하고 선택하느냐에 따라 패턴 인식의 성공 여부가 달려 있다. 패턴인식에서 특징벡터 추출 및 선택의 목표는 패턴표현의 차원 (dimension)을 줄이고 그 신호들의 분리도를 향상시키는데 있다. 분류기의 성능적 관점에서 보면, 차원의 축소는 인식율을 향상시킨다. 즉 불필요한 특징의 추가는 인식의 효율을 저하시키기 때문이다^[4].

본 논문에서 추출한 특징벡터는 크게 두 가지로 나눌 수 있는데 첫 번째 특징벡터는 연속된 근전신호에서 기본 운동영역을 구분하기 위한 것으로 영교차율, 절대 적분치가 여기에 속한다. 두 번째는 구분된 기본운동을 분류하기 위한 특징벡터로 자기상관법 (autocorrelation method)을 이용한 12차 선형예측계수 (Linear Predictive Coefficient, LPC)를 이용하였다.

그림 1에 특징 추출을 위한 전체 블록도가 나타나 있다. 각 채널을 통하여 입력되는 근전신호는 증폭된 후에 여과된 신호이다. 이 신호들로부터 설정한 기본 운동(표 1 참고) 영역을 검출하기 위하여 특징벡터로써 절대 적분치와 영교차율을 선택하였다. 구간 검출을 위해서 에너지값을 사용하는 경우도 있으나 절대 적분치에 비하여 계산에 소요되는 시간이 길기 때문에 본 연구에서는 계산이 용이하고 빠른 절대 적분치와 영교차율을 기본운동 구간 검출에 이용하였다. 기본운동 구간이 검출되면 그 구간에 대한 영교차율과 절대 적분치, 선형예측계수를 구하여 이를 제안한 근전신호 인식기의 특징벡터로써 사용하였다.

히든마르코프 모델은 음성인식분야 등에 활발하게 이용되고 있는 확률모델의 일종으로 다른 여러 알고리즘과 비교했을 때 저장해야 할 파라미터가 적고, 인식 속도가 빠르다는 장점을 가지고 있다^[5]. 또한, 히든마르코프 모델은 확률·통계적인 방법에 기초하여 패턴매칭을 시도하며, 특히 내재되어있는 마르코프 프로세스(Markov process)를 통하여 신호의 시간적인 변화의 모습을 모델링하는 구조를 가지고 있기 때문에 근전신호의 시간적 변화를 수용하고, 모델링하는데 적합하다고 할 수 있다.

본 연구에서는 수학적 정의가 가장 명확하고 계산량이 적은 이산형 히든마르코프 모델을 적용하여 근전신호의 해석을 시도했다.

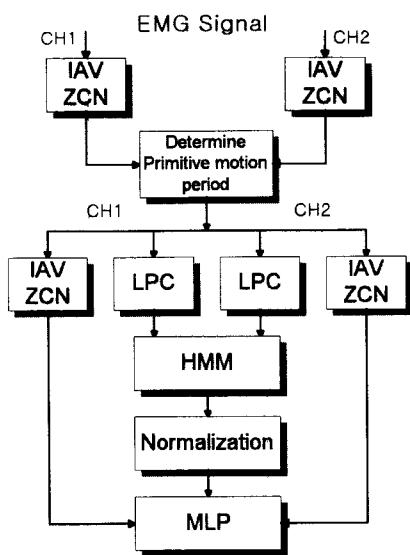


그림 1. 특징 추출 블록도

Fig. 1. Block diagram for feature extractions.

위의 그림 1에서 근전신호의 특징벡터를 추출하고 이를 신경회로망의 입력으로 사용하는 과정의 흐름도를 나타내었다. 여기서 히든마르코프 모델은 근전신호로부터 추출된 선형예측계수들을 이용하여 근전신호의 시변성을 반영하고자 사용되었다.

III. 신경회로망 및 유전알고리즘

1. 신경회로망과 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 큼 것이다. 이를 이용하면 별도의 평가함수를 만들지 않아도 적합도를 판정할 수 있다.

2. 제안한 인식기 구조

본 논문에서 제안한 인식기에서는 가장 일반적인 신경회로망 중의 하나인 오류역전파 신경회로망과 빠른 학습속도를 자랑하는 카운터 프로페게이션 네트워크를 사용하여 근전신호의 인식을 행하였다. 다음 그림 2에서 제안된 인식기법 중 오류역전파에 유전알고리즘을 적용하였을 때의 흐름도를 나타냈다.

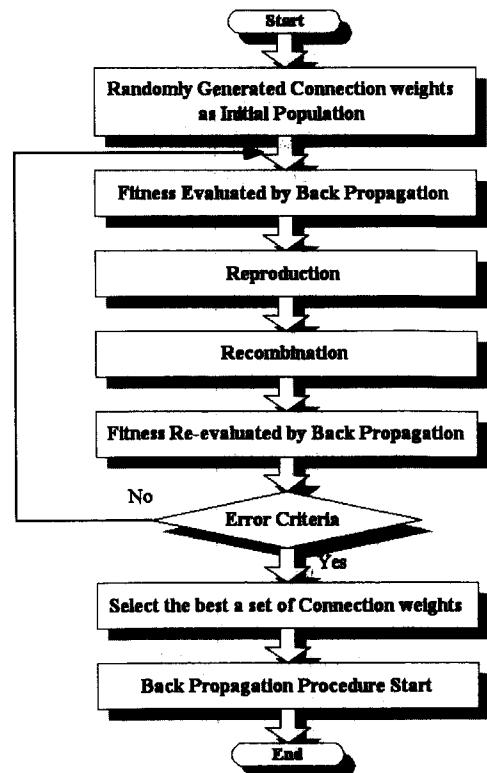


그림 2. 오류역전파에 유전알고리즘을 적용시켰을 때의 흐름도

Fig. 2. Flowchart of BP coupled with GA.

그림 2의 제안된 알고리즘은 다음과 같은 순서를 갖는다. 유전알고리즘의 모집단으로 신경회로망의 연결강도를 2진표현법을 사용하여 나타낸다. 그리고 교배, 돌연변이 등의 연산자를 거친 염색체를 네트워크를 이용해 평가한 후, 그 평가순위에 따라 재결합 및 재생산을 수행한다. 이때 평가함수로는 출력뉴런과 출력기대 패턴과의 오차의 제곱합을 사용하였다. 이런 과정을 오차허용기준을 만족시킬 때까지 반복한다.

그림 3은 카운터 프로퍼케이션에 유전알고리즘을 적용시켰을 때의 흐름도를 나타낸다. 이 기법은 그림 2에 나타낸 오류역전파에 유전알고리즘을 적용시킨 방법과 그 흐름은 같으나 중간 과정이 복잡함을 알 수 있는데, 이는 카운터 프로퍼케이션이 내재하고 있는 단점을 보완하기 위한 처리과정이 추가되었기 때문이다. 카운터 프로퍼케이션은, 코호넨 층에서 경쟁이 일어날 때, 같은 뉴런이 계속 승리할 수 있고, 입력층 연결강도들의 직교성 (Orthogonality)이 낮으면, 학습률이 떨어지는 단점이 있다. 이러한 문제점들을 해결하기 위해서는 두 번째 층의 뉴런수를 입력패턴의 수보다 많게 하거나, 입력층의 초기 연결강도로서 입력패턴의 프로토타입 (Prototype)을 사용하여 입력뉴런의 직교성을 확보하는 방법이 있다^[7].

본 논문에서 제안한 인식기법에서는 위의 두 가지 해결방법을 모두 적용하고, 출력층의 연결강도를 설정할 때에만 유전알고리즘을 사용한다. 프로토타입으로는 입력패턴의 전체 평균값을 사용하여 입력패턴과 연결강도사이에 직교성의 확보준다. 또한 카운터 프로퍼케이션은 그 특성상 두 번째 층과 출력층 사이에서는 학습이 이루어지지 않고 단순한 매핑만 실행되므로 빠른 실행 속도에 비해 인식률이 좋지 않다. 따라서 두 번째 층과 출력층 사이를 유전알고리즘으로 학습시키면 더 나은 결과를 얻을 수 있다.

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

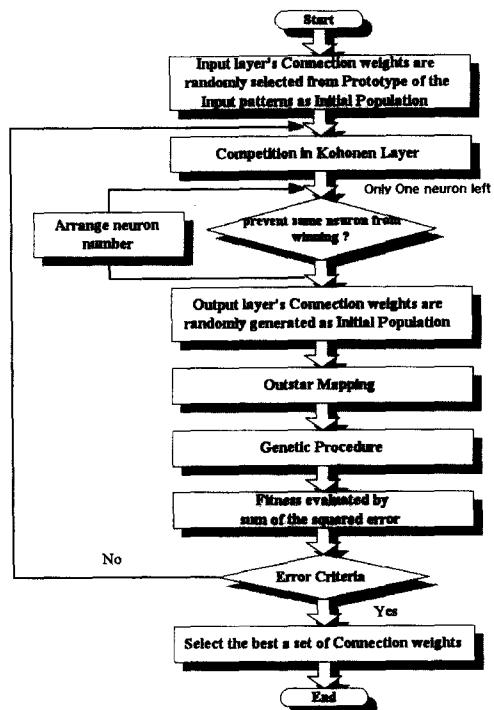


그림 3. 카운터 프로퍼케이션에 GA를 적용시켰을 때의 흐름도

Fig. 3. Flowchart of CPN coupled with GA.

IV. 실험 및 결과

1. 실험 데이터

인식에 사용한 근전신호는 20대 후반의 정상인을 대상으로 이두박근과 삼두박근의 중심부와 끝부분에 각각 2개씩의 전극을 부착하고, 그 중앙에 접지전극을 부착하여 얻어진 6가지의 기본운동에 대한 신호를 사용하였다. 이때, 이두박근을 채널1로, 삼두박근을 채널2로 정하고 실험을 행하였다.

표 1과 같이 6가지의 기본운동을 행하였고, 각각의 운동에 대해서 30회 반복하여 실험을 하였다. 30회의 반복 실험데이터 중 10세트의 특징 벡터군을 샘플로

해서 제안한 인식기의 훈련을 위한 입력패턴으로 사용하였다. 그림 4와 5는 근전신호의 한 예로서 각각 채널1과 채널2에서 나타난 굴곡운동의 파형을 나타내었다.

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

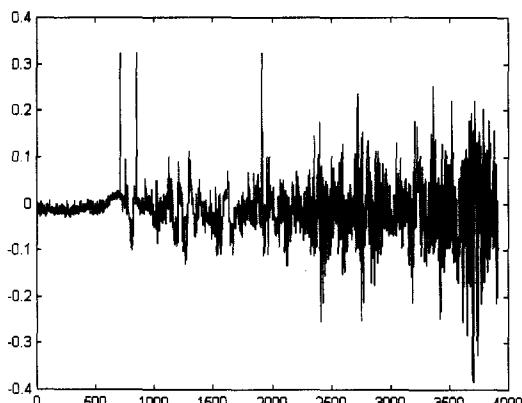


그림 4. 외전운동의 신호파형 (Ch1)

Fig. 4. A signal of WO movement in Ch1.

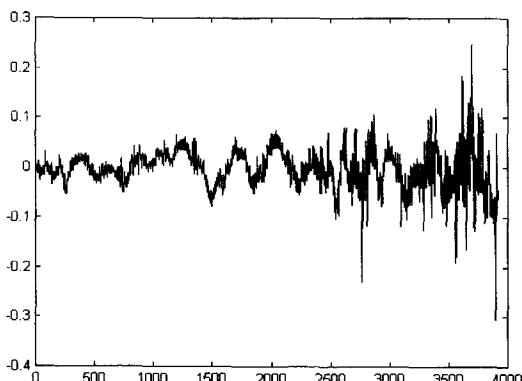


그림 5. 외전운동의 신호파형 (Ch2)

Fig. 5. A signal of WO movement in Ch2.

2. 실험 및 결과

실험은 제안한 인식기의 성능을 비교하기 위해서 다음과 같은 5종류의 실험을 행하였다.

실험 1 : 기존의 오류역전파 알고리즘만 사용한 인식기

실험 2 : 유전알고리즘과 오류역전파를 결합하여 사용한 인식기

실험 3 : 기존의 카운터 프로퍼게이션 알고리즘만 사용한 인식기

실험 4 : 유전알고리즘과 카운터 프로퍼게이션을 결합한 인식기

실험 5 : HMM만을 이용한 인식기

각 실험은 학습반복횟수를 1000번으로 동일하게 하여 실행하였으며 각 10회 실행후 평균 값을 계산하였다.

1) 오류역전파와 유전알고리즘을 결합한 인식기법

실험 1과 2에서는 제안된 인식기법의 효용성을 보이기 위해 가장 일반적인 신경회로망 알고리즘인 오류역전파 학습알고리즘과 이에 유전알고리즘을 적용한 합성인식기를 사용하여 근전신호의 인식을 수행하였다. 그림 6에 실험1과 실험 2의 기본운동별 인식률을 나타내었다.

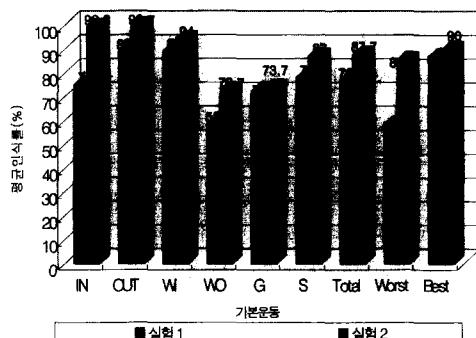


그림 6. 실험 1과 실험 2의 각 기본운동별 평균인식률

Fig. 6. Each primitive motion's average recognition rates of the experiment 1 and experiment 2.

실험 1과 실험2의 인식결과, 제안된 인식기법을 사용한 인식기가 모든 기본운동에 대해서 높은 인식률을 보이고, 전체적으로는 11%가량 인식률이 향상되었다. 실험 1에서 58.3% 정도의 낮은 인식률을 보이는 경우

는 학습시 국부최소점으로 수렴하여 학습에 실패한 것이다.

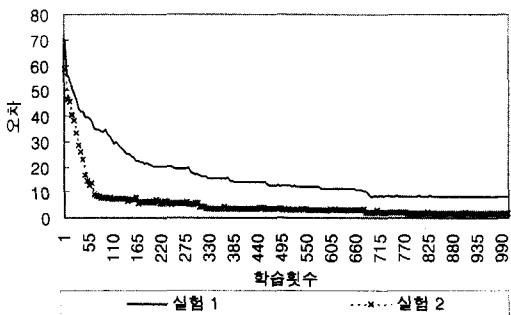


그림 7. 실험 1과 실험 2의 오차수렴 속도
Fig. 7. Error convergence speed of the experiment 1 and experiment 2.

위의 그림 7은 실험 1과 실험 2에서의 학습시 오차수렴속도이다. 실험 2의 오차수렴 곡선을 보면 100번 정도 학습하기 이전에 오차가 급격히 줄어들고 그후에는 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 국부최소점으로 수렴하는 것을 방지해주는 등의 역할을 해주기 때문에 빠른 학습이 가능하게된다.

2) 카운터프로퍼게이션과 유전알고리즘을 결합한 인식 기법

실험 3과 4는 카운터 프로퍼게이션 학습알고리즘을 사용하여 실험 1과 실험 2의 실험을 같은 조건에서 반복 실현한 것으로 유전알고리즘을 적용했을 때 나타나는 빠른 학습속도를 다시 한번 검증할 수 있었다. 그림 8은 실험 3과 실험 4의 각 기본운동별 평균인식률을 나타낸 것이다.

실험 3과 실험4의 인식결과, 제안된 인식기법을 사용한 인식기가 개수운동(S)을 제외한 모든 기본운동에서 높은 인식률을 보이고 전체적으로는 30%가량 인식률이 향상되었다.

그림 9는 실험 3과 실험 4의 학습 시 오차수렴 속도를 나타낸 것이다. 실험 4의 오차수렴속도가 실험 3 보다 빠른 것을 알 수 있다. 그림에서 실험 3은 115 번 정도 학습했을 때, 실험 4는 160번 정도 학습했을 때 오차가 급격하게 상승하는 것을 볼 수 있는데 이는

카운터 프로퍼게이션의 학습 알고리즘에서 두 번째 경쟁층에서 세 번째 출력층으로 이동하는 과정에서 연결강도가 재 설정되기 때문이며, 유전알고리즘을 적용한 실험 4는 이를 빠른 시간 내에 극복하고 수렴하는 것을 알 수 있다.

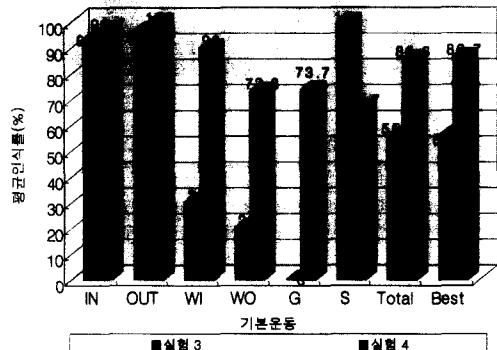


그림 8. 실험 3과 실험 4의 각 기본운동별 평균인식률
Fig. 8. Each primitive motion's average recognition rates of the experiment 3 and experiment 4.

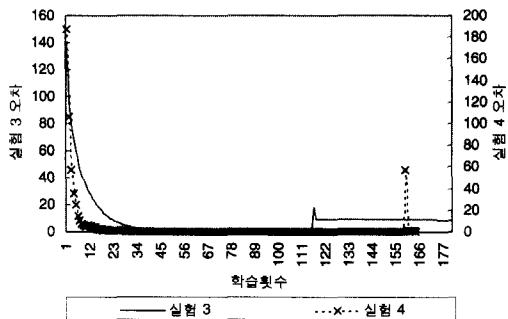


그림 9. 실험 3과 실험 4의 오차수렴 속도
Fig. 9. Error convergence speed of the experiment 3 and experiment 4.

3) HMM만을 이용한 인식기법

실험 5에서는 확률모델인 HMM만을 적용하여 실험한 후, 그 결과를 신경회로망을 이용한 다른 인식기와 비교였다. HMM을 적용한 알고리즘에서는 각 채널의 추출된 LPC 계수만을 특징 벡터로 사용하며 HMM 알고리즘만으로 학습 및 인식을 수행한다.

그림 10에는 HMM만을 이용하여 구한 총 인식률이 나타나 있다. 그림에 나타난 것처럼 기본 운동 WI의 경우가 90%로 인식률이 가장 높았으며, 기본운동 IN가 63.3%로 가장 낮았다. 실험 5의 인식 기법을 이용한 전체 인식률은 74.45%이다.

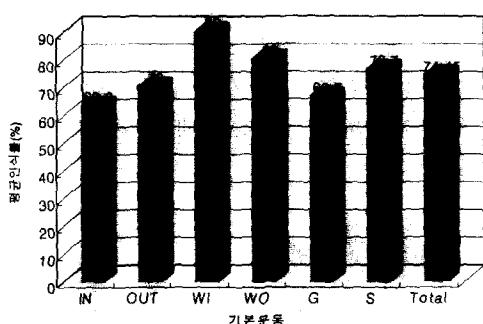


그림 10. 실험 5의 각 기본운동별 평균인식률
Fig. 10. Each primitive motion's average recognition rates of the experiment 5.

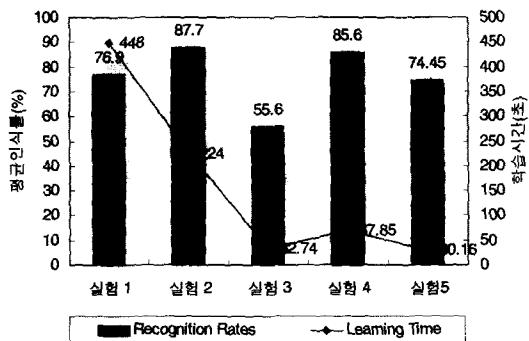


그림 11. 각 실험의 평균인식률과 학습속도
Fig. 11. Average recognition rates and learning time of each experiments.

그림 11에 각 실험별 평균인식률과 학습속도를 함께 나타냈다. 실험 결과에서 유전알고리즘을 적용한 제안된 인식기가 기존의 인식기보다 인식률은 최대 30% (실험 3과 실험 4 비교) 향상되었고, 학습속도는 최대 6배 가량 (실험 1과 실험 4 비교) 향상되었다.

HMM만을 적용한 실험 5의 경우, 학습속도는 30.16초로 가장 빨랐으나, 74.45%의 인식률을 나타내 55.6%의 학습속도를 보인 실험 3에 대해서만 우위를 나타냈다. 다른 실험에 대해서는 인식률 면에서 최대 13.3%의 차를 보였다.

실험 4가 실험 3보다 학습속도가 느린 것은 카운터 프로퍼게이션의 경쟁층과 출력층 사이에서 유전알고리즘이 최적의 연결강도를 탐색하는 과정에서 시간이 소요된 것이며 이 과정이 생략될 경우 향상된 인식률을 얻을 수 없으므로 불가피하다.

V. 결 론

본 논문에서는 근전신호의 인식을 위해 신경회로망과 유전알고리즘의 합성 인식기법을 제안하였다. 제안된 인식기는 신경회로망의 내재된 여러 단점들을 개선하는데 중점을 두었으며, 이를 위해 유전알고리즘을 신경회로망의 초기 연결강도를 결정하는데 사용하여 학습속도를 향상시키려 하였고, 근전신호의 전처리과정에 HMM을 적용하여 근전신호의 시변성을 반영하였다. 그리고 오류역전파와 카운터 프로퍼게이션의 두 종류의 학습알고리즘을 이용하여 네 가지의 실험을 통해 제안한 인식기의 효용성을 검증하였다.

실험 결과 기존의 학습알고리즘만을 사용한 네트워크보다 유전알고리즘을 적용해 초기 연결강도를 적절하게 조정한 네트워크가 카운터 프로퍼게이션에 적용했을 경우 학습속도는 최대 6배 더 빠르고, 오류역전파에 적용했을 경우 인식률이 최대 11% 정도 우수함을 보였다. 또한 실험 중 학습에 실패하는 경우는 없었으며, 인식률이 가장 좋은 경우와 좋지 않은 경우의 차가 3%로 적었다. 이는 제안된 인식기가 국부최소점으로 수렴하지 않기 때문이며, 따라서 안정적이고, 평균적으로 높은 인식률을 가진다.

본 연구는 6가지의 간단한 기본운동에 대한 근전신호를 대상으로 하였으나 인식대상으로 좀 더 복잡한 팔운동으로 확장할 필요성이 있고, 이때 추출된 근전신호의 특징을 효과적으로 반영할 수 있는 더욱 정교한 파라미터의 개발과 카운터 프로퍼게이션을 이용한 근전신호 인식기의 인식률을 좀더 향상시킬 수 있는 기법이 요구된다.

참 고 문 헌

- [1] Michael F.Kelly, Philip A. Parker, and Robert N.Scott, "The Application of Neural Networks to Myoelectric Signal Analysis: A Preliminary Study", IEEE Trans on Biomedical Engineering. vol. 37. No. 3, March 1990.
- [2] Barnard Hudgins and Philip A Parker, and Robert N.Scott, "A New Startegy for Multifunction Myoelectric Control", IEEE Trans on Biomedical Engineering. vol.40. No. 1. January 1993.

- [3] David E. Goldberg, "Genetic Algorithm in Search, Optimization, and Machine Learning", Addison-Wesley Publishing, 1989.
- [4] C. Lee and D.A.Landgrebe, "Feature Extraction Based on Decision Boundaries", IEEE Trans on Pattern Analysis and Machine Intelligence, vol. 15, No. 4, April 1993.
- [5] 권장우, "의수의 궤적제어를 위한 근전신호의 인식기법에 관한 연구", 인하대학교 박사학위청구 논문, 1996
- [6] 김정룡, "Backpropagation에 유전알고리즘의 응용", 전남대학교 석사학위 청구논문, 1994
- [7] James A. Freeman and David M. Skapura, *Neural Networks. Algorithms, Applications, and Programming Techniques*, Addison-Wesley Publishing Company, 1991.

[5] 권장우, "의수의 궤적제어를 위한 근전신호의 인

저자 소개

申 敏 圭(正會員)

1996. 2월 인하대학교 전자공학과 졸업 (공학사). 1998. 2월 인하대학교 전자공학과 대학원 졸업 (공학석사). 1998. 3월~현. 일본 Mikura Engineering사 근무

李 相 晟(正會員)

1983년 ~ 1987년: 인하대학교 전자공학과(공학사). 1987년 ~ 1989년: 인하대학교 대학원 전자공학과(공학석사). 1995년 ~ 현재 : 인하대학교 대학원 전자공학과 박사과정. 1989년 ~ 1994년 : 금성정밀(주) 연구소 선임연구원. 1995년 ~ 현재 : 삼성종합기술원 의료기기연구팀 선임연구원. 주관심 분야 : 생체신호처리, 재활공학 등

李 殷 實(正會員)

1983년 2월. 인하대학교 전자공학과 졸업. 1986년 2월. 인하대학교 전자공학과(공학석사). 1996년 3월~현재 : 인하대학교 전자공학과 박사과정

權 章 禹(正會員)

1990년 인하대학교 전자공학과 (공학사). 1992년 인하대학교 대학원 전자 공학과 (공학석사). 1996년 8월 인하대학교 대학원 전자 공학과 (공학박사). 1996년 10월 ~ 1998년 2월. 특허청 심사관. 1998년 3월 - 현재, 동명정보대학교 컴퓨터공학과 전임강사. 주관심 분야 : 인공지능, 생체 신호처리, 3차원 입체 디스플레이 시스템 등

張 永 健(正會員)

1991년 9월 ~ 1995년 2월 인하대학교 대학원 전자공학과 (공학박사). 1979년 12월 ~ 1983년 1월 국방과학연구소 연구원. 1983년 1월 ~ 1994년 2월 대우중공업(주) 중앙연구소 책임연구원. 1995년 3월 ~ 1996년 2월 고등기술연구원 생산기술연구실 책임연구원. 1996년 3월 ~ 현. 청주대학교 컴퓨터정보공학과 조교수. 주관심 분야 : 생체신호처리, 재활공학, 지능제어, 원격감시제어시스템 등

洪 勝 弘(正會員)

1975년 10월. 일본동경대학 대학원 의용생체정보공학 전공 (공학박사). 1978년 3월 ~ 현 : 인하대학교 전자공학과 교수. 1998년 1월 ~ 현 : (사)한국전기전자학회(IEEE Korea council) 회장