

연결 축소 회로망을 이용한 EMG 신호 기능 인식에 관한 연구

조정호* · 최윤호* · 왕문성** · 박상희*

=Abstract=

A Study on EMG Functional Recognition Using Reduced-Connection Network

Jeong-Ho Jo*, Yoon-Ho Choi*, Moon-Sung Wang**, Sang-Hui Park*

In this study, LPC cepstrum coefficients are used as feature vector extracted from AR model of EMG signal, and a reduced-connection network which has reduced connection between nodes is constructed to classify and recognize EMG functional classes.

The proposed network reduces learning time and improves system stability. Therefore it is shown that the proposed network is appropriate in recognizing function of EMG signal.

1. 서 론

인간이 근육을 수축시킬 때 발생하는 EMG (electromyogram) 신호를 추출하여 처리하는 EMG 신호처리의 분야는 크게 두 부분으로 나눌 수 있다. 첫째는 근전위에 대한 생리학적 연구에 바탕을 두어 근육 질환의 진단이나 근육의 피로도를 측정하여 임상 의학 및 스포츠 과학에 응용하는 분야이고, 둘째는 사지의 기능을 상실한 환자를 위한 재활 공학(rehabilitation engineering)적 측면에서 인간-기계시스템에 적용하는 보철제어(prosthetic control)를 응용 분야로 연구가 진행되고 있다¹⁾.

보철제어를 위한 EMG신호처리에서 생체에서 추출한 EMG신호는 인간의 의사에 따른 근육 수축의

결과로 발생하는 신호이므로, 인간의 의지를 반영하는 신호원으로 생각할 수 있다. 따라서 이 신호를 보철제어의 제어원으로 하여 인간의 의지대로 기계가 움직일 수 있게 하는 것이 인간-기계 시스템 구현의 궁극적인 목표라 할 수 있다.

보철제어를 위한 EMG신호처리에 관한 연구로는 Groupe등의 시계열 분석법을 이용한 기능 분리, Saridis등의 영교차율 및 모멘트를 이용한 기능 분리, Doerschuk등의 자기상관 합수와 상호상관 합수를 이용한 기능 분리, Scott등의 칼만 필터를 이용한 비례제어를 위한 기능분리, 최근에는 LPC 챕스트럼을 이용한 거리 측정(distance measure)을 통한 기능분리등이 있다²⁻⁵⁾. 이러한 연구는 상호 보완적으로 발전해 왔으나 분류 패턴의 종류가 많거나 분류 패턴들이 유사할 경우 오인식의 확률이 크기 때문에 다기능 보철제어에서는 많은 문제점을 가진다.

한편, 인간의 뇌는 어떠한 기계적 계산기보다도 탁월한 패턴 분류의 기능을 가지고 있으므로 이러한 기능을 모방한 신경 회로망은 Rosenblatt에 의해 등장한 “perceptron”을 시발로 하여 Hopfield에

<접수 : 1990년 11월 27일 >

* 연세대학교 전기공학과

* Dept. of Electrical Engineering, Yonsei University

** 동양 공업 전문대학 전기공학과

** Dept. of Electrical Engineering, Dongyang Junior Technical College*

의한 “Hopfield net”로 각광 받기 시작하였다⁶⁾. 그리고 “perceptron”的 패턴분류 능력의 한계를 극복하게 한 NLP(multi-layer perceptron)와 지도 학습 규칙적인 BP(back propagation) 알고리듬이 PDP그룹에 의해 개발·개선되어 왔다⁷⁾. 신경회로망의 적용은 특히 음성 인식의 분야에서 활발히 진행되어 비교적 좋은 결과를 얻어왔으나, 처리 데 이타가 광대함으로 인하여 현재의 Von Neuman형 컴퓨터에서 시뮬레이션을 위한 시스템의 수행시간 등이 문제가 되어 왔다. 그래서 Sakoe등에 의해 신경 회로망을 음성인식에 이용할 때 회로망의 연결을 줄이려는 시도가 있었다⁸⁾.

따라서, 본 연구에서는 여러가지의 팔 운동에 대하여 EMG신호를 분류할 경우에 오인식율의 감소를 위해, 학습기능을 가지는 신경 회로망을 팔 운동에 대한 EMG신호의 분류에 적용함으로써 팔의 기능을 정확하게 분리하여 이에 대응되는 동작을 판별하고자 한다. 이 때 인식 수행 시간을 감소시키기 위하여 가중값의 연결을 줄인 연결 축소 회로망(reduced-connection network)을 이용한다.

2. EMG신호의 전처리 과정

2.1 EMG 신호의 모델링

인간이 수의수축(voluntary contraction)을 할 때, 뇌의 운동 피질(motor cortex)에서 신경 임펄스 열(nerve impulse train)이 발생하여 척수를 통해 연속적으로 근육에 전달 됨으로써 수축의 정도에 따라 필요한 수의 운동단위(motor unit : MU)들을 자극하게 된다. 이때 자극에 관련되는 근섬유(muscle fiber)의 표면에는 Na^+ K^+ 등의 이온 전위차에 의한 탈분극과 재분극에 의해 운동단위 활동전위(motor unit action potential : MUAP)가 발생되며, 운동에 기여하는 많은 다른 근섬유의 MUAP들의 중첩(superposition)의 결과로서 EMG신호가 구성된다^{9,10)}.

일반적으로 EMG신호는 비정상적(nonstationary) 신호이지만, 단시간 구간(100ms내외)에서는 통계적 성질이 크게 변하지 않는 정상적(stationary) 신호라 할 수 있다. 선형 모델중 자기회귀 모델(autoregressive model : AR model)을 이용해서

EMG신호를 모델링 하면, EMG신호의 샘플 $x[n]$ 은 식(1)과 같이 과거의 샘플 $x[n-k]$ 에 독립적인 오차신호 $e[n]$ 을 합한 선형 조합으로 나타난다¹¹⁾.

$$x[n] = -\sum_{k=1}^p a[k] \cdot x[n-k] + e[n] \quad (1)$$

여기서 $x[n]$: EMG 신호의 샘플

$a[k]$: AR 계수

$e[n]$: 백색 잡음 성질의 오차신호

p : 모델의 차수

식(1)에서 EMG신호 $x[n]$ 을 p 개의 과거 샘플로 추정하면 식(2)와 같이 된다.

$$x[n] = -\sum_{k=1}^p a[k] \cdot x[n-k] \quad (2)$$

이때 실제의 EMG신호 $x[n]$ 과 예측값 $x[n]$ 사이의 오차 $e[n]$ 은 식(3)과 같다.

$$\begin{aligned} e[n] &= x[n] - x[n] \\ &= x[n] + \sum_{k=1}^p a[k] \cdot x[n-k] \end{aligned} \quad (3)$$

따라서 오차신호 $e[n]$ 이 충분히 작거나 0에 가까울 때, 예측신호 $x[n]$ 은 원신호 $x[n]$ 과 거의 동일화 될 수 있으며, 결과적으로 식(3)에서 특정시간의 신호값을 추정하려면 특정 p 개의 원신호 $x[n-k]$ 와 예측계수 $a[k]$ 를 각각 보유함으로써 EMG 신호의 정보를 압축하여 실시간 처리에 이용 할 수 있다.

2.2 LPC 켭스트럼 계수의 추정

식(1)의 AR 모델에서, 오차 $e[n]$ 의 EMG신호 $x[n]$ 간의 전달함수(transfer function)는 식(4)와 같이 주어진다.

$$H(z) = \frac{X(z)}{E(z)} = \frac{1}{1 + \sum_{k=1}^p a[k] \cdot z^{-1}} = \frac{1}{A(z)} \quad (4)$$

여기서 $E(z)$ 와 $X(z)$ 는 각각 $e[n]$ 과 $x[n]$ 의 Z변환이다.

$A(z)$ 는 단위원 내에 모든 근을 가지고, $\ln[A(z^{-1})]$ 는 단위원 내에서 해석적이므로 Laurent 전개가 가능해 진다¹²⁾. 따라서 켭스트럼 계수 $c[k]$ 를 유도하면 식(5)과 같이 주어진다.

$$c[n] = \frac{1}{n} \sum_{k=1}^p (n-k) \cdot a[k] \cdot c[n-k] \quad n > 0 \quad (5)$$

단, $c[0] = \ln[E_{min}]$ 이다.

위에서 행한 EMG신호의 AR 모델링을 통해서 구한 LPC 챕스트럼 계수의 타당성을 살펴보면, 실제 EMG신호의 고속 푸리에 변환(fast fourier transform : FFT)을 통해 구간 파워 스펙트럼과 LPC 챕스트럼 계수를 이용해 구간 파워 스펙트럼이 유사한 특성을 가지고 있음을 확인할 수 있다^[13]). 따라서 LPC 챕스트럼은 EMG신호의 정보를 충실히 반영하고 있음을 알 수 있다. 따라서 백색 잡음 신호가 모델의 입력이고 EMG신호는 대역폭이 제한된 백색 잡음 신호로 볼 수 있으므로 AR 모델링은 타당하다고 볼 수 있다.

3. 연결 축소 회로망

3·1 연결 축소 회로망

전통적인 다층 인식자(multi-layer perceptron : MLP)는 모든 입력에 대해 온닉층의 모든 노드들이 구조적으로 완전히 연결되어 동작하도록 구성된다. 그러나 실제 신경구조에서 모든 뉴런들이 모두 연결되어 있는 것은 아니고 서로 연관이 있는 뉴런들끼리만 상호 연결되어 동작하므로, 본 연구에서는 MLP에서 연결의 수를 감소한 연결 축소 회로망(reduced-connection network)을 사용한다.

회로망에 EMG신호를 적용할 때, 활성함수로는 식(6)과 같은 sigmoid함수를 사용하였다.

$$f(\text{net}) = 1 / \{\exp[-S(\text{net} - \theta)]\} \quad (6)$$

식(6)에서의 $\text{net} - \infty$ 에서 ∞ 까지 임의 값을 가질 수 있기 때문에, sigmoid함수를 사용해서 net 에 따른 출력값을 항상 0과 1사이에 있도록 할 수 있다. 또한 net 에 따른 출력의 변화율을 살펴보면 net 가 θ 인 구근에서 가장 급격한 기울기를 가지고 θ 를 중심으로 멀리 떨어질수록 기울기가 완만해져 결국 변화가 거의 없게 된다. 따라서 net 가 θ 와 크기가 거의 같은 소신호일 경우 높은 이득을 제공하고, net 와 θ 의 크기 차가 큰 대신호일 경우 적은 이득을 제공함으로써 0인 1로 출력값이 수렴하게 하는 자동 이득 조절장치(automatic gain control)로서의 기능을 제공한다.

한편, 전처리 단계에서는 해닝 윈도우(Hanning

window)를 사용하여 데이터를 적당한 시간 프레임으로 나누어서 AR모델의 입력으로 사용한다. 따라서 입력 데이터간의 시간적 연관이 없는 프레임의 특징 벡터는 회로망의 입력시 어떠한 연결도 가지지 않게 된다. 그러므로 실제 하드웨어 구현이 줄어든 연결로 인해 보다 간명한 구조로 구현이 가능할 것이다. 그림1은 연결 축소 회로망이 구조를 나타낸다.

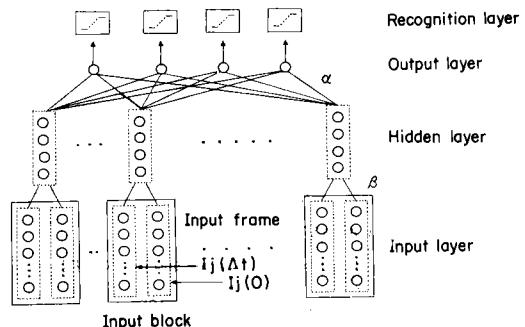


그림 1 연결 축소 회로망의 구조
Fig. 1 Structure of reduced-connection networek

그림 1에서 각 입력 블록내의 입력 프레임들은 시간 지역 특성을 나타내는데, $I_i(\Delta t)$ 와 $I_j(0)$ 사이는 전처리 단계시 윈도우를 Δt 만큼 오버랩(overlap)시킴을 의미한다. 즉, 각 입력 데이터 블록에서 $I_i(0)$, $I_i(\Delta t)$, ..., $I_i(0)$ 간에는 전혀 오버랩이 없는 특징 벡터이고, 그림1에서는 각 입력 데일당 프레임이 두개이므로 50[%]로 오버랩시켰음을 의미한다. 결국 입력층의 i번째 블록에서 온닉층 j번째 프레임으로의 가중값 벡터는 i와 j가 같을 때만 연결되고, 그렇지 않을 때는 아무런 연결도 제공하지 않고 별개의 연산을 수행한다. 인식층의 각 노드는, 동작 인식시 출력층의 노드값이 0에서 1사이의 값을 가지지만 결코 0이나 1로 완전 수

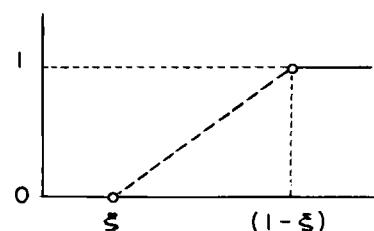


그림 2 인식층의 문턱함수
Fig. 2 Threshold function in the recognition layer

럼하지는 않으므로, 최종 결과를 0이나 1로 강제 할당하는 역할을 수행한다. 즉 생물학적 뉴런의 일반적 문턱값의 특성을 인식층에서는 문턱함수(threshold function)를 이용해서 모방한다.

그림 2에서 ϵ 는 정확한 인식의 판별을 위한 구간을 정의하며 ϵ 와 $1-\epsilon$ 사이의 구간에서는 일종의 'suspended'상태로 간주된다. 즉 1이 기대되는 출력 노드가 $1-\epsilon$ 사이에 있고, 0이 기대되는 출력 노드가 ϵ 사이에 있어야 인식 노드에서는 입력 운동이 학습된 운동중의 하나로 기능을 분류해 낸다. 만일, 출력 노드의 값들이 ϵ 이하와 $(1-\epsilon)$ 이상사이에 있지 않으면 'suspended'상태나 오인식을하게 된다.

EMG신호의 기능 분류시 일반적 거리측정(distance measure) 방식에서는 단지 기준 패턴(reference pattern)과 시험 패턴(test pattern)들 간의 비교를 통하여 가장 짧은 거리차의 경우를 인식된 운동으로 판단한다. 하지만 시험 패턴을 만드는 EMG 데이터를 정확히 측정하지 못한 경우, 또는 각 시험 패턴간에 유사한 특정 벡터를 가져서 거의 거리차가 유사 할 경우 오인식의 확률이 높아지므로 실제 보철용 팔에 적용할 때 오동작의 위험성이 우려된다. 따라서 신경 회로망의 인식층에 문턱함수를 도입하여 'suspended'상태를 제공하여 관계되는 조건이 하나라도 만족되지 않으면 아무런 결과동작도 수행하지 않도록 함으로써 오동작의 위험성을 줄일 수 있게 된다.

3·3 학습 알고리즘

본 연구에서는 MLP의 전형적인 지도 학습 알고리즘인 back propagation(BP) 알고리즘을 연결 축소 회로망에 적용하였다. BP 알고리즘은 고전적인 델타 규칙(delta rule)을 일반화하여 학습될 모든 입출력 벡터쌍에 대해 전향 경로(forward path)를 통해 실제 출력을 생성하고, 시스템의 초기화시 선정된 목표벡터(desired vector)와 실제 출력벡터를 비교해서 시스템의 평균 제곱 오차를 최소화 시키도록 후향 경로(reverse path)를 통해 가중값 벡터를 점진적으로 최적화 시켜나가는 알고리즘이다.

4. 실험 및 결과 고찰

4·1 실험장치와 실험방법

본 실험에서는 2인의 피검자를 대상으로 기능 분류를 하였고, 신호는 1KHz로 샘플링 하였다. Ag-AgCl표면 전극은 모두 3개를 사용하였는데 전극의 위치는 이두박근 및 삼두박근에 각각 1개씩 부착하였고, 나머지는 상완근과 원회내근 사이의 불록 튀어나온 뼈부위에 부착하여 접지 전극으로 사용했다. 피검자는 약1초의 시간동안 1회의 단일 운동을 실시하였고 운동간에는 충분한 시간을 두어 피로의 영향을 줄이고자 하였다.

인간의 팔에서 손목관절을 제외한 상반관절과 팔꿈치관절을 이용하여 운동을 4개의 기계적 자유도(degree of freedom)로 해석 가능한데, 본 연구에서는 팔꿈치관절에 의한 4가지 운동에 대한 인식 실험을 수행하였다. 이때 인식 실험에 사용된 4가지 운동은 굽곡(flexion movement), 신전 운동(extension movement), 회내 운동(pronation movement) 및 회외 운동(supination movement) 등이다.

4·2 기능 분류 및 인식 실험

연결 축소 회로망의 학습을 위해 사용하는 학습 패턴은 2인의 피검자의 각 운동당 10개씩의 단일 운동에 대한 데이터의 LPC 캡스트럼 계수에 대해 평균을 취해 생성하였으며, EMG데이터를 256 [msec], 128[msec] 그리고 64[msec]시간 길이로 해닝 윈도우를 사용하여 윈도우 Ying을 하고 50[%] 만큼 오버랩시켜 각 단위 시간 프레임당 특징 벡터를 만들었다. 또한 4가지 운동의 기능 정보를 가장 잘 나타내는 모델의 차수를 선택하기 위해 LPC의 차수를 4에서 15차 까지 적당히 변화 시켜 가며 실험해 보았다.

패턴 분류를 위한 학습실험에서 은닉층의 각 은닉 프레임의 노드수는 4개로 고정하여 실험하였는데, 그 이유는 노드의 수를 2,4 및 8로 실험한 결과 올바른 기능 분류를 한 인식율이 은닉 노드가 4일때 가장 좋은 결과를 나타내었기 때문이다. 표1은 은닉 노드의 갯수가 2, 4 및 8일 때 인식층의 문턱함수의 인식 구간을 =0.1, 0.2 및 0.25로 각각 설정 했수에 따른 시스템의 오차곡선을 나타내

는데 학습 횟수에 따라 오차 곡선이 계단적으로 감소하여 시스템의 학습시에 불안정한 상태임을 보여주고 있다.

표 1에서 문턱함수의 제약이 엄격할수록, 즉 인식구간의 폭이 작을수록 인식율이 낮아지지만 그 만큼 오인식의 확률은 작아지게 되고 회로망은 안

표 1 은닉도 노드의 수가 2, 4 및 8일때의 인식율 [%]비교

(모델의 차수가 14이고, 시간 프레임이 해닝 윈도우 64[msec] 일때)

Table 1 Recognition rate for 2, 4 and 8 hidden nodes

number of Nodes in a hidden frame	recognition interval of threshold func- tions in recognition layer			
	0.9/0.1	0.8/0.2	0.75/0.25	largest output
2	67.5	90	97.5	100
4	84.1	90.3	96	100
8	72.5	85	90	100

정되게 된다. 또 출력 노드의 값을 비교하여 가장 큰값의 동작을 인식 동작으로 취하는 방법(표에서 largest output)은 100[%]의 인식율을 나타냈지만 인식 방법에서 거리측정의 최단거리를 인식 동작으로 하는 방법과 동일해서 각각의 입력 데이터는 반드시 학습 데이터중 하나에 사상(mapping)되기 때문에 오인식의 확률이 높아서 적절하지 못한 방법으로 생각된다.

연결 축소 회로망의 학습시 가중값과 문턱값 (offset)의 학습율 η 는 동일하게 0.5에서 0.7사이의 값을 취했으며, 모멘텀 항 λ 는 0.8로 고정하였다. 그 이유는 학습율은 클수록 빠른 수렴 속도를 가지지만 과할 경우 시스템의 오차 곡선이 크게 진동하므로 수렴상태에 도달하지 못하기 때문이다.

학습을 통한 인식 실험에서 전처리 단계의 모델 차수가 증가함에 따라 인식율은 높게 나타났지만, 그 증가폭은 줄어 들었다. 4차에서 15차까지 적

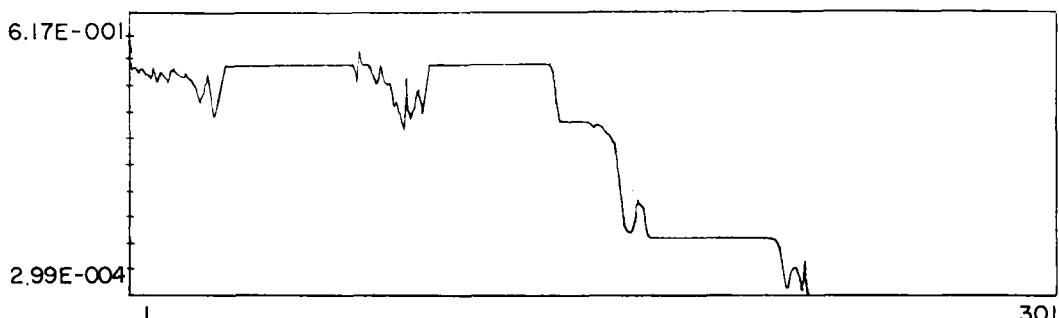


그림 3 은닉 노드가 8일때의 오차 곡선

Fig. 3 Error curve for 8 hidden nodes

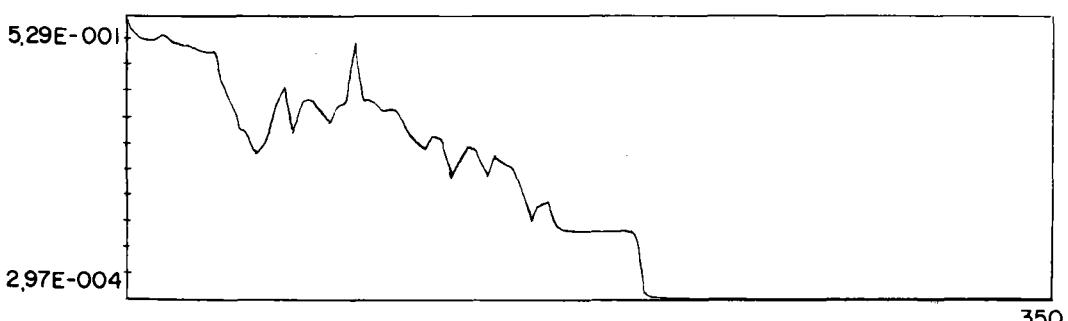


그림 4 MLP의 오차 곡선

Fig. 4 Error curve of MLP

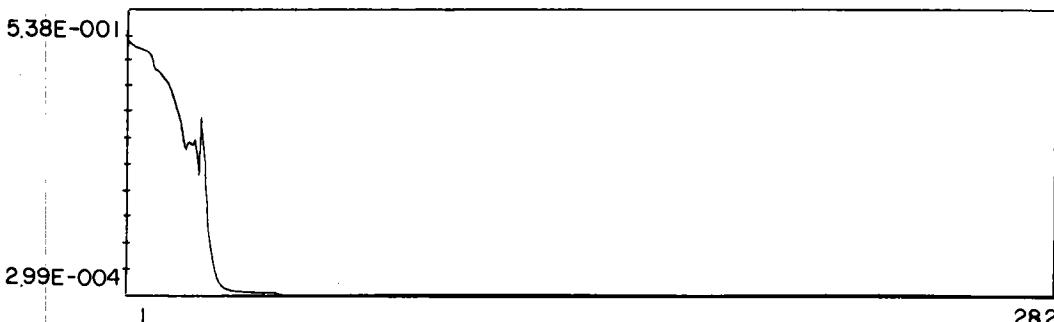


그림 5 14차일 때의 오차 곡선

Fig. 5 Error curve for model order 14

282

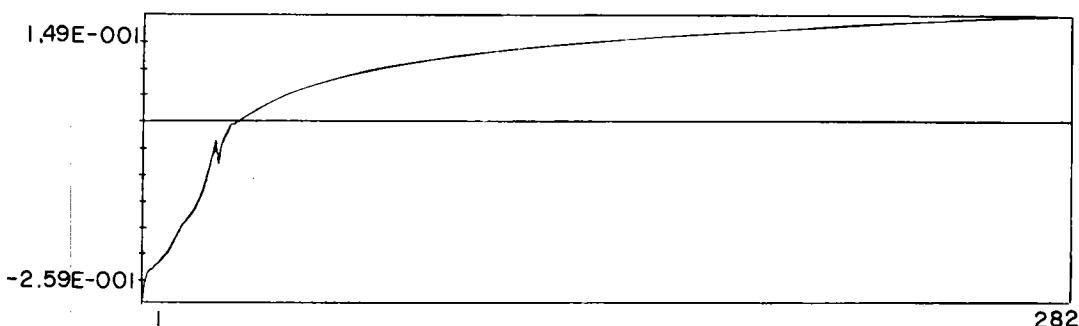


그림 6 14차일 때 학습에 따라 수렴되는 가중값
Fig. 6 Weight trajectory according to learning

282

당히 차수를 변화시키면서 실험한 결과 14차일 때 시스템의 안정성과 인식율이 가장 좋은 것으로 나타났다. 또한 전처리단의 윈도우 크기가 256[msec], 128[msec] 및 64[msec]로 변함에 따라 인식율은 64[msec]일 때 가장 좋은 결과를 보였다. 그 이유는 EMG 신호의 비정상성으로 인해서 윈도우의 크기가 가장 작은 64[msec]의 시간 프레임에서 AR 모델의 원신호의 정보를 가장 잘 예측하기 때문이라고 생각된다.

MLP와 연결 축소 회로망과의 효율성을 비교하기 위해 수행한 간단한 실험에서 MLP의 은닉 노드의 갯수는 연결 축소 회로망의 은닉노드의 갯수가 4일때와 동일한 조건하에서는 인식율이 거의 유사한 결과를 나타냈지만 오차곡선은 상당히 진동의 폭이 크게 나타났다. 그 이유는 연결 축소 회로망의 전체 은닉 노드의 갯수와 비교되어진 MLP의 은닉 노드의 수가 충분히 입력의 정보를 얻지 못하여 발생한 것이라 생각된다. 그림4는 비교된

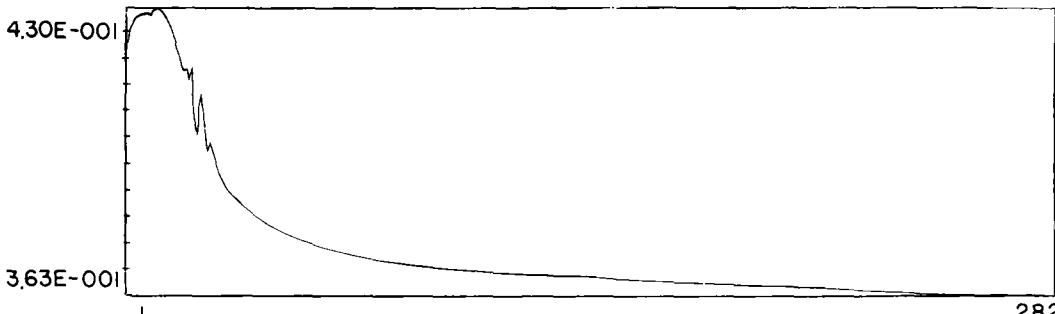
MLP의 진동하는 오차 곡선을 나타낸다.

실험에서 모델 차수가 14차이고 윈도우가 64[msec]일 때 목표 출력이 1인 노드에서 실제 출력은 0.9928, 0.9897, 0.9944 및 0.9888로 각각 접근하였다. 이때의 시스템 오차는 0.0003까지 감소되었다. 그림5의 오차 곡선에서 기존의 MLP보다 수렴 속도가 줄어든 연결로 인해 훨씬 빠르고, 곡선이 지수함수적으로 안정되게 줄어듬을 알 수 있다.

또한 다음의 그림6은 3번째 출력 노드에서 3번째 은닉 프레임의 3번째 은닉 노드의 가중값을 나타낸다. 학습의 규칙은 gradient descent 원리로 행해지므로 학습의 진행에 따라 안정되게 시스템의 오차가 줄어들도록 가중값이 일정한 크기로 수렴하고 있음을 보여준다.

그림7은 은닉 프레임의 3번째 은닉 노드의 옵셋으로 학습이 진행됨에 따라 일정 수준으로 완만하게 수렴하고 있음을 보여 준다.

그림 5의 오차 곡선과 가중값과 옵셋이 수렴되



282

그림 7 14차일 때 학습에 따라 수렴되는 옵셋

Fig. 7 Offset trajectory according to learning

표 2 인식 구간과 차수에 따른 인식율과 오인식율의 비교

단위 : 인식율[%]/오인식율[%]

Table 2 Recognition rates and error recognition rates according to recognition intervals and orders of model

Recognition interval of threshold function	Order of AR model					
	4	8	12	13	14	15
0.9/0.1	55/0	80.7/0	80.7/0	84.1/0	84.1/0	80/0
0.8/0.2	64.7/1.25	90.3/0	90.3/0	90.3/0	90.3/0	92.8/0
0.75/0.25	73.2/1.25	91.6/0	91.6/0	90.3/0	96/0	94.1/0
largest output	95/5	100/0	100/0	100/0	100/0	100/0

는 그림 6 그리고 7을 학습의 횟수에 따라 비교해 보면, 오차 곡선의 초기 학습에서는 다소의 진동이 발생하며 그 진동이 발생하는 지점에서 가중값과 옵셋 역시 진동을 할 수 있다. 또한 오차 곡선이 시스템의 오차가 전체적으로 줄어드는 방향을 발견하고 지수 함수적으로 안정하게 감소함에 따라 가중값과 옵셋 역시 완만한 곡선을 그리면서 임의의 값으로 수렴해 감을 알 수 있다.

다음의 표2는 윈도우를 64[msec]로 하고 차수의 변화에 따른 2인의 피검자에 대해서 인식 실험시 추가되는 인식층의 문턱함수에서 = 0.1, 0.2 및 0.25로 하여 인식구간을 0.9/0.1, 0.8/0.2 및 0.75/0.25로 하고, 그리고 출력노드의 가장 큰 값을 인식 기능으로 하는 방법(largest output)에 대한 인식율의 결과를 나타낸다.

위의 표2에서 ‘suspended’ 상태는 (100 - 인식율 - 오인식율)[%]로 표현되는 반면, largest output은 인식율이 100[%] 정도로 나타났지만 인식층에 문턱함수를 두지 않고 출력노드의 가장 큰 값을 인식 기능으로 판별하는, 거리 측정과 유사한 방법

이다. 따라서 4차의 경우에서처럼 오인식의 가능성은 인식구간을 둔 형태보다 훨씬 높음은 당연하다 하겠다.

그러면 인식층의 인식구간 사용의 타당성을 보기 위해, 극단적인 경우이지만 앞의 4가지 운동을 이용해 회로망을 학습시킨 후 학습파는 무관한 어깨틀안, 밖으로 움직이는 운동과 어깨를 앞, 뒤로 움직이는 운동을 회로망에 입력하였을 때 인식 결과를 살펴보면 다음과 같다.

표 3에서 보면 largest output방법은 반드시 학습 패턴 중의 하나에 사상(mappong)되기 때문에, 이 실험에서 인식되는 모든 동작 기능은 오동작이 되

표 3 학습된 운동이외의 운동에 대한 오인식율

Table 3 Error recognition rates for unlearned movements

Recognition interval of threshold function	Error recognition rate	Suspended condition rate[%]
0.9/0.1	10	90
0.8/0.2	15	85
0.75/0.25	20	80
largest output	100	0

고 많다. 따라서 앞의 실험들과 비교해서 보면, 문턱함수에 인식 구간과 같은 제약 조건을 임격하게 둘수록 표면적인 인식율은 낮아지지만 오인식의 가능성은 현저히 줄어듬을 알 수 있다. 따라서 문턱 함수의 인식 구간은 어떻게 설정하느냐에 따라 오동작의 위험성을 감수하고 인식율을 높이거나, 아니면 인식율은 다소 낮아지더라도 오동작의 위험을 줄일 수 있다.

5. 결 론

AR모델을 통해서 구간 LPC 켐스트럼 계수를 신호의 특징 정보로 하고 각종의 노드간의 연결을 줄인 연결 축소 회로망에 적용하여 각 운동기능의 인식 실험을 수행한 결과는 다음과 같다.

1. 표면 전극을 통해 추출한 EMG신호를 AR모델링하여 LPC 켐스트럼 계수를 특징 매개변수로 선택함은 원신호를 충분히 반영하는 것으로 나타났다.
2. 연결 축소 회로망은 학습의 수렴 속도와 수행 시간면에서 일반적인 MLP에 비해 상당히 절감되었다.
3. 2인의 피검자를 대상으로 인식 실험을 한 결과, 전처리단의 모델 차수가 14차일때가 시스템의 안정성과 인식율을 고려할때 가장 좋은 결과를 보였다.
4. 회로망의 인식층에 적용한 문턱함수에서는 인식 구간의 선택은 인식율과 오인식율간에 trade off 관계를 초래했다.
이상의 결과를 바탕으로 인식구간과 ‘suspended’ 구간의 적절한 선택으로 운동 기능의 인식율과 오인식율간의 관계를 고려하면 보철제어 및 인간-기계 시스템 제어에 응용될 수 있으리라 기대한다.

참 고 문 헌

- 1) IEEE EMB Society, “Rehabilitation engineering”, IEEE EMB, Vol11, No.4, 1982.
- 2) D. Graupe et al, “A microprocessor system for multifunctional control of upper limb prosthesis via myoelectric signal identification”, IEEE Trans., Auto. Control, Vol AC-23, pp 538–544, 1978.
- 3) G. N. Saridis et al, “EMG pattern analysis and classification for prosthesis arm”, IEEE Trans., BME, Vol 29, pp. 403–409, 1982.
- 4) P. C. Doerschuk et el, “Upper extremity limb function discrimination using EMG signal analysis”, IEEE Trans., BME, Vol 30, pp.18–38, 1983.
- 5) R. N. Scott et al, “Signal processing for proportion myoelectric control”, IEEE Trans., BME, Vol 31, pp. 207–211, 1984.
- 6) R. P. Lippman, “An introduction to computing with neural nets”, IEEE ASSP Magazine, Vol 3., No4, pp 4–22, 1987.
- 7) D. E. Rumelhart, J. L. McClelland and the PDP Groups : Parallel distributed processing, MIT Press, Vol 1, 1986.
- 8) H. Sakoe et al, “Speaker-independent word recognition using dynamic programming neural networks”, ICASSP, pp.29–32, 1989.
- 9) C. J. DeLuca, “Physiology and mathematics of myoelectric signals”, IEEE Trans. BME, Vol 26, No. 6, 1979.
- 10) J.V. Basmajian and C. J. DeLuca : Muscles alive, Williams & Wilkins Co, 1985.