

신경 회로망을 이용한 EMG신호 기능 인식에 관한 연구

조 정 호, 최 윤 호, 림 문 성, 박 상 희
연세대학교 전기공학과

A Study on EMG functional Recognition Using Neural Network

Jeong-Ho Jo, Yoon-Ho Choi, Moon-Sung Wang, Sang-Hui Park
Dept. of Electrical Engineering, Yonsei University

ABSTRACT

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 the function of EMG signal.

1. 서 론

EMG(electromyogram)신호처리 연구는 근전위에 대한 생리학적 연구에 바탕을 두어 근육의 피로도나 근육질량의 유무를 판단하여 임상 의학 및 스포츠 과학에 응용하는 분야와 사지의 기능을 상실한 환자를 위한 재활공학(rehabilitation engineering)¹⁾적 측면에서 인간-기계(man-machine) 시스템에 적용하는 보철제어(prosthetic control)의 응용분야로 크게 나눌 수 있는데, 보철제어를 위한 EMG신호처리에서 생체에서 추출한 EMG신호는 인간의 의사에 따른 근육수축의 결과로 발생하는 신호이므로, 인간의 의지를 반영하는 신호원으로 생각할 수 있다. 따라서 이 신호를 보철제어의 제어원으로 하여 인간의 의지대로 기계가 움직일 수 있게 함이 인간-기계 시스템의 궁극적인 목표라 할 수 있다.

보철제어를 위한 EMG신호처리에 관한 연구로는 Graupe²⁾등의 시계열 분석법을 이용한 기능 분리, Saridis³⁾등의 영교차율 및 모멘트를 이용한 기능 분리, Doerschuk⁴⁾ 자기상관 함수와 상호상관 함수를 이용한 기능 분리, Scott⁵⁾등의 갑판 필러를 이용한 비례제어를 위한 기능분리, 최근에는 LPC 캡스트럼을 이용한 거리측정(distance measure)을 통한 기능분리 등이 있다.

인간의 뇌는 탁월한 패턴분류의 기능을 가지고 있으므로 그러한 기능을 모방한 신경회로망(neural network)은 Rosenblatt에 의한 "perceptron"의 등장을 시발로 하여 Hopfield에 의한 "Hopfield net"⁶⁾으로 각광 받기 시작하였다. 그리고 "perceptron"의 패턴분류 능력의 한계를 극복하게한 MLP(multi-layer perceptron)와 지도 학습 규칙인 BPA(back propagation algorithm)가 PDP그룹에 의해 개발, 개선 되어 왔다.⁷⁾

따라서 본 연구에서는 지금까지의 확률적 처리에 의한 거리측정에서의 여러 한계를 극복하고, 신경회로망에서의 수행 시간의 문제를 감소하기 위해서 가장값의 연결을 줄인 연결 축소 회로망(reduced-connection network)을 이용하여 EMG신호의 기능분리 및 인식에 적용하려 한다.

2. EMG신호의 전처리 과정

2.1 선형 모델링

인간이 수의수축(voluntary contraction)을 할때, 뇌의 운동 피질(motor cortex)에서 신경 임펄스열(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 감탄되는 근섬유(muscle fiber)의 표면에는 Na⁺와 K⁺등의 이온 전위차에 의한 탈분극(depolarization)과 재분극(repolarization)에 의해 운동단위 활동전위(motor unit action potential: MUAP)가 발생되며, 운동에 기여하는 많은 다른 근섬유의 MUAP들의 중첩(superposition)의 결과로서 EMG신호가 구성된다.⁸⁾

일반적으로 EMG신호는 비정상적(nonstationary) 신호이지만, 단시간 구간(100ms내외)에서는 통계적 성질이 크게 변하지 않는 정상적(stationary) 신호라 할 수 있다. 또한 선형 모델링을 통하여 선형 예측 계수를 각 단구간 별로 추정해 보면 특정 계수의 시간에 따른 변동의 범위가 미세하기 때문에, 적절히 시간 구간을 선택하여 EMG신호를 선형 모델화 할 수 있다.

EMG신호 처리 과정에서 피부 조직과 같은 요소로 인해 신호는 저주파 대역에서 대부분의 정보를 함축하고 있으므로, 적절한 시간 간격으로 샘플링을 하고 선형 모델을 통하여 EMG신호의 정보를 추출함으로써 데이터 처리량과 시간을 크게 줄일 수 있다.

선형 모델중 자기회귀 모델(autoregressive model: AR model)을 이용해서 EMG신호를 모델링 하면, EMG신호의 샘플 x[n]은 식(2.1)과 같이 과거의 샘플 x[n-k]에 독립적인 오차신호 e[n]을 합한 선형 조합으로 나타난다.

$$x[n] = - \sum_{k=1}^p a[k] \cdot x[n-k] + e[n] \quad (2.1)$$

여기서 $x[n]$: EMG 신호의 샘플
 $a[k]$: AR 계수
 $e[n]$: 백색 잡음 성질의 오차신호
 p : 모델의 차수

식(2.1)에서 EMG신호 $x[n]$ 을 p 개의 과거 샘플로 추정하면

$$\hat{x}[n] = - \sum_{k=1}^p a[k] \cdot x[n-k] \quad (2.2)$$

과 같다. 이때 실제의 EMG신호 $x[n]$ 과 예측값 $\hat{x}[n]$ 사이의 오차 $e[n]$ 은 식(2.3)과 같다.

$$e[n] = x[n] - \hat{x}[n] \\ = x[n] + \sum_{k=1}^p a[k] \cdot x[n-k] \quad (2.3)$$

따라서 오차신호 $e[n]$ 이 충분히 작거나 0에 가까울 때, 예측신호 $\hat{x}[n]$ 은 원신호 $x[n]$ 과 거의 동일화 될 수 있으며, 결과적으로 식(2.3)에서 특정시간의 신호 값을 추정하려면 특정 p 개의 원신호 $x[n-k]$ 와 예측계수 $a[k]$ 를 각각 보유함으로써 EMG신호의 정보를 압축하여 실시간 처리에 이용할 수 있다.

선형 예측 계수 $a[k]$ 는 오차신호 $e[n]$ 의 제곱이 최소가 되도록 하는 최소 제곱법(least square method : LS method)과 고속 알고리즘을 통해 쉽게 구할 수 있다.

2.2 LPC 캡스트럼 계수의 추정

식(2.1)의 AR 모델에서, 오차 $e[n]$ 과 EMG신호 $x[n]$ 간의 전달함수(transfer function)는 다음 식(2.4)와 같다.

$$\frac{X(z)}{E(z)} = \frac{1}{1 + \sum_{k=1}^p a[k] \cdot z^{-k}} = \frac{1}{A(z)} \quad (2.4)$$

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

$A(z)$ 가 단위원 내에서 모든영점을 가지므로 $A(z^{-1})$ 은 단위원 위나 내에서 해석적(analytic)이게 된다. 따라서 $\ln[A(z^{-1})]$ 도 역시 단위원 내에서 해석적이므로 Laurent 전개가 가능해 지고 z^{-p} 의 계수간 비교를 하여 캡스트럼 계수 $c[k]$ 를 유도하면 다음 식(2.5)와 같다.

$$c[n] = \frac{1}{n} \sum_{k=1}^p (n-k) \cdot a[k] \cdot c[n-k] \quad n > 0 \quad (2.5)$$

단 $c[0] = \ln[E_{min}]$ 이다.

3. 연결 축소 회로망

3.1 신경 회로망의 개요

인간의 신경계(nervous system)는 뉴런(neuron)이라 불리는 신경 세포들로 구성되어 지는데, 뉴런들은 서로간의 정보전달경로를 통해 필요한 정보를 처리한

다. 이러한 생물학적 뉴런 모델의 간단한 기능을 모방하는 인공적인 수학적 뉴런 모델은 다음의 그림3.1과 같다.




그림 3.1 인공 뉴런 모델

인공 뉴런 모델은 생물학적 뉴런 모델의 일차 기능적 특성을 모방하도록 설계 되어져 있다. 다른 뉴런의 출력을 나타내는 일련의 입력이 뉴런에 가해지면, 시냅스의 연결강도와 유사한 가중값(weight)이 각 입력에 곱해지고 가중된 입력이 합쳐져서 뉴런의 활동 레벨을 결정하게 된다.

인공 신경 회로망(artificial neural network)은 위와 같은 인공 뉴런 모델이 병렬적으로 복잡하게 상호연결되어져, 인간의 학습 능력같은 반복적이고 지속적인 학습에 의해 뉴런간의 연결강도를 최적상태로 적응시킴으로써 복잡한 정보처리 능력을 발휘할 수 있도록 하는 회로망을 지칭한다.

3.2 연결 축소 회로망

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

이 회로망에 EMG신호를 적용할 때, 회로망의 입력으로 가해지기 이전의 전처리 단계에서는 해닝 윈도우(Hanning window)로 데이터를 적당한 시간 프레임으로 나누어서 AR모델의 입력으로 사용하기 때문에 입력 데이터간의 시간적 연관이 없는 프레임의 특징 벡터는 회로망의 입력시 어떠한 연결도 가지지 않게 된다. 따라서 실제 하드웨어 구현시 줄어든 연결로 인해 보다 간단한 구조로 구현이 가능할 것이다. 다음의 그림3.2는 연결 축소 회로망의 기본 구조를 나타낸다.




그림3.2 연결 축소 회로망의 구조

위의 그림3.2에서 각 입력 블록내의 입력 프레임들은 시간 지연 특성을 나타내는데, $I_j(\Delta t)$ 와 $I_j(0)$ 사이에는 전체로 겹치며 오버랩(overlap) 시킴을 의미한다. 즉 각 입력 데이터 블록에서 $I_1(0)$, $I_2(0)$, ..., $I_j(0)$ 간에는 전혀 오버랩이 없는 특징 벡터이고, 그림3.3에서는 각 입력 블록당 프레임이 두개이므로 50%의 오버랩시킴을 의미한다. 결국 입력층의 1번째 블록에서 온니층의 j번째 프레임으로의 가장 값 벡터는 1과 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 수렴하지는 않으므로, 최종 결과를 0이나 1로 강제 할 당하는 역할을 수행한다. 즉 생물학적 뉴런의 일반적 문턱값의 특성을 인식층에서는 문턱함수(threshold function)를 이용해서 모방한다.




그림3.3 인식층의 문턱함수

위의 그림에서 k는 정확한 인식의 판별을 위한 구간을 정의 하며 k와 1-k사이의 구간에서는 일종의 'don't care' 상태로 간주된다. 즉 1이 기대되는 출력 노드가 1-k사이에서 있고, 0이 기대되는 출력 노드가 k사이에서 있어야 인식 노드에서는 입력 운동이 학습된 운동중의 하나로 기능을 분류해 낸다. 만일 출력 노드의 값들이 k와 1-k사이에서 있지 않으면 'don't care' 상태나 오인식을 하게된다.

EMG신호의 기능 식별시 일반적 거리측정(distance measure) 방법에서는 단지 기준 패턴(reference pattern)과 시험 패턴(test pattern)들 간의 거리 비교를 통하여 가장 짧은 거리차의 경우를 인식된 운동으로 판단한다. 하지만 시험 패턴을 구성하는 EMG 데이터를 정확히 측정하지 못한 경우, 또는 각 시험 패턴간에 유사한 특징 벡터를 가져서 거의 거리차가 유사 할 경우 오인식의 확률이 높아지므로 실제 보철용 팔에 적용할 때 오동작의 위험성이 무려된다. 따라서 신경 회로망의 인식층에 문턱함수를 도입하여 'don't care' 상태를 제공하여 관계되는 조건이 하나라도 만족되지 않으면 아무런 결과동작도 수행하지 않도록 함으로써 오동작의 위험성을 줄일 수 있게 된다.

3.3 학습 알고리즘

인간의 지력은 학습의 반복을 통하여 습득 강화되어지므로, 신경 회로망도 이 같은 능력을 모방하는 형태로, 시스템의 입력에 입력벡터를 제공받아서 미리 정의된 절차에 따라서 시스템의 출력이 목표로 하는 출력 벡터로 적응되게 가장 값 벡터를 조정해 나가면서 학습을 하게된다.

본 연구에서는 MLP의 전형적인 학습 알고리즘인 Error back propagation (EBP) 알고리즘을 연결 축소 회로망에 적용하였다. EBP 알고리즘은 고전적인 델타 규칙(delta rule)을 일반화하여 학습될 모든 입력 벡터쌍에 대해 전향 경로(forward path)를 통해 실제 출력 생성하고, 시스템의 초기화시 선정된 목표 벡터(desire vector)와 실제 출력 벡터를 비교해서 시스

템의 평균 제곱 오차를 최소화 시키도록 후향 경로(reverse path)를 통해 가장 값 벡터를 최적이 되도록 점진적으로 수정해가는 알고리즘이다.

4. 실험 및 결과 고찰

4.1 실험장치와 실험방법

EMG 신호를 추출하고 관리하는 실험 장치는 다음의 그림4.1과 같다.




그림4.1 EMG 신호의 추출 장치

본 실험에서는 피검자의 고통을 덜기위하여 Ag-AgCl 표면 전극(Beckman, Model 650418, diameter 17mm)을 사용하였다. 또한 실험전 1%의 식염수에 전극을 넣어 반전지 전위(half-cell potential)를 제거한 후, 피부의 불순물을 에탄올로 세정하고 전극의 원활한 전도를 위해 피부와 전극 사이에 전도용 겔을 사용하였다. 전극에서 검출된 EMG신호는 Averaging coupler(Beckman, Model 9854A)로 전달되고 전치 증폭기와 전력 증폭기를 통하여 본 연구실에서 제작한 10bit HD 46508 A/D 변환기를 거쳐 IBM PC/AT에 저장된다. 대부분의 EMG 신호 정보는 500Hz 내에 분포하므로 샘플링 주파수는 1KHz로 하였다.

실험에서는 2인의 피검자를 대상으로 기능 분류를 하였고, 실험전 모든 계기는 충분히 접지를 시켰으며, Dynograph는 안정화 시켰다. Ag-AgCl 표면 전극은 모두 3개를 사용하였는데 전극의 위치는 이두박근 및 삼두박근에 각각 1개의 부착하였고, 나머지는 상완근과 원회내근 사이의 블록 튀어나온 부분위에 부착하여 접지 전극으로 사용했다. 피검자는 약 1초의 시간동안 1회의 단일 운동을 실시하였고 운동간에는 충분한 시간을 두어 피로의 영향을 줄이고자 하였다.

인간의 팔에서 손목관절을 제외한 상반관절과 팔꿈치관절을 이용하는 운동을 4개의 기계적 자유도(degree of freedom)로 해석 가능한데, 본 연구에서는 팔꿈치관절에 의한 4가지 운동에 대한 인식 실험을 연결 축소 회로망을 이용하여 수행하였다. 각 운동은 굴곡 운동(flexion movement), 신전 운동(extension movement), 회내 운동(pronation movement) 그리고 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 시스템 계수에 대해 평균을 취해 생성하였다. 다음 그림4.2은 모델의 차수가 14차이고 윈도우 크기가 64msec일때의 굴곡 운동에 대한 학습 패턴을 나타낸다.




그림 4.2 글자 운동에 대한 학습 패턴

패턴 분류를 위한 학습실험에서 은닉층의 각 은닉 프레임의 노드수는 4개로 고정하여 실험하였는데, 그 이유는 노드의 수를 2, 4, 5, 및 8로 실험한 결과 적당한 기능 분류를 한 인식율이 은닉 노드가 4일 때 가장 좋은 결과를 나타내었다. 표1은 은닉 노드의 갯수가 2, 4 및 8일 때 인식층의 문턱함수의 인식 구간을 $k = 0.1, 0.2$ 및 0.25 로 각각 설정 했을 때 인식율의 비교를 나타낸다. 또 그림 4.3은 은닉 노드가 8일 때 회로망의 학습 횟수에 따른 시스템의 오차곡선을 나타내는데 학습 횟수에 따라 오차 곡선이 계단적으로 감소하여 시스템의 상태가 학습시에 불안정한 상태임을 보여 주고 있다.

표1 은닉 노드의 수가 2, 4 및 8일 때의 인식율[%] 비교 (모델의 차수가 14이고, 시간 프레임이 헤닝 윈도우 64msec 인 경우)

Hidden nodes in a hidden frame	recognition interval of threshold function 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




그림 4.3 은닉 노드가 8일 때의 오차 곡선

표1에서 문턱함수의 제약이 엄격할수록, 즉 인식구간이 작을수록 인식율이 낮아지지만 그만큼 오인식의 확률은 작아지게 되고 회로망은 안정되게 된다. 또 출력 노드의 값을 비교하여 가장 큰값의 동작을 인식 동작으로 취하는 방법(표에서 largest output)은 100%의 인식율을 나타냈지만 인식방법에서 거리측정의 최단거리를 인식 동작으로 하는 방법과 동일해서 각각의 입력 데이터는 반드시 학습 데이터중 하나에 매핑되기 때문에 오인식의 확률이 높아져 적절하지 못한 방법으로 생각된다.

연결 속소 회로망의 학습시 가중값과 옵셋의 학습을 k 는 동일하게 0.5에서 0.7 사이의 값을 취했으며, 모멘텀항수는 0.8로 고정하였다. 그 이유는 학습율은 클수록 빠른 수렴 속도를 가지지만 과할 경우 시스템의 오차 곡선이 크게 진동함으로써 불안정한 과도 상태를 가지게 되기 때문이다.

학습을 통한 인식 실험에서 전처리 단계의 모델 차수의 증가에 따라 인식율은 높게 나타났지만, 그 증가


폭은 줄어들었다. 4차에서 15차 까지 적당히 차수를 변화 시키면서 실험한 결과 14차일 시스템의 안정성과 인식율이 가장 좋은 것으로 나타났다. 또한 전처리단의 윈도우 크기가 256msec, 128msec 및 64msec로 변화에 따라 인식율은 64msec일 때 가장 좋은 결과를 보였다. 그 이유는 EMG 신호의 비정상성으로 인해서 윈도우의 크기가 가장 작은 64msec의 시간 프레임에서 AR 모델이 원신호의 정보를 가장 잘 예측하기 때문이라고 생각된다.

실험에서 모델 차수가 14차이고 윈도우가 64msec 일 때 기대출력이 1인 노드에서 실제 출력은 0.9928, 0.9897, 0.9944 및 0.9888로 각각 접근하였다. 이때의 시스템 오차는 0.0003까지 줄어들었다. 그림 4.10의 오차 곡선에서 기존의 MLP보다 수렴 속도가 줄어든 인 결과 인해 훨씬 빠르고, 곡선이 지수함수적으로 안정되게 줄어들음을 알 수 있다.




그림 4.4 14차일 때의 오차 곡선

또한 다음의 그림 4.5(a)는 3번째 출력 노드에서 3번째 은닉 프레임의 3번째 은닉 노드로의 가중값을, 그림 4.5(b)는 3번째 입력 블록의 2번째 프레임에서의 3번째 입력 노드로부터 2번째 은닉 프레임의 2번째 은닉 노드로의 가중값을 나타낸다. 학습의 규칙은 gradient descent 원리로 행해지므로 학습의 진행에 따라 안정되게 시스템의 오차가 줄어들수록 가중값이 일정한 크기로 수렴하고 있음을 보여준다.



(a) 은닉 노드에서 출력 노드로의 가중값




(b) 입력 노드에서 은닉 노드로의 가중값

그림 4.5 14차일 때 학습에 따라 수렴되는 가중값.

그림 4.6(a)는 3번째 출력 노드의 옵셋이고 그림 4.6(b)는 3번째 은닉 프레임의 3번째 은닉 노드의 옵셋으로 학습이 진행됨에 따라 일정 수준으로 완만하게 수렴하고 있음을 보여준다.

그림 4.4의 오차 곡선과 가중값과 옵셋이 수렴되는 그림 4.5 및 그림 4.6를 학습의 횟수에 따라 비교해 보면, 오차 곡선의 초기 학습에서는 다소의 진동이 발생하며 그 진동이 발생하는 지점에서 가중값과 옵셋 역시 진동을 함을 알 수 있다. 또한 오차 곡선이 시스템

의 오차가 전체적으로 줄어드는 방향을 발견하고 지수 함수적으로 안정되게 감소함에 따라 가중값과 옵셋 역시 완만한 곡선을 그리면서 임의의 값으로 수렴해 감을 알 수 있다.



(a) 출력 노드의 옵셋



(b) 은닉 노드의 옵셋

그림 4.6 14차일때 학습에 따라 수렴되는 옵셋

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

표2 인식 구간과 차수에 따른 인식율과 오인식율의 비교
단위 : 인식율[%]/오인식율[%]

recognition interval of threshold function	order of AR model					
	4	8	12	13	14	15
0.9/0.1	53/0	80.7/0	80.8/0	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	92.6/0
0.75/0.25	73.2/1.25	91.8/0	92.8/0	90.3/0	96/0	94.1/0
largest output	95/5	100/0	100/0	100/0	100/0	100/0

표2에서 largest output은 인식율이 100% 정도로 나타났다지만 인식층에 문턱함수를 두지않고 출력노드의 가장 큰값을 인식 기능으로 판별하는, 거리 측정과 유사한 방법이다. 따라서 4차의 경우처럼 오인식의 가능성은 인식구간을 큰 형태보다 훨씬 높음은 당연하다 하겠다.

그러면 인식층의 인식구간 사용의 타당성을 보기 위해, 극단적인 경우이지만 앞의 4가지 운동을 이용해 회로망을 학습시킨후 학습과는 무관한 어깨를만, 밖으로 움직이는 운동과 어깨를 앞,뒤로 움직이는 운동들 회로망에 입력하였을때 인식 결과를 살펴보면 다음과 같다.

표3에서 보면 largest output방법은 반드시 학습때 인 층의 하나에 매핑되기 때문에 사실은 이 실험에서 인식되는 모든 동작 기능은 오동작이 되고만다. 따라서 앞의 실험들과 비교해서 보면, 문턱함수에 인식 구

간과 같은 제약 조건을 엄격하게 들수록 표면적인 인식율은 낮아지지만 오인식의 가능성은 현저히 줄어들 수 있다. 따라서 문턱 함수의 인식 구간을 어떻게 설정하느냐에 따라 오동작의 위험성을 감소하고 인식율을 높이거나, 아니면 인식율은 다소 낮아 지더라도 오동작의 위험을 줄일 수 있다.

표3 학습된 운동이외의 운동에 대한 오인식율

recognition interval of threshold function	error recognition rate [%]
0.9 / 0.1	10
0.8 / 0.2	15
0.75 / 0.25	20
largest output	100

5. 결론

본 연구는 상실되거나 마비된 팔의 기능을 대신하는 보철제어 장치에 적용될 수 있는 EMG신호처리에 관한 연구로서, AR모델을 통해서 구한 LPC 캡스트럼 계수를 신호의 특징 정보로 하고 각 층의 노드간의 연결을 줄인 연결 축소 회로망에 적용하여 각 운동기능의 인식 실험을 수행하였다.

실험을 통해 얻어진 결과는 다음과 같다.

1. 표면 전극을 통해 추출한 EMG신호를 AR모델링하여 LPC 캡스트럼 계수를 특징 매개변수로 선택한 은신호를 충분히 반영하는 것으로 나타났다.
2. 연결 축소 회로망은 학습의 수렴 속도와 수행 시간이 일반적인 MLP에 비해 상당히 절감되었다.
3. 2인의 피검자를 대상으로 인식 실험을 한 결과, 전처리 단의 모델 차수가 14차일때가 가장 시스템의 안정성과 인식율을 고려할때 가장 좋은 결과를 보였다.
4. 회로망의 인식층에 문턱함수의 인식구간의 선택은 인식율과 오인식율간에 trade-off가 발생했다.

이상의 결과를 바탕으로 인식구간의 적절한 선택으로 운동 기능의 인식율과 오인식율간의 관계를 고려하면 보철제어 및 인간-기계 시스템 제어에 응용될 수 있으리라 기대한다.

참고 문헌

- 1) IEEE EMB society, "Rehabilitation engineering", IEEE, EMB, 1, 4, 1982
- 2) D. Graupe etc, "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 etc, "EMG pattern analysis and classification for prosthesis arm", IEEE Trans., BME, Vol-29, pp. 403-409, 1982

- 4) P. C. Doerschuk etc, "Upper extremity limb function discrimination using EMG signal analysis", IEEE Trans., BME, Vol-30, pp.18-38, 1983
- 5) R. N. Scott etc, "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. McClland and the PDP Groups : Parallel distributed processing, Vol-1, 1986
- 8) C. J. DeLuca, "Physiology and mathematics of myoelectric signals", IEEE Trans., BME-26, No. 6, 1979
- 9) H. Sakoe etc, "Speaker-independent word recognition using dynamic programming neural networks", ICASSP, 10. S1. 8, pp. 29-32, 1989