

# 시간 지연을 갖는 쌍전파 신경회로망을 이용한 근전도 신호 인식에 관한 연구

권장우·정인길\*·홍승홍

= Abstract =

## A Study on EMG Signals Recognition using Time Delayed Counterpropagation Neural Network

Jangwoo Kwon, Inkil Jung\*, Seunghong Hong

In this paper a new neural network model, time delayed counterpropagation neural networks (TDCPN) which have high recognition rate and short total learning time, is proposed for electromyogram(EMG) recognition. Signals the proposed model increases the recognition rates after learned the regional temporal correlation of patterns using time delay properties in input layer, and decreases the learning time by using winner-takes-all learning rule. The outstar learning rule is put at the output layer so that the input pattern is able to map a desired output.

We test the performance of this model with EMG signals collected from a normal subject. Experimental results show that the recognition rates of the suggested model is better and the learning time is shorter than those of TDNN and CPN.

**Key words** : TDCPN, TDNN, EMG, Recognition

### 서 론

義手는 손실 또는 손상된 팔의 기능을 기계적으로 대행하는 장치로 筋電圖(electromyogram) 신호를 이용한 제어 시스템을 구축하는 것이 보편적인 경향이다. 그러나 팔의 복잡한 기능을 모사하기 위하여 근전도신호를 의수의 제어원으로 이용하는 데에는 아직도 많은 제한점들이 있다[1]. 근전도 신호는 시변성을 갖고, 많은 잡음을 포함하고 있기 때문에 신호의 해석도 용이하지 않다. 효율적인 의수 제어의 성공 여부는 근전도신호의 인식율 향상과 밀접한 관계를 가지고 있으므로 이를 위한 다양한 방식의 연구가 이루어져야하나 기존의 근전도신호의 인식율 향상을 위한 접근 방식 대부분이 근전도신호의 동적 특성은 고려하지 않고 정적인 신호인식에 적합한 기능 인식

기법을 사용하는 경우가 빈번하다[2]. 따라서 본 논문에서는 의수의 효율적인 제어를 위해서 선행되어야 하는 근전도 신호의 인식율 향상을 위하여 근전도 신호의 動的 특성을 고려하며 기존 신경회로망들의 단점을 보완하여 인식률이 우수하면서도 학습시간이 짧은 새로운 구조의 신경회로망을 제안한다. 이 모델은 근전도 신호와 같이 시간에 따라 순차적으로 변화하는 패턴에 대해 인식률을 높이기 위해 시간 지연을 도입하고, 학습 시간을 줄이고자 자율 학습의 하나인 승자 독점 학습을 사용한다. 또한 대부분의 응용분야의 경우 주어진 입력에 대해 원하는 값을 출력하게 하므로 이를 위해 지도 학습의 하나인 外星(outstar) 학습층을 추가하였다.

제안한 모델의 유용성을 입증하기 위해 특정 모사 장애인(simulated amputee)의 삼각근 영역에서 추출한 근전

(속보논문)

인하대학교 전자공학과

Dept. of Electronic Eng., Inha Univ.

\*LG 정보통신

\*LG Information and Communication

통신저자 : 권장우, (402-753) 인천시 남구 용현동 253번지 인하대학교 전자공학과 생체 정보 시스템 공학 연구실  
Tel.(032)868-4691, Fax.(032)868-3654




그림 1. TDCPN의 기본 구조  
Fig. 1. Unit of TDCPN

도 신호를 대상으로 실험을 하였다. 특징 파라미터로는 Hamming 윈도우를 사용하여 16차의 선형 예측 계수를 추출하여 사용하였고, 신경회로망은 PC상의 Matlab 환경에서 프로그래밍하여 쌍전과 신경회로망 및 시간지연 신경회로망과 성능을 비교해 보았다.

### 신경회로망

#### 1. 쌍전과 신경회로망(counterpropagation network : CPN)

쌍전과 신경회로망은 Robert Hecht-Nielsen이 1987년에 제안한 혼합형 신경회로망으로서 기존의 네트워크 형태를 조합하여 새로운 구조를 생성시킴으로서 기존 구조로부터 또다른 유용한 네트워크를 형성시킬 수 있는 가능성을 제시하였다[3],[5]. CPN의 학습 알고리즘은 다른 어떤 구조보다 빠르게 학습하여, 다층퍼셉트론(multilayer perceptron, MLP)과 비교할 경우에는 백배까지 줄일 수 있어 학습 시간이 짧아야 하는 응용분야에 매우 유용하며, 함수를 생성하는 능력등에 있어 이와 관련된 많은 시스템들에 응용될 수 있다는 특징이 있다. 그러나 CPN은 비상관성(nonassociative)이기 때문에 특정 출력과 입력을 상관시키기 어렵고, 연결 강도 벡터의 초기화에 민감하며, 대부분의 매칭 응용분야에 있어서 오류 역전과 학습보다 우수하지 못하다는 단점이 있다.

#### 2. 시간 지연 신경망(time delay neural network : TDNN)

시간 지연 신경망은 1989년 일본의 ATR 연구소의 Waibel 등이 제안한 모델로 오류 역전과 알고리즘에 시간 지연 요소를 첨가한 것이다[4],[6],[7]. 이 신경망은 시간 지연 효과를 통해 패턴의 시간적 상관성을 기억하고




그림 2. TDCPN의 전체 구조  
Fig. 2. Architecture of TDCPN

재생함으로써 음성의 시간적 지연현상에 둔감하게 되어 일본어 음소 인식에서 높은 인식률을 보여 주었으며 최근에는 이의 단순한 응용뿐만 아니라 자체의 성능을 향상시키려는 연구도 병행되어지고 있다[8],[9].

TDNN은 기본적으로 오류 역전과 학습을 사용함으로써 승자 독점 학습에는 없는 시그모이드 함수의 계산이나  $\delta_0$ 의 계산, 모든 연결 강도의 학습등으로 학습 시간이 길어진다. 게다가 일반적인 3층 구조의 MLP에 비해 은닉층이 한 층 증가함으로써 학습 시간은 더욱 증가하게 된다. 따라서 높은 인식률을 유지하면서도 학습 시간의 문제를 해결할 수 있는 새로운 모델이 필요하게 된다. 본 논문에서는 이러한 학습 시간의 문제를 CPN의 학습 방법을 이용하여 해결하고자 한다.

#### 3. 시간지연 쌍전과 신경회로망(time delayed counterpropagation network : TDCPN)

학습시간이 빠르다는 CPN의 장점을 살리고 인식률이 우수하다는 TDNN의 구조적 특징을 결합하여, 충분한 인식률을 유지하면서 학습 시간을 줄이는 모델을 제안한다. 이 모델은 CPN과 TDNN을 조합하였기에 시간지연 쌍전과 신경회로망(time delayed counterpropagation network, TDCPN)이라 명명한다. TDCPN은 높은 인식률과 짧은 학습 시간외에도 확장성에 한계가 있는 TDNN에 비해 확장이 용이하다는 장점이 있으며, 3층 구조로 각 층마다 독립된 학습 규칙을 사용함으로써 각각의 학습방법의 성능개선에 따라 제안한 모델역시 성능이 개선될 수 있다는 특징이 있다. 신경회로망의 기본단위들은 입력에 연결 강도가 곱해진 합을 구하여 이를 선형함수나 시그모이드 함수를 통과시킨 후 그 출력을 다음 층에 전달하게 된다. TDCPN에서는 이러한 기본 단위들에 시간 지연 요소를 도입하여 그림 1과 같이 변형하였다.

그림 1에서  $x_j$ 는 입력 벡터의  $j$ 번째 성분을 나타내고,  $w_j$ 는  $x_j$ 에 곱해지는 연결 강도이며,  $D$ 는 시간 지연을 나타내고 있다. 이렇게 시간 지연 요소를 도입하여 TDCPN은 현재의 입력과 과거의 입력을 연관시켜 비교할 수 있

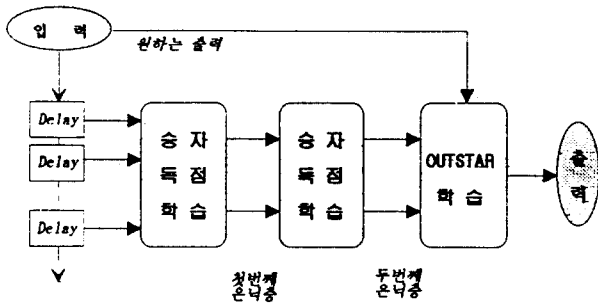


그림 3. TDCPN 각 단계에서의 학습  
Fig. 3. Learning rule in each layer of TDCPN

고 입력층과 은닉층에는 승자 독점 학습을 사용하므로 시그모이드 함수등의 전달 함수는 필요하지 않게 된다.

제안한 모델의 전체 구조 및 각 단계에서의 학습 방법을 그림 2와 그림 3에 나타낸다.

p 개 프레임만큼 시간 지연된 입력에 대해 나타나는 첫번째 은닉층의 값 y는 식 (1)과 같이 주어진다.

$$Y_{kl} = \sum_{i=1}^{m_0} \cdot \sum_{i=1}^{l+p-1} \cdot W_{i(j-l-1)}^k \cdot x_{ij} \quad (1)$$

단,  $i \leq k \leq p, 1 \leq l \leq m_1$

식 (1)에서 x는 시간 지연된 입력값이고,  $W^k$ 는 첫번째 은닉층의 k번째 프레임에 연결된 연결강도를 나타낸다. 그림 5에서 보이듯이 첫번째 은닉층은  $m_1 \times p_1$ 의 행렬이므로 k행 1열의 값을  $y_{kl}$ 로 표시하였다. 이때 사용되는 승자 독점 학습을 그림 4에 나타낸다.

이는 입력 벡터 x와 상이한 신경의 연결강도는 저지되고 가장 유사한 신경의 연결 강도 벡터 u(승자 신경)만이 용인되도록 학습한다. 승자 독점 학습은 연결 강도 및 입력을 정규화하므로 벡터의 크기는 1이 된다. 제안한 모델은 국부적으로 시간 지연된 입력들에 대해서 승자 독점 학습을 하여 전체 입력의 특성을 고려하는 CPN에 비해 음성과 같이 시간적 상관성이 높은 패턴의 인식률을 높일 수 있으며, 오류 역전파 학습의 TDNN과 달리 가장 유사한 연결강도 벡터만을 학습시킴으로써 학습시간을 단축할 수 있다. 두번째 은닉층의 값 z는 다음처럼 표현된다.

$$I_l = \sum_{i=1}^{n_1} \cdot \sum_{i=1}^{m_1} \cdot V_{ij}^k \cdot Y_{ij} \quad (2)$$

단,  $1 \leq l \leq m_2$

$$Z = \begin{cases} 1, & \text{만약 } I_k > I, \forall i \\ 0, & \text{이외의 경우} \end{cases} \quad (3)$$

첫번째 은닉층값 y에 대해, v'는 두번째 은닉층의 첫번째




그림 4. 승자 독점 학습 규칙  
Fig. 4. Winner-takes-all learning rule

신경에 연결된 연결강도 벡터를 나타낸다. 최종값  $z_k$ 는 다음의 외성 학습을 위해 식 (3)과 같이 하나의 승자만이 활성화되고 나머지는 비활성화되어 진다. 두 번째 은닉층에서도 그림 3에서 보듯 역시 승자 독점 학습을 사용하므로 시그모이드 함수는 사용하지 않는다. 이때 연결강도 v의 변화는 다음과 같다.

$$V_{win} = V_{ore} + \beta(y - V_{win}) \quad (4)$$

첫 번째 은닉층에서 시간 지연된 입력의 국부적 상관성을 코딩하게 되고 이렇게 구해진 국부적 상관성을 두 번째 은닉층에서는 전체적으로 동일하여 또한번의 승자 독점 학습을 행함으로써 첫번째 은닉층에서의 미진한 분류를 완전하게 하고자 하였다. 두번째 은닉층에서의 학습이 종료되면 이를 원하는 목표 패턴으로 寫像시키고자 외성 학습층을 추가하였다. 즉 두번째 은닉층과 출력층을 잇는 연결 강도의 변화는 다음 식에 따른다.

$$\Delta u = r \cdot (d - u) \quad (5)$$

여기서 d는 원하는 출력값 벡터로서 두 번째 은닉층의 값 z에 대해 a를 벡터로 출력하도록 연결강도 u를 학습하게 된다. 이때 최종 출력값 o는 다음과 같다. 최종 출력층에서는 시그모이드 함수대신 선형함수를 사용하였다.

$$O_k = \text{linear}(\sum_{i=1}^{m_2} u_i z_i) \quad \text{단, } 1 \leq k \leq m_3 \quad (6)$$

linear( )는 선형 함수를 의미하고 u는 연결 강도 벡터를 나타낸다.

### 특징 추출 및 선택

패턴인식에서, 특징점 추출 및 선택의 주제는 패턴 표현의 차원(dimensionality)을 줄이기 위한 수학적 틀에 관련된 것이다. 저차원적 표현을 구성하는 패턴의 표현자(descriptor)는 패턴 클래스의 성질을 구별하는 특성으로 쓰이며, 특징이라 부른다. 공학적 관점에서 가장 필수

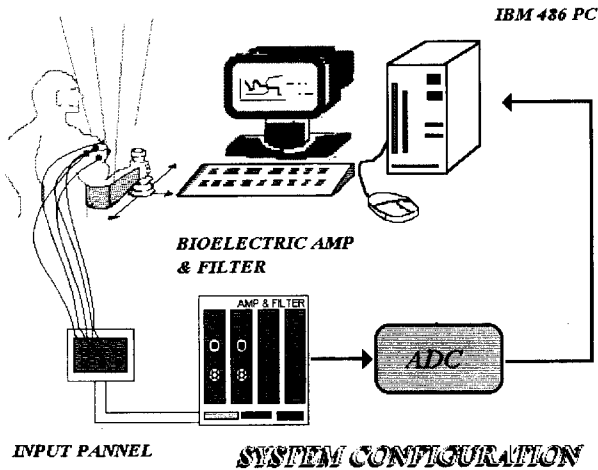


그림 5. 시험시스템 구성도  
Fig. 5. Test system configuration

적인 정보에 근거한 판단을 내린다는 것은 매우 효율적이라 하겠다. 분류기의 성능적 관점에서 보면, 차원의 축소는 오인식율을 줄이는 데도 기여할 수 있다. 즉 불필요한 특징의 추가는 인식의 효율을 저하시키며, 인식율을 저하시키는 데도 기여하기 때문이다.

근전도 신호를 인식하기 위하여 특징점 후보로서 절대적분치(integral absolute value), 영 교차수, 신호의 AR 계수들 및 AR 계수의 캡스트럼계수를 선정하여, 분리도 및 견고성을 비교하여 시험하였다[11].

### 실험 및 고찰

#### 1. 신호의 취득 및 특징 추출

제한한 시스템의 타당성 검증을 위해 우선 모사 장애자가 2차원 조이스틱 평면을 조종공간으로 운전을 행하고, 운전을 행하는 팔로부터 근전도 신호를 획득하였다. 시험 시스템의 구성은 그림 5와 같으며, 실험대상자는 절단모사기를 사용한 정상인을 선택하여 실험하였다. 증폭기는 Nihon Kohden사의 생체증폭기인 AB-621G를 사용하였으며, 시간상수는 피부와 전극사이에 움직임으로 유기되는 포텐셜 및 극포텐셜등이 원인인 저주파잡음제거등을 고려하여 0.01초로 하였고, 감도는 0.2mV/div를 사용하여, A/D변환기의 입력범위를 충분히 사용할 수 있게 하였다. 획득하는 근전도신호의 한 프레임 길이는 80ms이고, 샘플링주파수는 10kHz로 하였다. 조이스틱의 운동은 2차원 평면을 45° 각도로 나누어 8가지 운동형태로 구성되며, 각각의 운동에 대해 10회의 반복실험을 하였다. 어깨의 삼각근에 쌍극법을 사용하여 5개의 전극을 부착하였고, 이중 하나는 접지로서 사용하였다. 2개 채널에서

추출한 근전도신호에서 상관잡음을 제거하고, 특징을 추출한다.

#### 2. 특징 선택

특징 후보로서 시간적 영역에서의 특징인 절대적분치, 영교차수와 주파수 영역에서의 특징인 AR계수, LPC 캡스트럼계수를 선정하였다. 일반적으로 추출된 특징후보들의 클래스간 분리도가 클수록 분류율은 높아지며, 오분류율은 줄어든다. 분리도에 대한 척도에는 시티블럭(city block), 유클리디안(Euclidean), 체비셰프(Chebyshev), 바타케리아(Bhattacharyya), quadratic 거리등이 있으나 본 논문에서는 베이스 에러의 상위 경계를 추정하는데 쓰이는 바타케리아 거리를 사용하였다. 특징에 대한 공통적 기준을 적용하기 위해 분류기에 대한 베이스 오차의 확률을 구하면 되지만, 공통적으로 오확률에 대한 닫힌 형태의 해(closed form solution)를 얻을 수 없으므로, 근사적인 오확률의 상위 경계(upper bound of error probability)를 비교특성으로 결정하였다. 오확률의 상위 경계로서 바타케리아 거리(Bhattacharyya distance)  $\mu$ 을 선정하였고, 다음 식과 같이 표현될 수 있다.

$$\mu(1/2) = \frac{1}{8} (M_2 - M_1)^T \left\{ \frac{\sum_1 + \sum_2}{2} \right\}^{-1} (M_2 - M_1) \quad (7)$$

$$+ \frac{1}{2} \ln \frac{|\sum_1 + \sum_2|}{\sqrt{|\sum_1| |\sum_2|}}$$

$M_1, M_2$ : 클래스 1, 2의 평균,

$\sum_1, \sum_2$ : 클래스 1, 2의 공분산,  $||$ : 행렬식

절대적분치, 영교차수, AR계수, LPC 캡스트럼계수에 대한 클래스간 바타케리아거리를 각각 그림 6에 나타내었다. 비교를 쉽게 하기 위해 공통적으로 스케일링하였다. 그림의 밑에 배열된 좌우의 숫자는 모두 클래스의 종류를 나타내며, 좌측 끝점을 기준으로 대각선에 속한 크기는 모두 같은 클래스간 거리이므로 0이 되며, 대각선은 좌우는 대칭적으로 분포된다. 그림에서 보는 바와 같이 절대적분치와 영교차수에 비해 스펙트럼추정에 의한 AR계수와 LPC 캡스트럼계수의 거리가 월등히 커서 분류에 유리하다는 것을 알 수 있다.

#### 3. TDCPN의 학습 및 인식

제한한 모델인 TDCPN에 대해서 학습 횟수에 따른 첫 번째 및 두 번째 은닉층에서의 연결 강도 변화량에 대한 예를 그림 7에 나타내었다.

세 개의 점선은 TDCPN이 3단 구조로 세 개의 독립된 연결 강도 벡터의 변화를 표시한다. 그림에서 x축은 학습




그림 6. 바타케리야 거리[12]  
 (a). 절대적분치의 클래스별 바타케리아거리  
 (b). 영교차수의 클래스별 바타케리아거리  
 (c). AR 계수의 클래스별 바타케리아거리  
 (d). LPC 켈스트럼계수의 클래스별 바타케리아거리

Fig. 6. Bhattacharyya distance[12]  
 (a). Bhattacharyya distance of IAV between each class.  
 (b). Bhattacharyya distance of ZCN between each class.  
 (c). Bhattacharyya distance of AR coeff. between each class.  
 (d). Bhattacharyya distance of LPC cepstrum coefficient between each class.

횟수이고 y축은 학습전의 연결 강도와 학습후의 연결 강도간의 변화량을 자승 오차로 표시한다. 학습 횟수가 증가함에 따라 연결강도는 분류에 가장 적절한 값으로 학습되어지고 최종적으로 임의의 값으로 수렴이 되면 변화량은 '0'이되어 학습이 종료되어진다. 그러나 '0'으로 될 때까지는 오랜학습시간이 필요하므로 실제적으로는 전체 인식율에 대한 영향이 없는 정도의 임계치를 주어 학습시간을 단축시킨다. 본연구에서는 이러한 임계치로  $10^{-3}$ 을 사용하였다. 출력층인 외성(outstar)학습층은 교사학습이므로 최종 학습의 종료는 원하는 출력값과의 오차로 판단된다. 이와 같은 학습을 거쳐 최종적으로 얻은 TDCPN의




그림 7. 학습 횟수에 따른 연결 강도의 변화  
 Fig. 7. Weight change vs. learning epoch




그림 8. CPN, TDNN 과 TDCPN에서 비학습용 데이터에 대한 인식율 비교  
 Fig. 8. Recognition rates of nontraining data of CPN, TDNN and TDCPN




그림 9. CPN, TDNN 과 TDCPN에서 전체 데이터에 대한 인식율 비교  
 Fig. 9. Recognition rates of total data of CPN, TDNN and TDCPN

인식율을 표 1에 나타내었다. TDCPN의 학습에는 각 클래스별로 40개씩 얻은 데이터 총 320개중 각 클래스별로 20개씩 총 160개의 데이터가 사용되었으며 표 1에는 학습용 데이터를 제외한 실험 데이터의 인식율이 은닉층의 수에따라 달라짐을 보인다.

표 1. 각 구조에 따른 TDCPN의 인식율 도표

Table. 1. The recognition rates of TDCPN of different structure.

입력층		12×7			
첫번째은닉층		10×4	20×4	30×4	40×4
두번째은닉층		160	160	160	160
출력층		8	8	8	8
각 모션에 대한 오인식 수	전진	5	5	2	4
	전우향선회	6	6	9	6
	우향선회	2	0	0	1
	후우향선회	4	0	0	0
	후진	2	4	5	2
	후좌향선회	7	6	8	4
	좌향선회	6	3	0	0
	전좌향선회	6	7	4	6
전체 인식율		76.3%	80.7%	82.5%	85.7%

표 1에서 첫 번째 은닉층이 40×4의 구조를 가질 때 가장 우수한 인식율을 나타냄을 알 수 있다. 또한 학습시 연결 강도의 초기화에 따라 인식 결과에 차이가 나타나기도 했다. 즉, 제안한 모델은 연결 강도를 임의변수(random variable)를 이용하여 초기화함으로써 각 학습시마다 초기 연결 강도의 변화가 최종 인식율에 영향을 미쳤다. 제안한 모델의 성능 비교를 위하여 CPN과 TDNN에 대하여 동일한 실험을 하였다. 이에 대한 인식율을 표 2에 나타낸다.

각 CLASS마다 40개씩의 데이터가 수집되었고 이중 20개씩을 학습용 데이터로 사용하였다. 그림 8은 실험 데이터 중 학습용 데이터를 제외한 CLASS별 20개씩의 실험 데이터를 CPN, TDNN, TDCPN에 적용시켰을때의 인식율을 나타낸다. 그림 9는 학습용 데이터를 포함한 각 CLASS별 40개씩의 전체 실험 데이터를 CPN, TDNN, TDCPN에 적용시켰을때의 인식율을 나타낸다. 표 2와 그림 8과 9에 나타난것처럼 제안한 모델인 TDCPN이 인식율에서 우수하였으며 학습시간도 TDNN에 비하여 단축되었다. 인식율에 있어서 TDNN보다도 우수한 결과가 나온 것은 학습상의 차이때문으로 판단된다. TDNN이 기본적으로 원하는 출력에 대한 오차를 역전파함으로써 패턴을 분류하는 오류 역전파 알고리즘을 사용하는데 반하여 제안한 모델인 TDCPN은 입력 패턴들간의 시간 지연만큼의 패턴들간의 유사도만을 이용하여 분류하는 승자 독점 학습을 하기때문이다. 실험에 사용된 EMG 신호의 패턴들의 유사성이 오류 역전파 알고리즘보다는 승자 독점 학습에서 효율적이었기 때문이다. 동일한 승자 독점 학습임에도 CPN과의 인식율의 차이를 보이는 것은 TDCPN의 경우 일단 시간 지연된 입력에 대하여 승자

표 2. 각 신경회로망의 인식율 및 학습시간

Table. 2. Recognition rates and learning time of different types neural networks.

입력층		CPN	TDNN	TDCPN
		12×7		
첫번째은닉층		160	12×6	40×4
두번째은닉층		0	8×3	160
출력층		8	8	8
각 모션에 대한 오인식 수	전진	4	4	4
	전우향선회	5	6	6
	우향선회	1	0	1
	후우향선회	7	3	0
	후진	4	1	2
	후좌향선회	4	5	4
	좌향선회	5	0	0
	전좌향선회	4	8	6
전체 인식율		78.7%	83.1%	85.7%
학습시간(CPU TIMES (sec))		728	52730	2166

독점 학습이 이루어지고 이를 승자 독점 학습 알고리즘을 이용 재학습했기 때문이다.

## 결 론

본 연구에서는 의수의 효율적 제어를 위해 근전도 신호의 동적 특성을 고려한 TDCPN 신경회로망을 제안했다. 이 구조의 새로운 신경회로망은 신호의 동적 특성을 고려한 신경회로망의 일종인 TDNN의 느린 학습 속도를 개선하기 위하여 고속의 학습속도를 가진 CPN과의 결합을 유도했으며 그 결과 학습 시간이 빠르면서 인식율도 양호한 TDCPN을 제안할 수 있었다. 이 신경망은 기존의 연구들이 단일 신경망이나 단일 신경망과 확률적 접근 모델인 HMM 등을 결합한 형태인 점을 감안 한다면 제안한 모델은 서로 다른 두 신경망을 결합한다는 점에서 새로운 시도이다. 제안한 TDCPN의 성능을 알아보기 위하여 EMG 패턴을 대상으로 LPC 캡스트럼 계수를 특징 파라미터로 잡아 인식율과 전체 학습 시간을 조사하였다. 그 결과 학습용 데이터를 제외한 동일한 실험 데이터에 대하여 제안한 신경 회로망인 TDCPN은 85.7%의 인식율을 TDNN은 83.1%의 인식율을 보였고 CPN은 78.7%의 인식율을 나타냈으며 전체 실험 데이터에 대하여 제안한 신경 회로망인 TDCPN은 92.8%의 인식율을 TDNN은 91.6%의 인식율을 보였고 CPN은 89.4%의 인식율을 나타냈다. 하지만 TDCPN은 충분한 수의 뉴런수가 보장될 때 인식율의 향상을 가져올 수 있었고 이를 위해서는 연결 강도의 수가 커져야하는 문제점도 나타내었다. 효율적인

의수 제어를 위한 근전도 신호의 인식을 향상은 불특정 다수의 장애인에게 적용 가능한 특징 벡터의 추출과 선택 과도 깊은 관계를 갖으며 이를 위한 연구가 시급하다.

### 참 고 문 헌

1. Andreas Gerber, Roland M. Studer and R. J. P. de Figueiredo, "A New Framework and Computer Program for Quantitative EMG Signal Analysis", IEEE Trans. Biomed. Eng., vol. 31, no.12, pp. 857-858, 1984
2. Michael F. Kelly, Philip A. Parker, and Robert N. Scott, "The Application of Neural Networks to Myoelectric Signal Analysis: A Preliminary Study", IEEE Trans. Biomed. Eng., vol. 37, no.3, pp. 221-223, 1990
3. Robert Hecht-Nielsen, "Counterpropagation networks", Applied Optics, vol. 26, no. 23, pp. 4979-4984, 1987.
4. A. Waibel, T. Hanazawa, G. Hinton, K. Shikano and K. J. Lang, "Phoneme Recognition using Time Delay Neural Network", IEEE Trans. ASSP, vol. 39, no. 3, pp. 328-339, Mar. 1989.
5. Robert Hecht-Nielsen, "Nearest matched filter classification of spatio temporal patterns", Applied Optics, vol. 26, no. 10, pp. 1892-1899, 1987.
6. F. Bimbot, G. Chollet and J. Tubach, "TDNN's for Phonetic Features Extraction: A Visual Exploration", IEEE ICASSP, pp. 73-76, 1990.
7. 이영호, 정홍, "음절을 기반으로한 한국어 음성 인식", 전자공학회논문지, 제31권, B편, 제1호, pp. 11-22, 1994.
8. Hideumi Sawai, "Frequency-Time-Shift-Invariant Time Delay Neural Networks for Robust Continuous Speech Recognition", IEEE ICASSP, pp. 45-48, 1991.
9. F. Greco, A. Paoloni and G. Ravaoli, "A Recurrent Time Delay Neural Network for Improved Phoneme Recognition", IEEE ICASSP, pp. 81-84, 1991.
10. Burg, J. P., "Maximum Entropy Spectral Analysis", Proceedings of the 37th Meeting of the Society of Exploration Geophysics 1967, Reprinted in Modern Spectral Analysis, D. G. Childers (Eds), 1978, IEEE Press, New York, pp. 34-41
11. L. R. Rabiner and R. W. Schafer, Digital Processing of Speech Signals. Prentice-Hall, Inc., pp. 359-362, 1978
12. 장영건, 근전도 신호의 패턴인식을 통한 의수의 지능 제어에 관한 연구. 인하대학교 공학박사 학위 청구논문, pp. 129-130, 1995

#### 국문초록

본 연구에서는 의수 제어를 위한 筋電圖(electromyogram) 신호의 인식을 향상을 위하여 패턴 인식에 있어 인식률이 높으면서도 학습 시간이 짧은 '시간지연 쌍전파 신경회로망(time delayed counterpropagation neural networks, TDCPN)'을 제안한다. 이 모델은 시간 지연을 통해 패턴의 국부적인 시간적 상관성을 기억하고 재생하여 인식률을 향상시키고, 승자 독점 학습을 사용하여 전체 학습 시간을 단축시키며, 출력층에서는 外星(outstar) 학습을 이용하여 원하는 패턴으로의 사상(mapping)이 가능하게 하였다. 특정 모사 장애인을 대상으로 실험한 결과, 제안한 모델은 전체 실험 데이터에 대하여 92.8%의 인식률을 보여, 시간지연 신경망(time delayed neural network, TDNN)과 쌍전파 신경회로망(counterpropagation neural network, CPN)에 비해 우수한 성능을 나타내었다. 전체 학습 시간은 쌍전파 신경회로망과는 비슷하였고, 시간지연 신경망보다는 빠른 학습 속도를 보였다.