

신경회로망을 이용한 근전도 신호의 특성분석 및 패턴 분류

이석주^{*}†, 이성환[†], 조영조[†]

† 한국과학기술연구원 지능제어연구센터, † 현대중공업 기전연구소

Pattern Recognition of EMG Signal using Artificial Neural Network

Seok-Joo Yi^{*}†, Sung-Hwan Lee[†], Young-Jo Cho[†]

† ISCRC, Korea Institute of Science and Technology, † Hyundai Heavy Industries

Abstract - In this paper, pattern recognition scheme for EMG signal using artificial neural network is proposed. For manipulating ability, the movements of human arm are classified into several categories. EMG signals of appropriate muscles are collected during arm movement. Patterns of EMG signals of each movement are recognized as follows: 1) The features of each EMG signal are extracted. 2) With these features, the neural network is trained by using feedforward error back-propagation (FFEBP) algorithm. The results show that the arm movements can be classified with EMG signals at high accuracy.

1. 서 론

최근 장애인에 대한 관심이 높아지면서 인체의 근전도 (electromyography) 신호에 대한 연구가 인공의수, 전동 손목 등의 재활공학 분야와 원격제어 및 web 기반 제어 등의 분야에서 매우 활발하게 논의되고 있다 [1][2][3]. 본 논문에서는 장애인에 대한 보조생체메카니즘의 개발에 필수적으로 요구되는 근전도 신호에 대한 특성 분석과 신경회로망을 이용한 근전도 신호의 패턴분류 기법을 제안하였다. 먼저 매니퓰레이터, 인공의수 등 가장 광범위하게 사용될 수 있는 팔의 근육들을 기초로 하여 팔의 기본동작들을 사용되는 근육들을 중심으로 구분하고, 각각의 동작 시 발생하는 각 근육들의 근전도 신호를 측정하여 특성을 분석한 후 이 특성들을 입력으로 하고 각 동작을 출력으로 하는 신경회로망을 통해 학습을 시키게 된다. 이때 사용되는 신경회로망의 연결하중 개선은 역전파 알고리즘을 이용하여 수행된다. 이렇게 분류된 근전도 신호는 보조생체메카니즘의 제어신호로서 이용될 수 있으며, 실험 결과 신경회로망을 이용한 근전도 신호의 분류는 매우 높은 신뢰성을 보임을 알 수 있었다.

2. 근전도 신호 계측

2.1 팔의 움직임 구분

팔의 움직임은 크게 위팔(arm)과 아래팔(forearm)의 움직임으로 구분할 수 있다[4]. 먼저 위팔의 움직임은 앞으로 모음(anteverision), 뒤로 벌림(retroversion), 앞으로 들기(abduction), 앞으로 내리기(adduction) 등으로 분류된다. 또한 아래팔의 움직임은 굽힘(flexion), 펌(extension), 엎침(pronation), 뒤침(supination) 등으로 구분할 수 있다. 본 연구에서는 적은 수의 전극으로도 전체 움직임에 대한 근전도 신호를 표현하기 적합한 굽힘, 펌, 엎침, 뒤침, 모음, 벌림

등 6개의 움직임을 정하여 근전도 신호를 측정하였다. 이렇게 선택된 각각의 움직임은 각기 사용되는 근육들이 다르기 때문에 근전도 신호에 대한 분류가 용이하다는 장점이 있다. 표 1에 각 움직임에 사용되는 근육들을 정리하였다.

표 1. 각 움직임에 사용되는 근육들

움직임	근육
모음	어깨세모근 큰 가슴근
벌림	어깨세모근 넓은 등근
굽힘	위팔두갈래근 위팔노근
펴	위팔세갈래근
엎침	위팔두갈래근 원 엎침근
뒤침	위팔세갈래근 뒤침근

2.2 근전도 신호 계측 위치

표 1에서와 같이 6가지의 팔 움직임은 사용되는 근육들이 각각 다르기 때문에 한 근육에서만 근전도신호를 측정하게 되면 움직임을 구분할 수 없게 된다. 본 연구에서는 반복된 실험을 통해 근전도 신호 계측에 필요한 최적 근육으로서 어깨세모근, 위팔 두갈래근, 위팔 세갈래근, 그리고 원 엎침근을 선택하였다. 그림 1은 실험에 이용된 근전도 계측 위치를 보여준다.

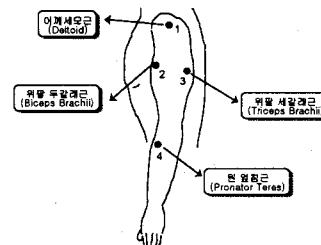


그림 1. 근전도 계측 위치

2.3 근전도 계측 시스템

본 연구의 실험에 사용된 근전도 신호 계측 시스템은 BIOPAC의 MP100 시스템이다. 이 시스템은 모두 16 channel의 아날로그 입력을 계측할 수 있고, 계측과 동시에 on-line analysis와 filtering이 가능하다. 또한 근전도 신호는 대략 0~10mV_{p-p}의 아주 미세한 신호이기 때문에 전극 자체에 앰프가 내장된 active electrode TSD150을 사용하였다.

3. 신경회로망을 이용한 패턴 분류

근전도 신호의 패턴 분류는 그림 2와 같은 과정을 거친다. 먼저 수집된 4 channel의 원 신호로부터 신경회로망 학습에 필요한 근전도 신호 특성들을 추출하고, 추출된 특성을 입력으로 하고, 6가지의 팔 움직임을 출력으로 하는 신경회로망을 구성하였다. 교사 데이터 (teacher data)를 구성하여 신경회로망을 학습시키게 되면 결과적으로 근전도 신호에 대한 패턴분류 모델을 완성하게 된다.

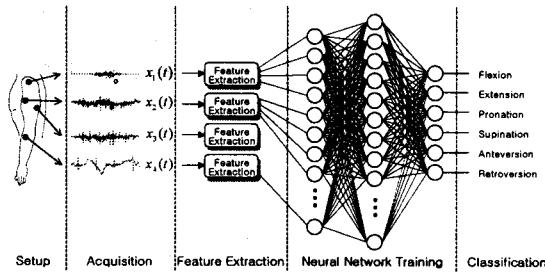


그림 2. 신경회로망을 이용한 근전도 신호의 패턴 분류

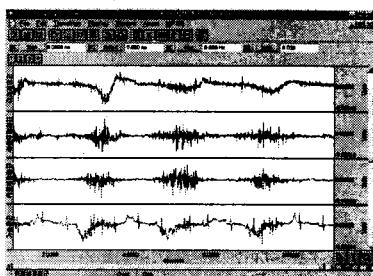


그림 3. 근전도 신호의 예

3.1 주요요소분석을 통한 근전도 신호의 특성 추출

근전도 신호는 대략 $0\sim10\text{mV}_{\text{p,p}}$ 의 아주 미세한 신호이며 일반적으로 그림 3과 같이 복잡한 파형을 갖는다. 따라서 근전도 신호를 분석하기 위해서는 정량적 지표가 필요하다.

본 연구에서는 이와 같은 특성 추출과 데이터 차원의 감소를 위해 데이터의 에너지가 대부분 집중되어 있는 공간좌표계를 찾아내는 선형 과정으로서 특징 되는 형태를 추출하는 알고리즘이 주요요소분석(Principal Component Analysis: PCA)[5] 기법을 이용하였으며 그 알고리즘을 정리하면 다음과 같다.

주요요소분석 방법을 보이기 위해 먼저 데이터의 평균값(mean)과 데이터간의 공분산(covariance)을 구해야만 한다. 만일 n 개의 차원을 갖는 m 개의 실험데이터 X 가 존재한다고 가정하면 이 데이터에 대한 평균행렬 \bar{X} 와 공분산 행렬 S 는 각각 식 (1), 식(2)와 같다.

$$\bar{X} = \begin{bmatrix} \bar{x}_1 \\ \vdots \\ \bar{x}_n \end{bmatrix}, \quad \bar{x}_i = \sum_{k=1}^m x_{ik} \quad (1)$$

$$S = \begin{bmatrix} s_{11} & \cdots & s_{1n} \\ \vdots & \ddots & \vdots \\ s_{n1} & \cdots & s_{nn} \end{bmatrix}, \quad s_{ij} = \frac{n \sum_{k=1}^m x_{ik}x_{jk} - \sum_{k=1}^m x_{ik}\sum_{k=1}^m x_{jk}}{m(m-1)} \quad (2)$$

여기서 \bar{x}_j 는 j 번째 차원의 m 개의 실험데이터에 대한 평균을 의미하며, s_{ij} 는 $i=j$ 일 경우에는 분산을, 그리고, $i \neq j$ 일 경우에는 i 번째와 j 번째 차원사이의 공분산을 의미하게 된다. 그 다음 과정으로 실험데이터의 공분산 행렬 S 에 대한 고유값 L 과 고유벡터 U 의 산출이 필요하게 되는데 식 (3)과 같이 얻어질 수 있다.

$$U^T S U = L \quad (3)$$

여기서 얻어지는 대각행렬 L 의 원소 l_1, l_2, \dots, l_n 은 S 의 고유값이라고 불리며, 행렬 U 의 종행렬 u_1, u_2, \dots, u_n 은 S 의 고유벡터라고 불린다. 고유값과 고유벡터의 특성상 각 특성벡터들은 데이터의 특성을 가장 잘 나타내고 있는 직교 좌표계를 대표하고 있다. 식 (4)에 의한 주요축 전환에 의하여 n 차원의 연관된 데이터 $X = [x_1, x_2, \dots, x_n]^T$ 는 새롭게 연관되지 않은 n 차원의 $Z = [z_1, z_2, \dots, z_n]^T$ 를 생성하게 된다.

$$Z = U^T [X - \bar{X}] \quad (4)$$

여기서, X 가 n 차원을 갖는 m 회 실험데이터라고 할 때, \bar{X} 는 $n \times 1$ 의 X 의 평균행렬이고 U 는 $n \times n$ 의 크기를 갖는 공분산의 고유벡터이다. 이와 같은 주요축 변환에 의한 변수들을 주요요소라고 불리고, 변환된 변수명인 주요요소에 대하여 변환된 데이터 쌍을 "스코어(score)"로 정의하여 구분하게 된다. 식 (5)에 의하여 i 번째 스코어가 계산될 수 있다.

$$z_i = u_i^T [x - \bar{x}] \quad (5)$$

주요 요소 분석 알고리즘에 의해 나타난 특징 중 가장 큰 특징은 공분산의 고유 벡터 u_i 는 공분산의 고유값 l_i 에 대응하기 때문에 원래의 데이터 쌍의 u_i 방향 분산정도는 l_i 에 비례한다. 따라서, u_i 방향의 분산정도는 식 (6)과 같이 전체 고유값 중에 i 번째 고유값의 비율을 구함으로서 측정될 수 있다.

$$u_i \text{의 \%분산} = \frac{l_i}{\sum l_i} \cdot 100 = \frac{l_i}{\text{trace}(S)} \cdot 100 \quad (6)$$

만일, 데이터 변화량의 약 95% 이상을 지니는 스코어만을 추출한다고 할 때 $l_1 \geq l_2 \geq \dots \geq l_n$ 의 순서로 정렬되어 있는 고유값 $L = [l_1, l_2, \dots, l_n]$ 에 대한 검정을 수행하여 적합한 것으로 판정된 y 개의 스코어만을 고려한다면, $n \times n$ 의 스코어 행렬 Z 를 5% 정도의 특성을 무시한 상태에서 $n \times y$ 의 행렬로 데이터의 감소를 가져올 수 있다.

3.2 신경회로망의 구조

근전도 신호의 패턴분류에 사용된 신경회로망은 입력층, 중간층, 출력층의 다층구조를 가지며 연결하중의 개선은 역전파(feed-forward error back-propagation: FFEFBP) 알고리즘[6]을 통해 이루어진다. 각 층을 연결하는 연결하중값은 다음과 같이 계산된다. 먼저 주어진 입력에 대해 계산된 신경회로망 출력값은 교사 데이터에 의해 주어진 목표값과 식 (7)에 의해 그 오차가 계산되고 신경회로망은 이 오차를 줄이는 방향으로 중간 층-출력층, 그리고 입력층-중간층 간의 연결하중값을 차례로 바꾸어나간다.

$$E = \frac{1}{2} \sum_{i=1}^n (y_i - y_i^d)^2 \quad (7)$$

이때, y_i 는 신경회로망에서 계산된 실제 출력, y_i^d 는 교사 데이터(teacher data)의 목표출력값을 의미한다.

3.3 교사 데이터

구축된 신경회로망을 학습시키기 위한 교사 데이터는 입력 데이터와 출력 데이터 쌍으로 구성된다. 먼저 입력 데이터는 4개의 채널에 대해 각각 y 개의 주요요소가 추출되므로 모두 $4 \times y$ 개가 되고, 출력 데이터는 각 동작에 대한 on-off 값으로 설정하여 모두 6개가 된다. 따라서 하나의 교사 데이터는 다음과 같이 정의된다.

$$\{x_1, x_2, \dots, x_{4 \times y}, y_1^d, y_2^d, \dots, y_6^d\} \quad (8)$$

이러한 교사 데이터는 6가지 동작에 대한 데이터를 모두 포함해야 하므로, 각 동작마다 5회씩의 실험을 통해 획득한 근전도 신호로부터 지속시간, 진폭, 면적, 위상 네 가지 특성값을 계산하여 교사 데이터를 구성하면 모두 30개의 교사 데이터 쌍이 결정된다.

4. 실험 및 결과

먼저 교사 데이터를 구성하기 위해 각 근전도 신호에 대한 주요요소분석을 실시한 결과 그림 4와 같이 대부분의 연관관계는 축 변환된 데이터의 마지막 몇 개의 스코어에 집중되어 있으며, 이러한 주요 스코어로 근전도 신호궤적을 대표할 수 있음을 알 수 있다. 또한 그림 5에서 스코어에 따른 %누적 변화량을 살펴보면 마지막 7개의 주요 요소 안에 근전도 신호궤적 전체 변화량의 95%가 숨어있음을 알 수 있으며 이는 이 7개의 주요 요소들로 원 근전도 신호의 특성을 5%의 오차로 표현할 수 있음을 의미한다. 따라서 패턴분류를 위한 신경회로망의 학습에 필요한 교사 데이터의 입력변수 개수를 4×7 개로 설정하였다.

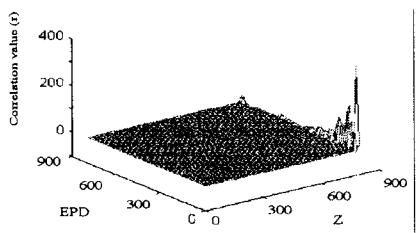


그림 4. 원 근전도 신호와 변환된 신호와의 연관관계

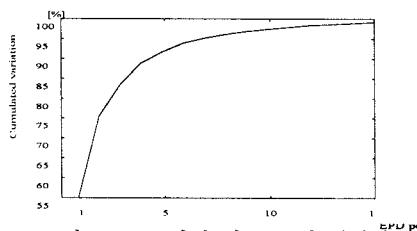


그림 5. 스코어에 따른 누적 변화량

이와 같이 구성된 교사 데이터는 신경회로망모델 학습에 이용되며 학습이 끝난 신경회로망은 근전도 신호에 대한 패턴을 분류하는 모델로 이용된다. 신경회로망 학습은을 위한 파라미터는 표 2와 같다.

이렇게 구성된 근전도 패턴분류 모델을 검증하기 위해 각 동작에 대한 테스트를 실시하였다. 테스트 결과는 2 가지로 구분하였다. 첫 번째 실험은 구성된 모델을 수정하지 않고 테스트만 실시하였고, 두 번째 실험은 테스트에서 발생한 근전도 신호를 새로운 교사 데이터로 설정하여 온라인 학습을 시키면서 테스트를 진행하였다. 그

표 2. 신경회로망 모델링을 위한 학습 파라미터

파라미터	설정값
입력총 뉴런 수	28
중간층 뉴런 수	40
출력총 뉴런 수	6
학습률	0.001
학습오차	1×10^{-3}

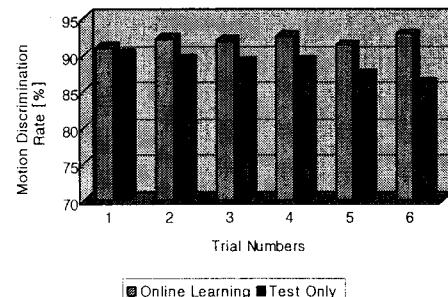


그림 6. 동작구분 테스트 결과

그림 6은 테스트 결과를 보여준다. 이 때 각 trial은 모두 10회씩의 테스트를 종합한 결과를 나타낸다.

그림 6을 살펴보면 먼저 두 가지 경우 모두 85% 이상의 정확도를 보임을 알 수 있다. 또한 단지 테스트만 실시한 경우에는 실험횟수가 많아질수록 정확도가 떨어지는데 비해 온라인 학습을 진행한 경우에는 점차 정확도가 향상되는 것을 볼 수 있다.

5. 결 론

본 논문에서는 신경회로망을 이용한 근전도 신호의 패턴분류 방법에 대해 연구하였다. 주요요소분석 기법에 의해 추출된 근전도 신호로 구성된 신경회로망 모델은 온라인 학습을 진행하며 테스트를 실시한 결과 약 92%의 정확성을 보였다. 추후 연결동작에 대한 순차분석 및 제어신호 생성에 필요한 power 및 force에 대한 연구가 진행되어야 할 것이다.

(참 고 문 헌)

- [1] O. Fukuda, et. al., "An EMG Controlled Robotic Manipulator Using Neural Networks", Proc. of IEEE Int. Workshop on Robot and Human Communication, 442-447, 1997
- [2] Constantinos S. Pattichis, et. al., "Neural Network Models in EMG Diagnosis", IEEE Trans. on Biomedical Eng., Vol.42, No.5, pp.486-496, 1995
- [3] Francis H. Y. Chan, et. al., "Fuzzy EMG Classification for Prostheses Control", IEEE Trans. on Rehabilitation Eng., Vol.8, No.3, pp.305-311, 2000
- [4] Blandine Calais-Germain, 조상현 역, *Anatomy of Movement*, 영문출판사, 1999
- [5] J. Edward Jackson, A user's guide to principal components, Wiley series in probability and mathematical statistics, pp.26-47, 1991
- [6] D. Z. Anderson, *Neural Information Processing Systems*, Denver, 1987