

원형 구조 알고리즘을 이용한 근전도 패턴 인식 및 분류

Electromyography Pattern Recognition and Classification using Circular Structure Algorithm

최유나¹·성민창¹·이슬아²·최영진[†]

Yuna Choi¹, Minchang Sung¹, Seulah Lee², Youngjin Choi[†]

Abstract: This paper proposes a pattern recognition and classification algorithm based on a circular structure that can reflect the characteristics of the sEMG (surface electromyogram) signal measured in the arm without putting the placement limitation of electrodes. In order to recognize the same pattern at all times despite the electrode locations, the data acquisition of the circular structure is proposed so that all sEMG channels can be connected to one another. For the performance verification of the sEMG pattern recognition and classification using the developed algorithm, several experiments are conducted. First, although there are no differences in the sEMG signals themselves, the similar patterns are much better identified in the case of the circular structure algorithm than that of conventional linear ones. Second, a comparative analysis is shown with the supervised learning schemes such as MLP, CNN, and LSTM. In the results, the classification recognition accuracy of the circular structure is above 98% in all postures. It is much higher than the results obtained when the linear structure is used. The recognition difference between the circular and linear structures was the biggest with about 4% when the MLP network was used.

Keywords: Electromyography, Pattern Recognition, Classification, Deep Learning

1. 서 론

최근사물 인터넷(IoT) 및 인공지능(AI) 기술의 발달에 따라 근전도(EMG: Electromyography) 및 심전도(ECG: Electrocardiogram) 등의 생체신호를 인간과 컴퓨터 사이의 인터페이스로서의 사용가능성이 증대되고 있다. 그 중 근전도는 근육에 전달되는 신경과 자극을 전달받는 근섬유에서 나타나는 활동전위로부터 발생된 전기 신호이며, 이는 절단 장애인을 위한 제어 수단으로 다양한 연구들이 진행되고 있다¹⁻³⁾. 근전도를 이용한 전

동 의수는 절단 부위에서 표면 근전도 신호를 취득하여 사용자가 별다른 조작 없이 동작을 수행할 수 있도록 설계되어 있다. 최근에는 기계학습(Machine learning)을 이용하여 실제 사용자가 의도한 동작을 역으로 추론하는 알고리즘이 연구되고 있으며, 서포트 벡터 머신(Support Vector Machine, SVM), 다층 퍼셉트론(Multi-layer Perceptron, MLP), 합성곱 신경망(Convolution Neural Network, CNN), 순환 신경망(Recurrent Neural Network, RNN) 등의 학습 알고리즘을 이용한 패턴 분류 방법들이 적용되어 왔다^{4,5)}.

대표적인 근전도 전동 의수에는 Touch Bionic의 i-Limb, Otto Bock의 Bebionic, Michelangelo 등이 있으며 근전도를 이용한 다양한 손동작이 가능하다. 그러나 상용 전동 의수들은 주로 On-off 형식의 구동 시스템을 사용하고 있으며, 사용자들은 이를 습득하기 위한 학습과정 및 시간이 필요하다. 이를 개선하기 위해, 다채널 근전도 신호를 이용한 패턴 인식에 대한 연구들이 진행되고 있으나^{6,7)}, 고정된 위치에서 근전도 신호가 측정되어야하므로 위치가 변동될 때마다 새로운 데이터를 수집하고 학습하는데 많은 시간과 노력이 요구된다. 또한 기존

Received : Aug. 14. 2019; Revised : Oct. 10. 2019; Accepted : Dec. 9. 2019

※ This work was supported by the convergence technology development program for bionic arm through the National Research Foundation of Korea (NRF) funded by the Ministry of Science & ICT (No. 2015M3C1 B2052811).

1. MS student, Department of Electrical and Electronic Engineering, Hanyang University, Ansan, Korea (chldbsk2220@naver.com, tjaldskd@gmail.com)

2. Researcher, Department of Electrical and Electronic Engineering, Hanyang University, Ansan, Korea (seulah@hanyang.ac.kr)

† Professor, Corresponding author: Department of Electrical and Electronic Engineering, Hanyang University, Ansan, Korea (cyj@hanyang.ac.kr)

선행연구들의 경우, 개발된 의수의 기존 학습 방법을 사용하거나, 여러 가지 기계학습 알고리즘에 대한 비교 연구가 진행되어 왔으나, 전동 의수를 위한 팔 구조를 모방한 알고리즘 개발 및 측정 위치에 관한 연구들은 미비한 실정이다.

따라서, 본 논문에서는 근전도 센서의 측정 위치에 상관없이 원통 형상의 팔에서 근전도 신호의 특성을 반영한 원형 구조 기반의 패턴 인식 및 분류 알고리즘을 제안한다. 근전도 센서의 전극 위치를 무작위로 지정해도 동일한 패턴을 인식할 수 있고, 모든 채널의 데이터가 서로 연결되어 있는 원형 구조(Circular structure)를 제안한다. 제안된 알고리즘의 성능 평가를 위해, 3가지 지도 학습(Supervised learning)의 알고리즘에 적용하여 분류 가능성을 평가하고, 기존 선형 구조(Linear structure)와의 차이를 비교 분석함으로써 알고리즘의 실용성과 상용화 가능성에 대하여 의의를 두는 바이다.

본 논문은 다음과 같이 구성된다. 2장에서는 원형 알고리즘에 관한 데이터 수집 방법 및 분류 가능성을 평가하기 위해 적용된 기계 학습 알고리즘을 설명한다. 3장에서는 제안된 방법의 학습 환경 및 신경망을 통한 패턴 분류 실험 결과를 설명하며, 4장에서는 본 연구에 대한 요약과 결론 및 추후 연구 방향에 대해 기술한다.

2. 원형 구조 알고리즘 제안


2.1 원형 구조 기반 데이터 수집

2.1.1 근전도 신호 처리 과정

전완의 둘째에서 측정된 8채널의 데이터는 [Fig. 1]과 같이 특징점 추출과 정규화 과정을 통해 기계 학습에 적용 가능한 학습 데이터로 생성된다. 근전도 신호의 특징점 추출은 Root mean squaring (RMS), Zero crossing (ZC), Mean absolute value (MAV), Slope sign change (SSC)와 같이 시간 영역에서 사용되는 다양한 방법들이 있으며^[5], 본 연구에서는 비교적 계산이 간단하고 우수한 성능을 보이는 다음 식과 같은 RMS를 사용하였다.

$$x_{rms,i}(k) = \sqrt{\frac{1}{N} \sum_{n=1}^N x_i(k-n+1)^2} \quad (1)$$

여기서 N은 데이터 윈도우의 크기, $x_i(k)$ 는 i번째 채널에서 k번째 sampling time에 측정된 sEMG 데이터이다. 각 채널의 값은 N개씩 제공하여 더해진 후에 평균을 취하고 이어서



[Fig. 1] Surface electromyography signal processing

제공된 연산을 수행하여 RMS값 $x_{rms,i}(k)$ 으로 구해진다. 추출된 특징은 항상 0 이상의 값을 가지며 네트워크에 적용하기 쉽게 만들기 위해 0과 1 사이로 정규화 하였다^[8]. 정규화는 최소-최대 방법을 사용하였고 다음 식을 통해 얻어진다.


$$x_{n,i}(k) = \frac{x_{rms,i}(k) - x_{min,i}}{x_{max,i} - x_{min,i}} \quad (2)$$

여기서 $x_{n,i}(k)$ 는 k번째의 정규화 데이터를 의미하며 $x_{min,i}$ 은 휴식 상태에서 i번째 채널 RMS 값 중 최소값, $x_{max,i}$ 는 실험자가 주먹 상태에서 낼 수 있는 최대 힘을 주어 얻은 MVC (Maximum voluntary contraction)에서의 최대 RMS 값이다.

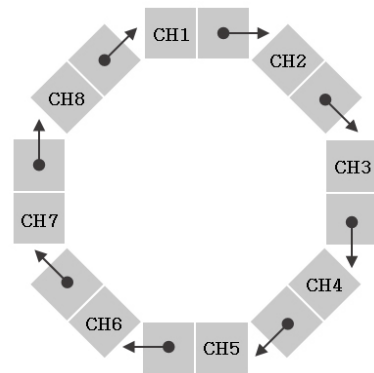
2.1.2 원형 구조 알고리즘

정규화된 데이터는 네트워크의 학습 데이터로 생성 된다. 일반적인 데이터 세트는 [Fig. 2]와 같은 선형 구조로 각 채널의 데이터가 순차적으로 나열되어 있고, 채널1과 채널8의 데이터가 연결되어 있지 않은 형태를 나타낸다. 반면에, 본 논문에서 제안하는 알고리즘은 [Fig. 3]과 같이 원형 구조를 가지는 데이터를 이용하여 패턴을 분류하였다. 제안하는 원형 구조에서는 원형 연결 리스트(Circular linked list) 구조를 적용하였다^[9-12]. 이는 [Fig. 3]과 같이 첫 노드(Node)와 마지막 노드가 연결되어 원형 구조를 이룬다. 따라서 각 채널 사이의 구분이 사라지기 때문에 전극의 위치를 무작위로 위치시켜도 동일하게 동작을 분류하도록 설계하였다.

제안된 방법은 선입선출(First-in First-out)을 이용하여 채널 1의 데이터부터 순차적으로 입력되며 8개 채널의 근전도 신호를 시계방향으로 시프트(Shift) 시켜 사용하여 원형 구조를 유지



[Fig. 2] Dataset with linear structure



[Fig. 3] Dataset with circular structure

한다. 회전된 채널은 8번 반복된 후에 처음 채널의 위치로 돌아오게 된다.

2.2 기계학습 알고리즘

근전도 신호의 패턴 분류 방법은 [Fig. 4]의 과정을 따른다. 신호 처리 과정을 거쳐 생성된 원형 구조 학습 데이터는 다층 퍼셉트론(MLP), 합성곱 신경망(CNN), 장단기 메모리 신경망(LSTM)의 네트워크에 각각 적용되어 분류 결과를 비교 분석하고, 학습을 마친 네트워크를 검증하기 위해 원형 구조 근전도 신호를 테스트 데이터로 사용하여 패턴 인식 및 분류 결과를 확인하였다.


2.2.1 다층 퍼셉트론(MLP)

다층 퍼셉트론은 입력층(Input layer), 은닉층(Hidden layer), 출력층(Output layer)으로 구성되며, 모든 노드가 연결된 전 방향(Feedforward) 신경망이다¹³⁾. 활성화 함수를 가지는 노드는 가중치를 가지고 연결되며 가중치를 조절하여 목표값을 추정한다. 가중치는 오류 역전파 알고리즘(Backpropagation)을 이용하여 출력과 목표값이 허용될 오차보다 클 경우 반복적으로 학습된다¹⁴⁾.

사용된 입력층의 노드에는 근전도 센서의 8채널에서 측정되는 근전도 신호에 대해서 RMS와 정규화를 거쳐서 생성되는 신호들이 적용되며, 출력층의 노드는 실험에 사용된 5가지의 동작으로 구성된다. 사용된 MLP는 [Fig. 5]와 같이 은닉층 1개에 128개의 노드를 가지며 활성화 함수로 ReLU (Rectified linear unit) 함수를 사용하였다. MLP의 입력층 노드 개수를 i , 은닉층 노드 개수를 j , 출력층 노드 개수를 k 라고 가정할 때, 은닉층의 j 번째 노드 h_j 이며, 식은 다음과 같다.



[Fig. 4] Schematic diagram of pattern classification



[Fig. 5] Structure of multi-layer perceptron (MLP)

$$h_j = \sum_i w_{ij} u_i \quad (3)$$

여기서 w_{ij} 는 입력층의 i 번째 노드와 은닉층의 j 번째 노드를 연결하는 가중치(Weight)를 의미하며 u_i 는 입력층의 i 번째 노드의 입력 값인 i 번째 채널의 RMS와 정규화를 거친 근전도 신호이다. 은닉층 노드 h_j 는 다음 식과 같은 Softmax 함수를 거쳐 출력층의 입력으로 사용되고 출력 값 y_k 식은 다음과 같다.

$$y_k = \frac{e^{h_j}}{\sum_{j=1}^n e^{h_j}} \quad (4)$$

여기서 y_k 는 학습 데이터의 목표 값과 함께 특정한 목적함수에 적용되어 오차를 생성하게 되며, 이를 최소화하도록 MLP를 반복 훈련시킨다. 본 연구를 위해서 목적함수로는 교차-엔트로피 오차(Cross-entropy error)가 사용되었다.

$$E = - \sum_k t_k \log y_k \quad (5)$$

여기서 t_k 는 실제 레이블(Label)이며 데이터를 중복 없이 표현하기 위해 원-핫 인코딩(One-hot encoding) 방법을 사용하였다. 원-핫 인코딩은 목표 동작에 대한 값은 1이고 나머지는 모두 0으로 표시하는 방법이며, 예를 들어, 첫번째 동작인 주먹(grasping)은 [1,0,0,0,0]와 같이 나타낸다.

2.2.2 합성곱 신경망(CNN)

합성곱 신경망(Convolution Neural Network, CNN)은 이미지 분류에 주로 활용되는 신경망으로 입력 이미지(Input image)에 합성곱(Convolution) 연산을 사용하여 특징(Feature)을 추출하는데 사용된다¹⁵⁾. 다음의 식은 2차원 구조에서의 합성곱 연산을 의미하며 x 는 입력 이미지, y 는 출력, w 는 가중치, $[m,n]$ 은 픽셀(Pixel) 좌표, k 는 커널 크기를 의미한다.

$$y[i,j] = (x * w)[i,j] = \sum_{i=0}^k \sum_{j=0}^k x[m-i, n-j] w[m,n] \quad (6)$$

합성곱 신경망에 사용할 이미지를 만들기 위해, 8채널의 근전도 신호를 측정하여 RMS와 정규화 처리를 거쳐서 8개의 샘플을 8×8의 입력 이미지로 생성하였다. 입력 이미지는 합성곱을 수행하기 위해 1×3×16×16의 텐서(Tensor)로 변환되었다. 커널을 통과하기 위해 이미지 크기를 재조정하였는데, 이때 방식은 픽셀 간의 영역 평균(Area averaging)을 이용하였다. 또한, 기존의 흑백 이미지를 3개 겹쳐 RGB 크기의 이미지로 만들어


사용하였다. 이후 입력 이미지는 합성곱 계층(Convolutional layer), 최대 풀링 계층(Max pooling layer), 전 연결 계층(Fully-connected layer)을 통과하여 5개의 출력값으로 변환하였다.

CNN의 전체적인 구조는 [Fig. 6]과 같다. 합성곱 계층은 총 3개의 레이어를 사용하였고 첫 번째 층과 두 번째 층의 커널(Kernel) 크기는 3이고 세 번째 층의 커널 크기는 2로 설정하였다. 최대 풀링 계층에서는 2x2 픽셀 크기에서 가장 큰 값을 선택하여 텐서의 크기를 줄였고, 모든 전 연결 계층은 드롭아웃(Drop-out) 기법과 활성화 함수인 ReLU 함수를 사용하여 64개의 출력을 5개의 출력값으로 변환시켰다. 이렇게 5개의 출력값은 argmax 함수를 사용하여 가장 큰 인수를 찾는다. 이 인수는 합성곱 신경망을 통해 분류된 동작을 의미한다.


2.2.3 장단기 메모리 신경망(LSTM)

장단기 메모리 신경망(Long short-term memory, LSTM)은 현재 입력 시퀀스 x_t , 직전 은닉층 출력인 h_{t-1} 가 필요하다. LSTM 셀(Cell)은 직전 상태 h_{t-1} 와 입력 x_t 에 대해 4개의 내부 레이어를 가진다. 내부 레이어는 망각 게이트(Forget gate), 입력 게이트(Input gate), 업데이트 게이트(Update gate), 출력 게이트(Output gate)로 구성되어 있다^[6]. 입력 시퀀스는 센서의 8채널 원형 구조 데이터 세트를 의미하며 현재 상태는 동작의 패턴이 된다. LSTM의 전체 구조는 [Fig. 7]과 같다.

망각 게이트는 셀로부터 어떤 동작의 패턴 정보를 버릴 것인지 정하며 시그모이드 레이어에 의해 결정된다. h_{t-1} 와 x_t



[Fig. 6] Structure of convolution neural network (CNN)



[Fig. 7] Structure of long short-term memory (LSTM)

를 입력받아 0과 1 사이의 값인 y_{t-1} 로 보내진다. 여기서 U_f 는 입력층에서 은닉층으로 갈 때의 가중치이며 W_f 는 은닉층과 은닉층을 연결하는 순환 노드의 가중치를 의미한다. 망각 게이트는 다음과 같다.

$$f_t = \sigma(U_f x_t + W_f h_{t-1} + b_f) \tag{7}$$

입력 게이트는 앞으로 들어올 새로운 패턴 중 어떤 데이터를 셀에 저장할지를 결정하며, 시그모이드 레이어가 업데이트 할지 선택한다. 하이퍼볼릭 탄젠트(Hyperbolic tangent) 레이어가 새로운 후보 값인 y_t 라는 벡터를 만들어 셀에 더하고 두 단계에서 나온 정보를 합쳐 상태를 업데이트하게 된다.

$$i_t = \sigma(U_i x_t + W_i h_{t-1} + b_i) \tag{8}$$

$$\tilde{y}_t = \tanh(U_f x_t + W_f h_{t-1} + b_y) \tag{9}$$

과거 상태인 y_{t-1} 를 업데이트해서 새로운 셀 상태인 y_t 를 만든다. 이전 상태의 f_t 를 곱해서 가장 첫 단계에서 잊은 정보를 제거한 후 $x_t * \tilde{y}_t$ 를 더하여 업데이트하는 값을 얼마나 수행할지 지정한 만큼 스케일링 한 값이 된다. 업데이트 게이트는 다음 식과 같다.

$$y_t = f_t * y_{t-1} + x_t * \tilde{y}_t \tag{10}$$

마지막으로 출력 게이트는 어떤 패턴을 출력으로 내보낼지 결정한다. 먼저, 시그모이드 레이어에 입력 데이터를 사용하여 셀의 어느 부분을 출력으로 결정할지 정한 후 하이퍼볼릭 탄젠트 레이어를 거쳐 -1과 1 사이의 값을 출력하고, 시그모이드 게이트의 출력과 곱하여 원하는 출력 값만 얻는다. 출력은 다음 식을 통해 얻는다.

$$o_t = \sigma(U_o x_t + W_o h_{t-1} + b_o) \tag{11}$$

$$h_t = o_t * \tanh(y_t) \tag{12}$$


3. 실험 및 결과

3.1 실험 대상 및 학습 환경


본 연구는 한양대학교 기관 생명윤리위원회(Institutional Review Board: IRB)에서 2019년 7월(HYI-16-0550-8) 최종 승인을 받은 후에 진행하였다. 연구 대상은 신체 건강한 성인 남녀 3명(남성 2명, 여성 1명)으로 선정하였고, 연구의 목적 및 실험 절차에 대하여 실험 참여자에게 충분한 설명을 제공한 후 진행하였다.

본 실험은 전완에 대한 원형 구조의 데이터 세트를 생성하기 위하여 근전도 센서(MYO, Thalmic Labs)를 사용하였다. MYO 센서는 8개의 전극으로 구성되어 있고 8bit의 분해능과 200 Hz의 샘플링 속도를 가지며 측정 위치는 손과 손목의 움직임과 관련이 있는 전완에 위치하도록 착용하였다. 전완의 근육에는 손 동작에 참여하는 지신근(extensor digitorum)과 손목 동작에 참여하는 요측수근굴근(radial flexor of wrist), 장장근(palmaris longus) 등이 있으며, 근육의 움직임은 동작에 의해 생성되는 근전도 패턴과 밀접한 관계를 가진다²¹⁾. 따라서, 근전도 센서를 손과 손목의 동작과 관련된 근육 부위에 착용한 후, 서로 다른 특징의 패턴을 생성하기 위하여 [Fig. 8]과 같이 주먹(Grasping), 굴곡 및 신전(Flexion-Extension), 회외와 회내(Supination-Pronation)의 5가지 목표 동작을 선정하였다. 실험 데이터 획득은 한 동작에 대하여 약 20초 동안 수행하였다. 측정 데이터는 밴드 패스 필터(Band-pass Filter of 8-200 Hz)와 노치 필터(60 Hz)를 적용한 후 300 ms 윈도우 크기를 갖는 RMS를 이용하고 정규화를 적용하였다.

이러한 방법으로 [Fig. 9(a)]와 같이 고정된 위치에서의 학습 데이터 세트 1개와 [Fig. 9(b)]와 같이 시계 방향으로 전극 채널을 회전시켜 임의로 정한 위치에서의 학습 데이터 2개에 대하여 총 5번 반복 측정하였다. 생성된 학습 데이터들은 각각의 네트워크



[Fig. 8] Five target postures for pattern classification



[Fig. 9] MYO band sensor and wearing location: (a) fixed location (b) varying location

에 적용되어 패턴 분류를 위한 학습과정을 수행하게 된다.

실험은 크게 두 부분으로 나누어진다. 첫 번째는 전극 채널을 회전시키며 서로 다른 위치에서 반복 측정된 선형 구조와 원형 구조의 데이터에 대하여 패턴 인식을 수행한 후 결과를 분석한다. 두 번째로는 MLP, CNN, LSTM의 기계학습 알고리즘에 적용하여 두 가지 구조의 분류 정확도에 대하여 비교 분석한다.

3.2 실험 결과

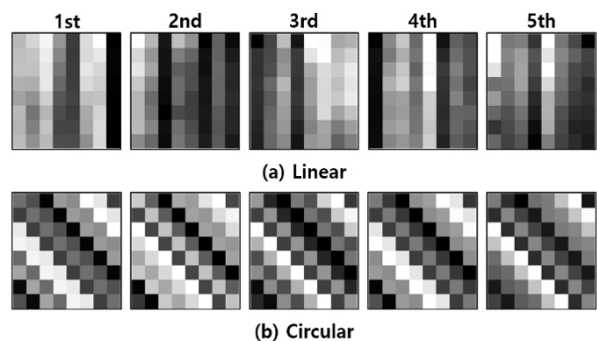
3.2.1 선형 구조와 원형 구조의 반복 측정 분석

기존 선형 구조와 제안된 원형 구조의 반복 측정 데이터를 비교 분석하기 위해, 주먹 동작에 대하여 5회 반복 측정하였으며, 그 결과는 [Fig. 10]과 같다. [Fig. 10]은 8개의 채널에서 얻어진 데이터를 8x8의 이미지를 비교한 것이다. 한 줄의 데이터는 8개의 채널 중 가장 큰 값과 가장 작은 값을 선별하여 정규화하였으며 큰 값은 흰색 작은 값은 검은색으로 표현하였다.

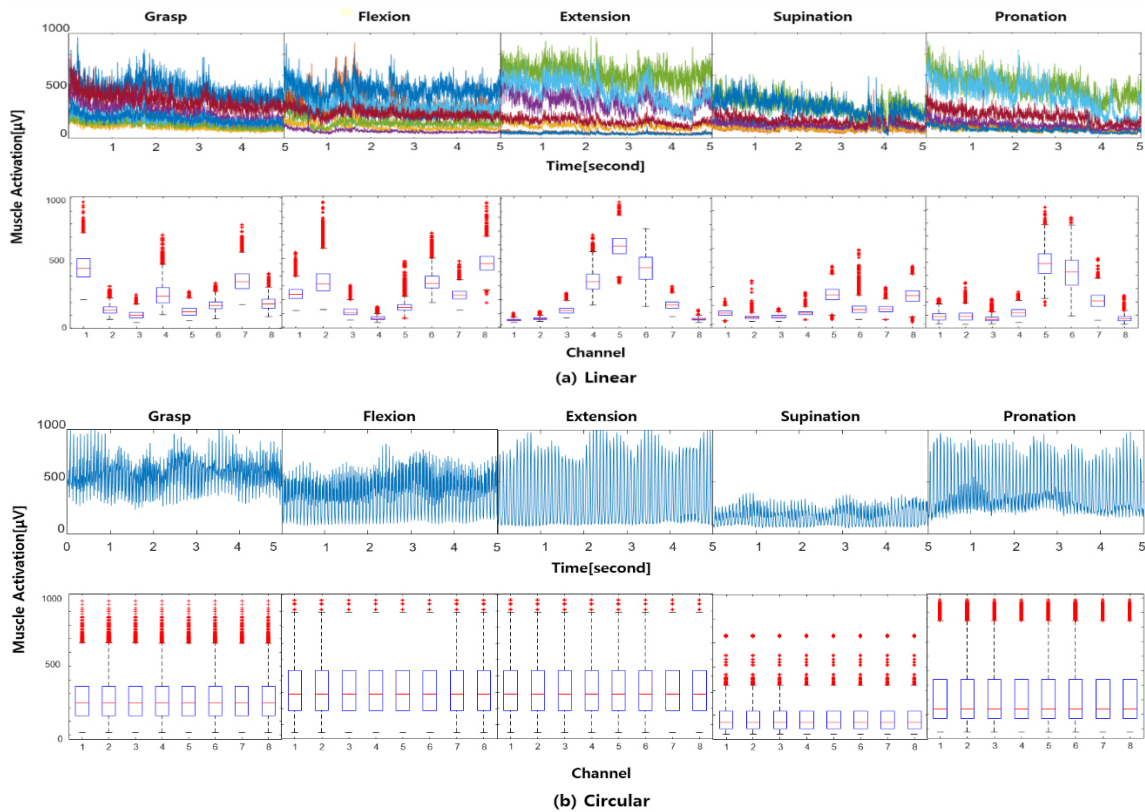
[Fig. 10(a)]는 선형 구조 데이터로 각 채널에 위치한 근육의 활성화 유무를 알 수 있으나, 임의의 위치에서 반복 측정하였을 경우 위치가 변화함에 따라 각 채널의 근전도 증폭에 대한 차이로 패턴이 변화됨을 확인할 수 있었다. 반면에, [Fig. 10(b)]는 원형 구조 데이터로 5회 반복 측정한 결과 유사한 패턴이 생성됨을 확인하였다.

[Fig. 11]은 5개의 목표 동작에 대하여 선형 구조와 원형 구조의 패턴과 상자 그래프(Box plot)이다. [Fig. 11(a)]는 선형 구조의 결과로 각 동작에 대해 특정 채널의 값이 증폭되며 상자 그래프에서 증폭된 채널이 높게 나타나는 데이터의 분포를 확인할 수 있었다. [Fig. 11(b)]에서는 원형 구조의 결과로 각 채널의 최댓값과 최솟값, 그리고 중앙값이 모두 동일한 데이터의 분포가 나타난다.

따라서, 원형 구조는 반복 측정하였을 때 유사한 패턴이 나타나며, 5가지에 대한 각 동작의 패턴에 대하여 명확한 차이를 확인하였다. 이를 통해 일상생활 활동을 위해 근전도 전동 의수의 착용하는 경우 기준에 한번 학습이 이루어졌다면, 전극



[Fig. 10] Pattern image: (a) linear (b) circular



[Fig. 11] Five target postures for pattern recognition and box plot: (a) linear structure (b) circular structure

[Table 1] Experimental results of three subjects

		Sub. 01			Sub. 02			Sub. 03			Mean
		MLP	CNN	LSTM	MLP	CNN	LSTM	MLP	CNN	LSTM	
Circular	Grasping	100.00	95.00	100.00	100.00	99.00	99.00	99.00	97.00	99.00	98.67
	Flexion	94.00	100.00	98.00	100.00	97.00	93.00	99.00	97.00	97.00	97.20
	Extension	100.00	100.00	100.00	98.00	99.00	100.00	100.00	99.00	99.00	99.44
	Supination	99.00	96.00	99.00	97.00	100.00	100.00	97.00	96.00	96.00	97.78
	Pronation	97.00	98.00	99.00	98.00	98.00	99.00	95.00	99.00	96.00	97.67
Mean		98.00	97.80	99.20	97.80	98.60	98.20	98.00	97.60	97.40	98.07
Linear	Grasping	98.00	96.00	97.00	98.00	96.00	99.00	98.00	99.00	95.00	97.33
	Flexion	89.00	98.00	83.00	91.00	97.00	93.00	91.00	99.00	95.00	92.89
	Extension	79.00	100.00	100.00	99.00	92.00	100.00	95.00	93.00	83.00	93.44
	Supination	98.00	93.00	94.00	92.00	95.00	76.00	96.00	95.00	91.00	92.23
	Pronation	93.00	92.00	92.00	99.00	95.00	89.00	87.00	96.00	82.00	91.67
Mean		91.40	95.80	93.20	95.80	95.00	91.40	93.40	96.40	89.20	93.51

채널 위치 변경에 따라 다시 학습을 수행할 필요가 없다. 이를 통해 제안된 원형 구조 방법의 목표 동작에 대한 반복성 및 실용 가능성을 확인할 수 있었다.

3.2.2 선형 구조와 원형 구조의 분류 정확도 비교

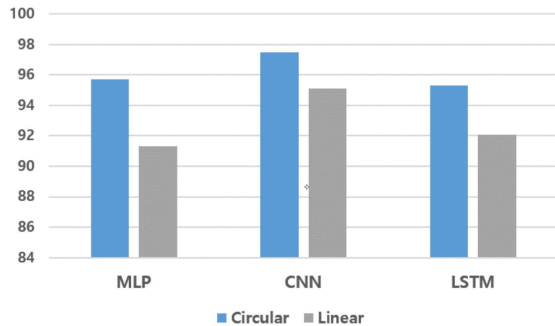
선형 구조와 원형 구조의 분류 정확도를 비교하기 위하여,

기계학습 방법인 MLP, CNN, 그리고 LSTM 네트워크에 적용하였다. 분류를 위한 동작은 [Fig. 8]과 같이 주먹, 굴곡, 신전, 회외, 회내의 순서로 수행되었다. Learning rate는 0.001로 설정하였고 Epoch는 300회 반복 학습하였다.

[Table 1]은 3명의 피험자에 대한 3가지 네트워크의 패턴 분류 실험을 실시한 결과이다. 각 동작당 5,000개의 데이터를 측

[Table 2] Results of the paired *t*-test analysis

	Circular		Linear		<i>t</i>	<i>p</i>
	Mean	SD	Mean	SD		
Accuracy	98.07	0.55	93.51	2.47	5.476*	0.001

**p*<.01

[Fig. 12] Comparison of classification accuracy regarding three subjects

정하였으며, 전체 데이터 세트는 총 25,000개이다. 각 동작에 대한 원형 구조 인식률에서는 신전 동작이 99.44%로 가장 높게 나타났으며, 선형 구조에서는 주먹 동작에서 97.33%로 가장 높은 인식률을 보였다. 이는 원형 구조의 주먹 동작과 비교했을 때 약 1.3% 낮게 나타났다. 추가적으로 원형 구조와 선형 구조의 정확도의 차이에 대하여 [Table 2]와 같이 대응 표본 *t*-검정을 통해 분석하였다. 그 결과 원형과 선형 구조의 정확도에 있어서 유의한 차이를 보였다(*p*<.01). 전체 피험자에 대한 원형 구조의 인식률은 평균 98.07%이며, 선형 구조의 평균 인식률(93.51%) 보다 약 4.6%의 높은 인식률이 나타났다.

더 나아가 전체 피험자의 75,000개(=25,000×3명) 데이터 세트를 3가지 네트워크에 적용하여 패턴 분류 실험을 실시하였다. 결과는 [Fig. 12]와 같으며 MLP, CNN, 그리고 LSTM에서 모두 원형 구조의 분류 정확도가 더 높게 나타났음을 확인하였다. 특히, MLP 네트워크에서 정확도의 차이가 약 4%로 가장 크게 나타났다.

4. 결론

본 연구는 근전도 센서의 착용 위치에 제한을 두지 않고 원통형의 팔에서 측정되는 신호의 특성을 반영하여 원형 구조 기반의 패턴 인식 및 분류 알고리즘을 제안하였다. 원형 구조의 데이터 수집 방법은 센서의 채널 위치를 임의로 지정해도 동일한 패턴으로 인식할 수 있도록 모든 채널이 원형으로 서로 연결되어 있는 형태를 유지한다. 이렇게 제안된 원형 구조의 성능을 평가하기 위하여, 기존의 선형 구조와의 비교 분석을 실시하였다.

첫째, 원형 구조와 선형 구조의 학습 데이터를 이용한 패턴 인식을 실시하였으며, 각각 다른 위치에서 3번 반복 측정하였다. 그 결과, 선형 구조의 데이터는 같은 동작에 대하여 반복 측정 시 다른 패턴이 생성되었지만, 원형 구조는 유사한 형태의 패턴이 생성되었다. 또한, 5개의 목표 동작에 대해서는 서로 다른 패턴이 뚜렷하게 나타났으며 이는 수행할 수 있는 손 동작에 대하여 다양한 패턴 인식이 가능함을 확인할 수 있었다. 둘째, 3명의 피험자에 대하여 지도학습 알고리즘인 MLP, CNN, LSTM에 대해서 적용 실험을 실시하였다. 그 결과 3개의 네트워크에서 원형 구조의 높은 분류 정확도를 확인하였고, LSTM에서 가장 큰 차이를 보였다. 이처럼 기존의 데이터 수집에 사용되는 선형 구조의 패턴 분류 알고리즘은 실제 의수 사용자의 경우, 정확한 측정 위치에서 사용이 가능하다는 현실적인 어려움을 갖게 된다. 또한, 실제 사람의 팔에 착용하는 근전도 센서는 원형 구조를 가지며 센서의 각 채널에서 출력되는 데이터는 양 끝이 이어져 있어 서로 다른 채널에도 영향을 미친다. 기존의 선형 구조의 데이터는 이러한 특성을 표현하지 못하며 양 끝의 채널 사이의 근전도 신호의 관계를 무시한다는 것 또한 한계점으로 작용한다.

본 연구는 근전도 전동 의수의 구동 시스템 개발뿐만 아니라 재활 및 웨어러블 로봇 분야로 확대될 수 있다. 또한 앞으로의 후속 연구에서는 전동 의수와 제안된 알고리즘을 통합하여 실시간 제어가 가능한 의수 개발하는 것이 목표이다.

References

- [1] M. A. Oskoei and H. Hu, "Myoelectric control systems-A survey," *Biomedical Signal Processing and Control*, vol. 2, no. 4, pp. 275-294, 2007.
- [2] M. Ferdjallah, J. J. Wertsch, and G. F. Harris, "Effects of surface electrode size on computer simulated surface motor unit potentials," *Electromyography and Clinical Neurophysiology*, vol. 39, no. 5, pp. 259-265, 1999.
- [3] Y.-J. Kim, D.-H. Lee, H. Park, J.-H. Park, J.-H. Bae, and M.-H. Baeg, "Wrist and Grasping Forces Estimation using Electromyography for Robotic Prosthesis," *The Journal of Korea Robotics Society*, vol. 12, no. 2, pp. 206-216, Jun., 2017.
- [4] M. Pontil and A. Verri, "Properties of support vector machines," *Neural Computation*, vol. 10, no. 4, pp. 955-974, 1998.
- [5] A. Hiraiwa, K. Shimohara, and Y. Tokunaga, "EMG pattern analysis and classification by neural network," *Conference Proceedings, IEEE International Conference on Systems, Man and Cybernetics*, Cambridge, USA, pp.1113-1115, 1989.
- [6] S. Lee, M.-O. Kim, T. Kang, J. Park, and Y. Choi, "Knit Band Sensor for Myoelectric Control of Surface EMG-based Prosthetic Hand," *IEEE Sensors Journal*, vol. 18, no. 20, Oct., 2018.


- [7] Y. Jiang, M. Togane, B. Lu, and H. Yokoi, "sEMG Sensor Using Polypyrrole-Coated Nonwoven Fabric Sheet for Practical Control of Prosthetic Hand," *Frontiers in Neuroscience*, vol. 11, no. 33, Feb., 2017.
- [8] A. Phinyomark, P. Phukpattaranont, and C. Limsakul, "Feature reduction and selection for EMG signal classification," *Expert Systems with Applications*, vol. 39, no. 8, pp. 7420-7431, 2012.
- [9] J. Sola and J. Sevilla, "Importance of input data normalization for the application of neural networks to complex industrial problems," *IEEE Transactions on Nuclear Science*, vol. 44, no. 3, pp. 1464-1468, 1997.
- [10] J. E. Hopcroft and J. D. Ullman. *Data structures and algorithms*. 1983.
- [11] M. M. Michael and M. L. Scott, "Simple, Fast, and Practical Non-Blocking and Blocking Concurrent Queue Algorithms," *Proc. 15th Ann. ACM Symp. Principles of Distributed Computing*, pp. 267-275, May, 1996.
- [12] C. D. Kasper. "Method and network device for creating circular queue structures in shared memory," U.S. Patent No. 6,526,451. 25 Feb., 2003.
- [13] M. W. Gardner and S. R. Dorling. "Artificial neural networks (the multilayer perceptron)-a review of applications in the atmospheric sciences," *Atmospheric Environment*, vol. 32, no. 14-15, pp. 2627-2636, 1998.
- [14] R. Hecht-Nielsen. "Theory of the backpropagation neural network," *Neural Networks for Perception*, Academic Press, 1992. pp. 65-93.
- [15] A. Krizhevsky, I. Sutskever, and G. E. Hinton. "Imagenet classification with deep convolutional neural networks," *Advances in Neural Information Processing Systems*, 2012.
- [16] S. Hochreiter and J. Schmidhuber. "Long short-term memory," *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, 1997.



최유나

2019 순천향대학교 전자정보공학과(공학사)
현재 한양대학교 전자공학과(석사과정)

관심분야: 생체신호 처리, 로봇 제어



성민창

2019 한양대학교 ERICA 전자공학부(공학사)
현재 한양대학교 전자공학과(석박사통합과정)

관심분야: 딥러닝, 컴퓨터 비전, 로봇 제어



이슬아

2017 한양대학교 의류학과 (박사)
현재 한양대학교 ERICA 공학기술연구소
연구원

관심분야: 웨어러블 센서, 스마트 텍스타일&디자인



최영진

2002 POSTECH 기계공학과 (공학박사)
2005 KIST 지능로봇연구센터 선임연구원
현재 한양대학교 ERICA 전자공학부 교수

관심분야: 로봇제어, 생체신호처리