

# 사전 자세에 따른 근전도 기반 손 제스처 인식

최현태<sup>1</sup>, 김덕화<sup>2</sup>, 장원두<sup>3\*</sup>

<sup>1</sup>부경대학교 인공지능융합학과 학생, <sup>2</sup>부경대학교 컴퓨터공학과 학생, <sup>3</sup>부경대학교 컴퓨터·인공지능공학부 교수

## Recognition of hand gestures with different prior postures using EMG signals

Hyun-Tae Choi<sup>1</sup>, Deok-Hwa Kim<sup>2</sup>, Won-Du Chang<sup>3\*</sup>

<sup>1</sup>Student, Artificial Intelligence and Convergence Department, Pukyong National University

<sup>2</sup>Student, Department of Computer Engineering, Pukyong National University

<sup>3</sup>Professor, Division of Computer Engineering and Artificial Intelligence, Pukyong National University

**요약** 손 제스처의 인식은 구어 사용이 어려운 사람들의 의사소통을 위한 중요한 기술이다. 제스처 인식에 널리 사용되는 근전도 신호는 사전 자세에 따라 동작이 달라지기 때문에 제스처 인식의 어려움이 있을 것으로 예상되지만, 이에 관한 연구는 찾기 어렵다. 본 연구에서는 사전 자세에 따른 제스처 인식 성능의 변화를 분석하였다. 이를 위해 총 20명의 피험자에게서 사전 자세를 가지는 동작에 대한 근전도 신호를 측정하고, 제스처 인식을 실험하였다. 그 결과, 학습 및 테스트 데이터 간 사전 상태가 단일한 경우에는 평균 89.6%의 정확도를, 상이한 경우에는 평균 52.65%의 정확도를 보였다. 반면, 사전 자세를 모두 고려한 경우에는 정확도가 다시 회복됨을 발견하였다. 이를 통해 본 연구에서는 근전도를 활용하는 손 제스처 인식시에 사전 자세가 다양하게 고려하여야 함을 실험적으로 확인하였다.

**주제어** : 근전도, 손 제스처 인식, 인간-컴퓨터 상호작용, 패턴 인식

**Abstract** Hand gesture recognition is an essential technology for the people who have difficulties using spoken language to communicate. Electromyogram (EMG), which is often utilized for hand gesture recognition, is expected to have difficulties in hand gesture recognition because its people's movements varies depending on prior postures, but the study on this subject is rare. In this study, we conducted tests to confirm if the prior postures affect on the accuracy of gesture recognition. Data were recorded from 20 subjects with different prior postures. We achieved average accuracies of 89.6% and 52.65% when the prior states between the training and test data were unique and different, respectively. The accuracy was increased when both prior states were considered, which confirmed the need to consider a variety of prior states in hand gesture recognition with EMG.

**Key Words** : Electromyogram, Hand Gesture Recognition, Human-Computer Interaction, Pattern Recognition

## 1. 서론

2022년 현재 대한민국에는 41만 명의 청각장애인이

있으며[1], 수화는 청각장애인이 대면 또는 영상으로 사람들과 대화할 때 주로 사용하는 제 1언어다. 하지만, 이와 같은 공공성에도 불구하고 청각장애인 외에 수화 가

본 논문은 부경대학교 자율창의기술연구비(2022년)에 의하여 연구되었음.

\*교신저자 : 장원두(chang@pknu.ac.kr)

접수일 2023년 9월 20일 수정일 2023년 11월 14일 심사완료일 2023년 11월 20일

능자는 매우 드물며, 이로 인해 청각 장애인과 비장애인 사이의 대화는 아직까지 어려운 경우가 많다. 수화인식은 청각장애인과 같이 구어 사용이 힘든 사람들을 위한 중요한 기술이다.

수화의 인식은 카메라 기반의 연구가 많은데 이 방법 [2-4]은 휴대폰 카메라를 활용할 수 있어, 편리성 부분에서 장점이 있으나, 카메라 각도가 맞지 않거나 어두운 환경에서는 인식이 어렵다. 또한, 비장애인이 휴대폰 어플리케이션을 설치하고 실행하는 것을 전제하는 경우가 많으므로, 청각장애인이 능동적으로 비장애인과 대화를 시작하기 어려우며, 환경이 갖추어진 제한적인 상황에서만 사용할 수 있다는 단점이 있다.

한편, 근전도(Electromyogram: EMG) 기반의 수화 인식은 센서 등을 부착하거나 착용할 필요가 있으며, 스피커가 부착된 형태로 구성된다면 카메라 기반 방식의 수동적인 면을 극복할 수 있을 것으로 기대된다.

EMG를 이용하는 수화 또는 제스처 인식은 최근 다양한 그룹에 의해 연구되고 있다. Shin 등은 EMG를 가속도 센서와 함께 사용하여 한국 수화 동작을 인식하는 연구를 진행하였고[5], Yuk 등은 k-NN 알고리즘을 통해 6가지 손동작의 패턴을 인식하는 연구를 수행하였다[6]. Celal 등은 SVM 알고리즘을 통해 26가지의 미국 지화 동작을 인식하는 연구를 수행하였으며[7], Amina 등은 EMG 센서로부터 측정된 신호(7가지 아랍 수화 동작)를 합성곱, 확장된 합성곱(dilated convolution), 장단기 메모리(LSTM) 층 등으로 구성된 네트워크를 사용하여 인식하는 연구를 수행하였다[8]. Simin 등은 랜덤 포레스트(Random Forest) 알고리즘을 통해 30가지의 중국 지화 동작을 인식하는 연구를 수행하였다[9]. Qi 등은 PCA를 통한 특징추출과 GRNN 모델을 이용하여 9개의 손동작을 인식하는 연구를 수행하였다[10]. Ozdemir 등은 푸리에 변환과 ResNet을 함께 이용하여 7가지 손동작을 인식하였다[11]. Chen 등은 중국어 수화 동작에서 40가지의 손동작을 선택하여 30가지 동작으로 모델을 사전학습한 후 다른 10가지의 동작을 소수의 데이터만으로 전이학습하는 연구를 수행하였다[12].

하지만 현재까지 대다수 연구에서의 데이터 측정은 동일한 사전 자세가 전제되었다. 근전도는 사용자의 근육 움직임에 따라 반응하므로, 사전 자세에 따라 동일한 제스처의 신호가 다르게 발생할 것으로 예측되지만, 사전 자세가 근전도 인식에 미치는 영향에 대해서는 아직까지 충분히 다루어지지 못했다.

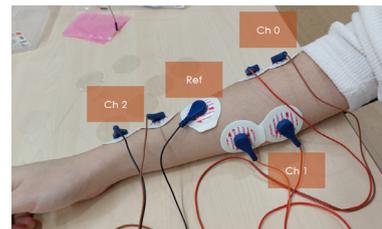
본 연구에서는 사전 상태에 따른 제스처 인식의 정확

도 변화를 다수(20인) 피험자로부터 측정된 데이터를 사용하여 분석하였다. 사전 상태에 따른 신호 인식 정확도의 차이 분석에 집중하기 위하여, 본 연구에서는 비교적 단순하며 사전 상태가 명확한 가위바위보 동작을 대상으로 선택하였으며, 각 동작시 활성화되는 근육인 손가락 편근, 앞손가락굽힘근, 긴엄지벌림근에 EMG 센서를 부착하여 근전도 신호를 측정하였다[13].

이 논문의 구성은 다음과 같다. 2장에서는 데이터 측정 동작, 데이터 전처리 과정에 관해 설명하고, 3장에서는 정규화 적용, 동작 인식을 위한 딥러닝 모델에 대해서 설명할 것이다. 4장에서는 결론 및 향후 연구에 관하여 기술하였다.

## 2. 근전도 데이터 측정

본 연구에서는 3개의 근전도 센서[14]와 7개의 전극을 사용하여 근육 움직임을 측정하였다. 각각의 전극은 피험자의 오른팔에 부착되었으며, 부착 위치는 Fig. 1과 같다. 근전도 센서는 아두이노를 통해 100Hz로 컴퓨터에 측정값을 전송하도록 하였으나, 하드웨어 상의 문제로 인해 실제로는 평균 76 Hz로 측정되었다.

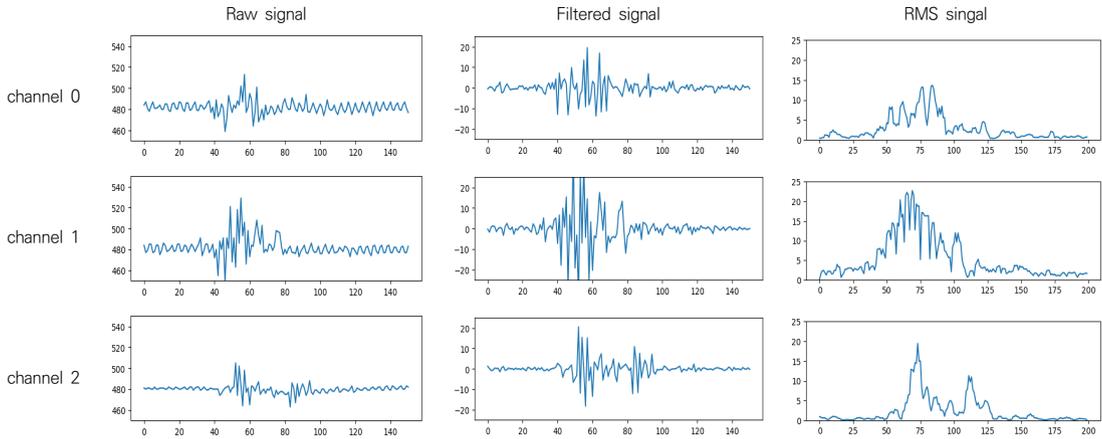


[Fig. 1.] Electrode location



[Fig. 2.] Electrode location

측정된 동작은 Fig. 2 사진과 같이 가위, 주먹, 보의 총 3개이며, 사전 상태는 다른 2개의 동작을 사용한다. 즉, 주먹 동작을 측정하는 경우 사전 상태가 가위인 경우와 사전 상태가 보인 경우를 둘 다 측정하였다. 측정은 피험자가 의자에 앉고, 책상에 오른팔을 얹은 상태로 진



[Fig. 3] EMG signals of hand gesture at each step

행되었다. 사전 상태와 측정 동작을 명시해준 후, 피험자가 사전 상태 상태로 기다리다 신호에 맞춰 측정 동작을 취하고, 약 1초 후 다시 사전 상태로 복귀하게 하였다.

피험자는 총 6개의 패턴에 대해 각각 6번의 태스크(Task)를 수행하였다. 각 태스크에서는 지정된 동작을 5회 반복하였으며, 각 동작은 3초에 한번씩 들려지는 신호음에 맞추어 수행하도록 하였다. 각 태스크 사이에는 30초간의 휴식시간이 제공되었다. 결과적으로, 20명의 피험자로부터 총 3600개의 데이터가 수집되었다.

측정한 데이터에는 5 Hz 고주파 필터와 노치 필터를 추가로 적용하였다. 딥러닝 모델 학습을 위해서 데이터 길이를 통일시켜줄 필요가 있으므로, 실제 샘플링 주파수를 기준으로 2초 분량만큼 자른 후, 100Hz로 오버샘플링하여 사용하였다. 또한, 일반적인 근전도 신호의 활용방법을 따라, 평균제곱근(RMS: rooted mean square)를 계산하여 신호를 변형하였다[15]. 집합이  $n$ 개의 원소로 구성되어 있고  $\{x_1, x_2, \dots, x_n\}$ 일 때,  $RMS(x_{RMS})$ 는 아래와 같다.

$$x_{RMS} = \sqrt{\frac{1}{n}(x_1^2 + x_2^2 + \dots + x_n^2)} \quad (1)$$

$x_i$ 가  $i$ 번째 데이터를 가리킬 때, 해당 위치의 RMS 값은 해당 위치의 앞, 뒤까지의 데이터로,  $\{x_{i-1}, x_i, x_{i+1}\}$ 를 의미한다.  $i-1$  또는  $i+1$ 이 데이터의 범위를 벗어나는 경우에는, 전체 데이터의 길이를 유지하기 위해 해당 범위를 제외하고 RMS를 계산하였다. Fig. 3은 EMG 원신호와 필터가 적용된 신호, 그리고 리샘플링 및 RMS가 적용된 신호를 나타낸다.

딥러닝의 원활한 학습을 위해 데이터는 각 채널별로 정규화되었다. Min-Max Scaler와 Z-Score의 두 가지 방법을 사용하여 정규화를 진행하였고, 각각의 결과에 대해 성능을 비교하였다. Min-Max Scaler는 데이터값의 범위를 0과 1 사이로 조정해주는 것으로, 아래의 수식을 사용하여 적용할 수 있다.

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

여기서  $X$ 는 특정 채널의 데이터,  $X_{\min}$ 과  $X_{\max}$ 는 각각 최솟값과 최댓값을 의미한다.

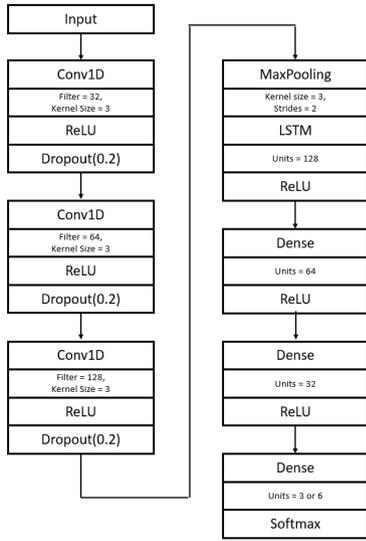
Z-Score는 데이터값을 평균이 0, 분산이 1이 되도록 조정해주는 것으로 아래의 수식을 사용하여 적용할 수 있다.

$$Z = \frac{X - \mu}{\sigma} \quad (3)$$

여기서  $\mu$ 는  $X$ 의 평균,  $\sigma$ 은 표준편차다.

### 3. 모델 학습

본 연구에서 사용된 딥러닝 모델은 Fig. 4와 같이 구성되었다. 이 모델은 시계열 데이터에 특화된 순환신경망의 일종인 LSTM(Long short-term memory)을 공간상의 특징을 추출하는 합성곱층과 함께 사용하여, 분류 성능을 향상시키고자 하였다[16]. 드롭아웃 층은 과적합을 방지하기 위한 목적으로 합성곱 층과 함께 사용하였다. 활성화 함수는 모든 층에서 ReLU를 사용하였다. 각 층의 하이퍼파라미터는 Fig. 4와 같다.



[Fig. 4] Neural network structure

수집된 데이터셋은 사전상태에 의한 영향을 분석하기 위해 4가지로 구성되었다(Table 1). 먼저, 사전 상태를 하나로 고정된 데이터셋이 사전상태의 조합에 따라 2개 존재한다. 세 번째 데이터셋은 다른 사전상태를 가진 동작들을 서로 다른 클래스로 분리하여 레이블링한 것으로, 총 6개의 패턴이 존재한다. 마지막 데이터셋은 사전 상태를 무시하고 최종 상태만을 사용해 레이블링한 것으로, 3개의 패턴으로 구성되었다. 즉, 사전 상태가 다른 두 클래스를 하나로 합친 것이다.

모델의 학습과 테스트를 위해 학습 데이터, 검증 데이터, 테스트 데이터를 64:16:20의 비율로 나누어 실험을 수행하였다. 학습 시에 학습율은 0.001, 배치 사이즈는 64, 에포크 횟수는 500으로 설정되었으며, 이 설정은 일부 데이터에 대한 실험을 통해 실험적으로 결정되었다.

모델을 학습을 위한 훈련 데이터에는 모델 정확도의 향상을 위해 스케일링(scaling), 윈도 슬라이스(window slice), 윈도 워프(window warp)라는 3가지의 데이터 증강 기법이 적용되었다[17, 18]. 스케일링은 데이터의 값들에 무작위 실수를 곱하는 것으로, 무작위 실수는 정규분포  $N(1, 0.01)$ 에서 추출하였다. 윈도 슬라이스는 데이터의 90%에 해당하는 구간을 무작위로 선택하고, 선택되지 않은 구간을 제거하는 기법이다. 윈도 워프는 데이터의 10%에 해당하는 구간을 무작위로 선택하고, 해당 구간의 길이를 0.5배 또는 2배로 보간하는 기법이다. 윈도 슬라이스와 윈도 워프의 경우 적용 후 데이터 증강 적용 전의 데이터와의 길이 통일을 위해 선형 보간 작업이 수행된다.

<Table 1> Dataset configurations

Dataset	Number of classes	Target patterns (Previous state)
Single previous state #1 (Single 1)	3	scissors (paper) rock (scissors) paper (scissors)
Single previous state #2 (Single 2)	3	scissors (rock) rock (paper) paper (rock)
Separated set (Separated)	6	scissors (paper) scissors (rock) rock (scissors) rock (paper) paper (scissors) paper (rock)
Mixed set (Mixed)	3	rocks (all) scissors (all) papers (all)

Table 2는 학습과 테스트 데이터의 사전 상태에 따른 분류 정확도를 나타낸다. 이 실험에서는 Min-Max Scaler를 사용해 데이터가 정규화되었다. 각 실험은 5회씩 반복되었으며, 이에 대한 평균, 최고, 최저 정확도가 표기되었다. 사전 상태가 동일한 경우(Single 1-Single 1 또는 Single 2-Single 2)에는 각 데이터셋에 대한 정확도가 88.4%와 90.8%로, 평균 89.6%의 정확도를 보였다. 하지만, 학습과 테스트 데이터의 사전 상태가 다르게 설정된 경우, 각 데이터셋에 대한 정확도는 58.6% (Single 1-Single 2) 와 46.7% (Single2-Single 1)로, 52.65%의 평균 정확도를 나타내었다. 이것은 사전 상태가 동일하게 지정된 경우에 비해 정확도가 60% 이하로 하락한 것으로, 사전 상태에 따라 신호의 패턴이 달라졌음을 의미한다.

<Table 2> Recognition accuracy of hand gestures according to train and test dataset pairs

Training set	Test set	Best	Avg	Worst
Single 1	Single 1	0.903	0.884	0.856
Single 2	Single 2	0.93	0.908	0.883
Single 1	Single 2	0.618	0.586	0.549
Single 2	Single 1	0.509	0.467	0.448
Separated	Separated	0.807	0.793	0.769
Mixed	Mixed	0.894	0.861	0.792

반면, 두 가지 사전상태를 가지는 데이터를 모두 사용하여 학습시키는 경우에는 정확도가 대폭 증가하였다. 사전상태가 다른 동작을 다른 패턴으로 간주한 경우에는 평균 79.3%, 사전 상태에 관계없이 최종 상태만을 인식한 경우에는 86.1%로 사전상태가 단일한 경우와 유사한 수준의 정확도를 달성하였다.

<Table 3> Hand gesture recognition accuracy according to normalization method

Experiments	Normalization method	Best	Avg	Worst
Single 1	Min-Max	0.903	0.884	0.856
	Z-Score	0.922	0.893	0.836
Single 2	Min-Max	0.93	0.908	0.883
	Z-Score	0.927	0.897	0.855
Separated	Min-Max	0.807	0.793	0.769
	Z-Score	0.857	0.8	0.768
Mixed	Min-Max	0.894	0.861	0.792
	Z-Score	0.886	0.871	0.86

<Table 4> Confusion matrix for the separated set of six patterns. (R, S, P denote rock, scissors, and paper respectively.) The confusions with the identical posterior states are highlighted in gray, and the confusion with the identical prior states are highlighted in yellow.

P \ T	S→P	S→R	P→R	P→S	R→P	R→S
S→P	97	12	1	7	3	0
S→R	4	103	9	0	1	3
P→R	1	14	82	22	0	1
P→S	1	2	11	104	0	2
R→P	18	3	3	1	87	8
R→S	0	5	1	5	1	108

<Table 5> Confusion matrix for the mixed set of six patterns.

True \ Pred	scissors	rock	paper
scissors	224	12	4
rock	23	213	4
paper	19	14	207

Table 3은 정규화 방법에 따른 정확도의 차이를 비교한 것이다. 전반적으로 Z-score를 사용하는 것이 근소하게 높으나(최대 1.0%p), 반복실험으로 나타난 최대/최소 정확도가 5%p가량 발생하는 것으로 미루어 볼 때, 이 차이를 유의미한 것으로 판단하기는 어렵다.

Table 4는 사전상태가 다른 데이터셋을 사용한 실험에 대한 혼동행렬이다. 5회의 실험 중 가장 높은 정확도를 보인 결과로부터 도출되었다. 혼동이 가장 많이 발생한 경우는 보에서 바위로의 움직임일 때, 보에서 가위로 움직임으로 혼동한 것(22회)이며, 두 번째와 세 번째는 각각 바위에서 보로 변하는 움직임일 때, 보에서 바위로 변하는 움직임일 때, 보에서 바위로 변하는 움직임으로 혼동한 것(18회)과, 보에서 바위로 변하는 움직임일 때, 가위에서 바위로 변하는 움직임으로 혼동한 것(14회)이다. 이

표로부터 대부분의 혼동이 사전상태가 같은 패턴(58회, 41.7%)이나 사후상태가 같은 패턴(51회, 36.7%)간에 발생한 것을 알 수 있으며, 사전-사후 상태가 반대인 경우에 발생한 혼동은 19회(13.7%)로 상대적으로 적었다.

Table 5는 혼합(mixed) 데이터셋에 대해 동일한 방식으로 혼동행렬을 계산한 것으로, 오차가 약 55% 수준으로 감소한 것을 알 수 있다. 오인식이 가장 많이 발생한 사후동작은 보이며, 혼동이 가장 많이 발생한 경우는 바위를 가위로 오인식한 것(23회)이다.

### 4. 결론

본 연구는 사전 상태가 근전도 기반의 손 제스처 인식 정확도에 미치는 영향을 실험적으로 파악하고, 문제의 해결 방안을 제시하였음에 그 의의가 있다. 향후 연구에서는 딥러닝 모델을 개선하고 파라미터를 최적화함으로 전반적인 성능의 개선을 도모하고자 한다. 또한, 본 연구에서 사용한 데이터셋은 사전/사후 상태의 수가 각각 3개로 비교적 작은 규모이지만, 지화 등과 같이 더 많은 동작의 데이터를 수집하여 연구를 확장할 수 있을 것이다. 이와 같은 연구는 향후 근전도 기반의 손 제스처 인식을 실용화하는데 중요한 역할을 할 수 있을 것으로 기대된다.

### REFERENCES

- [1] Korean Statistical Information Service[Internet], [https://kosis.kr/statHtml/statHtml.do?orgId=117&tblId=DT\\_11761\\_N003](https://kosis.kr/statHtml/statHtml.do?orgId=117&tblId=DT_11761_N003)
- [2] R.L.Weerasinghe and G.U.Ganegoda, "A Comprehensive Review on Vision-based Sign Language Detection and Recognition," 2022 International Research Conference on Smart Computing and Systems Engineering, Vol.5, pp.88-95, 2022.
- [3] S.A.M.A.S.Senanayaka, R.A.D.B.S.Perera, W.Rankothge, S.S.Usgalhe, H.D.Hettihewa and P.K.W.Abeygunawardhana, "Continuous American Sign Language Recognition Using Computer Vision and Deep Learning Technologies," 2022 IEEE Region 10 Symposium, pp.1-6, 2022.
- [4] I.H.Kim and I.H.Jung, "A Study on Korea Sign Language Motion Recognition Using OpenPose Based on Deep Learning," Journal of Digital Contents Society, Vol.22, No.4, pp.681-687, 2021.
- [5] S.Shin, Y.Baek, J.Lee, Y.Eun and S.H.Son, "Korean Sign Language Recognition Using EMG and IMU Sensors Based on Group-Dependent NN Models," 2017 IEEE

Symposium Series on Computational Intelligence, pp.1-7, 2017.

[6] D.G.Yuk and J.W.Sohn, "Hand Gesture Recognition Using Surface Electromyogram," Korean Soc. Noise Vib. Eng., Vol.28, No.6, pp.670-676, 2018.

[7] C.Savur and F.Sahin, "Real-Time American Sign Language Recognition System Using Surface EMG Signal," 2015 IEEE 14th International Conference on Machine Learning and Applications, pp.497-502, 2015.

[8] A.B.H.Amor, O.El Ghouli and M.Jemni, "A deep learning based approach for Arabic Sign Language Alphabet Recognition Using Electromyographic Signals," 2021 8th International Conference on ICT & Accessibility, pp.1-4, 2021.

[9] S.Yuan, Y.Wang, X.Wang, H.Deng, S.Sun, H.Wang, P.Huang and G.Li, "Chinese Sign Language Alphabet Recognition Based on Random Forest Algorithm," 2020 IEEE International Workshop on Metrology for Industry 4.0 & IoT, pp.340-344, 2022.

[10] J.Qi, G.Jiang, G.Li, Y.Sun, and B.Tao, "Surface EMG Hand Gesture Recognition System Based on PCA and GRNN," Neural Computing and Applications, Vol.32, pp.6343-6351, 2020.

[11] M.A.Ozdemir, D.H.Kisa, O.Guren, A.Onan, and A.Akan, "EMG Based Hand Gesture Recognition Using Deep Learning," In 2020 Medical Technologies Congress, pp.1-4, 2020.

[12] X.Chen, Y.Li, R.Hu, X.Zhang, and X.Chen, "Hand Gesture Recognition Based on Surface Electromyography Using Convolutional Neural Network with Transfer Learning Method," IEEE Journal of Biomedical and Health Informatics, Vol.25, No.4, pp.1292-1304, 2020.

[13] J.J.Park and C.K.Kwon, "Study on Forearm Muscles and Electrode Placements for CNN Based Korean Finger Number Gesture Recognition using sEMG Signals," Journal of the Korea Academia-Industrial Cooperation Society Vol.19, No.8, pp.260-267, 2018.

[14] Myoware muscle sensor[Internet], <https://www.digikey.com/en/maker/projects/myoware-muscle-sensor-kit/39ecba5502ad4c59ad0f7eca25b6e338>

[15] M.Jordanić, M.Rojas-Martínez, M.Maňanas, J.F.Alonso and H.R.Marateb, "A Novel Spatial Feature for The Identification of Motor Tasks Using High-Density Electromyography," Sensors, Vol.17, No.7, pp.1597, 2017.

[16] S.-H.Kim, H.-R.Shin, Y.Han, W.-D.Chang, Y.-J.Min, "Gesture Recognition of Writing Numbers Using Pressure Sensor Based on CNN-LSTM Combination Model, Journal of The Institute of Electronics and Information Engineers," 2023. (In press)

[17] T.T.Um, F.M.Pfister, D.Pichler, S.Endo, M.Lang, S.Hirche, U.Fietzek and D.Kulić, "Data Augmentation of Wearable Sensor Data for Parkinson's Disease Monitoring Using Convolutional Neural Networks," Proceedings of the 19th ACM International Conference on Multimodal Interaction, pp.216-220, 2017.

[18] A.L.Guennec, S.Malinowski, and R.Tavenard, "Data Augmentation for Time Series Classification Using Convolutional Neural Networks," ECML/PKDD Workshop on Advanced Analytics and Learning on Temporal Data. 2016.

최 현 태(Hyun-Tae Choi)

[준회원]



- 2023년 2월 : 부경대학교 컴퓨터 공학과 (공학사)
- 2023년 3월 ~ 현재 : 부경대학교 인공지능융합학부 석사과정

<관심분야>

딥러닝, 패턴인식, 시계열 신호처리, 컴퓨터비전

김 덕 화(Deok-Hwa Kim)

[준회원]



- 2023년 8월 : 부경대학교 컴퓨터 공학전공 (공학사)

<관심분야>

패턴인식, 딥러닝, 영상처리

장 원 두(Won-Du Chang)

[정회원]



- 2003년 2월 : 부산대학교 정보컴퓨터공학부 (공학사)
- 2005년 2월 : 부산대학교 컴퓨터 공학과 (공학석사)
- 2011년 3월 : Aizu Univ. (일) Info. Sys. Dept. (컴퓨터이공학박사)

- 2011년 8월 ~ 2013년 6월 : Mongolia Int. Univ. IT Dept. 조교수
- 2017년 3월 ~ 2020년 2월 : 동명대학교 전자및의용공학부 조교수
- 2020년 3월 ~ 현재 : 부경대학교 컴퓨터·인공지능 공학부 조교수/부교수

<관심분야>

패턴인식, 신호처리, 딥러닝, 영상처리, 헬스케어