

원형 근전도 센서 어레이 시스템의 센서 틀어짐에 강인한 손 제스처 인식

Hand Gesture Recognition Regardless of Sensor Misplacement for Circular EMG Sensor Array System

주성수*, 박훈기, 김인영, 이종실

S. S. Joo, H. G. Park, I. Y. Kim, J. S. Lee

요 약

본 논문에서는 원형 근전도 시스템 장비를 사용하여 근전도 패턴인식을 할 때, 장비의 센서 위치와 무관하게 패턴 인식이 가능한 알고리즘을 제안한다. 6가지 동작의 8채널 근전도 신호를 1초간 측정된 데이터를 이용하여 14개의 특징점을 추출하였다. 또한 8개의 채널에서 추출된 112개의 특징점을 나열하여 주성분분석을 하고 영향력이 높은 데이터만을 추려내어 8개의 입력 신호로 줄였다. 모든 실험은 k-NN 분류기를 이용하여 데이터를 학습시키고 5-fold 교차 검증을 사용하여 데이터를 검증하였다. 기계학습에서 데이터를 학습시킬 때, 어떤 데이터를 학습하느냐에 따라 그 결과가 크게 달라진다. 기존의 연구들에서 사용하는 학습 데이터를 사용 할 경우 99.3%의 정확도를 확인하였다. 그러나 센서의 위치가 22.5도 정도만 틀어지더라도 67.28%의 정확도로 명확하게 떨어짐을 보였다. 본 논문에서 제안하는 학습 방법을 사용 할 경우 98%의 정확도를 보이고 장비의 센서의 위치가 바뀌더라도 98% 근처의 정확도를 유지함을 보였다. 이러한 결과를 사용하여 원형 근전도 시스템을 사용하는 사용자들의 편의성을 크게 증대시켜 줄 수 있을 것으로 보인다.

ABSTRACT

In this paper, we propose an algorithm that can recognize the pattern regardless of the sensor position when performing EMG pattern recognition using circular EMG system equipment. Fourteen features were extracted by using the data obtained by measuring the eight channel EMG signals of six motions for 1 second. In addition, 112 features extracted from 8 channels were analyzed to perform principal component analysis, and only the data with high influence was cut out to 8 input signals. All experiments were performed using k-NN classifier and data was verified using 5-fold cross validation. When learning data in machine learning, the results vary greatly depending on what data is learned. EMG Accuracy of 99.3% was confirmed when using the learning data used in the previous studies. However, even if the position of the sensor was changed by only 22.5 degrees, it was clearly dropped to 67.28% accuracy. The accuracy of the proposed method is 98% and the accuracy of the proposed method is about 98% even if the sensor position is changed. Using these results, it is expected that the convenience of the users using the circular EMG system can be greatly increased.

Keyword : Bio-Signal Processing, EMG, Pattern Classification, Machine Learning, PCA

접 수 일 : 2017.11.20

심사완료일 : 2017.11.28

게재확정일 : 2017.11.29

* 주성수 : 한양대학교 생체의공학과 석사과정

seongsoo@bme.hanyang.ac.kr (주저자)

박훈기 : 한양대학교병원 가정의학과 교수

hoonkp@hanyang.ac.kr (공동저자)

김인영 : 한양대학교 의공학교실 교수

iykim@hanyang.ac.kr (공동저자)

이종실 : 한양대학교 의공학연구소 연구교수

netlee@hanyang.ac.kr (교신저자)

※ 이 연구는 국방과학연구소 생존성 기술 특화연구센터의 사업으로 지원을 받아 수행하였음. (No. UD150013ID)

1. 서론

최근에 IoT 기술이 발달하면서, 점차적으로 휴대용 기기를 사용하여 사용자의 동작을 인식하고 장비 간의 신호를 주고받는 일이 많아지고 있다. 이러한 기술을 HCI(Human Computer Interaction)라고 부르고 주로 다양한 사용자의 의도(생각)를 기계로 넣는 기술을 말한다[1]. 사용자의 의도를 알 수 있는 목소리, 시각, 제스처 등에서 활용 가능한 여러 생체 신호 중 근전도 신호는 사람이 의도하는 동작을 가장 직관적으로 알 수 있고, 오래 전부터 근전도 신호의 연구가 지속되어 왔다. 특히, 팔에서의 근전도 신호를 활용한 패턴 인식 연구는 인공 팔이나 수화 인식 등에서 많이 사용되고 최근 들어 엔터테인먼트적인 접근도 많아지고 있다[2].

팔에서의 Surface 근전도 패턴 인식 연구는 전극의 위치와 개수에 따라 많은 차이를 보이고 있다. 그 중 Multi-channel 방식과 High-Density 방식으로 많은 연구가 진행되고 있다[3-4]. Multi-channel 방식은 특정 근육 위치에 전극을 놓아 원하는 근육 신호를 얻는 방식으로, 특정 근육에 전극을 뚫으로써 상대적으로 적은 전극을 사용하여 높은 수준의 신호를 얻을 수 있다는 장점이 있다. High-Density 방식은 전극을 좁은 간격으로 두어 원하는 면적에서의 근육 신호를 얻는 방식으로 전극을 많이 사용하여 상대적으로 근육 신호를 분해(Decomposition)하여 세밀하게 관찰 할 수 있다. 또한, 최근 들어 팔이 원통형이라는 것에 착안하여 팔 둘레를 따라 전극을 두어 한 시점에 팔의 단면의 근전도 신호를 측정하여 패턴 인식을 진행하는 연구들이 증가하고 있다[5-6].

근전도 패턴 인식에서 결과에 많은 영향을 끼치고 많은 연구가 진행된 두 가지는 특징점 추출과 분류 알고리즘이다. 그 중 특징점 추출연구에서는 비교적 간단한 MAV(Mean Absolute Value)나 RMS(Root Mean Square)에서부터 Hjorth parameter 특징점까지 다양한 특징점들이 연구되어 있고 근전도 패턴 인식에서 많은 정확도의 향상을 가져왔다[7-8]. 나머지 하나인 분류 알고리즘은 LDA(Linear Discriminant Analysis), k-NN(k-Nearest Neighborhood), SVM(Support Vector Machine), ANN(Artificial Neural Network), GMM(Gaussian Mixture Model)등이 쓰이며 분류 알고리즘의 일반화가 많이 진행되었다[9-12].

그러나 기존의 연구들에서 전극의 위치가 조금 틀어지거나 전극의 위치가 완전히 바뀔 경우 정확

도가 현저하게 떨어진다. 실제로 관련 장비를 사용할 때 정확한 근육의 위치에 두고 사용해야 하며 위치가 바뀔 경우 그 정확도를 보장하지 못한다. 그러므로 사용자가 실 제품을 착용 할 시에는 전극의 위치를 정확하게 인지하고 사용해야 한다는 불편함이 존재한다.

따라서 본 논문에서는 이전 연구가 채널의 위치를 알아야 한다는 점을 개선하기 위하여 장비 착용 시의 채널의 위치와 관계없이 근전도 패턴 인식을 분류하는 알고리즘을 제안한다. 원형 근전도 시스템 장비를 가지고 장비가 틀어진 상황을 가정하여 여러 장비의 착용 각도에 대해 데이터를 측정하였다. 측정된 데이터를 사용하여 14개의 특징점을 사용하여 각 채널에서의 특징점을 추출하였다. 또한 주성분 분석을 통하여 전체 데이터에서 노이즈에 가까운 불필요한 특징점들을 제거하여 머신 러닝을 진행하였다. 머신러닝은 k-NN을 사용하여 학습 데이터와 테스트 데이터를 바꿔 가며 실험 결과를 나타내고 각 데이터는 5fold-cross validation을 활용하여 데이터를 검증하였다.

2. 원형 근전도 제스처 인식 알고리즘

2.1 제안하는 제스처 인식 알고리즘

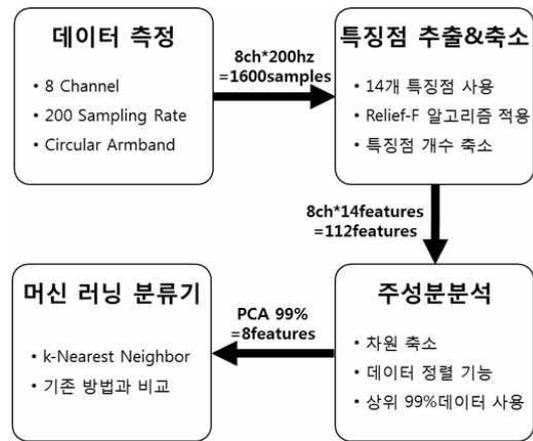


그림 1. 제스처 인식 알고리즘 개요도
Fig. 1. Outline of Gesture Recognition Algorithm

본 논문에서 제안하는 알고리즘은 그림 1과 같이 원형 근전도 시스템인 Armband를 통하여 8개 전극에서의 근전도 데이터를 1초 동안 받은 데이터를 받는다. 장비의 샘플링 레이트는 200Hz으로 8채널에서 1초 데이터는 총 1600sample의 데이터를 가진다. 측정된 데이터를 사용하여 각 채널의 1초 데이터를 각 채널별 14개의 특징점을 추출하였다. 특징

점들은 근전도 패턴 인식에서 사용하는 여러 논문들을 참고하여 사용하였고 Relief-F 알고리즘을 사용하여 유효하지 않은 특징점들을 제외하였다[13]. 유효하지 않은 특징점을 제외하고 추출된 총 특징점의 개수는 112개이다. 추출된 특징점을 주성분 분석을 거쳐 상위 99%의 영향력을 가지는 8개의 데이터만을 사용하였다. 전체 데이터에서 50%는 머신러닝의 훈련 데이터로 사용하고 나머지 50%는 테스트 데이터로 사용하였다.

2.2 데이터 획득

본 논문에서 데이터를 얻기 위해 사용한 장비는 그림 2.(a)와 같은 Thalmic Lab社의 Myo Armband다. 그림에서 숫자는 장비에서 제공하는 전극의 채널 번호를 뜻한다. 이 장비는 사용자의 노쪽손목굽힘근의 상단에 Myo의 4번 채널이 위치하도록 착용하고, 내부 8개의 EMG 센서를 통해 측정된 근전도 신호를 블루투스를 통해 컴퓨터로 전송한다. 컴퓨터에서는 Thalmic Lab社에서 제공하는 SDK 프로그램을 이용해 데이터를 받고, 200Hz의 Sampling Rate를 가진다.

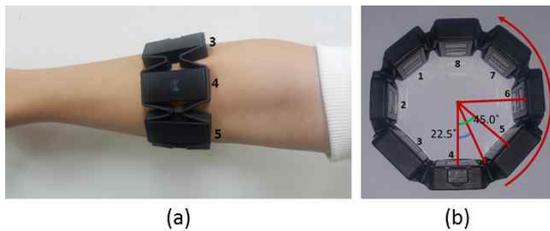


그림 2. (a) Thalmic Lab社 근전도 장비 (b) 데이터 획득에 사용한 장비의 회전각도
 Fig. 2. (a) Thalmic Lab Myo armband (b) The angle of rotation of the equipment used to acquire data.

데이터 측정에 참여한 연구 대상자는 20~30세 사이의 연령을 가진 10명(남: 8명, 여: 2명)의 지원자를 대상으로 하고 근전도 신호를 위한 동작 행위에 불편함이 없는 자를 대상으로 선정하였다. Thalmic Lab 사에서 제공하는 SDK 프로그램을 사용하여 MATLAB에서 GUI를 만들어 근전도를 측정하였다. 그림 3과 같이 손을 안으로 꺾는 동작, 손을 밖으로 꺾는 동작, 손을 펴는 동작, 주먹을 쥐는 동작, 휴식 상태, 손바닥을 위로 향하는 동작으로 총 6가지의 동작을 사용하여 근전도를 측정하였다. 각 실험 대상자의 팔에 장비를 착용하고 그림 2.(b)와 같이 4번 채널의 위치를 기준으로 22.5도씩

장비를 회전시켜 가며 지정된 동작 중의 근전도 데이터를 1초간 15번 측정하였다. 총 데이터의 개수는 14,400개(10명 × 16방향 × 6개 동작) 이다.

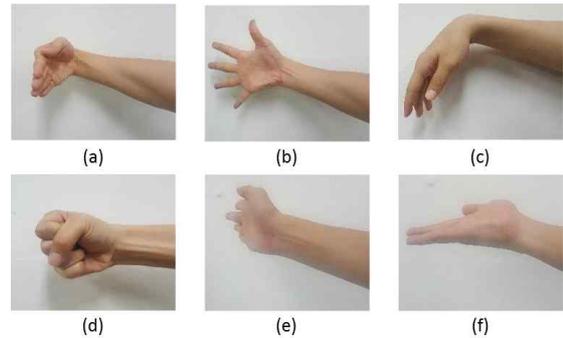


그림 3. 손의 6가지 움직임: (a) 손을 안으로 꺾는 동작 (b) 손을 펴는 동작, (c) 휴식 상태, (d) 주먹을 쥐는 동작, (e) 손을 밖으로 꺾는 동작, (f) 손바닥을 위로 향하는 동작
 Fig. 3. 6 Hand motion: (a) wrist flexion, (b) finger extension, (c) hand at rest, (d) hand close, (e) wrist extension, (f) forearm supination

2.3 특징점 추출

특징점 추출은 동작 분류 알고리즘에 있어 중요한 역할을 수행한다. 특징점 추출과 분류기의 알고리즘을 어떻게 하느냐에 따라 시스템의 성능차이가 크게 달라진다. 본 논문에서는 패턴 인식에서 많이 사용하는 시간 축에서의 여러 개의 특징점 중 Relief-F 알고리즘을 사용하여 추려낸 14개의 특징점인 적분값(Integrated EMG), 절대값평균(Mean Absolute Value: MAV), 변형된 절대값평균1(Modified MAV type1: MAV1), 변형된 절대값평균2(Modified MAV type2: MAV2), 제곱평균제곱근(Root Mean Square), 절대차분표준편차(Difference Absolute Standard Deviation Value: DASDV), 분산치(Variance of EMG: VAR), 신호의 길이(Waveform Length: WL), 최댓값(Max), 평균값(Mean), 변화량평균(Average Amplitude Change: AAC), Hjorth 파라미터(Hjorth mobility, Hjorth complexity)를 사용하였다. 8개의 전극에서 측정된 1초의 근전도 데이터를 사용하여 14개의 특징점을 채널별로 나열하여 총 112개의 특징점을 추출하였다[14].

112개의 특징점을 가진 총 데이터 전체를 주평균 분석을 사용하여 데이터의 개수를 줄이고자 하였다. 통상적으로 주평균분석을 통하여 얻은 데이터는 높은 영향력을 가지는 값일수록 데이터의 주요 신호

에 가깝고 낮은 영향력을 가지는 값 일수록 노이즈 데이터를 의미하게 된다[15]. 본 논문에서는 주평균 분석을 사용하여 사용하는 누적 영향력의 비율을 변경시키면서 패턴 인식의 정확도를 비교하여 최적의 비율을 선정하였다. 실험적으로 주평균분석의 누적 비율이 99.90%를 차지하는 8개의 데이터만을 사용하였을 때 정확도가 가장 높게 나왔다.

3. 실험 결과

EMG 패턴 인식에서 어떤 데이터를 학습 시키느냐에 따라 데이터의 결과가 많이 달라진다. 기존의 연구들에서는 전극의 위치를 고정시키고 그 위치에서 특정한 데이터만을 가지고 패턴 인식을 진행하여 근전도 데이터가 조금만 틀어질 경우 정확성이 많이 떨어지는 문제점을 가지고 있다. 본 논문에서는 특정한 확률 분포를 따르지 않는 비모수적 방법의 대표적인 알고리즘인 k-NN 패턴 분류 알고리즘을 사용하였다[16]. k-NN 패턴 분류 알고리즘을 사용하여 장비를 회전시켜 가며 얻은 16가지 방향에서의 근전도 신호를 가지고 5-Fold cross validation 으로 학습 데이터와 테스트 데이터를 바꿔 가며 정확성을 검증하였다. 본 논문에서 제안한 알고리즘의 성능을 비교하기 위하여 원형 장비에서 장비의 위치를 고정시키고 한 방향에서의 데이터만으로 학습 및 테스트 한 정확성과 기준 데이터로 학습 후 다양한 각도의 범위에서 장비를 회전시켜 전극의 위치를 바꾸어 획득한 데이터를 테스트한 결과의 정확성을 비교하였다.

그림 4는 기존 근전도 패턴 인식에서 널리 연구되던 한 방향에서의 데이터만을 사용하여 기계학습을 한 결과이다. 6개의 동작 모두 높은 정확성을 가지고 평균 99.3%로 14개의 특징점과 주성분 분석을 통한 데이터를 사용하여 6가지의 패턴을 모두 분류 가능하다.

기존의 연구 방법들은 전극의 위치가 정확하게

위치하지 않고 조금만 틀어져도 그 정확도가 현저하게 낮아진다. 표 1은 기준 데이터를 가지고 학습시킨 상황에서 장비의 착용 각도를 바꿔 가며 패턴 분류의 정확성을 나타낸다. 장비의 각도가 22.5도 정도의 각도만 틀어져도 정확성이 67.28%로 낮아지고 장비 착용 각도가 더 틀어질 경우 패턴 분류가 전혀 되지 않는다.

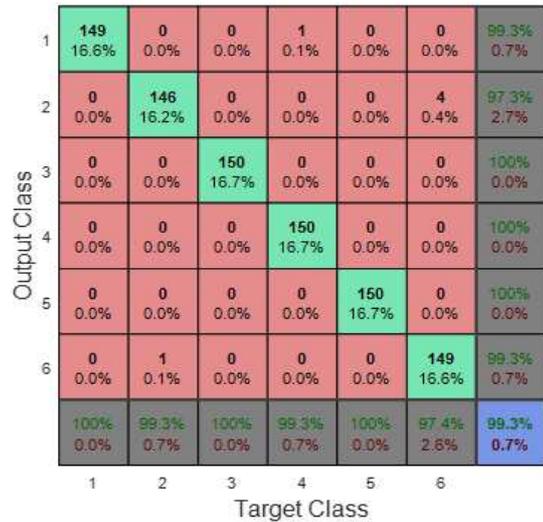


그림 4. 기준 위치에서의 패턴 인식 결과
Fig. 4. Pattern classification result at base position

본 논문에서 제안한 알고리즘대로 장비가 틀어진 상황을 가정하고 측정된 데이터를 모두 사용하여 데이터 학습을 시키고 테스트하였다. 그림 5는 장비를 22.5°씩 16번 돌린 데이터를 모두 학습 및 테스트 데이터로 활용 할 경우의 정확도를 나타낸다. 다양한 각도에서의 데이터를 모두 사용하여도 8개의 채널 데이터가 중복되지 않아 6개의 클래스를 모두 분류 가능하며 98.22%의 정확도를 가진다. 또한 표 2처럼 회전을 시킨 경우에 기존의 방법과 비교하여 대체적으로 98%의 정확도를 가진다.

표 1. 기존 방법을 사용한 틀어진 정도에 따른 패턴 인식 정확성

Table 1. Accuracy of Pattern Recognition according to the degree of difference using existing methods

회전 각도	0°	±22.5°	±45.0°	±67.5°	±90.0°	±112.5°	±135.0°	±157.5°	±180.0°
정확도	99.3%	67.28%	27.28%	20.17%	21.00%	21.17%	21.33%	19.33%	19.44%

표 2. 제안한 방법을 사용한 틀어진 정도에 따른 패턴 인식 정확성

Table 2. Accuracy of Pattern Recognition according to the degree of difference using proposed methods

회전 각도	0°	±22.5°	±45.0°	±67.5°	±90.0°	±112.5°	±135.0°	±157.5°	±180.0°
정확도	98.22%	98.78%	98.89%	98.67%	98.33%	97.44%	98.89%	98.89%	97.11%

Output Class	1	2296 15.9%	10 0.1%	4 0.0%	39 0.3%	31 0.2%	20 0.1%	95.7% 4.3%
	2	4 0.0%	2333 16.2%	7 0.0%	7 0.0%	16 0.1%	33 0.2%	97.2% 2.8%
	3	3 0.0%	4 0.0%	2389 16.6%	1 0.0%	0 0.0%	3 0.0%	99.5% 0.5%
	4	26 0.2%	4 0.0%	0 0.0%	2367 16.4%	2 0.0%	1 0.0%	98.6% 1.4%
	5	11 0.1%	8 0.1%	0 0.0%	0 0.0%	2376 16.5%	5 0.0%	99.0% 1.0%
	6	8 0.1%	11 0.1%	0 0.0%	0 0.0%	7 0.0%	2374 16.5%	98.9% 1.1%
			97.8% 2.2%	98.4% 1.6%	99.5% 0.5%	98.1% 1.9%	97.7% 2.3%	97.5% 2.5%
		1	2	3	4	5	6	
		Target Class						

그림 5. 장비의 여러 각도에서의 데이터를 사용한 패턴 인식 결과

Fig. 5. Pattern classification results using data from various angles of equipment

4. 결론 및 고찰

본 논문에서는 원형 근전도 장비를 사용하여 팔에서의 동작 분류 시, 장비의 회전과 무관한 패턴 인식 방법에 대해 제안하였다. 장비의 틀어진 상황을 가정한 데이터를 측정하고 특징점 추출 후 학습 데이터에 추가하여 머신 러닝을 적용시켰다. 여러 장비의 틀어진 상황을 가정하더라도 머신 러닝을 학습 시 초평면에서의 데이터가 섞이지 않고 98%의 정확도로 구분이 잘 되는 것을 확인 할 수 있었다. 이는 8개의 채널에서 측정된 데이터의 신호의 크기가 회전을 시키더라도 기존 동작들의 데이터와 중복이 되지 않음을 의미한다. 이 결과로 인해 원형 장비를 착용 할 때 사용자가 장비의 방향을 항상 고려하여 사용하여야 하는 불편함을 효과적으로 제거할 수 있을 것으로 보인다.

그러나 패턴 분류에 사용한 동작들이 기존에 연구되던 방식의 결과가 99.3%로 나온 것으로 보아 상대적으로 분류가 쉬운 동작들이라 볼 수 있다. 이러한 동작은 엔터테인먼트용으로 사용하기에 적합하나 수화나 인공 팔처럼 더 많은 패턴의 분류가 필요하거나 손가락 분류처럼 더 작은 근육을 사용하는 동작들에 있어서는 주파수 분석과 같은 다른 범위에서의 특징점을 사용하여야 할 것으로 보인다.

근전도 신호는 대략 500Hz 이상의 주파수 특성을 가지고 있다. 전반적인 근전도 패턴 분류에 관한 연구는 각 전극 당 1k이상의 Sampling Rate으로 데이

터를 획득하여 주파수 특성을 분석 할 수 있으나, 본 논문에서 사용한 장비는 200Hz Sampling rate를 가지고 있어 주파수 분석에 의한 유효한 특징점을 잡을 수 없었다.

향후 연구에서 장비의 틀어짐과 무관한 더 다양한 동작들을 분류할 예정이며, 시간 축에서의 특징점 뿐만 아니라 더 높은 Sampling rate를 가지는 장비를 사용하여 다양한 방향에서의 특징점을 가지고 패턴 분류 알고리즘을 더 고도화 할 예정이다.

REFERENCES

- [1] Ahsan, Md Rezwatul, Muhammad I. Ibrahimy, and Othman O. Khalifa. "EMG signal classification for human computer interaction: a review.", *European Journal of Scientific Research*, vol 33, no. 3, pp. 480-501, 2009.
- [2] Abreu, Teixeira and Figueiredo, "Evaluating Sign Language Recognition Using the Myo Armband." XVIII Symposium on Virtual and Augmented Reality(SVR) on IEEE, 2016.
- [3] W Geng, Y Du and W Jin, "Gesture recognition by instantaneous surface EMG images." *Scientific reports*, 6, 36571, 2016.
- [4] E. C. Jeong, S. J. Kim, Y. R. Song, S. M, Lee. "Artificial Neural Network based Motion Classification Algorithm using Surface Electromyogram", *Rehabilitation Engineering & Assistive Technology Society of Korea*, vol. 6, no. 1, pp. 67-74, 2012.
- [5] Khushaba, Rami N. et al., "Combined influence of forearm orientation and muscular contraction on EMG pattern recognition.", *Expert Systems with Applications*, vol. 61, pp. 154-161, 2016.
- [6] Sathiyarayanan, Mithileysh, and Sharanya Rajan., "MYO Armband for physiotherapy healthcare: A case study using gesture recognition application.", *Communication Systems and Networks*, 8th International Conference on. IEEE, 2016.
- [7] Phinyomark, Angkoon and Pornchai Phukpattaranont, and Chusak Limsakul, "Feature reduction and selection for EMG signal classification." *Expert Systems with Applications*, vol. 39, no. 8, pp. 7420-7431, 2012.
- [8] Caesarendra and Wahyu, "A classification method of hand EMG signals based on principal component analysis and artificial neural network." *International*

Conference on Instrumentation, Control and Automation (ICA), Bandung, Indonesia, August, 2016.

[9] Purushothaman, Geethanjali, and K. K. Ray. "EMG based man-machine interaction-A pattern recognition research platform." *Robotics and Autonomous Systems*, vol. 62, no. 6, pp. 864-870, 2014.

[10] Ahsan, Md Rezwatul and Muhammad I. Ibrahimy, "EMG signal classification for human computer interaction: a review." *European Journal of Scientific Research*, vol. 33, no. 3, pp. 480-501, 2009.

[11] Ariyanto and Mochammad, "Finger movement pattern recognition method using artificial neural network based on electromyography (EMG) sensor." *Automation, Cognitive Science, Optics, Micro Electro-Mechanical System, and Information Technology (ICACOMIT)*, Bandung, Indonesia, pp. 29-30, 2015.

[12] Y. R. Song, S. J. Kim, E. C. Jeong, S. M. Lee., "A Gaussian Mixture Model Based Pattern Classification Algorithm of Rorearm Electromyogram", *Rehabilitation Engineering & Assistive Technology Society of Korea*, vol. 5, no. 1, pp. 95-101, 2011.

[13] Sapsanis, Christos, George Georgoulas, and Anthony Tzes., "EMG based classification of basic hand movements based on time-frequency features." *Control & Automation (MED)*, 21st Mediterranean Conference on. IEEE, 2013.

[14] Federolf, P. A., K. A. Boyer and T. P. Andriacchi. "Application of principal component analysis in clinical gait research: identification of systematic differences between healthy and medial knee-osteoarthritic gait." *Journal of biomechanics*, vol. 46, no. 13, pp. 2173-2178, 2013.

[15] Bosco and Gianfranco. "Principal component analysis of electromyographic signals: an overview." *The Open Rehabilitation Journal*, vol. 3, no. 1, pp. 127-131, 2010.

[16] Al-Faiz, Mohammed Z, A. Ali and Abbas H. Miry, ""A k-nearest neighbor based algorithm for human arm movements recognition using EMG signals." *Energy, Power and Control (EPC-IQ)*, Basrah, Iraq, November, 2010.



주 성 수(SeongSoo Joo)

2016년 2월 인제대학교 의용공학과 졸업(학사)
2016년 - 현재 한양대학교 의생명공학전문대학 생체 의공학과 석사과정

Interest: Bio-signal processing, Rehabilitation engineering



박 훈 기(HoonKi Park)

1987년 서울대학교 의과대학 의학과 졸업(학사)
1993년 서울대학교 보건 대학원 의학과(석사)
1999년 서울대학교 대학원 가정의학 (박사)

1993년 - 1994년 서울대학교병원 가정의학과 전임강사
1994년 - 1995년 단국대학교 의과대학 가정의학교실
1995년 - 현재 한양대학교 의과대학 가정의학교실 교수

Interest: Bio-signal Monitoring, Sports Medicine



김 인 영(InYoung Kim)

1989년 2월 서울대학교 의과대학 의학과 졸업(학사)
1991년 2월 서울대학교 대학원 의학과 의공학전공 졸업(석사)

1994년 2월 서울대학교 대학원 의학과 의공학전공 졸업(박사)
1994년 5월 - 2000년 2월 삼성중합기술원 수석연구원
2000년 3월 - 현재 한양대학교 의과대학 의공학교실 교수

Interest: Biosignal Monitoring, Rehabilitation engineering, Neural engineering



이 종 실(JongShill Lee)

1995년 2월 인하대학교 전자공학과 졸업(공학사)
1997년 2월 인하대학교 대학원 전자공학과 졸업(공학석사)

2005년 2월 인하대학교 대학원 전자공학과 졸업(공학박사)
2005년 3월 - 현재 한양대학교 의공학연구소 연구교수

Interest: Biosignal processing, Rehabilitation engineering, Biometrics