

표면 근전도를 이용한 Artificial Neural Network 기반의 동작 분류 알고리즘 Artificial Neural Network based Motion Classification Algorithm using Surface Electromyogram

정의철*, 김서준, 송영록, 이상민

E. C. Jeong, S. J. Kim, Y. R. Song, S. M, Lee

요 약

본 논문에서는 표면 근전도 신호를 사용하여 손목 움직임의 동작을 분류하기 위해 인공 신경 회로망(ANN : Artificial Neural Network)기반의 동작 분류 알고리즘을 제안한다. 손목 움직임에 무리가 없는 20~30대 성인 26명을 대상으로 척측 수근 굴근과 척측 수근 신근에 부착한 2채널의 전극으로부터 표면 근전도 신호를 취득하고, 취득한 근전도로부터 손목의 굴곡, 신전, 내전, 외전, 휴식 다섯 동작을 인식한다. 빠른 처리 속도를 위해 획득한 신호로부터 시간 영역에서의 특징점을 추출하고 ANN을 이용한 동작 분류에 사용된다. 특징점으로 DAMV, DASDV, MAV, RMS를 사용하였으며, ANN 기반의 동작 분류의 인식율은 DAMV는 98.03%, DASDV는 97.97%, MAV는 96.95%, 그리고 RMS는 96.82%의 정확도를 나타낸다.

ABSTRACT

In this paper, Artificial Neural Network(ANN) based motion classification algorithm is proposed to classify wrist motions using surface electromyograms(sEMG). surface EMGs are obtained from two electrodes placed on the flexor carpi ulnaris muscle and extensor carpi ulnaris muscle of 26 subjects under no strain condition during wrist motions and used to recognize wrist motions such as up, down, left, right, and rest. Feature is extracted from obtained EMG signals in time domain for fast processing and used to classify wrist motions using ANN. DAMV, DASDV, MAV, and RMS were used as features and accuracies of motion classification based on ANN were 98.03% for DAMV, 97.97% for DASDV, 96.95% for MAV, 96.82% for RMS.

Keyword : Artificial Neural Network, EMG, pattern classification, feature extraction

1. 서론

최근 HCI(Human Computer Interface) 기술 및 사지 절단 장애인을 위한 재활 공학의 일환으로 표면 근전도(the surface electromyogram, sEMG)를 장치 제어 수단으로 활용하려는 연구가 증가하고 있다[1]. 이를 위해서는 EMG신호의 특성을 잘 이해하고, 획득, 처리, 분석하는 기술이 필요하다. EMG 신호의 측정방법 중 하나인 피부 표면에서 측정하는 방법은 비용효과가 뛰어나고 사용이 편리하다는 장점을 가지고 있어 널리 사용되어 왔다[2]. EMG신호는 근육의 수축시에 발생하는 전기적 신호로서 척수에서 신경임펄스가 발생되어 운동뉴런을 활성화

접 수 일 : 2012.06.07

심사완료일 : 2012.06.11

게재확정일 : 2012.06.18

* 정의철 : 인하대학교 전자공학과 석사과정

kaisergod@naver.com (주저자)

김서준 : 인하대학교 전자공학과 석사과정

wodud4435@naver.com (공동저자)

송영록 : 인하대학교 전자공학과 연구교수

gatway32@inha.ac.kr (공동저자)

이상민 : 인하대학교 전자공학과 교수

sanglee@inha.ac.kr (교신저자)

※ 본 연구는 지식경제부 및 정보통신산업진흥원의 IT융합 고급인력과정 지원사업의 연구결과로 수행되었음 (NIPA-2012-센터별 과제번호)

화 시키고 이에 따라 운동단위(motor unit)내의 근 섬유가 활성화되면서 전위차(motor unit action potential)가 발생하는데 이 현상은 피부 표면 전극에 의한 공간적 합으로서 추출이 가능하다[3].

손목 근육에서 발생하는 EMG신호는 임상신경학이나 신경근육 문제 등에 널리 사용되어 왔다. 또한 모터 제어, 운동 장애, 보행 분석, 운동 생리학 등 많은 연구에도 사용되어 왔다[4]. 기존의 연구에서는 wavelet 기반의 방법으로 근전도 패턴을 분류하는 연구[5]와 K-Nearest Neighbor(k-NN)과 genetic algorithm(GA)를 이용한 근전도 패턴 인식 기법 등이 연구되었다[6]. 또한 Gaussian Mixture Model(GMM)을 사용하여 근전도 신호를 분류하는 연구[7]과 Fuzzy Logic System을 사용하여 근전도 기반의 보조기기 제어를 연구하였다[8].

본 논문에서는 전완부 절단 환자의 의수나 손목 재활을 필요로 하는 환자, 혹은 힘이 없는 노약자 등을 위한 손목 보조기기의 사용에 있어서 손목의 굴곡, 신전, 내전, 외전, 휴식 등의 다섯 가지 동작을 분류하는 표면 근전도를 이용한 인공 신경 회로망(ANN : Artificial Neural Network) 기반의 동작 분류 알고리즘을 제안한다. 근전도의 패턴 분류에 있어 가장 중요한 특징점 선택에 있어서 기존의 주파수 영역에서 추출하는 방법이 아닌 비교적 간단한 계산과정을 요구하는 시간 영역에서의 특징점을 추출하였다. 사용되는 특징점으로는 절대차분평균치(DAMV : Difference Absolute Value)[9], 절대차분 표준편차(DASDV : Difference Absolute Standard Deviation Value)[10], 평균절대값(MAV : Mean Absolute Value)[11], 제곱평균제곱근(RMS : Root Mean Square)[12]가 있다.

제한한 동작 분류 알고리즘의 성능을 검증하기 위해서 건강한 20~30대 성인 26명(남성 22명, 여성 4명)을 대상으로 실험을 실시하였다. 여기서 측정된 데이터를 이용하여 알고리즘을 학습시키고, 24시간이 지난 뒤 동일한 피실험자를 상대로 같은 실험을 실시하여 측정된 신호를 학습시킨 알고리즘에 입력함으로써 정확한 동작 분류의 여부를 확인한다.

2. ANN 기반의 동작 분류 알고리즘

논문에서는 손목의 굴곡, 신전, 내전, 외전, 휴식 동작을 분류하기 위해서 그림 1과 같은 ANN 기반의 표면 근전도 패턴 분류 알고리즘을 제안한다. 근전도 신호를 측정하고 측정된 신호를 대역 통과 필터를 거친 후 특징점 추출을 위한 time-window의

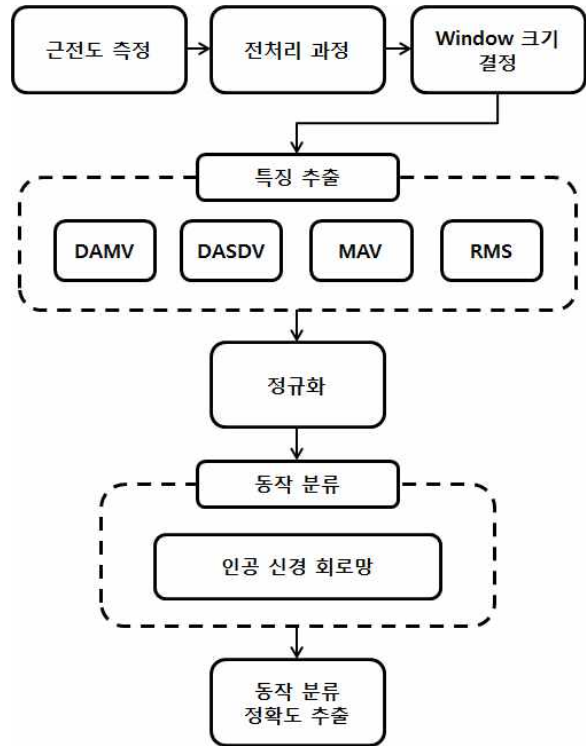


그림 1. ANN 기반의 동작 분류 알고리즘 흐름도

길이를 결정한다. 결정된 time-window내의 데이터를 이용하여 근전도 신호의 특징점(DAMV, DASDV, MAV, RMS)를 추출하고, 이 특징점들을 적용하여 ANN 기반의 동작 분류를 실행한다.

2.1 근전도 측정 및 전처리 과정

본 논문에서는 그림 2와 같이 손목의 굴곡, 신전, 내전, 외전, 휴식 다섯 가지 동작을 인식한다. 손목 움직임을 구별하기 위하여, 손목 움직임을 주로 주관하는 척측 수근 굴근(Flexor Carpi Ulnaris Muscle)과 척측 수근 신근(Extensor Carpi Ulnaris



그림 2. 손목의 다섯 가지 동작 상태

Muscle)에 4개의 표면전극을 부착하여 2채널로 근전도를 측정한다. 그림 3은 측정한 근육의 위치와 전극의 위치를 나타냈다. 사용된 전극은 Ag/AgCl 표면 전극을 사용하였다. 근전도는 0~10mV의 진폭을 가지며 0~1.5mV의 실효값(rms)을 가진다. 사용 가능한 근전도 신호는 0~500Hz에 분포하고 있으며 50~150Hz에 에너지가 집중되어 있다[13]. 본 논문에서는 BIOPAC사의 MP150WSW와 BN-EMG2 앰프를 이용하여 2000의 이득값으로 증폭되고 10~500Hz 대역 제한된 근전도 신호를 획득한다. 다음으로 획득된 근전도 신호는 동작 분류를 위해서 1kHz로 샘플링된다. 동작 분류 알고리즘에서 원신호를 대변하는 특징점을 추출하기 위한 time-window의 길이를 설정하는 것은 매우 중요하다. 기존의 많은 연구에서는 실시간 처리를 위해 time-window의 길이를 150~300ms로 설정했다. 본 논문에서는 실시간 처리를 위한 동작 분류 방법을 제안하는 것은 아니지만 향후 연구를 위해 time-window 길이를 166ms로 설정하였다.

2.2 특징점 추출

EMG 신호는 근육 세포조직의 특성 및 인체 생리학적 간섭에 의해 많은 영향을 받으며, 60Hz 전원 노이즈, 컴퓨터나 주변 전자기기의 사용에 의한 외부 노이즈, 전극과 측정기기에 의해서 많은 영향을 받는다. 따라서 동작 분류의 성능은 원신호를 대변하는 특징점의 선택에 따라 크게 달라진다[9]. 기존의 많은 연구에서는 푸리에 변환을 통해 주파수 영역에서 근전도 신호를 분석해 왔다. 하지만 푸리에 변환은 분석되는 신호가 안정적이지 않으면 푸리에 변환에 적합하지 않기 때문에 신호가 안정적이어야 한다는 가정을 가지고 있다[14]. 이는 비안정적인 특징을 가지는 근전도 신호에는 푸리에 변환이 적합하지 않으며, 계산과정이 복잡하다는 단점이 있다. 따라서 본 논문에서는 최근 연구에 널리 사용되고 비교적 계산과정이 간단한 시간 영역에서 특징점을 추출한다.

특징점은 다음과 같은 기법을 사용하여 추출한다.

1. Difference absolute mean value(DAMV) : 근전도 신호의 인접한 두 데이터 샘플간의 차이의 평균을 나타내는 값으로 식(1)로 정의된다.

$$DAMV = \frac{1}{N-1} \sum_{k=1}^{N-1} |X_{k+1} - X_k| \quad (1)$$



(a) 척추 수근 굴근 (b) 척추 수근 신근

그림 3. 근전도 측정을 위한 전극의 위치

2. Difference absolute standard deviation value(DASDV) : 근전도 신호의 인접한 두 데이터 샘플간의 표준편차를 나타내는 값으로 식(2)로 정의된다.

$$DASDV = \sqrt{\frac{1}{N-1} \sum_{k=1}^{N-1} (X_{k+1} - X_k)^2} \quad (2)$$

3. Mean absolute value(MAV) : 근전도 신호의 절대평균값으로 각 데이터 샘플의 절대값의 평균을 나타내며 식(3)으로 정의된다.

$$MAV = \frac{1}{N} \sum_{k=1}^N |X_k| \quad (3)$$

4. Root mean square(RMS) : 근전도 신호의 각 데이터 샘플들의 제곱값의 평균을 나타내는 값으로 식(4)로 정의된다.

$$RMS = \sqrt{\frac{1}{N} \sum_{k=1}^N X_k^2} \quad (4)$$

추출된 특징점들은 정규화 과정을 거치게 된다. 정규화 과정을 거치면서 근전도 신호로부터 추출한 특징점들은 일정한 범위안의 값들로 변환된다. 다음의 식(5)는 정규화 과정을 나타낸다.

$$Value' = \frac{Value - \min_{mean}}{\max_{mean} - \min_{mean}} \quad (5)$$

여기서 Value는 근전도 신호로부터 추출한 특징점이고 Value'는 정규화 과정을 거친 일정한 범위안의 값이다. \max_{mean} 과 \min_{mean} 은 각 동작에 해당

하는 특징점들의 평균값 중 가장 큰 값과 가장 작은 값이다.

2.3 인공 신경 회로망(ANN)

손목의 움직임 분류를 위해서 인공 신경 회로망(ANN)을 사용한다. ANN은 각 채널(CH1, CH2)에서 획득한 근전도 신호로부터 추출된 한 특징점의 값을 입력으로 하여 원하는 동작을 분류한다. 분류하기 위한 손목 움직임의 종류는 굴곡, 신전, 내전, 외전, 휴식 등 다섯 가지의 동작이므로 본 논문에서는 다층 퍼셉트론(MLP : Multi-Layer Perceptron)을 사용하여 학습시킨다. MLP의 입력층(input layer)은 2개의 노드, 은닉층(hidden layer)은 5개의 노드, 출력층(output layer)은 5개의 노드를 사용하여 구성하였고, 출력층의 5노드에 굴곡, 신전, 내전, 외전, 휴식으로 할당하여 입력 데이터가 해당 출력 노드에 유사할 경우 해당 출력 노드의 값이 1에 가까운 출력이 나오도록 하였다. 그림 4는 MLP의 구조를 나타낸다.

ANN의 학습을 위해 손목의 각 움직임에 해당하는 출력결과를 설정하여 역전파(back-propagation) 알고리즘을 사용하여 학습시킨다. 역전파 알고리즘의 학습은 전향 단계와 후향 단계로 이루어진다. 학습에서 중요한 것은 가중치의 갱신인데 역전파 알고리즘은 후향 단계에서 가중치의 갱신이 이루어진다. 전향단계는 신경 회로망에 입력 패턴을 제시하고, 각 노드에 대해서 입력 함수와 활성화 함수를 이용하여 출력을 산출하는 단계이다. 이 때 입력 신호는 전방향 즉, 출력층 방향으로만 전달된다. 초기에 임의로 정한 가중치에 의하여 출력층에서 출력값은 목표 값과 당연히 일치하지 않고 큰 오차를 발생하게 된다. 후향 단계는 목표 출력과 실제 출력의 차이를 계산하여 오차를 구하고, 이를 역방향 즉, 출력층에서 입력층으로 순서대로 층과 층 사이의 가중치를 갱신하는 단계이다. 연결 강도를 조절 한 후, 다시 입력을 넣어 계산하면 출력은 처음 시도 때보다 오차가 작은 값을 얻게 된다. 이를 반복 하면 총 오차의 합이 줄어들게 되며 본 논문에서는 반복 횟수를 400번으로 지정하였다.

가중치를 조정할 때 그 보정 값을 오차에 비례하게 해주는 것은 델타 규칙에 LMS 학습 규칙을 적용하여 일반화한 델타 규칙(Generalized Delta Rule)으로 행하게 된다. 즉 다층 구조에서 계층마다 역방향으로 차례대로 이 방법을 적용한다. MLP의 입력층이 i 개, 은닉층이 j 개, 출력층이 k 개라고 가정하면,




그림 4. 다층 퍼셉트론의 구조

은닉층 j 번째의 유니트에 대한 입력의 합은

$$net_{pj} = \sum_i W_{ji} O_{pi} \quad (6)$$

이고, 노드 j 번째의 출력은

$$O_{pj} = f(net_{pj}) \quad (7)$$

이다. 여기서 f 는 시그모이드 활성화 함수이므로

$$O_{pj} = \frac{1}{1 + \exp(-net_{pj})} \quad (8)$$

가 된다. 마찬가지로 출력층 k 번째의 유니트에 대한 입력의 합은

$$net_{pk} = \sum_j W_{kj} O_{pj} \quad (9)$$

이고, k 번째 유니트의 출력은

$$O_{pk} = f(net_{pk}) \quad (10)$$

가 된다. 일반적으로 출력 O_{pk} 는 원하는 값 t_{pk} 와 같지 않기 때문에 각각의 패턴에 대한 오차는 다음과 같다.

$$E = \frac{1}{2} \sum_k (t_{pk} - O_{pk})^2 \quad (11)$$

일반화 델타 규칙은 LMS 학습 규칙을 이용하여 이 오차 E 를 최소로 하는 가중치를 구한다. 이 방법은 가중치의 미분값을 구하여 이 값에 비례해서 가중치를 변화시킬 양을 산출하는 방법이다.

3. 실험 및 결과

3.1 실험 방법

본 논문에서는 손목 움직임에 무리가 없는 20~30대 성인 26명(남성 22명, 여성 4명)을 대상으로 실험을 실시하였다. 각 피 실험자는 척추 수근 굴근과 척추 수근 신근에 전극을 부착하고 5초간 휴식을 취한 후, 각 동작을 5초간 실시한다. 각 동작 사이에 5초의 휴식을 가지고 마지막 동작을 취한 뒤 다시 5초의 휴식을 취하여 총 45초의 근전도 신호를 획득한다. 획득한 근전도 신호는 크기가 166ms인 time-window를 이용하여 각 동작당 30개의 특징점 값을 추출하고, 이 값들은 정규화 과정을 거친 뒤 제안한 알고리즘의 학습 데이터로 입력된다.

제안한 알고리즘의 성능을 확인하기 위해 24시간이 지난 후 동일 피실험자를 상대로 위의 실험을 실시하였다. 여기서 획득한 근전도 신호는 같은 방법으로 특징점 값을 추출하고, 이 값들은 앞서 학습된 알고리즘의 입력으로 사용되어 제안한 동작 분류 알고리즘의 성능을 확인하였다.

3.2 실험 결과

본 논문에서는 ANN 기반의 표면 근전도 패턴 분류 알고리즘의 성능을 확인하기 위해 하나의 특징점을 이용한 채널별 분류를 수행하였고, 패턴 분류에 사용된 특징점으로 간단한 계산과정을 고려한 DAMV, DASDV, MAV, RMS를 사용하였다.

피실험자의 근전도 신호로부터 추출된 특징점을 사용하여 알고리즘의 학습시키고, 학습에 참여하지 않은 신호를 학습 시킨 결과에 입력함으로써 제안한 알고리즘의 성능을 확인하였다.

그림 5은 ANN의 학습이 진행되는 과정에서 오차의 변화를 그래프로 나타냈다. 반복횟수가 지날수록 오차가 줄어드는 것을 확인 할 수 있다.

ANN 기반의 동작 분류의 경우, DAMV를 특징




그림 5. 반복 회수에 따른 오차그래프

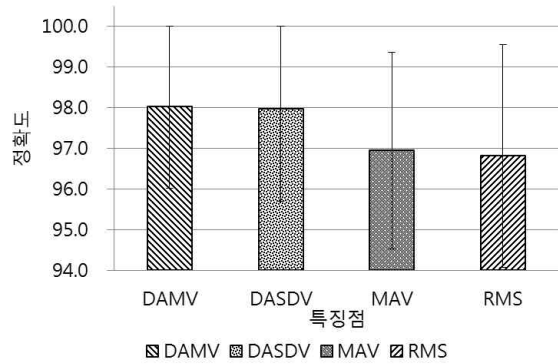


그림 6. 각 특징점에 대한 ANN 기반의 동작 분류 알고리즘의 결과그래프

점으로 사용하였을 때 98.03%로 가장 높은 정확도를 나타냈다. 다음으로 DASDV가 97.97%의 정확도를 보였으며, MAV와 RMS가 각각 96.95%와 96.82%를 나타냈다. 전반적으로 DAMV와 DASDV가 높은 성능을 보였고, MAV와 RMS가 비교적 낮은 성능을 보였다. t-test의 결과 DAMV와 DASDV 사이에는 유의한 차이를 보이지 않았으며, MAV와 RMS 사이에서도 유의한 차이를 보이지 않았다. 하지만 DAMV와 MAV, DAMV와 RMS사이에서는 양측 검정의 관례적 수준에는 이르지 못했지만 단측 검정에는 유의미한 결과를 보였다($p < 0.05$).

그림 6은 각 특징점에 대한 ANN 기반의 동작 분류 알고리즘의 결과를 그래프로 나타내고 있으며, 표 1은 수치로 나타낸 것이다. 기존의 연구에서는 DAMV를 이용한 k-NN 기반의 근전도 분류가 84.9%, MAV를 이용한 SVM 알고리즘 기반 근전도 분류가 약 99%의 정확도를 보이고 있다. 본 논문에서 제안한 동작 분류 알고리즘과 실험 방법의 차이 등에 의해 정확한 비교는 어려우나, 높은 분류 정확도를 이루어 보아 제안한 알고리즘의 우수성과 신뢰성을 검증할 수 있었다.

4. 결론

본 논문에서는 손목의 움직임을 추정하기 위해 비교적 계산과정이 간단한 특징점을 사용한 ANN 기반의 동작 분류 알고리즘을 제안하였다. 본 논문에서 사용한 특징점으로는 DAMV, DASDV, MAV, RMS를 사용했으며, 각 특징점 별로 DAMV는 98.03%, DASDV는 97.97%, MAV는 96.95%, RMS는 96.82%의 성능을 보여주었다. DAMV가 가장 뛰어난 성능을 보였으며, DAMV와 MAV, DAMV와 RMS 사이에는 양측 검정의 관례적 수준에는 이르

표 1. 각 특징점에 대한 ANN 기반의 동작 분류 알고리즘의 결과표

피실험자	DAMV	DASDV	MAV	RMS
1(남)	99.33	100.00	98.00	98.00
2(남)	93.33	96.67	92.00	94.00
3(남)	100.00	100.00	99.33	99.33
4(남)	93.33	91.33	94.00	93.33
5(남)	100.00	100.00	100.00	100.00
6(남)	100.00	100.00	100.00	100.00
7(남)	96.67	96.00	95.33	94.67
8(남)	95.33	96.00	99.33	98.67
9(남)	98.67	98.67	96.00	94.67
10(남)	99.33	99.33	98.00	99.33
11(남)	100.00	100.00	95.33	93.33
12(남)	100.00	100.00	100.00	100.00
13(남)	100.00	100.00	99.33	99.33
14(남)	97.33	99.33	98.00	98.67
15(남)	97.33	98.00	97.33	96.00
16(여)	100.00	98.67	98.00	97.33
17(남)	96.00	97.33	92.67	93.33
18(여)	98.00	98.00	95.33	94.67
19(남)	99.33	98.67	97.33	95.33
20(남)	100.00	100.00	98.67	98.67
21(남)	98.00	99.33	99.33	100.00
22(남)	98.67	98.00	99.33	99.33
23(여)	96.67	92.67	95.33	90.00
24(남)	97.33	96.67	94.00	96.67
25(여)	96.67	96.67	93.33	97.33
26(남)	97.33	96.00	95.33	95.33
평균	98.03	97.97	96.95	96.82
표준편차	2	2.27	2.42	2.71

지 못했지만, 단측 검정에서는 유의미한 결과를 보여주었다($p < 0.05$).

본 연구는 상지 절단 환자나 상지 재활을 필요로 하는 사람, 혹은 힘이 약한 노약자를 위한 손목 움직임을 추정하고 분류한다. 사용자의 의도에 맞게 필요한 동작을 수행할 수 있는 보조기기를 제어하는 것으로 의수나 외골격 로봇과 같은 재활 보조기 분야에 활용이 가능하다. 향후 연구에서 굴곡, 신전, 내전, 외전, 휴식 등의 다섯 동작뿐만 아니라 손목의 여러 움직임을 분류하는 개선된 동작 분류 알고리즘을 개발할 예정이며, 손목뿐만 아니라 손가락의 움직임을 구별할 수 있는 알고리즘을 연구할 예정이다. 또한 상지의 움직임뿐만 아니라 하지 절단 환자들을 위한 하지 움직임을 구별하는

알고리즘을 개발하여 사용자의 의도를 파악하고 명령을 정확하고 신속히 전달하여 실시간으로 동작할 수 있는 알고리즘으로 개선할 예정이다.

참 고 문 헌

- [1] 유경진, 신현출, “엔트로피 및 최대우도추정법을 이용한 표면 근전도 기반 손가락 동작 인식,” 대한전자공학회논문지, 제46권, SC편 제6호, 대한전자공학회, pp.38-43, 2009
- [2] C. Castellini, P. van der Smagt, “Surface EMG in advanced hand prosthetics,” Biological Cybernetics, vol. 100, no.1, pp.35-47, 2009
- [3] 장영건, 권장우, 한영환, 장석원, 홍승홍, “신경회로망과 확률모델을 이용한 근전도신호의 패턴분류에 관한 연구,” 대한전자공학회논문지, 제28권, 제10호, 대한전자공학회, pp.831-841, 1991
- [4] S.A. Ahmad, P.H. Chappell, “Surface EMG pattern analysis of the wrist muscles at different speeds of contraction,” Journal of Medical Engineering & Technology, vol. 33, no. 5, pp.376-385, 2009.
- [5] K. Englehart, B. Hudgins, A.D.C. Chan, “Continuous multifunction myoelectric control using pattern recognition,” Technology and Disability, vol. 15, no. 2, pp.95-103, 2003.
- [6] D. Peleg, E. Braimah, E.Y. Tov, G.F. Inbar, “Classification of Finger Activation for Use in a Robotic Prosthesis Arm,” IEEE Transactions in Neural Systems and Rehabilitation Engineering, vol. 10, no. 4, pp.290-293, 2002.
- [7] A.D.C. Chan, K.B. Englehart, “Continuous Classification of Myoelectric Signals for Powered Prostheses using Gaussian Mixture Models,” in Proc. 25th Annual international Conference of the IEE EMBS, Cancun, Mexico, pp.2841-2844. September, 2003
- [8] F.H.Y. Chan, Y.S. Yang, F.K. Lam, Y.T. Zhang, P.A. Parker, “Fuzzy EMG Classification for Prosthesis Control,” IEEE Transactions on Rehabilitation Engineering, vol. 8, no. 3, pp.305-311, 2000.
- [9] S.P Lee, S.H Park, “EMG Pattern Recognition based on Evidence Accumulation for Prosthesis Control,” Journal of Electrical Engineering and Information Science, vol. 2,

no. 6, pp.20-27, 1997.

[10] K.S. Kim, H.H. Choi, C.S. Moon, C.W. Mun, "Comparison of k-nearest neighbor, quadratic discriminant and linear discriminant analysis in classification of electromyogram signals based on the wrist-motion directions," Current Applied Physics, vol. 11, no. 3, pp. 740-745, 2011.

[11] A. Phinyomark, P. Phukpattaranont, C. Limsakul, "Feature reduction and selection for EMG signal classification," Expert Systems with Application, vol. 39, no. 8, pp.7420-7431, 2012.

[12] F.D. Farfán, J.C. Politti, C.J. Felice, "Evaluation of EMG processing techniques using information Theory," BioMedical Engineering OnLine, vol. 9, no. 72, 2010.

[13] C.J. De Luca, "Surface Electromyography: Detection and Recording," Tech. Rep., DelSys Inc., pp.2-3, 2002.

[14] 송영록, 김서준, 정의철, 이상민, "Gaussian Mixture Model 기반 전완 근전도 패턴 분류 알고리즘," 한국재활복지공학회논문지, 제5권, 제1호, 한국재활복지공학회, pp.95-101, 2011



송영록

2001년 2월 인천대학교 정보통신학과 졸업(학사)
 2003년 8월 인천대학교 대학원 정보통신공학과 졸업(석사)
 2009년 2월 인천대학교 대학원 정보통신공학과 졸업(박사)
 2009년 7월 - 현재 인하대학교 전자공학과 연구교수
 관심분야 : Ubiquitous Computing, Semantic Web, Bio-Signal Processing



이상민

1987년 2월 인하대학교 전자공학과 졸업(학사)
 1989년 2월 인하대학교 대학원 전자공학과 졸업(석사)
 2000년 2월 인하대학교 대학원 전자학과 졸업(박사)
 2006년 9월 - 현재 인하대학교 전자공학과 부교수
 관심분야 : Bio-Signal Processing, Psycho-Acoustic, Brain-Machine Interface



정의철

2011년 2월 인하대학교 전자공학과 졸업(학사)
 2011년 - 현재 인하대학교 대학원 전자공학과 석사과정
 관심분야 : Bio-Signal Processing, Neural Engineering



김서준

2012년 2월 인하대학교 전자공학과 졸업(학사)
 2012년 - 현재 인하대학교 대학원 전자공학과 석사과정
 관심분야 : Bio-Signal Processing, Pattern Classification