

손목 움직임 추정을 위한 Gaussian Mixture Model 기반 표면 근전도 패턴 분류 알고리즘

정의철 · 유송현 · 이상민 · 송영록

인하대학교 전자공학과

A Gaussian Mixture Model Based Surface Electromyogram Pattern Classification Algorithm for Estimation of Wrist Motions

Euichul Jeong, Songhyun Yu, Sangmin Lee and Youngrok Song

Department of Electronic Engineering, Inha University

(Received February 8, 2012. Accepted April 19, 2012)

Abstract: In this paper, the Gaussian Mixture Model(GMM) which is very robust modeling for pattern classification is proposed to classify wrist motions using surface electromyograms(EMG). EMG is widely used to recognize wrist motions such as up, down, left, right, rest, and is obtained from two electrodes placed on the flexor carpi ulnaris and extensor carpi ulnaris of 15 subjects under no strain condition during wrist motions. Also, EMG-based feature is derived from extracted EMG signals in time domain for fast processing. The estimated features based in difference absolute mean value(DAMV) are used for motion classification through GMM. The performance of our approach is evaluated by recognition rates and it is found that the proposed GMM-based method yields better results than conventional schemes including k-Nearest Neighbor(k-NN), Quadratic Discriminant Analysis(QDA) and Linear Discriminant Analysis(LDA).

Key words: GMM, pattern classification, EMG, feature extraction, wrist motion estimation

1. 서 론

오늘날 공학분야의 기술이 발전하고 인간의 삶의 질 향상에 관심이 증대됨에 따라 인간의 신체활동의 편의성을 추구하고 상대적으로 약한 근력을 가진 노인이나 여성들, 장애인들이 많은 가운데 근력을 강화하기 위한 보조기구의 필요성이 늘어나고 있다[1]. 최근에는 EMG(Electromyogram), EEG(Electroencephalogram), EOG(Electrooculogram) 등의 생체 신호처리를 기반으로 한 기술개발이 활발해지고 있는 가운데 EMG 신호처리는 뇌졸중으로 인한 반신 부전

마비나 긴장 항진 등의 치료나 재활, 스포츠 선수들의 부상 에 의한 재활 등과 같은 의학, 스포츠, 재활공학과 같은 분야에서 인간의 골격근분석 및 진단을 통한 동작 모방이 연구되어 왔다[2-3]. EMG 신호는 근육의 수축 시 발생하는 전기적인 신호로서 척수에서 신경임펄스가 발생되어 운동 뉴런을 활성화시키고 이에 따라 운동단위(motor unit)내의 근 섬유가 활성화되면서 전위차(motor unit action potential)가 발생한다[4]. 근전도를 측정하는 방법에는 크게 피부 표면에서 측정하는 방법과 바늘을 이용한 침습형 측정방법이 있는데 피부 표면에 부착한 전극 주위의 근육들에서 발생하는 이러한 전위차들의 합이 표면 근전도 신호로 나타나며 피부 표면에서 측정하는 방법은 비용효과가 뛰어나고 사용이 편리한 장점이 있어 널리 이용되어 왔다[5-7].

EMG 신호를 이용하여 동작을 분류하기 위한 기존의 연구에서는 비선형 신호로부터 추출된 특징을 분류할 수 있다는 장점에서 신경회로망(Neural Network) 방법을 많이 사

Corresponding Author : 송영록
인천시 남구 용현4동 인하대학교 하이테크관 716호
TEL: +82-70-8251-1549
E-Mail: gateway32@inha.ac.kr

본 연구는 지식경제부 및 정보통신산업진흥원의 IT융합 고급인력 과정 지원사업의 연구결과로 수행되었음(NIPA-2012-H0401-12-1007).

용하였다[8-10]. 신경회로망의 성능을 결정짓는 가장 중요한 것은 신경망 구조의 복잡도이며 신경망의 구조가 커지게 되면 아무리 복잡한 비선형성 관계의 신호들도 잘 추정할 수 있게 되지만, overfitting 문제가 발생할 수 있으며, 학습하는데 많은 시간이 소요된다는 단점이 있다[11]. 이 외에도 뉴로-퍼지(neuro-fuzzy), locally weighted projection 등을 사용한 분류법들이 연구되어 왔으나 이러한 방법들 또한 계산과정이 복잡하다는 단점이 있다[12-13].

이에 본 논문에서는 손목 움직임을 추정하기 위해 입력과 각 노드와의 가중치값을 임의적으로 초기화하고 학습률의 크기에 따라 가중치를 변화시키면서 분류를 하는 신경회로망에 비해 계산과정이 비교적 간단하고 처리속도가 빠른 가우시안 혼합 모델(GMM : Gaussian Mixture Model)기반의 표면 근전도 패턴 분류 알고리즘을 제안한다. GMM은 관찰된 데이터를 이용하여 가우시안 분포의 파라미터(평균과 공분산)를 추정하는 모델로써 계산량이 기존에 많이 쓰인 신경회로망보다 적다. 여러 분야에서 널리 쓰이는 매우 견고한 모델링이고 EM알고리즘으로 최적의 모델을 추정하며, Bayesian-Laplace approximation, minimum description length(MDL), minimum message length(MML) 등을 포함하여 모델링 차수를 선택한다[15]. 이는 화자 인식 및 확인 분야에서 매우 뛰어난 인식기법으로 사용되어 왔으며, 화자 인식 및 확인에서 발생하는 여러 문제들이 근전도 신호의 패턴을 분류하는 과정에서 발생하는 문제들과 매우 유사하기 때문에 손목 움직임을 추정하기 위한 표면 근전도 패턴 분류 방법으로 사용하였다[16]. GMM 기반의 표면 근전도 패턴 분류에 필수적으로 적용되는 특징점으로는 근전도 신호의 진폭특성을 고려한 절대적분치(IAV : Integrate Absolute Value)[17,19]와 절대차분평균치(DAMV : Difference Absolute Mean Value)[17], 절대차분표준편차

(DASDV : Difference Absolute Standard Deviation Value)[14], 제곱평균제곱근(RMS : Root Mean Square)[18,22]을 사용한다. 제안한 알고리즘의 성능을 검증하기 위해서, k 근접 이웃(k-NN : k-Nearest Neighbor), 이차 판별 분석(QDA : Quadratic Discriminant Analysis), 선형 판별 분석(LDA : Linear Discriminant Analysis) 기반의 동작 분류 알고리즘의 성능을 비교 평가한 연구[14]와 동일한 방법으로 손목의 상, 하, 좌, 우, 휴식 다섯 동작의 근전도를 측정하는 실험을 성인 남성 15명을 대상으로 실시하였다. 측정된 근전도 신호를 알고리즘에 학습 시킨 후, 학습에 참여하지 않은 테스트 근전도 신호를 입력하여 동작 분류에 있어 제안한 알고리즘의 분류 성능의 정확도를 판단하고, k-NN, QDA, LDA 기반의 동작 분류 알고리즘의 결과와 비교 평가 하였다.

II. GMM 기반의 표면 근전도 패턴 분류 알고리즘

본 논문에서는 손목의 상, 하, 좌, 우, 휴식 동작을 분류하기 위해서 그림 1과 같은 표면 근전도 패턴 분류 알고리즘을 제안한다. 제안하는 알고리즘은 근전도 신호를 측정하고 측정된 신호를 증폭 및 대역 통과 필터 등의 전처리 과정을 거친 후 time-window의 길이를 결정한다. 결정된 time-window내의 데이터를 사용하여 근전도 신호의 진폭 특성을 고려한 특징점(IAV, DAMV, DASDV, RMS)을 추출하고,




그림 1. GMM 기반의 동작 분류 알고리즘
Fig. 1. The GMM based motion classification algorithm




그림 2. 손목의 4가지 움직임과 휴식 상태. (a) 위, (b)휴식, (c) 아래, (d) 왼쪽, (e) 오른쪽
Fig. 2. Pictures of four wrist motion and rest state. (a) up, (b) rest, (c) down, (d) left, (e) right

이 특징점들을 적용하여 GMM 기반의 동작 분류를 실행한다. 제안한 GMM 기반의 표면 근전도 패턴 분류 알고리즘의 평가를 위하여 기존 연구에서 평가된 k-NN, QDA, LDA 알고리즘의 성능[14]과 비교한다.

1. 근전도 측정 및 전처리 과정

본 논문에서는 그림 2와 같이 전완에서 자주 사용되는 손목의 상, 하, 좌, 우의 네 가지 동작과 휴식 동작을 포함하는 다섯 가지 동작을 인식한다. 손의 움직임은 손을 관장하는 근육의 변화로 나타나므로 근육의 움직임을 분석함으로써 손가락과 손의 움직임을 파악할 수 있게 된다[20]. 앞의 네 가지 동작은 그림 3에서 보이는 전완근육들의 수축을 통해서 이루어진다. 특히 척측 수근 굴근(Flexor Carpi Ulnaris Muscle)과 척측 수근 신근(Extensor Carpi Ulnaris Muscle)은 손목 동작에 관여하는 중요한 근육으로써 4개의 표면전극을 부착하여 2채널로 근전도를 측정한다. 사용된 전극은 Ag/AgCl 표면전극을 사용하였다.

근전도는 0~10 mV의 진폭을 가지며 0~1.5 mV의 실효값(rms)을 가진다. 그리고 사용가능한 근전도 신호는 0~500 Hz에 분포하고 있으며 50~150 Hz에 에너지가 집중되어 있다[21]. 따라서 본 논문에서는 BIOPAC사의 MP150WSW와 BN-EMG2 앰프를 이용하여 근전도 신호의 이득값을 2000으로 조정하고 10~500 Hz대역으로 필터링하여 인체에서 나오는 근전도에 가장 근접한 신호를 획득한다. 획득한 근전도 신호는 1 kHz로 샘플링하고, 근전 신호의 특징점 추출을 위한 time-window 길이는 166 ms로 설정한다.

2. 특징점 추출

EMG 신호는 생리학 및 해부학적 특성과 기기장치의 특징 등에 의해 많은 간섭을 받으며, 또한 개개인별 측정되는 EMG 신호도 차이를 보인다[23]. 따라서 동작 분류의 성공 여부에 있어서 원신호를 대변할 수 있는 특징점의 선택이 매

우 중요하다[7]. 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[24]. 따라서 비 안정적인 생체신호에 푸리에 변환의 적용은 적합하지 않으며, 계산 과정이 복잡하다는 단점을 가지고 있기 때문에 비교적 실시간으로 신호를 처리할 수 있는 시간 영역에서 특징점을 도출할 필요가 있다. 본 논문에서는 근전도 신호의 진폭 특성을 고려한 IAV, DAMV, DASDV, RMS 등의 기법을 적용하여 근전도 신호의 특징점을 추출한다.

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

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

$$DASDV = \sqrt{\frac{1}{N-1} \sum_{k=1}^{N-1} (X_{k+1} - X_k)^2} \quad (3)$$

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

IAV는 근전도 신호의 절대적분치로써 각 데이터 샘플의 절대값의 평균을 나타내며, 식(1)로 정의된다[6,17]. 여기에서 N 은 time-window 내에 있는 데이터 샘플의 개수이며, X_k 는 time-window내의 k 번째 데이터 샘플을 나타낸다. DAMV는 근전도 신호의 절대차분평균값을 나타내며, 일정 시간 동안의 신호의 절대값을 적분한 것으로써 식 (2)로 정의되고[17], DASDV는 근전도 신호의 절대차분표준편차로 인접한 두 샘플간의 표준편차의 차이를 나타내며, 식 (3)으로 정의된다[14]. RMS는 근전도 신호의 제곱평균제곱근을 나타내며, 식(4)로 정의된다[3].




그림 3. 근전도 측정을 위한 전극의 위치. (a) 척측 수근 굴근, (b) 척측 수근 신근

Fig. 3. Electrode positions for electromyogram acquisition. (a) Flexor Carpi Ulnaris Muscle, (b) Extensor Carpi Ulnaris Muscle

3. 가우시안 혼합 모델(GMM)

GMM은 주어진 표본 데이터 집합의 분포 밀도를 단 하나의 확률밀도함수로 모델링하는 방법을 개선한 밀도 추정 방법으로 복수 개의 가우시안 확률밀도함수로 데이터의 분포를 모델링하는 방법이다[25]. 이 방법은 간혹 세미-파라메트릭(semi-parametric) 방법이라고도 하는데 개별 밀도 함수를 전체 확률밀도함수의 성분인 커널(kernel)로 간주하는 방법이다. 이는 clustering이나 classification 분야에 많이 적용되어 왔고, 유한한 가우시안 밀도의 가중치 합에 기반한 일반적인 확률밀도함수를 나타내는데 널리 사용되었다[15]. 그리고 단일한 가우시안으로는 도저히 모델링 할 수 없는 복수개의 중심점을 가지는 1차원 데이터뿐만 아니라 그림 4와 같이 2차원 데이터에 대하여 견고하게 모델링이 가능하다. 그림 4는 10×10 이미지 데이터의 한 픽셀당 RGB값의 벡터들을 분류한 그림이다.

최종적인 전체 확률밀도함수는 M개의 가우시안 확률밀도함수의 선형결합으로 식 (5)로 정의된다.

$$p(x|\theta) = \sum_{i=1}^M p(x|\omega_i, \theta_i) P(\omega_i) \quad (5)$$

여기서 $p(x|\omega_i, \theta_i)$ 는 데이터 x 에 대하여 ω_i 번째 성분 파라미터 θ_i 로 이루어진 확률밀도함수를 의미하며, $P(\omega_i)$ 는 혼합 가중치(mixture weight)로 각 확률밀도함수의 상대적인 중요도를 의미한다. 혼합 가중치를 사전 확률과 같은 형태 α_i 라고 두면 식(2)와 같은 제약 조건에 따른다.

$$0 \leq \alpha_i \leq 1 \quad \text{그리고} \quad \sum_{i=1}^M \alpha_i = 1 \quad (6)$$

확률밀도함수가 가우시안 분포를 따를 경우는 식 (7)과 같은 파라미터 집합이 된다.




그림 4. 2차원 데이터에 대한 GMM 모델링 예시
Fig. 4. Example of GMM Modeling for 2-dimensional data

$$\theta_i = (\mu_1, \mu_2, \dots, \mu_M, \sigma_1^2, \sigma_2^2, \dots, \sigma_M^2, \alpha_1, \alpha_2, \dots, \alpha_M) \quad (7)$$

μ 은 평균을 나타내고 σ^2 은 분산을 나타낸다. 전체 모델을 이루는 각 가우시안 성분은 완전(full), 대각(diagonal) 혹은 정방형(spherical) 공분산 행렬의 형태를 가질 수 있다. 또한 혼합 성분의 개수는 학습 데이터 집합의 크기에 따라 조절할 수 있다. 따라서 GMM은 모델의 비대칭성(asymmetry)과 멀티모달(multimodal) 특성을 가지도록 혼합 가중치와 같은 파라미터를 추가하여 단일 가우시안 확률밀도 함수를 개선한 보다 견고한 밀도 추정법이라고 할 수 있다. 그리고 이렇게 모델링 된 모델을 베이스 분류기에 적용하면, 단일 확률밀도함수의 경우보다 더 나은 인식 결과를 얻을 수 있다.

III. 실험 및 결과

1. 실험 방법

본 논문에서는 손목 움직임에 무리가 없는 건강한 20~30대 남성 15명을 대상으로 실험을 실시하였으며 각 피실험자는 척측 수근 굴근과 척측 수근 신근에 전극을 부착하고 5초간 휴식한 후 각 동작을 5초간 실시한다. 각 동작 사이에는 5초간의 휴식을 취하고 마지막 동작이 끝나고 난 뒤 다시 5초간의 휴식을 취하여 총 45초의 신호를 획득한다. 획득한 근전도 raw 신호는 그림 5에 나타내었다. 그림 5의 위의 다섯 그림은 척측 수근 굴근에 전극을 부착한 채널 1(CH1)의 신호이고, 아래의 다섯 그림은 척측 수근 신근에 전극을 부착한 채널 2(CH2)의 신호이다. 획득한 신호에 길이가 166 ms인 time-window를 이용하여 한 동작 당 30개의 특징점 계산 결과값을 추출하고, 이를 제안한 표면 근전도 패턴 분류 알고리즘의 학습 데이터로 활용한다.

표면 근전도 패턴 분류 알고리즘의 성능을 확인하기 위해 모든 피실험자는 24시간이 지난 후, 다시 위의 과정을 반복하여 실험을 실시하였다. 여기서 획득한 데이터는 앞서 학습된 동작 분류 알고리즘의 입력으로 활용하여 제안한 알고리즘의 동작 분류 성능을 확인하였다.

2. 실험 결과

본 논문에서는 k-NN, QDA, LDA와 GMM의 표면 근전도 패턴 분류 성능을 비교하기 위해 하나의 특징점을 이용한 채널별 분류를 수행하였고, 패턴 분류에 사용된 특징점은 신호의 진폭 특성을 고려하는 IAV, DAMV, DASDV, RMS를 사용하였다.

그림 6은 본 논문에서 제시한 특징점들을 사용하여 5가지의 동작을 분류하기 위해 GMM을 이용하여 up, down, left, right, rest신호를 사용하여 패턴 분류를 학습 시키고 학습에 참여하지 않은 test-up, test-down, test-left, test-

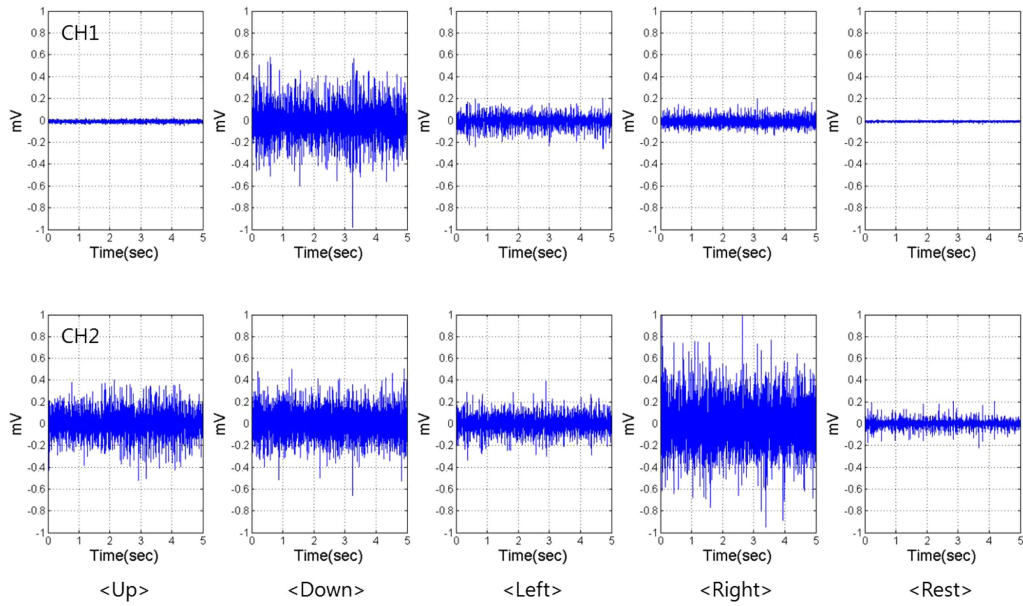


그림 5. 취득된 근전도 원신호
 Fig. 5. Obtained electromyogram raw signals

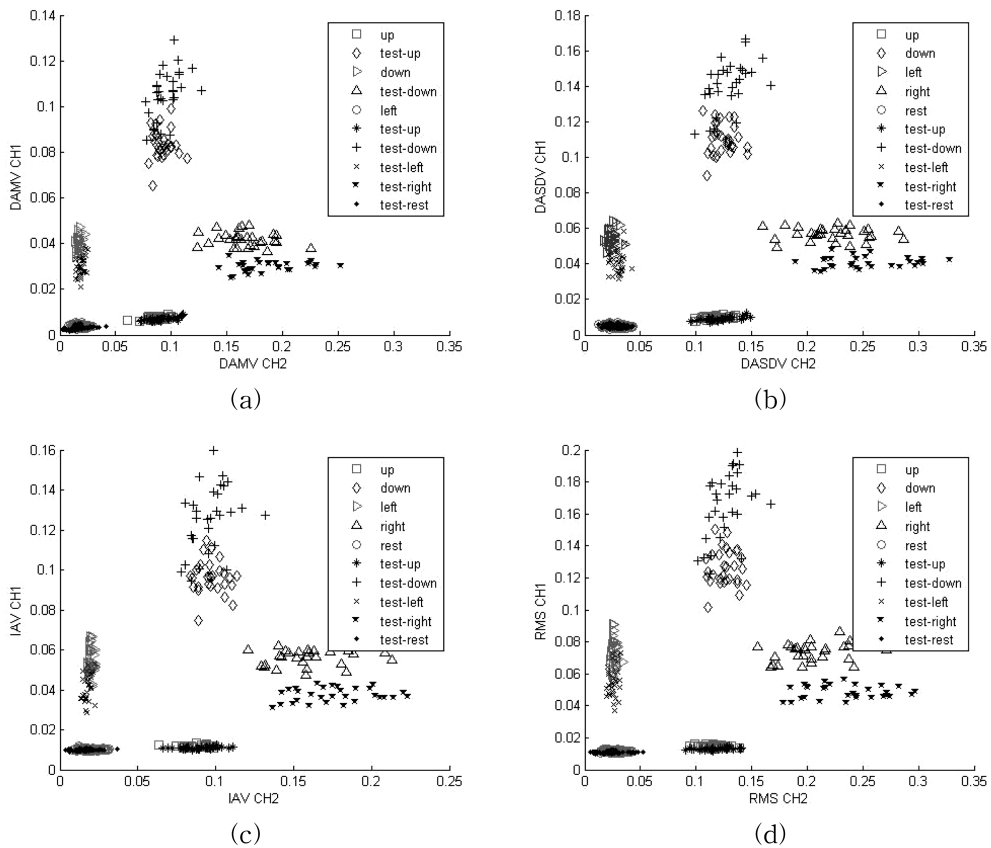


그림 6. GMM 기반의 동작 분류 학습 결과. (a) 절대차분평균치, (b) 절대차분표준편차, (c) 절대적분치, (d) 제곱평균제곱근
 Fig. 6. The result of GMM based motion classification. (a) DAMV, (b) DASDV, (c) IAV, (d) RMS

right, test-rest신호를 학습 시킨 결과에 입력함으로써 제안한 GMM 기반 표면 근전도 패턴 분류의 결과를 나타냈

다. k-NN, QDA, LDA 기반의 동작 분류 방법을 비교 평가한 연구[14]의 경우 DAMV와 DASDV를 특징점으로 사

용한 결과가 IAV와 RMS를 특징점으로 사용한 결과보다 상대적으로 높은 정확도를 나타냈다. 분산분석 결과 DAMV를 특징점으로 사용한 결과와 DASDV를 특징점으로 사용한 결과에서 유의한 차이를 보이진 않았다. 기존의 연구에서는 IAV와 RMS와의 비교에서 유의한 차이를 보이고 동작 분류의 성능이 가장 좋은 DAMV를 특징점으로 선택하였으며, k-NN은 84.9%의 정확도를 나타내고, QDA와 LDA는 82.4%와 81.1%의 정확도로 동작 분류가 가능했다.

본 논문에서 제안한 GMM 기반의 동작분류의 경우에도 DAMV와 DASDV를 특징점으로 사용한 결과가 IAV와 RMS를 특징점으로 사용한 결과보다 높은 정확도를 나타냈다. 그림 7은 본 논문에서 제안한 GMM 기반의 동작 분류 알고리즘을 각 특징점별로 분류한 결과를 그래프로 나타냈다. 가장 높은 정확도를 나타낸 특징점으로는 DASDV이며, 96.4%의 정확도로 동작을 분류할 수 있었고, DAMV를 특징점으로 사용했을 경우 96.1%의 정확도로 동작을 분류할 수 있었다. 분산분석 결과 기존의 연구와 마찬가지로 DAMV를 특징점으로 사용한 결과와 DASDV를 특징점으로 사용

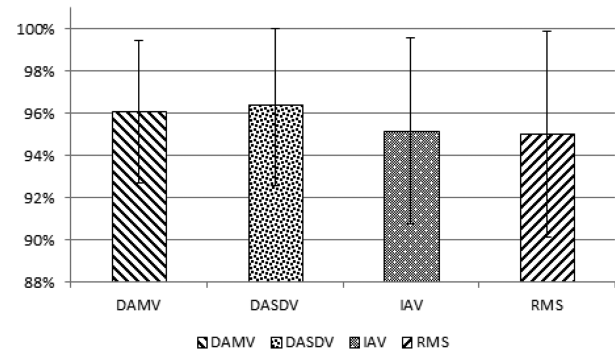


그림 7. 각 특징점에 대한 GMM 기반의 패턴분류 결과
Fig. 7. The results a GMM based pattern classification for each feature

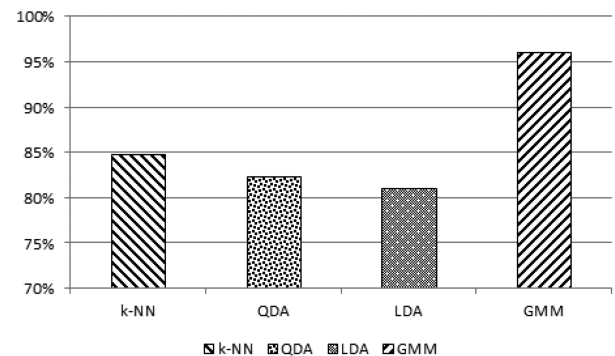


그림 8. DAMV를 특징점으로 사용했을 때 k-NN, QDA, LDA[14] 그리고 GMM 기반의 패턴 분류 방법에 대한 결과
Fig. 8. The results of a k-NN, QDA, LDA[14] and GMM pattern classification using DAMV to feature extraction




그림 9. k-NN, QDA, LDA[14] 그리고 GMM 기반의 표면 근전도 패턴 분류 결과
Fig. 9. The results of a k-NN, QDA, LDA[14], and GMM based surface electromyogram pattern classification

한 결과에서 유의한 차이를 보이지 않았으며, 기존의 연구와 비교를 위해 DAMV를 특징점으로 채택하였다. 그림 8은 DAMV를 특징점으로 하였을 경우 각 동작 분류 방법에 대한 결과를 그래프로 나타냈다.

k-NN, QDA, LDA와 GMM을 사용하여 동작을 분류 하였을 경우 전반적으로 DASDV와 DAMV를 특징점으로 사용했을 때의 정확도가 IAV와 RMS를 특징점으로 사용했을 때보다 뛰어나다고 볼 수 있으며, 본 논문에서 제안한 GMM 기반의 표면 근전도 패턴 분류 알고리즘이 기존의 연구에서 사용한 동작 분류보다 향상된 성능을 보이고 있음을 확인하였다. 그림 9는 특징점에 따른 각 동작 분류 방법에 대한 결과를 그래프로 나타냈다.

IV. 결 론

본 논문에서는 손목 움직임을 추정하기 위해 비교적 간단하고 처리속도가 빠른 k-NN, QDA, LDA와 비교되는 GMM 기반의 동작분류 알고리즘을 제안하였다. 또한 본 논문에서는 동작 분류의 필수적인 요소인 특징점으로는 근전도 신호의 진폭 특성을 고려한 DAMV, DASDV, IAV, RMS를 사용했으며, 대표적으로 DAMV를 특징점으로 사용하였을 경우, k-NN, QDA, LDA의 동작 분류 성능 결과로 각 84.9%, 82.4%, 81.1%의 정확도를 보이는 반면, GMM 기반의 동작 분류에서는 96.1%의 정확도로 근전도 신호의 5가지 동작 분류에 성공하였다.

향후 연구에서 보다 다양한 동작에 따른 근전도 신호의 분류 알고리즘으로 개선할 예정이며, 상지절단 환자의 근전 의수 사용에 있어 사용자의 의도를 더욱 명확히 파악하고 동작 명령 전달에 있어 사용자의 의도에 빠르게 반응 할 수 있도록 실시간, 높은 신뢰성이 있는 알고리즘으로 개선할 예정이다.

참고문헌

- [1] B.I. Jeon, H.C. Cho, "Exoskeleton robot arm Control by fuzzy algorithm using EMG signal," *Proceedings of KILLS Fall Conference*, Jeju, Korea, December, 2009, pp. 218-221.
- [2] A.Y. Lee, G.H. Jang, D.C. Lee, H.J. Yu, Y.J. Choi, "1 DOF Human Arm Tracking Robot System using EMG Signals," *Conference on Information and Control Systems*, Jeju, Korea, October, 2009, pp. 186-187.
- [3] K.S. Tae, S.J. Song, Y.H. Kim, "Estimation of Motor Recovery using Characteristics of EMG during Isometric Muscle Contraction in Hemiparetic Wrist," *Journal of Biomedical Engineering Research*, vol. 29, no. 1, pp. 8-16, 2008.
- [4] Y.G. Jang, J.W. Kwon, Y.H. Han, W.S. Jang, S.H. Hong, "A Study on the Classification of the EMG Signals Using Neural Network and Probabilistic Model," *Journal of The Institute of Electronics Engineers of Korea*, B vol. 28, no. 10, pp. 831-841, 1991.
- [5] 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.
- [6] C. Castellini, P. van der Smagt, "Surface EMG in advanced hand prosthetics," *Biological Cybernetics*, vol. 100, no. 1, pp. 35-47, 2009.
- [7] 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.
- [8] B. Hudgins, P. Parker, "A New Strategy for Multifunction Myoelectric Control," *IEEE Transactions on Biomedical Engineering*, vol. 40, no. 1, pp. 82-94, 1993.
- [9] L. Ozyilmaz, T. Yildirim, H. Seker, "EMG Signal Classification Using Conic Section Function Neural Networks," *International Joint Conference on Neural Networks*, Washington, D.C, USA, July, 1999, pp. 3601-3603.
- [10] A. Hiraiwa, K. Shimohara, Y. Tokunaga, "EMG Pattern Analysis and Classification by Neural Network," *IEEE International Conference on Systems, Man, and Cybernetics*, Cambridge, USA, November, 1989, pp. 1113-1115.
- [11] C.M. Choi, M.H. Shin, S.C. Kwon, J. Kim, "EMG-based Real-time Finger Force Estimation for Human-Machine Interaction," *Journal of the Korean Society for Precision Engineering*, vol. 26, no. 8, pp. 132-141, 2009.
- [12] Sabri Koçer, "Classification of EMG Signals Using Neuro-Fuzzy System and Diagnosis of Neuromuscular Diseases," *Journal of Medical Systems*, vol. 34, no. 3, pp. 321-329, 2010.
- [13] P. Geethanjali, K.K. Ray, "Identification of motion from multi-channel EMG signals for control of prosthetic hand," *Australasian Physical & Engineering Science in Medicine*, vol. 34, no. 3, pp. 419-427, 2011.
- [14] 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.
- [15] J.U. Chu, Y.J. Lee, "Conjugate-Prior-Penalized Learning of Gaussian Mixture Models for Multifunction Myoelectric Hand Control," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 17, no. 3, pp. 287-297, 2009.
- [16] Y.H. Huang, K. Englehart, B. Hudgins, A.D.C. Chan, "A Gaussian Mixture Model Based Classification Scheme for Myoelectric Control of Powered Upper Limb Prostheses," *IEEE Transactions on Biomedical Engineering*, vol. 52, no. 11, pp. 1801-1811, 2005.
- [17] 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.
- [18] K. Momen, S. Krishnan, T. Chau, "Real-Time Classification of Forearm Electromyographic Signals Corresponding to User-Selected Intentional Movements for Multifunction prosthesis Control," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 15, no. 4, pp. 535-542, 2007.
- [19] 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.
- [20] Y.H. Lee, C.H. Choi, S.S. Kim, D.H. Kim, "Detection of Hand Motion using Cross-correlation of Surface EMG," *Journal of Biomedical Engineering Research*, vol. 29, no. 3, pp. 205-211, 2008.
- [21] C. De Luca, "Surface Electromyography: Detection and Recording," Tech. Rep., DelSys Inc., 2002, pp. 2-3.
- [22] D. Nishikawa, W. Yu, H. Yokoi, Y. Kakazu, "EMG Prosthetic Hand Controller Discriminating Ten Motions using Real-time Learning Method," *IEEE/RSJ International Conference on Intelligent Robots and Systems*, Kyongju, Korea, October, 1999, pp. 1592-1597.
- [23] M. Khezri, M. Jahed, "Real-time intelligent pattern recognition algorithm for surface EMG signals," *BioMedical Engineering OnLine*, vol. 6, no. 45, 2007
- [24] Y.J. Cho, J.Y. Kim, "The Limitation of Interpretation of MPF Parameter in Muscle Fatigue Assessment," *Fall Conference of Ergonomics Society of Korea*, Kimhae, Korea, October, 2008, pp. 67-72.
- [25] Y.R. Song, S.J. Kim, E.C. Jeong, S.M. Lee, "A Gaussian Mixture Model Based Pattern Classification Algorithm of Forearm Electromyogram," *Journal of Rehabilitation Welfare Engineering & Assistive Technology*, vol. 5 no. 1, pp. 95-101, 2011.