

주성분 분석을 활용한 적응형 근전도 패턴 인식 알고리즘

Adaptive sEMG Pattern Recognition Algorithm using Principal Component Analysis

김 세 진¹ · 정 완 균[†]

Sejin Kim¹, Wan Kyun Chung[†]

Abstract: Pattern recognition for surface electromyogram (sEMG) suffers from its nonstationary and stochastic property. Although it can be relieved by acquiring new training data, it is not only time-consuming and burdensome process but also hard to set the standard when the data acquisition should be held. Therefore, we propose an adaptive sEMG pattern recognition algorithm using principal component analysis. The proposed algorithm finds the relationship between sEMG channels and extracts the optimal principal component. Based on the relative distance, the proposed algorithm determines whether to update the existing patterns or to register the new pattern. From the experimental result, it is shown that multiple patterns are generated from the sEMG data stream and they are highly related to the motion. Furthermore, the proposed algorithm has shown higher classification accuracy than k-nearest neighbor (k-NN) and support vector machine (SVM). We expect that the proposed algorithm is utilized for adaptive and long-lasting pattern recognition.

Keywords: Pattern Recognition, Principal Component Analysis, Adaptive Process, Classification Accuracy

1. 서 론

표면 근전도(surface electromyogram, sEMG)는 피부에 부착된 전극을 통해 근육이 활성화될 때 발생하는 생체 전기 신호(bio-electric signal)를 측정하는 것을 의미한다^[1]. 표면 근전도는 동작의 종류에 따라 특정한 패턴을 보이는데, 이러한 특성으로 인해 사용자의 의도 파악을 위한 인터페이스로 활용되고 있다^[2-5]. 의도 파악은 동작별로 표면 근전도의 패턴을 학습한 후, 새로 측정된 표면 근전도와 가장 유사한 패턴을 비교하는 방식으로 이루어진다^[6].

하지만, 표면 근전도는 비정상(nonstationary)일 뿐만 아니라 스토캐스틱(stochastic)하여 시간의 흐름에 따라 신호의 특성이 변하게 된다^[7,8]. 따라서, 처음에 학습된 표면 근전도의 패턴과

이후 동작 의도를 파악할 때의 표면 근전도의 패턴 사이에는 차이가 발생할 수 있다.

패턴을 업데이트하는 가장 대표적인 방법은 새로운 학습 데이터를 획득하는 것이다. 하지만 새로운 학습 데이터를 지속적으로 획득하는 것은 많은 시간이 걸리는 작업이므로 사용자의 부담이 가중될 수 있다^[9-11]. 또한, 패턴의 변화는 점진적이고 연속적으로 일어나므로 새로운 학습 데이터를 언제 얻어야 할지 기준을 정하기도 어렵다. 이러한 한계를 극복하기 위해, 학습 없이도 표면 근전도 패턴을 등록하고 이를 업데이트하는 반복적인 자가 적응(iterative self-adaptation) 알고리즘이 제안되었다^[12]. 해당 알고리즘에서 각 패턴은 가우시안 분포(Gaussian distribution)로 표현되며, 표면 근전도가 측정되면 현재 존재하는 모든 패턴에 대해 가능도(likelihood)를 계산한다. 최대 가능도가 확률 문턱(probability threshold)보다 높을 경우, 최대 가능도를 보이는 패턴을 업데이트한다. 그렇지 않을 경우, 측정된 표면 근전도를 기준으로 새로운 패턴을 등록하게 되며 이 과정은 새로운 표면 근전도가 측정될 때마다 반복된다. 또한, 실험 결과를 통해 해당 알고리즘이 시간의 흐름이나 동작 속도에 따라 기존 패턴을 업데이트하거나 새로운 패턴을 등록하며, 이들 패턴이 동작과도 높은 연관성을 보인다는 것을 확인하였다^[13].

Received : Mar. 21. 2024; Revised : May. 9. 2024; Accepted : May. 21. 2024

※ This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education (No.2020R111A2074953).

1. Ph. D. Candidate, Department of Mechanical Engineering, POSTECH, Pohang, Korea (universe2030@postech.ac.kr)

† Professor, Corresponding author: Department of Mechanical Engineering, POSTECH, Pohang, Korea (wkchung@postech.ac.kr)

본 논문은 위에서 설명한 알고리즘이 가지고 있는 몇 가지 한계점을 보완하기 위한 방법론을 제시한다. 우선, 기존 알고리즘에서는 각 표면 근전도 채널(sEMG channel)이 서로 독립이라고 가정한 상태에서 패턴을 가우시안 분포로 표현하므로 일부 채널 사이에 상관관계가 존재할 경우 이를 제대로 설명하지 못하거나 너무 많은 패턴이 등록될 가능성이 존재한다. 그리고 기존 알고리즘에서는 최대 가능도를 보이는 패턴을 제외하더라도 나머지 패턴들의 표준 편차를 일정 비율만큼 증가시키는데, 이로 인해 일정 시간 이상 등장하지 않는 패턴은 최대 가능도가 확률 문턱값보다 낮아져 해당 패턴으로 설명 가능한 표면 근전도가 측정되더라도 새로운 패턴이 등록된다. 이렇게 의미 없는 패턴이 존재하면 최대 가능도 계산에 걸리는 시간이 증가하므로 연산 효율이 감소하게 된다. 따라서, 본 논문은 주성분 분석(principal component analysis, PCA)을 통해 채널 사이의 상관관계를 잘 나타낼 수 있는 변수를 추출하여 패턴을 표현하는 데 활용한다. 또한, 제안하는 알고리즘은 측정된 표면 근전도를 가장 잘 설명할 수 있는 패턴만 업데이트하여 의미 없는 패턴이 등록되는 것을 방지한다.

본 논문의 2장에서는 표면 근전도의 획득 프로토콜과 신호 처리 방식을 소개한다. 3장에서는 주성분 분석을 활용한 패턴의 특성 추출, 상대적 거리의 정의, 패턴의 업데이트 및 등록과 분류 정확도 계산 방식을 설명한다. 4장에서는 기존 알고리즘 대비 제안하는 알고리즘이 가지는 장점을 검증하였으며, 5장에서는 실험 결과를 제시한다. 6장의 고찰에서는 기존 알고리즘과 제안하는 알고리즘의 매개변수(parameter) 사이의 등가성을 설명하며, 7장의 결론을 통해 본 논문을 마무리한다.

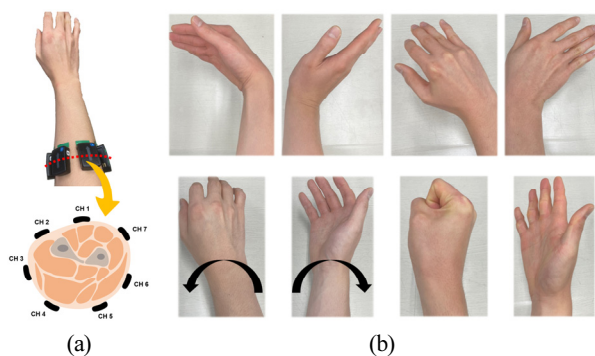
2. 표면 근전도 획득 프로토콜 및 신호 처리

본 논문에서는 총 11명의 건강하고 다친 곳이 없는 피실험자(모두 남성, 평균 연령 23.6 ± 1.3세, 평균 키 174.0 ± 4.0 cm, 평균 몸무게 68.7 ± 10.1 kg)가 실험에 참여하였다. 외부의 영향을 최소화하기 위해 피실험자는 노이즈 캔슬링(noise canceling) 기능이 있는 헤드셋을 착용하였다. 피실험자는 일어서서 팔을 내리고 손바닥이 몸을 향한 자세를 취한 후, 전방의 모니터에서 제공되는 시각적 신호(visual cue)에 따라 [Fig. 1(b)]의 8가지 동작들을 다음의 순서로 5초간 수행하였다: 손목 굴곡(wrist flexion, WF), 손목 신전(wrist extension, WE), 요측 편위(radial deviation, RD), 척측 편위(ulnar deviation, UD), 손목 회내(wrist pronation, WP), 손목 회외(wrist supination, WS), 손 움켜쥐기(hand close, HC), 손 펴기(hand open, HO). 각 동작 사이에는 근육 피로를 방지하기 위해 3초의 휴식(rest)이 주어졌다. 해당 과정은 5번씩 반복되었으며, 각 반복 사이에는 10초의 휴식이 주어졌다. 만약 피실험자가 도중에 근육 피로를 호소할 경우, 총

분한 휴식을 취한 후 실험을 재개하였다.

본 연구에서는 알코올 솜으로 피부를 먼저 소독한 후, 표면 근전도 센서를 오른팔에 부착하였다. 이전에 진행된 표면 근전도 기반 동작 구분 연구들에서 표면 근전도 채널 개수를 동작 개수와 비슷하게 설정하였음을 고려하여¹⁴⁻¹⁶, 총 7개의 근전도 센서를 활용하였다(일부 피실험자의 경우 전완부(forearm) 둘레에 동간격으로 최대 7개의 센서까지 부착할 수 있었고, 선행 실험 결과 7개의 채널로도 제시된 8개의 동작을 구분할 수 있었기 때문에 7개의 센서를 사용하는 것으로 결정하였음). 센서 위치의 경우, [Fig. 1(a)]와 같이 첫 센서를 요측 수근 신근(extensor carpi radialis)의 근복(muscle belly)에 부착한 상태에서 나머지 6개의 센서가 같은 간격을 이루도록 팔 둘레에 반시계 방향으로 부착하였다. 실험 과정은 피실험자에게 사전에 통지되었으며, 모든 피실험자가 실험 참여에 동의하였다. 본 실험은 포항공과대학교(Pohang University of Science and Technology, POSTECH)의 생명윤리위원회(institutional review board, IRB)에 의해 승인되었다(승인번호: PIRB-2023-E012).

표면 근전도의 에너지는 주로 500 Hz 아래에 집중되어있다¹⁷. 나이퀴스트-샤넌 표본화 정리(Nyquist-Shannon sampling theorem)에 따라, 500 Hz 이내의 표면 근전도를 에일리어싱(aliasing) 없이 획득하기 위해 샘플링 주파수를 1000 Hz로 설정하였다. 또한 신호 왜곡(signal distortion)과 동작 아티팩트(motion artifact)의 효과를 완화하기 위해, 20 Hz부터 450 Hz까지 대역 통과 필터(band-pass filter)와¹⁸ 60 Hz의 노치 필터(notch filter)를 적용하였다. 표면 근전도에서 의미 있는 특성을 추출하기 위해, 본 논문에서는 시스템 지연 허용 최댓값의 절반인 150 ms 크기의 슬라이딩 윈도우에서 계산한 평균 절대값(mean absolute value, MAV)을 알고리즘에 활용하였다¹⁹.



[Fig. 1] (a) The placement of sEMG sensors on forearm. Total 7 sensors are attached around the forearm circumference with equal distance while the first sensor is attached on the muscle belly of the extensor carpi radialis. (b) Target motions. (From top left to bottom right) wrist flexion (WF), wrist extension (WE), radial deviation (RD), ulnar deviation (UD), wrist pronation (WP), wrist supination (WS), hand close (HC), and hand open (HO)

3. 주성분 분석을 활용한 근전도 패턴 인식

3.1 주성분 분석

주성분 분석은 기존 변수의 선형 결합(linear combination)을 통해 데이터의 분산(variance)을 최대화하는 새로운 기저 축(basis axis)을 찾는 방법으로, 특징 추출(feature extraction)에 널리 활용되는 방법론이다²⁰⁾. 또한, 주성분 분석은 데이터의 분산이 큰 순서대로 주성분을 정렬할 수 있어 고차원의 데이터를 저차원으로 변환하는 차원 축소(dimension reduction)에도 활용된다²¹⁾. 본 논문에서는 특징 추출을 위해 활용된다.

총 N 개의 채널과 L 개의 관측된 표면 근전도 샘플로 이루어진 데이터 행렬 $X \in \mathbb{R}^{N \times L}$ 는 다음과 같이 표현할 수 있다.

$$X = \begin{bmatrix} \vec{x}_1^T & \dots & \vec{x}_N^T \end{bmatrix}^T \quad (1)$$

여기서 채널 지수 $n \in \{1, 2, \dots, N\}$ 에 대해 $\vec{x}_n \in \mathbb{R}^{1 \times L}$ 다. 새로운 특징을 표현하는 벡터(vector)인 $\vec{\alpha}_n$ 을 통해 X 를 변환한 새로운 데이터 행렬 $Z \in \mathbb{R}^{N \times L}$ 은 다음과 같이 표현된다.

$$Z = \begin{bmatrix} \vec{z}_1 \\ \vdots \\ \vec{z}_N \end{bmatrix} = \begin{bmatrix} \vec{\alpha}_1^T \\ \vdots \\ \vec{\alpha}_N^T \end{bmatrix} X = A^T X \quad (2)$$

주성분 분석의 목적은 여기서 Z 의 분산을 최대화하는 A 를 찾는 것이다. 이를 수학적으로 표현하면 아래와 같다.

$$A = \underset{A}{\text{max}} \{ \text{Var}(A^T X) \} = \underset{A}{\text{max}} \{ A^T \text{Var}(X) A \} \quad (3)$$

여기서 $\vec{\alpha}_n$ 의 크기에 따른 분산 증가 효과를 제한하기 위해, $\vec{\alpha}_n$ 는 아래와 같이 단위 벡터(unit vector)로 설정한다.

$$\vec{\alpha}^T \cdot \vec{\alpha} = 1 \quad (4)$$

위 제약 조건을 만족하는 최적화 문제를 풀기 위해 임의의 특징 벡터 $\vec{\alpha}_n$ 에 대한 라그랑지안(Lagrangian) L_n 을 아래와 같이 정의한 후,

$$\begin{aligned} L_n &= \vec{\alpha}_n^T \text{Var}(X) \vec{\alpha}_n - \lambda_n (\vec{\alpha}_n \cdot \vec{\alpha}_n - 1) \\ &= \vec{\alpha}_n^T \Sigma \vec{\alpha}_n - \lambda_n (\vec{\alpha}_n^T \cdot \vec{\alpha}_n - 1) \end{aligned} \quad (5)$$

L_n 이 최댓값이 되게 하는 $\vec{\alpha}_n$ 를 찾기 위해 L_n 을 $\vec{\alpha}_n$ 에 대해

미분하면 다음과 같다.

$$\frac{\partial L_n}{\partial \vec{\alpha}_n} = (\Sigma - \lambda_n) \vec{\alpha}_n = 0 \quad (6)$$

따라서 λ_n 는 X 의 공분산 행렬(covariance matrix)인 Σ 의 고윳값(eigenvalue), $\vec{\alpha}_n$ 는 고유벡터(eigenvector)임을 알 수 있으며, $\vec{\alpha}_n$ 가 주성분이 된다. 이를 기반으로 새로운 특징 \vec{z}_n 을 다음과 같이 계산하면,

$$\vec{z}_n = \vec{\alpha}_n^T X \quad (7)$$

해당 특징의 분산은 아래와 같이 계산할 수 있다.

$$\text{Var}(\vec{z}_n) = \vec{\alpha}_n^T \Sigma \vec{\alpha}_n = \lambda_n (\vec{\alpha}_n^T \cdot \vec{\alpha}_n) = \lambda_n \quad (8)$$

따라서 본 논문에서는 고윳값의 크기를 통해 높은 분산을 가지는 순서대로 특징 벡터를 정렬한 후, 모든 특징 벡터를 패턴을 표현하는 데 활용하였다.

3.2 상대적 거리 정의

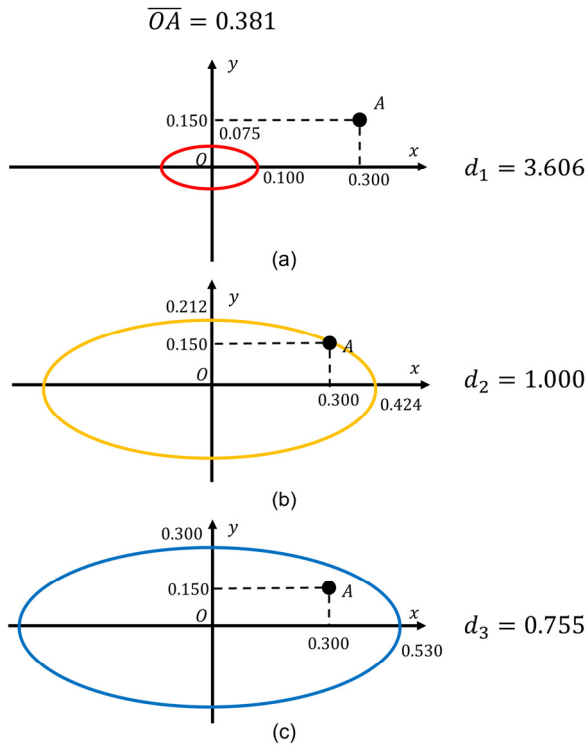
3.1을 통해 주성분 분석 기반으로 정의되는 패턴은 N 차원 초타원체(N -dimensional hyperellipsoid)로 표현된다는 것을 알 수 있다. N 차원 초타원체의 경계는 다음과 같이 표현된다.

$$\sum_{n=1}^N \left(\frac{x_n}{R_n} \right)^2 = 1 \quad (9)$$

여기서 R_n 은 초타원체의 n 번째 축 길이(length of axis)를 나타낸다. 따라서, m 번째 패턴을 표현한 초타원체의 중심에 대한 새로운 표면 근전도 데이터 x 의 상대적 거리 $d_m(x)$ 는 아래와 같이 표현할 수 있다.

$$d_m^2(x) = \sum_{n=1}^N \left(\frac{x_{nm}}{R_{nm}} \right)^2 \quad (10)$$

여기서 R_{nm} 은 m 번째 패턴의 n 번째 주성분의 축 길이를, 그리고 x_{nm} '은 x 를 m 번째 패턴의 n 번째 주성분 벡터에 사영한 값을 의미한다. 이를 통해 [Fig. 2]와 같이 $d_m(x)$ 의 값이 1보다 작으면 x 가 초타원체 내부에, 1이면 초타원체 경계에, 그리고 1보다 크면 초타원체 외부에 존재한다는 점을 알 수 있다.



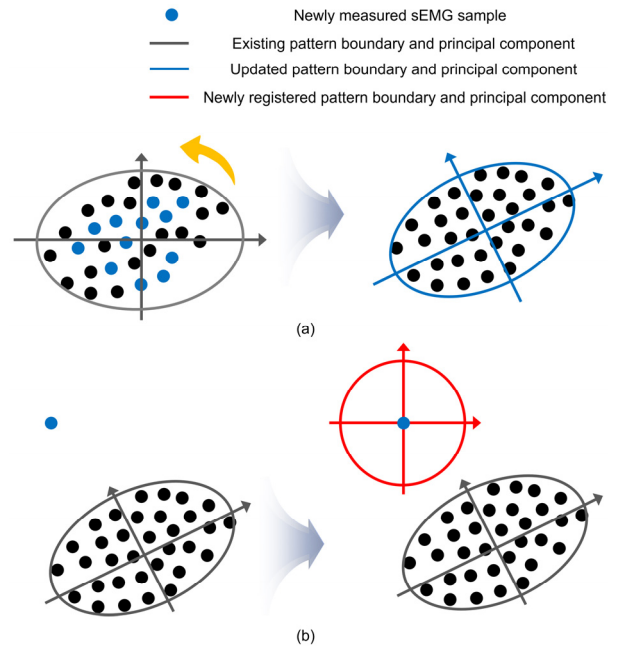
[Fig. 2] Schematic diagram of the relative distance between hyper-ellipsoid-shaped pattern and a sample when the sample is located (a) outside the pattern, (b) at the boundary of the pattern, and (c) within the pattern

3.3 패턴 업데이트 및 등록

3.3.1 기준 설정

3.2를 통해 d_m 에 따라 새로운 표면 근전도가 m 번째 패턴을 나타내는 초타원체 내부에 존재하는지 여부를 결정할 수 있음을 보였다. 초타원체가 각 패턴이 표현할 수 있는 영역을 나타낸다고 할 때, 모든 패턴 중 가장 작은 d_m 의 값이 1보다 작거나 같다면 새로운 표면 근전도는 해당 패턴으로 표현 가능하다고 할 수 있다. 하지만, 만약 1보다 크다면 이를 표현하기 위해 새로운 패턴이 필요하다. 따라서, 본 논문에서는 이를 기반으로 패턴을 업데이트하거나 등록하는 기준을 설정하였다.

새로운 표면 근전도가 측정되면 현재 존재하는 모든 패턴에 대해 상대적 거리 d_m 을 계산한다. 이 중 가장 작은 값을 \bar{d} 라고 하고, 해당 값이 \bar{m} 번째 패턴에서 도출되었다고 가정하자. 만약 \bar{d} 가 1보다 작거나 같으면 표면 근전도를 \bar{m} 번째 패턴을 업데이트하는 데 사용한다. 업데이트는 \bar{m} 번째 패턴에 속하는 데이터를 메모리에 저장해둔 후, 이에 대한 주성분 분석을 수행하여 이루어진다. 반대로, \bar{d} 가 1보다 크면 해당 표면 근전도를 중심으로 하는 새로운 패턴을 등록한다.



[Fig. 3] (a) Schematic diagram of existing pattern update. If the measured sEMG is included in the existing pattern, then pattern boundary and principal component are updated by reflecting the data. (b) Schematic diagram of new pattern registration. If the measured sEMG is not explainable by the existing pattern, then the boundary and principal component of new pattern are set to predefined parameters

3.3.2 기존 패턴 업데이트

[Fig. 3(a)]은 기존 패턴을 업데이트하는 과정을 나타내고 있다. 설명을 위해 m 번째 패턴을 업데이트하는 경우를 가정하자. 우선, m 번째 패턴에 포함된 데이터에서 패턴의 중심값을 뺀 값을 활용하여 고유 벡터를 새로 계산한다. 그 후에는 다음과 같이 해당 값을 모든 특징 벡터에 사영한다.

$$R_{nl}' = \vec{a}_n \cdot (x_l - \mu), n \in \{1, \dots, N\}, l \in \{1, \dots, L_m\} \quad (11)$$

여기서 μ 은 패턴 중심 벡터, N 은 채널(혹은 주성분)의 개수, L_m 은 m 번째 패턴에 포함된 데이터 샘플의 개수를 의미한다. 이후, 다음과 같이 주성분별로 사영된 값 중에서 최댓값을 구한다.

$$\bar{R}_n = \max_l \{R_{nl}'\} \quad (12)$$

이 최댓값을 다음과 같이 n 번째 주성분의 축 길이로 설정한다.

$$R_{mn} = \bar{R}_n \quad (13)$$

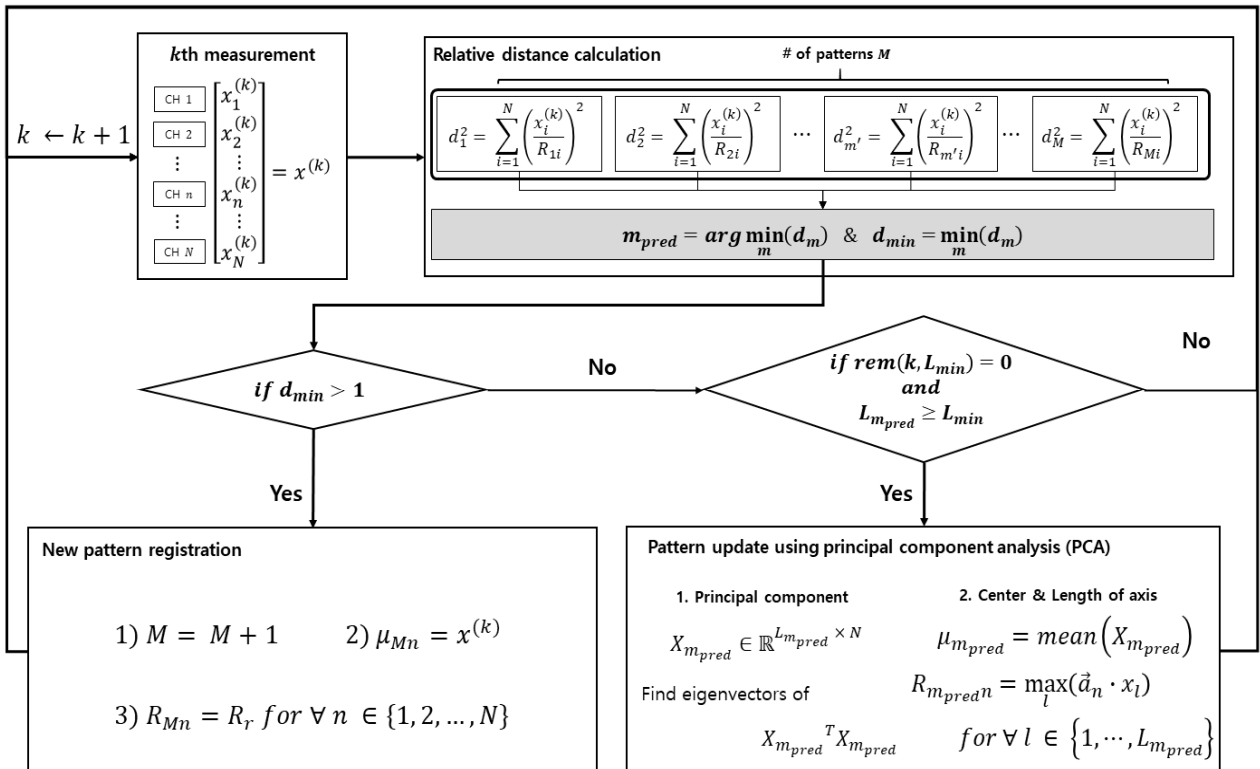
위에서 설명한 업데이트는 해당 패턴에 포함된 표면 근전도 샘플의 수가 L_{min} 이상일 때만 수행한다. 필요한 최소 샘플의 수를 지정한 이유는 너무 적은 데이터에 대해 주성분 분석을 적용하게 되면 채널 사이의 상관관계를 찾아내기 어렵기 때문이다. 또한, 새로운 샘플이 측정될 때마다 식 (11)과 (12)의 연산을 수행하는 것은 부하가 크기 때문에, 샘플이 L_{min} 개 측정될 때마다 업데이트 수행 여부를 판별한다.

3.3.3 신규 패턴 등록

[Fig. 3(b)]는 신규 패턴을 등록하는 과정을 나타내고 있다. 새로운 패턴은 현재의 표면 근전도 이외의 정보가 존재하지 않기 때문에, 측정될 표면 근전도를 반영하는 고유벡터와 경계를 설정하기가 어렵다. 따라서, 새로 등록할 패턴은 각 채널을 나타내는 단위 벡터를 고유벡터로 설정하며, 경계는 초매개변수 (hyperparameter)인 R_r 로 설정한다. 이후에는 3.3.2와 같이 해당 패턴으로 표현할 수 있는 표면 근전도 데이터 샘플의 수가 L_{min} 이상이 되면 업데이트를 수행한다.

3.4 전체 알고리즘 구성

[Fig. 4]는 3.1부터 3.3까지 설명한 방법론을 활용한 전체 알고리즘의 구성을 나타내고 있다. k 번째 표면 근전도 데이터 샘플이 측정되면 현재 존재하는 M 개의 패턴에 대해 상대 거리를 계산하여 가장 그 거리가 짧은 패턴의 지수 m_{pred} 와 그 값인 d_{min} 을 도출한다. 만약 d_{min} 이 1보다 클 경우, 현재 측정된 표면 근전도 샘플을 중심으로 하고 사전에 지정된 R_r 을 주성분의 축 길이로 하는 새로운 패턴을 생성한다. 알고리즘이 시작되는 시점에는 패턴이 존재하지 않으므로, 처음으로 측정된 표면 근전도 샘플로 새로운 패턴을 등록한다. d_{min} 이 1보다 작거나 같고 m_{pred} 번째 패턴에 포함된 데이터 샘플이 L_{min} 개 이상이면 해당 패턴의 업데이트를 수행한다. 우선 해당 패턴에 포함된 표면 근전도를 활용한 주성분 분석을 통해 고유벡터를 업데이트한다. 패턴의 중심은 포함된 데이터의 평균으로 지정하며, 주성분의 축 길이는 업데이트된 고유벡터에 포함된 모든 데이터를 사영시킨 값 중 최댓값으로 설정한다. 업데이트는 L_{min} 개의 표면 근전도가 측정될 때마다 수행된다.



[Fig. 4] Schematic diagram of overall algorithm procedure. When new sEMG is measured, relative distance is calculated for every existing pattern. If the minimum relative distance is larger than 1, then new pattern is registered. If the minimum relative distance is less than or same as 1, the algorithm checks whether the number of data samples which belong to the pattern to be updated is larger than L_{min} . If the conditions are satisfied, then the algorithm conducts the principal component analysis (PCA) and updates the principal component, center, and length of axis

3.5 패턴을 활용한 동작 분류 정확도 계산

제안하는 알고리즘에서 생성된 패턴이 동작과 어느 정도의 연관성을 보이는지 확인하기 위해, 해당 패턴을 활용하여 분류기를 학습한 후 동작 분류 정확도를 계산하였다. 동작 레이블을 활용하여, 다음과 같이 각 패턴에 포함된 데이터 중에서 가장 많은 표면 근전도가 도출된 동작을 해당 패턴의 대표 동작으로 설정하였다.

$$\hat{y}(\theta) = \underset{y}{\operatorname{argmax}} \sum_{k \in \{k | \hat{\theta}^{(k)} = \theta\}} \delta(y^{(k)}, y) \quad (14)$$

식 (14)의 δ 는 크로네커 델타 함수(Kronecker delta function)로, 다음과 같이 정의된다.

$$\delta(a, b) = \begin{cases} 1 & \text{if } a = b \\ 0 & \text{otherwise} \end{cases} \quad (15)$$

동작 분류 정확도를 비교하기 위해, 제안하는 알고리즘을 k-최근접 이웃(k-nearest neighbor, k-NN)^[22], 서포트 벡터 머신(support vector machine, SVM)^[23], 기존 알고리즘^[12], 그리고 컨볼루션 신경망(convolutional neural network, CNN)^[24]과 비교하였다. 본 논문에서는 평균 절대값을 활용하였으므로, 1차원 컨볼루션 커널(kernel)을 활용하였다. 적용한 컨볼루션 신경망은 8, 16 (이상 크기 2의 커널 사용), 32, 64 (이상 크기 3의 커널 사용)개의 커널로 구성된 4개의 컨볼루션 층(convolution layer), 25개의 노드(node)로 구성된 완전 연결층(fully connected layer, FCL), 그리고 소프트맥스(softmax) 함수를 거쳐 각 동작에 대한 확률을 출력하는 구조로 구성되었다. 2장에서 설명한 것처럼 동작을 5회씩 반복하였으므로, 각 분류기에는 다음의 5분할 교차 검증(5-fold cross validation)이 적용되었다^[25]. 동작을 5회 반복했을 때의 표면 근전도와 레이블 중에서 한 번의 시도(trial)를 제외한 나머지를 활용하여 분류기를 학습시키고, 동작 분류 정확도는 학습에서 사용되지 않은 한 번의 시도에서 얻은 표면 근전도와 레이블을 통해 계산했다.

4. 제안하는 방법의 필요성 검증

1장에서, 제안하는 알고리즘은 채널 사이의 상관관계를 찾고, 의미 없는 패턴이 생성되는 것을 막아 기존 알고리즘이 가지고 있던 한계점을 극복하였다고 소개하였다. 4장에서는 이에 대한 검증을 진행하였다.

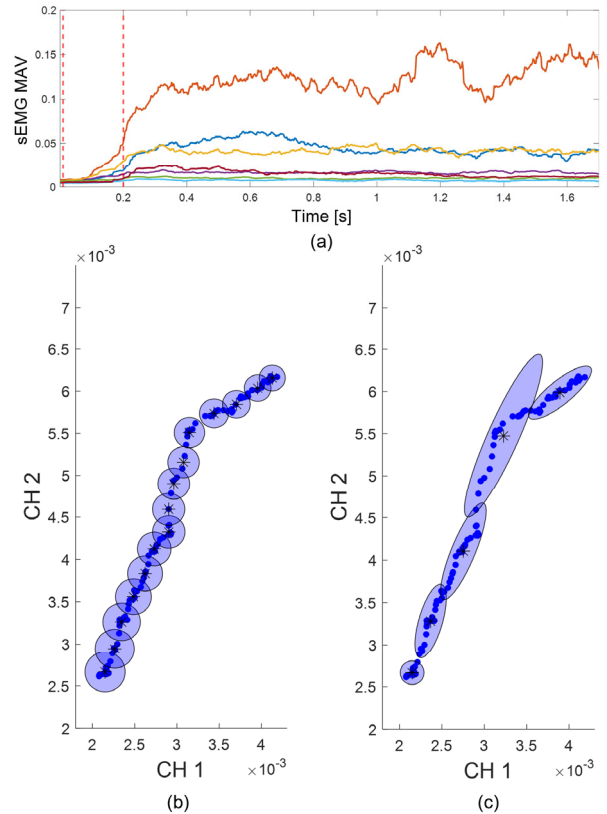
우선, 기존 알고리즘은 각 채널이 독립이라고 가정하고 각 채널마다 같은 표준 편차를 가지도록 패턴을 생성하거나 업데

이트한다. 이 경우, 특정 양상을 표현하기 위해 종종 너무 많은 수의 패턴이 필요하게 된다. 반면, 제안하는 알고리즘은 채널 사이의 상관관계를 고려할 뿐만 아니라, 각 주성분별로 축의 길이가 다르므로 하나의 패턴이 더 다양한 양상의 데이터 분포를 표현할 수 있다. 이러한 특성은 [Fig. 5(a)]에서 빨간색 선으로 표시된 부분처럼 휴식 상태에서 특정 동작을 수행할 때 발생하는 과도 상태(transient state)에서 잘 드러난다. 시각화를 위해 가장 특징이 두드러지는 두 개의 채널을 선택하여 나타냈을 때, 기존 알고리즘을 적용하면 [Fig. 5(b)]와 같이 총 15개의 패턴이 생성된다. 반면, 제안하는 방법을 적용하면 [Fig. 5(c)]와 같이 5개의 패턴이 생성된다. 이를 통해 채널 사이의 상관관계를 활용하면 더 적은 수의 패턴으로도 표현이 가능함을 검증하였다.

또한, 기존 알고리즘은 패턴의 확률 분포에 확산(diffusion)을 적용하므로 시간이 흐름에 따라 의미 없는 패턴이 생성된다. 확산은 다음의 식으로 표현된다.

$$p_n(x_n | \theta_m) \leftarrow p_n(x_n | \theta_m) + \alpha \frac{\partial^2}{\partial x_n^2} p_n(x_n | \theta_m) \quad (16)$$

여기서 x_n 은 n 번째 채널의 근전도 값, θ_m 은 m 번째 패턴의 때

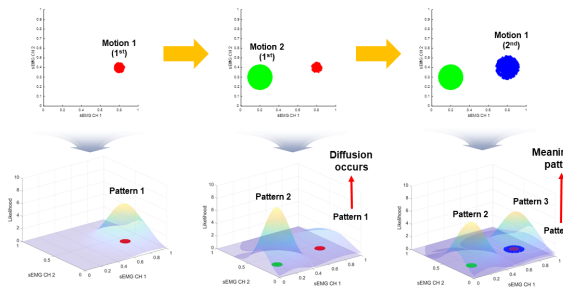


[Fig. 5] (a) sEMG MAV (Mean Absolute Value) from radial deviation. Pattern boundaries generated from original and proposed method are visualized with (b) and (c) respectively

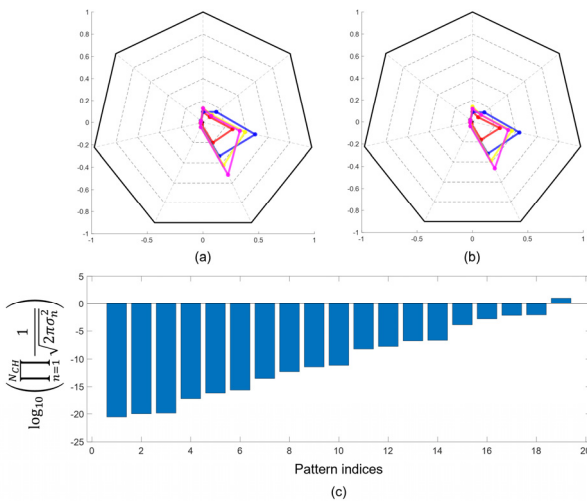
개변수, 그리고 $p_n(x_n|\theta_m)$ 은 n 번째 채널의 가능도를 나타낸다. 기존 확률 분포 함수 $f(x_n)$ 가 가우시안 분포라고 가정할 때 식 (16)에 따라 확산을 적용한 $f_d(x_n)$ 는 다음과 같다.

$$f_d(x_n) = f(x_n) \left[1 + \alpha \left\{ \frac{(x_n - \mu_n)^2}{\sigma_n^4} - \frac{1}{\sigma_n^2} \right\} \right] \quad (17)$$

식 (17)을 통해, $|x_n - \mu_n| < \sigma_n$ 일 경우 가능도가 감소하여 $x_n = \mu_n$ 일 때의 최대 가능도 또한 감소함을 알 수 있다. 따라서, 확산이 지속적으로 적용되면 최대 주변 가능도(maximum marginal likelihood)가 패턴의 생성 여부를 판단하는 확률 문턱 p^* 보다 낮아지는 시점에 도달하게 된다. 이를 확인하기 위해, 다음과 같이 시뮬레이션 및 실제 데이터를 사용하여 검증을 진행하였다.



[Fig. 6] Simulation results of original method. As maximum likelihood of pattern 1 decreases, it becomes meaningless pattern and pattern 3 is newly generated



[Fig. 7] Spider web plot of patterns with (a) original and (b) proposed method. Please note that multiple patterns are overlapped with original method. (c) Maximum marginal likelihood of overlapping patterns from original method are plotted with log scale

[Fig. 6]은 가우시안 확률 분포에 따라 샘플링된 인공 표면 근전도(synthetic sEMG) 및 해당 근전도에 기존 방법을 적용했을 때 각 패턴의 확률 분포를 나타내고 있다. [Fig. 6]에서 확인할 수 있듯이, 첫 번째 패턴이 생성된 이후 두 번째 패턴으로 설명되는 초록색 근전도가 발생하면 확산으로 인해 첫 번째 패턴의 최대 가능도는 낮아지게 된다. 따라서 첫 번째 패턴으로 설명 가능한 파란색 근전도가 발생하더라도 세 번째 패턴이 새로 생성된다.

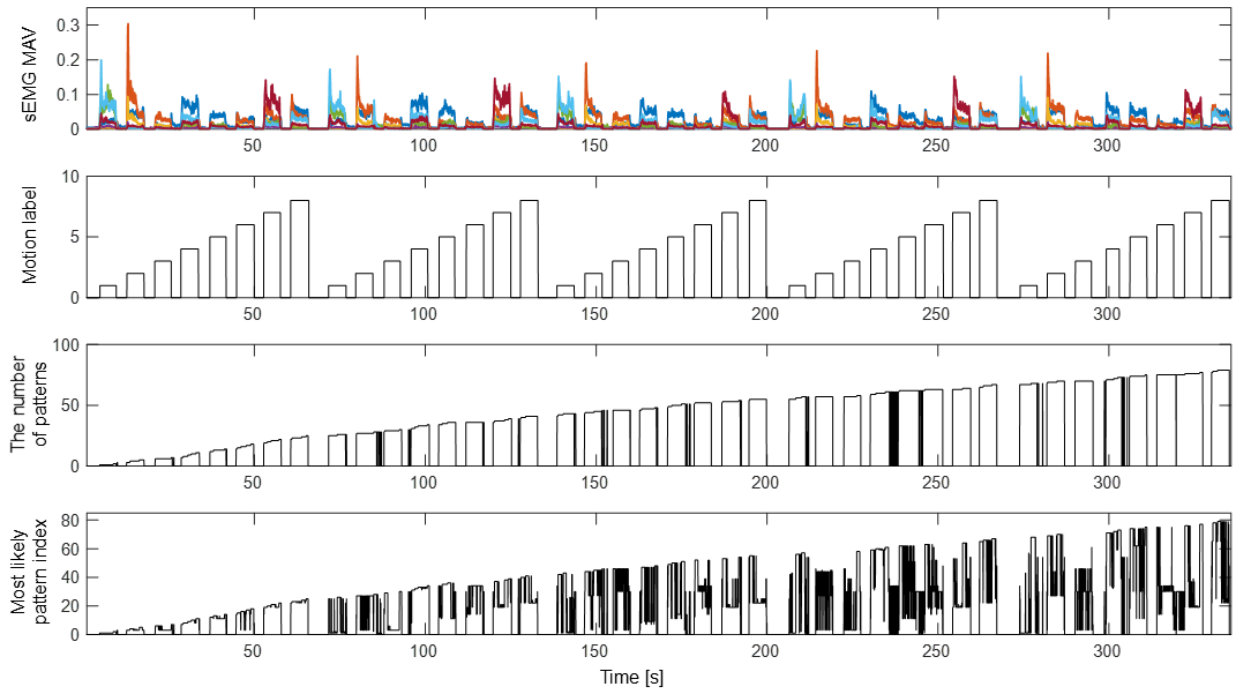
[Fig. 7(a)]와 [Fig. 7(b)]는 기존 알고리즘과 제안하는 알고리즘에 실제 근전도를 활용했을 때의 결과를 각각 나타내고 있다. 기존 알고리즘을 적용했을 때 생성된 패턴을 나타낸 [Fig. 7(a)]의 경우 앞서 설명한 이유로 인해 중심이 같은 패턴이 여러 개 생성되었으며, 중심이 같은 패턴이 겹쳐져 있기 때문에 그림 상에 나타난 패턴의 개수는 실제 패턴의 개수보다 더 적다. 반면, 제안하는 알고리즘을 적용했을 때 생성된 패턴을 나타낸 [Fig. 7(b)]에서는 같은 종류의 패턴이 생성되지 않았다. [Fig. 7(c)]는 [Fig. 7(a)]에서 겹치는 패턴들의 최대 주변 가능도를 나타내고 있다. 이를 통해 초반에 생성된 패턴의 최대 주변 가능도는 이후에 생성된 패턴보다 작은 값을 가지는 것을 알 수 있다. 4장의 결과를 통해, 제안하는 알고리즘이 기존 알고리즘이 가지고 있던 한계점을 완화하였다는 점을 알 수 있다.

5. 실험 결과


본 논문에서 제안하는 알고리즘은 R_r 와 L_{min} 의 두 가지 초매개변수를 활용하며, 다음부터 소개될 실험 결과에서는 R_r 을 0.50, L_{min} 을 500으로 설정하였다.

5.1 측정된 표면 근전도 및 패턴 형성 결과

[Fig. 8]은 측정된 표면 근전도의 평균 절대값, 동작 레이블, 생성된 패턴의 개수, 그리고 가장 작은 상대적 거리를 보이는 패턴의 지수를 나타낸다. [Fig. 8]을 통해 비록 같은 동작에서도 출된 표면 근전도라고 하더라도 새로운 패턴이 지속적으로 생성된다는 것을 알 수 있다. 이는 서론에서 설명한 것처럼 표면 근전도가 스토캐스틱하고 비정상적의 특성을 보이기 때문이다. 이로 인해 패턴의 개수는 시간이 흐름에 따라 계속 증가하게 된다. [Fig. 9]는 [Fig. 8]에서 손 펴기로 분류된 패턴의 중심을 거미줄 그림(spider web plot)으로 나타내고 있다. 이를 통해, 새로운 근전도가 들어올 때마다 고유한 특성을 가진 패턴이 지속적으로 형성되고 있음을 확인할 수 있다. [Fig. 8]의 첫 번째 줄에서 약 70초까지 각 동작을 한 번씩 수행한 후에는 기존의 패턴이 가장 작은 상대적 거리를 보이기도 하는데, 이는 생성된




[Fig. 8] The graph shows the sEMG mean absolute value(MAV), motion label, the number of patterns, and the most likely pattern index which has drawn the minimum relative distance. It is shown that even though the motion label is same, new patterns are generated from the algorithm and therefore, the number of patterns is continuously growing. After the first trial of each motion, some existing patterns are selected as the most likely one while new patterns are also generated because of the nonstationarity and stochastic property of sEMG



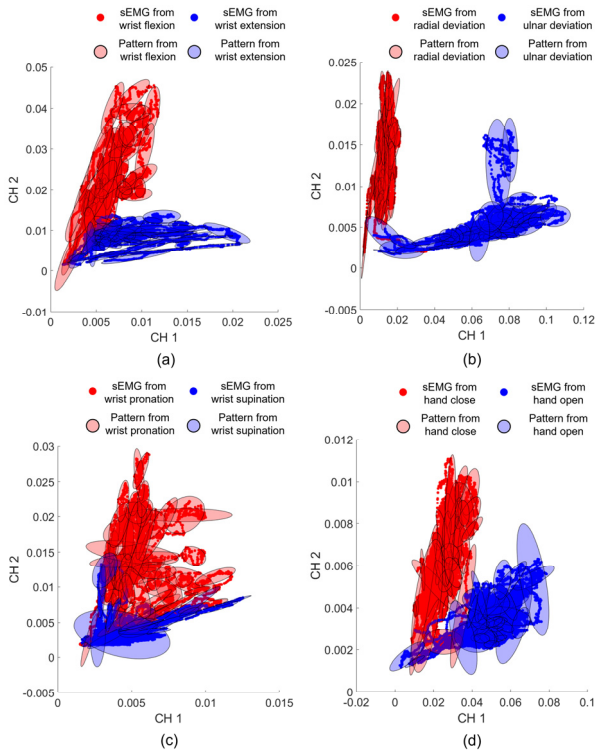
[Fig. 9] Spider web plot of patterns from hand open (HO) motion with proposed method

패턴이 동작과 높은 연관성을 보인다는 것을 나타내는 지표라고 할 수 있다. 이를 직접 확인하기 위해, 패턴마다 어떤 동작에서 도출된 표면 근전도가 포함되는지 그 비율을 확인해보았다. [Fig. 10]은 패턴별 동작 포함 비율을 나타내고 있는데, 이를 통해 각 패턴은 특정 동작에서 도출된 표면 근전도를 주로 포함하고 있음을 확인할 수 있다. 따라서 생성된 패턴은 동작 분류기



[Fig. 10] The motion appearance rate of each pattern. The rate is normalized from 0 to 1 by dividing the total number of motion appearance in each pattern into each value

로도 활용될 수 있으며, 동작 분류 정확도 결과는 4.3에서 설명하였다.



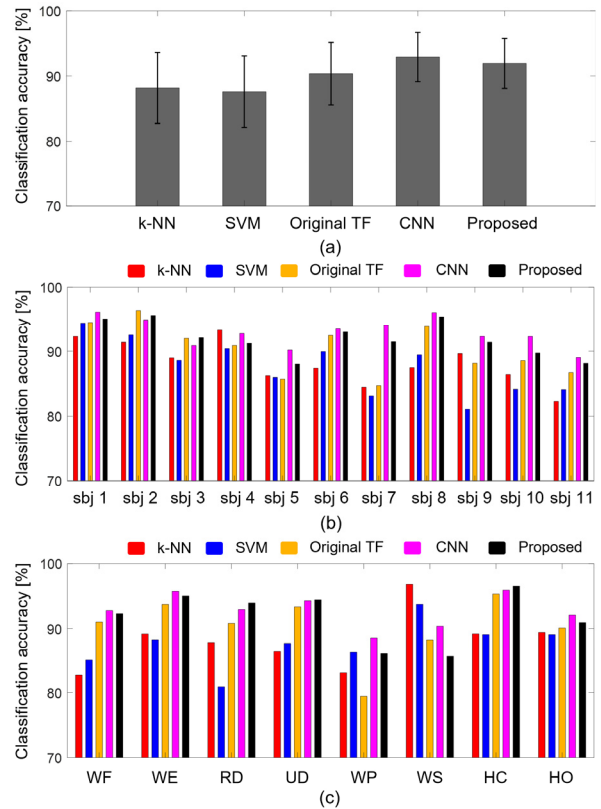
[Fig. 11] The visualization of sEMG and generated patterns from the algorithm. For each case, following motions are conducted: (a) wrist flexion and wrist extension, (b) radial deviation and ulnar deviation, (c) wrist pronation and wrist supination, and (d) hand close and hand open

5.2 표면 근전도 및 생성된 패턴 시각화

패턴의 시각화를 위해, 7개의 표면 근전도 채널 중 동작을 구분할 수 있는 특징이 두드러진 두 개의 채널을 선정한 후 이를 2차원 좌표계에 표현하였다. [Fig. 11]은 특정 피실험자의 각 자유도(총 4자유도: 손목 3자유도 + 손 1자유도)별로 길항적으로 작용하는 두 가지 동작에서 도출된 표면 근전도와 생성된 패턴을 나타내고 있다. 각 피실험자마다 주요 근전도 채널 및 활성화 양상이 달라 대표적인 경우만 [Fig. 11]에 나타내었으나, 패턴이 형성되는 양상에서 큰 차이를 보이거나 알고리즘이 제대로 적용되지 않은 경우는 없었다. 이를 통해 제안하는 알고리즘이 채널 사이의 상관관계를 잘 표현할 수 있는 주성분과 그에 상응하는 축 길이를 계산하여 표면 근전도를 잘 표현할 수 있는 패턴을 생성하고 있음을 알 수 있다. 또한, 4.1의 결과를 뒷받침 하듯이 패턴 대부분이 한 가지 동작에서 도출된 표면 근전도를 포함하고 있음을 확인할 수 있다.

5.3 동작 분류 정확도 비교

[Fig. 12]는 k-최근접 이웃, 서포트 벡터 머신, 기존 알고리즘,



[Fig. 12] (a) Total, (b) subject-wise, and (c) motion-wise classification accuracy from k-nearest neighbor(k-NN), support vector machine(SVM), original algorithm(original TF), convolutional neural network(CNN), and the proposed method

컨볼루션 신경망, 그리고 제안하는 알고리즘을 썼을 때의 전체 및 각 동작의 분류 정확도를 나타내고 있다. [Fig. 12(a)]를 통해 제안하는 알고리즘이 컨볼루션 신경망을 제외한 다른 분류기보다 더 높은 분류 정확도를 보이는 것을 알 수 있다. 컨볼루션 신경망의 경우 가장 높은 분류 정확도를 보이는데, 그 이유는 해당 신경망이 컨볼루션 층의 커널을 통해 근전도를 고차원의 잠재 공간(latent space)으로 사영하여 각 동작의 고유한 특성을 더 잘 표현할 수 있기 때문으로 추정된다. k-최근접 이웃, 서포트 벡터 머신, 그리고 컨볼루션 신경망은 전체 데이터 분포를 고려하여 학습을 진행하므로, 새로운 데이터가 측정될 때마다 패턴을 업데이트하는 제안하는 알고리즘보다 최적화된 결정 경계(decision boundary)를 계산하기에 유리한 측면이 있다. 그럼에도 불구하고 제안하는 알고리즘이 높은 분류 정확도를 보인다는 점은 주목할 만한 결과이며, 제안하는 알고리즘이 동작과 연관성이 높은 패턴을 생성한다는 것을 보여준다. 특히, 제안하는 알고리즘은 기존 지도 학습 기반의 분류기와 달리 레이블 없이도 패턴 형성이 가능할 뿐만 아니라 많은 양의 데이터로 파라미터를 업데이트하는 인공 신경망과 달리 새로운 데이터가 들어올 때마다 업데이트가 가능하다는 장점이 있다. 각 피실

협자별 분류 정확도를 나타낸 [Fig. 12(b)]의 경우, 앞서 설명한 이유로 인해 제안하는 알고리즘이 컨볼루션 신경망을 제외한 다른 분류기들에 비해 대부분의 피실험자에서 높은 분류 정확도를 보이고 있다. 특히 제안하는 알고리즘은 기존 알고리즘과 비교했을 때 7번째 피실험자에 대해 가장 큰 차이를 보이고 있는데, 이는 주성분 분석을 통해 더 다양한 양상의 패턴을 생성할 수 있기 때문으로 추정된다.

그리고 [Fig. 12(c)]를 통해 제안하는 알고리즘이 손목 회내와 손목 회외를 제외한 모든 동작에서 k-최근접 이웃과 서포트 벡터 머신보다 더 높은 분류 정확도를 보인다는 것을 알 수 있다. 손목 회내와 손목 회외에서 더 낮은 분류 정확도를 보이는 이유는 손과 손목 동작에 관여하는 전완부 근육들과 관련이 있다. 손목 회내에 관여하는 방형회내근(pronator quadratus)은 피부에서부터의 거리가 먼 심부 근육(deep muscle)에 속하므로 표면 근전도를 획득하기 어렵다. 또한, 손목 회내에 관여하는 또 다른 근육인 원회내근(pronator teres)은 피부에서부터의 거리가 가까운 표면적 근육(superficial muscle)에 속하기는 하지만 그 크기가 인접 근육들보다 작아 표면 근전도를 얻기가 어렵다. 손목 회외에 관여하는 회외근(supinator) 또한 심부 근육이므로 표면 근전도 획득이 어렵다. 이러한 이유로 인해 두 동작에서 측정된 표면 근전도는 다른 동작과 비교할 때 그 세기가 작으며, 따라서 뚜렷한 구분 경계를 가지는 패턴 생성이 어려워 동작 분류 정확도가 낮아지게 된다. k-최근접 이웃과 서포트 벡터 머신의 경우 손목 회외에 대해 더 높은 분류 정확도를 보이는 것을 확인할 수 있는데, 이는 손목 회외에 대한 결정 경계가 다른 동작들에서 얻어지는 표면 근전도를 포함하기 때문이다. 따라서 손목 회외를 제외한 다른 동작에 대해서는 더 낮은 분류 정확도를 보이게 된다.

6. 고찰

기존 알고리즘과 제안하는 알고리즘은 패턴의 중심과 그 경계에 대해 등가 관계가 존재한다. 설명에 앞서 패턴에 포함된 데이터의 개수를 N_x , 데이터 채널의 개수를 N_{CH} , 새로 등록된 패턴의 표준 편차를 σ_r , 업데이트할 때의 표준 편차를 σ_u , 그리고 기존 방법에서 새로운 패턴을 등록하는 확률 문턱을 p^* 로 표현하였다.

우선, 기존 방법에서 데이터 x 로 업데이트되는 패턴의 중심 μ_o 은 다음과 같이 표현된다.

$$\mu_o = \frac{\sigma_u^2 \bar{\mu}_o + \sigma_o^2 x}{\sigma_u^2 + \sigma_o^2} \quad (18)$$

여기서 $\bar{\mu}_o$ 와 $\bar{\sigma}_o$ 는 각각 업데이트 전 패턴의 평균과 표준 편차

를 의미한다. 식 (18)을 통해 N_x 개의 데이터 x_1, \dots, x_{N_x} 로부터 등록 및 업데이트된 패턴의 중심 μ_o 은 다음과 같이 표현된다.

$$\mu_o = \frac{\sigma_u^2 x_1 + \sigma_r^2 \sum_{n=2}^{N_x} x_n}{\sigma_u^2 + (N_x - 1)\sigma_r^2} \quad (19)$$

만약 데이터 샘플의 개수가 많아져 $(N_x - 1)\sigma_r^2 \gg \sigma_u^2$ 의 조건을 만족하게 될 경우, μ_o 는 다음과 같이 산술 평균(arithmetic mean)으로 수렴하게 된다.

$$\mu_o \approx \frac{\sigma_r^2 \sum_{n=2}^{N_x} x_n}{(N_x - 1)\sigma_r^2} = \frac{\sum_{n=2}^{N_x} x_n}{N_x - 1} \quad (20)$$

식 (20)을 통해, 데이터 샘플의 개수가 일정 수준 이상으로 많아지면 기존 방법과 제안하는 방법에서의 패턴의 중심은 같은 값으로 수렴하게 된다는 것을 알 수 있다.

다음으로, 기존 방법에서 패턴의 경계는 주변 가능도(marginal likelihood)가 확률 문턱 p^* 보다 낮아지는 지점으로 결정된다. 다만 기존 방법에서는 각 채널의 표준 편차가 같으므로, 비교를 위해 제안하는 방법에서의 주성분 축 길이가 같을 때의 등가 관계를 분석하였다.

패턴의 경계에 위치하는 특정 근전도 채널 데이터 x 는 다음의 식을 만족한다.

$$\frac{1}{\sqrt{2\pi\sigma_o^2}} \exp\left(-\frac{(x - \mu_o)^2}{2\sigma_o^2}\right) = (p^*)^{\frac{1}{N_{CH}}} \quad (21)$$

식 (21)을 정리하면 다음의 관계식을 얻을 수 있으며,

$$(x - \mu_o)^2 = 2\sigma_o^2 \left(\frac{1}{N_{CH}} \ln\left(\frac{1}{p^*}\right) + \frac{1}{2} \ln\left(\frac{1}{2\pi\sigma_o^2}\right) \right) \quad (22)$$

마지막으로 식 (22)를 x 에 대해 정리하면 다음과 같다.

$$x = \mu_o \pm \sqrt{2\sigma_o^2 \left(\frac{1}{N_{CH}} \ln\left(\frac{1}{p^*}\right) + \frac{1}{2} \ln\left(\frac{1}{2\pi\sigma_o^2}\right) \right)} \quad (23)$$

따라서, 제안하는 알고리즘에서의 주성분 축 길이 R 은 다음과 같은 등가 관계에 있다고 결론지을 수 있다.

$$R \leftrightarrow \sqrt{2\sigma_o^2 \left(\frac{1}{N_{CH}} \ln\left(\frac{1}{p^*}\right) + \frac{1}{2} \ln\left(\frac{1}{2\pi\sigma_o^2}\right) \right)} \quad (24)$$

7. 결 론

본 논문에서는 새로운 학습 데이터를 지속적으로 획득할 때 사용자의 부담이 증가하는 점과 그 획득 기준을 정하기 어렵다는 점을 완화하기 위한 주성분 분석을 활용한 적응형 근전도 패턴 인식 알고리즘을 제안하였다. 제안하는 알고리즘은 주성분 분석을 통해 각 채널의 상관관계를 계산하며, 이를 통해 표면 근전도를 효율적으로 표현할 수 있는 패턴을 찾아낸다. 또한, 제안하는 알고리즘은 새로운 표면 근전도가 측정될 때마다 설정한 기준에 따라 기존 패턴을 업데이트할지 혹은 새로운 패턴을 등록할지 판단하여 시간의 흐름에 따른 신호의 특성 변화에 적응하게 된다. 그리고 실험 결과를 통해, 제안하는 알고리즘에서 다양한 패턴이 생성된다는 것과 해당 패턴이 동작과도 높은 연관성을 보인다는 것을 확인하였다. 또한, 이를 분류기로 활용하였을 때도 높은 분류 정확도를 보인다는 것을 확인할 수 있었다. 이러한 이유에서, 제안하는 알고리즘이 사용자의 개입 없이도 표면 근전도의 변화에 적응하여 오래 사용할 수 있는 패턴 인식에 활용될 수 있기를 기대한다.

References

- [1] M. Zheng, M. S. Crouch, and M. S. Eggleston, "Surface electromyography as a natural human-machine interface: a review," *IEEE Sensors Journal*, vol. 22, no. 10, pp. 9198-9214, May, 2022, DOI: 10.1109/JSEN.2022.3165988.
- [2] M. R. Williams and R. F. Kirsch, "Evaluation of head orientation and neck muscle EMG signals as command inputs to a human-computer interface for individuals with high tetraplegia," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 16, no. 5, pp. 485-496, Oct., 2008, DOI: 10.1109/TNSRE.2008.2006216.
- [3] K. Gui, H. Liu, and D. Zhang, "A practical and adaptive method to achieve EMG-based torque estimation for a robotic exoskeleton," *IEEE/ASME Transactions on Mechatronics*, vol. 24, no. 2, pp. 483-494, Apr., 2019, DOI: 10.1109/TMECH.2019.2893055.
- [4] M. Ghassemi, K. Triandafilou, A. Barry, M. E. Stoykov, E. Roth, F. A. Mussa-Ivaldi, D. G. Kamper, and R. Ranganathan, "Development of an EMG-controlled serious game for rehabilitation," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 27, no. 2, pp. 283-292, Feb., 2019, DOI: 10.1109/TNSRE.2019.2894102.
- [5] C. Yang, J. Luo, C. Liu, M. Li, and S.-L. Dai, "Haptics electromyography perception and learning enhanced intelligence for teleoperated robot," *IEEE Transactions on Automation Science and Engineering*, vol. 16, no. 4, pp. 1512-1521, Oct., 2018, DOI: 10.1109/TASE.2018.2874454.
- [6] C. Shen, Z. Pei, W. Chen, J. Wang, J. Zhang, and Z. Chen, "Toward generalization of sEMG-based pattern recognition: A novel feature extraction for gesture recognition," *IEEE Transactions on Instrumentation and Measurement*, vol. 71, pp. 1-12, Jan., 2022, DOI: 10.1109/TIM.2022.3141163.
- [7] Y. Zheng, G. Xu, Y. Li, and W. Qiang, "Improved online decomposition of non-stationary electromyogram via signal enhancement using a neuron resonance model: A simulation study," *Journal of Neural Engineering*, vol. 19, no. 2, Apr., 2022, DOI: 10.1088/1741-2552/ac5f1b.
- [8] A. Furui, T. Igaue, and T. Tsuji, "EMG pattern recognition via Bayesian inference with scale mixture-based stochastic generative models," *Expert Systems with Applications*, vol. 185, Dec., 2021, DOI: 10.1016/j.eswa.2021.115644.
- [9] H. Wang, P. Huang, T. Xu, G. Li, and Y. Hu, "Towards zero retraining for multiday motion recognition via a fully unsupervised adaptive approach and fabric myoelectric armband," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 30, pp. 217-225, Jan., 2022, DOI: 10.1109/TNSRE.2022.3144323.
- [10] N. Zheng, Y. Li, W. Zhang, and M. Du, "User-independent emg gesture recognition method based on adaptive learning," *Frontiers in Neuroscience*, vol. 16, pp. 1-13, Mar., 2022, DOI: 10.3389/fnins.2022.847180.
- [11] R. Soroushmojdehi, S. Javadzadeh, A. Pedrocchi, and M. Gandolla, "Transfer learning in hand movement intention detection based on surface electromyography signals," *Frontiers in Neuroscience*, vol. 16, pp. 1-18, Nov., 2022, DOI: 10.3389/fnins.2022.977328.
- [12] S. Park, W. K. Chung, and K. Kim, "Training-free Bayesian self-adaptive classification for sEMG pattern recognition including motion transition," *IEEE Transactions on Biomedical Engineering*, vol. 67, no. 6, pp. 1775-1786, Jun., 2020, DOI: 10.1109/TBME.2019.2947089.
- [13] S. Park, H.-J. Lee, W. K. Chung, and K. Kim, "Training-Free sEMG Pattern Recognition Algorithm: A Case Study of A Patient with Partial-Hand Amputation," *Journal of Korea Robotics Society*, vol. 14, no. 3, pp. 211-220, Aug., 2019, DOI: 10.7746/jkros.2019.14.3.211.
- [14] T. Matsubara and J. Morimoto, "Bilinear modeling of EMG signals to extract user-independent features for multiuser myoelectric interface," *IEEE Transactions on Biomedical Engineering*, vol. 60, no. 8, pp. 2205-2213, Aug., 2013, DOI: 10.1109/TBME.2013.2250502.
- [15] Z. Li, B. Wang, C. Yang, Q. Xie, and C.-Y. Su, "Boosting-based EMG patterns classification scheme for robustness enhancement," *IEEE Journal of Biomedical and Health Informatics*, vol. 17, no. 3, pp. 545-552, May, 2013, DOI: 10.1109/JBHI.2013.2256920.
- [16] A. H. Al-Timemy, G. Bugmann, J. Escudero, and N. Outram, "Classification of finger movements for the dexterous hand prosthesis control with surface electromyography," *IEEE journal of biomedical and health informatics*, vol. 17, no. 3, pp. 608-618, May, 2013, DOI: 10.1109/JBHI.2013.2249590.
- [17] 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, Jun., 2012, DOI: 10.1016/j.eswa.2012.01.102.

- [18] C. J. De Luca, L. Donald Gilmore, M. Kuznetsov, and S. H. Roy, “Filtering the surface EMG Signal: Movement artifact and Baseline Noise Contamination,” *Journal of Biomechanics*, vol. 43, no. 8, pp. 1573-1579, May, 2010, DOI: 10.1016/j.jbiomech.2010.01.027.
- [19] M. A. Oskoei and H. Hu, “Myoelectric Control Systems—a survey,” *Biomedical Signal Processing and Control*, vol. 2, no. 4, pp. 275-294, Oct., 2007, DOI: 10.1016/j.bspc.2007.07.009.
- [20] S. M. S. Shah, S. Batool, I. Khan, M. U. Ashraf, S. H. Abbas, and S. A. Hussain, “Feature extraction through parallel probabilistic principal component analysis for heart disease diagnosis,” *Physica A: Statistical Mechanics and its Applications*, vol. 482, pp. 796-807, Sept., 2017, DOI: 10.1016/j.physa.2017.04.113.
- [21] K. K. Vasan and B. Surendiran, “Dimensionality reduction using principal component analysis for network intrusion detection,” *Perspectives in Science*, vol. 8, pp. 510-512, Sept., 2016, DOI: 10.1016/j.pisc.2016.05.010.
- [22] A. C. Turlapaty and B. Gokaraju, “Feature analysis for classification of physical actions using surface EMG data,” *IEEE Sensors Journal*, vol. 19, no. 24, pp. 12196-12204, Dec., 2019, DOI: 10.1109/JSEN.2019.2937979.
- [23] F. Amirabdollahian and M. L. Walters, “Application of support vector machines in detecting hand grasp gestures using a commercially off the shelf wireless myoelectric armband,” *2017 IEEE International Conference on Rehabilitation Robotics(ICORR)*, London, UK, pp. 111-115, 2017, DOI: 10.1109/ICORR.2017.8009231.
- [24] X. Zhai, B. Jelfs, R. H. M. Chan, and C. Tin, “Self-recalibrating surface EMG pattern recognition for neuroprosthesis control based on convolutional neural network,” *Frontiers in Neuroscience*, vol. 11, pp. 1-11, Jul., 2017, DOI: 10.3389/fnins.2017.00379.
- [25] A. Subasi, “Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders,” *Computers in Biology and Medicine*, vol. 43, no. 5, pp. 576-586, Jun., 2013, DOI: 10.1016/j.combiomed.2013.01.020.



김 세 진

2017 포항공과대학교 기계공학과(학사)
2017~현재 포항공과대학교 기계공학과
통합과정

관심분야: Biosignal processing, AI-based biorobotics



정 완 균

1981 서울대학교 기계설계학과(학사)
1983 한국과학기술원 기계공학(석사)
1987 한국과학기술원 로봇공학(박사)
1987~1993 포항공과대학교 기계공학과
조교수

1993~2000 포항공과대학교 기계공학과 부교수

2000~현재 포항공과대학교 기계공학과 교수

관심분야: Medical Robot, Surgical Robot, Robust Control,
Underwater Robot, Haptics