

다채널 말초 신경신호의 실시간 디코딩

Real-Time Decoding of Multi-Channel Peripheral Nerve Activity

지인혁*, 이연정*, 추준욱**★

In-Hyeog Jee*, Yun-Jung Lee*, Jun-Uk Chu**★

Abstract

Neural decoding is important to recognize the user's intention for controlling a neuro-prosthetic hand. This paper proposes a real-time decoding method for multi-channel peripheral neural activity. Peripheral nerve signals were measured from the median and radial nerves, and motion artifacts were removed based on locally fitted polynomials. Action potentials were then classified using a k-means algorithm. The firing rate of action potentials was extracted as a feature vector and its dimensionality was reduced by a self-organizing feature map. Finally, a multi-layer perceptron was used to classify hand motions. In monkey experiments, all processes were completed within a real-time constrain, and the hand motions were recognized with a high success rate.

요약

신경의수를 제어하기 위해서는 사용자의 의도를 인식하는 신경신호 디코딩이 중요하다. 본 논문에서는 다채널 말초 신경신호의 실시간 디코딩 방법을 제안한다. 말초 신경신호는 정중신경과 요골신경에서 측정되었으며 운동잡음은 국소 근사 다항식에 의해 제거되었다. 다음으로 활동전위는 k-평균 알고리즘으로 분류되었다. 특징벡터는 활동전위의 발화율로부터 추출되었으며 자기 조직화 특징지도를 통해 차원이 축소되었다. 마지막으로 다층 퍼셉트론으로 손동작을 분류하였다. 원숭이 실험에서 모든 신호처리가 실시간 제한조건 이내에 완료되었으며 높은 성공률로 손동작을 인식할 수 있었다.

Key words : Neural activity, Decoding, Action potentials, Neuro-prosthetic hand, Monkey experiments

1. 서론

상지 절단환자의 감각과 운동기능을 복원하기 위해 자신의 손처럼 느끼고 움직일 수 있는 신경의수

(neuro-prosthetic hand) 연구가 활발히 진행되고 있다[1]-[3]. 이러한 연구는 절단으로 인해 손기능에 심각한 장애를 가지더라도 감각과 운동에 관계된 말초 신경계의 기능은 유지된다는 사실에 기반

* School of Electronics Engineering, Kyungpook National University

** Dept. of Medical Device, Daegu Research Center for Medical Devices and Rehabilitation Engineering, Korea Institute of Machinery and Materials

★ Corresponding author

E-mail : juchu@kimm.re.kr, Tel : +82-53-670-9105

※ Acknowledgment

This work was supported in part by the convergence technology development program for bionic arm through the National Research Foundation of Korea (NRF) funded by the Ministry of Science & ICT (2017M3C1B2085311) and the National Research Council of Science & Technology (NST) grant by the Korea government (MSIT) (No. CAP-18-01-KIST). Manuscript received Nov. 25, revised Dec. 23 2020; accepted Dec. 28, 2020.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

하고 있다. 즉, 절단환자는 잔존하는 말초신경을 통해 인공적으로 유발된 감각정보를 전달받을 수 있으며 의수를 움직일 수 있는 동작명령을 생성할 수 있다.

최근 연구들에서는 다양한 감각정보 전달과 다자유도 동작명령 생성을 위해 다채널의 신경전극을 절단환자의 말초신경에 이식함으로써 다수의 독립적인 신경신호 채널을 확보하고 있다. 이를 기반으로 전기자극을 통해 활동전위를 유발함으로써 감각피드백이 제공되며, 신경신호 측정을 통해 활동전위를 검출함으로써 동작의도를 추정하고 있다.

대표적 다채널 신경전극인 유타전극(Utah slanted electrode array)은 상지 절단환자의 잔존 말초신경에 삽입되어 최대 131개의 자기수용감각 또는 외부수용감각 정보를 전달할 수 있었으며 5자유도의 동작명령을 생성할 수 있었다[4]. 구체적으로 동작의도를 추정하는 과정은 192채널의 신경신호로부터 활동전위를 검출하고 채널별로 33-ms 증가분을 가진 300-ms 이동윈도우 내 활동전위 발화율을 계산하여 칼만필터의 입력으로 사용하였다. 이 과정에서 모든 채널의 발화율을 칼만필터의 입력으로 사용하였을 때 추정 성능이 저하되는 문제가 발생하였으며, 이를 해결하기 위해 측정된 발화율과 제시된 동작명령 사이의 상관관계가 높은 채널만을 실험자가 수동으로 선택하였다. 이러한 수동 채널선택은 환자의 훈련과정 중에 수행되었으며 칼만필터의 오프라인 학습과정에 반영되었다. 오프라인 학습이 완료된 후 검증과정에서 채널선택 및 칼만필터의 성능이 평가되었다. 이와 같이 실험자가 개입하는 수동 채널선택 과정은 디코딩 알고리즘을 온라인으로 학습시킬 수 없게 하는 제약조건으로 작용한다. 디코딩 알고리즘의 온라인 학습은 절단환자의 훈련시간을 단축할 수 있을 뿐만 아니라 훈련과정 중에 디코딩 결과를 절단환자에게 피드백함으로써 훈련효율을 향상시킬 수 있다. 기존의 연구들에서 보고된 바와 같이 신경전극이 삽입되는 말초신경 주위는 근육에서 발생하는 근전도 간섭과 근육 수축운동에 의한 전극 및 전선의 움직임 잡음이 발생하는 열악한 환경이다[4]. 따라서 측정된 신경신호에 대하여 주파수대역 필터뿐만 아니라 추가적인 운동잡음 제거 알고리즘이 필요하다. 이와 함께 말초신경 다발 내 신경섬유 단위의 신경신호 분해가 가능한 활동전위 분류 알고리즘을 적

용함으로써 동작의도 디코딩 성능을 향상시킬 수 있다. 기존의 연구들은 다채널 신경신호의 실시간 처리를 위해 많은 연산이 필요한 운동잡음 제거 및 활동전위 분류 알고리즘을 생략하고 있다.

본 논문에서는 훈련과정 중에 디코딩 알고리즘을 온라인으로 학습시킬 수 있는 방법을 제안한다. 이를 위하여 수동 채널선택을 대신하여 활동전위 발화율 벡터의 차원을 자동으로 축소할 수 있는 자기조직화 특징지도를 제안한다. 이와 같은 방법은 클래스 분리도는 유지하면서 차원이 축소된 특징벡터를 제공함으로써 동작의도 분류기인 다층 퍼셉트론이 온라인으로 학습 파라미터를 갱신할 수 있었다. 또한 다채널 말초 신경신호에 대해 운동잡음 제거 알고리즘과 활동전위 분류 알고리즘을 실시간으로 처리할 수 있는 병렬 처리 구조를 제안한다. 이러한 구조를 이용하여 64채널의 말초 신경신호에 대하여 운동잡음 제거, 활동전위 검출 및 분류, 차원축소, 동작의도 분류를 포함하는 모든 알고리즘을 34.13 ms 이내에 처리할 수 있었다. 원숭이를 대상으로 하는 동물실험에서는 운동잡음이 발생하는 상황에서도 안정적인 활동전위 검출과 분류가 가능하였으며, 원숭이가 파지동작을 훈련하는 과정 중에 활동전위 패턴을 온라인으로 학습하고 파지동작을 분류할 수 있었다.

II. 말초 신경신호 측정 시스템

1. 원숭이 동물모델

생리학적 반응과 계통 발생학적 유사성의 이유로 인간과 비슷한 비인간 영장류(non-human primate)가 의학 연구 분야에서 많이 활용되고 있다. 본 논문에서는 신경공학 연구에 가장 많이 사용되는 Rhesus 원숭이(*Macaca mulatta*)를 대상으로 동물실험을 진행하였다.




Fig. 1. Rhesus monkey and insertion site of neural electrode.
그림 1. 원숭이 동물모델과 신경전극 삽입위치




Fig. 2. Fork type neural electrode and neural amplifier.
그림 2. 포크타입 신경전극과 신경신호 증폭기.

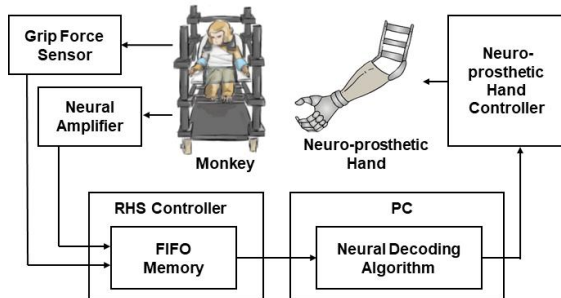


Fig. 3. Experimental setup for neural decoding.
그림 3. 신경신호 디코딩을 위한 실험환경 구축

손의 파지동작은 각 손가락의 굴곡-신전 운동 (flexion-extension motion)을 통해 이루어지며 상완 신경총(Brachial plexus)에서 분화하는 정중신경(Median nerve)과 요골신경(Radial nerve)이 주로 관여한다. 정중신경은 엄지부터 약지까지의 굴곡운동에 관여하며 요골신경은 손등쪽의 모든 신전근에 연결되어 있다. 그림 1과 같이 손가락의 굴곡운동과 신전운동에 관계된 신경신호를 동시에 측정하기 위해 정중신경과 요골신경을 대상으로 32채널 신경전극을 각각 삽입하였다. 본 실험은 한국생명공학연구원 동물보호 및 사용에 관한 가이드라인과 법규에 따라 수행되었다.

2. 말초 신경전극

말초신경으로부터 다채널의 신경신호를 검출하기 위해 사용한 포크타입 신경전극을 그림 2에 도시한다. 포크타입 신경전극은 4개의 가지(shank)로 구성되며 각 가지별로 8채널의 전극을 배치함으로써 총 32채널을 가지도록 제작하였다. 수술과정에서 포크타입 신경전극의 가지들을 말초신경을 관통하여 삽입함으로써 전극들이 신경섬유에 근접하도록 위치시킬 수 있었다. 또한, 유연한 지지체로 제작된 4개의 가지들은 말초신경 외경을 따라 일정 간격으로 삽입함으로써 32채널의 전극들을 말초신경 단면에 균일하게 배치할 수 있었다.

삽입된 신경전극은 근육운동에 의해 말초신경으로부터 이탈하는 현상과 함께 근전도 신호가 신경신호에 간섭을 일으키는 문제가 발생한다. 이를 해결하기 위해 의료용 실리콘으로 제작한 멤브레인으로 신경전극과 말초신경을 감싸는 형태로 고정하였다. 또한, 멤브레인 외막에 골드거즈를 몰딩하고 접지전극과 연결함으로써 근전도를 차폐하였다. 이 과정에서 기준전극은 골드거즈로 차폐된 멤브레인 내부의 신경외막에 위치시켜 차동 증폭기의 기준전압이 근전도에 의해 간섭을 일으키지 않도록 하였다.

3. 신경신호 증폭기

말초 신경신호를 측정하기 위해 Intan사의 32채널 RHS 증폭기를 사용하였다. 그림 2에서와 같이 체내 삽입을 위해 RHS 증폭기를 의료용 실리콘으로 몰딩하였으며 32채널 포크타입 신경전극과 연결하였다. 여기서, RHS 증폭기의 공통 차동입력에 기준전극을 결선하였으며, RHS 증폭기의 접지에 골드거즈를 포함한 멤브레인 접지전극을 결선하였다. 정중신경과 요골신경에 삽입된 2개의 포크타입 신경전극은 각각 RHS 증폭기와 결선되고 SPI 통신 케이블을 통해 체외에 위치한 RHS 컨트롤러와 연결되었다. 마지막으로 RHS 컨트롤러는 USB 통신을 통해 PC로 64채널의 신경신호를 전송하였다. 각 채널의 신경신호는 300 Hz에서 5000 Hz 구간의 대역폭에서 45.7 dB로 증폭되었으며 30 kSamples/s로 샘플링 되었다.

4. 실험환경 구축

원숭이 대상 실험환경은 원숭이에 삽입된 64채널 신경전극과 신경신호 증폭기, 파지력 센서, RHS 컨트롤러, 신경신호 디코딩을 위한 PC, 그리고 신경의수 제어기와 신경의수로 구성되었다. 그림 3에서 보듯이 원숭이를 실험의자에 앉히고 파지력 센서를 쥐는 동작을 반복하도록 유도하였다. RHS 컨트롤러는 64채널 신경신호와 파지력 센서 출력을 30 kSample/s로 동시에 샘플링하고 FIFO 메모리에 저장하였다. 여기서 파지력은 원숭이의 파지동작 구간을 검출하기 위해 측정되었으며 온라인 학습 및 검증과정에서 사용되었다. 다음으로 PC에서는 신경신호 디코딩 알고리즘이 수행되었으며 말초 신경신호로부터 원숭이의 파지동작을 추정하였

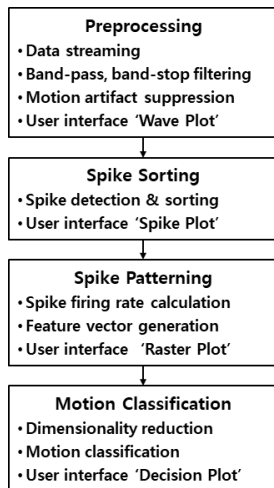


Fig. 4. Signal processing structure for real-time decoding of multi-channel peripheral nerve activity.

그림 4. 다채널 말초 신경신호의 실시간 디코딩을 위한 신호 처리 구조

다. 마지막으로 추정된 파지동작은 신경의수 제어기로 전달되어 신경 의수를 제어하는 동작명령으로 사용되었다.

III. 말초 신경신호 처리 알고리즘

본 장에서는 다채널 말초 신경신호의 실시간 디코딩을 위한 병렬 처리 구조와 온라인 학습 알고리즘을 제안한다.

1. 말초 신경신호 처리 구조

신경신호 디코딩 알고리즘은 그림 4에서 보듯이 4가지 신호처리 과정으로 구성되었으며 실험자가 그 결과를 모니터링할 수 있도록 사용자 인터페이스를 제공하였다.

- 1) 전처리 과정에서는 연속적인 데이터 스트리밍을 기반으로 대역통과 및 차단 필터링과 운동잡음 제거 알고리즘을 수행하였다. 또한, 신호처리 결과를 분석할 수 있도록 'wave plot' 윈도우를 제공하였다.
- 2) 활동전위 분류 과정에서는 잡음이 제거된 신경신호로부터 활동전위를 검출하고 분류하였으며 실험자는 'spike plot' 윈도우를 통해 64채널에 대한 활동전위 분류 결과를 확인하였다.
- 3) 활동전위 패턴링 과정에서는 활동전위가 검출된 시점과 분류된 군집정보로부터 래스터 데이터를 생성하고 'raster plot' 윈도우로 출력

하였다. 이와 함께 파지력 센서 출력을 래스터 데이터와 동기화하여 보여줌으로써 활동전위와 파지동작 사이의 상관관계를 모니터링할 수 있도록 하였다. 또한, 채널별 활동전위 발화율을 계산하여 특징벡터를 생성하였다.

- 4) 동작의도 분류 과정에서는 자기조직화 특징지도를 이용하여 고차원의 특징벡터를 저차원으로 축소하고 그 결과를 'decision plot' 윈도우에 출력하였다. 또한, 다층 퍼셉트론을 이용하여 데이터 윈도우 마다 원숭이의 파지동작을 추정하고 그 결과를 파지력 센서 출력값과 함께 도시하였다.

2. 병렬 처리 구조

절단환자가 시간지연을 느끼지 않고 의수를 제어하기 위해서는 동작의도를 가진 신경신호가 발생한 시점으로부터 100 ms 이내에 동작의도를 추정하고 의수를 구동해야 한다. 본 연구에서는 디코딩 알고리즘이 34.13-ms 윈도우 데이터를 34.13 ms 이내에 처리하는 실시간 제한조건을 설정하였다. 이러한 실시간 제한조건은 동작의도 발생에서부터 의수 구동까지 68.23 ms 이하의 시간지연을 보장한다.

본 논문에서는 다음과 같은 병렬 처리 구조를 제안한다.

- 1) 데이터 스트리밍 쓰레드는 64 채널의 신경신호를 포함하는 34.13-ms 윈도우 데이터를 RHS 컨트롤러의 FIFO 메모리로부터 읽어오고 64개의 채널별 쓰레드로 분배한다.
- 2) 병렬화된 각 채널별 쓰레드에서는 대역통과 및 차단 필터링과 운동잡음 제거, 활동전위 검출 및 분류, 발화율 계산을 진행한다. 활동전위 분류에서 채널별로 3개의 군집을 허용하여 최대 192개의 군집이 생성된다. 발화율은 34.13-ms 증가분을 가진 68.26-ms 중첩윈도우에서 각 군집별로 계산되며 최종적으로 192차원의 특징벡터를 생성한다.
- 3) 8개의 차원축소 쓰레드는 각각 8채널에 해당하는 24차원의 특징벡터를 2차원으로 축소함으로써 192차원의 특징벡터를 16차원으로 축소한다.
- 4) 동작의도 분류 쓰레드에서는 16차원으로 축소된 특징벡터로부터 동작의도를 추정한다.

이상의 과정에서 활동전위 분류, 차원축소, 동작 의도 분류는 온라인 학습이 가능한 알고리즘으로 구현되었다. 다채널 말초 신경신호의 실시간 디코딩을 위한 병렬 처리 구조는 C++에서 구현되었으며 10코어 20쓰레드로 구성된 Intel Core i9 3.7GHz 프로세서를 사용하였다. 아래 절에서 신호처리 알고리즘을 상세히 기술한다.

3. 운동잡음 제거

운동잡음은 신경전극 주위의 근육활성에 따라 전극에 기록되는 근전도 간섭뿐만 아니라 근육의 수축운동에서 비롯된 전극 및 전선의 움직임 잡음을 포함한다. 운동잡음은 활동전위의 수배에서 수십 배의 진폭과 파장을 가질 수 있으며 장기간 활동전위의 검출을 방해할 수 있다. 역치값 이상의 운동잡음을 소거하는 블랭킹(blanking) 방법은 역치값 이상의 구간에 포함된 활동전위까지 제거함으로써 동작의도 추정 성능을 저해할 수 있다. 따라서 최소 시간 구간에서 운동잡음을 제거하여 데이터의 손실을 줄이고 필요한 정보를 유지하도록 하여야 한다.

운동잡음 제거를 위해 국소다항근사를 통한 잡음 제거(Subtraction of Artifacts by Local Polynomial Approximation, SALPA) 방법[5]을 이용하였다. 이 방법은 운동잡음은 모델링할 수 있으면서 활동전위는 표현하는 못하는 다항식을 찾고 이를 신경신호에서 빼줌으로써 운동잡음은 제거하고 활동전위는 유지하는 방법이다. 250 Hz 고역통과 필터와 60 Hz 대역차단 필터를 적용한 신경신호를 V_n 으로 표기한다. 여기서 n 은 데이터 윈도우 내 임의의 샘플 번호를 의미한다. 데이터 포인트 n_c 를 중심으로 $2N+1$ 개로 구성된 세그먼트를 다음과 같이 3 차 다항식 $A_n^{(n_c)}$ 으로 근사한다.

$$A_n^{(n_c)} = \alpha_0^{(n_c)} + \alpha_1^{(n_c)}(n - n_c) + \alpha_2^{(n_c)}(n - n_c)^2 + \alpha_3^{(n_c)}(n - n_c)^3$$

중심 포인트 n_c 에서 근사된 절편값 $\alpha_0^{(n_c)}$ 을 신경신호 V_{n_c} 에서 빼줌으로써 운동잡음이 제거된 신경신호 v_{n_c} 을 다음과 같이 구할 수 있다.

$$v_{n_c} = V_{n_c} - A_{n=n_c}^{(n_c)} = V_{n_c} - \alpha_0^{(n_c)}$$

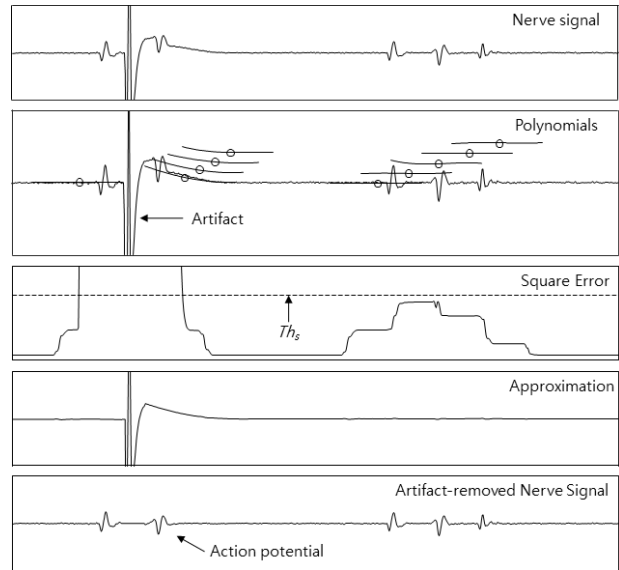


Fig. 5. Illustration of motion artifact removal by SALPA. 그림 5. SALPA를 이용한 운동잡음 제거 설명도

이 과정에서 근사화된 다항식의 나머지 부분들은 사용하지 않는다. 다음 포인트 n_c+1 에서 이상의 과정을 반복함으로써 운동잡음을 제거한다. 반면에 큰 운동잡음이 발생한 구간에서는 신경신호와 근사 다항식 사이의 오차합수

$$X_{n_c}^2 = \sum_{n=n_c-N}^{n_c+N} (V_n - A_n^{(n_c)})^2$$

를 계산하여 역치값 Th_s 이상의 구간에 대하여 근사 다항식을 추정된 신경신호로 대신한다. 이러한 구간은 결과적으로 블랭킹 방법과 동일한 결과를 가진다. 이를 보완하기 위해 역치값 이상의 구간에 진입 또는 탈출하는 시점에서 3차 다항식의 후반부 또는 전반부 $N+1$ 개 값을 이용하여 운동잡음을 근사한다. 이러한 보완 방법은 그림 5에서 보듯이 블랭킹 구간을 최소화하면서 역치값 이상의 구간에도 활동전위가 손실 없이 유지됨을 알 수 있다.

원숭이 실험에서 운동잡음의 진폭과 파장을 고려하여 세그먼트의 크기 $2N+1$ 을 121(6 ms)로 설정하였다. 또한 운동잡음이 발생한 구간만을 검출하도록 역치값 Th_s 를 30,000으로 설정하였다.

4. 활동전위 검출 및 분류

운동잡음이 제거된 신경신호 x 에 대하여 활동전위를 검출하기 위해 역치값 Th_d 을 다음과 같이 설정하였다[6].

$$Th_d = -6\sigma_n, \sigma_n = \text{median}\left\{\frac{|x|}{0.6745}\right\}$$

여기서 σ_n 는 백그라운드 잡음의 표준편차 추정치로서 신경신호의 중간값(median)을 기반으로 계산된다. 이와 같은 방법은 역치값 설정에서 활동전위 발화율의 간섭을 배제할 수 있다. 일반적으로 신경신호의 표준편차를 이용할 경우 활동전위 발화율에 따라 역치값이 증가하거나 감소하는 현상이 발생한다. 신경신호가 역치값에 도달하는 시점을 기준으로 이전 0.5 ms에서 이후 1.5 ms까지의 2-ms 구간을 활동전위로 검출하였다.

다음으로 k-평균(k-means)[7] 알고리즘을 기반으로 활동전위 분류를 위한 비교사 온라인 학습을 설명한다. 검출된 활동전위의 2-ms 윈도우 데이터를 X 그리고 군집의 평균파형을 μ_j 로 표기한다. 여기서 $j=1, \dots, k$ 이고, k 는 군집의 개수이다.

- 1) 초기 군집의 개수는 1이며 평균파형의 초기값은 검출된 활동전위로부터 설정한다.
- 2) 검출된 활동전위와 가장 유사한 평균파형의 군집 번호 $i(X)$ 를 다음과 같이 계산하고 활동전위 분류 결과로 출력한다.

$$i(X) = \underset{j}{\operatorname{argmin}} \|X - \mu_j\|, j = 1, \dots, k$$

- 3) 검출된 활동전위와 가장 유사한 평균파형과의 거리를 다음과 같이 계산한다.

$$D = \|X - \mu_{i(X)}\|$$

- 4) 거리 D 가 역치값 Th_D 이하이면 군집의 평균파형을 다음과 같이 갱신한다.

$$\mu_{i(X)} \leftarrow (\eta - 1)\mu_{i(X)} + \eta X$$

여기서 η 는 학습계수이다.

- 5) 거리 D 가 역치값 Th_D 이상이면 군집의 개수 k 를 증가시키고 새로운 평균파형의 초기값은 검출된 활동전위로 설정한다.
- 6) 군집의 개수 k 가 설정값 Th_k 이하이면 과정 (2)-(5)를 반복하고, 군집의 개수 k 가 설정값 Th_k 이상면 과정 (2)-(4)를 반복한다.

원숭이 실험에서 학습계수 η 를 0.1, 거리 역치값 Th_D 를 55,000 그리고 군집 개수 역치값 Th_k 를 3으

로 설정하였다.

5. 차원 축소

활동전위 분류에서 채널별로 3개의 군집을 허용하여 최대 192개의 군집이 생성되었다. 활동전위 발화율은 각 채널별로 34.13-ms 증가분을 가진 68.26-ms 중첩윈도우에서 각 군집에서 포함되는 활동전위의 개수로 산출되었으며 최종적으로 192차원의 특징벡터를 생성하였다.

기존의 수동 채널선택 방법을 대신하여 클래스 분리도는 유지하면서 특징벡터의 차원을 자동으로 축소할 수 있는 자기조직화 특징지도(Self-Organizing Feature Map, SOFM)[8] 알고리즘을 제안한다. 본 논문에서는 8개의 SOFM이 각각 24차원의 입력층과 40×40 의 2차원 격자공간 출력층을 가지도록 구성하였다. 연결강도는 비교사 온라인 학습으로 갱신되었으며 다음과 같이 구현되었다. 이산시간 n 에서의 특징벡터를 $X(n)$ 그리고 연결강도를 $w_j(n)$ 로 표기한다. 여기서 $j=1, \dots, l$ 이고, l 는 출력층 뉴런의 개수이다.

- 1) 연결강도 $w_j(0)$ 를 무작위로 초기화한다.
- 2) 입력된 특징벡터와 가장 유사한 연결강도를 가진 승리뉴런의 번호 $i(X)$ 를 다음과 같이 계산하고 2차원 좌표값을 차원 축소 결과로 출력한다.

$$i(X) = \underset{j}{\operatorname{argmin}} \|X(n) - w_j(n)\|, j = 1, \dots, l$$

- 3) 모든 뉴런의 연결강도를 다음과 같이 갱신한다.

$$w_j(n+1) = w_j(n) + \eta(n)h_{j,i(X)}(n)(X(n) - w_j(n))$$

여기서 $\eta(n)$ 은 학습계수, $h_{j,i(X)}(n)$ 은 승리뉴런 $i(X)$ 를 중심으로하는 거리비례 학습계수이다.

- 4) 과정 (2)와 (3)을 반복한다.

과정 (3)에서 거리비례 학습계수가 시변특성을 가지도록 다음과 같이 설정하였다.

$$h_{j,i(X)} = \exp\left(-\frac{d_{i,j}^2}{2\sigma^2(n)}\right)$$

여기서 $d_{i,j}$ 는 승리뉴런 i 와 연결강도를 갱신하는 뉴런 j 간의 유클리디언 거리(Euclidean distance)를 의미한다. 거리비례 함수의 폭을 의미하는 σ 는 이

산시간 n 에 대해 지수적으로 감소하도록 다음과 같이 설계하였다.

$$\sigma(n) = \sigma_0 \exp\left(-\frac{n}{\tau_1}\right)$$

여기서 σ_0 는 초기값이며 τ_1 은 시상수이다. 학습계수 또한 시변특성을 가지도록 초기값 η_0 에서 시작하여 이산시간 n 과 시상수 τ_2 에 따라 지수적으로 감소하도록 다음과 같이 설정하였다.

$$\eta(n) = \eta_0 \exp\left(-\frac{n}{\tau_2}\right)$$

원숭이 실험에서 거리비례 함수의 폭의 초기값 σ_0 를 20 그리고 시상수 τ_1 을 2000으로 설정하였다. 또한 학습계수의 초기값 η_0 을 1 그리고 시상수 τ_2 를 2,000으로 설정하였다.

6. 동작의도 분류

동작의도 분류를 위해 대표적인 비선형 분류기인 다층 퍼셉트론(Multi-Layer Perceptron, MLP) [8]을 이용하였다. MLP는 1개의 입력층, 2개의 은닉층, 1개의 출력층으로 구성되었으며 교사 온라인 학습으로 연결강도를 갱신하였다.

입력층은 이산시간 n 에서의 추출된 특징벡터로 구성되며 $x_l(n)$, $l=0,1,\dots,N_i$ 으로 표기한다. 여기서 바이어스는 $x_0(n)=1$ 로 정의되며, N_i 는 특징벡터의 16차원을 나타낸다. 공간 $[1,40]$ 의 좌표값으로 표현되는 특징벡터는 공간 $[-1,1]$ 으로 정규화되었다. 은닉층은 다음과 같이 표현된다.

$$h_k^1(n) = f\left(\sum_{l=0}^{N_i} w_{kl}(n)x_l(n)\right), \quad k=0,1,\dots,N_1$$

$$h_j^2(n) = f\left(\sum_{k=0}^{N_1} w_{jk}(n)h_k^1(n)\right), \quad j=0,1,\dots,N_2$$

여기서 바이어스는 $h_0^1(n)=h_0^2(n)=1$ 로 정의되며, $w_{kl}(n)$ 와 $w_{jk}(n)$ 는 연결강도를 의미한다. N_1 과 N_2 는 은닉층 뉴런의 개수이며 분류 성공률과 실시간 처리 성능을 고려하여 각각 16개와 5개로 설정하였다. 또한 뉴런의 활성화함수는 다음과 같이 양극성 시그모이드를 이용하였다.

$$f(v) = \frac{2}{1+e^{-v}} - 1$$

마지막으로 출력층은 다음과 같이 표현된다.

$$y_i(n) = f\left(\sum_{j=0}^{N_2} w_{ij}(n)h_j^2(n)\right), \quad i=1,\dots,N_o$$

여기서 $w_{ij}(n)$ 는 연결강도를 의미하며 N_o 는 출력층 뉴런의 개수이다. 원숭이의 휴지동작과 파지동작을 구분하기 위해 2개의 출력뉴런을 가지도록 설정하였다.

학습을 위한 교사 데이터는 $t_i(n)$, $i=1,\dots,N_o$ 으로 표기한다. 파지력의 역치값 Th_f 을 설정하고 휴지동작과 파지동작에 대한 교사 데이터를 각각 $[1,-1]$ 와 $[-1,1]$ 로 정의하였다. 따라서 오차는 다음과 같이 표현된다.

$$e_i(n) = t_i(n) - y_i(n), \quad i=1,\dots,N_o$$

뉴런의 연결강도는 오차역전과 학습 방법을 기반으로 다음과 같이 온라인으로 갱신되었다.

$$w_{ij}(n+1) = w_{ij}(n) + \eta \frac{\partial e_i(n)}{\partial y_i(n)} \frac{\partial y_i(n)}{\partial w_{ij}(n)}$$

$$w_{jk}(n+1) = w_{jk}(n) + \eta \frac{\partial e_i(n)}{\partial y_i(n)} \frac{\partial y_i(n)}{\partial h_j^2(n)} \frac{\partial h_j^2(n)}{\partial w_{jk}(n)}$$

$$w_{kl}(n+1) = w_{kl}(n) + \eta \frac{\partial e_i(n)}{\partial y_i(n)} \frac{\partial y_i(n)}{\partial h_k^1(n)} \frac{\partial h_k^1(n)}{\partial w_{kl}(n)}$$

여기서 η 는 학습계수이다.

원숭이 실험에서 학습계수 η 를 0.01로 설정하였다. 또한 파지력의 역치값 Th_f 를 1 N로 설정하여 1 N 이상일 경우 파지동작으로, 1 N 미만인 경우 휴지동작으로 교사 데이터를 생성하였다.

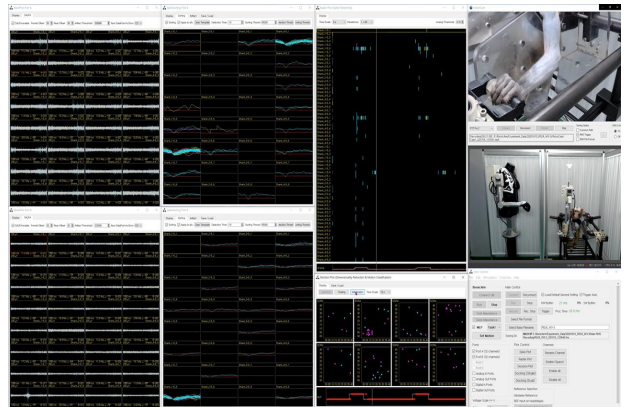


Fig. 6. User interface for real-time neural decoding.

그림 6. 실시간 신경신호 디코딩을 위한 사용자 인터페이스

IV. 원숭이 대상 다채널 말초 신경신호의 실시간 디코딩

1. 실시간 디코딩 프로그램

그림 6에서 원숭이 실험을 위해 개발된 실시간 신경신호 디코딩 프로그램을 보인다. ‘wave plot’에서 64채널의 신경신호와 운동잡음 제거 성능을 확인하였고 ‘spike plot’에서 활동전위 분류 결과를 모니터링하였다. ‘raster plot’을 통해 파지력이 발생할 때의 활동전위 패턴을 관찰하였으며 ‘decision plot’에서는 SOFM의 차원축소 및 군집화 성능과 MLP의 분류 성능을 검증하였다. 또한 비디오 윈도우를 통해 원숭이와 신경의수의 파지동작 영상을 동시에 모니터링할 수 있었다.

제안하는 디코딩 알고리즘은 병렬화된 채널별 쓰레드 프로그래밍 방법을 통해 34.13 ms 이내에 모든 처리가 완료되어야 하는 실시간 제한조건을 만족할 수 있었다. 20분간 수행된 원숭이 실험에서 전반 10분간 온라인 학습이 진행되었으며 후반 10분간 성능을 검증하였다. 다음 절에서 보이는 결과들은 실시간 처리과정에서 기록된 데이터이다.




Fig. 7. Neural signals before motion artifact removal. 그림 7. 운동잡음 제거 전 신경신호




Fig. 8. Neural signals after motion artifact removal. 그림 8. 운동잡음 제거 후 신경신호




Fig. 9. Effect of motion artifact removal on action potential waveform. 그림 9. 운동잡음 제거가 활동전위 파형에 미치는 영향

2. 운동잡음 제거 결과

그림 7과 8에서 운동잡음 제거 전과 후의 말초 신경신호를 보인다. 채널 1~32은 정중신경에서 측정된 신경신호이며 채널 33~64은 요골신경에서 측정된 신경신호이다. 그림 7에서 파지력 센서 출력과 신경신호를 동기화하여 도시하였으며 파지동

작 구간에서 큰 운동잡음이 관측되었다. 특히 파지 동작 시 손가락의 굴곡운동과 관계된 정중신경에서 운동잡음의 영향이 크게 나타났다. 그림 8에서 SALPA 알고리즘을 적용한 신경신호를 보인다. 파지 동작 구간에서 발생한 운동잡음이 상당부분 제거되었음을 확인할 수 있었다. 그림 9에서는 얇은 선과 굵은 선으로 SALPA 알고리즘의 적용 전과 후의 신경신호를 확대하여 도시한다. 전반부의 큰 운동잡음은 제거되었지만 후반부의 활동전위의 파형은 큰 영향을 받지 않았다. 이와 같은 운동잡음 제거 과정은 이후 수행되는 활동전위 검출 및 분류 결과에 큰 영향을 준다.

3. 활동전위 분류 결과

그림 10은 그림 8에서 보인 운동잡음이 제거된 1분 동안의 신경신호에 대하여 활동전위를 검출하고 분류한 결과이다. 채널당 최대 3개의 군집을 허용하였으며 서로 다른 색으로 도시하였다. 채널에 따라 활동전위 발화율이 다름에 따라 중첩되어 그려지는 활동전위의 개수가 서로 다르게 나타났다. 특히 정중신경에 삽입된 채널 16과 28 그리고 요골신경에 삽입된 채널 47의 발화율이 높게 나타났다.




Fig. 10. Sorted action potentials of 64-channel neural signals. 그림 10. 64 채널 신경신호의 분류된 활동전위

4. 활동전위 패턴닝 결과

그림 11에서는 채널별로 활동전위가 검출된 시점에 래스터를 생성함으로써 시간에 따른 활동전위 패턴을 보인다. 분류된 군집에 따라 래스터의 색을 달리 하였으며 파지력 센서 출력과 래스터 데이터를 동기화하여 도시하였다. 앞서 언급한 채널 16,

28 그리고 47에서 왼손이가 파지동작을 수행되는 동안 연속적인 활동전위 발화가 관측되었다. 다른 채널의 활동전위 발화패턴은 파지동작과 낮은 상관 관계를 보였다. 또한 일부 파지동작 구간에서는 많은 채널에서 동기화된 활동전위가 검출되었는데 이는 운동잡음이 완벽히 제거되지 못했기 때문이다.




Fig. 11. Raster data of 64-channel neural signals. 그림 11. 64 채널 신경신호의 래스터 데이터

5. 동작의도 분류 결과

래스터 데이터를 기반으로 중첩 윈도우 방법으로 활동전위 발화율을 계산하고 192차원의 특징벡터




Fig. 12. Dimensional reduced and clustered feature vectors. 그림 12. 차원축소 및 군집화된 특징벡터

를 산출하였다. 8개의 SOFM은 192차원의 특징벡터의 차원을 축소하고 유사한 특징벡터들을 군집화하였다. 그림 12에서 SOFM의 온라인 학습결과를 보인다. 빨간점과 파란점은 각각 휴지동작과 파지동작 구간에서 추출되고 차원이 축소된 특징벡터이다. SOFM 2, 6 그리고 8의 2차원 격자공간에서 파지동작에 해당하는 특징벡터가 군집을 형성하였다.

MLP는 16차원으로 축소된 특징벡터를 입력으로 휴지동작과 파지동작을 분류하도록 연결강도를 온라인으로 학습하였다. 그림 13에서 1분 동안의 동작의도 분류 결과를 보인다. 휴지동작을 클래스 0으로, 파지동작을 클래스 1로 표기하였다. 실선은 파지력 센서 출력으로 생성한 교사 데이터이며 빨간점은 34.13 ms 마다 출력되는 동작의도 분류 결과이다. 동작 클래스가 변화하는 구간에서 주로 오차가 발생되었으며 10분간의 검증과정에서 분류 성공률은 97.17%로 조사되었다.




Fig. 13. Classified hand motions.

그림 13. 분류된 손동작

V. 결론

본 논문에서는 기존의 오프라인 학습기반 동작의도 추정방법의 문제점을 극복하기 위해 다채널 말초 신경신호에 대하여 병렬 처리 구조와 온라인 학습 알고리즘을 제안하였다. 채널별 쓰레드 프로그밍을 통해 운동잡음 제거, 활동전위 검출 및 분류 그리고 차원축소 알고리즘이 병렬 처리되도록 구

성하였다. 동시에 활동전위 분류, 차원축소 그리고 동작의도 분류 알고리즘이 온라인으로 학습되도록 구현하였다.

제안한 병렬 처리 구조와 온라인 학습 알고리즘의 성능을 검증하기 위해 원숭이 실험을 진행하였다. 64채널의 말초 신경신호에 대하여 온라인 학습을 포함한 모든 알고리즘이 34.13 ms 이내에 처리됨을 확인하였다. 이와 같은 실시간 처리 성능은 절단환자가 시간지연을 느끼지 않으며 신경의수를 제어할 수 있도록 보장한다.

제안한 온라인 학습 알고리즘은 실험자의 개입 없이 원숭이의 말초 신경신호로부터 파지동작을 추정할 수 있었으며 학습 파라미터가 10분 이내에 수렴함을 확인하였다. 이와 같은 온라인 학습 성능은 절단환자의 훈련시간을 단축할 수 있을 뿐만 아니라 훈련과정 중에 디코딩 결과를 절단환자에게 피드백함으로써 훈련효율을 향상시킬 수 있다.

근육활성에 의한 운동잡음 간섭에도 불구하고 말초 신경신호로부터 파지동작을 97.17%의 성공률로 분류할 수 있었으며 분류결과를 바탕으로 신경의수를 제어할 수 있었다. 이와 같은 실험결과는 제안한 방법이 신경의수 제어를 위한 실시간 디코딩에 사용되어질 수 있음을 보였다.

향후에는 신경의수에 장착된 촉각센서 정보를 바탕으로 말초신경을 자극함으로써 사용자에게 촉각 정보를 피드백 할 수 있는 양방향 말초 신경 인터페이스로 발전시킬 계획이다.

References

- [1] A. Sharma, L. Rieth, P. Tathireddy, R. Harrison, and F. Solzbache, "Long term in vitro stability of fully integrated wireless neural interfaces based on utah slant electrode array," *Applied Physics Letters*, vol.96, issue.7, 073702, 2010.
DOI: 10.1063/1.3318251
- [2] D. Borton, S. Micera, Jdel. R Millán, and G. Courtine, "Personalized neuroprosthetics," *Science Translational Medicine*, vol.5, issue.210, 210rv2, 2013.
- [3] G. S. Dhillon, S. M. Lawrence, D. T. Hutchinson and K. W. Horch, "Residual function in peripheral nerve stumps of amputees: implications for neural

control of artificial limbs,” *The Journal of hand surgery*, vol.29, no.4, pp.605–615, 2004.

DOI: 10.1016/j.jhsa.2004.02.006

[4] S. Wendelken D. M. Page, T. Davis, H. A. Wark, D. T. Kluger, C. Duncan and G. A. Clark, “Restoration of motor control and proprioceptive and cutaneous sensation in humans with prior upper-limb amputation via multiple Utah Slanted Electrode Arrays (USEAs) implanted in residual peripheral arm nerves,” *Journal of neuroengineering and rehabilitation*, vol.14, no.1, 121, 2017.

DOI: 10.1186/s12984-017-0320-4

[5] D. A. Wagenaar and S. M. Potter, “Real-time multi-channel stimulus artifact suppression by local curve fitting,” *Journal of neuroscience methods*, vol.120, issue.2, pp.113–120, 2002.

DOI: 10.1016/s0165-0270(02)00149-8

[6] R. Quiroga, Quian, Z. Nadasdy and Y. Ben-Shaul, “Unsupervised spike detection and sorting with wavelets and superparamagnetic clustering,” *Neural computation*, vol.16, no.8, pp.1661–1687, 2004. DOI: 10.1162/089976604774201631

[7] U. Rutishauser, E. Schuman and A. Mamelak, “Online detection and sorting of extracellularly recorded action potentials in human medial temporal lobe recordings, in vivo,” *Journal of neuroscience methods*, vol.154, issue.1-2, pp.204–224, 2006.

DOI: 10.1016/j.jneumeth.2005.12.033

[8] H. Haykin, *Neural Networks: a comprehensive foundation*. Upper Saddle River, New Jersey: Prentice-Hall, 1999.

Yun-Jung Lee (Member)



1994 : Ph.D. degree in Electrical Engineering, Korea Advanced Institute of Science and Technology.
1995~present : Professor, School of Electronics Engineering, Kyungpook National University.

Jun-Uk Chu (Member)



2009 : Ph.D. degree in Electronics Engineering, Kyungpook National University.
2009~2013 : Post-Doctoral Fellow, Korea Institute of Science and Technology.
2014~present : Principal Researcher, Korea Institute of Machinery and Materials.

BIOGRAPHY

In-Hyeog Jee (Member)



2016 : B.S. degree in Mechatronics, Kumoh National Institute of Technology.
2019~present : M.S. degree course in Electronics Engineering, Kyungpook National University.