

Brain to IoT BCI 통신, Belief Propagation 기법을 이용한

Brain Area Binary Classification

김도영, 이해수, 이상현*

고려대학교, 한국과학기술원, 고려대학교

mharry345@korea.ac.kr, laura316@kaist.ac.kr, sanghyunlee@korea.ac.kr

Brain Area Binary Classification using

Belief Propagation technique for Brain to IoT BCI Communication

Kim Do Young, Lee Hye Su, Lee Sang Hyeon*

Korea University, KAIST, Korea University

요약

본 논문은 기존의 머신러닝 기반 BCI 통신의 한계를 극복하기 위한 또 다른 대안으로 뇌의 상호작용을 수학적으로 모델링하고 Belief Propagation 기법을 통한 이진 분류 알고리즘을 제시한다. 결과적으로, 적은 데이터만으로도 단축된 시간 내에 활성화된 뇌의 영역을 정확히 분류하는 것이 가능하다는 것을 보였다.

I. 서론

BCI (Brain-Computer Interface)는 뇌신경계로부터 발생한 신경 신호를 측정하고 분석하여 컴퓨터와 같은 외부 기기를 제어하거나 사용자의 의사를 전달하는 기술을 통칭한다. 최근 전체 BCI 산업에서 스마트 홈 제어(IoT) 분야가 약 15%를 차지하며 중요성이 확대되고 있다 [1].

하지만 뇌 신호는 노이즈가 심하고 사람과 시간에 따라 달라지기 때문에 처리하기가 매우 어렵다. 그래서 현재 대부분의 BCI는 신호를 분석하고 어떤 일을 수행할지 결정하는 과정에서 딥러닝 (Deep Learning)과 같은 머신러닝 (Machine Learning)을 필수적으로 사용하지만 딥러닝 기반의 BCI는 상용화되기에 여러 문제점이 존재한다. 첫째, 판단의 근거를 설명할 수 없는 블랙박스(Black-box) 문제로 인해 오작동 시 원인 규명이 어렵고, 시스템의 신뢰도를 감소시킨다 [2]. 둘째, 매 사용 전 수백 번 이상의 명령 수행을 통한 방대한 데이터 수집이 요구되므로 사용자 편의성이 저하되고, 이에 따라 현실에서 제한된 성능 저하와 과적합 문제가 일어난다 [3].

본 연구는 이러한 딥러닝의 한계를 극복하고자 한다. Brain to IoT 통신의 핵심은 사용자의 의도를 명확한 디지털 신호로 변환하는 것이다. 예를 들어, 전등을 켜거나 끄는 IoT 명령을 수행하기 위해서 해당 의도와 관련된 뇌 영역이 실제로 활성화되었는지(State 1), 비활성화 되었는지(State 0)를 정확히 판별해야 한다. 즉, 뇌 영역의 활성화도에 대한 정밀한 이진 분류(Binary Classification)를 이용하면 BCI 통신 IoT 기기 제어가 가능하다.


따라서 기존 딥러닝 기반 BCI가 겪는 데이터 부족 및 설명 불가능성(Black-box) 문제를 해결하기 위한 새로운 방법을 제안한다. 구체적으로, 뇌 영역 간의 상호작용의 수학 모델을 얻고, Belief Propagation 알고리즘을 통해 이진 분류 문제의 목적 함수를 최대화함으로써 활성화된 뇌 영역을 정밀하게 분류하였다.

II. 수학적 모델링


a) 뇌 상호작용의 수학적 모델

뇌 영역 간의 복잡한 상호작용을 공간적 제약(Spatial Constraint, D), 기능적 연결성(Functional Connectivity, FC), 구조적 연결성(Structural Connectivity, SC)의 세 가지 요인으로 분류하였다 [4]. 세 가지 제약 조건이 서로 선형적인 관계가 있다고 가정하면 영역 i 와 j 사이의 전체 상관 관계(W)는 다음과 같이 표현할 수 있다.

$$W_{ij} = \alpha \cdot SC_{ij} + \beta \cdot FC_{ij} + \gamma \cdot D_{ij}$$



[그림 1] SC (왼쪽): 각 영역이 실제로 어느 영역과 연결되어 있는지를 표현. FC (오른쪽): 특정 기능을 함께 수행한다고 알려져 있는 구역들을 묶어서 구분.



[그림 2] D (왼쪽): 거리가 멀어짐에 따라 연결될 확률이 지수적으로 감소함을 표현. W (오른쪽): SC, FC, D의 영향을 선형적으로 조합한 결과를 표현.

b) 이진분류를 위한 목적함수 정의

뇌의 특정 영역이 자극에 관여했는지 활성화 여부를 표현하기 위해, 이진 변수 벡터 $X = \{x_1, x_2, x_3, \dots, x_N\}$ 를 도입하였다. 여기서 $x_i \in \{0, 1\}$ 이며, 1은 x_i 영역의 활성화, 0은 비활성화를 의미한다. 최적의 상태 벡터 X 를 찾기 위한 목적 함수 $J(X)$ 를 다음과 같이 설계하였다.

$$J(X) = \sum_{i=1}^N \phi_i(x_i) + \sum_{i=1}^N \sum_{j=i+1}^N \psi_{ij}(x_i, x_j) - \lambda \sum_{i=1}^N x_i$$

이 함수는 크게 Node Potential (ϕ), Edge Potential (ψ), 그리고 Sparsity Penalty (λ)로 구성된다.

c) 목적함수 구성 요소

Node Potential $\phi_i(x_i)$ 은 개별 영역의 관측 데이터를 반영한다. 만약 $x_i = 1$ (활성)이면, 실제 관측된 뇌 신호의 활성화 값을 반환하고 $x_i = 0$ (비활성)이면, 0을 반환한다.

Edge Potential $\psi_{ij}(x_i, x_j)$ 는 두 영역 간의 상호작용을 수치화하며, 두 영역의 관계에 따라 두 가지 역할을 수행한다.

$$\psi_{ij}(x_i, x_j) = \epsilon \{W_{ij} \cdot (x_i \wedge x_j) - \delta \cdot D_{ij} \cdot (x_i \otimes x_j)\}$$

첫 번째 항은 두 영역이 모두 활성화 ($x_i \wedge x_j = 1$) 될 경우 연결 강도 W_{ij} 만큼 목적 함수 값을 증가시키고, 두 번째 항은 두 영역의 상태가 다를 경우 ($x_i \otimes x_j = 1$), D_{ij} 에 비례하는 페널티를 부여한다. 예를 들어, 주변 영역은 모두 0인데 혼자 1인 이상치의 경우, 두 번째 항을 통해 목적함수에 높은 페널티를 준다. δ 와 ϵ 는 뇌 영역의 배치 형태를 고려하여 결정했다. 샘플링 한 뇌 영역이 격자구조 형태로 배치되어 있을 때 가장자리에 위치한 영역을 제외하면 일반적으로 한 영역에 대해 주변 영역은 8개이다. 이를 이용하여 δ 를 결정하고 전체 목적함수의 항들의 스케일을 맞추기 위해 ϵ 를 정의하였다.

마지막으로 Sparsity penalty는 모든 x_i 가 1일 때 최대가 되는 자명 해 (Trivial solution)를 방지하기 위한 것으로, 6~8 사이의 값으로 지정해 주었다.

d) 목적함수의 최적화

정의된 목적 함수는 복잡한 구조를 가져서 이를 최대화하는 전역 최적해 x 를 완전탐색으로 구하는 것은 $O(2^N)$ 의 기하급수적인 시간 복잡도를 요구하므로 현실적으로 불가능하다. 그러나 Belief Propagation 기법을 적용하면, 변수 노드와 함수 노드 사이의 간단한 메시지 전달 과정을 통해 시간 복잡도를 $O(N^2)$ 수준으로 획기적으로 낮추면서도 효율적으로 최적해 x 를 구할 수 있다. 알고리즘 수행을 위해 각 노드(Variable Node)와 함수(Factor Node) 사이에서 교환되는 메시지는 다음과 같이 정의된다.

$$\text{def } F_i(x_i) = \phi_i(x_i) - \lambda \cdot x_i$$

$$1) \mu_{F_k \rightarrow x_k}(x_k) = F_k(x_k) - \lambda \cdot x_k$$

$$2) \mu_{x_k \rightarrow \psi_{kl}}(x_k) = F_k(x_k) + \sum_{r \neq k, l} \mu_{\psi_{kr} \rightarrow x_k}(x_k)$$

$$3) \mu_{\psi_{kl} \rightarrow x_l}(x_l) = \max_{x_k} (\psi_{kl}(x_k, x_l) + \mu_{x_k \rightarrow \psi_{kl}}(x_k))$$

III. 시뮬레이션 결과 및 해석

총 네 가지 경우 (Focal, Cross-boundary, Multi-focal, Multi-focal diagonal) 에 대해 알고리즘을 적용하였고, 각 경우마다 accuracy와 Jaccard Similarity를 계산하였다.

Focal (F) 은 한 구역 (FC로 구분되는) 내에서 특정 영역들이 활성화된 경우, Cross-boundary (CB)는 활성화된 영역들이 두 구역에 걸쳐 있는 경우, Multi-focal (MF)은 가까운 두 구역에서 각각 특정 영역들이 활성화된 경우, Multi-focal diagonal (MFD)은 MF와 동일하지만 두 구역이 먼 경우이다.


[표 1]은 각 경우당 10회의 실행 결과의 평균 Accuracy와 Jaccard Similarity를 정리하였다.

[표 1] 4가지 시나리오 평균 Accuracy, Jaccard Similarity


	F	CB	MF	MFD
Accuracy	0.9556	0.9514	0.8993	0.9146
Jaccard	0.8062	0.8737	0.7355	0.7658

Accuracy는 F, CB, MFD, MF 순, Jaccard Similarity는 CB, F, MFD, MF 순으로 낮아지는 경향성을 보인다. 두 지표에는 어느 정도 차이는 있으나, 모두 MF인 경우에 가장 낮은 것을 알 수 있다.


[그림 3]은 CB, [그림 4]는 MF, [그림 5]는 MFD의 시뮬레이션 결과이다. 가장 왼쪽 그림이 자극에 실제 관여하는 영역 (Ground Truth), 가운데가 노이즈가 포함된 뇌 활성화도 input 데이터 (Noisy input), 오른쪽이 알고리즘 적용 후 추론된 자극 관여 영역 (BP Inferred Result)이다. 정답과 결과의 경우 활성화된 점은 빨간색, 비활성화된 점은 파란색으로 표시하였고, 실제 input의 경우 세기가 셀수록 진한 빨간색으로 표시하였다.



[그림 3] Spanning A & B Boundary



[그림 4] Centers of C & D



[그림 5] Centers of A & D

[그림 5]을 보면, 최종 영역이 가장자리 영역을 포함하는 경향성이 있음을 알 수 있다. 이는 인접 영역이 8개일 때를 기준으로 알고리즘을 유도했는데, 가장자리에 위치한 영역은 실제 인접 영역이 3개 또는 5개에 불과하기 때문에 나타난 결과이다. 이 문제는 replicate padding을 사용해서 해결할 수 있을 것이라 기대한다. 가장자리 열과 행을 복제한 뒤 가장자리에 덧붙이게 되면 (N by N → (N+2) by (N+2)) 인접영역이 부족한 문제를 해결할 수 있고 알고리즘의 가정을 충족할 수 있다.

또한, [그림 4]과 같이 가까운 두 영역 사이에 이상치가 존재하면 두 영역이 이어지는 결과가 나타난다. 이는 인접 영역에 대해서 edge penalty 값이 부족하기 때문이다. 이와 같은 오차는 최적해 도출을 방해하며, 주변 영역으로 전파됨에 따라 시스템의 정확도를 저하시킨다. 하지만 이 문제는 알고리즘의 목적을 고려해 보았을 때 허용 가능한 오차 범위 안에 있다.

IV. 결론

본 논문에서는 머신러닝 알고리즘 기반 BCI 통신의 속도 및 데이터 부족 문제를 효율적으로 해결하기 위한 알고리즘을 제안한다. 실제 뇌의 환경을 수학적으로 모델링 하고 목적함수를 정의한 뒤 이를 최대화 하는 벡터 x 를 찾기 위하여 Belief Propagation 기법을 사용하였다. N개의 이진 변수를 완전 탐색하기 위해서는 $O(2^N)$ 의 기하급수적인 시간 복잡도가 필요하지만 Belief Propagation을 사용하게 되면 $O(N^2)$ 으로 시간 복잡도를 획기적으로 줄일 수 있다. 또한 본 알고리즘을 위한 데이터의 양은 머신러닝에 비해 현저히 적으므로 데이터 부족 문제를 해결할 수 있을 것으로 보인다.

이 알고리즘은 근적외선을 이용해 뇌의 혈류량 변화를 측정하는 fNIRS와 함께 사용되어, 각 IoT 사용 시에 활성화되는 영역들을 효과적으로 탐색 및 감지할 수 있게 할 것이다. 추가적으로, fNIRS로 측정한 헤모글로빈 농도 변화량의 기율기 등의 정보와 함께 부분적으로 딥러닝을 사용하여 파형 변화까지 파악하거나, EEG처럼 직접적으로 전기 신호를 측정하는 기계와 함께 사용하여 시간 해상도를 향상시키는 등의 방법을 통해 Brain to IoT 통신의 기능을 더욱 개선할 수 있을 것이라 기대한다.

ACKNOWLEDGMENT

본 논문은 고려대학교 차세대통신학과 진리장학 프로그램의 지원을 받아 작성되었습니다.

참고 문헌

- [1] Global Growth Insights. (2025). *Brain Computer Interface Market Size: Industry Report 2033*. (<https://www.globalgrowthinsights.com/market-reports/brain-computer-interface-market-105929>)
- [2] Sturm, I., Bach, S., Samek, W., & Müller, K.-R. (2016). *Interpretable deep neural networks for single-trial EEG classification*. arXiv. (<https://arxiv.org/pdf/1604.08201>)
- [3] Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., & Yger, F. (2018). A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. *Journal of Neural Engineering*, 15(3), 031005.
- [4] Chen, Y., Wang, S., Hilgetag, C. C., & Zhou, C. (2017). Features of spatial and functional segregation and integration of the primate connectome revealed by trade-off between wiring cost and efficiency. *PLOS Computational Biology*, 13(9), e1005776
- [5] Kschischang, F. R., Frey, B. J., & Loeliger, H. A. (2001). Factor graphs and the sum-product algorithm. *IEEE Transactions on Information Theory*, 47(2), 498-519.