

하이퍼네트워크를 이용한 EEG 신호의 시공간적 패턴 탐색

김은솔○, 이충연, 이기석, 이현민, 김준식, 장병탁
 {eskim, cylee, kslee, hmlee, jskim, btzhang} @ bi.snu.ac.kr
 서울대학교 컴퓨터공학부 바이오지능연구실

Searching for Spatio-Temporal Pattern in EEG Signal with Hypernetwork

Eun-Sol Kim○, Chung-Yeon Lee, Ki-Seok Kevin Lee, Hyunmin Lee, JoonShik Kim, Byoung-Tak Zhang
 Biointelligence Lab, School of Computer Science and Engineering, Seoul National University

요 약

입력 데이터의 공통적인 특징을 찾아내는 방법은 기계 학습 분야의 중요한 분야이다. 일반적으로 입력 데이터의 형태적 패턴을 찾아내는 알고리즘들이 많이 연구되었는데, 최근에는 데이터의 입력 순서 또는 데이터 사이의 시간적 인과 관계와 같이 시간에 연관된 패턴을 찾는 방법이 주목을 받고 있다. 우리는 형태적 혹은 공간적 패턴 탐색에 뛰어난 성능을 보이는 하이퍼네트워크 모델을 확장하여 입력 데이터의 시공간적 패턴을 찾는 방법을 제시한다. 하이퍼네트워크는 두 개 이상의 변수를 하나의 엷자로 연결하여 문제공간을 탐색하는 모델로, 시간과 공간의 변수를 동시에 고려하여 데이터의 특성을 찾아내는 데에 적합하다. 이를 확인하기 위하여 사람의 EEG 신호를 분석하였는데, 시각적인 정보를 처리할 때와 언어적 정보를 처리할 때의 특징적인 패턴들을 찾았다.

1. 서 론

사람 수준의 기계 학습 알고리즘을 만드는 데에 있어 가장 어려운 문제는 사람은 기계가 다룰 수 있는 데이터보다 훨씬 변수가 많은 고차원의 데이터를 매우 효율적으로 처리할 수 있다는 점이다[1]. 여기서 데이터의 특성을 두 가지로 나누면, 데이터의 공간적(형태적, spatio pattern) 요소를 결정짓는 변수가 많은 것과 데이터가 입력되는 시간이 변수가 되어 데이터의 특성에 영향을 미치는 것이다[2]. 전자의 경우 이미지나 생물학적 데이터를 이용하여 변수가 많은 데이터의 공통적 패턴을 찾는 연구가 많이 이루어졌고 비교적 효율적으로 패턴을 찾을 수 있다. 인공 신경망이나 이를 계층적으로 연결한 Deep Belief Network등을 그 예로 들 수 있다. 이에 반해 데이터의 시간적 특징을 찾는 방법에 대한 연구는 비교적 늦게 시작되었는데, 주식 예측에 많이 쓰이는 AR 모델이나 로켓 또는 헬리콥터의 궤도를 예측하는데 쓰이는 Kalman filter 와 같은 알고리즘 같은 것이 해당된다.

데이터의 시간적 패턴(temporal pattern)이라는 것은 데이터의 입력 순서가 의미를 가지는 경우 또는 시간적으로 인접한 데이터가 인과적 특징을 가지거나 특정 시각에 데이터가 입력되었을 때에 특정 의미를 가지는 것을 이야기 한다. 이러한 시간적인 특징을 찾는 문제는 매우 어려운데 그 이유는 일반적으로 시간의 흐름에 따라 입력되는 데이터는 그 샘플의 수가 매우 많기 때문이다. 공간적 패턴을 찾는 문제는 변수(feature)의 수가 많더라도 그 크기가 정해져 있어 비교적 쉽지만 시간적 패턴을 찾는 문제는 시간이 지남에 따라 샘플의 수가 늘어나기 때문에 변수가 계속 늘어날 수 있다. 패턴을 찾는 문제에서 변수가 늘어나면 조합의 경우의 수에 비례하게 문제의 공간이 커지므로 시간적 패턴을 찾는 문제는 그 난이도가 공간적 패턴을 찾는 문제보다 상당히 높다. 우리는 이 연구에서 이러한 시간적 변수를 고려하여 공간적 패턴을 찾는 기계 학습 방법을 소개한다. 우리는 공간적 패턴을 찾는데 뛰어난 성능을 보이는 하이퍼네트워크 모델을 확장하여 데이터의 시공간적 패턴(spatio-temporal pattern)을 찾을 수 있는 알고리즘을 연구하였다. 이를 위해 사용자가 영화를 볼 때(시각적 정보 처리)와 영화에 관련된 문제를 풀 때(언어적 정보 처리)의 뇌 신호를 EEG를 이용하여 기록하였다. EEG 데이터는 채널(뇌 영역)과 시간에 따라 변하는 해당 영역의 활성전위로 이루어지므로 시공간적 패턴을 찾는 문제에 매우 적합하다.

2장에서는 시공간적 패턴을 찾기 위해 이 연구에서 사용한 하이퍼네트워크 모델을 설명하고 3장에서 데이터를 수집하고 처리한 방법을 설명한 후에 4장에서 제안하는

* 이 논문은 교육과학기술부의 재원으로 국가연구재단의 지원을 받아 수행된 연구(2010-0018950, 뇌정보처리 기반 사용자 의도 변화 모델링 및 예측 기술 개발), (0421-20110032, 지능형 추천 서비스를 위한 인지기반 기계학습 및 추론기술, Videome)이며, 지식경제부 산업원천기술개발사업(10035348, 모바일 플랫폼 기반 계획 및 학습 인지 모델 프레임워크 기술 개발) 및 교육과학기술부의 BK21-IT사업에 의해 일부 지원되었음.

모델을 이용하여 찾아낸 EEG의 시공간적 패턴을 보인다. 마지막으로 5장에서 결론을 맺는다.


2. 하이퍼네트워크 모델

2.1 기본 프레임워크

하이퍼네트워크[3]는 두 개 이상의 노드를 하나로 묶어 그것들의 연관관계를 가중치로 표현하는 하이퍼그래프[4]를 이용하는 기계학습 모델이다. 하이퍼네트워크에서는 노드들의 연결관계를 하이퍼에지라고 하는데 이는 기존의 그래프가 두 개의 노드만을 연결하는데 반해 하이퍼네트워크는 두 개 이상의 노드를 연결할 수 있음을 표현하기 위해서이다. 하이퍼에지는 고유의 가중치를 가지고 있고 이 값은 데이터 특징을 반영하는 정보의 양으로 생각할 수 있으며 일종의 정보 조각이다. 이 때 하이퍼네트워크의 목적은 전체 데이터의 특징을 대표할 수 있는 하이퍼에지의 조합을 찾는 것이고, 이는 변수들의 조합의 공간을 진화연산 기법을 이용하여 탐색함으로써 이루어진다[3]. 하이퍼네트워크를 이용하여 이미지나 생물학적 데이터의 패턴을 찾는 연구가 있었는데 기존의 기계학습 알고리즘과 비교했을 때 뛰어난 성능을 보임이 확인되었다[5-7].

2.2 시공간적 패턴 탐색을 위한 하이퍼네트워크

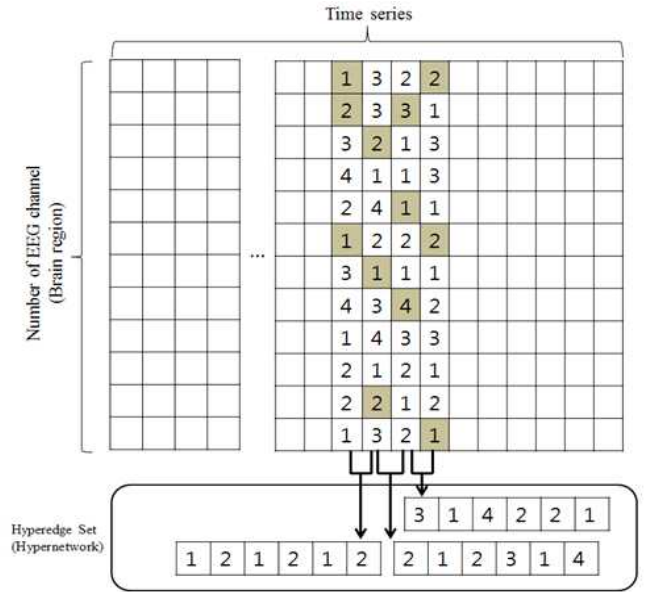
우리는 2.1의 모델을 확장하여 시공간적 패턴 탐색에 적합한 하이퍼네트워크 모델을 제시한다. 하이퍼네트워크의 학습 과정을 크게 1)하이퍼에지의 생성 2)하이퍼에지의 가중치 계산 3)하이퍼에지 교체로 나눌 수 있는데 [3], 우리는 시공간 변수를 다루기 위해 하이퍼에지를 생성하는 방법을 새로 고안하였고, 이를 그림 1과 2에 표현했다.



[그림 2] 기존 하이퍼네트워크에서 하이퍼에지 생성 방법

기존의 하이퍼네트워크는 공간적 변수만 가지는 데이터를 다루었기 때문에 1차원 배열로 데이터를 표현할 수 있다. 이와 비교하여 시공간적 변수를 가지는 데이터는 2차원 배열로 표현된다. 이는 하나의 하이퍼에지를 만들기 위해(sampling) 노드를 선택할 때, 그 범위가 확장됨을 의미한다.

우리는 2차원 배열에서 하이퍼에지를 만들 때, 모든



[그림 3] 시공간 데이터에서 하이퍼에지 생성 방법. 범위에서 무작위로 노드를 고르게 되면 시간에 대한 인과관계를 고려하지 못하는 점을 보완하기 위하여 다음과 같은 방법으로 하이퍼에지를 생성하였다.


2.2.1 하이퍼에지 생성

연속된 두 시각의 공간적 데이터에 대해서 임의로 노드를 뽑아 하나의 하이퍼에지를 만들었다[그림 2]. 즉 하나의 하이퍼에지를 만들 때에 모든 시각에 대해서 임의로 노드를 고르는 것이 아니라 바로 앞과 뒤 시각의 데이터에서만 노드를 골랐다. 이 때 공간적 변수에는 제한이 없다. 이 과정을 모든 시간에 대해서 반복하고 나면 시각 변수의 크기가 2인 하이퍼에지의 집합이 만들어진다. 이제 그림 3과 같은 하이퍼에지의 통합과정을 거쳐 2보다 더 큰 시간 변수의 하이퍼에지 집합을 찾는다. 시간 변수의 크기가 t인 하이퍼에지에 대해서 연속된 (t-1)만큼의 노드의 값이 같은 하이퍼에지를 찾아 (t+1) 크기의 새로운 하이퍼에지를 만드는 방법이다. 이 과정을 통해 시간 사이의 인과 관계가 있는 하이퍼에지들을 조합하여 전체적인 시공간적 패턴을 찾을 수 있다. 그림 3과 같은 방법을 반복 수행하다가 더 이상 통합할 수 있는 하이퍼에지가 없는 경우 멈추게 된다.

2.2.2 하이퍼네트워크 학습

모든 시간에 대해서 모든 가능한 하이퍼에지의 조합을 찾아 비교를 통해 통합하는 과정은 매우 오랜 시간을 요구한다. 이를 해결하기 위하여 진화연산을 이용한 학습 방법을 이용하였다. 하이퍼네트워크 모델은 하이퍼에지의 가중치 계산과 가중치에 따른 하이퍼에지의 교체를 반복함으로써 하이퍼에지의 집합을 진화시킨다.

하이퍼에지의 집합이 만들어지면 각각의 가중치를 계산하는데 이것은 원래의 데이터셋과 비교하는 과정을 통해 계산된다. 하나의 하이퍼에지에 대하여 데이터셋에



[그림 4] 하이퍼에지의 통합 과정

있는 모든 데이터와 비교를 하는데, 하이퍼에지의 노드의 값(시간적, 공간적)이 데이터의 노드의 값과 같으면 하이퍼에지의 가중치를 1씩 올리는 방법을 취했다. 예를 들어, 데이터 $x = \{x_1=0, x_2=1, x_3=1, x_4=0, x_5=1\}$ 와 하이퍼에지 $e_1 = \{x_1=0, x_2=1, x_3=1\}$, $e_2 = \{x_2=1, x_3=1, x_5=0\}$ 를 비교하면 e_1 은 데이터 x 와 같은 변수에 대해 같은 값을 가지므로 가중치가 1만큼 올라가고, e_2 는 같은 변수에 대해 다른 값을 가지므로 가중치를 올리지 않는다.

우리는 시간 변수의 크기가 큰 하이퍼에지에 더 큰 가중치를 주었다. 그 이유는 시간 변수의 크기가 작은 하이퍼에지는 시간 변수의 크기가 큰 하이퍼에지보다 데이터와 비교해서 값이 같은 경우가 상대적으로 많기 때문이다. 또한 우리는 작은 조각들을 조립하여 큰 조각들을 만들어 가기 때문에 큰 조각들에게 더 큰 가중치를 주었다. 이를 위하여, 그림 3과 같이 하이퍼에지를 통합하는 과정에서 통합된 에지의 가중치는 통합되기 전 두 개의 에지의 가중치의 합으로 정의하였다.

모든 하이퍼에지의 가중치가 계산이 되면 가중치가 낮은 하이퍼에지들을 버리고 새로운 하이퍼에지를 생성한다. 하이퍼에지를 교체하는 비율은 학습을 반복하는 횟수에 따라 달라지는데, 학습 초기에는 많이 버리고 학습 후반부에는 조금만 교체하는 방식을 취했다. 이를 수식으로 표현하면 다음과 같다.

$$R(i) = \frac{M-m}{\exp(\frac{i-1}{C})} + m \quad (1)$$

M 은 최고 교체 비율, m 은 최소 교체 비율, C 는 수렴 속도를 의미한다. i 는 학습을 반복한 횟수로 이 값이 높을수록 교체하는 하이퍼에지의 양이 줄어든다.

위의 과정을 미리 정해진 횟수만큼 학습을 반복하고 나면 가중치가 있는 하이퍼에지들이 남게 되는데 이를 분석하여 데이터의 시공간적 패턴을 찾을 수 있다.

3. 실험 데이터

우리는 시공간 데이터로 EEG 신호를 이용하였다. EEG 신호는 뇌 영역에서 발생하는 전위를 시간에 따라 기록한 데이터이므로 시간과 공간의 변수를 가진다. 또한 EEG는 다른 뇌 신호 측정 장비에 비해 짧은 주기로 뇌의 전위를 측정하기 때문에 시간 변수가 매우 많다. 그래서 EEG는 매우 빠른 속도로 일어나는 사람의 인지 과정을 관찰하는 데에 적합하지만 변수가 너무 많아서 해석이 어려운 단점이 있다. 우리는 다른 두 가지 정보를 처리할 때의 EEG 신호를 기록하여 뇌의 활동에 따른 활성 전위의 특징적인 패턴을 확인하였다.

우리는 피험자가 시각적인 정보를 많이 처리하거나 언어적인 정보를 많이 처리하도록 실험을 설계하여 EEG 신호를 기록하였다. 시각적인 정보를 많이 처리하는 실험에서는 피험자에게 드라마를 보여주었고 드라마에 관련된 내용을 묻는 실험을 통해 언어적인 정보를 많이 처리하도록 유도했다. 14개의 뇌 영역에서 발생하는 활성 전위를 Emotiv EEG 장비를 통해 측정하였고, 시각적 정보 처리과정을 보는 실험은 약 20분동안, 언어적 정보를 처리하는 실험은 약 5분동안 진행되었다. Emotiv EEG 장비는 128Hz로 전위를 측정하므로 시각처리 실험은 14개의 공간 변수와 약 15만 개의 시간 변수를 가지고, 언어처리 실험은 14개의 공간 변수와 약 3만개의 시간 변수를 가진다.


EEG 장비는 두개골 바깥 쪽에서 뇌 영역의 활성 전위를 측정하기 때문에 외부 요인에 의한 방해 신호가 많이 포함된다. 이 때문에 대부분의 연구에서 EEG 신호의 전처리 과정을 거치는데 일반적으로, EEG 신호를 직접 사용하지 않고 사람이 판단하여 직관적으로 외부 요인이라고 생각되는 부분을 제거한다. 또 feature selection 알고리즘을 사용하여, 전체 EEG 신호 중에서 일부분만 사용한다. 그러나 우리는 이러한 전처리 과정을 사용하지 않았다. 방해 신호를 제거하지 않고 실험 시간 동안 얻은 전체 시간에 대한 데이터를 그대로 사용하였다.

EEG 신호를 측정하면 뇌의 영역마다 활성 전위의 범위에 차이가 있다. 우리는 모든 영역에 대해 같은 확률로 하이퍼에지를 만들기 때문에 영역마다 나타나는 차이를 보정할 필요가 있다. 우리의 목적은 시간과 영역에 따라 변화하는 활성 전위의 패턴을 보는 것이므로, 측정된 EEG 신호의 전위를 사용하지 않고 EEG 신호의 변화량을 사용하였다. 즉 영역별로 측정된 EEG 신호의 값을 시간에 따라 미분하여 그 미분값을 사용하였다.

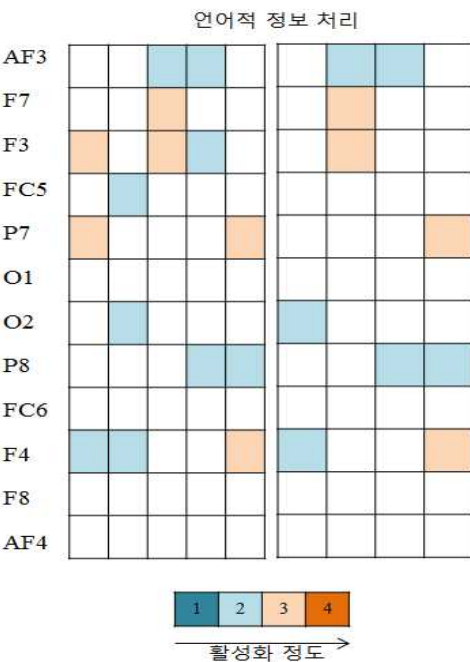
하이퍼네트워크는 이산화 데이터를 이용하므로 미분한 EEG 신호 값을 영역별로 정규화하여 4구간으로 나누었는데, 정규화한 값이 $(-\infty, -1]$ 이면 1, $(-1, 0]$ 이면 2, $(0, 1]$ 이면 3, $(1, \infty)$ 이면 4로 바꾸어 실험에 사용하였다.

4. 실험 결과

그림 4와 5에 하이퍼네트워크를 이용하여 EEG 신호의 시공간적 패턴을 찾은 결과를 나타냈다.



[그림 4] 시각 정보 처리시 뇌 활성화 패턴



[그림 6] 언어 정보 처리시 뇌 활성화 패턴

그림 4와 5를 보면 뚜렷하지는 않지만 두 가지 다른 종류의 정보를 처리 할 때 뇌에서 발생하는 활성화 전위 패턴에 차이가 있음을 확인할 수 있다. 그림 5를 보면 언어 및 기억에 관여하는 전전두엽이 활성화 패턴에 나타나는 것을 확인할 수 있고, 그림 4에서는 시각 정보 처리에 관여하는 O1, O2, P1, P1가 언어 처리에 비해 활성화 되는 것을 확인할 수 있다.

5. 결 론

우리는 하이퍼네트워크를 확장하여 데이터의 시공간적 패턴을 찾는 방법을 제안하였고, EEG 데이터에 적용해 보았다. EEG 데이터는 방해 신호가 많고 시간 변수가 많아 연구에 이용하기 어려운 단점이 있었는데, 하이퍼네트워크를 이용하여 효율적으로 분석할 수 있음을 확인하였다. 우리는 이 연구를 확장하여 EEG 신호를 이용해 뇌의 활동을 분류하려는 계획을 가지고 있다. 또한 이 연구에서 제안한 하이퍼네트워크를 이용하여 EEG 신호뿐만 아니라 비디오 스트림과 같이 시간에 따라 변화하는 데이터를 유용하게 분석할 수 있을 것이라 기대한다.

6. 참고문헌

- [1] R. Bellman, *Dynamic Programming*, Princeton, NJ:Princeton Univ. Press, 1957.
- [2] I. Arel, D. C. Rose, and T. P. Karnowski. "Deep machine learning—a new frontier in artificial intelligence research". *IEEE Computational Intelligence Magazine*, November 2010.
- [3] B.-T. Zhang, "Hypernetworks: A molecular evolutionary architecture for cognitive learning and memory", *IEEE Computational Intelligence Magazine*, 3(3):49-63, 2008.
- [4] D. Zhou, J. Huang, B. Schoelkopf, "Learning with hypergraphs: Clustering, classification, and embedding", *In Advances in Neural Information Processing Systems (NIPS)* 19, Vol. 19 (2006)
- [5] J.-W. Ha, J.-H. Eom, S.-C. Kim, and B.-T. Zhang, "Evolutionary hypernetwork models for aptamer-based cardiovascular disease diagnosis", *The Genetic and Evolutionary Computation Conference (GECCO 2007)*, pp.2709-2716, 2007.
- [6] S.-J. Kim, J.-W. Ha, B. Lee, and B.-T. Zhang, "Evolutionary layered hypernetworks for identifying microRNA-mRNA regulatory modules", *IEEE World Congress Computational Intelligence (WCCI-CEC 2010)*, pp. 2299-2306, 2010.
- [7] J.-W. Ha, B.-H. Kim, B. Lee, and B.-T. Zhang, "Layered hypernetwork models for cross-modal associative text and image keyword generation in multimodal information retrieval", *Proceedings of the Eleventh Pacific Rim International Conference on AI (PRICAI2010)*, Lecture Notes in Artificial Intelligence, 6230:76-87, 2010.