

상호 정보량을 이용한 동작 상상 뇌 신호 구분 방법론

황보선¹, 박철수², 장병탁¹

서울대학교 컴퓨터공학부¹, 광운대학교 컴퓨터 공학과²

{bshwang, [btzhang](mailto:btzhang@bi.snu.ac.kr)}@bi.snu.ac.kr¹, parkcheolsoo@kw.ac.kr²

Methodology for Motor Imagery Brain Response

Classification using Mutual Information

Bosun Hwang¹, Cheolsoo Park², Byoung-Tak Zhang¹

School of Computer Science and Engineering, Seoul National University¹

Computer Engineering Department, KwangWoon University²

요 약

인간의 동작 계획 단계에서의 동작 상상 뇌 반응 (motor imagery brain response) 연구는 뇌-컴퓨터 인터페이스 (Brain-computer interface: BCI) 분야의 가장 대표적인 분야이다. 이러한 동작 상상 뇌 반응 연구를 위해 사용되는 대표적인 생체 전기 신호인 뇌전도(Electroencephalogram :EEG) 신호는 비침습적이고 측정이 용이한 특성을 가지고 있으며, 또한 다양한 주파수 분석 기법 및 표준 알고리즘들이 주요 특징 벡터(Feature) 추출을 위해 다양하게 정립되어 왔다. 본 연구에서는 이러한 뇌전도 신호를 이용하여 오른손과 왼손의 동작 준비를 위해 발생하는 뇌전도 신호를 처리하여, 상상만으로 동작을 예측 구분하는 분류 방법론을 다룬다. 제안된 방법론은 시계열(Time series) 특징 벡터 추출 방법을 이용해 추출한 특징 벡터 집합에 대해 민감도 분석을 이용한 주요 특징 벡터 선정 과정부터 신호 전처리 및 머신러닝 기법을 이용한 분류기 적용까지의 수행 과정을 정립하였다. 본 논문의 실험 결과는 “Physiobank motor/mental imagery database”의 40명(11채널, 45번 실험측정)의 대상자에 대해 수행하였으며, 제안된 방법론을 이용한 수행 결과는 모든 입력 특징 벡터를 사용한 기존 방법에 비해 평균 9% 정도의 성능 향상을 보인다.

1. 서론.

뇌전도를 기반으로 하는 뇌-컴퓨터 인터페이스(BCI) 분야의 동작 상상 뇌 반응 연구는 최근 많은 주목을 받고 있다. 실제적인 동작 없이 동작을 상상하는 것만으로도 뇌전도 신호는 상상에 따른 특징적인 신호 변화를 보이게 된다 [1]. 이런 특징들은 뇌전도 신호를 이용한 전자 제어 및 재활 공학 측면에서도 많은 관심을 받고 있다.

뇌전도 신호는 비선형, 비정상성 및 멀티채널 신호라는 특징을 보이고 있기 때문에, 뇌전도 신호를 이용한 응용에서는 그것의 특징을 잘 고려하여 분석하여야 한다.

본 논문에서는 뇌전도 신호를 이용하여 동작 상상 뇌 반응을 구분하는 연구 내용에 대하여 논하고자 한다. 피실험자는 오른손과 왼손의 움직임을 상상만 하는 경우이며, 이 때 오른손/왼손을 구분하여 클래스 정보 역시 같이 기록되어 감독 학습 분류 문제로 다루어지게 된다.

뇌 전도 신호는 64개 채널로 기록이 되며, 이 중 주요 11개 채널 (Motor Cortex 영역)의 신호를 이용하여 실험을 진행하였다. 연속 시간 신호인 뇌전도 신호의 특징적인 입력을 구성하기 위해 9 종류의 연속 시간 특징 벡터 추출 기법을 이용하여 활용하는 방법을

다룬다 [2]. 최종 분류 알고리즘 적용은 단일 분류기가 아닌 앙상블 분류기를 사용하였으며, 논의된 모든 비교 실험 결과를 통해 상대 정보량 민감도 분석 기법이 동작 상상 뇌 반응 분류 문제에 대해 유용함을 보였다.

2. 신호 처리 기법 (Signal processing)

뇌전도 신호로부터 중요한 주파수 성분 (약 8~25 Hz) 을 추출하기 위하여 multivariate empirical mode decomposition (MEMD) 알고리즘을 사용하였다 [3]. MEMD 알고리즘은 동작 상상 뇌 반응으로부터 중요한 주파수 성분을 기존 디지털 필터 (FIR 또는 IIR) 나 wavelet 변환보다 더 효율적으로 추출해 낸다고 알려져 있다 [3]. 기존 디지털 필터나 wavelet 변환 알고리즘들은 코사인 함수나 mother wavelet 함수와 같은 basis 함수에 의존하여 비선형적인 뇌전도 신호를 선형적으로 분석을 하지만, MEMD 알고리즘은 입력 신호 자체에서 적응적으로 basis 함수를 추출하여 비선형적인 뇌 전도 신호를 보다 효율적으로 분석할 수 있다. 또한 기존 분석 알고리즘들은 단채널 분석 방법인데 반해 MEMD 알고리즘은 다채널 데이터를 동시에 분석하여 여러 채널에 동시에 나타나는 성분들을 보다 정확히 추출해 낼 수 있다.

3. 민감도 분석 (Sensitivity analysis)

뇌전도 신호의 측정은 비침습적인 방식으로 64 채널의 연속 시간 신호를 저장하는 방식을 취한다. 그러나, 64 채널의 신호를 모두 사용하는 것은 데이터 분석 과정에서 주요 정보 특성을 감쇄 시킬 수 있으므로, 동작 상상 반응에 적합하다고 알려져 있는 뇌반구 중심 영역의 11개 채널을 선별하여 사용하였다. 동작 상상 뇌 반응의 경우, 오른손과 왼손의 동작을 클래스 레이블로 고려할 때, 클래스 결과에 따라 좀 더 민감하게 반응하는 주요 특징 입력 특징 벡터를 선별할 필요가 있게 된다. 이러한, 민감도 분석 지표에는 선형적인 관계를 보여주는 상관계수(Correlation coefficient)가 있을 수 있으나, 이 계수는 입출력간의 선형적인 관계만을 나타내 주어 비선형적 관계가 있는 정보를 놓치는 경우가 발생할 수 있다. 이러한 단점을 극복하기 위해 정보 처리 이론 분야의 상호 정보량(Mutual information)을 사용할 수 있다. 상호 정보량은 두 데이터가 동시에 변동되는 사건(Joint probability)이라는 관점에서 접근하여, 상호 비선형적 관계까지 나타내어 줄 수 있다는 특징이 있다. 본 논문에서는 추출된 11채널, 9종의 총 99개 특징 입력과 클래스 레이블(Left/Right)과의 관계를 실험 대상마다 계산하여 분류 성능을 높이는 방법을 제안하였다.

$$I(X;Y) = \sum_{y \in Y} \sum_{x \in X} p(x,y) \log \left(\frac{p(x,y)}{p(x)p(y)} \right)$$

식 1) 상호 정보량 (Mutual information)

4. 특징 벡터 추출 (Feature extraction)

분류기 입력으로 사용될 특징 벡터 추출 방법에는 시계열 신호의 대표 값을 계산하여 주는 총 9종의 시계열 특징 벡터 추출 기법이 사용되었다. 각각의 추출 기법은 다음의 표 1)과 같다 [2].

Time series feature extraction methods	SignalPower
	Area
	AveragePeakAmplitude
	AverageValleyAmplitude
	LineLength
	NormalizedDecay
	NormalizedPeakNumber
	PeakVariation
	RootMeanSquare

표 1) 주요 특징 벡터 추출 방법

5. 기계 학습 분류 알고리즘

상호 정보량에 의해 선별된 입력을 이용하여, 최종 분류를 위해 앙상블 분류기가 사용되었으며, 여러 실험적인 결과를 바탕으로 앙상블 분류기 중, 랜덤 포레스트(Random forest) 분류기가 사용되었다.

랜덤 포레스트는 다수의 의사결정나무(Decision tree)로 구성되며, 각각의 의사결정나무의 입력 데이터는 랜덤하게 선정된다. 최종 결과는 개별 의사결정나무들의 결과를 바탕으로 투표에 의해 결정하게 된다. 랜덤 포레스트 분류기는 다수의 입력에 대해 유용한 결과를 보이며, 비교적 정확한 예측 성능을 보이는 알고리즘으로 알려져 있다.




그림 1) 랜덤 포레스트(Random forest) 개념도 [6]

6. 실험 결과

6.1 민감도 분석 결과

연구를 위해 사용된 데이터는 “Pysiobank motor/mental imagery database”의 40명(11채널, 45번 측정) 데이터이다. 동작 상상 반응 뇌 반응 분류기는 뇌전도 신호의 비정상성(non-stationary) 및 무결성적이지 않은(noisy) 특성으로, 모든 대상자들에 대한 통합된 분류기를 사용하지 않고, 실험 대상 별 독립적인 분류기 구성을 위한 학습을 수행한다. 즉, 대상마다 각 대상에 더 적합한 주요 특징 벡터 집합을 구성함으로써 분류 성능을 높이고자 하는 것이 본 연구의 핵심 목표이다. 프로그램 구성상 데이터 처리 과정에서 모든 대상들을 신호 처리하여, 40명 모두 각각 99개의 최초 특징 벡터를 구성한다. 모든 특징 벡터 중 6개 정도가 실험적으로 클래스 레이블과 높은 연관성을 보이며, 이에 따라 매 대상마다 상호 정보량에 기반한 6개의 적합 특징 벡터를 선정하게 되며, 이 결과가 분류기의 최종 입력으로 들어가게 된다. 주요 적합 특징 벡터는 실험 대상마다 상호 정보량의 순위에 따라 표 1)에서 보인 특징 벡터들이 모든 대상마다 다른 조합으로 나타나게 된다.

민감도 순위에 따른 비교 실험을 하기 위해, 랜덤 포레스트 분류기를 이용한 특징 벡터 비교 실험을 5-fold 교차 검증 방법을 통해 진행하였다.




그림 2) 특징 벡터에 따른 실험 대상 별 정확도 결과
(총 40명 실험 대상 중 1~10번 피실험자 결과)

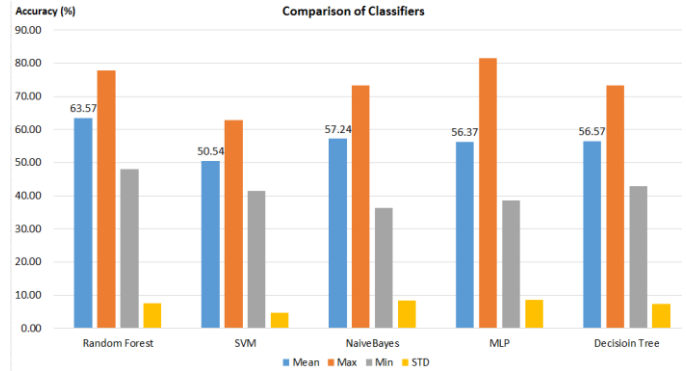


그림 4) 분류 알고리즘 성능 비교 결과




그림 3) 특징 벡터에 따른 평균 정확도 비교 결과

그림 2)와 3)에서 볼 수 있듯이 상호 정보량이 가장 큰 순서로 6종류의 특징 벡터를 사용한 결과가 99개의 모든 특징 벡터를 사용한 결과 보다 40명 실험 결과 기준 평균 9% 정도 높은 정확도를 나타내는 것을 확인할 수 있다. 실제 민감도의 유의성 검증을 위한 비교 대상으로 가장 낮은 상호 정보량을 나타내는 6종류의 특징 벡터를 사용했을 때, 그 성능이 확연히 낮아지는 결과 역시 확인할 수 있었다. 이러한 결과는 뇌 상상 동작 반응의 분류 성능을 높인데, 제안된 민감도 분석 방법이 주요하게 작용하고 있음을 보여주는 결과이다.

6.2 분류기 성능 비교 결과

실험 결과 6.1을 바탕으로 6종의 주요 특징 벡터를 이용하여 다른 분류기 성능을 평가하였다. 아래 그림 4)와 같이 대표적인 분류 알고리즘들인 SVM, NaiveBayes, MLP, DecisionTree와 비교 실험을 진행하였다. 결과에서 확인할 수 있듯이 랜덤 포레스트 분류기가 평균적으로 가장 좋은 성능을 보이고 있음을 또한 확인할 수 있었다.

7. 결론 및 향후 연구 방향

본 논문에서는 동작 상상 뇌 반응 분류 문제에 대해, 시계열 신호의 다양한 특징 벡터를 추출하여, 이를 상호 정보량을 이용한 민감도 분석을 통하여 분류 성능 향상을 이룰 수 있는 방법론을 제안하였다.

제안된 방법론을 통해 민감도 분석에서 상호 정보량이 대상 별 분류기의 학습을 위한 주요 특징 벡터 선택에 주요한 지표로 사용될 수 있음을 확인할 수 있었으며, 최종적으로 앙상블 분류기인 랜덤 포레스트 알고리즘이 분류 성능을 높일 수 있는 적합한 알고리즘임을 역시 실험적으로 확인할 수 있었다.

향 후 연구 과제로는 시계열 특징 벡터 외에 소스 지역화(Source localization) 개념이 가미된 특징 벡터 추출 기법이 추가로 연구될 예정이며, 새롭게 추출된 특징 벡터에 적합한 분류기의 적용 및 개발에 대한 연구 역시 진행될 예정이다.

8. 참고 문헌

- [1] G. Pfurtscheller, C. Neuper, D. Flotzinger, and M. Pregenzer, "EEG based discrimination between imagination of right and left hand movement," *Electroencephalogr. Clin. Neurophysiol.*, vol. 103, no. 6, pp. 642-651, 1997
- [2] J.T. Turner, A. Page, T. Mohsenin, and T. Oates, "Deep Belief Networks used on High Resolution Multichannel Electroencephalography Data for Seizure Detection," 2014 AAAI Spring Symposium Series, 2014
- [3] C. Park, D. Looney, N. Rehman, A. Ahrabian, and D. P. Mandic, "Classification of Motor Imagery BCI Using Multivariate Empirical Mode Decomposition", *IEEE Transactions on neural systems and rehabilitation engineering*, January 2013
- [4] Chung-Yeon Lee, Byoung-Tak Zhang, "Effective EEG Connectivity Analysis of Episodic Memory Retrieval", In *Proceedings of Annual Meeting of the Cognitive Science Society (CogSci 2014)*, pp. 833-838, 2014
- [5] S. Oh, M.S. Lee, and B.-T. Zhang, "Ensemble learning with active example selection for imbalanced biomedical data classification", *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 8(2):316-325, 2011
- [6] http://blogs.sas.com/content/analytics/files/2012/04/blog_4_11.jpg