

Вступление

О методах измерения активности головного мозга

Существует множество различных способов записи сигналов активности мозга. Они различаются временным и пространственным разрешением, а также степенью инвазивности. Электроэнцефалограмма (EEG) - самый распространенный вид данных, так как они являются неинвазивным и не требуют дорогостоящего оборудования. К сожалению, она обладает низким пространственным разрешением. Магнитоэнцефалограмма (MEG) и функциональная магнитно-резонансная томография (fMRI), которые также являются неинвазивными, записываются с помощью сложного и дорогостоящего оборудования, что делает их неприменимыми для большинства практических задач, таких как создание нейро-компьютерного интерфейса (BCI). С другой стороны, такие методы, как запись SUA (single unit activity) приводят к необратимым изменениям в работе мозга и из-за этого требуют постоянного обновления модели для поддержания ее точности [1]. Изменения, происходящие после внедрения электродов в глубину головного мозга, являются плохо исследованным и представляют опасность для пациента.

Для достижения высокого пространственного разрешения в нейро-компьютерных интерфейсах, предназначенных для распознавания движений человека используются электрокортикограммы (ECoG). Такие данные, полученные при помощи измерения потенциалов электромагнитного поля непосредственно с коры головного мозга, обладают большим пространственным разрешением, чем EEG и являются более безопасными, так как являются полуинвазивными и не требуют внедрения электродов в кору головного мозга. Более того, спектр частот, которые можно записать с помощью ECoG, намного шире, чем у EEG. Так, с помощью EEG обычно записываются частоты менее 40 Hz, а с помощью ECoG возможно записать частоты до 200 Hz. Это важно, так как компоненты сигнала на частотах от 70 до 200 Hz содержат информацию о выполнении конкретных действий [2].

Как видно из Рис. (1), ECoG уступает в пространственном разрешении только SUA, при этом является намного безопаснее и позволяет получать долгосрочную модель для нейро-компьютерного интерфейса [1].

О задачах

Задача создания нейро-компьютерного интерфейса, использующего информацию об активности мозга для управления различными устройствами, исследуется больше сорока лет [3]. Основными направлениями в этой области являются создание недорогого и легкого в использовании устройства для общего потребителя [4] и разработка устройств для людей с ограниченными возможностями.

Для того чтобы устройство было относительно недорогим и удобным используются всего несколько каналов EEG. Использование таких данных позволяет распознавать только небольшое количество состояний, при этом требуются воспроизводить одно и то же состояние, например, концентрацию или расслабленность [5–7]. Примером устройства общего пользования является нейро-гарнитура для управления дроном [4].

Другим направлением в задаче создания нейро-компьютерных интерфейсов является помощь пациентам с травмами мозга или парализованными конечностями. Здесь можно выделить два основных направления, во-первых, создание экзоскелетов и протезов [8], во-вторых, использование нейро-компьютерного интерфейса для восстановления утраченных двигательных функций. [9–11].

Механизм работы протезов заключается в том, что пациент представляет себе движение, нейро-компьютерный интерфейс распознает представленное движение, а экзоски-




Рис. 1. Схематический обзор масштабов пространственного и временного разрешения методов измерений, используемых для BCI.

лет выполняет распознанное движение. Распознавание воображаемых движений является трудной задачей, так как активность коры головного мозга при представлении того или иного движения, хоть и схожа с активностью при реальном движении [12] является плохо изученной.

Промежуточной задачей является декодирование движений человека, не при его представлении этого движения, а при реальном движении. Этот метод сам по себе не используется при управлении экзоскелетом. Тем не менее он дает возможность измерять точность используемого алгоритма декодирования, а также представляет собой модельный эксперимент, так как при движении конечностью в коре активируются одни и те же зоны. Для решения задачи декодирования положения конечности в пространстве необходимо высокое пространственное разрешение, поэтому, при декодировании используются сигналы электрокортикограмм (ECoG). Данная задача недавно изучалась при проведении экспериментов с обезьянами [1, 13, 14]. Помимо этого, было проведено несколько экспериментов при участии людей [15, 16]. Полученные результаты показывают, что декодирование движений человека по данным ECoG значительно выше случайного, но достигаемая точность не достаточна, чтобы использовать эти алгоритмы для управления искусственной рукой [16]. Для повышения точности декодирования можно, например, использовать ECoG с большим количеством электродов [17].

Другой промежуточной задачей является декодирование движений в 1D и 2D пространстве [18]. Эта промежуточная задача имеет практическое применение, так как позволяет людям с ограниченными возможностями управлять курсором компьютерной мышки [19, 20].

Для декодирования движений можно сначала декодировать промежуточные показатели, такие как локальный потенциал (LFP) [21] или показатели мышечной активности [22]. Например, можно декодировать электромиограмму (EMG), а далее воспользоваться алгоритмами декодирования движений по EMG [23].

При создании протеза руки человека ставится более сложная задача. Так, кроме определения положения руки в пространстве, необходимо распознавать движения пальцев. Эту задачу решали в работах [24–27]. С помощью использования априорных знаний о движении пальцами и графических моделей получилось добиться точности в 65 % для классификации на 6 классов (5 пальцев и нейтральное состояние) [27].

За последние 10 лет было проведено много исследований, направленных на создание точного и устойчивого алгоритма декодирования ECoG данных. В данном обзоре рассматриваются основные подходы, используемые в задачах декодирования, их эффективность и ограничения.

О методах обработки ECoG

Первым этапом декодирования сигнала ECoG, как и EEG сигнала, является выделение признаков. Существует много методов выделения признаков из пространственно-временных данных. В данном обзоре будут рассмотрены основные методы выделения признаков и их эффективность при применении к ECoG данным.

1. Фильтрация.

Перед тем как извлекать признаки, необходимо выбрать частотный диапазон, внутри которого будут частоты генерируемые сигналом, а вне которого шумом. Частоты подбираются исходя из результатов предметной области.

2. Вейвлет преобразование

Вейвлет преобразование [28] - это обобщение разложения в ряд Фурье, оно является разложением исходного сигнала в ряд из вейвлетов.

Набор вейвлетов получается путем растяжения, сжатия и перемещения из материнского вейвлета. Однако, часто остается неясно, как выбирать материнский вейвлет [29]. Необходимо отметить широкое использование комплексного вейвлета Морле во многих работах связанных с декодированием движений по ECoG данным [1, 8, 14, 30]

Так как вейвлет преобразование позволяет варьировать ширину окна, оно дает более гибкий способ пространственно-временного представления сигнала. Для того чтобы получить лучшее представление низких частот, используются большая ширина окна, для выделения информации о больших частотах, необходимо использовать меньшую ширину окна.

После применения вейвлет преобразование на разных частотах (варьируя параметр масштаба) получается скаллограмма. (См. Рис. 2)

3. Нормализация. Процедура предобработки входных данных, при которой значения признаков, образующих входной вектор, приводятся к некоторому заданному диапазону. Как видно из Рис. (2), нормализация полученной скаллограммы делается так, чтобы для каждой частоты стандартное отклонение было равно 1, что позволяет в равной мере использовать информацию содержащуюся на разных частотах.

Вторым этапом обработки ECoG данных является использование полученных признаков для декодирования движений.




Рис. 2. Схема преобразования ECoG сигнала с помощью вейвлет преобразования для получения признаков. Взято из [1].

Эта задача является задачей регрессии. Необходимо восстановить координаты положения руки по полученным признакам. При использовании обычной модели регрессии возникают проблемы с тем, что признаки полученные с помощью вейвлет преобразования от соседних электродов сильно коррелируют друг с другом, и при обучении данной модели возникает переобучение [31].

Для решения этой проблемы используется метод частичных наименьших квадратов (PLS). Он и его модификации используются в большинстве работ по декодированию движений. [1, 13–16]. Этот алгоритм проецирует пространство признаков на пространство меньшей размерности, выделяя те комбинации признаков, которые больше всего коррелируют с вектором ответов. Это позволяет выделить основную структуру в пространстве признаков и избежать переобучения.

Кроме канонического алгоритма PLS [32, 33], для декодирования движений также используются его модификации: метод частичных наименьших квадратов высшего порядка (HOPLS) [30] и его нелнейный вариант [34], смесь моделей PLS (mix-PLS) [35], рекурсивный PLS [36, 37], разряженный ортонормированный PLS (SOPLS) [14]. В обзоре [38] представлена вводная информация для того чтобы лучше понять тензорное обобщение PLS, а также примеры применения этого алгоритма для ECoG данных.

Литература

- [1] Zenas C Chao, Yasuo Nagasaka, and Naotaka Fujii. Long-term asynchronous decoding of arm motion using electrocorticographic signals in monkey. *Frontiers in Neuroengineering*, 3(3), 2010.
- [2] Kai J Miller, Christopher J Honey, Dora Hermes, Rajesh PN Rao, Marcel denNijs, and Jeffrey G Ojemann. Broadband changes in the cortical surface potential track activation of functionally diverse neuronal populations. *NeuroImage*, 85, Part 2:711 – 720, 2014. New Horizons for Neural Oscillations.
- [3] J. J. Vidal. Real-time detection of brain events in eeg. *Proceedings of the IEEE*, 65(5):633–641, May 1977.
- [4] Bin He, Bryan Baxter, Bradley J Edelman, Christopher C Cline, and Wenjing W Ye. Noninvasive brain-computer interfaces based on sensorimotor rhythms. *Proceedings of the IEEE*, 103(6):907–925, 2015.
- [5] Jonathan R Wolpaw, Niels Birbaumer, Dennis J McFarland, Gert Pfurtscheller, and Theresa M Vaughan. Brain-computer interfaces for communication and control. *Clinical neurophysiology*, 113(6):767–791, 2002.
- [6] Gernot R Muller-Putz, Vera Kaiser, Teodoro Solis-Escalante, and Gert Pfurtscheller. Fast set-up asynchronous brain-switch based on detection of foot motor imagery in 1-channel eeg. *Medical & biological engineering & computing*, 48(3):229–233, 2010.

- [7] Robert Leeb, Volker Settgast, Dieter Fellner, and Gert Pfurtscheller. Self-paced exploration of the austrian national library through thought. *International Journal of Bioelectromagnetism*, 9(4):237–244, 2007.
- [8] Andrey Eliseyev and Tetiana Aksenova. Recursive n-way pls for the adaptive multisession calibration of ecog based bci system. *Frontiers in Computational Neuroscience*, (18).
- [9] Alireza Gharabaghi. Learned self-regulation of the lesioned brain with epidural electrocorticography. *Frontiers in Behavioral Neuroscience*, 8(429), 2014.
- [10] Stefano Silvoni, Ander Ramos-Murguialday, Marianna Cavinato, Chiara Volpato, Giulia Cisotto, Andrea Turolla, Francesco Piccione, and Niels Birbaumer. Brain-computer interface in stroke: A review of progress. *Clinical EEG and Neuroscience*, 42(4):245–252, 2011.
- [11] M SpGjler, A Walter, A Ramos-Murguialday, G Naros, N Birbaumer, A Gharabaghi, W Rosenstiel, and M Bogdan. Decoding of motor intentions from epidural ecog recordings in severely paralyzed chronic stroke patients. *Journal of Neural Engineering*, 11(6):066008, 2014.
- [12] A. Athanasiou, E. Chatzitheodorou, K. Kalogianni, C. Lithari, I. Moulos, and P. D. Bamidis. *XII Mediterranean Conference on Medical and Biological Engineering and Computing 2010: May 27 – 30, 2010 Chalkidiki, Greece*, chapter Comparing Sensorimotor Cortex Activation during Actual and Imaginary Movement, pages 111–114. Springer Berlin Heidelberg, Berlin, Heidelberg, 2010.
- [13] Kentaro Shimoda, Yasuo Nagasaka, Zenas C Chao, and Naotaka Fujii. Decoding continuous three-dimensional hand trajectories from epidural electrocorticographic signals in japanese macaques. *Journal of neural engineering*, 9(3):036015, 2012.
- [14] Marcel AJ van Gerven, Zenas C Chao, and Tom Heskes. On the decoding of intracranial data using sparse orthonormalized partial least squares. *Journal of neural engineering*, 9(2):026017, 2012.
- [15] Yasuhiko Nakanishi, Takufumi Yanagisawa, Duk Shin, Ryohei Fukuma, Chao Chen, Hiroyuki Kambara, Natsue Yoshimura, Masayuki Hirata, Toshiki Yoshimine, and Yasuharu Koike. Prediction of three-dimensional arm trajectories based on ecog signals recorded from human sensorimotor cortex. *PloS one*, 8(8):e72085, 2013.
- [16] David T Bundy, Mrinal Pahwa, Nicholas Szrama, and Eric C Leuthardt. Decoding three-dimensional reaching movements using electrocorticographic signals in humans. *Journal of neural engineering*, 13(2):026021, 2016.
- [17] Po T Wang, Christine E King, Colin M McCrimmon, Jack J Lin, Mona Sazgar, Frank P K Hsu, Susan J Shaw, David E Millet, Luis A Chui, Charles Y Liu, An H Do, and Zoran Nenadic. Comparison of decoding resolution of standard and high-density electrocorticogram electrodes. *Journal of Neural Engineering*, 13(2):026016, 2016.
- [18] Tobias Pistohl, Tonio Ball, Andreas Schulze-Bonhage, Ad Aertsen, and Carsten Mehring. Prediction of arm movement trajectories from ecog-recordings in humans. *Journal of neuroscience methods*, 167(1):105–114, 2008.
- [19] G Schalk. Two-dimensional movement control using electrocorticographic signals in humans. *JOURNAL OF NEURAL ENGINEERING*.
- [20] E. C. Leuthardt, K. J. Miller, G. Schalk, R. P. N. Rao, and J. G. Ojemann. Electrocoigraphy-based brain computer interface-the seattle experience. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 14(2):194–198, June 2006.
- [21] Hidenori Watanabe, Masa-aki Sato, Takafumi Suzuki, Atsushi Nambu, Yukio Nishimura, Mitsuo Kawato, and Tadashi Isa. Reconstruction of movement-related intracortical activity from micro-electrocorticogram array signals in monkey primary motor cortex. *Journal of neural engineering*, 9(3):036006, 2012.

- [22] Duk Shin, Hidenori Watanabe, Hiroyuki Kambara, Atsushi Nambu, Tadashi Isa, Yukio Nishimura, and Yasuharu Koike. Prediction of muscle activities from electrocorticograms in primary motor cortex of primates. *PLoS ONE*, 7(10):1–10, 10 2012.
- [23] J. Fernandez-Vargas, T. V. J. Tarvainen, K. Kita, and W. Yu. Hand motion reconstruction using eeg and emg. In *2016 4th International Winter Conference on Brain-Computer Interface (BCI)*, pages 1–4, Feb 2016.
- [24] JOJWGSJ Kubanek, KJ Miller, JG Ojemann, JR Wolpaw, and G Schalk. Decoding flexion of individual fingers using electrocorticographic signals in humans. *Journal of neural engineering*, 6(6):066001, 2009.
- [25] Zuoguan Wang, Q Ji, KJ Miller, and Gerwin Schalk. Prior knowledge improves decoding of finger flexion from electrocorticographic signals. *Front Neurosci*, 5:127, 2011.
- [26] D. Furman, R. Reichart, and H. Pratt. Finger flexion imagery: Eeg classification through physiologically-inspired feature extraction and hierarchical voting. In *2016 4th International Winter Conference on Brain-Computer Interface (BCI)*, pages 1–4, Feb 2016.
- [27] Jaime F Delgado Saa, Adriana de Pestere, and Mujdat Cetin. Asynchronous decoding of finger movements from ecog signals using long-range dependencies conditional random fields. *Journal of Neural Engineering*, 13(3):036017, 2016.
- [28] C Sidney Burrus, Ramesh A Gopinath, and Haitao Guo. Introduction to wavelets and wavelet transforms. 1997.
- [29] O. Aydemir. Investigation of the most appropriate mother wavelet for characterizing imaginary eeg signals used in bci systems. *Turkish Journal of Electrical Engineering & Computer Sciences*, 24(1):38, 1 2016.
- [30] Qibin Zhao, Cesar F Caiafa, Danilo P Mandic, Zenas C Chao, Yasuo Nagasaka, Naotaka Fujii, Liqing Zhang, and Andrzej Cichocki. Higher order partial least squares (hopls): A generalized multilinear regression method. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 35(7):1660–1673, 2013.
- [31] Douglas C Montgomery, Elizabeth A Peck, and G Geoffrey Vining. *Introduction to linear regression analysis*. John Wiley & Sons, 2015.
- [32] Hervé Abdi. Partial least square regression (pls regression), 2003.
- [33] Anjali Krishnan, Lynne J Williams, Anthony Randal McIntosh, and Hervé Abdi. Partial least squares (pls) methods for neuroimaging: a tutorial and review. *Neuroimage*, 56(2):455–475, 2011.
- [34] Q. Zhao, G. Zhou, T. Adali, L. Zhang, and A. Cichocki. Kernelization of tensor-based models for multiway data analysis: Processing of multidimensional structured data. *IEEE Signal Processing Magazine*, 30(4):137–148, July 2013.
- [35] Francisco AA Souza and Rui Araújo. Mixture of partial least squares experts and application in prediction settings with multiple operating modes. *Chemometrics and Intelligent Laboratory Systems*, 130:192–202, 2014.
- [36] Andrey Eliseyev and Tetiana Aksenova. Recursive n-way partial least squares for brain-computer interface. *PloS one*, 8(7):e69962, 2013.
- [37] Bhupinder S Dayal and John F MacGregor. Recursive exponentially weighted pls and its applications to adaptive control and prediction. *Journal of Process Control*, 7(3):169–179, 1997.
- [38] Qibin Zhao, Liqing Zhang, and Andrzej Cichocki. Multilinear and nonlinear generalizations of partial least squares: an overview of recent advances. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 4(2):104–115, 2014.