


КОГНИТИВНАЯ НАУКА В МОСКВЕ
НОВЫЕ ИССЛЕДОВАНИЯ



**МАТЕРИАЛЫ
КОНФЕРЕНЦИИ
2017**

ПОД РЕД. Е.В. ПЕЧЕНКОВОЙ, М.В. ФАЛИКМАН

УДК 159.9

ББК 81.002

К57

К57 Коллективный

Когнитивная наука в Москве: новые исследования. Материалы конференции 15 июня 2017 г.

Под ред. Е.В. Печенковой, М.В. Фаликман. – М.: ООО «Буки Веди», ИППИП. 2017 г. – 596 стр.

Электронная версия

ISBN 978-5-4465-1509-7

УДК 159.9

ББК 81.002

ISBN 978-5-4465-1509-7

© Авторы статей, 2017

МЕТОД СКРЫТОЙ ПЕРЕМЕННОЙ ДЛЯ АВТОМАТИЧЕСКОГО ОБНАРУЖЕНИЯ ФОНОВЫХ СОСТОЯНИЙ В ИНТЕРФЕЙСЕ МОЗГ – КОМПЬЮТЕР

Н. И. Дагаев*, К. В. Волкова, А. Е. Осадчий

ndagaev@hse.ru

Центр нейроэкономики и когнитивных исследований, НИУ «Высшая школа экономики», Москва

Аннотация. Известно, что системы интерфейсов мозг – компьютер (ИМК) чувствительны к изменениям в фоновых состояниях пользователя. Как правило, детальная информация об этих состояниях отсутствует даже на этапе обучения. Таким образом, необходим метод, который способен учитывать фоновые состояния автоматически, в режиме «без учителя». В настоящей работе предлагается подобный метод, основанный на вероятностной модели с дискретной скрытой переменной, моделирующей фоновые состояния пользователя ИМК. Чтобы оценить параметры модели, мы предлагаем использовать алгоритм максимизации ожидания (EM). Предлагаемый метод направлен на оценку характеристик фоновых состояний без какой-либо соответствующей маркировки данных. В контексте асинхронной парадигмы ИМК, основанного на воображаемых движениях руками, мы применили этот метод к реальным данным. В качестве фоновых состояний рассматривались открытые и закрытые глаза. Для четырех из шести испытуемых метод скрытой переменной улучшил классификации целевых состояний по сравнению с базовым методом. Таким образом, метод скрытой переменной может быть использован для повышения качества систем ИМК путем автоматической адаптации к фоновым состояниям пользователя.

Ключевые слова: ЭЭГ, интерфейс мозг – компьютер, вероятностная модель, EM-алгоритм, нейронная сеть

Несмотря на разнообразие в применяемых парадигмах, признаках и методах обучения, качество неинвазивных интерфейсов мозг – компьютер (ИМК) зачастую остается ниже требуемого ввиду низких показателей точности классификации паттернов ЭЭГ, что делает прикладное использование таких систем затруднительным. Важной причиной этого является нестационарность в сигналах ЭЭГ, появляющаяся в результате различных фоновых состояний, которые сопровождают выполнение испытуемым задачи ИМК. Эти фоновые состояния могут быть связаны со многими разнообразными факторами: различиями в условиях проведения эксперимента, эмоциональными и когнитивными состояниями, физиологическими условиями (например, глаза открытые или закрытые) и др. Действительно, как между сессиями, так и внутри сессии из-

меняющиеся состояния испытуемого могут существенно изменять паттерны регистрируемой активности мозга и таким образом влиять на точность работы алгоритма классификации. За последнее время был предложен ряд методов, направленных на преодоление негативных влияний этой фоновой изменчивости (Liyanage et al., 2013; Shenoy et al., 2006), таких как адаптивные методы, учитывающие влияние не связанных с основной задачей факторов (например, Nicolas-Alonso et al., 2015).

В этом контексте нами был разработан новый метод, эксплицитно подразумевающий наличие неизвестных переменных и адаптирующийся к различным фоновым состояниям в ИМК, основанном на воображаемых движениях. Метод основан на вероятностной модели со скрытыми переменными и извлекает информацию о фоновых состояниях автоматически. Метод был опробован для асинхронной парадигмы ИМК с тремя целевыми состояниями (воображаемые движения левой или правой рукой, а также состояние покоя). Чтобы протестировать пригодность метода для автоматического обнаружения скрытых фоновых состояний, испытуемые выполняли парадигму в периоды с открытыми и закрытыми глазами; последние рассматривались нами как два различных фоновых состояния.

Методика

С вероятностной точки зрения, скрытое фоновое состояние, которое нужно учитывать во время обучения классификатора, может быть смоделировано с помощью скрытой переменной Z_n . Это скалярная дискретная случайная величина, количество принимаемых значений k которой равно числу различных фоновых состояний. Поскольку предполагается, что фоновые состояния Z_n могут быть выделены на основе ЭЭГ-паттерна X_n , Z_n можно рассматривать как условно зависящее от X_n , $p(Z_n|X_n)$. Кроме того, целевое состояние T_n зависит от X_n по-разному при разных скрытых состояниях Z_n , поэтому T_n может быть смоделировано как условно зависящее и от X_n , и от Z_n , $p(T_n|X_n, Z_n)$. Таким образом, совместное распределение вероятности ЭЭГ паттерна, скрытого фонового состояния и целевого состояния определяется по формуле: $p(X_n, Z_n, T_n) = p(T_n|X_n, Z_n) p(Z_n|X_n) p(X_n) = p(T_n, Z_n|X_n) p(X_n)$. Поскольку паттерны ЭЭГ X_n даны, важен лишь компонент $p(T_n, Z_n|X_n)$; это распределение вероятностей может быть представлено как параметризованное некоторым набором параметров Θ , $p(T_n, Z_n|X_n, \Theta)$. На этапе обучения T_n даны, но $p(T_n, Z_n|X_n, \Theta)$ не может быть максимизировано непосредственно, так как Z_n неизвестны. По этой причине необходимо суммировать по скрытой переменной Z_n , чтобы получить выражение, которое можно будет максимизировать: $p(T_n|X_n, \Theta) = \sum_k (p(T_n, Z_{nk}|X_n, \Theta))$. После этого в качестве параметров модели Θ выбираются значения, которые обеспечивают максимальную совместную вероятность наблюдаемых данных: $\Theta = \text{argmax}(p(T|X, \Theta))$, где $p(T|X, \Theta) = \prod_n (p(T_n, Z_n|X_n, \Theta)) = \prod_n (\sum_k (p(T_n, Z_{nk}|X_n, \Theta)))$.

После нахождения Θ предсказание целевого состояния T_{n+1} для нового паттерна ЭЭГ X_{n+1} производится путем выбора наиболее вероятного значения. Однако, как и на этапе обучения, скрытое фоновое состояние Z_{n+1} остается не-

известным, так что предсказание должно основываться на частном распределении: $p(\mathbf{T}_{n+1} | \mathbf{X}_{n+1}, \Theta) = \sum_k (p(\mathbf{T}_{n+1}, \mathbf{Z}_{(n+1)k} | \mathbf{X}_{n+1}, \Theta))$.

Данная модель была применена на реальных данных (20 каналов по системе 10–10, частота дискретизации 250 Гц), записанных в асинхронной парадигме с использованием воображаемых движений. В качестве признаков \mathbf{X}_n , на основе которых проводилось обучение и тестирование алгоритма, использовались проекции данных на CSP-компоненты (common spatial pattern; Wu et al., 2006). Целевыми состояниями являлись движения левой или правой рукой, а также покой; в качестве фоновых состояний использовались периоды с открытыми и закрытыми глазами. Для моделирования $p(\mathbf{Z}_n | \mathbf{X}_n)$ мы использовали логистическую регрессию, поскольку число скрытых состояний (открытые/закрытые глаза) равно двум. Для моделирования $p(\mathbf{T}_n | \mathbf{X}_n, \mathbf{Z}_n)$ использовались нейронные сети прямого распространения (по одной на каждое значение \mathbf{Z}_n ; 15 скрытых нейронов) с выходным слоем softmax, что соответствует категориальному вероятностному распределению. Для нахождения оценок параметров модели в соответствии с критерием максимального правдоподобия мы применили алгоритм максимизации ожидания (expectation maximization, EM; Neal, Hinton, 1998): на E-шаге вычислялось математическое ожидание (по апостериорному распределению \mathbf{Z}_n) логарифма функции правдоподобия от \mathbf{T}_n и \mathbf{Z}_n , а на M-шаге найденное ожидание логарифма правдоподобия максимизировалось относительно искомым параметров. В качестве контрольного метода использовалась обычная нейронная сеть прямого распространения, аналогичная по своей архитектуре описанным выше сетям, которые использовались для моделирования $p(\mathbf{T}_n | \mathbf{X}_n, \mathbf{Z}_n)$.

Результаты

В табл. 1 представлены результаты применения методов на тренировочной и тестовой выборках. Усредненная по испытуемым, разница в средней точности классификации между методом скрытой переменной и контрольным методом составила 0.02, $t(5) = 2.82$, $p < .05$. Для испытуемых S2, S4, S5 и S6 средняя тестовая точность классификации для метода скрытой переменной оказалась больше, чем средняя тестовая точность классификации для контрольного

Таблица 1. Сравнение средней точности классификации целевых состояний на тренировочном и тестовом наборах данных (в скобках указаны стандартные отклонения)

Испытуемый	Контрольный метод		Метод скрытой переменной	
	Тестовая успешность	Тренировочная успешность	Тестовая успешность	Тренировочная успешность
S1	.709 (.026)	.901 (.014)	.705 (.032)	.907 (.024)
S2	.67 (.011)	.879 (.01)	.71 (.006)	.884 (.006)
S3	.737 (.11)	.901 (.024)	.738 (.031)	.896 (.008)
S4	.702 (.007)	.902 (.013)	.729 (.011)	.892 (.008)
S5	.806 (.01)	.943 (.006)	.833 (.013)	.949 (.009)
S6	.49 (.008)	.713 (.032)	.52 (.013)	.688 (.018)




Рисунок 1. Зависимость точности классификации целевых состояний для тренировочных (Train) и тестовых (Test) данных от количества циклов EM алгоритма для каждого испытуемого

метода (в качестве пороговой была установлена разница в .01). На рис. 1 продемонстрирована зависимость точности классификации целевых состояний от количества циклов EM алгоритма. Для испытуемых S2, S4, S5 и S6 точность классификации имеет тенденцию к увеличению по мере увеличения числа циклов.

Обсуждение результатов

Таким образом, информация о фоновых состояниях, полученная в отсутствие меток скрытых состояний в процессе обучения, позволила методу скрытой переменной достичь более высоких показателей точности классификации, чем в случае контрольного метода. Данный алгоритм хорошо подходит для ситуаций, когда некоторые факторы, как ожидается, влияют на точность распознавания целевых состояний, но точные моменты времени и обстоятельства их влияния неизвестны. Кроме того, модель скрытой переменной можно применять, когда точное число скрытых состояний доподлинно неизвестно. Так, известно, что для EM-алгоритма характерно удаление избыточных компонентов (Neal, Hinton, 1998). Возможные применения описанного выше метода не ограничиваются условиями открытых/закрытых глаз. В качестве скрытых состояний могут выступать любые другие фоновые состояния испытуемого, которые влияют на разделимость целевых состояний. Описанный в настоящем исследовании метод дополняет существующие способы повышения точности классификации в ИМК-системах путем учета влияния скрытых фоновых состояний.

Литература

Liyang S.R., Guan C., Zhang H., Ang K.K., Xu J., Lee T.H. Dynamically weighted ensemble classification for non-stationary EEG processing // Journal of Neural Engineering. 2013. Vol. 10. No. 3. P.036007. doi:10.1088/1741-2560/10/3/036007

Neal R.M., Hinton G.E. A view of the EM algorithm that justifies incremental, sparse, and other variants // Learning in Graphical Models. Netherlands: Springer Netherlands, 1998. P. 355 – 368. doi:10.1007/978-94-011-5014-9_12

Nicolas-Alonso L.F., Corralejo R., Gomez-Pilar J., Álvarez D., Hornero R. Adaptive semi-supervised classification to reduce intersession non-stationarity in multiclass motor imagery-based brain–computer interfaces//Neurocomputing.2015.Vol.159.P.186–196.[doi:10.1016/j.neucom.2015.02.005](https://doi.org/10.1016/j.neucom.2015.02.005)

Shenoy P., Krauledat M., Blankertz B., Rao R.P., Müller K.R. Towards adaptive classification for BCI // Journal of Neural Engineering. 2006. Vol.3. No.1. P.R13–R23. [doi:10.1088/1741-2560/3/1/r02](https://doi.org/10.1088/1741-2560/3/1/r02)

Wu W., Gao X., Gao S. One-versus-the-rest (OVR) algorithm: An extension of common spatial patterns (CSP) algorithm to multi-class case // 27th Annual International Conference of the Engineering in Medicine and Biology Society. IEEE, 2006. P.2387–2390.

Latent Variable Method for Automatic Detection of Background States in a Brain-Computer Interface

Dagaev N.*, Volkova K., Ossadtchi A.

ndagaev@hse.ru

Centre for Cognition and Decision making, National Research University Higher School of Economics, Moscow

Abstract. Brain-computer interface (BCI) systems are sensitive to changes in the background states of a user. As a rule, detailed information about these states is absent even at the stage of training. For this reason, an unsupervised method that can automatically take background states into account is needed. In the current study, we present a method based on a probabilistic model with a discrete latent variable which is aimed at modeling the background state of a user. To evaluate the parameters of our model, we suggest applying the expectation-maximization (EM) algorithm. The method proposed is aimed at assessing characteristics of background states without any corresponding labeling of data. In the context of the asynchronous BCI paradigm based on imaginary hand movements, we applied this method to real data. Open and closed eyes were considered as distinct background states. In four of the six participants, the latent variable method increased the classification accuracy of target states compared to the baseline method. Thus, the latent variable method can be used to improve the quality of BCI systems by the automatic adaptation to background states of a user.

Keywords: EEG, brain-computer interface, probabilistic model, EM-algorithm, neural network