

Построение аппроксимирующего описания скалограммы в задаче прогнозирования движений по электрокортикограмме*

Э. Э. Гасанов¹, А. П. Мотренко²

elnur.gasanov@phystech.edu; anastasia.motrenko@gmail.com

¹Московский физико-технический институт, Россия, г. Долгопрудный, Институтский пер., 9

²ФИЦ «Информатика и управление» РАН, Россия, г. Москва, ул. Вавилова, 44/2

Работа посвящена декодированию движений пальцев человека по электрокортикограмме (ЭКоГ). Данные представляют собой временные ряды потенциалов электродов, расположенных на коре головного мозга, и временные ряды положений пальцев руки пяти испытуемых добровольцев. Решается задача прогнозирования движений пальцев руки по временным рядам показаний электродов. В качестве признаков, описывающих сигнал, используется вейвлет-преобразование ЭКоГ сигналов для различных частот и различных промежутков времени. Объединение скалограмм, построенных для каждого электрода, описывает временной ряд в пространственно-частотно-временной области. Для снижения размерности признакового пространства используется метод локальной аппроксимации: скалограмма для каждого электрода приближается параметрической моделью. Для дальнейшего снижения размерности признакового пространства используется метод частичных наименьших квадратов. Приближение скалограмм параметрическими моделями не привело к существенному ухудшению прогноза, хотя значительно сократило количество признаков.

Ключевые слова: временные ряды; ЭКоГ; локальная аппроксимация; метод частичных наименьших квадратов

DOI: 10.21469/22233792.3.2.06

1 Введение

В системах, основанных на нейрокомпьютерном интерфейсе (НКИ) [1, 2], анализ временных рядов электрической активности мозга человека позволяет понять его намерение о движениях. Нейрокомпьютерный интерфейс успешно используется в прикладных задачах, например в управлении летающими дронами [3], движении курсором по экрану компьютера [4]. Ввиду того что в нем не используются сигналы от периферической нервной системы, НКИ применяется при создании систем управления экзоскелетами, имеющих важное значение для людей с ограниченными возможностями [5].

Нейрокомпьютерный интерфейс может быть реализован несколькими способами. Электроэнцефалографические (ЭЭГ) сигналы обеспечивают интерфейс без проведения операции, дешевы во внедрении [6]. Однако ЭЭГ сигналы имеют узкую ширину полосы частот, так как некоторые сигналы головного мозга поглощаются тканями человека (кровью, кожей и т. д.) [7]. Настройка НКИ на ЭЭГ сигналах требует много времени, такие НКИ обладают плохой пространственной локализацией [8], так как электроды удалены от коры головного мозга, где происходит активность. Инвазивный метод регистрации отдельных нейронов (single-unity active, SUA) позволяет получить высокоточные значения

*Работа выполнена при финансовой поддержке РФФИ, проект № 16-07-01155.

потенциалов электродов, однако НКИ, базирующиеся на SUA, требуют частой перекалибровки ввиду постоянного ухудшения снимаемого сигнала [9]. Нейрокомпьютерный интерфейс на ЭКоГ [10] лишены этих недостатков: в задачах декодирования движений обезьяны НКИ могут успешно применяться через несколько месяцев после настройки без серьезных ухудшений качества прогнозирования [11], ЭКоГ сигналы обладают существенно более широкой полосой частот, нежели ЭЭГ [7].

Эта работа посвящена предсказанию временных рядов положений пальцев человека [12] по временным рядам электродов, образующих сигналы ЭКоГ. Данная задача уже решалась другими группами ученых: например, методом выделения частотных областей авторегрессионного процесса [13] с применением линейной модели для аппроксимации [14]. В данной работе каждому электроду с помощью вейвлет-преобразования с вейвлетом Морле ставится в соответствие скалограмма — двумерный массив признаков в пространстве частота–время. Скалограмма сигнала позволяет определить частоты, сильнее всего участвующие в образовании сигнала в короткий диапазон времени. Параметры моделей, наилучшим образом аппроксимирующие скалограммы различных электродов, образуют признаковое описание временного ряда [15, 16]. Получаемые признаки обладают мультиколлинеарностью, для снижения размерности и повышения устойчивости модели применяется метод частичных наименьших квадратов.

2 Формирование выборки

Данные представляют собой два временных ряда: временной ряд X вектора потенциалов электродов, расположенных на коре головного мозга объекта

$$X = [\mathbf{x}_1^T, \dots, \mathbf{x}_{T_x}^T]^T, \quad \mathbf{x}_i = \begin{bmatrix} x_i^1 \\ \vdots \\ x_i^k \end{bmatrix} \in \mathbb{R}^k,$$

где k есть количество электродов, и временной ряд Y вектора значений – показаний датчиков, фиксирующих движения объекта

$$Y = [\mathbf{y}_1^T, \dots, \mathbf{y}_{T_y}^T]^T, \quad \mathbf{y}_i = \begin{bmatrix} y_i^1 \\ \vdots \\ y_i^m \end{bmatrix} \in \mathbb{R}^m,$$

где m есть число датчиков. Количество строк матрицы X равно количеству строк матрицы Y , т. е. $T_x = T_y$. Для формирования выборки рассмотрим набор отсчетов времени t_1, \dots, t_n . Составим выборку $\mathcal{D} = \{\mathbf{x}_i, \mathbf{y}_i\}$, где \mathbf{x}_i и \mathbf{y}_i — столбцы матриц X и Y , соответствующие моменту времени t_i .

3 Постановка задачи

Дана выборка $\mathcal{D} = \{\mathbf{x}_i, \mathbf{y}_i\}, i \in \mathcal{I} = \{1, \dots, n\}$, состоящая из n пар объект–ответ и представляющая собой два временных ряда. Каждый из объектов описан k признаками $\mathbf{x} \in \mathbb{R}^k$ и имеет ответ $\mathbf{y} \in \mathbb{R}^m$. Через \mathcal{L} обозначим множество всех индексов объектов обучающей выборки, через \mathcal{C} — контрольной выборки, через $S_t \in \mathbb{R}^{k \times \tau}$ — матрицу $[\mathbf{x}_{t-\tau}, \dots, \mathbf{x}_t]$.

Требуется найти функцию f , приближающую временной ряд ответов наилучшим образом в смысле функции ошибки на \mathcal{L} :

$$f : S_t \mapsto \mathbf{y}_t$$

Необходимо построить признаковое описание $h(S_t)$, чтобы задача решалась оптимально с помощью линейной регрессии

$$f(S_t) = \mathbf{w}^T \mathbf{h}(S_t),$$

где $h : \mathbb{R}^{k \times \tau} \rightarrow \Theta \subseteq \mathbb{R}^l$ представляет собой признаковое описание матрицы S_t , зависящее от заранее выбранной модели аппроксимации. В задаче матрице S_t ставится в соответствие набор скалограмм (см. разд. 4). В качестве модели аппроксимации выбраны многомерные полиномы. Совокупность параметров полиномов всех скалограмм Θ используется в качестве признаков в задаче прогнозирования.

Пусть задана функция потерь

$$\mathcal{Q} = \frac{1}{|\mathcal{L}|} \sum_{t \in \mathcal{L}} \|\mathbf{w}^T \mathbf{h}(S_t) - y_t\|_2^2.$$

Параметр $\tilde{\mathbf{w}}$ линейной регрессии минимизирует квадрат отклонения:

$$\tilde{\mathbf{w}} = \arg \min_{\mathbf{w} \in \mathbb{R}^l} \mathcal{Q}(\mathbf{w}, \mathbf{h}, \tau, \mathcal{D}).$$

Для оценки качества построенных моделей будем использовать корреляцию Пирсона:

$$\text{corr}(\mathbf{y}, \hat{\mathbf{y}}) = \frac{\sum_{i=1}^m (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^m (y_i - \bar{y})^2 \sum_{i=1}^m (\hat{y}_i - \bar{\hat{y}})^2}}.$$

Требуется найти функцию h и параметр τ , максимизирующие среднюю по строкам матрицы $Y' = \|\mathbf{y}_i\|_{i \in \mathcal{L}}$ корреляцию Пирсона.

4 Построение скалограммы

Для построения скалограммы по матрице S_t используется вейвлет-преобразование с вейвлетом Морле:

$$[W_\psi \varphi_i](a, t') = \frac{1}{|a|} \sum_t \psi\left(\frac{t-t'}{a}\right) \varphi_i(t),$$

где ψ — вейвлет Морле; a — параметр растяжения; $\varphi_i(t)$ — i -я строка матрицы S_t . Параметр растяжения имеет прямую связь с частотой анализируемого сигнала f_w :

$$a = \frac{f_c f_s}{f_w},$$

где $f_c = 0,8125$ Гц — центральная частота для вейвлета Морле; f_s — частота дискретизации сигнала.

Скалограммы генерируются для каждого электрода. Для построения скалограммы размера $n \times n$, относящейся к отрезку времени $[t - \tau, t]$, в диапазоне $f_{\min} - f_{\max}$ определяется n частот f_w в логарифмическом масштабе. На $[t - \tau, t]$ для каждой из n выбранных частот применяется вейвлет-преобразование с вейвлетом Морле. Для удаления краевых эффектов из рассмотрения удаляется часть проведенных вычислений, соответствующая первым τ' секундам рассматриваемого отрезка времени. Отрезок времени $[t - \tau + \tau', t]$ делится на n равных частей, значения вейвлет-преобразования для каждой частоты усредняются в пределах каждого промежутка времени. В дальнейшем в работе под интервалом




Рис. 1 Пример скалограммы

времени построения скалограммы будем понимать τ , под интервалом времени обрезания края — τ' . На рис. 1 представлен пример скалограммы.

5 Аппроксимация скалограммы и функция $h(S_t)$

Для уменьшения размерности признакового пространства, сокращения вычислительной сложности всего алгоритма, снижения чувствительности к шумам необходима аппроксимация.

Определение 1. *Параметрической аппроксимирующей моделью g скалограммы G называется отображение*

$$g : \mathbb{R}^l \rightarrow \mathbb{R}^{n \times n} .$$

В пространстве скалограмм ($G \in \mathbb{R}^{n \times n}$) рассмотрим метрику ρ :

$$\rho(G, \hat{G}) = \left\| \text{vec} \left(G - \hat{G} \right) \right\|_2^2 .$$

Определение 2. *Признаковым описанием скалограммы G , порожденным параметрической моделью $g(\mathbf{v})$, назовем вектор оптимальных параметров этой модели:*

$$\mathbf{v}_g(G) = \arg \min_{\mathbf{v} \in \mathbb{R}^l} \rho(g(\mathbf{v}), G) .$$

Скалограммы электродов предлагается аппроксимировать полиномами. Пусть натуральные числа x и y определяют координаты ячейки скалограммы по горизонтали и вертикали соответственно:

(а) линейная модель:

$$g(\mathbf{v}, x, y) = v_0 + v_1x + v_2y ;$$

(б) квадратичная модель:

$$g(\mathbf{v}, x, y) = v_0 + v_1x + v_2y + v_3xy + v_4x^2 + v_5y^2 ;$$

(в) «purequadratic»:

$$g(\mathbf{v}, x, y) = v_0 + v_1x + v_2y + v_3x^2 + v_4y^2 ;$$

(г) кубическая модель:

$$g(\mathbf{v}, x, y) = v_0 + v_1x + v_2y + v_3xy + v_4x^2 + v_5y^2 + v_6x^2y + v_7xy^2 + v_8x^3 + v_9y^3;$$

(д) «purecube»:

$$g(\mathbf{v}, x, y) = v_0 + v_1x + v_2y + v_3x^2 + v_4y^2 + v_5x^3 + v_6y^3.$$

6 Метод частичных наименьших квадратов

Параметры полиномов, рассматриваемые как признаки временного ряда в указанный промежуток времени, обладают мультиколлинеарностью, так как сигналы с соседних электродов зависят друг от друга. Метод частичных наименьших квадратов (partial least squares, PLS) состоит в итеративном снижении размерности пространства признаков таким образом, чтобы ковариация между старыми и новыми признаками была максимальной.

Основная идея метода PLS заключается в проекции исходного пространства признаков X в такое пространство меньшей размерности, чтобы ковариация между новыми признаками и вектором ответов была максимальной. Метод поясняется следующим разложением матриц признаков и ответов:

$$X = TP^T + E; \quad Y = UQ^T + F,$$

где $X \subset R^{n \times m}$; $Y \subset R^{n \times p}$. Матрицы T и U размера $n \times l$ есть проекции X и Y соответственно. Матрицы P и Q есть ортогональные проецирующие матрицы размеров $m \times l$ и $p \times l$ соответственно. Матрицы E и F — матрицы ошибок, которые предполагаются независимыми и нормально распределенными.

7 Вычислительный эксперимент

Целью вычислительных экспериментов является эмпирическое исследование качества прогнозирования положения пальцев при определенных параметрах обработки исходных данных (дискретизация скалограммы, отрезок времени построения скалограммы, отрезок времени обрезания края) в моделях аппроксимации. Имеются данные временных рядов состояний электродов и положений пальцев для 5 человек («br», «ca», «сс», «de», «wm»).

Аппроксимация полиномами достигается за счет решения переопределенной системы уравнений методом наименьших квадратов. Для получения коэффициентов полиномов используются функция `linsolve` и пакет `polyfitn`, реализованные на MATLAB. Для реализации метода PLS используется функция `plsregress`, реализованная на MATLAB алгоритмом SIMPLS [17].

На рис. 2 показаны действительные и спрогнозированные положения одного из маркеров (объект «сс», дискретизация скалограммы 5×5 , временные отметки каждую секунду, $\tau = 0,05$ с и $\tau' = 0,001$ с, аппроксимация отсутствует) при обучении до 105-й секунды измерений.

На рис. 3 представлены данные о качестве прогнозирования для всех испытуемых при дискретизации скалограммы 5×5 , временных отметках каждые 0,05 с, $\tau = 0,05$ с и $\tau' = 0,001$ с при кросс-валидации на 5 блоках и различных вариантах локальной аппроксимации скалограммы.

Эксперимент при дискретизации скалограммы 10×10 , временных отрезках каждую секунду, $\tau = 0,3$ с и $\tau' = 0,08$ с показывает более высокие значения корреляции для каждого

испытуемого (табл. 1 и 2). В табл. 1 и 2 представлены сводные результаты по самым высоким корреляциям для каждого объекта, соответствующие дисперсии, число компонент в методе частичных наименьших квадратов, на котором достигалась соответствующая корреляция, и тип аппроксимации. Также для сравнения представлена аналогичная информация про эксперименты, в которых аппроксимация скалограмм не производилась, а в качестве признаков рассматривалась совокупность bn^2 чисел, определяющих скалограммы (b — число электродов; n — параметр, определяющий размер скалограммы, см. разд. 4).

Таблица 1 Результаты эксперимента при $\tau = 0,05$ с и $\tau' = 0,001$ с

| Данные | С использованием модели | | | | Без использования модели | | |
|--------|-------------------------|----------|-----------------|---------------|--------------------------|----------|-----------------|
| | corr | σ | Число компонент | Лучшая модель | corr | σ | Число компонент |
| bp | 0,1202 | 0,0452 | 53 | Purequadratic | 0,1564 | 0,0414 | 1 |
| ca | 0,108 | 0,0456 | 49 | Purequadratic | 0,0803 | 0,0423 | 4 |
| cc | 0,2497 | 0,0153 | 15 | Quadratic | 0,3847 | 0,0275 | 101 |
| de | 0,163 | 0,0052 | 15 | Purequadratic | 0,2306 | 0,026 | 2 |
| wm | 0,294 | 0,0173 | 119 | Cube | 0,3222 | 0,0126 | 10 |

Таблица 2 Результаты эксперимента при $\tau = 0,3$ с и $\tau' = 0,08$ с

| Данные | С использованием модели | | | | Без использования модели | | |
|--------|-------------------------|----------|-----------------|---------------|--------------------------|----------|-----------------|
| | corr | σ | Число компонент | Лучшая модель | corr | σ | Число компонент |
| bp | 0,3137 | 0,99 | 44 | Purecube | 0,3011 | 0,1044 | 29 |
| ca | 0,3508 | 0,1022 | 57 | Purecube | 0,348 | 0,2757 | 3 |
| cc | 0,2636 | 0,0815 | 56 | Purecube | 0,309 | 0,1774 | 1 |
| de | 0,3072 | 0,0976 | 36 | Quadratic | 0,458 | 0,1603 | 40 |
| wm | 0,2874 | 0,2135 | 3 | Purecube | 0,4181 | 0,1944 | 1 |

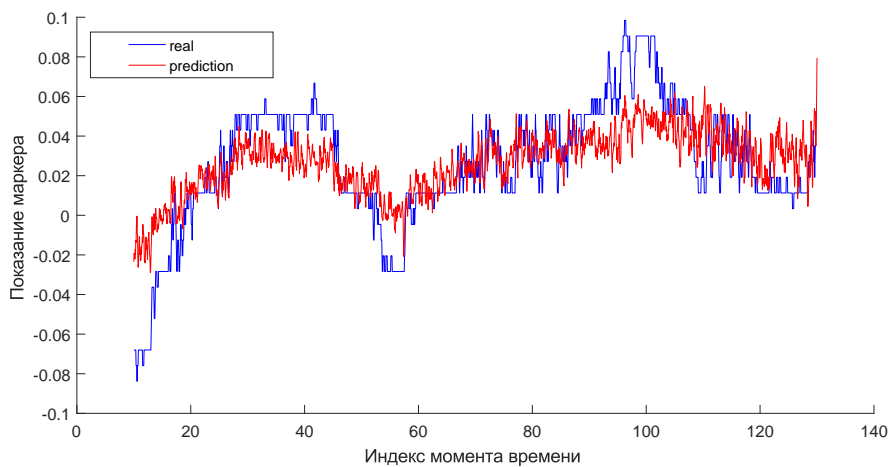


Рис. 2 Пример прогнозирования для объекта «cc»

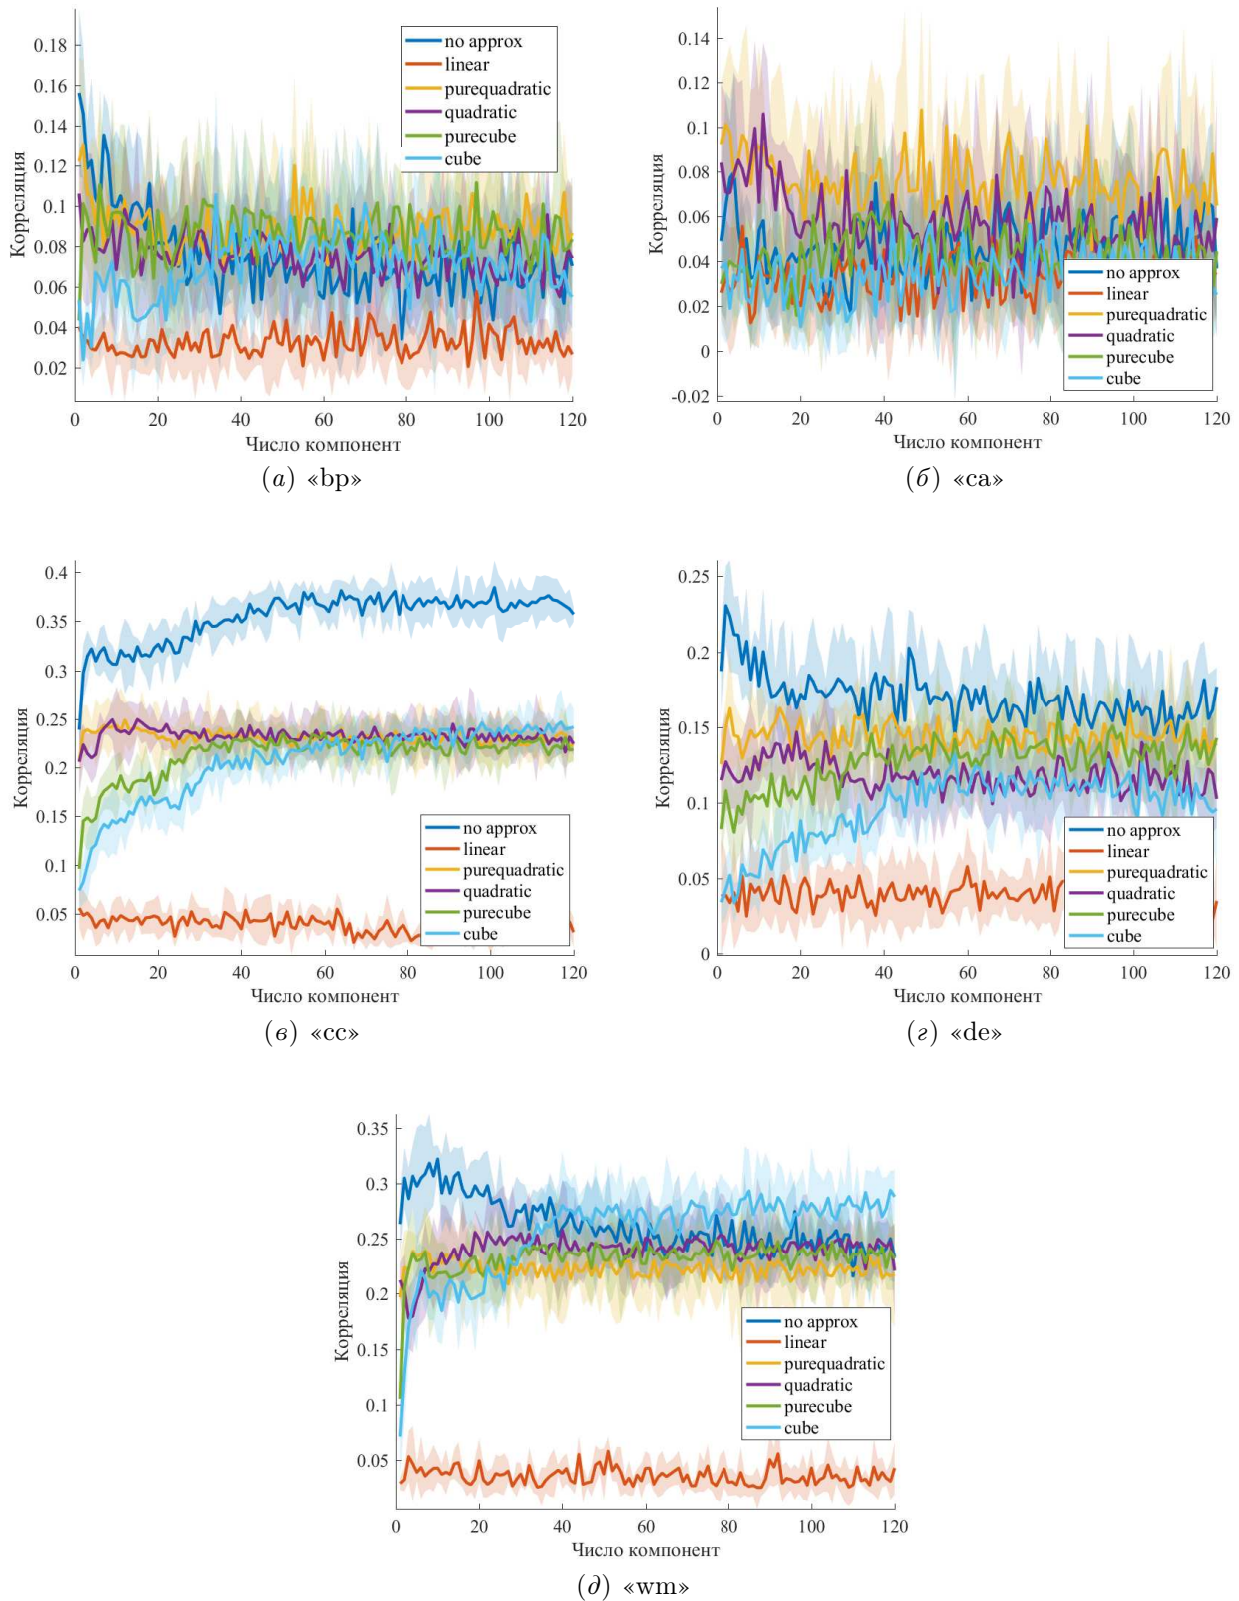


Рис. 3 Средние корреляции тестовых и предсказанных траекторий пальцев пяти испытуемых при кросс-валидации

Из приведенных таблиц и рисунков видно, что нельзя выделить тип аппроксимации, на котором предсказание давало бы результат существенно лучший, чем другие виды аппроксимаций.

8 Заключение

В задаче прогнозирования положения пальцев человека по сигналам с ЭКоГ реализован метод локальной аппроксимации, примененный для снижения размерности признакового пространства. Было выяснено, что аппроксимация скалограммы полиномами до 3-й степени приводит к средним корреляциям на кросс-валидации, не превосходящим 0,5.

Приближение скалограмм параметрическими моделями не привело к существенному ухудшению прогноза, хотя значительно сократило количество признаков. Последнее является свидетельством избыточности скалограмм. В дальнейшем предлагается исследовать способы построения признаков для решения данной задачи, не требующие построения скалограмм.

Авторы выражают благодарность В. В. Стрижову за постановку задачи и внимательное отношение к работе.

Литература

- [1] *Schalk G., McFarland D. J., Hinterberger T., et al.* BCI2000: A general-purpose brain-computer interface (BCI) system // *IEEE T. Bio-Med. Eng.*, 2004. Vol. 51. No. 6. P. 1034–1043.
- [2] *Lebedev M. A., Nicolelis M. A. L.* Brain-machine interfaces: Past, present and future // *Trends Neurosci.*, 2006. Vol. 29. Iss. 9. P. 536–546.
- [3] *He B., Baxter B., Edelman B. J., Cline C. C., Ye W. W.* Noninvasive brain-computer interfaces based on sensorimotor rhythms // *Proc. IEEE*, 2015. Vol. 103. Iss. 6. P. 907–925.
- [4] *Schalk G., Miller K. J., Anderson N. R., et al.* Two-dimensional movement control using electrocorticographic signals in humans // *J. Neural Eng.*, 2008. Vol. 5. No. 1. P. 75–84.
- [5] *Millán J. d. R., Rupp R., Müller-Putz G. R., et al.* Combining brain-computer interfaces and assistive technologies: State-of-the-art and challenges // *Front. Neurosci. Switz.*, 2010. Vol. 4. Article 161. 15 p.
- [6] *Mason S. G., Bashashati A., Fatourechi M., Navarro K. F., Birch G. E.* A comprehensive survey of brain interface technology designs // *Annal. Biomed. Eng.*, 2007. Vol. 35. No. 2. P. 137–169.
- [7] *Wilson J. A., Felton E. A., Garell P. C., Schalk G., Williams J. C.* ECoG factors underlying multimodal control of a brain-computer interface // *IEEE T. Neur. Sys. Reh.*, 2006. Vol. 14. No. 2. P. 246–250.
- [8] *Freeman W. J., Holmes M. D., Burke B. C., Vanhatalo S.* Spatial spectra of scalp EEG and EMG from awake humans // *Clin. Neurophysiol.*, 2003. Vol. 114. Iss. 6. P. 1053–1068.
- [9] *Chestek C. A., Batista A. P., Santhanam G., et al.* Single-neuron stability during repeated reaching in macaque premotor cortex // *J. Neurosci.*, 2007. Vol. 27. No. 40. P. 10742–10750.
- [10] *Leuthardt E. C., Schalk G., Wolpaw J. R., Ojemann J. G., Moran D. W.* A brain-computer interface using electrocorticographic signals in humans // *J. Neural Eng.*, 2004. Vol. 1. No. 2. P. 63–71.
- [11] *Chao Z. C., Nagasaka Y., Fujii N.* Long-term asynchronous decoding of arm motion using electrocorticographic signals in monkeys // *Front. Neuroeng.*, 2010. Vol. 3. Article 3.
- [12] *Dipietro L., Sabatini A. M., Dario P.* A survey of glove-based systems and their applications // *IEEE T. Syst. Man Cy. C*, 2008. Vol. 38. No. 4. P. 461–482.
- [13] *Marple S. L., Jr.* Digital spectral analysis: With applications. — Englewood Cliffs, NJ, USA: Prentice-Hall, 1987. Vol. 5. 492 p.

- [14] *Kubánek J., Miller K. J., Ojemann J. G., Wolpaw J. R., Schalk G.* Decoding flexion of individual fingers using electrocorticographic signals in humans // *J. Neural Eng.*, 2009. Vol. 6. No. 6. P. 066001.
- [15] *Кузнецов М. П., Ивкин Н. П.* Алгоритм классификации временных рядов акселерометра по комбинированному признаковому описанию // *Машинное обучение и анализ данных*, 2015. Т. 1. № 11. С. 1471–1483.
- [16] *Карасиков М. Е., Стрижов В. В.* Классификация временных рядов в пространстве параметров порождающих моделей // *Информатика и её применения*, 2016. Т. 10. № 4. С. 121–131.
- [17] *De Jong S.* SIMPLS: An alternative approach to partial least squares regression // *Chemometr. Intell. Lab.*, 1993. Vol. 18. No. 3. P. 251–263.

Поступила в редакцию 03.10.2017

Creation of approximating scalogram description in a problem of movement prediction*

E. E. Gasanov¹ and A. P. Motrenko²

elnur.gasanov@phystech.edu; anastasia.motrenko@gmail.com

¹Moscow Institute of Physics and Technology, 9 Institutskiy per., Dolgoprudny, Moscow, Russia

²Federal Research Center “Computer Science and Control” of RAS, 44/2 Vavilova Str., Moscow, Russia

The paper addresses the problem of a thumb movement prediction using electrocorticographic (ECoG) activity. The task is to predict thumb positions from the voltage time series of cortical activity. The scalograms are used as input features to this regression problem. Scalograms are generated by the spatio-spectro-temporal integration of voltage time series across multiple cortical areas. To reduce the dimension of a feature space, local approximation is used: every scalogram is approximated by parametric model. The predictions are obtained with partial least squares regression applied to local approximation parameters. Local approximation of scalograms does not significantly lower the quality of prediction while it efficiently reduces the dimension of feature space.

Keywords: *time series; ECoG; local approximation; partial least squares regression*

DOI: 10.21469/22233792.3.2.06

References

- [1] Schalk, G., D. J. McFarland, T. Hinterberger, *et al.* 2004. BCI2000: A general-purpose brain-computer interface (BCI) system. *IEEE T. Bio-Med. Eng.* 51(6):1034–1043.
- [2] Lebedev, M. A., and M. A. L. Nicolelis. 2006. Brain-machine interfaces: Past, present and future. *Trends Neurosci.* 29(9):536–546.
- [3] He, B., B. Baxter, B. J. Edelman, C. C. Cline, and W. W. Ye. 2015. Noninvasive brain-computer interfaces based on sensorimotor rhythms. *Proc. IEEE* 103(6):907–925.
- [4] Schalk, G., K. J. Miller, N. R. Anderson, *et al.* 2008. Two-dimensional movement control using electrocorticographic signals in humans. *J. Neural Eng.* 5(1):75–84.

*The research was supported by the Russian Foundation for Basic Research (grant 16-07-01155).

- [5] Millán, J. d. R., R. Rupp, G. R. Müller-Putz, *et al.* 2010. Combining brain–computer interfaces and assistive technologies: State-of-the-art and challenges. *Front. Neurosci. Switz.* 4:161.
- [6] Mason, S. G., A. Bashashati, M. Fatourechi, K. F. Navarro, and G. E. Birch. 2007. A comprehensive survey of brain interface technology designs. *Ann. Biomed. Eng.* 35(2):137–169.
- [7] Wilson, J. A., E. A. Felton, P. C. Garell, G. Schalk, and J. C. Williams. 2006. ECoG factors underlying multimodal control of a brain–computer interface. *IEEE T. Neur. Sys. Reh.* 14(2):246–250.
- [8] Freeman, W. J., M. D. Holmes, B. C. Burke, and S. Vanhatalo. 2003. Spatial spectra of scalp EEG and EMG from awake humans. *Clin. Neurophysiol.* 114(6):1053–1068.
- [9] Chestek, C. A., A. P. Batista, G. Santhanam, *et al.* 2007. Single-neuron stability during repeated reaching in macaque premotor cortex. *J. Neurosci.* 27(40):10742–10750.
- [10] Leuthardt, E. C., G. Schalk, J. R. Wolpaw, J. G. Ojemann, and D. W. Moran. 2004. A brain–computer interface using electrocorticographic signals in humans. *J. Neural Eng.* 1(2):63–71.
- [11] Chao, Z. C., Y. Nagasaka, and N. Fujii. 2010. Long-term asynchronous decoding of arm motion using electrocorticographic signals in monkeys. *Front. Neuroeng.* 3:3.
- [12] Dipietro, L., A. M. Sabatini, and P. Dario. 2008. A survey of glove-based systems and their applications. *IEEE T. Syst. Man Cy. C* 38(4):461–482.
- [13] Marple, S. L., Jr. 1987. *Digital spectral analysis: With applications*. Englewood Cliffs, NJ: Prentice-Hall, 1987. Vol. 5. 492 p.
- [14] Kubánek, J., K. J. Miller, J. G. Ojemann, J. R. Wolpaw, and G. Schalk. 2009. Decoding flexion of individual fingers using electrocorticographic signals in humans. *J. Neural Eng.* 6(6):066001.
- [15] Kuznetsov, M. P., and N. P. Ivkin. 2015. Algoritm klassifikatsii vremennykh ryadov akselerometra po kombinirovannomu prizmakovomu opisaniyu [Time series classification algorithm using combined feature description]. *J. Machine Learning Data Anal.* 1(11):1471–1483.
- [16] Karasikov, M. E., and V. V. Strijov. 2016. Klassifikatsiya vremennykh ryadov v prostranstve parametrov porohdayushchikh modeley [Feature-based time-series classification]. *Informatika i ee Primeneniya — Inform. Appl.* 10(4):121–131.
- [17] De Jong, S. 1993. SIMPLS: An alternative approach to partial least squares regression. *Chemometr. Intell. Lab.* 18(3):251–263.

Received October 3, 2017