

Порождение пространства признаков в задачах анализа кортикограмм

Эльнур Эльдарович Гасанов

Московский физико-технический институт
Физтех-школа прикладной математики и информатики
Факультет управления и прикладной математики
Кафедра «Интеллектуальные системы»

Научный руководитель: д.ф.-м.н. В.В. Стрижов

Выпускная квалификационная работа бакалавра

Москва 2018

Гипотеза

Учет перемещения зон возбуждения моторной коры головного мозга значительно повышает качество декодирования временного ряда физической активности по электрокортикограмме (ECoG).

Цель

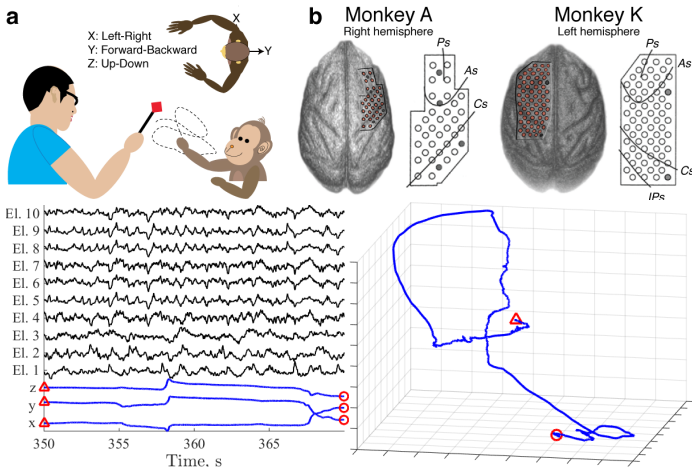
Предложить локально-аппроксимирующую модель, учитывающую пространственно-временную структуру измерений.

Проблема

Модели PLS, QPFS игнорируют структуру измерений.

Предлагается

использовать в качестве признаков параметры локально-аппроксимирующей модели.



Частота дискретизации электрокортикограммы равна 1КГц.

Neurotycho, RIKEN Brain Science Institute, Saitama, Japan

Модели декодирования временного ряда

- 1 Сравнение алгоритмов PLS, NPLS, QPFS, NQPFS, запущенных над скалограммами, построенных по ECoG
Motrenko A., Strijov V. "Multi-way Feature Selection for ECoG-based Brain-Computer Interface" 2018
- 2 Применение PLS над скалограммами
Chao ZC et al. "Long-term asynchronous decoding of arm motion using electrocorticographic signals in monkeys" 2010

Системы измерений сигналов ECoG

- 1 Neurotycho, RIKEN Brain Science, Tokyo, Japan Institute
<http://www.riken.jp/en>
- 2 Clnatek, Grenoble, France <http://www.clnatec.fr/en/>

Постановка задачи декодирования

Заданы временные ряды $s(t) \in \mathbb{R}^{N_{ch}}$, где N_{ch} – число каналов, и $y(t) \in \mathbb{R}^3$ положений маркера. Ряды преобразуются в матрицы \mathbf{X}, \mathbf{Y} : $\mathbf{X} \in \mathbb{R}^{M \times (TFN_{ch} + C)}$, $\mathbf{Y} = [\mathbf{y}_1^T, \dots, \mathbf{y}_M^T]^T$, $\mathbf{y}_m = y(t_m)$

Объект – t_m , признак – $\mathbf{X}_{(m,:)} =: \mathbf{x}_m$, ответ – \mathbf{y}_m .

Модель декодирования: $\hat{\mathbf{y}}_m = \mathbf{x}_m \hat{\mathbf{w}}$, $\mathbf{w} \in \mathbb{R}^{(TFN_{ch} + C) \times 3}$.

Качество модели оценивается средней корреляцией Пирсона на контрольной выборке \mathcal{C} , \mathcal{L} – обучающая выборка.

$$\text{corr}(\mathbf{y}, \hat{\mathbf{y}}) = \frac{1}{3} \sum_{j=1}^3 \frac{\sum_{i \in \mathcal{C}} (y_i^j - \bar{y}^j) (\hat{y}_i^j - \bar{\hat{y}}^j)}{\sqrt{\sum_{i \in \mathcal{C}} (y_i^j - \bar{y}^j)^2 \sum_{i \in \mathcal{C}} (\hat{y}_i^j - \bar{\hat{y}}^j)^2}}$$

Эмпирический риск:

$$Q(\mathbf{w}) = \frac{1}{|\mathcal{L}|} \sum_{t \in \mathcal{L}} L(\mathbf{x}_m \mathbf{w}, \mathbf{y}_m), L: \mathbb{R}^3 \times \mathbb{R}^3 \rightarrow \mathbb{R}_+,$$

$$\hat{\mathbf{w}} = \arg \min_{\mathbf{w} \in \mathcal{W}} Q(\mathbf{w}).$$

- PLS: $\mathbf{X} = \mathbf{TP}^T + \mathbf{E}$, $\mathbf{Y} = \mathbf{UQ}^T + \mathbf{F}$, где \mathbf{T} , \mathbf{U} – проекции, \mathbf{P} , \mathbf{Q} – ортогональные проецирующие матрицы \mathbf{X} , \mathbf{Y} соответственно, \mathbf{E} , \mathbf{F} – матрицы ошибок
- QPFS: \mathbf{Q} – матрица корреляции признаков, \mathbf{b} – вектор корреляции признаков с вектором ответов. Отбираемые признаки:

$$\mathbf{a} = \underset{\mathbf{a} \in \{0,1\}^{TFN_{ch}+C}}{\operatorname{arg\,min}} (\mathbf{a}^T \mathbf{Q} \mathbf{a} - \mathbf{b}^T \mathbf{a})$$

- LSBoost
- Решающие деревья
- Нейронные сети
- SVM-регрессия

Порождение признакового пространства: \mathbf{x}_m

Базовый набор

Для построения скалограммы по временному ряду $[s_n(t_m - \tau), \dots, s_n(t_m)]$ используется вейвлет-преобразование:

$$[W_\psi s_n](a, t') = \frac{1}{|a|} \sum_{t \in [t_m - \tau, t_m]} \psi \left(\frac{t - t'}{a} \right) s_n(t)$$

где ψ - вейвлет Морле, a - параметр растяжения. $a = f_c \cdot f_s \setminus f_w$, где $f_c = 0.8125$ Гц, f_s - частота дискретизации сигнала, f_w - частота анализируемого сигнала.

Предложим локально-аппроксимирующую модель перемещения зон возбуждения, учитывающую пространственно-временную структуру измерений. (u_j, v_j) – координаты j -ого электрода, $f(u_j, v_j)$ показание напряжения на j -ом электроде в зафиксированный момент времени. Сигнал аппроксимируется гауссианой:


$$f(u, v, \cdot) = D \cdot \exp -\frac{1}{2} \begin{bmatrix} u \\ v \end{bmatrix}^T \begin{bmatrix} a & b \\ b & c \end{bmatrix}^{-1} \begin{bmatrix} u \\ v \end{bmatrix}$$

$$m_1 = \frac{\|\bar{u} \odot \bar{f}\|_1}{\|\bar{f}\|_1}, m_2 = \frac{\|\bar{v} \odot \bar{f}\|_1}{\|\bar{f}\|_1},$$

$$a = \frac{\|(\bar{u} - m_1 \mathbf{1}_{N_{ch}}) \odot \sqrt{\bar{f}}\|_2}{\|\bar{f}\|_1}, c = \frac{\|(\bar{v} - m_2 \mathbf{1}_{N_{ch}}) \odot \sqrt{\bar{f}}\|_2}{\|\bar{f}\|_1},$$

$$b = \frac{\|(\bar{u} - m_1 \mathbf{1}_{N_{ch}}) \odot (\bar{v} - m_2 \mathbf{1}_{N_{ch}}) \odot \bar{f}\|_1}{\|\bar{f}\|_1}.$$

Демонстрация изменения физической активности



Neurotycho, RIKEN Brain Science Institute, Saitama, Japan

Экспериментальная проверка гипотезы о статистической значимости пространственного расположения очага возбуждения

Цели: сравнить

- 1 модели Мотренко (PLS, QPFS)
 - 1 с порождением признаков
 - 2 без порождения признаков
- 2 нейросетевые модели
 - 1 с порождением признаков
 - 2 без порождения признаков

и проанализировать ошибку

Эксперименты длились около 15 минут. Количество объектов \approx 1млн.

Предсказываются трехмерные координаты запястья левой конечности.

Сравнение средних корреляций для моделей PLS&QPFS

Объект	Алгоритмы	Количество компонент			
		10	25	200	500
0525K	PLS	0.254 ± 0.005	0.269 ± 0.01	0.282 ± 0.01	0.32 ± 0.01
	QFPS	0.236 ± 0.017	0.249 ± 0.012	0.28 ± 0.031	0.29 ± 0.05
0527K	PLS	0.414 ± 0.006	0.401 ± 0.006	0.323 ± 0.005	0.24 ± 0.02
	QFPS	0.268 ± 0.006	0.254 ± 0.01	0.247 ± 0.016	0.29 ± 0.018
0602K	PLS	0.585 ± 0.328	0.675 ± 0.167	0.271 ± 0.005	0.265 ± 0.01
	QFPS	0.104 ± 0.015	0.067 ± 0.067	0.126 ± 0.117	0.218 ± 0.121
0116A	PLS	0.174 ± 0.004	0.207 ± 0.003	0.196 ± 0.005	0.164 ± 0.013
	QFPS	0.234 ± 0.002	0.237 ± 0.003	0.247 ± 0.008	0.264 ± 0.014
1127A	PLS	0.348 ± 0.221	0.228 ± 0.011	0.466 ± 0.159	0.111 ± 0.09
	QFPS	0.241 ± 0.005	0.23 ± 0.022	0.294 ± 0.023	0.082 ± 0.06
0121A	PLS	0.108 ± 0.005	0.138 ± 0.003	0.208 ± 0.006	0.19 ± 0.006
	QFPS	0.206 ± 0.009	0.225 ± 0.016	0.247 ± 0.013	0.236 ± 0.006
0611A	PLS	0.246 ± 0.001	0.267 ± 0.003	0.274 ± 0.014	0.238 ± 0.009
	QFPS	0.256 ± 0.001	0.264 ± 0.016	0.292 ± 0.007	0.292 ± 0.006

Результаты вычислительных экспериментов для исходного признакового пространства

Сравнение средних корреляций для моделей PLS&QFPS

Объект	Алгоритмы	Количество компонент			
		10	25	200	500
0525K	PLS	0.26 ± 0.06	0.275 ± 0.01	0.281 ± 0.01	0.32 ± 0.01
	QFPS	-	-	-	-
0527K	PLS	0.42 ± 0.007	0.401 ± 0.004	0.331 ± 0.009	0.237 ± 0.024
	QFPS	-	-	-	-
0602K	PLS	0.226 ± 0.124	0.262 ± 0.145	0.209 ± 0.117	0.138 ± 0.077
	QFPS	-	-	-	-
0116A	PLS	0.004 ± 0.004	0.006 ± 0.004	0.005 ± 0.004	0.005 ± 0.004
	QFPS	-	-	-	-
1127A	PLS	0.341 ± 0.148	0.377 ± 0.001	0.25 ± 0.007	0.205 ± 0.114
	QFPS	-	-	-	-
0121A	PLS	0.091 ± 0.048	0.112 ± 0.05	0.168 ± 0.094	0.154 ± 0.086
	QFPS	-	-	-	-
0611A	PLS	0.01 ± 0.002	0.008 ± 0.003	0.004 ± 0.003	0.005 ± 0.004
	QFPS	-	-	-	-

Результаты вычислительных экспериментов для модифицированного признакового пространства

Эксперименты с нейросетевыми моделями без порождения пространственно-временных параметров


Эксперимент	SVM-p	NN	РД	Isboost
0525K	0.2448 ± 0.0084	0.3171 ± 0.0369	0.1624 ± 0.018	0.2240 ± 0.0132
0527K	0.1335 ± 0.0083	0.2350 ± 0.0401	0.1314 ± 0.0219	0.2023 ± 0.0271
0602K	0.2351 ± 0.1166	0.3176 ± 0.2635	0.1775 ± 0.1353	0.289 ± 0.1822
1224A	0.0819 ± 0.0917	0.1077 ± 0.0792	0.0505 ± 0.0448	0.1021 ± 0.0709
0116A	0.067 ± 0.0373	0.0295 ± 0.0226	0.0226 ± 0.0162	0.0545 ± 0.0246
1127A	0.0985 ± 0.0799	0.0784 ± 0.0243	0.0368 ± 0.03435	0.0595 ± 0.0157
0121A	0.0374 ± 0.0327	0.0607 ± 0.0336	0.0191 ± 0.015	0.0384 ± 0.0195
0611A	0.0331 ± 0.0215	0.0345 ± 0.0236	0.0153 ± 0.0136	0.0215 ± 0.0185

Эксперименты с нейросетевыми моделями с порождением пространственно-временных параметров

data	SVM-p	neural network	РД	Isboost
0525K	0.2425 ± 0.0917	0.3063 ± 0.1963	0.1624 ± 0.1343	0.2400 ± 0.1353
0527K	0.1368 ± 0.0937	0.2313 ± 0.2045	0.1315 ± 0.1478	0.1816 ± 0.1634
0602K	0.2246 ± 0.1340	0.3745 ± 0.2596	0.1749 ± 0.1333	0.3064 ± 0.1593
0116A	0.063 ± 0.019	0.016 ± 0.021	0.025 ± 0.013	0.02 ± 0.011
1127A	0.216 ± 0.004	0.028 ± 0.024	0.019 ± 0.011	0.024 ± 0.026
0121A	0.03 ± 0.037	0.01 ± 0.003	0.022 ± 0.017	0.02 ± 0.023
0611A	0.061 ± 0.032	0.048 ± 0.038	0.02 ± 0.009	0.035 ± 0.018

Учет пространственно-временной структуры и измерений не всегда повышает качество декодирования сигнала

Пример прогнозирования



- Предложена модель декодирования временного ряда, учитывающая пространственно-временную структуру измерений.
- Гипотеза о повышении значимости учета перемещения зон возбуждения моторной коры головного мозга не подтверждена
- Опубликована статья «Построение аппроксимирующего описания скалограммы в задаче прогнозирования движений по электрокортикограмме», JMLDA, 3(2), 160-169, 2017.