

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ
РОССИЙСКОЙ ФЕДЕРАЦИИ
«МОСКОВСКИЙ ФИЗИКО-ТЕХНИЧЕСКИЙ ИНСТИТУТ
(ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ)»
ФИЗТЕХ-ШКОЛА ПРИКЛАДНОЙ МАТЕМАТИКИ И ИНФОРМАТИКИ
ФАКУЛЬТЕТ УПРАВЛЕНИЯ И ПРИКЛАДНОЙ МАТЕМАТИКИ
КАФЕДРА «ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ»

Гасанов Эльнур Эльдар оглы

Порождение пространства признаков в задачах анализа кортикограмм

03.03.01- Прикладные математика и физика

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА
(БАКАЛАВРСКАЯ ДИССЕРТАЦИЯ)

Научный руководитель:
д. ф.-м. н. Стрижов Вадим Викторович

Москва

2018 г.

Содержание

Введение	4
1 Постановка задачи, исходные гипотезы, алгоритмы отбора признаков	6
1.1 Описание задачи, целеполагание	6
1.2 Построение локально аппроксимирующей модели	8
1.3 Метод частичных наименьших квадратов	9
1.4 Отбор признаков по решению задачи квадратичного программирования	10
1.5 Регрессионный бустинг	11
1.6 Дерево принятия решений	12
1.7 SVM-регрессия	13
1.8 Нейронная сеть	14
2 Вычислительные эксперименты	15
2.1 Модели PLS и QPFS.	16
2.2 Нейросетевые модели	18
3 Выводы	19
Список литературы	20

Аннотация

Рассмотрена задача декодирования временного ряда физической активности по электрокортикограмме (ECoG). Используются алгоритмы частных наименьших квадратов (PLS) и метод отбора признаков по решению задачи квадратичной оптимизации (QPFS). Проверена гипотеза о статистической значимости учета перемещения зон возбуждения моторной коры головного мозга. В качестве выборки использованы открытые данные лаборатории адаптивного интеллекта BSI RIKEN.

Ключевые слова: *декодирование временного ряда, электрокортикограмма, ECoG, метод частных наименьших квадратов, QPFS.*

Введение

Актуальность темы. Задача декодирования временного ряда физической активности по сигналам, снятым с коры головного мозга, играет центральную роль при конструировании искусственных конечностей: от качества решения задачи зависит применимость устройства в реальных условиях.

Цель работы. Предложить локально аппроксимирующую модель перемещения зон возбуждения на поверхности коры головного мозга, учитывая пространственно-временную структуру измерений.

Методы исследований. При построении алгоритма использовались элементы теории вероятности и математической статистики, методы преобразования сигналов. Для программной реализации разработанного алгоритма использовались среды MATLAB и Python 3.6.

Научная новизна. В задаче декодирования учтена информация про пространственное перемещение очагов возбуждения.

Практическая ценность. Доработан программный модуль, который

- по выборке строит модель декодирования временного ряда физической активности;
- визуализирует результаты.

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

НКИ может быть реализован несколькими способами. EEG сигналы обеспечивают интерфейс без проведения операции, дешевле во внедрении [6]. Однако EEG сиг-

налы имеют узкую ширину полосы частот, т.к. некоторые сигналы головного мозга поглощаются тканями человека (кровью, кожей и т.д.) [7]. Настройка НКИ на EEG сигналах требует много времени, такие НКИ обладают плохой пространственной локализацией [8], т.к. электроды удалены от коры головного мозга, где происходит активность. Инвазивный метод регистрации отдельных нейронов (SUA, single-unity active) позволяет получить высокоточные значения потенциалов электродов, однако НКИ, базирующиеся на SUA, требуют частой перекалибровки в виду постоянного ухудшения снимаемого сигнала [9]. НКИ на электрокортикограммах (ECoG) [10] лишены этих недостатков: в задачах декодировки движений обезьяны НКИ могут успешно применяться через несколько месяцев после настройки без серьезных ухудшений качества прогнозирования [11]. ECoG сигналы обладают существенно более широкой полосой частот, нежели EEG [7].

В предлагаемом решении задачи декодирования временного сигнала признаки можно поделить на две группы. Первая группа состоит из скалограмм, построенных для каждого электрода с помощью вейвлет-преобразования с вейвлетом Морле [13]. Скалограмма - двумерный массив признаков в пространстве частота-время. Вторая группа признаков описывает пространственные параметры перемещения очага возбуждения (эпицентр возбуждения, его направление, дисперсию сигнала).

Основные алгоритмы, используемые для построения модели декодирования, есть методы наименьших частных квадратов (PLS) [19] и метод отбора признаков по решению задачи квадратичного программирования (QPFS) [20]. В работе [20] представлена сводная информация по качеству решения обсуждаемой задачи алгоритмами PLS и QPFS над пространством скалограмм.

В работе использованы открытые данные лаборатории адаптивного интеллекта BSI RIKEN [18].

1 Постановка задачи, исходные гипотезы, алгоритмы отбора признаков

1.1 Описание задачи, целеполагание

Заданы временные ряды напряжений электродов, расположенных на коре головного мозга, $s(t) \in \mathbb{R}^{N_{ch}}$, где N_{ch} - число каналов, и временные ряды $y(t) \in \mathbb{R}^3$ положений конечности объекта в трехмерном пространстве. Указанные временные ряды преобразуются в пару матриц (\mathbf{X}, \mathbf{Y}) :

$$\mathbf{X} \in \mathbb{R}^{M \times (TFN_{ch} + C)}, \quad \mathbf{Y} = [\mathbf{y}_1^\top, \dots, \mathbf{y}_M^\top]^\top,$$

таких что $\mathbf{y}_m = y(t_m)$. Здесь T и F - количество временных промежутков и частот, использованных при построении скалограммы, по сути являются параметрами алгоритма построения скалограммы. M есть суммарное количество отсчетов времени. В задаче объект - отсчет времени t_m , признак - строка матрицы $\mathbf{X} =: \mathbf{x}_m$, ответ - \mathbf{y}_m . Каждый вектор \mathbf{x}_m представляет собой последовательно расположенные друг за другом векторизованные скалограммы - частотно-временные описания временного ряда $[s_n(t_m - \tau), \dots, s_n(t_m)]$, построенные для разных электродов n , $n = 1, \dots, N_{ch}$. В конце вектора \mathbf{x}_m располагается C чисел - параметры аппроксимирующей модели, характеризующего пространственную структуру сигнала (см. подраздел «Построение локально аппроксимирующей модели»). В данной работе сигнал аппроксимируется гауссианой.

Задача состоит в определении положения маркера \mathbf{Y} при заданном \mathbf{x}_m , $m = 1, \dots, M$. Предлагается решить задачу декодирования временного ряда с помощью линейной регрессии:

$$\hat{\mathbf{y}}_m = \mathbf{x}_m \hat{\mathbf{w}},$$

где $\mathbf{w} \in \mathbb{R}^{(TFN_{ch} + C) \times 3}$.

Через \mathcal{L} обозначим множество всех отчетов времени обучающей выборки, через \mathcal{C} - контрольной выборки.

Пусть задана функция потерь $L : \mathbb{R}^3 \times \mathbb{R}^3 \rightarrow \mathbb{R}_+$. Определим эмпирический риск алгоритма:

$$\mathcal{Q}(\mathbf{w}) = \frac{1}{|\mathcal{L}|} \sum_{t \in \mathcal{L}} L(\mathbf{x}_m \mathbf{w}, \mathbf{y}_m).$$

Параметр $\hat{\mathbf{w}}$ линейной регрессии минимизирует эмпирический риск:

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

Здесь \mathcal{W} пространство отобранных признаков. Для моделей LS_Boost, решающие деревья, SVM-регрессия и нейронные сети \mathcal{W} совпадает с исходным пространством признаков. При решении задачи методом отбора признаков по решению задачи квадратичного программирования или методом наименьших частичных квадратов упомянутое пространство признаков сужается.

Для оценки качества построенных моделей используется средняя корреляция Пирсона на контрольной выборке \mathcal{C}

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

1.2 Построение локально аппроксимирующей модели

Вектор \mathbf{x}_m , представляющий собой описание i -ого объекта, состоит из двух частей. Первая часть есть векторизованная скалограмма, построенная для момента времени t_i . Вторая часть содержит информацию о пространственных характеристиках сигнала (координатах очага возбуждения, скорости перемещения очага, дисперсию сигнала).

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

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

где ψ - вейвлет Морле, a - параметр растяжения. Параметр растяжения имеет прямую связь с частотой анализируемого сигнала f_w :

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

где $f_c = 0.8125$ Гц - центральная частота для вейвлета Морле, f_s - частота дискретизации сигнала.

Зафиксируем произвольный момент времени t_i . Пусть (x_1^j, x_2^j) - координаты j -ого электрода, $f(x_1^j, x_2^j)$ показание напряжения на j -ом электроде в зафиксированный момент времени. Сигнал предлагается аппроксимировать функцией Гаусса.

$$f(\bar{x}, D, a, b, c, m_1, m_2) = D \cdot e^{-\frac{c(x_1 - m_1)^2 - 2b(x_1 - m_1)(x_2 - m_2) + a(x_2 - m_2)^2}{2(ac - b^2)}}$$

Параметры m_1, m_2, a, b, c модели определяются по формулам:

$$m_1 = \frac{\sum_j x_1^j \cdot f(x_1^j, x_2^j)}{\sum_j f(x_1^j, x_2^j)}; m_2 = \frac{\sum_j x_2^j \cdot f(x_1^j, x_2^j)}{\sum_j f(x_1^j, x_2^j)};$$

$$a = \frac{\sum_j (x_1^j - m_1)^2 \cdot f(x_1^j, x_2^j)}{\sum_j f(x_1^j, x_2^j)}; c = \frac{\sum_j (x_2^j - m_2)^2 \cdot f(x_1^j, x_2^j)}{\sum_j f(x_1^j, x_2^j)};$$

$$b = \frac{\sum_j (x_1^j - m_1)(x_2^j - m_2) \cdot f(x_1^j, x_2^j)}{\sum_j f(x_1^j, x_2^j)};$$

Для оценки параметра масштаба D медианное значение вектора показаний напряжений делится на $e^{-\frac{c(x_1 - m_1)^2 - 2b(x_1 - m_1)(x_2 - m_2) + a(x_2 - m_2)^2}{2(ac - b^2)}}$, где x_1, x_2 - координаты электрода, показание напряжения которого есть медианное.

1.3 Метод частичных наименьших квадратов

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

Основная идея метода PLS (partial least squares) 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:

$$\mathbf{X} = \mathbf{TP}^T + \mathbf{E}$$

$$\mathbf{Y} = \mathbf{UQ}^T + \mathbf{F}$$

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

1.4 Отбор признаков по решению задачи квадратичного программирования

Пусть матрица $Q \in \mathbb{R}^{(TFN_{ch}+C) \times (TFN_{ch}+C)}$, вектор $b \in \mathbb{R}^{TFN_{ch}+C}$. Проблема отбора признаков может быть сформулирована как задача квадратичного программирования (quadratic programming feature selection, QPFS):

$$\mathbf{a} = \arg \min_{\mathbf{a} \in \{0,1\}^N} (\mathbf{a}^\top \mathbf{Q} \mathbf{a} - \mathbf{b}^\top \mathbf{a}),$$

где q_{ij} указывает на степень скоррелированности признаков i и j :

$$q_{ij} = |\text{corr}(\chi_i, \chi_j)|$$

Аналогично, b_i указывает на степень релевантности признака i и считается следующим образом:

$$b_i = \frac{1}{3} \sum_{j=1}^3 |\text{corr}(\chi_i, \mathbf{y}^j)|.$$

Указанная выше задача ищет равновесие между скоррелированностью признаков и их важностью в задаче определения положения маркера. Решение оптимизационной задачи определяет, какие признаки должны учитываться в конечном алгоритме.

1.5 Регрессионный бустинг

Пусть задано множество объектов и ответов $\{\mathbf{x}_i, y_i\}_{i=1}^N$, и требуется определить оптимальную композицию $F(\mathbf{x}) = \sum_{j=1}^M \rho_j h(\mathbf{x}, \mathbf{a}_j)$ для решения задачи восстановления регрессии, где $\rho_j \in \mathbb{R}$ определяется вес j -ого алгоритма, задаваемого некоторым параметром \mathbf{a}_j . Пошаговый подход к решению данной задачи с использованием квадратичной функции потерь определяет алгоритм LS_Boost.

```
1  $F_0(\mathbf{x}) = \bar{y}$ 
2 for  $m := 1$  to  $M$  do
3    $\tilde{y}_i = y_i - F_{m-1}(x_i), i = 1, N$ 
4    $(\rho_m, \mathbf{a}_m) = \arg \min_{\rho, \mathbf{a}} \sum_{i=1}^N [\tilde{y}_i - \rho h(\mathbf{x}_i, \mathbf{a})]^2$ 
5    $F_m(\mathbf{x}) = F_{m-1}(\mathbf{x}) + \rho_m h(\mathbf{x}, \mathbf{a})$ 
6 end
```

Algorithm 1: LS_Boost

1.6 Дерево принятия решений

Дерево принятия решений для задачи восстановления регрессии использует в качестве меры неопределенности множества объектов \mathbf{U} функцию

$$\Phi(\mathbf{U}) = \min_{y \in Y} \frac{1}{|\mathbf{U}|} \sum_{x_i \in \mathbf{U}} (y - y_i)^2$$

Значения в терминальных вершинах суть МНК-решение:

$$y_v = \frac{1}{|\mathbf{U}|} \sum_{x_i \in \mathbf{U}} y_i \quad (*)$$

При обучении дерева алгоритм принимает решение о необходимости дальнейшего ветвления на основании значения функции $\text{Gain}(f, \mathbf{U})$, f обозначает признак, по которому предлагается ветвить дерево, D_v есть множество возможных значений признака f , $\mathbf{U}_k = \{x \in U \mid f(x) = k\}$:

$$\text{Gain}(f, \mathbf{U}) = \Phi(\mathbf{U}) - \sum_{k \in D_v} \frac{|\mathbf{U}_k|}{|\mathbf{U}|} \Phi(\mathbf{U}_k)$$

Рекурсивный алгоритм обучения устроен следующим образом:

```
1 Функция TreeGrowing( $\mathbf{U}$ )  $\mapsto$  корень дерева  $v$ 
2 if выполнен критерий остановки then
3   | вернуть новый лист, взяв  $y_v$  по формуле (*)
4 end
5 найти признак наиболее выгодный для ветвления:  $f_v = \arg \max_f \text{Gain}(f, \mathbf{U})$ 
6 if  $\text{Gain}(f, \mathbf{U}) < G_0$  then
7   | вернуть новый лист, взяв  $y_v$  по формуле (*)
8 end
9 создать внутреннюю вершину  $v$  с функцией  $f_v$ 
10 for  $k \in D_v$  do
11   |  $\mathbf{U}_k := \{x \in U \mid f(x) = k\}$ 
12   |  $S_v(k) = \text{TreeGrowing}(\mathbf{U}_k)$ 
13 end
14 return  $v$ 
```

Algorithm 2: Обучение решающего дерева

1.7 SVM-регрессия

Введём функцию потерь:

$$L'(y(x) - t) = \begin{cases} 0 & |y(x) - t| < \varepsilon \\ |y(x) - t| - \varepsilon & \text{иначе} \end{cases}$$

Регрессия, восстановленная методом опорных векторов, есть решение задачи минимизации функции:

$$C \sum_{i=1}^N L(y(x_i) - y_i) + \frac{1}{2} \|w\|^2$$

1.8 Нейронная сеть

На рис. 1 представлена схема двухслойной нейронной сети: на вход подаются величины x_1, \dots, x_D , на выходе y_1, \dots, y_K .

Пусть

$$a_j = \sum_{i=1}^D w_{ji}^{(1)} x_i + w_{j0}^{(1)}$$

Пусть определена нелинейная функция активации $h : \mathbb{R} \rightarrow \mathbb{R}$. Тогда $z_j = h(a_j)$.

Значения выходных маркеров определяются по формуле:

$$y_k = \sum_{j=1}^M w_{kj}^{(2)} z_j + w_{k0}^{(2)}.$$




Рис. 1: Схема двухслойной нейронной сети.

Источник: Bishop, Machine Learning and Pattern Recognition, 2006

2 Вычислительные эксперименты

Данные были взяты с сайта лаборатории BSI RIKEN (Япония) [18]. Проводились эксперименты над обезьянами (обезьяны А и К), на коре головного мозга каждой были установлены датчики, считывающие напряжение в конкретной точке (см. 2 и 3). Данные считывались с частотой 1КГц. Также на левом запястье каждого объекта был установлен датчик, определяющий положение запястья с течение времени. Эксперименты длились порядка четверти часа.

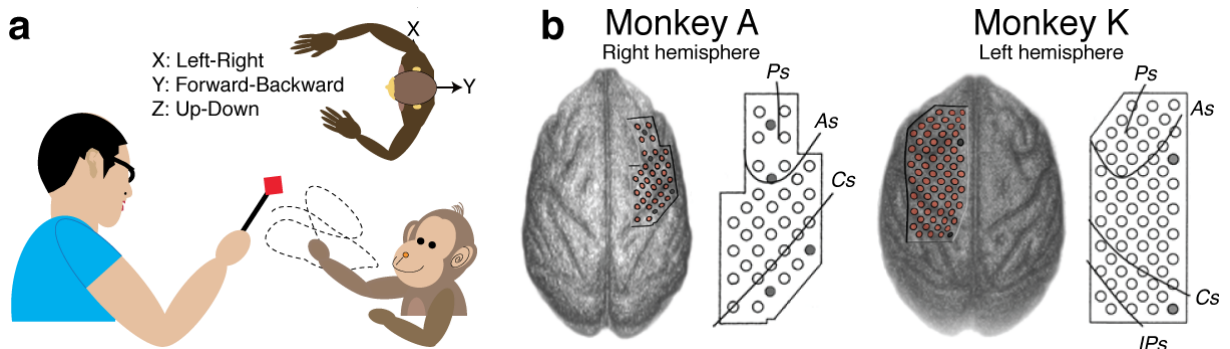


Рис. 2: Схемы экспериментов и расположения электродов на коре головного мозга испытуемых [11].

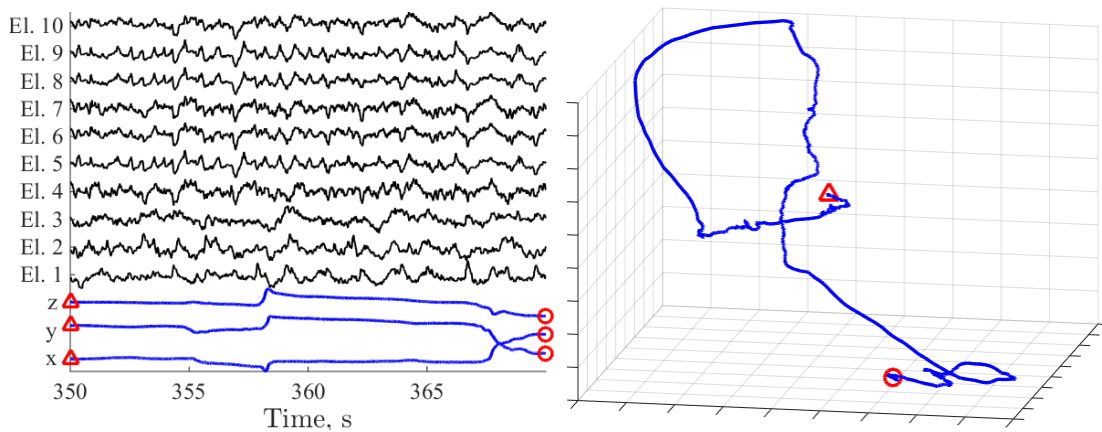


Рис. 3: Пример временных рядов напряжений, считываемых с первых 10 датчиков, и изменения положения датчика на запястье с течением времени [20]

2.1 Модели PLS и QPFS.

Алгоритмы PLS и QPFS были протестированы на вышеуказанных данных. Обучение велось на промежутке времени от 5 до 650 секунды эксперимента, время от 650 до 950 секунды было выделено для тестов. В таблице ниже указаны средние корреляции со стандартным отклонением моделей на холд-аут выборке для исходного (векторизованный набор скалограмм для каждого отсчета времени) и модифицированного (дополнение исходного пространства пространственно-временным описание сигнала) признаков пространств. Обучение проводилось пять раз, как при кросс-валидации, однако тестирование проводилось на холд-аут выборке. Значение корреляций усредняется. Алгоритм QPFS работал нестабильно в модифицированном признаковом пространстве.

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
	QPFS	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
	QPFS	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
	QPFS	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
	QPFS	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
	QPFS	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
	QPFS	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
	QPFS	0.256 ± 0.001	0.264 ± 0.016	0.292 ± 0.007	0.292 ± 0.006

Таблица 1: Результаты вычислительных экспериментов для исходного признакового пространства

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	-	-	-	-

Таблица 2: Результаты вычислительных экспериментов для модифицированного признакового пространства

2.2 Нейросетевые модели

Аналогичные эксперименты были проделаны для моделей SVM-регрессия, нейронная сеть, решающие деревья и регрессионный бустинг. Обучение проводилось один раз на обучающей выборке. Результаты экспериментов для исходного и модифицированного признаковых пространств приведены в таблицах ниже.

data	SVM-p	neural network	РД	lsboost
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 ± 0.18223
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

Таблица 3: Результаты вычислительных экспериментов на нейросетевых моделях при использовании исходного признакового пространства.

data	SVM-p	neural network	РД	lsboost
0525K	0.2425 ± 0.0917	0.3063 ± 0.1963	0.1624 ± 0.1343	0.2400 ± 0.1353
0525K	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

Таблица 4: Результаты вычислительных экспериментов на нейросетевых моделях при использовании модифицированного признакового пространства.

3 Выводы

В работе предложена модель декодирования временного ряда, учитывающая пространственно - временную структуру измерений. Были проведены эксперименты для 6 различных алгоритмов, создано программное обеспечение для декодирования временного ряда физической активности по электрокортикограмме. Гипотеза о значимом повышении качества декодирования при учете перемещения зон возбуждения моторной коры головного мозга не подтвердилась.

Список литературы

- [1] Mikhail A. Lebedev, Miguel A.L. Nicolelis. Brainmachine interfaces: past, present and future// Trends in Neurosciences, Vol.29
- [2] Schalk et al. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System// IEEE Transactions on biomedical engineering, vol. 51, no. 6. 2004
- [3] 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), 2015
- [4] Schalk et al. Two-dimensional movement control using electrocorticographic signals in humans// Journal of neural engineering, 5, 2008
- [5] J. d. R. Millan et al. Combining Brain Computer Interfaces and Assistive Technologies: State-of-the-Art and Challenges // Frontiers in neuroscience, vol. 4, 2010.
- [6] S.G. Mason, A. Bashashati, M. Fatourehchi, K.F. Navarro, G.E. Birch. A comprehensive survey of brain interface technology designs // Annals of biomedical engineering, vol. 35, no. 2, 2007
- [7] J. Adam Wilson, Elizabeth A. Felton, P. Charles Garell, Gerwin Schalk, and Justin C. Williams. ECoG Factors Underlying Multimodal Control of a Brain Computer Interface // IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 14, no. 2, 2006
- [8] W. J. Freeman, M. D. Holmes, B. C. Burke, and S. Vanhatalo. Spatial spectra of scalp EEG and EMG from awake humans // Clin. Neurophysiol., vol. 114, 2003
- [9] Chestek C.A et al. Singloneuron stability during repeated reaching in macaque premotor cortex // Journal of Neuroscience, 27, 2007
- [10] E.C. Leuthardt, G. Schalk, J.R. Wolpaw, J.G. Ojemann, D.W. Moran. A brain-computer interface using electrocorticographic signals in humans // Journal of neural engineering, vol. 1, no. 2, 2004
- [11] Zenas C. Chao, Yasuo Nagasaka and Naotaka Fujii. Long-term asynchronous decoding of arm motion using electrocorticographic signals in monkeys // Frontiers in neuroengineering, vol.3, 2010

- [12] Laura Dipietro, Angelo M. Sabatini, Paolo Dario. A Survey of Glove-Based Systems and Their Applications // IEEE Transactions on systems, man, and cybernetics-Part C: applications and reviews, vol. 38, no. 4. 2008
- [13] Марпл С.Л. Цифровой спектральный анализ и его приложения, 1990
- [14] J. Kubanek, K. J. Miller, J. G. Ojemann, J. R. Wolpaw, G. Schalk Decoding flexion of individual fingers using electrocorticographic signals in humans // Journal of Neural Engineering, vol.6, 2009
- [15] Карасиков М.Е., Стрижов В.В. Классификация временных рядов в пространстве параметров порождающих моделей // Информатика и ее применения, 2016
- [16] Кузнецов М.П., Ивкин Н.П. Алгоритм классификации временных рядов акселерометра по комбинированному признаковому описанию // Машинное обучение и анализ данных. 2015. Т. 1, no. 11
- [17] de Jong, S. SIMPLS: An alternative approach to partial least squares regression // Chemometrics and Intelligent Laboratory Systems, vol. 18, no. 3
- [18] "<http://neurotycho.org/expdatalist/listview?from=&to=&task=36&monkey=All&author=All>"
- [19] Wold S., Sjöström M., Eriksson L. PLS-regression: a basic tool of chemometrics // Chemometrics and Intelligent Laboratory Systems. 58 (2), 2001
- [20] Motrenko A., Strijov V. Multi-way Feature Selection for ECoG-based Brain-Computer Interface //