

Федеральное государственное автономное образовательное учреждение
высшего образования
«Московский физико-технический институт (государственный университет)»
Физтех-школа прикладной математики и информатики
Кафедра интеллектуального анализа данных

Направление подготовки: 03.03.01 Прикладные математика и физика

Направленность (профиль) подготовки: Интеллектуальный анализ данных

Локальные модели в задаче декодирования сигнала головного мозга
(бакалаврская диссертация)

Студент:

Маркин Валерий Олегович

(подпись студента)

Научный руководитель:

Стрижов Вадим Викторович,

д. ф.-м. н.

(подпись научного руководителя)

Москва 2020

Оглавление

1	Введение	4
2	Постановка задачи	6
2.1	Описание сигналов электрокортикограммы	6
2.2	Локальные модели	7
2.3	Решение задачи декодирования	7
2.4	Критерии качества	8
2.4.1	Критерии качества точечной локальной модели	8
2.4.2	Критерии качества декодирования	9
3	Описание используемых методов	10
3.1	Интервальные локальные модели	10
3.1.1	Преобразование Фурье	10
3.1.2	Вейвлет-преобразование	10
3.2	Точечные локальные модели	11
3.2.1	Модель на основе функции Гаусса	11
3.2.2	Модель на основе функций радиального базиса	11
3.3	PLS	12
4	Вычислительный эксперимент	13
4.1	Предобработка данных	13
4.2	Проверка основной гипотезы	13
4.3	Результаты эксперимента	14
5	Заключение	18

Аннотация

В работе рассматривается задача построения оптимального признакового описания в задаче декодирования сигналов. Рассматриваются электрические сигналы в коре головного мозга, записанные при помощи электрокортикографии (ECoG). Исходное признаковое пространство избыточно, модель прогнозирования оказывается неустойчивой. Для решения данной проблемы предлагается построить локальную модель сигнала. Локальная модель аппроксимирует сигнал и строит новое признаковое описание, которое учитывает пространственные зависимости в сигнале. Это позволяет существенно снизить размерность признакового пространства и учесть пространственную структуру сигнала. В работе приведены результаты численных экспериментов на данных электрокортикограмм головного мозга обезьян. Проводится сравнение различных методов отбора признаков и гипотез порождения данных

Ключевые слова: *Локальные модели, отбор признаков, нейрокомпьютерный интерфейс*

Глава 1

Введение

Нейрокомпьютерный интерфейс (BCI) считывает сигналы нейронов головного мозга и декодирует их в команды исполняющей системы. Исследования в данной области позволяют восстанавливать дееспособность людей с нарушениями двигательных функций организма. Примером такой системы является система управления роботизированным протезом посредством мозговых импульсов.

Мозговая активность представляет собой совокупность электрических импульсов различной амплитуды и частоты, возникающих в коре головного мозга. Электроды, закрепленные в коре, позволяют считывать сигналы для их дальнейшего декодирования алгоритмами нейрокомпьютерного интерфейса. В работе предполагается, что траектория движения кисти определяется перемещением зоны активности по поверхности моторной зоны коры головного мозга.

Метод решения задачи состоит в извлечении информативных признаков из частотных и временных характеристик сигнала [6, 1]. В работах [2, 3, 5] исследуют частотные характеристики. Для снижения размерности, после построения признакового описания, используются алгоритмы PLS [9, 4, 3], PCA [12, 10]. В работе [13] используются алгоритмы, построенные на скрытых марковских моделях. В [5, 10] рассматривают различные участки сигнала в виде слов. В работе [7] задача отбора признаков сводится к задаче квадратичного программирования (Quadratic Programming Feature Selection [8]). Для решения задачи используются нейросетевые модели [11]. В этой работе для извлечения признаков используются сверточная нейронная сеть, а для предсказания — сеть LSTM.

В данной работе проверяется гипотеза о связи траектории кисти с движением волнового фронта по поверхности мозга. Для этого предлагается построить локальную аппроксимацию сигнала, которая учитывает расположение электродов в пространстве. Параметры полученной локальной модели используются в качестве нового признакового описания.

Данный подход позволяет снизить размерность пространства признаков и повысить качество предсказания.

В вычислительном эксперименте используются данные электрокортикограмм обезьян с сайта neurotycho.org.

Глава 2

Постановка задачи

2.1 Описание сигналов электрокортикограммы

Введем основные понятия, связанные с временными рядами и их анализом.

Определение 2.1.1. *Временной ряд* — это набор значений некоторой величины $\mathbf{x}_t \in \mathbb{R}^n$ в конкретный момент времени $t \in T$, где T — множество моментов наблюдений.

Временные ряды разделяют на многомерные ($n > 1$) и одномерные ($n = 1$). Многомерные временные ряды можно рассматривать как набор одномерных, что позволяет легко обобщить методы анализа одномерных рядов на многомерный случай. Задана выборка $\mathcal{D} = (\mathbf{x}(t) \in \mathbb{R}^{n_{el}}, \mathbf{y} \in \mathbb{R}^3)$, где $\mathbf{x}(t)$ — записи электрических импульсов с электродов, закрепленных в коре головного мозга пациента, а $\mathbf{y}(t)$ — траектория движения кисти в пространстве. Ряды $\mathbf{x}(t)$ и $\mathbf{y}(t)$ синхронизированы во времени. Дополнительно известна матрица $\mathbf{Z} \in \mathbb{R}^{n_{el} \times 2}$ — координаты всех электродов в плоскости коры мозга. Требуется построить модель, восстанавливающую зависимость между $\mathbf{x}(t)$ и $\mathbf{y}(t)$.




Рис. 2.1: Координаты движения руки




Рис. 2.2: Расположение электродов на коре мозга

2.2 Локальные модели

Определение 2.2.1. Локальной моделью \mathbf{g} временного ряда $\mathbf{x}(t)$ называется параметрическое или непараметрическое отображение интервала $[t - \Delta t, t]$ (частным случаем является поэлементное отображение при $\Delta t = 0$), аппроксимирующее исходный временной ряд

$$\mathbf{g} : \mathbf{x}[t - \Delta t, t] \longrightarrow \hat{\mathbf{x}}[t - \Delta t, t]. \quad (2.1)$$

Модель \mathbf{g} имеет параметры γ , наилучшие значения которых находятся решением оптимизационной задачи

$$\gamma^* = \arg \min_{\gamma} \|\mathbf{x} - \hat{\mathbf{x}}\|_2. \quad (2.2)$$

Определение 2.2.2. Метод локальной аппроксимации строит признаковое описание φ момента времени t на основе решения задачи аппроксимации 2.2

$$\varphi = \varphi(\mathbf{g}, \gamma^*, \mathbf{x}).$$

Приведем несколько примеров локальных моделей:

1. Среднее значение (как по времени так и по компонентам вектора в данной точке)
2. Авторегрессия
3. Преобразование Фурье

Локальные модели, используемые в данной задаче, можно разделить на интервальные, в которых $\Delta t > 0$ и точечные ($\Delta t = 0$). В данной задаче точечные модели используются для учета пространственных зависимостей в сигнале, а интервальные позволяют хранить информацию о предыстории сигнала в конкретный момент времени, что и позволяет строить адекватное предсказание

2.3 Решение задачи декодирования

Пусть задана выборка $\mathcal{D} = (\mathbf{X} \in \mathbb{R}^{T \times n_{el}}, \mathbf{y} \in \mathbb{R}^{T \times 3})$, где \mathbf{X} - матрица объектов многомерного временного ряда (амплитуды сигналов на каждом из электродов) а \mathbf{y} — матрица ответов (координаты кисти в пространстве). Также дополнительно известна матрица $\mathbf{Z} \in \mathbb{R}^{n_{el} \times 2}$ — координаты всех электродов на плоскости.

Предполагается существование регрессионной зависимости между \mathbf{X} и \mathbf{y} следующего вида:

$$\mathbf{y} = \mathbf{W}^T \Theta + \epsilon, \quad (2.3)$$

$$\Theta = F(\mathbf{X}, \mathbf{Z}). \quad (2.4)$$

Где функция F — есть нелинейная функция. Предлагается искать функцию F в виде суперпозиции двух локальных моделей: интервальной, учитывающей временную структуру сигнала, и точечной, учитывающей пространственные свойства данных. Порядок применения локальных моделей может быть любым. Это означает, что возможно использовать точечную модель как до интервальной, так и после. Полную схему решения задачи можно увидеть на диаграммах:

$$\begin{array}{ccccccc} \mathbf{X}_{T \times n} & \xrightarrow[\text{model}]{\text{pointwise}} & \mathbf{\Gamma}_{T \times n'} & \xrightarrow[\text{model}]{\text{interval}} & \mathbf{\Theta}_{T \times n' \times N_f} & \xrightarrow{\text{reshape}} & \mathbf{\Theta}_{T \times n' \cdot N_f} \xrightarrow{\text{PLS}} \mathbf{Y}_{T \times 3}, \\ \mathbf{X}_{T \times n} & \xrightarrow[\text{model}]{\text{interval}} & \hat{\mathbf{X}}_{T \times n \times N_f} & \xrightarrow[\text{model}]{\text{pointwise}} & \mathbf{\Gamma}_{T \times n' \times N_f T} & \xrightarrow{\text{reshape}} & \mathbf{\Theta}_{T \times n' \cdot N_f} \xrightarrow{\text{PLS}} \mathbf{Y}_{T \times 3}. \end{array}$$

2.4 Критерии качества

2.4.1 Критерии качества точечной локальной модели

Основной показатель качества точечной локальной модели — способность с хорошей точностью аппроксимировать сигнал во всей исследуемой области пространства. Коэффициент корреляции между двумя временными рядами:

$$r(s(t), \hat{s}(t)) = \frac{1}{T} \sum_{j=1}^T \frac{(s(t_j) - \mu_s)(\hat{s}(t_j) - \mu_{\hat{s}})}{\sigma_s \sigma_{\hat{s}}}, \quad (2.5)$$

где

$$\mu_s = \frac{1}{T} \sum_{j=1}^T s, \quad \sigma_s^2 = \frac{1}{T-1} \sum_{j=1}^T T (s - \mu_s)^2$$

В исследуемой задаче каждому из электродов на записывающей пластинке соответствует некий временной ряд. Он может быть одномерным(исходные данные) или многомерным(данные после применения интервальной локальной модели). Для электрода с номером j и соответствующего ему временного ряда $\mathbf{x}_j(t) \in \mathbb{R}^{N_f}$ и его аппроксимации

$\hat{\mathbf{x}}_j(t) \in \mathbb{R}^{N_f}$ определим:

$$\rho_j(\mathbf{x}_j(t), \hat{\mathbf{x}}_j(t)) = \frac{1}{N_f} \sum_{i=1}^{N_f} N_f r(x_j^i(t), \hat{x}_j^i(t)) \quad (2.6)$$

Эта величина описывает, насколько хорошо локальная модель аппроксимирует сигнал в данной точке пространства. Так же введем

$$M_p = \frac{1}{N_{el}} \sum_{j=1}^{N_{el}} [\rho_j(\mathbf{x}_j(t), \hat{\mathbf{x}}_j(t)) \geq p],$$

где p — эмпирический порог качества аппроксимации. M_p — доля электродов, на которых модель дает качество аппроксимации не меньше p

2.4.2 Критерии качества декодирования

Целевая переменная в задаче - трехмерный временной ряд координаты кисти в пространстве $\mathbf{y}(t) \in \mathbb{R}^3$. Прогноз модели $\hat{\mathbf{y}}(t) \in \mathbb{R}^3$. Определим:

$$\text{MSE}(\mathbf{y}(t), \hat{\mathbf{y}}(t)) = \frac{1}{T} \sum_{i=1}^T \|\mathbf{y}(t_i) - \hat{\mathbf{y}}(t_i)\|_2^2$$

$$\text{sMSE}(\mathbf{y}(t), \hat{\mathbf{y}}(t)) = \frac{\text{MSE}(\mathbf{y}(t), \hat{\mathbf{y}}(t))}{\text{MSE}(\mathbf{y}(t), \bar{\mathbf{y}}(t))}$$

где $\bar{\mathbf{y}}(t)$ — среднее значение ряда $\mathbf{y}(t)$ во времени. Коэффициент sMSE показывает, как сильно прогноз модели отличается от простейшего прогноза.

Другой способ оценки качества прогноза - коэффициент корреляции Пирсона $r(y_k(t), \hat{y}_k(t))$ (формула 2.5, усредненный по трем компонентам $\mathbf{y}(t)$).

Глава 3

Описание используемых методов

3.1 Интервальные локальные модели

3.1.1 Преобразование Фурье

Фурье-преобразование временного ряда:

$$X_k = \sum_{n=0}^{N-1} x(t_n) e^{-\frac{2\pi i}{N} kn}$$

Выбирается некоторая ширина окна Δt и набор частот ω_i (в вычислительных экспериментах используются частоты 20 – 120Hz и с шагом 5). Для ряда $x[t - \Delta, t]$ вычисляются значения Фурье-образов X_k , которые и будут новыми признаками для данного момента времени.

3.1.2 Вейвлет-преобразование

Вейвлет преобразование представляет собой свертку исследуемой функции с особой вейвлет-функцией.

$$\phi(\tau, s) = \int_{-\infty}^{+\infty} x(t) \frac{1}{\sqrt{s}} \gamma^* \left(\frac{t - \tau}{s} \right) dt,$$

где τ и s — параметры переноса и размаха соответственно.

Вейвлет функция типа "Morlet" имеет следующий вид:

$$\gamma_\sigma(t) = c_\sigma \pi^{-\frac{1}{4}} e^{-\frac{1}{2}t^2} (e^{i\sigma t} - \kappa_\sigma),$$

где κ_σ из условия равенства нулю интеграла от вейвлета определяется как $\kappa_\sigma = e^{-\frac{1}{2}\sigma^2}$ и c_σ определяется из условия нормировки $c_\sigma = \left(1 + e^{-\sigma^2} - 2e^{-\frac{3}{4}\sigma^2}\right)^{-\frac{1}{2}}$

В случае дискретных наборов $\{\tau_1 \dots \tau_N\}, \{s_1 \dots s_M\}$:

$$\phi_{mn} = \int_{-\infty}^{+\infty} x(t) \frac{1}{\sqrt{s_m}} \gamma^* \left(\frac{t - \tau_n}{s_m} \right) dt,$$

3.2 Точечные локальные модели

3.2.1 Модель на основе функции Гаусса

Заданы координаты каждого электрода на плоскости $\mathbf{Z} = \{(\mathbf{z}_j \in \mathbb{R}^2, j \in \{1 \dots, N_{ch}\})\}$.

Локальная модель

$$g(\boldsymbol{\xi}, A, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = A \exp \left(-\frac{1}{2} (\boldsymbol{\xi} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\boldsymbol{\xi} - \boldsymbol{\mu}) \right).$$

Решением оптимизационной задачи $\sum_{i=1}^{N_{ch}} \|\mathbf{x}_i - g(\mathbf{z}_j, A, \boldsymbol{\mu}, \boldsymbol{\Sigma})\|_2 \longrightarrow \min_{\gamma=[A, \boldsymbol{\mu}, \boldsymbol{\Sigma}]}$ будет

$$\boldsymbol{\mu} = \frac{\sum_{j=1}^n \mathbf{x}_j \mathbf{z}_j}{\sum_{j=1}^n \mathbf{x}_j},$$

$$\boldsymbol{\Sigma} = \frac{1}{n} \bar{\mathbf{Z}}^T \text{diag}(\mathbf{x}) \bar{\mathbf{Z}},$$

где $\bar{\mathbf{Z}} = \{\mathbf{z}_j - \boldsymbol{\mu}, j \in \{1 \dots, N_{ch}\}\}$ В качестве новых признаков для описания сигнала используются параметры $A, \boldsymbol{\mu}, \boldsymbol{\Sigma}$.

3.2.2 Модель на основе функций радиального базиса

Помимо координат электродов выбраны дополнительно n_{basis} точек на плоскости $\hat{\mathbf{Z}} \in \mathbb{R}^{n_{\text{basis}} \times 2}$ (см. рисунок). Локальная модель в таком случае будет иметь вид

$$\mathbf{g}(\boldsymbol{\xi}) = \sum_{j=1}^{n_{\text{basis}}} \gamma_j \exp(-\|\boldsymbol{\xi} - \hat{\mathbf{z}}_j\|) \quad (3.1)$$

Вектор весов базисных компонент γ находится решением оптимизационной задачи:

$$\sum_{i=1}^n \|\mathbf{x}_i - \varphi(\mathbf{z}_i, \gamma)\| \longrightarrow \min_{\gamma} \quad (3.2)$$




Рис. 3.1: Выбранные центры для модели RBF

3.3 PLS

Алгоритм частичных наименьших квадратов проецирует матрицу \mathbf{X} и целевую матрицу \mathbf{Y} в скрытое пространство малой размерностью l ($l < M$). Алгоритм PLS находит в скрытом пространстве матрицы $\mathbf{T}, \mathbf{U} \in \mathbb{R}^{m \times l}$, которые лучше всего описывают оригинальные матрицы \mathbf{X} и \mathbf{Y} . При этом PLS максимизирует взаимосвязь между \mathbf{T} и \mathbf{U} .

Матрица \mathbf{X} и целевая матрица \mathbf{Y} проецируются в скрытое пространство следующим образом:

$$\mathbf{X}_{m \times n} = \mathbf{T}_{m \times l} \cdot \mathbf{P}_{l \times n} + \mathbf{F}_{m \times n} = \sum_{k=1}^l \mathbf{t}_k \cdot \mathbf{p}_k + \mathbf{F}, \quad (3.3)$$

$$\mathbf{Y}_{m \times r} = \mathbf{U}_{m \times l} \cdot \mathbf{Q}_{l \times r} + \mathbf{E}_{m \times r} = \sum_{k=1}^l \mathbf{u}_k \cdot \mathbf{q}_k + \mathbf{E}. \quad (3.4)$$

Здесь \mathbf{T} и \mathbf{U} – образы исходных матриц в скрытом пространстве, причём столбцы матрицы \mathbf{T} ортогональны; \mathbf{P} и \mathbf{Q} – матрицы перехода; \mathbf{E} и \mathbf{F} – матрицы невязок. Алгоритм PLS максимизирует линейную зависимость между столбцами матриц \mathbf{T} и \mathbf{U}

Глава 4

Вычислительный эксперимент


4.1 Предобработка данных

Обработка исходных данных в данной работе производится в несколько этапов и подробно описано в статье [12]. Исходный сигнал записан на частоте 1 kHz , данные о движении — на частоте 120 Hz . Сигнал фильтруется полосным фильтром с диапазоном от 0.3 Hz до 600 Hz . Затем для каждого момента времени t строится признаковое описание на основе локальных моделей. Длина предыстории момента t равна 1 секунде. В работе использовались 5 записей временных рядов по 15 минут. Первые 10 минут использовались для обучения, оставшиеся 5 — для валидации.

4.2 Проверка основной гипотезы

Для проверки гипотезы о движении зоны активности проводится анализ качества нормальной локальной модели на сырых данных, после фурье-преобразования и после вейвлет-преобразования. Для оценки качества аппроксимации для каждого из электродов используется коэффициент корреляции между исходным временным рядом и восстановленным после применения локальной модели 2.6. На рисунке 4.1 цветом показано значение ρ_j для каждого электрода (белый цвет соответствует более высоким значениям). Из рисунка следует, что наилучшая аппроксимация сигнала локальной моделью достигается после применения вейвлет-преобразования.

Рисунок 4.2 показывает траекторию движения центра гауссианы после применения различных интервальных моделей.




Без обработки

Фурье-преобразование

Вейвлет-преобразование

Рис. 4.1: Коэффициент ρ_j исходного и восстановленного ряда на разных электродах



Без обработки

Фурье-преобразование

Вейвлет-преобразование

Рис. 4.2: Траектория движения центра гауссианы

Из приведенных выше рисунков видно, что сигнал становится наиболее похожим на движение волнового фронта именно после применения вейвлет-преобразования.


4.3 Результаты эксперимента

В работе проведен ряд экспериментов на данных электрокортикограмм обезьян[12]. После построения признакового описания с использованием локальных моделей применяется метод PLS с различной размерностью скрытого подпространства n_c для предсказания траектории кисти. Значения коэффициента корреляции предсказанной и истинной траектории и $sMSE$ приведены в таблице 4.1. Результаты вычислительного эксперимента подтверждают обоснованность использования локальных моделей в данной задаче. Модель


на основе функции Гаусса дает лучшее качество в сравнении с использованием только вейвлет-преобразования. При этом размерность пространства признаков снижается в 5 раз.

Таблица 4.1: Качество предсказания на отложенной выборке для разных локальных моделей


Номер	модели	$n_c = 20$		$n_c = 40$		$n_c = 60$		$n_c = 80$		$n_c = 100$	
		r	sMSE	r	sMSE	r	sMSE	r	sMSE	r	sMSE
1	wavelet	0.42	0.82	0.42	0.83	0.42	0.85	0.42	0.86	0.42	0.87
	wavelet + Gauss	0.48	0.87	0.49	0.76	0.48	0.79	0.47	0.80	0.47	0.80
	wavelet + RBF	0.34	0.91	0.35	0.89	0.35	0.89	0.36	0.9	0.36	0.89
	RBF + wavelet	0.34	0.90	0.36	0.89	0.34	0.90	0.34	0.9	0.34	0.89
	Gauss + wavelet	0.34	0.92	0.37	0.88	0.35	0.89	0.36	0.91	0.36	0.87
2	wavelet	0.43	0.80	0.42	0.81	0.42	0.82	0.43	0.86	0.42	0.87
	wavelet + Gauss	0.49	0.79	0.49	0.76	0.48	0.76	0.47	0.81	0.46	0.82
	wavelet + RBF	0.35	0.87	0.36	0.88	0.36	0.90	0.37	0.9	0.38	0.85
	RBF + wavelet	0.34	0.91	0.36	0.89	0.35	0.89	0.36	0.90	0.36	0.88
	Gauss + wavelet	0.31	0.92	0.33	0.91	0.34	0.89	0.34	0.89	0.36	0.87
3	wavelet	0.41	0.83	0.41	0.83	0.42	0.82	0.42	0.83	0.41	0.86
	wavelet + Gauss	0.47	0.88	0.47	0.76	0.48	0.81	0.47	0.79	0.47	0.82
	wavelet + RBF	0.32	0.93	0.33	0.91	0.34	0.89	0.36	0.89	0.35	0.89
	RBF + wavelet	0.35	0.91	0.36	0.89	0.36	0.89	0.35	0.90	0.36	0.89
	Gauss + wavelet	0.32	0.90	0.35	0.88	0.35	0.91	0.36	0.91	0.36	0.88
4	wavelet	0.42	0.82	0.42	0.83	0.42	0.85	0.42	0.86	0.42	0.87
	wavelet + Gauss	0.48	0.87	0.49	0.76	0.48	0.79	0.47	0.80	0.47	0.80
	wavelet + RBF	0.34	0.91	0.35	0.89	0.35	0.89	0.36	0.9	0.36	0.89
	RBF + wavelet	0.34	0.90	0.35	0.88	0.35	0.87	0.36	0.90	0.36	0.88
	Gauss + wavelet	0.33	0.91	0.34	0.89	0.34	0.89	0.35	0.90	0.36	0.89
5	wavelet	0.42	0.82	0.42	0.83	0.42	0.85	0.42	0.86	0.42	0.87
	wavelet + Gauss	0.48	0.87	0.49	0.76	0.48	0.79	0.47	0.80	0.47	0.80
	wavelet + RBF	0.34	0.91	0.35	0.89	0.35	0.89	0.36	0.9	0.36	0.89
	RBF + wavelet	0.34	0.90	0.35	0.89	0.35	0.87	0.36	0.90	0.36	0.91
	Gauss + wavelet	0.35	0.91	0.35	0.88	0.36	0.91	0.36	0.88	0.35	0.90




Результаты предсказания траектории кисти, wavelet + Gauss



Результаты предсказания траектории кисти, wavelet



Результаты предсказания траектории кисти, wavelet + RBF



Результаты предсказания траектории кисти, Gauss + wavelet

Глава 5

Заключение

В работе предложен новый метод решения задачи декодирования сигналов головного мозга на основе локальных моделей. Предложено несколько вариантов локальных моделей. Предложенный метод учитывает не только временные, но и пространственные зависимости в данных.

В ходе вычислительного эксперимента подтверждена гипотеза о связи движения кисти и перемещения зоны активности по поверхности коры головного мозга. Установлено что предложенные методы улучшают качество предсказания и позволяют существенно снизить размерность признакового описания сигнала

Список литературы

- [1] David M. Alexander и др. «Traveling waves and trial averaging: The nature of single-trial and averaged brain responses in large-scale cortical signals». в: *NeuroImage* 73 (июнь 2013), с. 95—112. DOI: 10.1016/j.neuroimage.2013.01.016.
- [2] César Márquez Chin и др. «Identification of arm movements using correlation of electrocorticographic spectral components and kinematic recordings». в: *Journal of Neural Engineering* 4.2 (апр. 2007), с. 146—158. DOI: 10.1088/1741-2560/4/2/014.
- [3] Andrey Eliseyev и Tatiana Aksenova. «Stable and artifact-resistant decoding of 3D hand trajectories from ECoG signals using the generalized additive model». в: *Journal of Neural Engineering* 11 (окт. 2014).
- [4] Andrey Eliseyev и Tetiana Aksenova. «Penalized Multi-Way Partial Least Squares for Smooth Trajectory Decoding from Electrocorticographic (ECoG) Recording». в: *PLOS ONE* 11.5 (май 2016). под ред. Dingguo Zhang, e0154878. DOI: 10.1371/journal.pone.0154878.
- [5] Carlos A. Loza и Jose C. Principe. «Unsupervised robust detection of behavioral correlates in ECoG». в: *2017 8th International IEEE/EMBS Conference on Neural Engineering (NER)*. IEEE, май 2017. DOI: 10.1109/ner.2017.8008401.
- [6] Soichiro Morishita и др. «Brain-machine interface to control a prosthetic arm with monkey ECoGs during periodic movements». в: *Frontiers in Neuroscience* 8 (дек. 2014). DOI: 10.3389/fnins.2014.00417.
- [7] Anastasia Motrenko и Vadim Strijov. «Multi-way Feature Selection for ECoG-based Brain-Computer Interface». в: *Expert Systems with Applications* 114 (июль 2018). DOI: 10.1016/j.eswa.2018.06.054.
- [8] I Rodriguez-Lujan и др. «Quadratic Programming Feature Selection». в: *Journal of Machine Learning Research* (2010).

- [9] Roman Rosipal и Nicole Krämer. «Overview and Recent Advances in Partial Least Squares». в: *Subspace, Latent Structure and Feature Selection*. Springer Berlin Heidelberg, 2006, с. 34—51. DOI: 10.1007/11752790_2.
- [10] Yilin Song, Yao Wang и Jonathan Viventi. «Unsupervised Learning of Spike Patterns for Seizure Detection and Wavefront Estimation of High Resolution Micro Electrographic (μ ECoG) Data». в: *IEEE Transactions on NanoBioscience* 16.6 (сент. 2017), с. 418—427. DOI: 10.1109/tnb.2017.2714460.
- [11] Ziqian Xie. «Deep Learning Approach for Brain Machine Interface». в: 2018.
- [12] Hai-bin Zhao и др. «ECoG-based brain-computer interface using relative wavelet energy and probabilistic neural network». в: *2010 3rd International Conference on Biomedical Engineering and Informatics*. IEEE, окт. 2010. DOI: 10.1109/bmei.2010.5639897.
- [13] Rui Zhao, Gerwin Schalk и Qiang Ji. «Coupled Hidden Markov Model for Electrographic Signal Classification». в: *2014 22nd International Conference on Pattern Recognition*. IEEE, авг. 2014. DOI: 10.1109/icpr.2014.325.