

Задачи кибернетической нейробиологии

Н. А. Бабич, Е. А. Марзель, А. В. Рыбалко, О. В. Чен, В. П. Чулкин, А. Л. Фрадков

*Институт проблем машиноведения РАН;
Санкт-Петербургский государственный университет*

fradkov@mail.ru

Аннотация. Обсуждается новая научная область кибернетическая нейробиология (cybernetical neurosciences), изучающая математические модели, принятые в вычислительной нейробиологии методами кибернетики – науки об управлении и связи в живом организме, машине и обществе, а также рассматривающая применение на практике результатов, полученных при исследовании математических моделей. Перечисляются некоторые основные задачи, методы и результаты кибернетической нейробиологии. Представлены некоторые результаты в области нейронинтерфейсного управления и методов машинного обучения, полученные в ИПМаш РАН.

Ключевые слова: кибернетика; нейробиология; модели нейронов; управление; оценивание параметров

I. ВВЕДЕНИЕ

В последние годы в нейробиологии стали набирать популярность исследования, основанные на применении методов кибернетики – науки об управлении и связи в живом организме и машине, как определил её создатель Норберт Винер в 1948 году [1]. Методы кибернетики основаны на построении и использовании математических моделей и построении прямых и обратных связей между субъектом исследования (компьютерной системой) и объектом исследования (в данном случае – мозгом человека или животного).

В ходе исследований по применению методов кибернетики к нервным системам биологических организмов и популяций формируется новое научное направление в вычислительной нейробиологии, которое можно назвать «кибернетической нейробиологией».

Ниже перечисляются некоторые основные задачи, методы и результаты кибернетической нейробиологии.

II. ЗАДАЧИ И МЕТОДЫ КИБЕРНЕТИЧЕСКОЙ НЕЙРОБИОЛОГИИ

Исследования в области кибернетической нейробиологии решают следующие основные задачи.

1. Определение условий, при которых в моделях нейронных ансамблей существуют некоторые специальные режимы, соответствующие режимам поведения мозга, такие как синхронизация, десинхронизация, спайкинг, бёрстинг, солитоны, химеры и другие.
2. Построение (синтез) внешних (управляющих) воздействий, создающих в моделях нейронных ансамблей вышеперечисленные режимы.
3. Оценивание состояния и параметров моделей нейронных ансамблей по результатам измерения входных и выходных переменных.
4. Классификация состояний мозга и намерений человека методами адаптации и машинного обучения.
5. Нахождение алгоритмов управления или синтез обратных связей, обеспечивающих заданные свойства замкнутой системы, состоящей из взаимодействующих объекта управления и устройства управления.

Напомним, что объект управления в нейробиологических исследованиях – это нервная система или мозг человека, а устройство управления может быть реализовано в каком-то компьютерном устройстве. Для работы всей системы нервная система или мозг должны быть связаны с внешними компьютерными устройствами связи, называемыми нейроинтерфейсами (интерфейсами «мозг-компьютер»). Однако в теоретических исследованиях кибернетическая система управления, т. е. и мозг человека и устройство (алгоритм) управления, может быть не реализована физически, а представлена в виде набора математических моделей. При этом решение задач синтеза управления для модели предшествует реализации системы управления реальным организмом или головным мозгом, что предоставляет нейробиологам много новых возможностей.

Методы кибернетической нейробиологии – это, прежде всего, методы кибернетики (теории управления): из нейробиологии ведут происхождение методы сбора и обработки экспериментальных данных. Среди них имеются инвазивные, связанные с внедрением в организм электродов, и неинвазивные (ЭЭГ, МЭГ, fMRT и др.). Основные методы ориентированы на применение к нелинейным, адаптивным и интеллектуальным системам.

III. МОДЕЛИ КИБЕРНЕТИЧЕСКОЙ НЕЙРОБИОЛОГИИ

В случае моделей, описываемых векторными дифференциальными уравнениями состояния общего вида, кибернетическая версия модели имеет вид

$$dx/dt = F(x, w, t), \quad y = h(x, w, t), \quad (1)$$

где $x = x(t)$ – n -мерный вектор переменных состояния системы в момент времени $t \geq 0$, $w = w(t)$ – m -мерный вектор входных (управляющих) переменных, $y = y(t)$ – l -мерный вектор выходных (измеряемых) переменных. Вектор-функции $F(x, w, t)$, $h(x, w, t)$ удовлетворяют условиям, обеспечивающим существование решений системы (1) на интересующем промежутке времени.

Одна из самых популярных математических моделей нейрона – модель ФитцХью–Нагумо. Она является системой двух дифференциальных уравнений

$$\dot{u} = u - \frac{u^3}{3} - v + I_{ext}, \quad \dot{v} = \varepsilon(u - a - bv), \quad (2)$$

где $u(t)$ – мембранный потенциал нейрона (активатор), $v(t)$ – кумулятивный эффект всех медленных ионных токов, ответственных за восстановление потенциала покоя мембраны нервной клетки (ингибитор). Параметры a и b определяют характеристики проводимости ионных каналов, $\varepsilon > 0$ – относительное изменение скорости медленных ионных токов, I_{ext} – внешний ток, точка обозначает дифференцирование по времени.

Будем считать, что мембранный потенциал нейрона $u(t)$ доступен измерению. Это значит, что $u(t)$ играет роль выходной переменной. Модель (2) может быть записана в форме (1), если ввести вектор состояния $x = u, v$, и выходную переменную $y = u$. Вход модели может вводиться по разному. Им может быть внешний ток I_{ext} , если эта переменная доступна целенаправленному изменению. Входом может быть также какой-то из параметров модели a, b , или функция от них, если эта функция может целенаправленно изменяться. Можно считать, что входом в систему является внешний ток I_{ext} , который может быть постоянным или переменным. В любом случае возникает задача оценки состояния и вход системы по измерениям ее выхода.

Чтобы исследовать ансамбль взаимодействующих нейронов, каждый из которых описывается моделью ФитцХью–Нагумо, можно рассмотреть сетевую модель

$$\begin{aligned} \dot{u}_i &= u_i - \frac{u_i^3}{3} - v_i + I_{i,ext} + \\ &C_i \sum_{j=1}^N G_{ij} \varphi(u_j(t) - u_j(t - \tau_{ij})), \\ \dot{v}_i &= \varepsilon(u_i - a_i - b_i v_i), \quad i = 1, \dots, N, \end{aligned} \quad (3)$$

где – $u_i(t), v_i(t)$ – переменные i -го узла сети; C_i, a_i, τ_i – параметры сети; G – матрица информационных связей в сети. В модели (3) учтена задержка в передаче информации между нейронами. Важность сетевых моделей возросла после того, как в исследованиях коннектома человека был разработан атлас анатомических взаимосвязей нейронов в головном мозге человека в виде сети, состоящей из 90 узлов, соответствующих важным регионам головного мозга.

Входными и выходными переменными в сетевой системе могут быть входные и выходные переменные всех или части узлов сети. Если говорить о реализации управления на основе измерений ЭЭГ, то выходными переменными могут быть значения ЭЭГ в точках отведения электроэнцефалографа [2], [3]. Процессы в каждом узле можно описать различными моделями, в том числе моделями ФитцХью–Нагумо. В частности, в работе [4] показано, что в модели (3) возможны процессы, похожие на развитие эпилепсии.

Более сложная модель, которая также может быть получена из модели Ходжкина–Хаксли – это модель

Хиндмарша–Роуза, описываемая тремя дифференциальными уравнениями:

$$\begin{aligned} \dot{p} &= q - ap^3 + bp^2 - n + I_{ext}, \\ \dot{q} &= c - dp^2 - q, \\ \dot{n} &= r(s(p + p_0) - n), \end{aligned} \quad (4)$$

в которых через $p(t)$ обозначен мембранный потенциал нейрона, $q(t)$ и $n(t)$ моделируют работу кальциево-натриевого насоса, I_{ext} – внешний ток. Модель Хиндмарша–Роуза (4) позволяет описывать более сложные процессы, чем модель (2), в частности, демонстрировать не только спайковое, но и берстовое поведение (быстрые осцилляции).

Измеряемым выходом модели является мембранный потенциал $p(t)$, входом – внешний ток I_{ext} .

Модели (4) также можно связывать в сети, моделирующие поведение нейронных ансамблей.

IV. ПРИМЕРЫ

В качестве примера рассмотрим задачи, решаемые в системе нейроинтерфейсного управления инвалидным креслом, разрабатываемой в ИПМаш РАН. Система состоит из следующих взаимосвязанных блоков [5]:

- подсистема предобработки сигналов электроэнцефалограмм (ЭЭГ), включающая набор полосовых фильтров для выделения из ЭЭГ частот заданных диапазонов с целью фильтрации помех и удаления артефактов;
- подсистема классификации, включающая набор алгоритмов распознавания и классификации намерений испытуемого по сигналам ЭЭГ;
- подсистема управления, преобразующая выход классификатора в сигналы управления электроприводами, реализующими движения кресла.

В настоящее время реализовано распознавание и исполнение 4-х действий: поворот налево, поворот направо, движение вперед, остановка. Остановимся подробнее на алгоритмах работы классификатора. В системе имеется возможность применять стандартные программы классификации из библиотеки Scikit-learn на языке Python: SVM, KNN, RA и др. Кроме того, реализованы оригинальные алгоритмы классификации:

- Модифицированный алгоритм Якубовича–Брэгмана (YBM). Алгоритм предназначен для разделения двух конечных множеств точек в пространстве R^n гиперплоскостью. Задача классификации предварительно сводится стандартным преобразованием (отражение от нуля и повышение размерности на 1) к задаче отдаления набора точек от начала координат гиперплоскостью, что эквивалентно задаче поиска точки пересечения полупространств или решения системы неоднородных линейных неравенств:

$$\eta_i(x) = (-f_i, x) + a_i \geq 0, \quad i \in I. \quad (5)$$

Предполагается, что даны полупространства вида $A_i = \{x: (f_i, x) \leq a_i\}$, $f_i \in H$, $a_i \in R$ и $R = \bigcap_{i \in I} A_i \neq \emptyset$.

Пусть R содержит точку x^* вместе с некоторой окрестностью, т.е. существует $\varepsilon^* > 0$ такое, что $\eta_i(x^*) \geq \varepsilon^* > 0$ для $i = 1, 2, \dots$. Поскольку $i(n) = i(x_n)$, выбирается индекс, для которого $\min \eta_i(x_n)$ достигается. Строится последовательность точек x_n следующим образом:

$$\begin{aligned} x_{n+1} &= x_n, \text{ if } \eta_{i(n)}(x_n) \geq 0; \\ x_{n+1} &= x_n - f_{i(n)} \cdot [\rho_n - \beta_n \cdot \eta_{i(n)}(x_n) \cdot \|f_{i(n)}\|^2] \\ &\text{if } \eta_{i(n)}(x_n) < 0, \end{aligned} \quad (6)$$

где $0 < \beta \leq \beta_n \leq 2$, $\rho_n > 0$, $\rho_n \rightarrow 0$, $\rho_1 + \rho_2 + \dots = \infty$. Для $\beta_n = 1$, точка проектируется точно на границу полупространства, как в классическом методе Брэгмана. Показано, что алгоритм (6) является конечно-сходящимся алгоритмом решения неравенств (5).

- «Неявная полоска» (ISTRIP) – алгоритм, идея которого предложена в [11]. Алгоритм также основан на сведениях задачи разделения конечных множеств к решению системы целевых неравенств. Алгоритм решения неравенств

$$|F_k^T \theta - y_k| < \Delta \quad (7)$$

где θ – вектор неизвестных параметров, включает на каждом шаге предварительные операции

$$\begin{aligned} \bar{\theta}_{k+1} &= \theta_k - \frac{F_k^T \theta_k - y_k}{(2\gamma_k)^{-1} + \|F_k\|^2} F_k, \\ \beta_k(\bar{\theta}_{k+1}) &= (F_k^T \bar{\theta}_{k+1} - y_k)^2 (1 + 0.5\gamma_k \|F_k\|^2) \end{aligned} \quad (8)$$

и основную итерацию

$$\begin{aligned} \theta_{k+1} &= Pr_{\Xi}(\bar{\theta}_{k+1}), \beta_k(\bar{\theta}_{k+1}) > \varepsilon, \\ \theta_{k+1} &= \theta_k, \beta_k(\bar{\theta}_{k+1}) < \varepsilon. \end{aligned} \quad (9)$$

- Модифицированный алгоритм Козинца (АКМ) для «мягкого» разделения конечных множеств.

Алгоритм ищет вектор θ_* такой, что

$$\min p_i(\theta_*) = \max_i \min (p_i(\theta)), \quad (10)$$

где $p_i(\theta) = y_i(\theta^T F_i)$.

- Нечеткая версия метода k ближайших соседей (k nearest neighbors, FAKNN) [5].
- В число реализованных алгоритмов классификации входит новый метод, основанный на генерации новых признаков на основе оценок параметров модели ФитцХью–Нагумо (ФХН) для нейронного узла. Алгоритм в ходе работы строит последовательность оценок параметров модели ФХН по заданным измерениям сигнала ЭЭГ в одном отведении для сигналов, снятых при наличии намерения повернуть налево и при наличии намерения повернуть направо. Процедура снятия сигнала и построения оценок повторяется $M > 1$ раз для каждого окошка измерений (кадра) длиной N для кадров, соответствующих намерению повернуть направо и $M > 1$ раз для каждого

окошка измерений (кадра) длиной N для кадров, соответствующих намерению повернуть направо. Полученные $2M$ точек в пространстве оценок параметров рассматриваются как точки двух классов, подлежащие разделению. Для тестового набора оценок параметров можно либо применить один из имеющихся в системе алгоритмов YAM, ISTRIP или АКМ, либо использовать один из библиотечных алгоритмов: SVM, KNN, RF и др.

V. РЕЗУЛЬТАТЫ КИБЕРНЕТИЧЕСКОЙ НЕЙРОБИОЛОГИИ: 1. ИССЛЕДОВАНИЕ МОДЕЛЕЙ

A. Регулирование, слежение, синхронизация, управление хаосом

Результаты, которые относятся к области кибернетической нейробиологии, относятся к двум классам: результаты, касающиеся управления процессами в моделях нейронов и нейронных сетей и результаты, касающиеся управления на основе реальных данных. Перечислим сначала результаты по управлению моделями нейронов и нейронных сетей. Эти результаты имеют теоретическое значение, показывая принципиальную возможность управления нейронными процессами в предположении, что модели достаточно хорошо описывают реальные процессы, выходные переменные доступны измерению, а входные переменные доступны изменению.

Задача управления, кроме модели объекта управления включает еще описание цели управления. В качестве цели может выступать обычное для кибернетики требование приближения процесса к заданному состоянию или заданной траектории (регулирования или слежения). Могут также ставиться задачи синхронизации процессов в различных частях систем и возникновение колебаний, их хаотизация и т. д.

Первые результаты по управлению моделями нейронов и нейронных сетей были получены в 1990-е годы и относились к управлению хаосом и синхронизацией. В работе [6] был предложен алгоритм импульсного управления синхронизацией двух моделей ФХН на основе моделирования и аналогии между нейронными и электрическими процессами. В работе [7] предложен алгоритм управления цепью нейронов ФХН с целью сближения (синхронизации) колебаний каждого нейрона с колебаниями «эталонного» нейрона.

В работе [8] предложены алгоритмы синхронизации неоднородной сети диффузионно связанных моделей ФХН нейронов с иерархической архитектурой, основанные на методе скоростного градиента. Аналогичные результаты получены для алгоритмов адаптивного управления, не требующих точного знания параметров моделей нейронов [9], а также для задачи десинхронизации [10], важной для лечения ряда ментальных болезней, таких, как болезнь Паркинсона, тремор и др.

Метод функций Ляпунова и метод скоростного градиента были успешно применены также к построению и исследованию алгоритмов управления в задачах синхронизации и управления хаосом в моделях Хиндмарша–Роуза и их сетях [12], [13] и в задачах адаптивного управления сетями осцилляторов Ландау–Стюарта [14], [15].

В. Оценивание состояния и параметров моделей

Задача оценивания состояния и параметров модели нейронных ансамблей важна для управления ансамблем на основе данных, доступных для измерения. Кроме того, знание параметров и состояния сети важно, чтобы лучше судить о ее поведении и свойствах. Существует достаточно много работ по оценке параметров модели одного нейрона, причем в большинстве работ используются стохастические подходы [16], [17], [18]. В работе [19] предложен и обоснован алгоритм оценивания состояния и параметров пары ФХН нейронов на основе метода скоростного градиента и фильтрации. Метод скоростного градиента применялся также к оцениванию параметров модели нейрона Хиндмарша–Роуз [20], [21] и нейромассовой модели [22]. Другие подходы к оцениванию параметров моделей нейронов представлены в [23], [24], [25], [26].

VI. РЕЗУЛЬТАТЫ КИБЕРНЕТИЧЕСКОЙ НЕЙРОБИОЛОГИИ:

2. ИССЛЕДОВАНИЕ РЕАЛЬНЫХ ДАННЫХ

А. Классификация состояний мозга и диагностика

Классификация состояний нейронных ансамблей, в том числе состояний целого мозга, является важной областью применения кибернетических методов. Здесь используются методы распознавания образов и методы машинного обучения, которые часто относят к области искусственного интеллекта. Задача классификации состоит в следующем. Даны результаты измерения состояния некоторого конечного множества N нейробиологических объектов, каждый из которых принадлежит одному из M классов. Требуется построить набор решающих правил, позволяющих по измеренным данным определить, какому классу принадлежит новый, классифицируемый объект. Подобные задачи типичны для медицинской диагностики, где кибернетические методы распознавания образов применяются уже давно. В нейрофизиологии и психиатрии методы распознавания и машинного обучения активно применяются, см. [28], [29], [30], [31], [32], [33]. Используются как известные статистические методы (метод дискриминантного анализа, анализ главных компонент (РСА), анализ независимых компонент (ИСА), метод случайных лесов (random forests)) так и детерминистские методы машинного обучения. Появляются работы по применению новых для нейронаук подходов, например, метода целевых неравенств [34].

В. Управление на основе нейророботной связи

Нейророботная связь (НОС) (или биологическая обратная связь (БОС)) является наиболее эффективным подходом к взаимодействию человеческого мозга с внешним управляющим устройством и наиболее перспективным кибернетическим подходом в нейробиологии и нейрофизиологии. В основе НОС лежит идея условных рефлексов и подкрепление того спонтанного поведения, которое признается желательным. В этом проявляется пластичность головного мозга – способность мозга изменяться под действием обучения. Во время эксперимента по БОС испытуемому предъявляется информация о состоянии и желаемом изменении тех или иных собственных физиологических параметров. Базовый принцип кибернетики – обратная связь (отображение информации о результатах деятельности), служит «зеркалом», в котором можно увидеть иначе недоступные сознанию

физиологические параметры и регулировать параметры электрической активности головного мозга. Реализация НОС требует наличия нейроинтерфейса – устройства, обеспечивающего обмен информацией между мозгом и компьютером в реальном времени. Обычно неинвазивный нейроинтерфейс использует данные электроэнцефалографии (ЭЭГ), отражающие изменение потенциала электрического поля на поверхности головы (скальпе) испытуемого. Некоторые из текущих параметров ЭЭГ (или их комбинация) [37] предъявляются испытуемому в виде, например, визуального стимула (высоты столбика на экране, яркости экрана) с заданием изменять эти параметры в желательном направлении. В такой парадигме испытуемый, сосредотачиваясь на сигнале НОС, старается запомнить связь между параметром и своим состоянием. Параметры ЭЭГ и локализация электродов, образующие протокол НОС, выбираются в зависимости от задачи [38].

Задача формирования сигнала нейророботной связи является весьма сложной, т.к. на данный момент не существует четких правил предъявления стимула, которых надо придерживаться, чтобы помочь испытуемому наиболее эффективно (например, с точки зрения затраченного времени) справиться с задачей. В большинстве случаев сигнал НОС формируется пропорционально отклонению параметров ЭЭГ испытуемого от нормативных значений. Измеренное отклонение транслируется в сигнал НОС на основе некоторых экспериментально полученных правил [39], [37], работающих «в среднем» и для большинства испытуемых. Целесообразным представляется разработка адаптивных методов расчёта сигнала ОС, подстраивающих параметры правил применительно к конкретному испытуемому. Правила для расчёта количественных параметров ЭЭГ, используемых далее для формирования сигнала НОС, зависят от большого числа параметров, таких как, например, длина временного окна обработки данных или величина задержки при предъявлении управляющего воздействия. Индивидуальный подбор значений этих параметров также может повысить эффективность НОС тренинга [37]. Одним из перспективных путей развития НОС является предложенное в [35], [36] использование адаптивных математических моделей активности головного мозга.

VII. ЗАКЛЮЧЕНИЕ

Применение методов кибернетики и теории управления к задачам нейробиологии и нейрофизиологии имеет большую перспективу, и число публикаций в этом направлении стремительно растёт. Появляются обобщающие публикации и обзоры [40], [27]. В настоящей работе делается попытка структурирования и систематизации этой области, а также представлены некоторые работы, ведущиеся в ИПМаш РАН.

СПИСОК ЛИТЕРАТУРЫ

- [1] Wiener N. Cybernetics: or, control and communication in the animal and the machine. MIT Press, 1948.
- [2] Tzourio-Mazoyer N., Landeau B., Papathanassiou D., Crivello F., Etard O., Delcroix N., Mazoyer B., and M. Joliot, Automated anatomical labeling of activations in SPM using a macroscopic anatomical parcellation of the MNI MRI single-subject brain. Neuroimage 15, 273 (2002).

- [3] Human Connectome Projects <https://www.humanconnectome.org/>
- [4] Berster M., Berner R., Sawicki J., Zakharaova A., S'koch A., Hlinka J., Lehnertz K., and E. Sch'oll, "FitzHugh–Nagumo oscillators on complex networks mimic epileptic-seizure-related synchronization phenomena," *Chaos: An Interdisciplinary Journal of Nonlinear Science* 30, 123130 (2020).
- [5] Фрадков А.Л., Бабич Н.А. Трехпозиционное управление транспортным средством на основе нейроинтерфейса с применением машинного обучения. *Информатика и автоматизация*, 2025, №1, С. 5-29.
- [6] Carroll T. Synchronization and complex dynamics in pulse-coupled circuit models of neurons *Biol. Cybern.* 73, 553-559, 1995.
- [7] Dragoi, V., Grosu, I. Synchronization of Locally Coupled Neural Oscillators. *Neural Processing Letters* 7, 199–210, 1998. <https://doi.org/10.1023/A:1009618318908>
- [8] Plotnikov S. A., Lehnert J., Fradkov A. L., and E. Schoell. Synchronization in heterogeneous FitzHugh–Nagumo networks with hierarchical architecture. *Phys. Rev. E* 94, 012203 (2016).
- [9] Plotnikov S.A., Lehnert J., Fradkov A.L., Schoell E. Adaptive control of synchronization in delay-coupled heterogeneous networks of FitzHugh–Nagumo nodes. *International Journal of Bifurcation and Chaos*, Vol. 26, No. 4 (2016) 1650058 (14 pages).
- [10] Plotnikov, S.A., Fradkov A.L. Desynchronization Control of FitzHugh–Nagumo Networks with Random Topology. *IFAC-PapersOnLine*, Volume 52, Issue 16, 2019, P. 640-645.
- [11] Фрадков А.Л. Адаптивное управление сложными системами. М.: Наука, 1990.
- [12] Plotnikov, S. Synchronization conditions in networks of Hindmarsh–Rose systems. *Cybern. Phys.* 2021, 10, 254–259.
- [13] Semenov D.M., Plotnikov S.A., Fradkov A.L. Controlled synchronization in regular delay-coupled networks of Hindmarsh–Rose neurons. 2022 6th Scientific School Dynamics of Complex Networks and their Applications (DCNA). IEEE, Kaliningrad, 2022.
- [14] Selivanov A.A., Lehnert J, Dahms T., Hovel P., Fradkov A.L., Schoell E. Adaptive synchronization in delay-coupled networks of Stuart–Landau oscillators. *Phys.Rev. E* 85, 016201 (2012).
- [15] Lehnert J., Hovel P., Selivanov A. A., Fradkov A. L., and E. Schoell. Controlling cluster synchronization by adapting the topology, *Physical Review E* 90, 042914 (2014).
- [16] Jensen A. C., Ditlevsen S., Kessler M., and O. Papaspiliopoulos, "Markov chain Monte Carlo approach to parameter estimation in the FitzHugh–Nagumo model, *Physical Review E* 86, 041114 (2012).
- [17] Che Y., Geng L., Han C., Cui S., and J. Wang, Parameter estimation of the FitzHugh–Nagumo model using noisy measurements for membrane potential, *Chaos: An Interdisciplinary Journal of Nonlinear Science* 22, 023139 (2012).
- [18] Doruk R. O. and L. Aboshar, Estimating the parameters of FitzHugh–Nagumo neurons from neural spiking data, *Brain Sci.* 9, 364 (2019).
- [19] Rybalko A., Fradkov A. Identification of Two-Neuron FitzHugh–Nagumo Model Based on the Speed-Gradient and Filtering Chaos 2023, Vol.33, Is. 8. 083126.
- [20] Fradkov A.L., Kovalchukov A. and B. Andrievsky Parameter Estimation for Hindmarsh–Rose Neurons *Electronics* 2022, 11(6), 885.
- [21] Kovalchukov A.A., Fradkov A.L. Speed-Gradient approach to Hindmarsh–Rose model identification based on membrane potential measurements 2022 6th Scientific School Dynamics of Complex Networks and their Applications (DCNA). IEEE, Kaliningrad, Russian Federation, 2022.
- [22] Plotnikov, S.A. Fradkov, A.L. Adaptive Parameter Identification for a Class of Neural Mass Models with Application to Ergatic Systems. *Mekhatronika, Avtomatizatsiya, Upravlenie*, 2024, 25(1), pp.13–18.
- [23] Postoyan, R.; Chong, M.; Ne'sić, D.; Kuhlmann, L. Parameter and state estimation for a class of neural mass models. In *Proc. 51st IEEE Conf. Decision Control (CDC 2012)*, Maui, HI, USA, 10–13 December 2012; pp. 2322–2327.
- [24] Zhao, J.; Aziz-Alaoui, M.A.; Bertelle, C.; Corson, N. Sinusoidal disturbance induced topology identification of Hindmarsh–Rose neural networks. *Sci. China Inf. Sci.* 2016, 59, 112205.
- [25] Dong, X.; Si,W.;Wang, C. Global Identification of FitzHugh–Nagumo Equation via Deterministic Learning and Interpolation. *IEEE Access* 2019, 7, 107334–107345.
- [26] Wang, L.; Yang, G.; Yeung, L. Identification of Hindmarsh–Rose Neuron Networks Using GEO Metaheuristic. In *Proceedings of the Second International Conference on Advances in Swarm Intelligence–Volume Part I*, Chiang Mai, Thailand, 26–30 July 2019; Springer: Berlin/Heidelberg, Germany, 2011; pp. 455–463.
- [27] Howlett J.R., Paulus M.P. Out of control: computational dynamic control dysfunction in stress and anxiety-related disorders. *Discover Mental Health* (2024) 4:5.
- [28] Mueller A., G. Candrian G., Kropotov J.D., Ponomarev V. A., and Baschera G. M., Classification of ADHD patients on the basis of independent ERP components using a machine learning system, *Nonlinear Biomed Phys*, vol. 4 Suppl 1, p. S1, Jun 3 2010.
- [29] Lebedev A., Westman E., Van Westen G., Kramberger M., Lundervold A., Aarsland D., Soininen H., Kłoszewska I., Mecocci P., Tsolaki M., et al. Random Forest ensembles for detection and prediction of Alzheimer's disease with a good between-cohort robustness. *NeuroImage Clin.* 2014;6:115–125
- [30] Boyko M., Abramova O., Yarkin V., Sharaev, M. et al. Machine learning approaches to Mild Cognitive Impairment detection based on structural MRI data and morphometric features. *Cognitive Systems Research*. 78, (2022).
- [31] Zubrikhina M., Masnyi D., Sharaev M. et al. Autoencoders with deformable convolutions for latent representation of EEG spectrograms in classification tasks, *Proc. SPIE 12701, 15th International Conference on Machine Vision (ICMV 2022)*
- [32] Yoon J., Kang C., Kim S., Han J. D-vlog: Multimodal Vlog Dataset for Depression Detection. *Proc. Conf. AAAI Artif.Intell.* 2022; 36:12226–12234
- [33] Shanarova N., Pronina, M., Lipkovich, M. Mu'ller, A., Kropotov, J. Application of Machine Learning to Diagnostics of Schizophrenia Patients Based on Event-Related Potentials, *Diagnostics*, 2023, 13(3), 509.
- [34] Lipkovich M. Yakubovich's method of recursive objective inequalities in machine learning. *IFAC-PapersOnLine*, 2022, vol. 55, no. 12, pp. 138-143.
- [35] Овод И.В., Осадчий А.Е., Пупышев А.А., Фрадков А.Л. Формирование нейророботной связи на основе адаптивной модели активности головного мозга. *Нейрокомпьютеры*, 2012, 2, С.36-41.
- [36] Plotnikov S.A., Semenov D.M., Lipkovich M., Fradkov A.L. Artificial intelligence based neurofeedback. *Cybernetics And Physics*, 2019, Vol. 8, Is. 4, 287–291.
- [37] Кротоков Ю.Д. Количественная ЭЭГ, Донецк: изд-во «Заславский» 2010.
- [38] Kamiya J. Conscious control of brain waves. *Psychology Today*, 1968,1, 56–60.
- [39] Holten V. Bio and neurofeedback applications in stress regulation. *Neuroscience & Cognition*, track Behavioural Neuroscience, July 2009.
- [40] Wilson D., Moehlis J. Recent advances in the analysis and control of large populations of neural oscillators. *Annual Reviews in Control*, Volume 54, , 2022, 327-351.