

**ЗАДАЧИ
КИБЕРНЕТИЧЕСКОЙ
НЕЙРОБИОЛОГИИ**
(PROBLEMS OF
CYBERNETICAL NEUROSCIENCE)

А.Л.Фрадков
(ИПМаш РАН, СПбГУ)

**В докладе представлена новая научная
область: кибернетическая нейробиология**

**Кибернетическая нейробиология — раздел
вычислительной нейробиологии, изучающий
процессы в мозге человека и нервной системе
живых существ методами кибернетики.**

См. также

ALF, Definition of Cybernetical Neuroscience

<https://arxiv.org/abs/2409.16314>

Что такое вычислительная нейробиология?

Вычислительная нейробиология — это область исследований, в которой математические инструменты и компьютерные средства используются для исследования функций мозга.

(<https://www.nature.com/subjects/computational-neuroscience>)

Термин был введен в 1985–1990 годах Эриком Л. Шварцем (Бостонский университет).

Область вычислительной нейронауки быстро растет, см.

“20 years of computational neuroscience.”

Ed. James M. Bower. Berlin: Springer, 2013.

Что такое кибернетика?

Кибернетика — это наука об управлении и коммуникации в животном, машине и обществе (Норберт Винер, 1948, 1950).

Сегодня кибернетика понимается как теория управления в широком смысле. Кибернетические методы включают в себя не только методы управления, но и методы оценки переменных и параметров систем, фильтрации, оптимизации, распознавания образов, машинного обучения и т. д.

[АЛФ. Кибернетическая физика. СПб: Наука, 2003.

ALF, Применение кибернетических методов в физике. Т.48(2), Успехи физических наук, 2005]

ПЛАН ДОКЛАДА

- 1. ЗАДАЧИ кибернетической нейронауки
(задачи (А), (В), (С) и задачи (D), (Е))**
- 2. МОДЕЛИ кибернетической нейронауки**
 - 2.1. Модели нейрона**
 - 2.2. Модели нейронных ансамблей**
 - 2.3. Модели целого мозга**

ПРИМЕРЫ

- 3.1. Примеры решения задач (А)-(В)**
- 3.2. Примеры решения задачи (С)**
- 3.3. Примеры решения задачи (D)**
- 3.4. Примеры решения задачи (Е)**

1. Задачи кибернетической нейронауки

1.1. Задачи исследования моделей нейронных процессов:

- (А). Анализ условий, при которых модели нейронных процессов обладают особыми типами сложного поведения, такими как синхронизация, десинхронизация, спайки, пачечные разряды, солитоны, хаос, химеры и другие.**
- (В). Синтез внешних (управляющих) входов, создающих особое поведение в моделях мозга.**
- (С). Оценка состояния и параметров моделей мозга на основе результатов измерения входных и выходных переменных.**

1. Задачи кибернетической нейронауки

1.2. Задачи на основе реальных данных:

(D). Классификация состояний мозга и намерений человека (с использованием методов адаптации и машинного обучения).

(E). Разработка алгоритмов управления, обеспечивающих заданные свойства замкнутой системы, состоящей из управляемой нервной системы и управляющего устройства.

2. Модели кибернетической нейробиологии

2.1. МОДЕЛИ НЕЙРОНОВ

Модель «Integrate and fire» (1907),

Модель Ходжкина-Хаксли (1952)

* Модель ФицХью-Нагумо (1961)

Модель Уилсона-Коуэна (1972)

Модель Моррис-Лекара (1981)

* Модель Хиндмарша-Роуза (1984)

* Нейромассовые модели (1975, 1995)

Модель Ижикевича (2000)

* Модель Ландау-Стюарта (1944, 2007)

и т. д.

Дискретные модели (Рульков, Киалво...)

2.1. МОДЕЛИ НЕЙРОНОВ

Модель ФицХью-Нагумо

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

где $u(t)$ — мембранный потенциал нейрона, $v(t)$ — совокупное действие всех медленных ионных токов, отвечающих за восстановление потенциала покоя мембраны. Параметры a и b определяют проводимостные характеристики ионных каналов, $\varepsilon > 0$ — относительную скорость изменения медленных ионных токов, а I_{ext} — внешний ток [4, 5].

$I_{ext}(t)$ - ВХОД, $u(t)$ - ВЫХОД

2.1. МОДЕЛИ НЕЙРОНОВ

Модель Хиндмарша-Роуза

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

где $p(t)$ - мембранный потенциал,
 $q(t)$, $n(t)$ описывают натрий-калиевый насос,
 $r(t)$ - скорость изменения $n(t)$,
 a, b, c, d, s, p_0 - параметры модели,
 $0 < r < 1$, $I_{ext}(t)$ - вход, $p(t)$ - выход.

2.1. МОДЕЛИ НЕЙРОНОВ

Модель Ландау-Стюарта - нормальная форма суперкритической бифуркации Андронова-Хопфа

$$\frac{dZ}{dt} = Z[a + i\omega - |Z|^2]$$

где $Z(t)$ — комплексная переменная, состояние осциллятора; a, ω — параметры модели.

Ландау Л. К проблеме турбулентности. ДАН СССР, т. 44, № 8, с. 339-349, 1944.

Стюарт, Дж. Т. О нелинейной механике гидродинамической устойчивости. Журнал механики жидкости, 4(1), 1-21, 1958.

2.2. МОДЕЛИ НЕЙРОННЫХ АНСАМБЛЕЙ

Сеть моделей Ландау-Стюарта

$$\dot{W}_j = (1 + i\omega_j - |W_j|^2)W_j + C(\bar{W} - W_j) + S_j(t),$$

$W_j(t)$ – комплексная переменная, состояние $j^{\text{го}}$ осциллятора
 $S_j(t)$ – внешние входы.

$$\bar{W} = N^{-1} \sum_{k=1}^N W_k$$

C. Hauptmann, O. Omel'chenko, O. V. Popovych, Y., Maistrenko, and P. A. Tass, Control of spatially patterned synchrony with multisite delayed feedback. Phys. Rev. E 76, 066209 (2007).

Freyer F, Roberts J.A. Ritter P, Breakspear M.A. Canonical Model of Multistability and Scale-Invariance in Biological Systems. PLoS Comput Biol 8(8): e1002634 (2012).

2.2. МОДЕЛИ НЕЙРОННЫХ АНСАМБЛЕЙ

Нейромассовая модель

$$\dot{x}_1(t) = x_2(t),$$

$$\dot{x}_2(t) = \textcolor{red}{A}\textcolor{blue}{a}\sigma(x_3(t) - x_5(t)) - 2\textcolor{blue}{a}x_2(t) - \textcolor{blue}{a}^2x_1(t),$$

$$\dot{x}_3(t) = x_4(t),$$

$$\dot{x}_4(t) = \textcolor{red}{A}\textcolor{blue}{a}[u(t) + \textcolor{blue}{C}_2\sigma(\textcolor{blue}{C}_1x_1(t))] - 2\textcolor{blue}{a}x_4(t) - \textcolor{blue}{a}^2x_3(t),$$

$$\dot{x}_5(t) = x_6(t),$$

$$\dot{x}_6(t) = \textcolor{red}{B}\textcolor{blue}{b}\textcolor{blue}{C}_4\sigma(\textcolor{blue}{C}_3x_1(t)) - 2\textcolor{blue}{b}x_6(t) - \textcolor{blue}{b}^2x_5(t),$$

where $\mathbf{x} = (x_1, \dots, x_6)^T \in \mathbb{R}^6$ is a state vector, $u \in \mathbb{R}$ is an input (white noise), while $y = x_3 - x_5 \in \mathbb{R}$ is an output of the whole system. Parameters $\textcolor{blue}{a}$ and $\textcolor{blue}{b}$ have fixed values $\textcolor{blue}{a} = 100 \text{ s}^{-1}$, $\textcolor{blue}{b} = 50 \text{ s}^{-1}$. Parameters $\textcolor{blue}{C}_1$, $\textcolor{blue}{C}_2$, $\textcolor{blue}{C}_3$, $\textcolor{blue}{C}_4$ are connectivity constants, $\sigma(x)=1/(1+\exp(r(x_0-x)))$ – sigmoid function.

Jansen, B. H., and Rit, V. G.,


Electroencephalogram and visual evoked potential generation in a mathematical model of coupled cortical columns, Biol. Cybern., 1995, vol. 73, pp. 357-366.

2.3. МОДЕЛИ ЦЕЛОГО МОЗГА

Human Connectome Project – Создание образа мозга

<http://www.humanconnectomeproject.org>

FIGURE 4 Altered functional connectivity with their possible corresponding functional integration (red lines) or segregation (blue lines) in the IR group. The locations of ACG, SFG, OFG, and TPO are represented by multiple images for two reasons: (1) the sub-regions of TPO are disconnected and located in different hemispheres; and (2) changed functional connections in the ACG, SFG, or OFG were observed in different sub-regions. Detailed brain region connections are shown in Figures S1–S3



Automated anatomical labeling of activations in SPM using a macroscopic anatomical parcellation of the MNI MRI single-subject brain.

**Tzourio-Mazoyer, N., Landeau, B., Papathanassiou, D., (...), Mazoyer, B., Joliot, M.
NeuroImage 15(1), 2002.**

Определено 45 анатомических интересующих объемов (AVOI) в каждом полушарии. Процедура была выполнена с использованием специального программного обеспечения, которое позволило выполнить трехмерное отслеживание хода борозд на отредактированном мозге. 90 AVOI были реконструированы и им была присвоена метка.

Automated anatomical labels (AAL) Tzourio-Mazoyer et al (2002):

Label L/R	Region	Lobe
1/46	Precentral	Central region
2/47	Frontal Sup	Frontal lobe
3/48	Frontal Sup Orb	Frontal lobe
4/49	Frontal Mid	Frontal lobe
5/50	Frontal Mid Orb	Frontal lobe
6/51	Frontal Inf Oper	Frontal lobe
7/52	Frontal Inf Tri	Frontal lobe
8/53	Frontal Inf Orb	Frontal lobe
9/54	Rolandic Oper	Central Region
10/55	Supp Motor Area	Frontal lobe
11/56	Olfactory	Frontal lobe
12/57	Frontal Sup Medial	Frontal lobe
13/58	Frontal Med Orb	Frontal lobe
14/59	Rectus	Frontal lobe
15/60	Insula	Insula
16/61	Cingulum Ant	Limbic lobe
17/62	Cingulum Mid	Limbic lobe
18/63	Cingulum Post	Limbic lobe
19/64	Hippocampus	Limbic lobe
20/65	ParaHippocampal	Limbic lobe
21/66	Amygdala	Sub cort. gray nuc.
22/67	Calcarine	Occipital lobe
23/68	Cuneus	Occipital lobe

24/69	Lingual	Occipital lobe
25/70	Occipital Sup	Occipital lobe
26/71	Occipital Mid	Occipital lobe
27/72	Occipital Inf	Occipital lobe
28/73	Fusiform	Occipital lobe
29/74	Postcentral	Central region
30/75	Parietal Sup	Parietal lobe
31/76	Parietal Inf	Parietal lobe
32/77	Supramarginal	Parietal lobe
33/78	Angular	Parietal lobe
34/79	Precuneus	Parietal lobe
35/80	Paracentral Lobule	Frontal lobe
36/81	Caudate	Sub cort. gray nuc.
37/82	Putamen	Sub cort. gray nuc.
38/83	Pallidum	Sub cort. gray nuc.
39/84	Thalamus	Sub cort. gray nuc.
40/85	Heschl	Temporal lobe
41/86	Temporal Sup	Temporal lobe
42/87	Temporal Pole Sup	Limbic lobe
43/88	Temporal Mid	Temporal lobe
44/89	Temporal Pole Mid	Limbic lobe
45/90	Temporal Inf	Temporal lobe

3. ПРИМЕРЫ

3.1. ЗАДАЧИ (А)-(В). АНАЛИЗ И СИНТЕЗ УПРАВЛЯЕМЫХ НЕЙРОННЫХ МОДЕЛЕЙ

Предыдущие результаты - синхронизация:

T.Carroll. Synchronization and complex dynamics in pulse-coupled circuit models of neurons. Biol. Cybern. 73, 553-559 (1995).

B.Cazelles. Synchronization of a Network of Chaotic Neurons Using Adaptive Control in Noisy Environment. Intern. J. Bifurcation and Chaos, Vol. 08, No. 09, pp. 1821-1830 (1998)

V.Dragoi, I.Grosu, Synchronization of Locally Coupled Neural Oscillators. Neural Processing Letters 7, 199–210 (1998).

Y. Shi, J. Wang, B. Deng, Q. Liu. Chaotic Synchronization of Coupled Hindmarsh-Rose Neurons Using Adaptive Control. IEEE Int.Conf. Biomed. Eng. Informatics, 2009

Le Hoa Nguyen; Keum-Shik Hong. Synchronization of two uncoupled Fitzhugh-Nagumo neurons via nonlinear control. ICCAS 2010.

3.1. ЗАДАЧИ (А)-(В). АНАЛИЗ И СИНТЕЗ УПРАВЛЯЕМЫХ НЕЙРОННЫХ МОДЕЛЕЙ

Предыдущие результаты – другие цели:

P. Danzl and J. Moehlis, Spike timing control of oscillatory neuron models using impulsive and quasi-impulsive charge-balanced inputs, *2008 American Control Conference*, Seattle, WA, USA, 2008, pp. 171-176.

S. Pitchaiah and A. Armaou. Output feedback control of the FitzHugh-Nagumo equation using adaptive model reduction. *IEEE Conf. Dec. Control*, 2010, 864-769.

D. Wilson and J. Moehlis, Optimal chaotic desynchronization for neural populations. *SIAM Journal on Applied Dynamical Systems*, 13, 2014, 276–305.

D. Wilson and J. Moehlis,
Recent advances in the analysis and control of large populations of neural oscillators. *Annual Reviews in Control*, Volume 54, , 2022.

3.1. ЗАДАЧИ (А)-(В). АНАЛИЗ И СИНТЕЗ УПРАВЛЯЕМЫХ НЕЙРОННЫХ МОДЕЛЕЙ

Пример 1. Управляемая синхронизация в двух системах ФицХью-Нагумо

$$\begin{aligned}\varepsilon \dot{u}_1 &= u_1 - \frac{u_1^3}{3} - v_1 + C[u_2(t - \tau(t)) - u_1(t)] + I(t), \\ \dot{v}_1 &= u_1 + a, \\ \varepsilon \dot{u}_2 &= u_2 - \frac{u_2^3}{3} - v_2 + C[u_1(t - \tau(t)) - u_2(t)], \\ \dot{v}_2 &= u_2 + a,\end{aligned}\tag{1}$$

where u_i and v_i , $i = 1, 2$ denote the activator and inhibitor, respectively, ε is the time-scale parameter, a_i , $i = 1, 2$ is the threshold, C is the coupling strength, $\tau(t)$ is slowly-varying delay, i.e., $\dot{\tau} \leq d < 1$.

**S.Plotnikov. Controlled synchronization in two
FitzHugh-Nagumo systems with slowly-varying delays.
Cybernetics and Physics, vol. 4, no. 1, 2015, 21–25.**

3.1. ЗАДАЧИ (А)-(В). АНАЛИЗ И СИНТЕЗ УПРАВЛЯЕМЫХ НЕЙРОННЫХ МОДЕЛЕЙ

Пример 1. Управляемая синхронизация двух систем FHN

Цель управления: $\delta_1(t) \rightarrow 0, \quad \delta_2(t) \rightarrow 0$ as $t \rightarrow \infty$.

где $\delta_1 = u_1 - u_2, \quad \delta_2 = v_1 - v_2,$

choose the control $I(t)$ in form

$$I(t) = -\theta_1 \delta_1(t) + \theta_2 \delta_1(t - \tau),$$

Используется функционал Ляпунова-Красовского:

$$V(t, \Delta(t)) = \varepsilon \delta_1^2 + \delta_2^2 + \theta_0 \int_{t-\tau(t)}^t \delta_1^2(s) ds,$$

3.1. ЗАДАЧИ (А)-(В). АНАЛИЗ И СИНТЕЗ УПРАВЛЯЕМЫХ НЕЙРОННЫХ МОДЕЛЕЙ

Пример 1. Управляемая синхронизация двух систем FHN

Control goal: $\delta_1(t) \rightarrow 0, \quad \delta_2(t) \rightarrow 0, \quad \text{as } t \rightarrow \infty.$

Control algorithm:

$$\begin{aligned} I(t) &= -\theta_1 \delta_1(t) + \theta_2 \delta_1(t - \tau), \\ \theta_1 &> \frac{|\theta_2 - C|}{\sqrt{1-d}} - C + 1. \end{aligned} \quad (8)$$


Thus, the following theorem takes place.

Theorem

Let the delay τ be slowly-varying differential function in the plant (1), i.e., $\dot{\tau} \leq d < 1$. Then the control $I(t)$ in form (6), where parameters $\theta_1 \geq 0$ and θ_2 satisfy the inequality (8), ensures the control goal (4), meaning the substitutions (2).

3.1. ЗАДАЧИ (А)-(В). АНАЛИЗ И СИНТЕЗ УПРАВЛЯЕМЫХ НЕЙРОННЫХ МОДЕЛЕЙ

Пример 1. Управляемая синхронизация двух систем FHN



A new method for controlling synchrony in two delay-coupled FHN-systems is proposed. Applicability conditions of the method are formulated and proved by Lyapunov-Krasovskii functional. Simulation results exhibit fast convergence to synchronous mode.

3.1. ЗАДАЧИ (А)-(В). АНАЛИЗ И СИНТЕЗ УПРАВЛЯЕМЫХ НЕЙРОННЫХ МОДЕЛЕЙ

Пример 2. Управляемая синхронизация сети систем FHN

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

Алгоритм
адапт. управления
для $C_i(t)$ создан
методом скоростного
градиента
с целевой ф-ей:

$$Q(\mathbf{x}(t), t) = \frac{1}{2} \sum_{i=1}^N [u_i(t) - u_{(i+1) \bmod N}(t) + a_i - a_{(i+1) \bmod N}]^2$$

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

3.1. ЗАДАЧИ (А)-(В). АНАЛИЗ И СИНТЕЗ УПРАВЛЯЕМЫХ НЕЙРОННЫХ МОДЕЛЕЙ

Пример 2. Управляемая синхронизация сети систем FHN

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

Алгоритм адаптивного управления:


$$\begin{aligned} C_i(t) = C_i^0 + \frac{\gamma}{\varepsilon} [u_i(t) - u_{(i+1) \bmod N}(t - \tau)] \\ \times [2u_i(t) - u_{(i-1) \bmod N}(t)] \quad i=1, \dots, N \end{aligned}$$

3.1. ЗАДАЧИ (А)-(В). АНАЛИЗ И СИНТЕЗ УПРАВЛЯЕМЫХ НЕЙРОННЫХ МОДЕЛЕЙ

Пример 2. Управляемая синхронизация сети систем FHN

Результаты
моделирования
для $N=10$:

На основе
предложенной целевой
функции и метода
скоростного градиента
(SG) предложен
адаптивный регулятор,
который настраивает
общую силу связи
таким образом, чтобы
синхронизация была
устойчивой, несмотря
на неоднородности



3.1. ЗАДАЧИ (А)-(В). АНАЛИЗ И СИНТЕЗ УПРАВЛЯЕМЫХ НЕЙРОННЫХ МОДЕЛЕЙ дальнейшие результаты группы:

D. Nikitin, I. Omelchenko, A. Zakharova, M. Avetyan, A. Fradkov and E. Schoell. Complex partial synchronization patterns in networks of delay-coupled neurons. Philosophical Trans. Royal Society A, 2019, A 377 (2153), 20180128.

S.A. Plotnikov, A. L. Fradkov. Desynchronization in Oscillatory Networks Based on Yakubovich Oscillatority. IFAC-PapersOnLine, Volume 53, Issue 2, 2020.

Semenov D.M., Fradkov A.L. Adaptive synchronization in the complex heterogeneous networks of Hindmarsh–Rose neurons. Chaos, Solitons & Fractals, Volume 150, Sept. 2021.

3.2 ЗАДАЧА (С). ОЦЕНКА ПАРАМЕТРОВ МОДЕЛИ

Предыдущие результаты:

I. Tyukin, E. Steur, H. Nijmeijer et al.

State and parameter estimation for canonic models of neural oscillators
International Journal of Neural Systems. (2010).

R. Postoyan, M. Chong, D. Nesic, L. Kuhlmann.

Parameter and state estimation for a class of neural mass models
51st IEEE Conf. Decision and Control, Hawaii, USA (2012).

Y. Che, L. Geng, C. Han, S. Cui, 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).

T. Wigren, “Nonlinear identification of neuron models,” 2015 IEEE Conference on Control Applications (CCA), 1340–1346 (2015).

X. Lou, X. Cai, and B. Cui, “Parameter estimation of a class of neural systems with limit cycles,” Algorithms. 11, 169 (2018).

3.2 ЗАДАЧА (С). ОЦЕНКА ПАРАМЕТРОВ МОДЕЛИ

Пример 3. Идентификация параметров нейрона FHN

$$\begin{cases} \dot{u} = u - \frac{u^3}{3} - v + I_{ext}, \\ \dot{v} = \varepsilon(u - a - bv), \end{cases} \quad (1)$$

- ▶ $u(t)$ is the membrane potential,
- ▶ $v(t)$ is an unmeasured variable of slow ion currents responsible for restoring the resting potential of the nerve cell membrane.
- ▶ Unknown parameters: a and b determine the conductance characteristics of ion channels, $\varepsilon > 0$ is the relative velocity change in slow ion currents, I_{ext} is the external current.

Rybalko A., Fradkov A.

Identification of Two-Neuron FitzHugh-Nagumo Model Based on the Speed-Gradient and Filtering. Chaos 2023, Vol.33, Is, 8.

3.2 ЗАДАЧА (С). ОЦЕНКА ПАРАМЕТРОВ МОДЕЛИ

Пример 3. Идентификация параметров нейрона FHN

► $y(t) = cu(t)$, where c is some a priori unknown scaling factor.

► $\ddot{y} = \theta_1^* \dot{y} + 3\theta_2^* y^2 \dot{y} + \theta_3^* y + \theta_4^* y^3 + \theta_5^*$, where
 $\theta^* = \left(1 - \varepsilon b \quad -\frac{1}{3c^2} \quad \varepsilon(b-1) \quad -\frac{\varepsilon b}{3c^2} \quad c\varepsilon(a + bl_{\text{ext}}) \right)^T$.

► Second order filter-differentiator application:

$$\ddot{x} \approx \frac{p^2}{(\tau_1 p + 1)(\tau_2 p + 1)} x, \quad \tau_i > 0 \quad i = 1, 2, \quad p = d/dt.$$

$$y^*(t) = \frac{p^2}{(\tau_1 p + 1)(\tau_2 p + 1)} y(t),$$

$$x_1(t) = \frac{p}{(\tau_1 p + 1)(\tau_2 p + 1)} y(t), \quad x_2(t) = \frac{p}{(\tau_1 p + 1)(\tau_2 p + 1)} y^3(t),$$

$$x_3(t) = \frac{1}{(\tau_1 p + 1)(\tau_2 p + 1)} y(t), \quad x_4(t) = \frac{1}{(\tau_1 p + 1)(\tau_2 p + 1)} y^3(t).$$

$$y^* = \theta_1^* x_1 + \theta_2^* x_2 + \theta_3^* x_3 + \theta_4^* x_4 + \theta_5^* + \Delta \quad (2)$$

3.2 ЗАДАЧА (С). ОЦЕНКА ПАРАМЕТРОВ МОДЕЛИ

Пример 3. Идентификация параметров нейрона FNN

The problem is to build estimates of parameters of (2), $\theta(t) \in \mathbb{R}^5$, which would provide $\theta(t) - \theta^* \rightarrow 0$ for $t \rightarrow \infty$.

The speed-gradient algorithm:

$$\dot{\theta}(t) = -(\theta(t)^T z(t) - y^*(t)) \Gamma z(t), \quad (3)$$

where $z = (x_1 \ x_2 \ x_3 \ x_4 \ 1)^T$, $\Gamma = \Gamma^T > 0$.

Theorem. If the vector function $z(t)$ is persistently excited, i.e. there exists positive numbers L, α, t_0 such that, for every $t > t_0$

$$\int_t^{t+L} z(s)z(s)^T ds \geq \alpha I_m, \quad (4)$$

then the identification law (3) guarantees that $\theta(t) - \theta^* \rightarrow 0$ for $t \rightarrow \infty$.

3.2 ЗАДАЧА (С). ОЦЕНКА ПАРАМЕТРОВ МОДЕЛИ

Пример 3. Идентификация параметров нейрона FHN




Figure 1: Graphs of parameter estimation errors, $\theta_i(t) - \theta_i^*$ $i \in 1 : 5$, of the model (2) for two different sets of true parameter values and initial data obtained with the algorithm (3).

Rybalko A., Fradkov A.

Identification of Two-Neuron FitzHugh-Nagumo Model Based on the Speed-Gradient and Filtering. Chaos 2023, Vol.33, Is, 8.

3.2 ЗАДАЧА (С). ОЦЕНКА ПАРАМЕТРОВ МОДЕЛИ

Пример 4. Идентификация параметров нейромассовой модели

$$\dot{x}_1(t) = x_2(t),$$

$$\dot{x}_2(t) = Aa\sigma(x_3(t) - x_5(t)) - 2ax_2(t) - a^2x_1(t),$$

$$\dot{x}_3(t) = x_4(t),$$

$$\dot{x}_4(t) = Aa[u(t) + C_2\sigma(C_1x_1(t))] - 2ax_4(t) - a^2x_3(t),$$

$$\dot{x}_5(t) = x_6(t),$$

$$\dot{x}_6(t) = BbC_4\sigma(C_3x_1(t)) - 2bx_6(t) - b^2x_5(t),$$

where $\mathbf{x} = (x_1, \dots, x_6)^T \in \mathbb{R}^6$ is a state vector, $u \in \mathbb{R}$ is an input (white noise), while $y = x_3 - x_5 \in \mathbb{R}$ is an output of the whole system. Parameters a and b have fixed values $a = 100 \text{ s}^{-1}$, $b = 50 \text{ s}^{-1}$. Parameters C_1, C_2, C_3, C_4 are connectivity constants, which are connected to each other $C_1 = 1.25C_2 = 4C_3 = 4C_4$. Parameters A and B can be different for various cases of model activity and supposed to be unknown.

Плотников С.А., Фрадков А.Л.

Адаптивная идентификация параметров для класса моделей нейронных ансамблей с применением к эргатическим системам. Мехатроника, автоматизация, управление. 2024. Т. 25. № 1., С.13-18.

3.2 ЗАДАЧА (С). ОЦЕНКА ПАРАМЕТРОВ МОДЕЛИ

Пример 4. Идентификация параметров нейромассовой модели

Adaptive parameter identifier is based on the speed-gradient algorithm.

$$\dot{\hat{x}}_1(t) = \hat{x}_2(t),$$

$$\dot{\hat{x}}_2(t) = \hat{\theta}_1 a \sigma(y(t)) - 2a\hat{x}_2(t) - a^2\hat{x}_1(t),$$

$$\dot{\hat{x}}_3(t) = \hat{x}_4(t),$$

$$\dot{\hat{x}}_4(t) = \hat{\theta}_1 a [u(t) + C_2 \sigma(C_1 \hat{x}_1(t))] - 2a\hat{x}_4(t) - a^2\hat{x}_3(t),$$

$$\dot{\hat{x}}_5(t) = \hat{x}_6(t),$$

$$\dot{\hat{x}}_6(t) = \hat{\theta}_2 b C_4 \sigma(C_3 \hat{x}_1(t)) - 2b\hat{x}_6(t) - b^2\hat{x}_5(t),$$

$$\dot{\hat{\theta}}_1(t) = \frac{\gamma_1 a}{h} [\sigma(y(t)) e_2(t) + u(t) + C_2 \sigma(C_1 \hat{x}_1(t))] (y(t) - y(t-h) - h\hat{x}_4(t) + h\hat{x}_6(t)),$$

$$\dot{\hat{\theta}}_2(t) = \frac{-\gamma_2 b}{h} C_4 \sigma(C_3 \hat{x}_1(t)) (y(t) - y(t-h) - h\hat{x}_4(t) + h\hat{x}_6(t)),$$

where $\hat{\mathbf{x}} = (\hat{x}_1, \dots, \hat{x}_6)^T \in \mathbb{R}^6$ is a state vector of the tunable system; $h > 0$ is a discretization step, γ_1, γ_2 are gains. $\hat{\theta}_1$ and $\hat{\theta}_2$ are tunable parameters.

3.2 ЗАДАЧА (С). ОЦЕНКА ПАРАМЕТРОВ МОДЕЛИ

Пример 4. Идентификация параметров нейромассовой модели. Результаты моделирования




Figure 1: (a): Dynamics of the output of the neural mass model: original model is marked by red color, while tuned model is marked by blue color. (b): Parameter estimation.

3.2 ЗАДАЧА (С). ОЦЕНКА ПАРАМЕТРОВ МОДЕЛИ

Дальнейшие результаты группы:

A.Kovalchukov; A. Fradkov. 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, 2022.

A. Rybalko, A. Fradkov. Parameter Estimation of FitzHugh-Nagumo Neural Networks Based on the Speed-Gradient and Filtering. 11th Int.Conf “Physics and Control”, Istanbul, 2024.

A. Rybalko, A. Fradkov. **BF-NAICS 2024, poster 7, 20/09/2024**

3.3. ЗАДАЧА (D). КЛАССИФИКАЦИЯ СОСТОЯНИЙ И НАМЕРЕНИЙ МОЗГА

Предыдущие результаты (на основе ЭЭГ):

Hassan, F., Hussain, S.F. (2023). Review of EEG Signals Classification Using Machine Learning and Deep-Learning Techniques. In: Qaisar, S.M., Nisar, H., Subasi, A. (eds) Advances in Non-Invasive Biomedical Signal Sensing and Processing with Machine Learning. Springer, Cham.

L. Zhang (2019). EEG Signals Classification Using Machine Learning for The Identification and Diagnosis of Schizophrenia. 2019 41st Annual Intern. Conf. IEEE Engineering in Medicine and Biology Society (EMBC),

3.3. ЗАДАЧА (D). КЛАССИФИКАЦИЯ СОСТОЯНИЙ И НАМЕРЕНИЙ МОЗГА

Пример 5. Диагностика шизофрении на ранней стадии на основе сигналов ЭЭГ и ИИ

Трудности работы с ЭЭГ:

- Сигнал ЭЭГ очень зашумленный, - Данных мало.

Идеи решения:

А) обрабатывать потенциалы, связанные с событиями (ERP), вместо EEG;


В) использовать модель и классификацию на основе МО
Для применения моделей МО были предварительно обработаны ERP, и из ERP были извлечены различные признаки.

- Shanarova N., Pronina M., Lipkovich M., Ponomarev V., Müller A., Kropotov J. Application of Machine Learning to Diagnostics of Schizophrenia Patients Based on Event-Related Potentials // Diagnostics. — 2023. — Vol. 13, Is. 3.

- Shanarova et al – BF-NAICS 2024, poster 26, 20/09/2024

3.3. ЗАДАЧА (D). КЛАССИФИКАЦИЯ СОСТОЯНИЙ И НАМЕРЕНИЙ МОЗГА

Пример 5 (продолж.) Диагностика шизофрении



Несколько моделей были обучены на полученном наборе признаков. Лучшая модель была получена методом опорных векторных машин (SVM) с чувствительностью и специфичностью 91% и 90,8% соответственно.

3.3. ЗАДАЧА (D). КЛАССИФИКАЦИЯ СОСТОЯНИЙ И НАМЕРЕНИЙ МОЗГА

Дальнейшие результаты:

**Lipkovich M, et al. Detecting of intent to make a
two-stage movement,
BF-NAICS 2024, poster 1, 20/09/2024**

Пример 6: Коннектом и сеть Ландау-Стюарта

Joana Cabral, Francesca Castaldo, **Karl Friston**, Gustavo Deco et al
Metastable oscillatory modes emerge from interactions in the brain space-time connectome. COMMUNICATIONS PHYSICS (2022) 5:184

Авторы пересматривают механистическую гипотезу о том, что переходные ритмы мозга являются признаком метастабильной синхронизации, происходящей на сниженных коллективных частотах из-за задержек между областями мозга. Они используют сеть Ландау-Стюарта с $N=90$:

$$\frac{dZ_n}{dt} = Z_n[a + i\omega - |Z_n|^2] + K \sum_{p \neq n}^N C_{np} [Z_p(t - \tau_{np}) - Z_n(t)] + \beta\eta_1 + i\beta\eta_2, \forall n \in N,$$

((ссылаясь на:

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).)

Основанные на физике осцилляторов с задержкой, их численный анализ демонстрирует, как взаимодействия между локально генерируемыми быстрыми колебаниями в пространственно-временной структуре коннектома могут привести к возникновению коллективных мозговых ритмов, организованных в пространстве и времени.

Пример 7:

FitzHugh–Nagumo oscillators on complex networks mimic epileptic-seizure-related synchronization phenomena


Moritz Gerster, Rico Berner, Jakub Sawicki, Anna Zakharova, Antonín Škoch, Jaroslav Hlinka, K. Lehnertz and Eckehard Schöll.

...мы моделируем 90 областей человеческого мозга, отмеченных в атласе Automated Anatomical Labeling (AAL)⁴², сетью из $N = 90$ узлов, где каждая область мозга описывается осциллятором FHN, включающим активаторную переменную (мембранный потенциал) u_k и ингибиторную переменную (переменная восстановления) v_k . Мы располагаем области мозга $k = 1, 2, \dots, 90$ таким образом, что $k \in NL = \{1, \dots, 45\}$ соответствует левому, а $k \in NR = \{46, \dots, 90\}$ соответствует правому полушарию мозга. Динамика переменных u_k и v_k затем задается как

$$\varepsilon \dot{u}_k = u_k - \frac{u_k^3}{3} - v_k + \sigma \sum_{j=1}^N A_{kj} [B_{uu}(u_j - u_k) + B_{uv}(v_j - v_k)]$$

$$\dot{v}_k = u_k + a + \sigma \sum_{j=1}^N A_{kj} [B_{vu}(u_j - u_k) + B_{vv}(v_j - v_k)],$$

Сравнение результатов моделирования и измерений ЭЭГ



- (a) 90 областей мозга AAL
- (b) Вид сверху на мозг: черные точки — расположение электродов.
- (c) Вид снизу на мозг
- (d) Запись ЭЭГ типичного абсансного приступа
- (e) Моделируемый глобальный параметр порядка Курамото r в зависимости от времени (временной интервал 30 с) черным цветом во время одного смоделированного приступа.
- (f) То же, что на панели (e) для записи ЭЭГ в (d).

Пример 8: Настройка моделей мозга по данным ЭЭГ

1. A. Rybalko, A. Sagatdinov, "Modeling of Movement-Related Evoked Potentials by Identification of The Fitzhugh-Nagumo Model", 31st Saint Petersburg Intern. Conf, Integrated Navigation Systems (ICINS 2024), pp. 231-232, 2024.
2. A. Kovalchukov. Approximate Hindmarsh-Rose model identification: application to EEG data, DCNA, IEEE Kaliningrad, pp.155-158, 2023.

ЗАДАЧА (Е). НЕЙРОИНТЕРФЕЙСНОЕ УПРАВЛЕНИЕ МАШИНАМИ НА ОСНОВЕ МОДЕЛИ МОЗГА

Предыдущие результаты:

Овод И.В., Осадчий А.Е., Пупышев А.А., Фрадков А.Л. Формирование нейрообратной связи на основе адаптивной модели активности головного мозга. *Нейрокомпьютеры*, 2012, 2, С.36-41.

R.Mamunur, S. Norizam, ... K.Sabira et al. Current Status, Challenges, and Possible Solutions of EEG-Based Brain-Computer Interface: A Comprehensive Review. *Frontiers in Neurorobotics*. 2020. vol 14. no. 25.

Värbu K., Muhammad N., Muhammad Y. Past, Present, and Future of EEG-Based BCI Applications. *Sensors*. 2022. vol. 22. no. 9.

Fernández-Rodríguez Á., Velasco-Álvarez F., Ron-Angevin R. Review of real brain-controlled wheelchairs. *Neural Engineering*. 2016. vol. 13. no. 6.

H. Wang, Fan Yan, Tao Xu, A. Bezerianos. Brain-Controlled Wheelchair Review. *IEEE Access*. 2021.vol.9.

Yadav H., Maini S. Electroencephalogram based brain-computer interface: Applications, challenges, and opportunities. *Multimedia Tools and Applications*.2023.vol. 82.

ЗАДАЧА 5. УПРАВЛЕНИЕ МАШИНАМИ НА ОСНОВЕ МОДЕЛИ МОЗГА





Figure 2. Experimental setup and Software schematics - 1

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

НЕЙРОИНТЕРФЕЙСНОЕ УПРАВЛЕНИЕ МАШИНАМИ



НЕЙРОИНТЕРФЕЙСНОЕ УПРАВЛЕНИЕ МАШИНАМИ



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.

НЕЙРОИНТЕРФЕЙСНОЕ УПРАВЛЕНИЕ МАШИНАМИ



МЕТОДЫ КИБЕРНЕТИЧЕСКОЙ НЕЙРОНАУКИ

Кибернетические методы включают методы линейного управления, нелинейного управления, стохастического управления, надежного управления, адаптивного управления, интеллектуального управления и т. д. Кибернетические методы включают также методы оценки переменных и параметров систем, фильтрации, оптимизации, распознавания образов и машинного обучения и т. д.

SPEED-GRADIENT METHOD

$$\text{System : } \dot{x} = F(x, u), \quad x \in R^n, u \in R^m, t \geq 0 \quad (1)$$

$$\text{Goal : } Q(x(t)) \rightarrow 0 \text{ as } t \rightarrow \infty \quad (2)$$

Step 1: Evaluate speed of change of $Q(x)$

along (1): $\dot{Q} = \partial Q / \partial x F(x, u)$.

Step 2: Evaluate Speed – gradient w.r.t. $u : \nabla_u \dot{Q}$

SGA : *a)* $\dot{u} = -\Gamma \nabla_u \dot{Q}, \quad \Gamma = \Gamma^T > 0 \quad (3)$
(diff. form, 1979)

SGA : *b)* $u = -\Psi(\nabla_u \dot{Q}) \quad (4)$
(finite form, 1985)

$$\Psi(z)^T z > 0 \quad \text{if } z \neq 0, \text{ e.g. } \Psi(z) = \gamma z, \quad \Psi(z) = \gamma \text{sign } z$$

ЗАКЛЮЧЕНИЕ-1

- 1 Кибернетическая нейронаука является важной и быстрорастущей областью вычислительной нейронауки**
- 2 Дальнейшие направления исследований:**
 - Адаптивное нейробиоуправление**
 - Адаптивные и обучающиеся системы, управляемые мозгом (см. A.M. Annaswamy and A. L. Fradkov. A Historical Perspective of Adaptive Control and Learning. Annual Reviews in Control, 52, 2021)**
 - Коэволюция мозга и машины (гибридный интеллект)**

ЗАКЛЮЧЕНИЕ-2


Теория управления, зародившаяся в начале двадцатого века, оказалась незаменимой основой биологических наук, и ожидается, что ее значимость будет экспоненциально расти с развитием вычислительной нейронауки.

[Jonathon R. Howlett, · Martin P. Paulus. Out of control: computational dynamic control dysfunction in stress and anxiety-related disorders. Discover Mental Health (2024) 4:5.]

СПАСИБО ЧЛЕНАМ КОЛЛЕКТИВА!



Сергей
Плотников



Михаил
Липкович




Борис
Андриевский



Николай
Бабич



Данила
Семенов



Александр
Ковальчуков



Александр
Семенов



Александра
Рыбалко



Надежда
Шанарова



Артур
Сагатдинов

Студенты СПбГУ: Катя Марзель, Олег Чен, Влад Чулкин, Рита Грунина