

РОССИЙСКАЯ АКАДЕМИЯ НАУК
МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РОССИЙСКОЙ ФЕДЕРАЦИИ
ГОСУДАРСТВЕННАЯ КОРПОРАЦИЯ ПО АТОМНОЙ ЭНЕРГИИ «РОСАТОМ»
РОССИЙСКАЯ АССОЦИАЦИЯ НЕЙРОИНФОРМАТИКИ
НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ЯДЕРНЫЙ УНИВЕРСИТЕТ «МИФИ»
НАУЧНО-ИССЛЕДОВАТЕЛЬСКИЙ ИНСТИТУТ СИСТЕМНЫХ ИССЛЕДОВАНИЙ РАН

НЕЙРОИНФОРМАТИКА-2015

ХVII ВСЕРОССИЙСКАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ с международным участием

СБОРНИК НАУЧНЫХ ТРУДОВ

ЧАСТЬ 3

- **НЕЙРОСЕТЕВЫЕ СИСТЕМЫ ОБРАБОТКИ ДАННЫХ,
РАСПОЗНАВАНИЯ ОБРАЗОВ И УПРАВЛЕНИЯ**
- **НЕЙРОБИОЛОГИЯ**
- **ТЕОРИЯ НЕЙРОННЫХ СЕТЕЙ**
- **АДАПТИВНОЕ ПОВЕДЕНИЕ И ЭВОЛЮЦИОННОЕ
МОДЕЛИРОВАНИЕ**

МОСКВА

УДК 001(06)+004.032.26(06)
ББК 72Я5+32.818Я5
М 82

**XVII ВСЕРОССИЙСКАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ
"НЕЙРОИНФОРМАТИКА-2015": Сборник научных трудов.** В 3-х частях.
Ч. 3. М.: НИЯУ МИФИ, 2015. – 220 с.

Сборник научных трудов содержит доклады, включенные в программу XVII ВСЕРОССИЙСКОЙ НАУЧНО-ТЕХНИЧЕСКОЙ КОНФЕРЕНЦИИ «НЕЙРОИНФОРМАТИКА-2015», проходившей в г. Москве 19–23 января 2015 г. Тематика конференции охватывает широкий круг вопросов: методические вопросы нейронинформатики, теория нейронных сетей, нейробиология, модели адаптивного поведения и когнитивные исследования, нейронные сети для управления, обработки изображений, временных рядов и другие приложения нейронинформатики.

Во третью часть включены доклады, посвященные исследованиям в нейробиологии, теоретическим исследованиям искусственных нейронных сетей и их применению для решения прикладных задач обработки данных. Также в сборник вошли доклады, посвященные адаптивному поведению и эволюционному моделированию.

Ответственный редактор *А.Г. Трофимов*

Статьи получены до 25 октября 2014 года.
Материалы издаются в авторской редакции.

ISBN 978-5-7262-2045-1

© Национальный исследовательский
ядерный университет «МИФИ», 2015

Оригинал-макет подготовлен *Е.Н. Кочубей*

Подписано в печать 20.11.2014. Формат 60×84 1/16.
Печ. л. 13,75. Тираж 150 экз. Заказ № 184.

*Национальный исследовательский ядерный университет «МИФИ»
Типография НИЯУ МИФИ
115409, Москва, Каширское ш., 31*

ОРГАНИЗАТОРЫ КОНФЕРЕНЦИИ

- Российская академия наук
- Министерство образования и науки Российской Федерации
- Государственная корпорация по атомной энергии «Росатом»
- Российская ассоциация нейроинформатики
- Национальный исследовательский ядерный университет «МИФИ» (НИЯУ МИФИ)
- Научно-исследовательский институт системных исследований РАН (НИИСИ РАН)
- Московский авиационный институт (национальный исследовательский университет), МАИ
- Государственный научный центр РФ Троицкий институт инновационных и термоядерных исследований (ГНЦ РФ ТРИНИТИ)

ОРГАНИЗАЦИОННЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель – Президент НИЯУ МИФИ Оныкий Б. Н. (НИЯУ МИФИ)
Зам. председателя – Проректор НИЯУ МИФИ Петровский А. Н. (НИЯУ МИФИ)
Сопредседатель – Мишулина О. А. (НИЯУ МИФИ)
Сопредседатель – Тюменцев Ю. В. (МАИ)
Акад. РАН Бетелин В. Б. – НИИСИ РАН, Москва
Акад. РАН Евтушенко Ю. Г. – ВЦ РАН, Москва
Загребаяев А. М. – НИЯУ МИФИ
Трофимов А. Г. – НИЯУ МИФИ
Ушаков В. Л. – НИЦ «Курчатовский институт», Москва
Бесчастный Л.Л. – НИЯУ МИФИ
Халалов В. И. – НИЯУ МИФИ
Ученый секретарь – Бесхлебнова Г. А. (НИИСИ РАН, Москва)

ПРОГРАММНЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель – чл.-корр. РАН Крыжановский Б. В. (НИИСИ РАН, Москва)
Зам. председателя – Дунин-Барковский В. Л. (НИИСИ РАН, Москва)
Зам. председателя – Редько В. Г. (НИИСИ РАН, Москва)
Чл.-корр. РАН Анохин К. В. – НИЦ «Курчатовский институт», Москва
Чл.-корр. РАН Балабан П. М. – Институт высшей нервной деятельности
и нейрофизиологии РАН (ИВНД и НФ РАН), Москва
Бурцев М. С. – НИЦ «Курчатовский институт», Москва
Введенский В. Л. – НИЦ «Курчатовский институт», Москва
Чл.-корр. РАН Величковский Б. М. – НИЦ «Курчатовский институт», Москва
Головко В. А. – Брестский государственный технический университет, Республика
Беларусь
Доленко С. А. – НИИ ядерной физики им. Д.В. Скобельцына МГУ
Ежов А. А. – ГНЦ РФ ТРИНИТИ, Москва
Жданов А. А. – Институт точной механики и вычислительной техники
им. С.А. Лебедева РАН, Москва
Чл.-корр. РАН Иваницкий А. М. – ИВНД и НФ РАН, Москва
Каганов Ю. Т. – МГТУ им. Н. Э. Баумана
Казанович Я. Б. – Институт математических проблем биологии РАН, Пущино, Моск. обл.
Литинский Л. Б. – НИИСИ РАН, Москва
Макаренко Н. Г. – Главная астрономическая обсерватория РАН, Санкт-Петербург
Максимов В. В. – Институт проблем передачи информации им. А.А. Харкевича РАН,
Москва
Мишулина О. А. – НИЯУ МИФИ
Нечаев Ю. И. – Научно-исследовательский институт экспериментальной медицины
РАМН, Санкт-Петербург
Прохоров Д. В. – Toyota Research Institute, USA
Чл.-корр. РАН Рудаков К. В. – Вычислительный центр им. А.А. Дородницына РАН,
Москва
Самарин А. И. – НИИ нейрокибернетики им. А.Б. Когана, Ростов-на-Дону
Терехов С. А. – ООО «Нейрок Техсофт», Москва
Трофимов А. Г. – НИЯУ МИФИ
Тюменцев Ю. В. – МАИ
Ушаков В. Л. – НИЦ «Курчатовский институт», Москва
Чижов А. В. – Физико-технический институт им. А.Ф. Иоффе РАН, Санкт-Петербург
Фролов А. А. – ИВНД и НФ РАН, Москва
Шумский С.А. – Физический институт им. П.Н. Лебедева РАН, Москва
Яхно В. Г. – Институт прикладной физики РАН, Нижний Новгород

СПИСОК РЕЦЕНЗЕНТОВ

1. Бесхлебнова Г. А. – *Научно-исследовательский институт системных исследований РАН, Москва*
2. Бурцев М. С. – *Национальный исследовательский центр «Курчатовский институт», Москва*
3. Васильков В. А. – *НИИ нейрокибернетики им. А.Б. Когана Южного федерального университета, Ростов-на-Дону*
4. Витяев Е. Е. – *Новосибирский государственный университет*
5. Доленко С. А. – *НИИ ядерной физики им. Д.В. Скобельцына МГУ им. М.В. Ломоносова, Москва*
6. Дунин-Барковский В. Л. – *Научно-исследовательский институт системных исследований РАН, Москва*
7. Ежов А. А. – *Государственный научный центр Российской Федерации Троицкий институт инновационных и термоядерных исследований (ГНЦ РФ ТРИНИТИ)*
8. Каганов Ю. Т. – *Московский государственный технический университет им. Н.Э. Баумана*
9. Казанович Я. Б. – *Институт математических проблем биологии РАН, Пушкино, Московская обл.*
10. Карандашев Я. М. – *Научно-исследовательский институт системных исследований РАН, Москва*
11. Киселев И. И. – *Научно-исследовательский институт системных исследований РАН, Москва*
12. Котов В. Б. – *Научно-исследовательский институт системных исследований РАН, Москва*
13. Кошур В. Д. – *Сибирский федеральный университет, Красноярск*
14. Крыжановский В. М. – *Научно-исследовательский институт системных исследований РАН, Москва*
15. Литинский Л. Б. – *Научно-исследовательский институт системных исследований РАН, Москва*
16. Макаренко Н. Г. – *Главная астрономическая обсерватория РАН, Санкт-Петербург*
17. Мальсагов М. Ю. – *Научно-исследовательский институт системных исследований РАН, Москва*
18. Мишулина О. А. – *Национальный исследовательский ядерный университет «МИФИ», Москва*

19. Парин С. Б. – *Нижегородский государственный университет им. Н.И. Лобачевского*
20. Полевая С. А. – *Нижегородская государственная медицинская академия*
21. Ратушняк А. С. – *Конструкторско-технологический институт вычислительной техники СО РАН, Новосибирск*
22. Редько В. Г. – *Научно-исследовательский институт системных исследований РАН, Москва*
23. Смирнитская И. А. – *Научно-исследовательский институт системных исследований РАН, Москва*
24. Соловьева К. П. – *Научно-исследовательский институт системных исследований РАН, Москва*
25. Станкевич Л. А. – *Санкт-Петербургский государственный политехнический университет*
26. Тарков М. С. – *Институт физики полупроводников им. А.В. Ржанова СО РАН, Новосибирск*
27. Терехов С. А. – *ЗАО «Связной Логистика», Москва*
28. Трофимов А. Г. – *Национальный исследовательский ядерный университет «МИФИ», Москва*
29. Тюменцев Ю. В. – *Московский авиационный институт (национальный исследовательский университет)*
30. Ушаков В. Л. – *Национальный исследовательский центр «Курчатовский институт», Москва*
31. Чижов А. В. – *Физико-технический институт им. А.Ф. Иоффе РАН, Санкт-Петербург*
32. Шакиров В. В. – *Научно-исследовательский институт системных исследований РАН, Москва*
33. Шапошников Д. Г. – *НИИ нейрокибернетики им. А.Б. Когана Южного федерального университета, Ростов-на-Дону*
34. Шумский С. А. – *Физический институт им. П.Н. Лебедева РАН, Москва*

Уважаемые коллеги!

Конференция НЕЙРОИНФОРМАТИКА вновь собирает исследователей, работающих по актуальным направлениям теории и приложений искусственных нейронных сетей. Как и на предыдущих наших собраниях, в этом году на конференции НЕЙРОИНФОРМАТИКА-2015 представлены доклады по проблемам теории нейронных сетей, нейробиологии, моделям адаптивного поведения, нейросетевому моделированию объектов и систем, обработке статистических данных, временных рядов и изображений и многим другим прикладным задачам нейроинформатики.

Более 200 российских ученых и наших зарубежных коллег направили в оргкомитет конференции результаты своих исследований.

По сложившейся традиции конференцию открывают приглашенные доклады. В рамках школы-семинара участники конференции прослушают лекции известных специалистов по актуальным проблемам нейроинформатики. На рабочем совещании участники конференции обсудят теоретические модели в нейробиологии.

Особое внимание уделяется работам студентов, аспирантов и молодых специалистов, которые примут участие в творческом конкурсе.

За прошедшие годы российская конференция НЕЙРОИНФОРМАТИКА сложилась как представительный и многоплановый по тематике научный форум. В его работе принимают участие и известные ученые, и молодые специалисты, аспиранты и студенты. Желаем всем участникам конференции плодотворной работы, активного сотрудничества и новых творческих идей.

Оргкомитет

СОДЕРЖАНИЕ

Секция 5

НЕЙРОСЕТЕВЫЕ СИСТЕМЫ ОБРАБОТКИ ДАННЫХ, РАСПОЗНАВАНИЯ ОБРАЗОВ И УПРАВЛЕНИЯ

КРЫЖАНОВСКИЙ В. М., МАЛЬСАГОВ М. Ю., ЖЕЛАВСКАЯ И. С. Скалярное нейросетевое дерево в задаче поиска ближайшего соседа в бинарном пространстве высокой размерности	11
КОВАЛЬЧУК А. В., БАХЧИНА А. В., ПОЛЕВАЯ С. А. Спектральный анализ неравномерных временных рядов в кардиоинтервалографии для отображения вегетативного обеспечения активности человека	21
ИВАШИНА Е. А., КОРЛЯКОВА М. О., ПРОКОПОВ Е. Ю. Формирование ассоциации нейронных сетей для решения задачи стереореконструкции в бортовой системе технического зрения	29
ЭНГЕЛЬ Е. А. Энергосберегающая технология электротехнической системы на базе адаптивного нейроконтроллера	38
САВЧЕНКО А. В., МИЛОВ В. Р. Об одном подходе к последовательному иерархическому распознаванию изображений	50

Стендовая сессия 4

НЕЙРОБИОЛОГИЯ

КОТОВ В. Б. Использование нейронов с двумя входами в генераторе последовательностей внутренних образов	59
ВОРОНКОВ Г. С. Малоизвестный загадочный феномен в зрении: описание и попытка анализа	69
ЛАВРОВ В. В., РУДИНСКИЙ А. В. Межнейронная коммуникативная система: контекстное поле кодирования информации	79
СМИРНИТСКАЯ И. А. Об одном распространенном нейросетевом мотиве	89

ПОКРОВСКИЙ А. Н.

Пресинаптические компоненты вызванного потенциала
коры мозга 97

Стендовая сессия 5

ТЕОРИЯ НЕЙРОННЫХ СЕТЕЙ

ГОЛОЩАПОВ В. И.

Ансамбли синапсов как кандидаты на роль структур, кодирующих
признаки в искусственных нейронных сетях 106

ШИБЗУХОВ З. М., ЧЕРЕДНИКОВ Д. Ю.

О моделях искусственных нейронов агрегирующего типа 117

КИСЕЛЕВ М. В.

Применение эмпирических моделей для построения импульсных
нейронных сетей с заданными свойствами 126

Стендовая сессия 6

**АДАПТИВНОЕ ПОВЕДЕНИЕ И ЭВОЛЮЦИОННОЕ
МОДЕЛИРОВАНИЕ**

АНФИЛЕЦ С. В., ШУТЬ В. Н.

Использование искусственных иммунных систем
для оптимизации управления светофорным циклом 137

РЕДЬКО В. Г., НЕПОМНЯЩИХ В. А., ОСИПОВА Е. А.,

ШАРИПОВА Т. И., БЕСХЛЕБНОВА Г. А.

Моделирование формирования предсказаний у рыб,
изучающих лабиринты 145

АНОХИН М. Н.

Разработка нейроподобной системы управления модельным
агентом в динамической среде 153

Секция 6

НЕЙРОБИОЛОГИЯ

КОЗУНОВ В. В., ОСАДЧИЙ А. Е.

GALA, новый подход к решению обратной задачи в рамках
группового исследовательского анализа МЭГ данных 163

РАТУШНЯК А. С., ПРОСКУРА А. Л., ЗАПАРА Т. А. Анализ и возможные пути реинженеринга самоорганизующихся нейронных систем на основе конвергенции технологий	174
ЧИЖОВ А. В. Анализ чувствительности нейрона к входным сигналам с помощью модели ансамбля нейронов	184
БИБИКОВ Н. Г., НИЗАМОВ С. В. Временные признаки звука, вызывающие ответы нейронов слуховой системы	191
ДИК О. Е., ГЛАЗОВ А. Л. Мультифрактальный анализ тремора руки человека при двигательной патологии	200
ПОДЛАДЧИКОВА Л. Н., КОЛТУНОВА Т. И., ШАПОШНИКОВ Д. Г. Особенности локальных элементов траекторий осмотра изображений: объектно-возвратные фиксации взгляда	210
Именной указатель авторов	220

Секция 5

Нейросетевые системы обработки данных, распознавания образов и управления

**В. М. КРЫЖАНОВСКИЙ, М. Ю. МАЛЬСАГОВ,
И. С. ЖЕЛАВСКАЯ**

Научно-исследовательский институт системных исследований РАН, Москва
vladimir.krizhanovsky@gmail.com, magomed.malsagov@gmail.com,
irina.zhelavskaya@skolkovotech.ru

СКАЛЯРНОЕ НЕЙРОСЕТЕВОЕ ДЕРЕВО В ЗАДАЧЕ ПОИСКА БЛИЖАЙШЕГО СОСЕДА В БИНАРНОМ ПРОСТРАНСТВЕ ВЫСОКОЙ РАЗМЕРНОСТИ

Рассматривается задача поиска ближайшего соседа в бинарном пространстве высокой размерности. Для решения поставленной задачи предлагается и исследуется нейросетевое дерево. Узлами дерева являются перцептроны. Получена оценка сверху вероятности ошибки алгоритма. Нейросетевое дерево сравнивается по скорости работы с полным перебором. Получены аналитические оценки скорости работы алгоритма.

Ключевые слова: *поиск ближайшего соседа, перцептрон, дерево поиска, иерархический классификатор, мульти-классовый классификатор.*

**V.M. KRYZHANOVSKIY, M.YU. MALSAGOV,
I.S. ZELAVSKAYA**

Scientific Research Institute for System Analysis RAS, Moscow
vladimir.krizhanovsky@gmail.com, magomed.malsagov@gmail.com,
irina.zhelavskaya@skolkovotech.ru

SCALAR NEURAL NETWORK TREE FOR NEAREST NEIGHBOR SEARCH PROBLEM IN HIGH-DIMENSIONAL BINARY SPACE

Nearest neighbor search problem in high-dimensional binary space is considered. To solve this problem neural network tree is proposed and studied. Perceptrons are nodes of tree. Upper bound of algorithm error probability is obtained. Neural network tree is compared with exhaustive search. Theoretical estimations of algorithm computational complexity are obtained.

Keywords: *nearest neighbor search, perceptron, search tree, hierarchical classifier, multi-class classification.*

Введение

Данная работа посвящена решению задачи поиска ближайшего соседа в бинарном пространстве высокой размерности. Фактически требуется выбрать точку из набора, которая расположена ближе всех к некоторой запросной точке. Эта задача широко известна и возникает в различных областях науки и техники. Для ее решения предложено множество точных и приближенных алгоритмов, таких как LSH, k-d tree, spill-tree. Тем не менее, нет эффективного метода решения поставленной задачи в бинарном пространстве, когда точка в пространстве задается вектором с компонентами $\{0;1\}$ или $\{-1;1\}$.

В работе [1] показано, что применение известных алгоритмов к данной задаче приводит к неудовлетворительным результатам. Эти методы не способны решать задачу в бинарном пространстве быстро или надежно. В основном это связано с тем, что методы разрабатывались для работы с малоразмерными либо сильно неоднородными данными.

Ниже предлагается древовидный алгоритм, в узлах которого расположены перцептроны, способные решать задачу поиска ближайшего соседа в бинарном пространстве высокой размерности.

Постановка задачи

Пусть задан набор из M случайных бинарных векторов \mathbf{X}_μ размерности N с компонентами

$$x_{\mu i} = \{\pm 1\}, \mu = 1, \dots, M; i = 1, \dots, N. \quad (1)$$

На вход системы подается некоторая запросная точка – вектор \mathbf{X} .

Необходимо найти ближайший к вектору \mathbf{X} эталонный вектор \mathbf{X}_μ . Близость точек (векторов) в бинарном пространстве будем определять расстоянием Хемминга.

Описание алгоритма

Построение и обучение нейросетевого дерева. Корень дерева – это перцептрон с N входными нейронами и двумя выходными. Все множество эталонных точек разбивается на два равных непересекающихся подмножества. Весовые коэффициенты, соединяющие входные нейроны с

первым выходным нейроном, обучаются по правилу Хебба [2] на эталонах первого подмножества, а коэффициенты ко второму выходному нейрону – на втором подмножестве. Для простоты представления будем называть первый выходной нейрон левым, а второй – правым. На следующем уровне дерева уже два, аналогичные корневому, персептрона. Один из персептронов теперь обучен на эталонах левого корневого выходного нейрона, а другой на эталонах правого. Так, слой за слоем, дерево разрастается, а число эталонов в персептронах уменьшается, пока на каждый выход персептрона не останется по одному эталону. Эти выходы назовем *лепестками дерева*, а путь перехода от какого-либо узла до лепестка назовем *веткой дерева*. Число операций на создание и обучение всего дерева:

$$\Theta = 2MN \log_2 M . \quad (2)$$

Поиск по дереву. На корневой узел подается входной вектор – запросная точка. Вычисляется величина сигналов на выходных нейронах – скалярное произведение вектора весовых коэффициентов и входного вектора. Затем определяется выход с наибольшим по модулю сигналом. Выход с меньшим сигналом запоминается в «пуле проигравших». «Пул проигравших» содержит идентификаторы узлов и величины сигналов, соответствующих им нейронов, которые не были выбраны для дальнейшего спуска. Далее запросная точка подается на персептрон, связанный с выходом-победителем. Эта процедура спуска по веткам дерева продолжается, пока не будет достигнут лепесток дерева. В лепестке содержится номер эталона и величина скалярного произведения этого эталона на входной вектор. Эти данные сохраняются еще в одном хранилище – «пул ответов». Однако достижение лепестка не является условием остановки алгоритма. Критерием остановки в нейросетевом дереве является условие

$$\mathbf{xx}_\mu \geq (1 - 2b_{\max}) N , \quad (3)$$

μ – номер эталона, ассоциированного с лепестком дерева. Параметр b_{\max} будет рассмотрен ниже.

Таким образом, если полученный в результате спуска эталон не будет удовлетворять критерию остановки, алгоритм продолжит поиск. Для этого в «пуле проигравших» выбирается узел с наибольшим сигналом, и с него начинается новый спуск по дереву до нового лепестка. Сам стартовый узел удаляется из «пула проигравших». Такой бег по дереву от стартового узла до лепестка повторяется, пока не выполнится критерий остановки, либо все дерево не будет обойдено. После остановки в «пуле ответов» выбирается эталон с наибольшим сигналом и считается ответом системы.

Стоит пояснить наличие в алгоритме «пула ответов». Могут быть случаи, когда ни один эталон не удовлетворяет критерию остановки. Тогда

будет пройдено все дерево, а «пул ответов» будет содержать все эталоны. В результате, в качестве ответа системы будет выбран наиболее подходящий эталон. Такой исход крайне редок, но возможен из-за сильного искажения входного вектора, либо неудачного выбора параметров в критерии остановки. С другой стороны, можно добавить условие, чтобы алгоритм остановился после нескольких срабатываний критерия, или просто после нескольких дополнительных спусков по дереву после срабатывания критерия. Такой подход имеет смысл, когда важна надежность поиска, а не скорость.

Остановимся подробнее на параметре b_{\max} . Этот параметр указывает, на каком максимальном расстоянии от запросной точки может находиться эталон, чтобы считаться правильным ответом. То есть при $b_{\max} = 0,5$ точка будет охватывать половину всего пространства вокруг себя, а при $b_{\max} = 0$ – необходимо точное совпадение. Параметр этот выбирается пользователем, однако, если он окажется меньше реального отклонения запросной точки от правильного эталона, то система не найдет правильный ответ. В работе [3] показывается, что правильный выбор b_{\max} может на несколько порядков повысить надежность работы системы. Тем не менее, удалось получить оценку верхней границы параметра b_{\max} в зависимости от данных задачи:

$$b_{\max} < \frac{1}{2} \left(1 - \sqrt{\frac{2}{N} \ln \left[\frac{M-1}{P_{\max} \sqrt{2\pi N}} \right]} \right). \quad (4)$$

Здесь N – размерность пространства, M – число эталонов, сохраненных в дереве, P_{\max} – максимально допустимая вероятность ошибки распознавания, обычно выбирается меньше $1/M$.

Вероятность ошибки

Пока не удалось оценить вероятность ошибки предлагаемого алгоритма. Однако можно оценить эту ошибку сверху. Нейросетевое дерево может ошибиться в том случае, если в наборе паттернов присутствует более одного эталона, удовлетворяющих критерию (3). Формально вероятность этого события можно выразить следующим образом:

$$P^* = 1 - \Pr \left[\bigcap_{m=1}^{M-1} |\mathbf{X}\mathbf{X}_m| < (1 - 2b_{\max})N \right]. \quad (5)$$

Наличие таких паттернов не всегда приводит к ошибке алгоритма. Поэтому вероятность (5) можно использовать как оценку вероятности ошибки предлагаемого алгоритма сверху.

Выражение (5) можно преобразовать к виду:

$$P^* = 1 - \left\{ 1 - \sum_{k=0}^{b_{\max} N} \frac{C_N^k}{2^{N-1}} \right\}^{M-1}. \quad (6)$$

Однако использование формулы (6) при больших значениях $N > 200$ не представляется возможным. Для больших размерностей удобнее пользоваться приближенным выражением:

$$P^* < \frac{2M}{\sqrt{2\pi\tilde{N}}} \exp\left(-\frac{\tilde{N}}{2}\right), \quad \tilde{N} = N(1 - 2b_{\max})^2. \quad (7)$$

Из формулы (7) видим, что вероятность ошибки алгоритма экспоненциально убывает с ростом размерности задачи N . Например, при $N = 500$ и $b_{\max} = 0,3$ показатель экспоненты равен -40 . Это объясняет то, почему в работе [3] не получалось экспериментально измерить ошибку при больших размерностях. Фактически, на больших размерностях ($N \geq 500$) предложенный древовидный алгоритм можно условно считать точным.

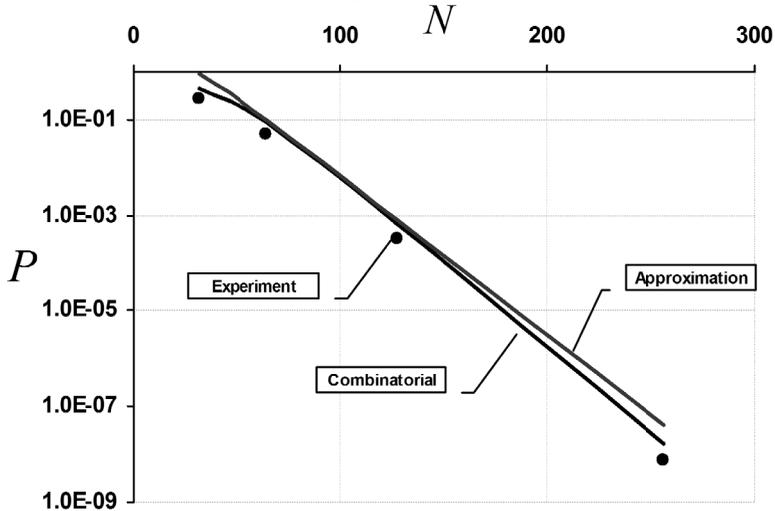


Рис. 1. Вероятность ошибки нейросетевого дерева поиска

На рис. 1 представлена зависимость вероятности ошибки алгоритма от размерности N при $b_{\max} = 0,3$ и $M = N$. Как и предполагалось выше, вероятность ошибки алгоритма (маркеры) меньше вероятностей, полученных по формулам (6) и (7) (сплошные линии). Следовательно, полученные выражения (6) и (7) можно использовать для оценки надежности работы

алгоритма. Более того, видно, что выражение (7) достаточно точно аппроксимирует выражение (6).

Вычислительная сложность

Оценка вычислительной сложности предложенного алгоритма – это нетривиальная задача, решить которую пока не удалось. Однако можно получить несколько оценочных выражений. Для начала заметим, что, как и в полном переборе, так и в нейросетевом дереве основная доля вычислений приходится на подсчет скалярных произведений векторов, и это число операций зависит только от размерности и всегда постоянно. Поэтому сравнивать алгоритмы будем в количествах скалярных произведений. Чтобы определить ближайший эталон к запросной точке, его необходимо сравнить с каждым эталоном. Таким образом, вычислительная сложность полного перебора составит

$$\theta_{III} = M. \quad (8)$$

Для скалярного нейросетевого дерева (СНСТ) получить единую оценку нельзя. В худшем случае необходимо будет произвести вычисления по всему дереву. Тогда максимальная вычислительная сложность составит

$$\theta_{СНСТ}^{\max} = 2M. \quad (9)$$

С другой стороны, в лучшем случае ответ можно получить после первого же спуска. Тогда минимальная вычислительная сложность составит

$$\theta_{СНСТ_1}^{\min} = 2 \lfloor \log_2 M \rfloor \quad \text{и} \quad \theta_{СНСТ_2}^{\min} = 2 \lceil \log_2 M \rceil. \quad (10)$$

Здесь $\lfloor x \rfloor$ и $\lceil x \rceil$ обозначают округление до ближайшего целого меньше x и округление до ближайшего целого больше x соответственно.

Два значения возникают, когда число эталонов не кратно степеням двойки, тогда некоторые ветки становятся длиннее других. Когда дерево сбалансировано, оба выражения дают один и тот же результат.

Выражения (8) и (9) позволяют определить максимальное ускорение, которое можно достичь, используя нейросетевое дерево вместо полного перебора. Также стоит заметить, что предлагаемый алгоритм в худшем случае может оказаться лишь в 2 раза медленнее полного перебора. Однако эксперименты показали, что вероятность такого исхода составляет менее 0,5 %.

На рис. 2 показано распределение отношения вычислительной сложности полного перебора θ_{III} к скалярному нейросетевому дереву $\theta_{СНСТ}$. На рисунке показана только крайняя правая часть распределения. Распределение это быстро затухающее, максимум приходится на крайние две

точки, которые соответствуют первому спуску по дереву. Эти точки хорошо согласуются с выражением (10). Таким образом, с вероятностью 30 % дерево выдаст ответ в 385 раз быстрее полного перебора. В конкретном примере среднее ускорение нейросетевого дерева составило 26 раз, а с вероятностью 86 % ускорение окажется больше среднего. Конечно, были случаи, когда алгоритм оказался медленнее полного перебора – вероятность этого 0,6 %. В ходе тестирования алгоритм ни разу не ошибся – вероятность ошибки равна нулю.

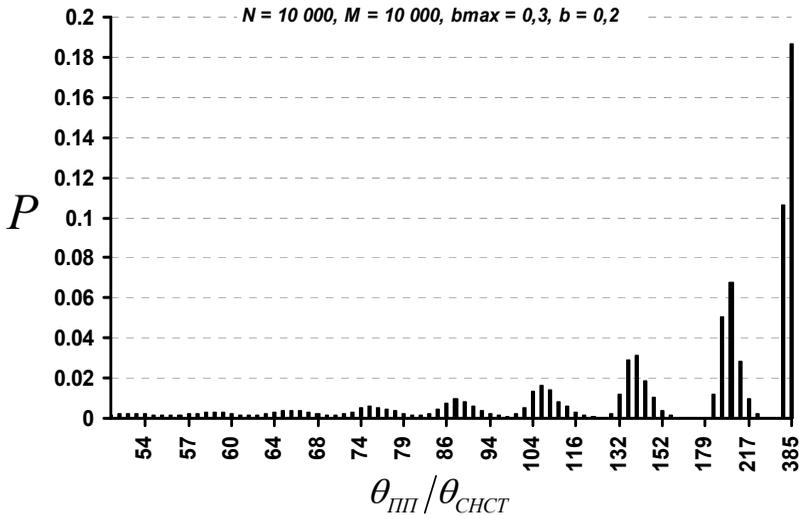


Рис. 2. Распределение отношения числа скалярных произведений полного перебора к нейросетевому дереву

В работе [3] было показано, что поставленную задачу эффективно можно решить только двумя алгоритмами: полным перебором всех эталонных векторов и нейросетевым деревом. Предложенный нейросетевый алгоритм с подавляющей вероятностью работает быстрее полного перебора, однако в процессе поиска могут совершаться ошибки. Согласно полученным в предыдущем разделе результатам, если размерность обрабатываемых векторов велика ($N \geq 500$ бит), то вероятность ошибки столь мала, что ею можно пренебречь. Поэтому даже незначительное по скорости работы превосходство нейросетевого дерева над полным перебором делает выбор в пользу первого.

Заметим, что, хотя минимальная и максимальная вычислительная сложность дерева не зависит от размерности задачи (в единицах числа скалярных произведений), средняя вычислительная сложность все-таки ведет себя иначе. Действительно, в зависимости от соотношения числа эталонов M и их размерности N сильно меняется надежность перцептронов в узлах дерева, что сказывается на количестве спусков по дереву. Получить аналитическое выражение средней скорости алгоритма пока не удалось. Тем не менее, можно аппроксимировать экспериментальные данные выражением

$$\theta = M \exp\{1.3 + b - (0.44 - 0.4b) \log_2 N\}. \quad (11)$$

На рис. 3 показана зависимость отношения вычислительной сложности полного перебора к сложности нейросетевого дерева от размерности задачи для различного уровня искажений входного вектора. Маркерами отмечены экспериментальные данные, а сплошные линии построены по формуле (11).

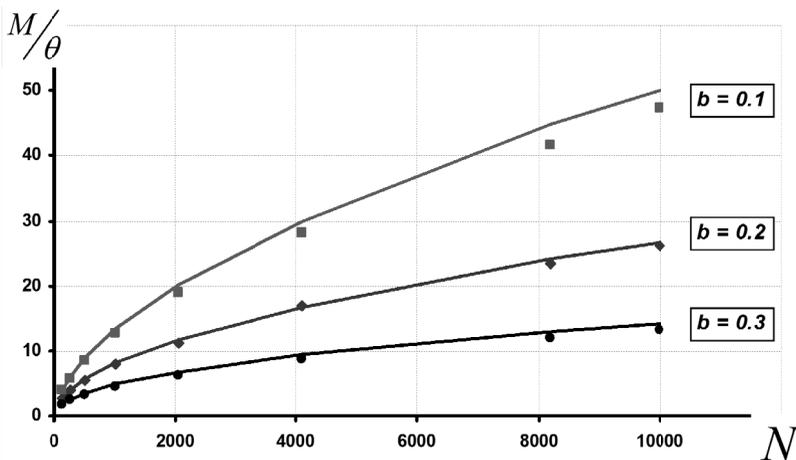


Рис. 3. Превосходство по скорости работы нейросетевого дерева над полным перебором в зависимости от размерности задачи

Таким образом, становится возможным оценить преимущество скалярного нейросетевого дерева по скорости над полным перебором для больших параметров задачи. В табл. 1 приведен пример такой оценки, где

видно, что использование нейросетевого дерева позволит в десятки и сотни раз увеличить скорость решения.

Таблица 1

Превосходство по скорости работы нейросетевого дерева над полным перебором, $M = N = 10^5$, $b_{\max} = 0,3$, используется формула (8)

b	M/θ
0,1	189
0,2	88
0,3	41

Заключение

Разработан древовидный алгоритм на основе нейронных сетей для решения задачи поиска ближайшего соседа в бинарном пространстве высокой размерности. На этапе обучения создается дерево, узлами которого являются перцептроны. Каждый перцептрон обучается на своем подмножестве эталонов, которое уменьшается с каждым уровнем. Такой подход позволяет постепенно сузить область поиска, а ассоциативные способности перцептрона позволяют направлять поиск.

Удалось оценить сверху вероятность ошибки нейросетевого дерева. Аналитический анализ показал, что вероятность ошибки экспоненциально падает с ростом размерности задачи. Так уже при размерности больше 500 ошибка алгоритма столь мала, что не поддается экспериментальному определению. Таким образом, предложенный алгоритм демонстрирует высокую степень надежности.

Получены выражения для максимальной и минимальной вычислительной сложности алгоритма. В худшем случае нейросетевое дерево может производить поиск медленнее полного перебора не более чем в 2 раза, однако, вероятность этого события составляет менее 0,5%. Также удалось аппроксимировать среднюю вычислительную сложность алгоритма, что позволит априори оценить преимущества использования дерева при больших параметрах задачи.

В данной работе предлагается простейшая модель алгоритма без каких-либо улучшений и оптимизаций. Дальнейшая работа будет направлена на увеличение числа выходов корневого элемента узла. Такой подход

должен снизить нагрузку на персептрон в корне дерева и, тем самым, уменьшить число лишних спусков по дереву. Однако нельзя безмерно увеличивать число выходов, так как это сведет весь алгоритм к полному перебору. Поэтому потребуется определить оптимальное число выходов корневого персептрона. Так как данные принадлежат бинарному пространству, то логично использовать бинарную арифметику для ускорения вычислений. Сделать это в персептроне тяжело из-за того, что весовые коэффициенты являются целыми числами. Однако в работах [4-5] исследуются процедуры бинаризации, которые позволят избавиться от целочисленных коэффициентов. Тем самым появляется возможность дальнейшего ускорения работы алгоритма.

Работа поддержана РФФИ (грант 12-07-00295а) и проектами ОНИТ РАН 1.8 и 2.1.

Список литературы

1. Kryzhanovsky V., Malsagov M., and Tomas J. A. C. Hierarchical Classifier: Based on Neural Networks Searching Tree with Iterative Traversal and Stop Criterion // Optical Memory and Neural Networks (Information Optics), 2013. V. 22. No. 4. P. 217–223.
2. Hopfield J.J. Neural networks and physical systems with emergent collective computational abilities // Proc. Nat. Acad. Sci. USA, 1982. V. 79. P. 2554-2588.
3. Kryzhanovsky V., Malsagov M., Tomas J. A. C., Zhelavskaya I. High-Dimensional Binary Pattern Classification by Scalar Neural Network Tree // Proc. of 24th International Conference on Artificial Neural Networks. Springer. Germany. 2014. P. 169-177.
4. Крыжановский, В.М. Исследование векторных нейронных сетей с бинаризованными синаптическими коэффициентами для задач обработки информации и принятия решения: дисс. ... к.ф.-м.н., М. 2010.
5. Мальсагов, М.Ю. Применение дискретизации для решения задач бинарной оптимизации с помощью нейронной сети Хопфилда: дисс. ... к.ф.-м.н., М. 2012.

А.В. КОВАЛЬЧУК¹, А.В. БАХЧИНА², С.А. ПОЛЕВАЯ³

¹Институт прикладной физики РАН, Нижний Новгород

²Нижегородский государственный университет им. Н.И. Лобачевского

³Нижегородская государственная медицинская академия

aka.xzib1t@gmail.com, nastya18-90@mail.ru, polevaia@ipfran.ru

СПЕКТРАЛЬНЫЙ АНАЛИЗ НЕРАВНОМЕРНЫХ ВРЕМЕННЫХ РЯДОВ В КАРДИОИНТЕРВАЛОГРАФИИ ДЛЯ ОТОБРАЖЕНИЯ ВЕГЕТАТИВНОГО ОБЕСПЕЧЕНИЯ АКТИВНОСТИ ЧЕЛОВЕКА¹

Для оценки неравномерных рядов ритмограммы используются различные способы их редукции к регулярной временной сетке, такие как сглаживание, аппроксимация значений и т.д. Хотя качество таких методов оказывается достаточным при использовании квазиравномерных ритмограмм, в случае динамичных изменений сердечного ритма, вызванных нормальным функционированием в социальной среде, такие подходы могут давать некорректные результаты. В работе рассматривается способ спектральной оценки временных рядов ритмограммы, который позволил бы с достаточной полнотой проводить их дальнейший спектральный анализ.

Ключевые слова: *временные ряды, спектральный анализ, вариабельность сердечного ритма, нестационарные процессы.*

A.V. KOVALCHUK¹, A.V. BAHCHINA², S.A. POLEVAYA³

¹The Institute of Applied Physics of the Russian Academy of Sciences, Nizhny Novgorod

²N.I. Lobachevsky State University of Nizhni Novgorod

³Nizhny Novgorod State Medical Academy

aka.xzib1t@gmail.com, nastya18-90@mail.ru, polevaia@ipfran.ru

SPECTRAL ANALYSIS OF CARDIOINTERVALOGRAPHY OF UNEVEN TIME SERIES FOR ESTIMATION OF HUMAN ACTIVITY VEGETATIVE SUPPORT

Basic methods of rhythmogram spectrum estimation use well developed regular time series theory. There are different methods of reduction to a regular time grid, such as smoothing, approximation values, etc. Although the quality

Работа выполнена при частичной поддержке гранта РФФИ 14-06-00390_а и проекта РНФ 14-11-00693.

of these methods is sufficient when using a quasi-uniform rhythmograms but in the case of dynamic changes of heart rate caused by the normal functioning in the social environment may give incorrect results. The paper presents a method of spectral estimation of rhythmogram time series that permits a further spectral analysis with sufficient details.

Keywords: *time series, spectral analysis, heart rate variability, non-stationary processes.*

Введение

Развитие методов математической обработки кардиоинтервалограмм закономерно привело к обнаружению большого количества показателей (статистических, геометрических, частотных), которые, с одной стороны, тесно коррелируют друг с другом, делая весь набор избыточным, а с дру-

гой – пригодны для интерпретации и оценки кардиосигнала только в стационарных условиях [1]. Важно, что использовавшиеся до настоящего времени методы обработки ритмограмм обладают низким разрешением по времени и не могут быть применены для поиска вегетативных отображений быстрых, краткосрочных когнитивных и эмоциональных процессов.

В XX в. отечественные физиологи (В.М. Бехтерев, К.М. Быков, В.Н. Черниговский) убедительно демонстрировали наличие кортиковисцеральных связей, обеспечивающих быстрые перенастройки кардиоритма при смене целевых функций [2]. Позднее была предложена нейровисцеральная интегративная модель (рис. 1), связывающая изменения сердечного ритма не столько с состоянием сердца, но

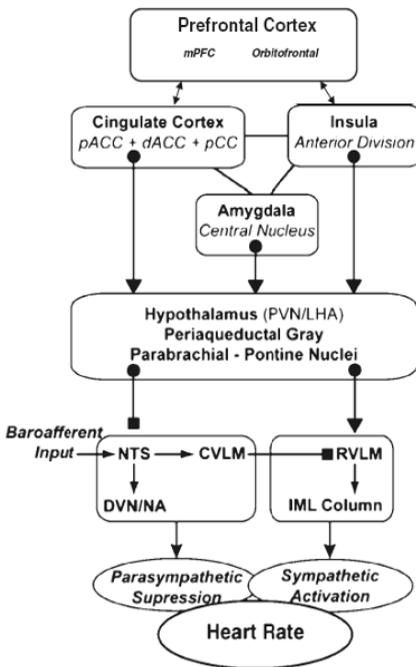


Рис. 1. Нейровисцеральная интегративная модель управления ритмом сердца (по [3])

гораздо больше с состоянием мозга [3]. Описано множество нервных структур, связанных с сердечным ритмом.

Данные, на которых основываются эти результаты, включали исследования на животных, исследования людей с локальными мозговыми поражениями, физиолого-фармакологический анализ, а также работы с методами нейровизуализации (ПЭТ, фМРТ) (примеры в табл. 1). Соответственно, логично предполагать, что множественные feed-back и feed-forward связи между ними создают сложную структуру информационных циклов, которая имеет отражение в динамике сердечного ритма.

Таблица 1

Примеры исследований, в которых осуществляется поиск связей между структурами головного мозга и сердечным ритмом (СР) [3]

Первый автор	Метод нейровизуализации	Измерение СР	Экспериментальная задача (контекст)
Critchley, 2003	фМРТ	непрерывно	отрицательная обратная связь + моторная активность
Gianaros, 2004	ПЭТ	непрерывно	оперативная память
Matthews, 2004	фМРТ	дискретно	тест Струпа
Neuman, 2006	фМРТ	дискретно	лица Экмана
O'Connor, 2007	фМРТ	дискретно	моторная активность
Napadow, 2008	фМРТ	непрерывно	печаль (слова)
Lane, 2009	ПЭТ	непрерывно	эмоциональные и нейтральные видеоролики
Ahs, 2009	ПЭТ	непрерывно	публичное выступление

Важно заметить, что помимо классических частотных диапазонов (VLF 0,01-0,04 Гц; LF 0,04-0,15 Гц; HF 0,15-0,4 Гц), ряд авторов в последние годы обращает внимание на присутствие в спектре variability сердечного ритма (BCR) очень высокочастотных колебаний: от 0,6 до 2 Гц. Анализ очень высокочастотной составляющей спектра ритмограммы показал информативность этих диапазонов для контроля функционального состояния пациентов в контексте послеоперационного восстановления [4]. Другие исследования демонстрируют наличие сверхвысокочастотных компонентов (VHF – very high frequency) в структуре спектра variability сердечного ритма не только у больных, но и у здоровых людей [5].

В работе рассматривается способ спектральной оценки временных рядов, который успешно применяется для анализа неравномерных времен-

ных рядов в астрономии [6] и может быть полезен для анализа ритмограмм при исследовании вегетативного обеспечения активности человека в различных динамических контекстах.

Спектральный анализ неравномерных временных рядов в кардиоинтервалографии

Оригинальный сигнал, используемый для спектрального анализа, может быть представлен в форме ряда временных интервалов между ударами $X = \{x_k\}_{k=1}^N$. Тогда ряд

$$T = \left\{ \sum_{p=1}^k x_p \right\}_{k=1}^N$$

описывает моменты ударов, а пара $\{X, T\}$ – двумерная форма временного ряда ритмограммы.

В работе мы будем рассматривать ритмограмму как результат модулирования собственного ритма сердца некоторым управляющим сигналом $m(t)$. Этот сигнал может быть представлен в виде конечного гармонического ряда, если рассматривать управление как набор циклических процессов [3]:

$$m(t) = \sum_{p=0}^P A_p \cos(2\pi\omega_p t + \varphi_p), \quad 0 \leq t \leq T.$$

Периоды ритма в моменты t_k могут быть определены в соответствии с формулой:

$$x_k = \tau + m(t_k), \quad t_k \in T,$$

где τ – собственный ритм сердца. Задача нахождения спектра мощности ритмограммы эквивалентна поиску спектра функции $m(t)$, в условиях неравномерности измерений, вызванных суперпозицией с функцией управления.

Классический метод получения спектра такого сигнала предусматривает выравнивание временной сетки T с помощью заранее заданного шага и аппроксимацию значений X в соответствии с сеткой. Отметим, что искажения, вносимые таким методом в оценку спектра мощности сигнала, несущественны в низкочастотной части и нарастают в высокочастотной.

Более точную оценку спектра можно получить, воспользовавшись оценкой для периодограммы Шустера:

$$D(\omega) = \frac{1}{N^2} \left| \sum_{k=0}^{N-1} x_k e^{-i2\pi\omega t_k} \right|^2.$$

Связь между периодограммой и спектром мощности выражает теорема Димминга [7] и может быть записана в виде:

$$D(\omega) = \int_{-\infty}^{\infty} g(\omega') W(\omega - \omega') d\omega' + D_0(\omega),$$

$$W(\omega) = \frac{1}{N^2} \left| \sum_{k=0}^{N-1} e^{-i2\pi\omega t_k} \right|^2,$$

где $g(\omega')$ – спектр мощности, $W(\omega)$ – спектральное окно, $D_0(\omega)$ – статистическая поправка оценки периодограммы, в рассматриваемых ситуациях пренебрежимо мала [8]. Из данного соотношения следует, что периодограмма есть комбинация истинного спектра и спектрального окна, а структура периодограммы определяется видом спектрального окна.

Рассмотрим основные варианты спектрального окна и их следствия.

Равномерная временная сетка. В случае равномерного распределения отсчетов находим, что спектральное окно определяется выражением:

$$W(\omega) = \frac{\sin^2(N\pi\omega\tau)}{N^2 \sin^2(\pi\omega\tau)},$$

где τ – период дискретизации сигнала. Нетрудно показать, что $W(\omega)$ периодическая, с периодом $\omega_c = 1/\tau$ и шириной лепестка $\omega_l = 2/N\tau$. Периодограмма в этом случае называется истинным спектром, и определяется частотой Найквиста $\left[-\frac{\omega_c}{2}, \frac{\omega_c}{2} \right]$. Кроме того, периодограмма содержит

боковые пики симметричного спектра на частоте $\pm k\omega_c$, $k = 1, 2, \dots$. Применительно к ритмограмме, этот факт означает появление симметричного спектра на кратных частотах дискретизации равномерного ряда.

Слабая неравномерность. В случае, если отклонения соседних отсчетов незначительны $\alpha = \max \left(\frac{\Delta t_k}{t_k} \right) \ll 1$, вид спектрального окна также изменяется незначительно:

$$W(\omega) = \frac{\sin^2(N\pi\omega\tau)}{N^2 \sin^2(\pi\omega\tau)} + \alpha\omega W_0(\omega).$$

Этот результат дает возможность использовать периодограмму как оценку спектра, по аналогии с равномерной временной сеткой. Заметим,

что искажения периодограммы нарастают с ростом частоты, а боковые пики теряют симметрию с истинным спектром.

Сильная неравномерность. В общем случае спектральное окно содержит центральный пик на 0 частоте, а также шумовой компонент на всем диапазоне [8]. Как правило, интенсивность шумовых пиков сравнительно невысока, но, в случае низкой мощности истинного спектра, периодограмма претерпевает значительные искажения.

Экспериментально установлено, что периодограммы сердечного ритма, полученные в стационарных условиях, а также ригидный ритм, обладают достаточно высокой степенью регулярности временных отсчетов. Периодограмма соответствует чистому спектру в диапазоне частот $\left[\frac{2}{N\tau}, \frac{1}{2\tau} \right]$, где τ – минимальный период между ударами.

Интересной особенностью периодограммы в нестационарных условиях поведения человека является сохранение периодичности спектрального окна с увеличением интенсивности шума в большинстве значимых измерениях. При этом с ростом частоты влияние шумов увеличивается, что характерно для временного ряда со слабой неравномерностью. Анализ корреляции основного и боковых пиков периодограммы показывает разрушение симметричной структуры пиков спектрального окна в моменты изменения режима сердечного ритма (например, в переходе состояний “лежа”–“сидя”). Диапазон анализа в нестационарных условиях разумно выбирать на уровне 2–5 % перцентилей в выборке.

Как уже говорилось выше, в нестационарных условиях оценка спектра мощности по периодограмме вычисляется некорректно. Из оценок для слабой неравномерности становится ясно, что ошибка вычислений растет с ростом частоты и максимальна вблизи границы ω_c . Поэтому анализ высокочастотных составляющих периодограммы в ряде случаев не дает необходимой точности для определения состояния системы. В работе проведен анализ двумя методами. В основе первого метода лежит алгоритм очистки спектра CLEAN, впервые предложенный [9]. Второй метод основан на регуляризации временной сетки пилообразным сигналом, который позволяет уменьшить влияние неравномерностей рядов на высокочастотную часть спектра.

Выводы

Представленная работа имеет целью показать основные методы спектрального анализа ритмограмм, полученных в условиях свободного поведения человека, и возникающие при этом отличия от классического спо-

соба анализа. С ростом доступности индивидуальных датчиков сердечного ритма растет и актуальность этих проблем.

Как показывает проведенный анализ и эксперименты, структуры спектра ритмограмм имеют существенные различия при стационарных и динамических измерениях (рис. 2).

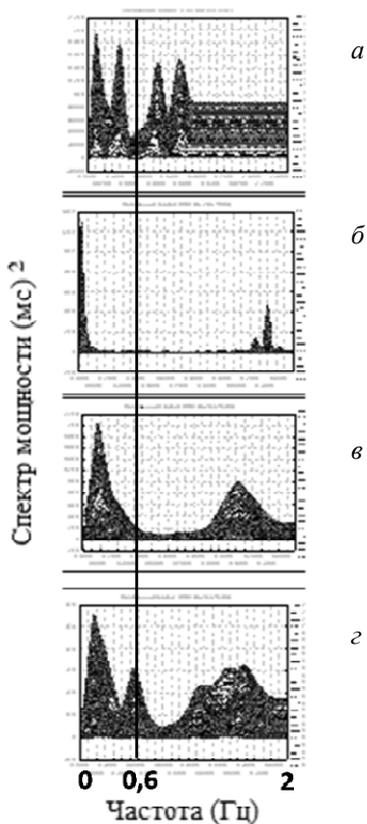


Рис. 2. Особенности спектра variability сердечного ритма в различных целевых контекстах: лежа (*а*); переход из "лежа" к "стоя" (*б*); в положении сидя при выполнении теста (*в*, *г*). "Часы с поворотом" (*в*) и теста "Сенсомоторные реакции на звук" (*г*). Изменение соотношения низкочастотного диапазона (до 0,6 Гц) и сверхвысокочастотного диапазона (0,6-2 Гц) спектра при переходе от стационарного контекста (лежа) к динамическим

При исследовании ритмограмм в условиях свободного поведения человека, а также для анализа ритмограммы в реальном времени (уменьшения задержки, увеличение временного разрешения), анализ высокочастотных компонент более эффективен и показателен. Принципиально, что перед исследованием сверхвысокочастотной области спектра мощности (VHF) в переходных состояниях необходимо проводить “очистление” спектра от помех, вызванных неравномерностью временного ряда. Напротив, при стационарных измерениях фактор неравномерности ряда оказывает меньшее влияние на общепринятый диапазон анализа, где успешно используется стандартная периодограмма Шустера.

Список литературы

1. Бань, А.С., Парамонова, Н.А., Загородный, Г.М., Бань, Д.С. Анализ взаимосвязи показателей variability ритма сердца // Военная медицина: научно-практический рецензируемый журнал/ Белорусский государственный медицинский университет. Минск: Красико-Принт, 2010. № 4. С. 21-24.
2. Чернавский Д.С. Синергетика и информация. Динамическая теория информации. УРСС, 2009.
3. Thayer, J.F., Åhs, F., Fredrikson, Sollers, M.J.J., Wager, T.D. A meta-analysis of heart rate variability and neuroimaging studies: Implications for heart rate variability as a marker of stress and health // Neuroscience and Biobehavioral Reviews, 2012. № 36. P. 747–756.
4. Toledo, E., Pinhas, I., Aravot, D., Akselrod, S. Very high frequency oscillations in the heart rate and blood pressure of heart transplant patients // Med. Biol. Eng. Comput., 2003. № 41. P. 432–438.
5. Божокин, С.В., Лесова, Е.М., Самойлов, В.О., Толкачев П.И. Вейвлет-анализ нестационарной variability сердечного ритма при проведении пассивной ортостатической пробы // Биофизика, 2012. Т. 57. № 4. С. 696–712.
6. Терещук В.Ю. Анализ временных рядов в астрофизике. М.: Наука, 1992.
7. Deeming T.J. Fourier analysis with unequally-spaced data // Astrophys. and Space Sci., 1975. V. 36. P. 137-158.
8. Витязев В.В., Прудникова Е.Я. Спектры скважности астро-метрических рядов наблюдений // Вестн. С.-Петерб. ун-та, 1994. Сер. 1. Вып. 2, N 8. С. 78-86.
9. Roberts D.H., Lehar J., Dreher J.W. Time Series Analysis with CLEAN. I. Derivation of a Spectrum // Astrophys. J., 1987. № 4. P. 968-989.

Е.А. ИВАШИНА, М.О. КОРЛЯКОВА, Е.Ю. ПРОКОПОВ

Калужский филиал МГТУ им. Н.Э. Баумана
mkorlyakova@yandex.ru

ФОРМИРОВАНИЕ АССОЦИАЦИИ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РЕШЕНИЯ ЗАДАЧИ СТЕРЕОРЕКОНСТРУКЦИИ В БОРТОВОЙ СИСТЕМЕ ТЕХНИЧЕСКОГО ЗРЕНИЯ

Предложено решение задачи стереорекострукции координат объектов сцены на основе анализа стереопары их проекций. Моделирование процедуры стереорекострукции проведено в условиях виртуальной сцены с учетом ошибок определения координат проекций, полученных при калибровке реальной стереопары камер. Рассмотрены результаты формирования решателя на основе бустинга и модели анализа неоднородности ошибок нейростей.

Ключевые слова: *ассоциация нейронных сетей, ошибки обобщения, обучение нейронных сетей.*

E.A. IVASHINA, M.O. KORLYAKOVA, E.YU. PROKOPOV

Bauman Moscow State Technical University Kaluga Branch
mkorlyakova@yandex.ru

GENERATION OF THE NEURAL NETWORKS ASSOCIATION FOR THE STEREO RECONSTRUCTION FOR ON BOARD TECHNICAL VISION SYSTEMS

Proposed solution of for the stereo reconstruction of coordinates of scene objects is based on the analysis of a stereo pair of projections. The process of stereo reconstruction was modeled in virtual scene with projections errors estimated from real cameras calibration. The results of the synthesis of the solver based on boosting and inhomogeneity error analysis of the neural network was presents.

Keywords: *the neural networks association, the generalization error, training of neural networks.*

Введение

Автономные мобильные системы, такие как автомобили с автопилотами и мобильные роботы, должны иметь постоянное обновление потока информации о внешней среде для успешного решения задачи ориентации и навигации. Использование не визуальных систем ориентации не всегда удобно и обосновано. В первую очередь среды, ориентированные на человека, содержат огромное количество визуальной информации, поддерживающей процессы ориентации. К такой информации можно отнести указатели, знаки, разметку, цвет объектов и их форму. Во-вторых, решение задач навигации и ориентации за счет, например, бесплатформенных инерциальных систем приводит к накоплению существенной ошибки определения скорости и координат от времени автономной работы [1]. В-третьих, системы, связанные с анализом среды на базе эхолокации или лазерной дальнометрии, создают активный сигнал, который может воздействовать на другие объекты сцены или отслеживаться, что не всегда допустимо. В свою очередь, системы технического зрения позволяют рассматривать сцену пассивно, а ошибка анализа сцены не зависит от времени и определяется только аппаратной и алгоритмической базой.

Современные системы технического зрения, ориентированные на работу на борту мобильного транспортного средства, существенно ограничены в вычислительных ресурсах и времени, предоставляемом для решения задач анализа видеопотока. При этом необходимо обеспечивать требуемую точность решения. Например, для задачи ориентации в среде приходится рассматривать последовательные стереопары снимков, а частота выдачи решения должна быть не менее 0.5-1 Гц для наземных транспортных средств с ошибкой не более 0.01 дальности [2]. Повышение скорости обработки видеоинформации на борту возможно за счет применения нейросетевых моделей обработки, как в [3-5], где вычислительная сложность задачи переносится на этап обучения. Решение задачи ориентации состоит из нескольких этапов [4]:

- предобработка кадров, которая обычно занимает 5-10 % общего времени обработки и хорошо реализуется в нейросетевом базисе [5],
- поиск сопряженных точек в стереопаре, занимает 60-70 % времени, но также реализуем в нейросетях,
- определение координат объектов сцены за счет стереорекострукции.

Ошибки этапа поиска сопряженных пар точек приводят к появлению существенного искажения координат и значительному росту времени поиска решения [4]. Необходимо построить решение, устойчивое к ошибкам

и не требовательное к ресурсам системы. Такое решение может быть получено на основе использования нейросетевой аппроксимации зависимости трехмерных координат объектов от стереопары их проекций [5]. Однако, необходимо рассмотреть возможности повышения качества решения задачи стереорекострукции на всех участках глубины сцены.

Постановка задачи нейросетевой стереорекострукции точек

Рассмотрим систему камер (стереопару), которая генерирует проекционные модели сцены с двух ракурсов [6]. Камеры заданы в форме матриц преобразования мировой системы координат в системы внутренних координат P и P' . Если считать, что мировая система координат совпадает с видовой системой координат камеры C , то камеры стереопары связаны между собой на этапе калибровки соотношением

$$P = K[I | 0], P' = K'[R' | t'],$$

где K, K' – матрицы центральной проекции камер (содержат параметры внутренней калибровки камер), R' – матрица поворота камеры C' относительно камеры C , t' – вектор переноса C' по C .

Таким образом, вся стереопара привязана к системе видовых координат камеры C . Любая точка $\langle X, Y, Z, 1 \rangle$ пространства однородных координат в процессе проецирования на камеры C' и C подвергается следующему преобразованию

$$\begin{cases} \langle x, y, 1 \rangle = P \langle X, Y, Z, 1 \rangle, \\ \langle x', y', 1 \rangle = P' \langle X, Y, Z, 1 \rangle, \end{cases} \quad (1)$$

где $\langle x, y \rangle, \langle x', y' \rangle$ – координаты проекции точки $\langle X, Y, Z, 1 \rangle$ на камеры C и C' соответственно.

При идеальном знании $\langle x, y \rangle, \langle x', y' \rangle$ процедура восстановления координат $\langle X, Y, Z \rangle$ сводится к решению системы линейных уравнений и имеет единственное решение. Однако координаты проекций известны в форме $\langle x, y \rangle_{\text{измерение}} = \langle x, y \rangle + \langle \epsilon_x, \epsilon_y \rangle$, где $\langle \epsilon_x, \epsilon_y \rangle$ – ошибки поиска проекций (в рассматриваемой модели они достигают 10-20 пикселей). Это приводит к усложнению процедуры поиска $\langle X, Y, Z \rangle$. Как показано в [6], можно получить решение в форме нейросетевой аппроксимации системы уравнений (1), но средняя ошибка нейросети для координат от глубины имеет нелинейную зависимость от дальности по Z (рис. 1), что не соответствует

логике модели (1). Хотя средняя ошибка стереореконструкции не превышает 10% дальности, но она неоднородна по глубине.

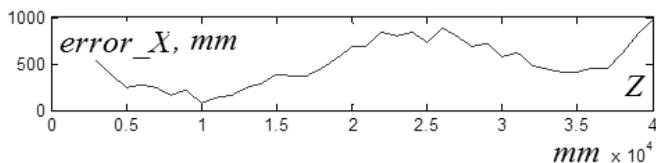


Рис. 1. Средняя абсолютная ошибка нейронной сети при стереореконструкции точки

Необходимо обеспечить не более чем линейную зависимость ошибки координат от глубины. На вход нейросетевого решателя подавали координаты $\langle x, y \rangle_{\text{измерение}}$, $\langle x', y' \rangle_{\text{измерение}}$, которые получены за счет моделирования в виртуальной сцене стереопары камер с параметрами калибровки, получаемыми для реальной стереопары, и ошибок алгоритма сопряжения левого и правого кадров $\langle \varepsilon_x, \varepsilon_y \rangle \in [-20, +20]$. Дальность моделируемой сцены составила от 0.5 до 40 м. Представленное на рис.1 решение получено на 25000 примерах, для нелинейной двухслойной сети с 12 нейронами скрытого слоя. Таким образом, очевидно, что даже значительный размер выборки не обеспечил монотонности ошибки стереореконструкции по глубине. Рассмотрим варианты повышения качества решения за счет использования решателей более сложной структуры.

Построение коллектива нейросетевых решателей

Поскольку решаемая задача относится к типу аппроксимаций функции в нейросетевой форме, то простые методы объединения классификаторов, например, смещение мнений [7, 8], не всегда будут эффективны.

На первом этапе рассмотрим влияние типа сети и объема выборки на качество формируемого решения. Анализ нескольких вариантов многослойного перцептрона в смысле числа нейронов и слоев сети не выявил существенного влияния сложности сети на результат или его однородность по глубине. Средние ошибки определения координат приведены в Таблице 1 (сеть 1, сеть 2, сеть 3). Следующей альтернативой является сеть RBF, которая содержит 31 нейрон и для ее обучения использовалось 30000 примеров. Средняя абсолютная ошибка обобщения по трем координатам представлена в табл. 1 (сеть 4).

Таблица 1

Результаты стереореконструкции в модели одной сети

Описание сети	Ошибка обобщения, м		
	X	Y	Z
Сеть 1. Нелинейный перцептрон, 2 слоя (12 нейронов), 25000 примеров	0.6145	0.6537	3.0535
Сеть 2. Нелинейный перцептрон, 2 слоя (16 нейронов)	0.6065	0.6309	2.9790
Сеть 3. Нелинейный перцептрон, 3 слоя (12 и 6 нейронов)	0.6462	0.6672	3.0418
Сеть 4. RBF сеть, 31 нейрон	0.6504	0.7184	3.2301
Сеть 5. Нелинейный перцептрон, 2 слоя (12 нейронов), 50000 примеров	0.6127	0.6327	3.0041

Опираясь на полученные данные, нетрудно заметить, что двухслойная сеть справилась с задачей лучше, чем сеть RBF. Кроме того, сеть радиально-но базисных функций имеет два значительных недостатка:

1. Ограниченное число обучающей выборки.

2. Сеть RBF часто должна содержать слишком большое число нейронов скрытого слоя. Это влечет более медленное функционирование RBF сети, чем многослойного перцептрона и значительно усложняет реализация в рамках бортовой вычислительной системы.

Влияние числа примеров обучающей выборки на ошибку обобщения также незначительно, как это видно для сети 1 и сети 5 из табл. 1. Ошибка обобщения уменьшилась незначительно.

Очевидно, что изменить характер ошибок обобщения ни за счет изменения типа сети, ни за счет размера множества примеров не удастся. Это свидетельствует о проблемах модели, т.е. о невозможности в таком представлении эффективно решить задачу.

Второй этап моделирования ориентирован на изменение состава выборки примеров. Исходная модель обучения была построена с учетом гипотезы о равномерном распределении примеров по объему пирамиды видимости стереопары. Однако результаты моделирования, где ошибка координат велика в диапазоне от 0.5 до 10 м, заставляют предположить, что следует рассматривать неравномерное распределение примеров по объему пирамиды видимости. Было сделано предположение, что число примеров должно быть не равномерным по объему. Для обучения всех сетей использовалась обучающая выборка с числом примеров $n = 100000$. Архитектура всех сетей одинакова и соответствует сети 2, описанной выше. Для обучения первой сети данные были распределены по равномерному

закону (тип 1 из табл. 2), для второй – данные распределены равномерно и их число жестко фиксировано (по 2500 примеров на каждый метр) (тип 2), для третьей модели количество примеров на каждом метре линейно увеличивалось ($n = 6li, i = 1, 2, \dots, 40$, где i – расстояние в метрах, тип 3).

Наилучшее решение демонстрирует модель обучения с типом примеров 3 (см. табл. 2, тип 3). Кроме того, для этой модели изменяется поведение ошибки по глубине, как это показано на рис. 2. Видно, что характер ошибок для выборки типа 3 становится более линейным по отношению к дальности объекта.

Таблица 2

Ошибки координат в зависимости от распределения примеров

Тип размещения примеров	Ошибка обобщения, м		
	X	Y	Z
Тип 1. Равномерное распределение примеров по объему.	0.6127	0.6327	3.0041
Тип 2. Выравнивание выборки	0.6237	0.6496	3.0631
Тип 3. Равномерное распределение примеров по глубины	0.6021	0.6293	2.9922

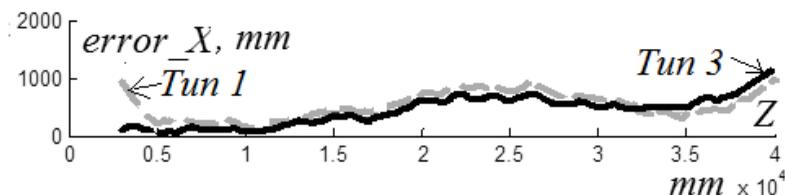


Рис. 2. Средняя абсолютная ошибка координат точки для неравномерной выборки

Однако общее решение остается довольно слабым и составляет в среднем $\epsilon_x \approx \epsilon_y \approx \epsilon_z \approx 0.1Z$ по координатам. Рассмотрим возможность построения более качественной модели решения за счет использования коллектива решателей. Поскольку методы создания коллективов решателей для решения задач классификации сложно распространить на аппроксимацию функций, использован подход к формированию модульной нейросетевой системы на основе идей метода нахождения однородных областей [8], где синтез модульной нейронной сети осуществляется в соответствии со следующими принципами:

- однородные фрагменты сложной функциональной зависимости представляется отдельными модулями;
- сложность нейросетевых модульных аппроксиматоров ограничена;
- расширение областей локальной аппроксимации ограничено уровнем сложности нейросетевых модулей точностью аппроксимации.

Используя эмпирические предположения, дисперсию ошибки и среднюю ошибку аппроксимации вдоль глубины, удалось определить структуру модели в следующем виде:

- интервал от 0 до 40 метров разбит на пересекающиеся участки по 12 м ([0,12], [6,18], [12,24], [18,30], [24,36], [30,40]) поскольку ошибка максимальная ошибка сети на предыдущем этапе составила ± 6 м;
- для каждого из полученных интервалов обучим нейросеть $F_k(X, \omega)$;
- на основании анализа ошибок исключили из второго уровня модели все модули, кроме $F_{0-12}(X, \omega)$ и $F_{6-18}(X, \omega)$ для областей [0,12], [6,18].

Таким образом, получим два уровня иерархии: сначала проекции точек подаются в общую нейросеть $F(X, \omega)$ (глубина от 0 до 40 м.), а потом, исходя из полученных результатов, каждая точка попадает в свою конкретную нейросеть узкого диапазона ($F_{0-12}(X, \omega)$ или $F_{6-18}(X, \omega)$). В табл. 3 представлена ошибка сетей, соответствующих интервалам [0,12] и ошибка исходной одноуровневой модели для трех случайных точек выборки тестовых примеров. Средние ошибки оценки координат не превышают $0.016Z$ (1.6% глубины).

Таблица 3

Ошибка нейросети $F_{0-12}(X, \omega)$ для интервала [0,12] метров

Тип сети	Абсолютная ошибка сети 1 уровня, м			Абсолютная ошибка сети 2 уровня, м		
	x	y	z	x	y	z
[0,12]	0.301	0.024	0.224	0.037	0.007	0.124
[6,18]	0.107	0.006	0.371	0.030	0.053	0.0062

Сравним результаты моделирования эмпирической модели решателя с результатами работы модели, полученной как результат работы алгоритма, близкого к бустингу [8] с жестким ограничением на число модулей $k=3$. Последовательность этапов работы с выборкой выглядит следующим образом:

1. Набирается n примеров выборки T . Делим ее на тренировочную $T_{\text{тр}}$ и $T_{\text{тест}}$ ($|T_{\text{тр}}| = 0.75|T|$, $|T_{\text{тест}}| = 0.25|T|$).
 2. Из $m = n/4$ примеров строим первый аппроксиматор.
 3. Определяем ошибку обучения e_k по каждому примеру X_k . Согласно полученной ошибке каждому примеру X_k присваивается вес, характеризующий, насколько хорошо этот пример был приближен к цели.
 4. Вычисляем среднюю ошибку обучения $E_{\text{ср}}$.
 5. Для обучения следующей сети набираем примеры X_k с наибольшими весами ($e_k \geq E_{\text{ср}}$) и следующие m примеров из T .
 6. Третью сеть строим из примеров X_k с наибольшими весами.
 7. Каждую из 3-х сетей проверяем на выборке $T_{\text{тест}}$.
- Решение модели формируется как усреднение решений отдельных нейросетей. Ошибки обучения и обобщения для глубины 10 м приведены в табл. 4.

Таблица 4

**Результаты работы коллектива решателей для координат X , Y , Z
в интервале $[0,40]$ и $[0,12]$ м**

Номер сети	Средняя абсолютная ошибка обучения, м			Средняя абсолютная ошибка обобщения, м		
	X	Y	Z	X	Y	Z
Интервал $[0,40]$ м						
1	0.4399	0.4543	2.1218	0.6039	0.6474	3.0078
2	0.4195	0.4544	2.0910	0.6147	0.6640	3.1000
3	0.4182	0.4381	2.0375	0.6241	0.6611	3.1329
Интервал $[0,12]$ м						
1	0.077	0.086	0.378	0.078	0.088	0.383
2	0.078	0.088	0.398	0.077	0.087	0.386
3	0.079	0.087	0.399	0.077	0.085	0.384

Очевидно, что модель в составе трех решателей не позволяет получить качественное решение (средняя ошибка координат $0.1Z$). Жесткое ограничение, наложенное на количества решателей, участвующих в ассоциативной модели, не позволяет получить необходимый уровень ошибок. Сравнив результаты моделирования в табл. 3 и 4, можно утверждать, что полученное на основе анализа ошибок выглядит значительно качественнее.

Итак, общая схема модели выглядит следующим образом:

- проекции точек подаются в нейросеть с глубиной $[0, 40]$ м;

- на основании полученных результатов отбираются точки принадлежащие интервалу $[0,12]$ или $[6,18]$ м и их координаты уточняются.

Данная схема алгоритма позволяет значительно уменьшить ошибку определения координат объекта в пространстве.

Выводы

Рассмотрены особенности организации бортовых систем технического зрения. Показано, что бортовая реализация процедур обработки видеoinформации в нейросетевом базисе позволяет повысить скорость и качество обработки кадров. Выделена задача нейросетевой аппроксимации процедуры стереорекострукции трехмерных точек по двум их проекция.

Предложена модель нейросетевой стереорекострукции с использованием неравномерного размещения примеров обучающей выборки. Кроме того, рассмотрены варианты построения коллектива нейросетей на основе анализа неравномерностей ошибок и бустинга.

По результатам анализа выбрана модель двухуровневой системы определения ошибок в составе трех решателей, которая обеспечивает ошибку не более $0.016Z$. Жесткое ограничение на объем коллектива решателей связано с необходимостью реализации модели в бортовой вычислительной системе. Дальнейшая работа будет направлена на реализацию разработанной модели в среде бортовой вычислительной системы.

Список литературы

1. Гурский Б.Г., Солунин В.Л., Новиков А.И. Навигационный комплекс беспилотных летательных аппаратов наземного базирования // Гироскопия и навигация, 2009. №2 (65). С. 12-23.
2. Дишель В.Д., Ивашина Е.А., Корлякова М.О., Пилипенко А.Ю., Филимонков А.А. Подход к коррекции азимутальной ориентации системы навигации с платформенным инерциальным блоком // Труды ФГУП "НПЦАП". Системы и приборы управления, 2013. № 4. С. 37-45.
3. S. Ozbay and E. Ercelebi, Automatic Vehicle Identification by Plate Recognition A Neural Network // World Academy of Science, Engineering and Technology, 2005. V. 9. P.222-225
4. Ивашина Е.А., Корлякова М.О., Пилипенко А.Ю., Филимонков А.А. Нейросетевой подход к формированию систем технического зрения мобильных объектов // Труды ФГУП "НПЦАП". Системы и приборы управления, 2013. № 3. С. 43-53
5. Sartin Maicon A. and da Silva Alexandre C. R., Evaluation of Image Segmentation and Filtering With Ann in the Papaya Leaf// International Journal of Computer Science & Information Technology (IJCSIT), 2014. V. 6. P.47-58

6. Кокарева Е.А., Корлякова М.О. Пилипенко А.Ю. Решение задачи стереореконструкции в нейросетевом базисе // XIV Всероссийская научно-техническая конференция «Нейроинформатика-2012»: Сборник научных трудов. В 3-х частях. Ч.1. М.: НИЯУ МИФИ, 2012. С. 160-169.

7. Хайкин С. Нейронные сети: полный курс. – 2-е изд./Пер. с англ. М.: ИД «Вильямс», 2006.

8. Мишулина О.А., Ускова А.А., Щербинина М.В. Оптимизация модульной нейросетевой структуры для моделирования комбинации разнородных в пространстве функциональных зависимостей // Нейроинформатика-2006. VIII Всероссийская научно-техническая конференция. Сборник научных трудов. Ч. 2. М.: МИФИ, 2006. С. 216-225.

9. Бурнаев Е.В., Приходько П.В. Теоретические свойства процедуры построения регрессионного ансамбля на основе беггинга и бустинга // Труды конференции «Информационные технологии и системы» (ИТиС'11), 2011. С. 438-443.

Е.А. ЭНГЕЛЬ

Хакасский государственный университет имени Н.Ф. Катанова, Абакан
angel@khsu.ru

ЭНЕРГОСБЕРЕГАЮЩАЯ ТЕХНОЛОГИЯ ЭЛЕКТРОТЕХНИЧЕСКОЙ СИСТЕМЫ НА БАЗЕ АДАПТИВНОГО НЕЙРОКОНТРОЛЛЕРА*

В рамках концепции интеллектуальной электроэнергетической системы с активно-адаптивной сетью разработана организующая функциональное взаимодействие учета и идентификации режима электропотребления технической системы энергосберегающая технология автоматизированной системы технического учета электроэнергии на базе адаптивного нейроконтроллера. Разработанный адаптивный нейроконтроллер на основе идентификации текущего состояния электротехнической системы и двойственных нейросетей, прогнозирующих и минимизирующих электропотребление, формирует эффективные управляющие воздействия, обеспечивающие энергосбережение в условиях случайных возмущений.

Ключевые слова: *временной ряд, прогнозирование, нейроконтроллер, энергосбережение.*

* Работа выполнена при поддержке РФФИ, проект №14-41-0402-а.

E.A. ENGEL

Katanov Khakass State University, Abakan
angel@khsu.ru

ENERGY SAVING TECHNOLOGY FOR ELECTROTECHNICAL SYSTEM ON THE BASIS OF THE ADAPTIVE NEUROCONTROLLER

Within the Smart Grid concept the energy saving technology of automated system of the electricity's technical accounting on the base of the adaptive neural controller organizing the functional interaction of the account and the mode identification of system's energy consumption is developed. This adaptive neural controller on the base of the identification of electro technical system's status and dual neural nets minimizing and forecasting power consumption's creates the effective control signal under random perturbations.

Keywords: *time series, prediction, neurocontroller, energy saving.*

Введение

Энергосбережение – комплексная проблема, сопряженная с вопросами энергоэффективности и оптимизации электроэнергетической системы (ЭЭС), актуальность которой утверждена на федеральном уровне как приоритетного направления и в соответствии с законом №261-ФЗ «Об энергосбережении и о повышении энергетической эффективности» с изменениями от 28.12.13. Экономии электроэнергии, увеличению эффективности функционирования электротехнической системы способствует повышение точности прогноза электропотребления. Эффективность мероприятий по управлению электропотреблением, экономичность режимов работы энергосистемы и энергосбережение определяются достоверностью прогноза. Методология прогнозирования развивалась учёными: Матросовым Н.Д., Вишнёвым С.М., Мосиным В.О., Клейн Л. и др. В рамках интеллектуальной электроэнергетической системы с активно-адаптивной сетью (ИЭС ААС) автоматизированная система технического учета электроэнергии (АСТУЭ), обеспечивающая совмещение функций учета, технологических измерений и управления является эффективным методом снижения потребления электроэнергии [1].

Применение интеллектуальных методов в ЭЭС необходимо в связи с современными требованиями по формированию технических средств управления ЭЭС и энергосбережением, для чего непригодны традиционные технологии управления, не обеспечивающие повышение качества

управления, особенно в условиях воздействия различных внешних и внутренних факторов неопределенности [2]. Значительный научный вклад в теорию и практику создания нечетких и нейросетевых систем управления внесли ученые: Л. Заде, Д.А. Поспелов, Ю.А. Борцов, Ф. Вассерман, Н. Хассоун, А.И. Галушкин и др. В последние годы в ЭЭС постепенно интеллектуальные регуляторы на базе нечеткой, нейросетевой или нейронечеткой технологии эффективно заменяют [2] широко используемые аналоговые ПИД-регуляторы. В отличие от ПИД-регуляторов интеллектуальные регуляторы описывают нелинейный закон управления, расширяющий рабочий диапазон и улучшающий показатели качества переходных процессов; поддерживают реализацию на базе современных контроллеров, имеющих высокие вычислительные возможности и низкую стоимость. С учетом указанных преимуществ интеллектуальные регуляторы позволяют реализовывать эффективные системы управления.

Методы анализа и синтеза нелинейных систем исследовались в работах ученых: А.М. Ляпунов, Р. Калман, А.А. Воронов, А.А. Красовский, А.П. Крищенко, Н.Б. Филимонов и др. Задача синтеза нелинейных регуляторов актуальна в настоящее время, поскольку без учета нелинейностей обеспечить требуемое качество процессов управления невозможно. В данном исследовании решается актуальная задача разработки адаптивного нейроконтроллера, отслеживающего текущее состояние электротехнической системы, прогнозирующего ее электропотребление и формирующего адекватные управляющие воздействия, обеспечивающие энергосбережение. Энергосберегающая технология АСТУЭ на базе адаптивного нейроконтроллера (АН) организует функциональное взаимодействие учета и идентификации режима электропотребления технической системы, обеспечивая формирование эффективного управляющего воздействия, минимизирующего электропотребление. Совмещение указанных функций сопряжено с иерархической обработкой информации технического учета электроэнергии, идентификации на ее основе режимов электропотребления и управления с учетом результатов обработки информации, полученных на двух указанных уровнях иерархии. Разработанная технология реализует адаптивное управление с прогнозирующей эталонной моделью.

Адаптивная система управления в форме нечеткой селективной нейросети с прогнозирующей моделью электропотребления

Временные ряды значений электропотребления технической системы характеризуются сложной зависимостью с множеством локальных особенностей и отсутствием периодичности. Существующие методы прогно-

зирования электропотребления имеют высокую степень агрегации, не ориентированы на аспект энергосбережения, недостаточно учитывают сложные, меняющиеся взаимосвязи между объемами электропотребления и параметрами электротехнической системы конечного потребителя [1].

Для обработки таких рядов необходимо использовать интеллектуальные методы, выявляющие указанные зависимости с целью прогнозирования их изменений. Процесс колебаний потребления электроэнергии представляет собой сложный нестационарный случайный процесс, имеющий некоторую цикличность – регулярные колебания, вызванные сезонными изменениями температуры и освещенности (времени суток), технологическим режимом работы предприятий и т.д. На регулярные колебания накладываются нерегулярные и случайные факторы, определяемые резкими изменениями погодных условий, различными социальными факторами, включение (отключение) энергоемких потребителей и т.д. Указанные аспекты определяют сложность, принципиальную нелинейность прогнозирующей модели и актуализируют ее разработку в форме нечеткой селективной нейросети. Нечеткая селективная нейросеть настраивается на наборе, содержащем m точек экспериментальных данных

$$Z^i = (s_1^i, s_2^i, \dots, s_r^i, u_1^i, u_2^i, \dots, u_b^i, q, \Omega_1^i, \Omega_2^i, \dots, \Omega_q^i, Y), \quad (1)$$

где $i \in \{1, \dots, m\}$ – моменты времени, Y – электропотребление; q – объем производства, обеспечиваемый электротехнической системой; s – вектор выходов электротехнической системы; u – вектор управляющих воздействий; Ω – вектор воздействий внешней среды.

Вектор $x = (s_1^i, s_2^i, \dots, s_r^i, u_1^i, u_2^i, \dots, u_b^i)$ включает следующие параметры: потребление электроэнергии в предыдущие часы (1, 2 и 3 часа), недельные и суточные параметры потребления, могут быть учтены функциональные факторы процесса, указанные экспертом. Вектор Ω включает следующие параметры: статус дня (рабочие, выходные, праздничные), время суток, среднесуточная температура воздуха, могут быть учтены факторы величин потребления других участников процесса. Для решения задачи суточного почасового прогнозирования потребления определенным потребителем берутся данные технологического архива не менее трех лет (т.е. $m \geq 26\ 280$).

Нечеткая селективная нейросеть реализует преобразования: неросетовое $u = f(x)$, формирующее управляющее воздействие на электротехническую систему и нейро-нечеткие $y_j = \eta_j(X)$, формирующие прогноз для j -го режима электропотребления, $X = (x, q, \Omega_1, \Omega_2, \dots, \Omega_q)$. Нечеткая селективная нейросеть настраивается для каждого потребителя с учетом его специфических особенностей. Выявление на основе расширяющегося нейронного газа (РНГ) [3] во временном ряде электропотребления общих тенденций,

формируемых нейросетевыми трендами, составляет основу базы знаний (формализованных шаблонов электропотребления) нечеткой селективной нейросети, соответствует концепции гранулярных вычислений и повышает точность прогноза.

Управление с прогнозирующей моделью основывается на настроенной нечеткой селективной нейросети, формирующей прогноз электропотребления. Полученные результаты прогноза используются алгоритмом численной оптимизации для нахождения значений параметров технологического процесса, минимизирующих электропотребление без снижения производительности.

Для реализации энергосбережения решается комбинированная задача в ее нейросетевой постановке, т.е. нахождение значений x – сигналов на входе обученной сети, минимизирующих выходной сигнал нейросети (электропотребление) при ограничениях на диапазоны изменения переменных:

$$\min Y, \quad (2)$$

$$\begin{matrix} a_{1i} \leq x_i \leq a_{2i} \\ q_1 \leq q \leq q_2 \end{matrix}$$

где $i \in \{1, \dots, r\}$, условие $q_1 \leq q \leq q_2$ гарантирует стабильную производительность, обеспечиваемую электротехнической системой. Для решения задачи (2) используется с конца 1980-х гг. прием дифференцирования нейросетевой функции (обученной решению прямой задачи) по входным сигналам нейросети x_i , $i \in \{1, \dots, r\}$ для вычисления их значений. При $r > 2$ решение задачи (2) может иметь континуум решений. Вычисляется градиент нейросетевой функции электропотребления по значениям входных сигналов x_i , $i \in \{1, \dots, r\}$ и алгоритмом обратного распространения некоторые стартовые значения входных сигналов сети корректируются вдоль направления антиградиента [3]. Градиентный спуск приведет к решению обратной задачи (соответствующему минимуму электропотребления при заданных ограничениях и стартовых значениях входных сигналов) или в области локального для градиентного спуска минимума (в этом случае решение обратной задачи при заданных начальных условиях или ограничениях на значения сигналов может не существовать).

Энергосберегающая технология АСТУЭ на базе адаптивного нейроконтроллера

Формирование и функционирование энергосберегающей технологии АСТУЭ на базе АН реализуют разработанные модули I и II гибридных интеллектуальных вычислений соответственно (рис. 1).

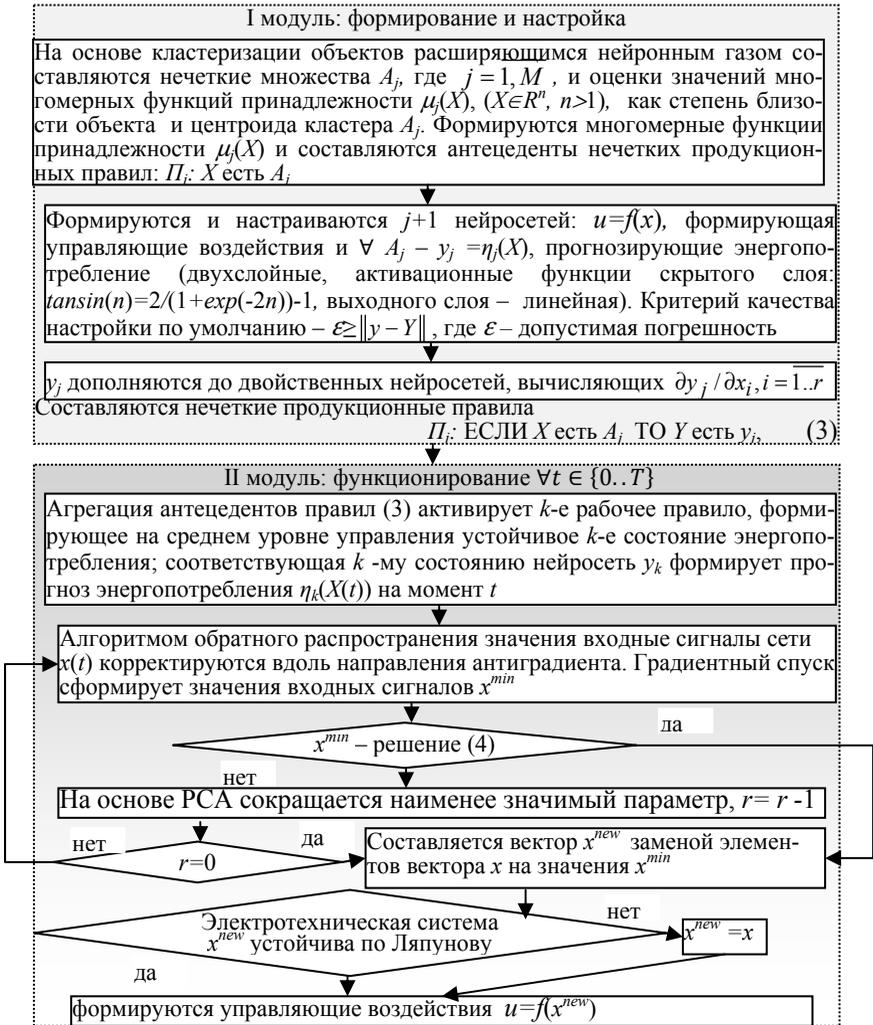


Рис. 1. Модули I и II гибридных интеллектуальных вычислений

В данном научном исследовании условие (4) сопряжено с глобальной оптимизацией; условие (5) – устойчивость электротехнической системы по Ляпунову, для расчета (5) применяется метод первого приближения и теоремы Ляпунова. Условия (4) и (5) – направление для дальнейшей работы и тема отдельной статьи.

Сформированная модулем I энергосберегающая технология АСТУЭ на базе адаптивного нейроконтроллера представляет собой интеллектуальную систему управления без целеполагания (рис. 2), функционирующую на основе гибридных интеллектуальных вычислений настроенной нечеткой селективной нейросети, реализованных II модулем.

Разработанная на базе синтеза нейронных сетей, эволюционных вычислений и нечеткой логики нечеткая селективная нейросеть позволяет транслировать структурные и функциональные аспекты систем управления ЭЭС, т.е. осуществляет структурно-параметрический синтез адаптивного нейроконтроллера.

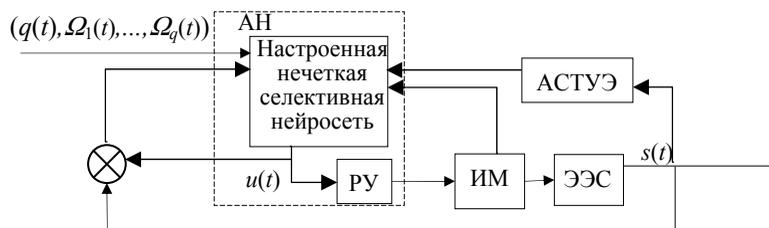


Рис. 2. Схема энергосберегающей технологии АСТУЭ на базе адаптивного нейроконтроллера:

ИМ – исполнительный механизм, РУ – регулирующее устройство, $s(t)$ – выход ЭЭС, $u(t)$ – управляющее воздействие

Моделирование энергосберегающей технологии АСТУЭ на базе адаптивного нейроконтроллера

Реализованный в среде Matlab Simulink I модуль гибридных интеллектуальных вычислений (рис. 3) сформировал энергосберегающую технологию АСТУЭ на базе адаптивного нейроконтроллера для сегмента электропотребления легкой промышленности – системы автоматического управления скоростными режимами электромеханической системы транспортирования и наматывания, управляемой многодвигательным асинхронным электроприводом. Функционирование энергосберегающей

технологии АСТУЭ на базе АН для электротехнической системы с транспортирующими и наматывающими механизмами реализует II модуль гибридных интеллектуальных вычислений (рис. 3) в виде модели Simulink (рис. 3, 4).

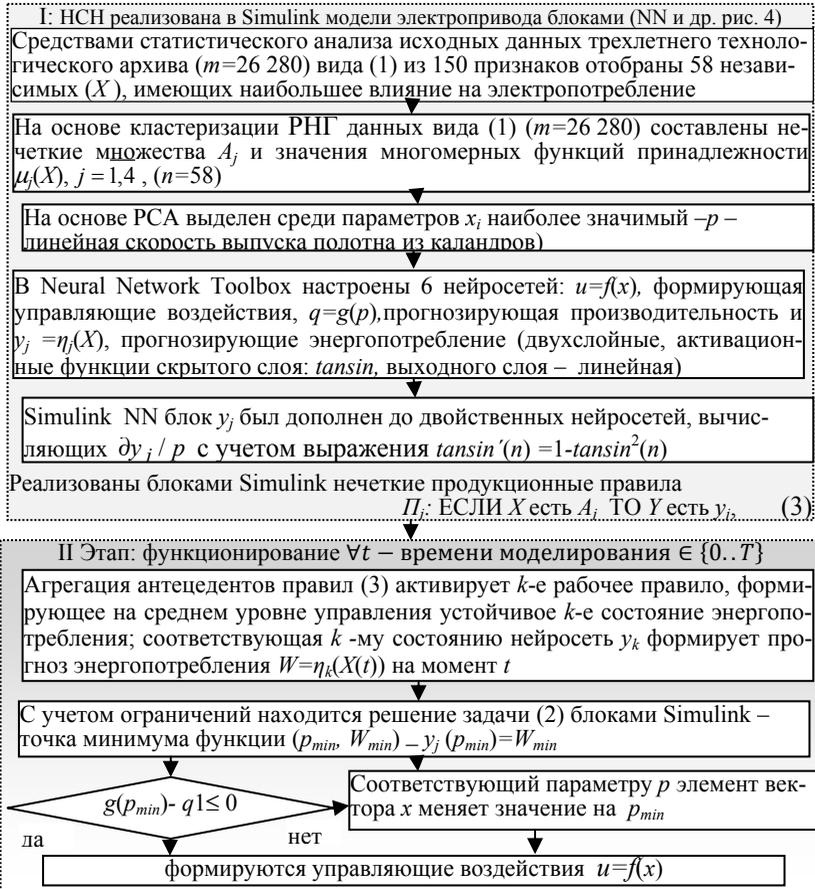


Рис. 3. Реализация Simulink модели энергосберегающей технологии АСТУЭ на базе адаптивного нейроконтроллера для многодвигательного асинхронного электропривода

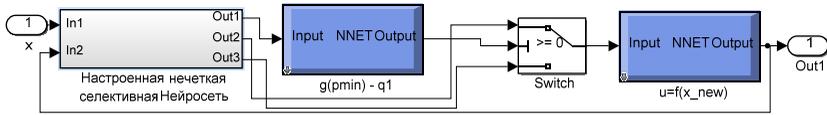


Рис. 4. Подсистема АН Simulink модели асинхронного электропривода

Моделирование энергосберегающей технологии АСТУЭ на базе АН для электротехнической системы с транспортирующими и наматывающими механизмами реализует модель Simulink. Для имитация реальных условий воздействия возмущений в АСТУЭ электротехнической системы с транспортирующими и наматывающими механизмами в Simulink модель многодвигательного асинхронного электропривода добавлен шум, являющийся распределением Гаусса с параметрами среднего значения 1, со стандартным отклонением 0.001.

На рис. 4 представлена подсистема адаптивного нейроконтроллера указанной Simulink модели. Полученные в результате моделирования оценки качества моделей: $y_j = \eta_j(X)$, прогнозирующих энергопотребление (рис. 5 и табл. 1) и $u=f(x)$ – адаптивного нейроконтроллера (рис. 5 и табл. 2) свидетельствуют об адекватности и эффективности функционирования в условиях возмущающих воздействий разработанной энергосберегающей технологии АСТУЭ на базе АН, настроенной для электротехнической системы с транспортирующими и наматывающими механизмами.

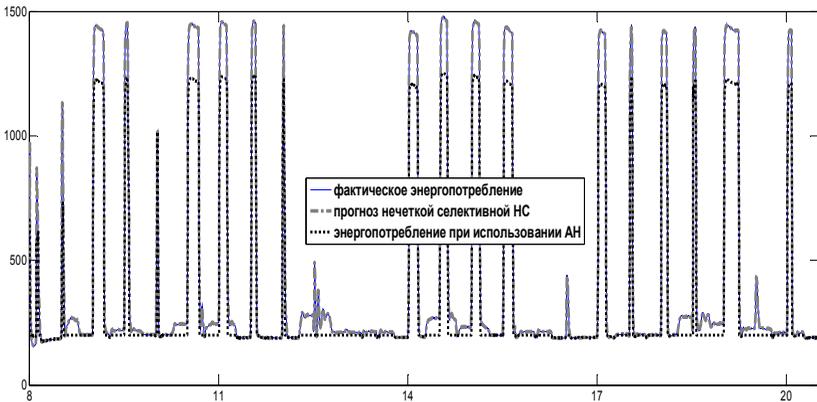


Рис. 5. График функций реального и модельного энергопотребления

Таблица 1

Качество прогнозирующей модели электропотребления

Абсолютная среднеквадратичная ошибка	0.44
Относительная среднеквадратичная ошибка, %	0.12
Статическая ошибка, %	0

Для сравнения качества регулирования адаптивного нейроконтроллера и ПИД-регулятора последний в был добавлен как Simulink блок в модель многодвигательного асинхронного электропривода. В результате моделирования установлено, что адаптивный нейроконтроллер (в условиях возмущающих воздействий) в сравнении ПИД-регулятором (функционирующим в отсутствии шума) улучшает качество переходных процессов системы транспортирования и наматывания, управляемой многодвигательным асинхронным электроприводом (табл. 2). Таким образом, адаптивный нейроконтроллер робастен к белому шуму, что позволяет реализовывать эффективное управление в условии зашумленности данных, полученных напрямую с датчиков АСТУЭ.

Таблица 2

Показатели качества переходных процессов

Параметры	Адаптивный нейроконтроллер	ПИД-контроллер
Время переходного процесса, мин	0,4	0,9
Перерегулирование, %	3	3
Статическая ошибка, %	0	0

Переходный процесс (отражает вытяжение полотна $E=p/s_2$, где s_2 – линейная скорость наматывания на валик) в электротехнической системе с ПИД-контроллером имеет колебательный характер и большую длительность по сравнению с адаптивным нейроконтроллером (рис. 6).

Фактическое энергопотребление (см. рис. 5) соответствует энергопотреблению системы с транспортирующими и наматывающими механизмами, регулируемой ПИД-контроллером. В сравнении с ПИД регулятором разработанный адаптивный нейроконтроллер обеспечивает сбережение электроэнергии в среднем на 20 % (см. рис. 5) снижением в два раза потерь при переходном процессе и времени стабилизации, а также сниже-

нием тока в фазах асинхронного двигателя в режиме холостого хода в 2,5 раза, потребляемой мощности в 2 раза.

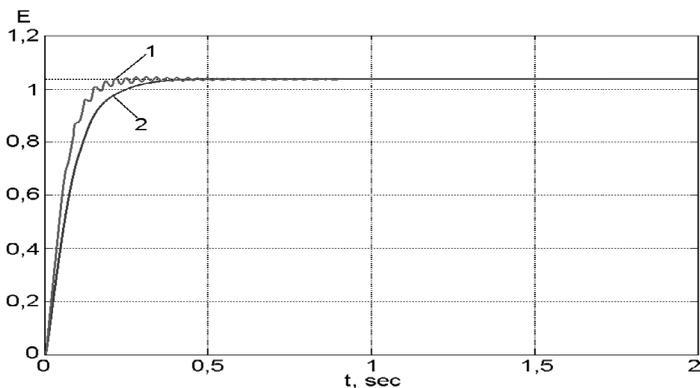


Рис. 6. Переходный процесс в зоне транспортирования и наматывания управляемый ПИД-регулятором (1) и адаптивным нейроконтроллером (2)

Заключение

Разработанная энергосберегающая технология автоматизированной системы технического учета электроэнергии на базе адаптивного нейроконтроллера, организующая функциональное взаимодействие учета, идентификации режима электропотребления и управления ТС в форме настроенной нечеткой селективной нейросети, обеспечивает минимизацию электропотребления при эффективном функционировании электротехнической системы конечного потребителя с заданной производительности в условиях случайных возмущений. При моделировании в среде Simulink Matlab разработанной энергосберегающей технологии АСТУЭ на базе адаптивного нейроконтроллера выявлены следующие достоинства: поддерживает режим реального и опережающего времени; настроенные гибридные вычислительные структуры (инкапсулированные технологией) позволяют обрабатывать зашумленные данные, полученные напрямую с датчиков АСТУЭ. Разработанный адаптивный нейроконтроллер позволяет отслеживать текущее состояние электротехнической системы, прогнозировать ее будущее электропотребление и формировать в условиях случайных возмущений адекватные управляющие воздействия, обеспечивающие энергосбережение.

Список литературы

1. Бахтадзе Н.Н., Моржин Ю.Н., Ядыкин И.Б. Мультиагентная интеллектуальная иммунная система электроэнергетической системы с активно-адаптивной сетью. // Автоматизация в промышленности, 2012. № 4. С. 61-64.
2. И.М. Макаров, В.М. Лохин, С.В. Манько, М.П. Романов, М.С. Ситников. Устойчивость интеллектуальных систем автоматического управления // Приложение к журналу «Информационные технологии», 2013. № 2.
3. Isaac J. Sledge, Growing Neural Gas for Temporal Clustering / IEEE Computer Society, 2008.
4. Kindermann J., Linden A. Inversion of neural networks by gradient descent / Parallel Computing, 1990. №14. P. 270-286.
5. Е.А. Энгель. Решение задач управления, принятия решений и обработки информации методом нечеткой селективной нейросети // Информационные технологии, 2012. №5.

А.В. САВЧЕНКО¹, В.Р. МИЛОВ²

¹Национальный исследовательский университет «Высшая школа экономики»,
Нижегородский филиал

²Нижегородский государственный технический университет им. Р.Е. Алексеева
avsavchenko@hse.ru

**ОБ ОДНОМ ПОДХОДЕ К ПОСЛЕДОВАТЕЛЬНОМУ
ИЕРАРХИЧЕСКОМУ РАСПОЗНАВАНИЮ
ИЗОБРАЖЕНИЙ**

Рассматривается задача автоматического распознавания изображений. Предложен иерархический подход к ее решению, в котором переход на более детальный уровень описания происходит только при недостаточной надежности классификации на предыдущем уровне. Представлены примеры практического применения в задаче распознавания лиц по фотографии.

Ключевые слова: *распознавание образов, распознавание изображений, иерархическое распознавание, критерий Чоу, вероятностная нейронная сеть.*

A.V. SAVCHENKO¹, V.R. MILOV²

¹Higher School of Economics, Nizhny Novgorod Branch

²Nizhny Novgorod State Technical University named after R.E. Alekseev
avsavchenko@hse.ru

AN APPROACH TO SEQUENTIAL HIERARCHICAL IMAGE RECOGNITION

The automatic image recognition problem is considered. A hierarchical approach is proposed in which the analysis on the next, more detailed level of object's description is performed only if the decision on the current level is unreliable. The practical examples of the proposed approach in face recognition problem are presented.

Keywords: *pattern recognition, image recognition, hierarchical recognition, Chow's reject option rule, probabilistic neural network.*

Введение

Задача автоматического распознавания сложных изображений (лиц, жестов, медицинских снимков) [1] в настоящее время становится все актуальней в связи с появлением достаточно надежных дескрипторов, таких как SIFT (Scale-Invariant Feature Transform) [2], HOG (Histograms of Oriented Gradients) [3], SURF (Speeded-Up Robust Features) [4] и т.п. Большинство исследователей связывают анализ изображений с характерной для человеческого интеллекта иерархической обработкой анализируемых объектов [5, 6]. В результате популярность получили такие иерархические методы, как пирамиды признаков (в частности, дескриптор PNOG (Pyramid HOG) [7]), иерархическая временная памяти [5], вейвлет-анализ [9, 10], искусственные "глубокие" (deep) нейронные сети свертки [11] и т.д.

Чаще всего в таких методах происходит *одновременное* сопоставление признаков входного объекта и эталонов из базы данных (БД) на каждом уровне иерархии, что зачастую приводит к невозможности реализации сложных иерархических алгоритмов в режиме реального времени [12]. Например, размерность дескриптора PNOG (и, соответственно, вычислительная сложность его обработки) обычно в 2-3 раза превышает размерность традиционного дескриптора HOG [3]. На преодоление этого недостатка и направлена настоящая работа. В ней предложено выполнять анализ детализированного представления входных объектов только при не-

возможности принятия достаточно надежного решения на предыдущих уровнях [13, 14].

Данная работа является развитием исследования [15].

Постановка задачи и описание алгоритма

В задаче распознавания изображение X с высотой U и шириной V требуется отнести к одному из $C > 1$ классов, заданных эталонами $X_r, r = \overline{1, R}$ с высотой U_r и шириной V_r , где $R \geq C$ – количество эталонов в БД. Каждому r -му эталону ставится в соответствие метка класса $c(r) \in \{1, \dots, C\}$. Предположим, что все изображения содержат только анализируемые объекты, выделенные, например, с помощью соответствующих детекторов [16]. Для решения задачи воспользуемся моделью кусочно-однородного объекта [17] – будем рассматривать J уровней детализации. Обычно количество шагов ограничивается исследователем исходя из особенностей конкретной задачи ($J = const$). На j -м уровне разобьем каждое изображение на $K_j^{(1)} \times K_j^{(2)}$ блоков (по $K_j^{(1)}$ строк и $K_j^{(2)}$ столбцов), при этом предполагаем, что $K_j^{(1)} < K_{j+1}^{(1)}, K_j^{(2)} < K_{j+1}^{(2)}$. Для учета небольших изменений ракурса после детектирования каждый блок $(k_j^{(1)}, k_j^{(2)})$, $k_j^{(1)} \in \{1, \dots, K_j^{(1)}\}$, $k_j^{(2)} \in \{1, \dots, K_j^{(2)}\}$ будет сопоставляться не только с соответствующим блоком $(k_j^{(1)}, k_j^{(2)})$ всех эталонов, но и с его "соседями" – участками $(\tilde{k}_j^{(1)}, \tilde{k}_j^{(2)})$, такими, что $|\tilde{k}_j^{(1)} - k_j^{(1)}| < \Delta$, $|\tilde{k}_j^{(2)} - k_j^{(2)}| < \Delta$, где $\Delta = const$ (обычно $\Delta = 0$ или $\Delta = 1$). Воспользуемся популярными признаками – направлением градиента яркости, множество значений которых разбивается на N отрезков одинакового размера и для каждого блока $(k_j^{(1)}, k_j^{(2)})$ вычисляют гистограммы

$$H_r(k_j^{(1)}, k_j^{(2)}) = \left[h_1^{(r)}(k_j^{(1)}, k_j^{(2)}), \dots, h_N^{(r)}(k_j^{(1)}, k_j^{(2)}) \right],$$

$$H(k_j^{(1)}, k_j^{(2)}) = \left[h_1(k_j^{(1)}, k_j^{(2)}), \dots, h_N(k_j^{(1)}, k_j^{(2)}) \right]$$

направлений градиентов r -го эталонного и входного изображений, соответственно. Далее для l -го уровня определяется близость с r -м эталоном [17]:

$$\rho_j(X, X_r) = \sum_{k_j^{(1)}=1}^{K_j^{(1)}} \sum_{k_j^{(2)}=1}^{K_j^{(2)}} \min_{\substack{|\Delta_1| \leq \Delta, \\ |\Delta_2| \leq \Delta}} \rho(H_r(k_j^{(1)} + \Delta_1, k_j^{(2)} + \Delta_2), H(k_j^{(1)}, k_j^{(2)})), \quad (1)$$

где $\rho(H_r(k_j^{(1)} + \Delta_1, k_j^{(2)} + \Delta_2), H(k_j^{(1)}, k_j^{(2)}))$ – некоторая мера близости между гистограммами признаков блока $(k_j^{(1)}, k_j^{(2)})$ входного изображения и эталона. Наиболее популярен [2, 3] квадрат метрики Евклида

$$\rho_2(H_r, H) = \sum_{i=1}^N (h_i - h_i^{(r)})^2, \quad (2)$$

где для упрощения выражения отброшены индексы $(k_j^{(1)}, k_j^{(2)})$.

Если для распознавания применяется статистический подход, то, как известно [18], асимптотически минимаксным критерием проверки сложных гипотез об однородности входного и эталонных объектов будет правило ближайшего соседа с мерой близости из вероятностной нейронной сети с проверкой однородности (homogeneity-testing probabilistic neural network, HT-PNN):

$$\rho_{\text{HT-PNN}}(H_r, H) = \sum_{i=1}^N \left(h_i \ln \frac{h_{K;i}}{\tilde{h}_{\Sigma;i}^{(r)}} + \frac{U_r V_r}{UV} h_i^{(r)} \ln \frac{h_{K;i}^{(r)}}{\tilde{h}_{\Sigma;i}^{(r)}} \right), \quad (3)$$

где $h_{K;i}^{(r)}$, $h_{K;i}$ – свертки гистограмм $h_i^{(r)}$, h_i с гауссовым ядром Парзена

$$[19], \text{ а } \tilde{h}_{\Sigma;i}^{(r)} = \frac{UV h_{K;i} + U_r V_r h_{K;i}^{(r)}}{UV + U_r V_r}.$$

В работе предлагается иерархический вариант процесса распознавания. Сначала анализируются наиболее грубые приближения (небольшое количество блоков $K_j^{(1)}$, $K_j^{(2)}$, на которые разбиваются изображения входного и эталонных объектов. Если в этом случае можно получить достаточно надежное решение, то процесс поиска на нем и останавливается. В противном случае, описание входного объекта детализируется, и процесс распознавания повторяется заново до тех пор, пока на некотором j -м шаге не будет получено достаточно надежное решение, либо по достижении наиболее детального уровня иерархии ($j = J$). Для этого на каждом шаге оценивается апостериорная вероятность $\hat{P}_j(c|X)$ принадлежности описания входного объекта на j -м уровне детализации к каждому c -му классу.

Как известно [20], для НТ-PNN (1), (3) оценка $\hat{P}_j(c|X)$ может быть получена из следующей формулы:

$$\hat{P}_j(c|X) = \frac{P_j(c) \cdot \max_{\{r \in \{1, \dots, R\} | c(r)=c\}} \exp\{-\rho_j(X, X_r)\}}{\sum_{i=1}^c P_j(i) \cdot \max_{\{r \in \{1, \dots, R\} | c(r)=i\}} \exp\{-\rho_j(X, X_r)\}}, \quad (4)$$

где $P_j(c)$ – априорная вероятность появления c -го класса на j -м уровне иерархии. Обычно на каждом следующем шаге учитываются результаты обработки предыдущего шага, как это делается в последовательном анализе Вальда [21]. Поэтому в простейшем случае последнюю можно оценить на основе апостериорных вероятностей, вычисленных на предыдущем уровне. При этом на первом уровне иерархии все классы считаются равновероятными или же апостериорная вероятность оценивается как доля объектов каждого класса в БД, как это делается в традиционной вероятностной нейронной сети [19]:

$$P_j(c) = \begin{cases} \frac{1}{R} \sum_{r=1}^R \delta(c(r) - c), & j = 1, \\ \hat{P}_{j-1}(c|X), & j > 1, \end{cases} \quad (5)$$

где $\delta(\cdot)$ – дискретная дельта-функция.

При использовании статистического подхода оптимальным критерием отбраковки ненадежных решений – опции отказа (reject option) – является правило Чоу [13]. Решение в пользу класса

$$v = \arg \max_{c \in \{1, \dots, C\}} \hat{P}_j(c|X) \quad (6)$$

признается надежным, если оценка апостериорной вероятности $\hat{P}_j(v|X)$ превышает наперед заданный порог

$$\hat{P}_j(v|X) > p_0 = \text{const}. \quad (7)$$

В таком случае решение задачи распознавания принимается в пользу класса v . Если же условие (7) для уровня $j < J$ не выполняется, то происходит переход в уровень $(j+1)$, и процесс повторяется: вычисляются расстояния (1) до всех эталонов, с учетом вычисленных на предыдущем

уровне вероятностей $\hat{P}_j(c|X)$ (5) оцениваются апостериорные вероятности (4), находится класс с максимальной апостериорной вероятностью (6) и выполняется проверка его надежности (7).

Таким образом, в предложенном методе (1), (5)-(7) применяется традиционный для иерархического распознавания подход [5, 15] – строится пирамида признаков переменного разрешения [7, 10]. Однако, в отличие от известных аналогов, происходит не одновременный анализ объединенного вектора признаков (такого, как PNOG), а последовательный анализ детализаций входного объекта с условием останова (7). Учитывая то, что сложность представления, а вместе с ней и вычислительная сложность обработки (1)-(3), возрастают при увеличении j , такой подход может привести к значительному повышению производительности алгоритма распознавания, особенно, при обработке существенно отличающихся друг от друга классов.

Результаты экспериментального исследования

Рассмотрим задачу классификации людей по фотографиям лиц [22]. В качестве их предварительной обработки для выделения лиц использовалась библиотека OpenCV с последующей медианной фильтрацией. Для тестирования использовались множество фотографий лиц Yale [23] и AT&T [24]. Для БД Yale (вариативный параметр – неравномерная освещённость объекта) в обучающее множество эталонов помещались 15 изображений (по одной фотографии каждого человека), а тестирование качества распознавания проводилось на остальных 181 фотографии тех же людей. Тем самым достигались наиболее жесткие условия для последующего распознавания. Для базы AT&T, в которой вариативным параметром является ракурс объекта на изображении, в качестве множества эталонов использовались 110 изображений 40 различных людей, а тестирование качества распознавания проводилось на других 291 фотографии тех же людей [20].

В качестве признаков применялись гистограммы ориентированных градиентов (HOG) [3, 22], которые при иерархическом распознавании на каждом j -м уровне вычислялись для разбиений классифицируемых объектов на сетку различного размера (в нашем эксперименте, квадратные сетки 5x5, 10x10, 15x15 и 20x20). Предлагаемый подход (4)-(7) фактически позволяет осуществить автоматический выбором наилучших для каждого классифицируемого объекта размеров сетки [20].

В качестве мер близости воспользуемся традиционной метрикой Евклида (2) и критерием, основанным на НТ-PNN (3), показавшим высокую

точность в задачах распознавания образов [18]. Оценки вероятности ошибки распознавания для фиксированного размера сетки сведены в табл. 1.

Таблица 1

**Оценки вероятности ошибки распознавания
для фиксированного размера сетки**

БД	Мера близости	Размеры сетки НОГ			
		5x5	10x10	15x15	20x20
Yale	Метрика Евклида (2)	13,3%	7,3%	7,3%	3%
	НТ-PNN (3)	11,5%	6,7%	6,7%	1,8%
AT&T	Метрика Евклида (2)	7,5%	2,5%	4,5%	5,75%
	НТ-PNN (3)	5,5%	2,7%	4%	6%

Далее в табл. 2 приведены вероятности ошибки для комбинирования результатов распознавания, полученных для всех выбранных размеров сетки. Проводится сравнение предложенного иерархического подхода (1)-(4) с усреднением решений, применяемым в традиционной РНОГ [7]. Кроме того, для сравнения в столбце "Наилучшая точность для фиксированного размера сетки" показана наименьшая вероятность ошибки из таблицы 1, которая может быть достигнута, если исследователь заранее задаст наиболее подходящий для задачи размер сетки.

Таблица 2

Оценки вероятности ошибки иерархического распознавания

БД	Мера близости	Наилучшая точность для фиксированного размера сетки	РНОГ	Иерархический подход (1)-(4)
Yale	Метрика Евклида (2)	3%	4,8%	2,4%
	НТ-PNN (3)	1,8%	10,3%	1,8%
AT&T	Метрика Евклида (2)	2,5%	4,2%	2,7%
	НТ-PNN (3)	2,7%	6%	2,5%

По результатам проведённых экспериментов можно сделать следующие выводы [20]. Во-первых, традиционный способ сопоставления пирамид HOG за счет усреднения результатов распознавания гистограмм для различных значений размеров сетки недостаточно эффективен по сравнению с выбранными заранее наилучшими значениями параметров. И, во-вторых, основанный на принципе максимума апостериорной вероятности критерий (1) показал высокую эффективность, причём не только для нашей НТ-PNN, для которой может быть получена строгая оценка апостериорной вероятности [20], но и для традиционной метрики Евклида. Таким образом, по результатам предварительных экспериментов можно сделать вывод о перспективности предлагаемой иерархической системы распознавания и целесообразности дальнейшего изучения особенностей ее применения для задач распознавания составных кусочно-однородных объектов [15, 25].

Проиллюстрируем действие предлагаемого подхода на примере распознавания изображения (рис. 1, *а*) из БД Yale [20].

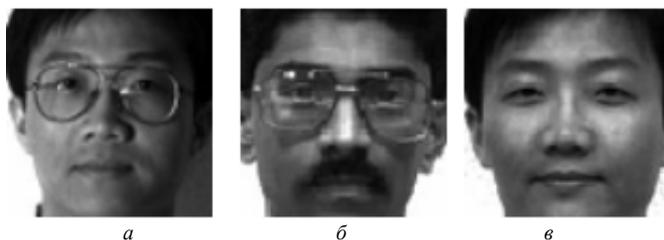


Рис. 1. Распознаваемый объект (*а*), ближайший в смысле рассогласования НТ-PNN (3) эталон (сетка 20x20) (*б*) и ближайший в смысле (3) эталон (сетка 10x10) (*в*)

Несмотря на то, что в целом для БД Yale точность критерия с большой сеткой (20x20) в среднем существенно лучше остальных (см. табл. 1), в этом случае для этого набора параметров было получено неверное решение (см. рис. 1, *б*). И только для сетки (10x10) решение в пользу эталона (рис. 1, *в*) принято верно. Действительно, в данном случае апостериорная вероятность (6) максимальна. В тоже время для сетки 20x20 рассогласование между входным объектом (см. рис. 1, *а*) и эталонами (см. рис. 1, *б* и *в*) практически совпадает: 0,266 и 0,269 соответственно. Поэтому и апостериорная вероятность (4) принадлежности объекта (см. рис. 1, *а*) к эталону (см. рис. 1, *б*) не велика. В тоже время для сетки 20x20 рассогласова-

ния между распознаваемым объектом и эталонами (см. рис. 1, б и в) заметно различаются: 0,254 и 0,212 соответственно.

Выводы

Предложен и реализован иерархический алгоритм распознавания изображений на основе статистического подхода и правила Чоу (7) с оценкой апостериорной вероятности (4) с помощью свойств вероятностной нейронной сети с проверкой однородности [18] (1), (3). Алгоритм позволяет повысить вычислительную эффективность распознавания за счет последовательного анализа изображений с различной степенью детализации (вначале – наименее детализированные изображения) и условием останова (7). Предложенный алгоритм показал свою эффективность в практически важной задаче распознавания лиц по фотографиям.

В рамках дальнейших исследований предполагается провести детальную экспериментальную оценку точности и быстродействия алгоритмов распознавания (4)-(7) в сравнении с существующими аналогами (такими, как PNOG), а также анализ применимости алгоритма для других задач распознавания сложных объектов (например, речи [26]).

Список литературы

1. Sonka, M., Hlavac, V., Boyle, R.: Image Processing, Analysis, and Machine Vision. Cengage Learning (4th ed.), 2014.
2. Lowe D.G. Distinctive Image Features from Scale-Invariant Keypoints // International Journal of Computer Vision, 2004. V. 60. No 2. P. 91–110.
3. Dalal N., Triggs B. Histograms of oriented gradients for human detection // IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), 2005. P. 886–893.
4. Bay, H., Ess, A., Tuytelaars, T., Van Gool, L.: SURF: Speeded Up Robust Features // Computer Vision and Image Understanding, 2008. V. 110. No. 3. P. 346–359.
5. Hawkins J., Blakeslee S. On Intelligence. New York: St. Martin's Griffin, 2005.
6. Баранов В.Г., Милов В.Р., Зарипова Ю.Х. Интеллектуализация системы распознавания образов на основе сравнения эффективности методов классификации // Информационно-измерительные и управляющие системы, 2010. Т. 8. № 2. С. 35–38.
7. Bosch A., Zisserman A., Munoz X. Representing Shape with a Spatial Pyramid Kernel // Proceedings of the 6th ACM International Conference on Image and Video Retrieval CIVR'07. New York, NY, USA: ACM, 2007. P. 401–408.
8. Munoz D., Bagnell J.A., Hebert M. Stacked Hierarchical Labeling // Proceedings of the 11th European Conference on Computer Vision: Part VI ECCV'10. Berlin, Heidelberg: Springer-Verlag, 2010. P. 57–70.

9. Zhai J.-H., Zhang S.-F., Liu L.-J. Image recognition based on wavelet transform and artificial neural networks // IEEE International Conference on Machine Learning and Cybernetics, 2008. P. 789-793.

10. Утробин В.А. Введение в теорию активного восприятия // Датчики и системы, 2013. № 7 (170). С. 34–39.

11. Cireşan D., Meier U., Masci J., Schmidhuber J. Multi-column deep neural network for traffic sign classification // Neural Networks. 2012. V. 32. P. 333–338.

12. Savchenko A.V. Directed enumeration method in image recognition // Pattern Recognition, 2012. V. 45. No 8. P. 2952–2961.

13. Chow, C.K. On optimum recognition error and reject trade-off // IEEE Transactions on Information Theory, 1970. V.16. P. 41–46.

14. Савченко В.В., Савченко А.В. Принцип минимального информационного рассогласования в задаче распознавания дискретных объектов // Известия вузов России. Радиоэлектроника, 2005. Вып.3. С.10–18.

15. Савченко А.В., Милов В.Р. О построении иерархической системы интеллектуального анализа и распознавания аудио/видео объектов // Нейрокомпьютеры: разработка, применение, 2014. № 11 (в печати).

16. Viola, P., Jones, M.J. Rapid object detection using a boosted cascade of simple features // IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), 2001. V.1. P. 511-518.

17. Савченко А.В. Образ как совокупность выборок независимых одинаково распределенных значений признаков в задачах распознавания сложноструктурированных объектов // Заводская лаборатория. Диагностика материалов, 2014. Т. 80, № 3. С. 70–80.

18. Savchenko A.V. Probabilistic neural network with homogeneity testing in recognition of discrete patterns set // Neural Networks. 2013. V. 46. P. 227–241.

19. Specht D.F. Probabilistic neural networks // Neural networks, 1990. V. 3, No 1. P. 109–118.

20. Савченко А.В. Выбор параметров алгоритма распознавания изображений на основе коллектива решающих правил и принципа максимума апостериорной вероятности // Компьютерная оптика, 2012. Т.36, №1. С.117-124.

21. Wald A. Sequential Analysis. New York: Dover Publications, 2013.

22. Савченко А.В. Об одной модификации метода SIFT на основе информационного расхождений Кульбака-Лейблера в задаче распознавания образов // Нейроинформатика-2012. XIX Всероссийская научно-техническая конференция. Сборник научных трудов. Ч. 1. М.: НИЯУ МИФИ, 2012. С.134-141.

23. <http://vision.ucsd.edu/content/yale-face-database>

24. <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>

25. Савченко А.В., Милов В.Р. Вероятностные нейросетевые модели и методы распознавания составных объектов // Нечеткие системы и мягкие вычисления-2014. VI Всероссийская научно-практическая конференция. Т. 2. 2014. С.200-208.

26. Benesty J., Sondhi M.M., Huang Y. Springer Handbook of Speech Processing. Berlin: Springer, 2008.

Стендовая сессия 4

Нейробиология

В.Б. КОТОВ

Научно-исследовательский институт системных исследований РАН, Москва
vkotov@ru.ru

ИСПОЛЬЗОВАНИЕ НЕЙРОНОВ С ДВУМЯ ВХОДАМИ В ГЕНЕРАТОРЕ ПОСЛЕДОВАТЕЛЬНОСТЕЙ ВНУТРЕННИХ ОБРАЗОВ

Рассмотрена работа рекуррентной нейронной сети (РНС) в качестве генератора последовательностей внутренних образов (ГПВО). Предложено для улучшения работы сети использовать нейроны с двумя суммирующими входами. Показано, что РНС с такими нейронами по сравнению с сетью простых суммирующих нейронов имеет увеличенную ёмкость и даёт возможность записывать и воспроизводить последовательности с совпадающими образами.

Ключевые слова: *генератор последовательностей внутренних образов, рекуррентная нейронная сеть, гиппокамп.*

V.B. KOTOV

Scientific Research Institute for System Analysis RAS, Moscow
vkotov@ru.ru

USING TWO-INPUT NEURONS FOR INNER IMAGE SEQUENCE GENERATOR

We consider the operation of a recurrent neural network (RNN) generates inner image sequences. Neurons with two summing inputs are suggested to improve the network performance. It is demonstrated that an RNN based on such neurons has increased capacity as compared with one-input neural networks and enables memorization and recall of the sequences with nearly identical or even identical images.

Keywords: *inner image sequence generator, recurrent neural network, hippocampus.*

Введение

Одной из главных особенностей нервной системы позвоночных является наличие гиппокампальной системы, способной записывать и воспроизводить временные последовательности обработанных образов мира [1,2]. Любая искусственная интеллектуальная система, претендующая на замену нервной системы человека (или, скажем, воробья) должна обладать аналогом гиппокампа. Ядро искусственного гиппокампа – генератор последовательностей внутренних образов (ГПВО) [3,4]. Такой генератор способен выдавать воспроизводимые последовательности образов внутреннего представления. Каждый такой образ ассоциируется с образом внешнего представления – образом мира. Тем самым происходит запись последовательности образов мира, которая в дальнейшем может быть воспроизведена и использована искусственным мозгом в качестве источника информации даже в отсутствие внешних сигналов.

Представляется естественным использовать в качестве ГПВО рекуррентную нейронную сеть (РНС) [5]. Это связано как с наличием биологических аналогов, так и с простотой и гибкостью РНС. Для успешного выполнения своей функции ГПВО должен обладать рядом свойств, таких как воспроизводимость записанных последовательностей, достаточно большая ёмкость, возможность записи временных последовательностей с совпадающими образами. Простейшая РНС, построенная из нейронов с одним суммирующим входом, не способна в полной мере удовлетворить этим требованиям. Требуется более сложная конструкция, однако желательно, чтобы необходимые усложнения не были чрезмерными и имели ясный смысл и биологические аналогии. Здесь в качестве такого усложнения рассматривается использование нейронов с двумя суммирующими входами.

РНС с простыми суммирующими нейронами

Рассмотрим сеть с бинарными нейронами и бинарными связями. Время дискретное, изменение состояний (выходов) нейронов происходит синхронно в каждый момент времени. Обозначим N – число нейронов, $x_i(t)$, $y_i(t)$ – вход и выход i -го нейрона в момент t , T – матрица связи между нейронами. Функционирование сети в векторном виде можно записать в виде

$$\mathbf{x}(t) = T\mathbf{y}(t-1), \quad (1)$$

$$\mathbf{y}(t) = P_a\mathbf{x}(t), \quad (2)$$

где \mathbf{P}_a – оператор, преобразующий a максимальных компонент вектора \mathbf{x} в единицы, а остальные компоненты – в нули (a – активность – целое положительное число, меньше N). Согласно уравнению (1) входы нейронов получаются путем взвешенного суммирования выходов нейронов в предыдущий момент времени.

В модели число активных нейронов постоянно и равно a . Обычно активность выбирается достаточно малой, значительно меньшей числа нейронов, что соответствует генерации разреженных образов. Заметим, что в формуле (2) преобразование вход-выход нелокальное – выход нейрона зависит от входов всех нейронов. Такое не очень естественное предположение связано с желанием получить постоянную активность при дискретном времени и синхронной динамике сети. Более естественные предположения можно получить для случаев дискретного времени или асинхронной динамики с использованием дополнительных нейронов – регуляторов активности.

Для записи временной последовательности образов (с заданной активностью a) $\mathbf{v}(t)$, $t=1, \dots, M$ (M – длина временной последовательности) формируем матрицу связей

$$\mathbf{T} = \mathbf{P}(\mathbf{v}(2) \otimes \mathbf{v}^T(1) + \mathbf{v}(3) \otimes \mathbf{v}^T(2) + \dots + \mathbf{v}(M) \otimes \mathbf{v}^T(M-1)), \quad (3)$$

где \mathbf{P} – оператор, заменяющий положительные элементы матрицы единицами. Каждый член в правой части формулы (3) связывает некоторый образ последовательности со следующим образом. Для записи циклической последовательности надо добавить член, связывающий последний член последовательности с первым, т.е. $\mathbf{v}(1) \otimes \mathbf{v}^T(M)$.

Если записываемые образы не пересекаются, т.е. имеют несовпадающие активные нейроны, то описывающие их векторы ортогональны, и при задании начального состояния $\mathbf{y}(1) = \mathbf{v}(t_0)$ все последующие образы записанной последовательности воспроизводятся безошибочно. К сожалению, число непересекающихся образов невелико – не больше N/a . Для увеличения длины записываемой последовательности образов необходимо использовать пересекающиеся образы, когда один и тот же нейрон активен для нескольких образов последовательности. При этом возникают ошибки воспроизведения образов. При небольших пересечениях ошибки воспроизведения невелики, и алгоритм преобразования (2) способен с ними справляться, т.е. следующий образ воспроизводится правильно даже для слегка искажённого образа.

Численные эксперименты показывают, что можно записывать и успешно воспроизводить последовательности длиной M , примерно равной N . На рис. 1 представлены результаты вычислений для ошибки воспроизведения E в зависимости от числа нейронов N при заданной длине запи-

санной циклической последовательности $M=200$. Вычисления проводились при $a = 10$. В качестве ошибки E выбрана величина хеммингова расстояния между записанной и воспроизводимой последовательностями, делённого на $2Ma$. Записываемая последовательность образов формировалась случайным образом для каждого эксперимента. Специальный выбор последовательностей позволил бы существенно уменьшить ошибку при $M \approx N$, однако использование ГПВО подразумевает случайный набор образов последовательности, не остающийся неизменным в процессе функционирования

При $N > M$ (неравенство выполняется с некоторым запасом) воспроизводится периодическая бесконечная последовательность, каждый период которой совпадает с записанной последовательностью. По мере приближения к равенству $N=M$ в воспроизводимой последовательности появляются и увеличиваются ошибки. По мере уменьшения N при выполнении неравенства $N < M$ воспроизводимая последовательность не имеет ничего общего с записанной последовательностью, теряется свойство периодичности, генерация становится «хаотической».

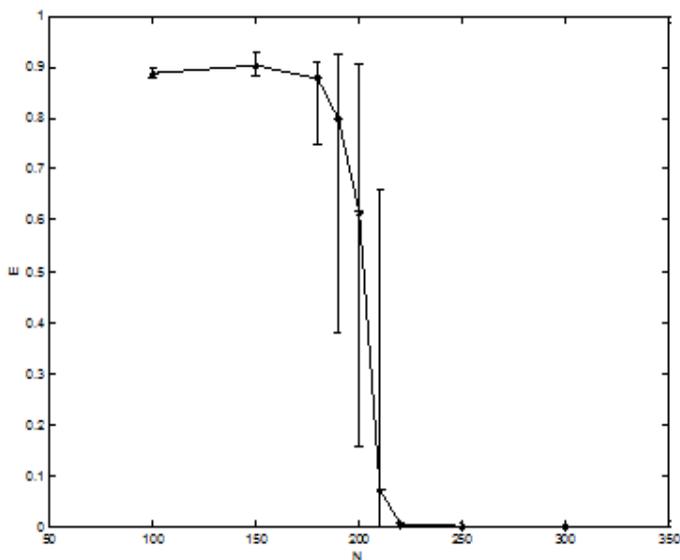


Рис. 1. Ошибка воспроизведения последовательности в зависимости от числа нейронов

Максимальное значение длины последовательности M_{\max} порядка N можно рассматривать как неплохой результат. Здесь помогает алгоритм преобразования (2), который препятствует накоплению ошибки. При более правдоподобных с точки зрения биологии локальных алгоритмах преобразования величина M_{\max}/N может стать заметно меньше единицы. В любом случае, учитывая, что общее число образов (с активностью a) равно $N/(a!(N-a)!)$ и значительно больше N , меры по увеличению ёмкости сети не кажутся лишними.

Серьёзные проблемы возникают в случае записи двух или более последовательностей, имеющих одинаковые образы. Пусть записаны две циклические последовательности образов $\mathbf{v}^{(1)}(t)$, $t=1, \dots, M_1$ и $\mathbf{v}^{(2)}(t)$, $t=1, \dots, M_2$, причём $\mathbf{v}^{(1)}(M_1)=\mathbf{v}^{(2)}(M_2)$. Для этого в формуле (3) суммирование производится по обеим последовательностям с учётом их цикличности. В процессе воспроизведения первой последовательности по достижении образа $\mathbf{v}^{(1)}(M_1)$ возникает неопределённость в выборе следующего образа. Возможны варианты: переход к следующему образу первой последовательности (в данном случае $\mathbf{v}^{(1)}(1)$), переход к следующему образу второй последовательности ($\mathbf{v}^{(2)}(1)$), переход к некоторому гибриду этих двух образов. В первом случае воспроизводится циклически исходная последовательность. Во втором случае происходит перескок на вторую последовательность с её циклическим воспроизведением. В третьем случае воспроизводится новая последовательность с возможными перескоками на записанные последовательности.

Эти случаи иллюстрируются рис. 2, 3, 4. На этих рисунках точка с координатами (t, dt) имеет цвет (в данном случае яркость серого), отражающий значение хеммингова расстояния между векторами $\mathbf{y}(t)$ и $\mathbf{y}(t+dt)$. Чёрный цвет означает совпадение векторов. Рисунки получены при $N=200$, $a=10$, $M_1=30$, $M_2=12$.

Чёрные вертикальные линии означают периодичность генерации. Для случая рис. 2 исходная последовательность повторяется неограниченно. Для рис. 3 после воспроизведения первой последовательности осуществляется переход с общего образа на вторую последовательность, которая затем повторяется неограниченно. Для случая рис. 4 после воспроизведения первой последовательности начинается периодическая генерация новой последовательности, период которой больше периодов исходных последовательностей.

Какой именно вариант перехода с общего образа будет реализован, зависит от случайного выбора записываемых последовательностей. Возможность контролируемого выбора отсутствует. Это существенный недостаток, побуждающий искать пути улучшения конструкции ГПВО.

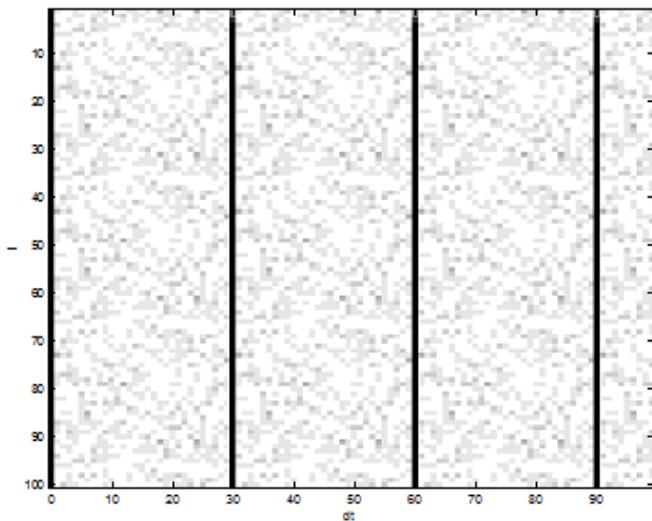


Рис. 2. Воспроизведение исходной последовательности

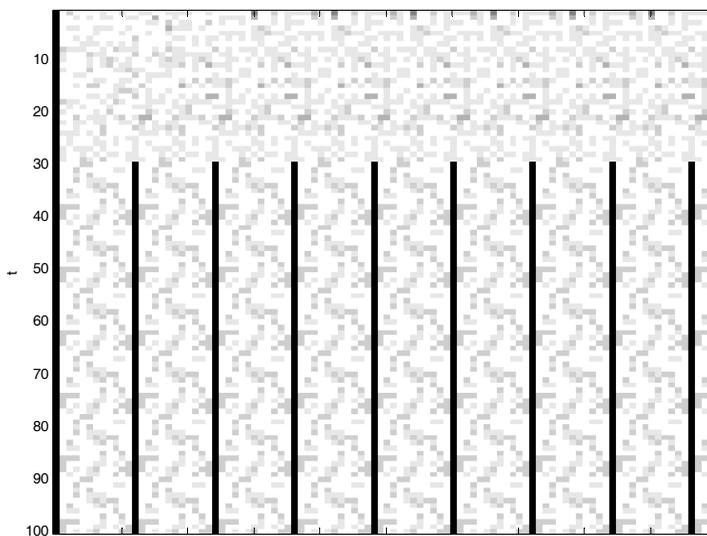


Рис. 3. Перескок на другую последовательность

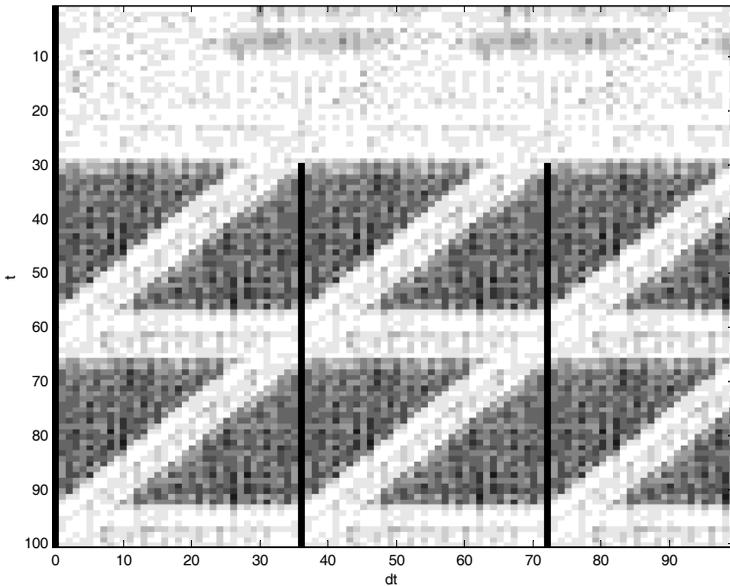


Рис. 4. Генерация новой последовательности

Пути улучшения схемы, подсказанные Природой

Биология подсказывает довольно простые способы устранения указанных недостатков. Синапсы, расположенные в разных местах (реального) нейрона, имеют разные характеристики преобразования приходящего сигнала [2]. Для нас наиболее интересны временные характеристики – задержка и время интегрирования. Приходящий к данному синапсу сигнал влияет на генерацию выходного сигнала нейрона с некоторой задержкой, эта задержка тем больше, чем дальше синапс находится от тела нейрона (для одинаковых синапсов). Время интегрирования – время, в течение которого приходящий к синапсу сигнал влияет на генерацию выходного сигнала нейрона – может сильно различаться для разных синапсов. Часто синапсы, находящиеся на теле клетки и проксимальных дендритах, и синапсы на дистальных дендритах имеют разные времена интегрирования. Кроме того, имеются разные типы синаптических рецепторов, преобладание в синапсе того или иного типа рецепторов приводит к существенно различающимся задержкам и временам интегрирования. Например, метаболитные рецепторы ответственны за большие задержки и времена интегрирования, на два порядка большие по сравнению с ионотропными

рецепторами. Заметим, что синапсы с разными типами рецепторов обычно располагаются в разных местах нейрона.

Возвращаясь к конструкции ГПВО, следует ожидать немалой выгоды от использования нейронов с несколькими входами, имеющими разные характеристики. Для простоты ограничимся случаем двух входов. Один из входов аналогичен рассмотренному выше – он даёт взвешенную сумму выходов нейронов с предыдущего временного такта. При выборе свойств второго входа имеется значительный произвол. Вполне естественно производить суммирование по нескольким моментам времени, предшествующим данному моменту. Такой вход можно назвать инициализирующим. Нейрон должен становиться активным только при достаточной интенсивности обоих входов, поэтому вычисление выхода по входам не должно сводиться к суммированию входов с последующим применением пороговой функции. Простейшая приемлемая операция – умножение входов. Ею и ограничимся, осознавая возможную неоптимальность такого выбора. Кроме того, для простоты примем, что для второго входа суммирование по времени заменено на выборку значений выходов нейронов в момент времени, отстоящий от данного на два такта.

Заметим, что для непрерывного времени все входы должны быть интегрирующими, однако ядра интегрирования существенно различаются для разных входов.

РНС с двумя суммирующими входами

Функционирование РНС описывается уравнениями

$$\mathbf{x}_1(t) = T_1 \mathbf{y}(t-1), \quad (4)$$

$$\mathbf{x}_2(t) = T_2 \mathbf{y}(t-2), \quad (5)$$

$$\mathbf{y}(t) = \mathbf{P}_a(\mathbf{x}_1(t) * \mathbf{x}_2(t)), \quad (6)$$

где \mathbf{x}_1 , \mathbf{x}_2 – векторы первого и второго входов, T_1 , T_2 – матрицы связей для первого и второго входов, «*» обозначает поэлементное умножение векторов. Согласно уравнениям (4)-(6) состояние сети $\mathbf{y}(t)$ зависит от состояния в два предыдущих момента времени.

Запись последовательности образов $\mathbf{v}(t)$ производится путём формирования матрицы связей для первого входа по формуле (3) и матрицы связей для второго входа

$$T_2 = \mathbf{P}(\mathbf{v}(3) \otimes \mathbf{v}^T(1) + \mathbf{v}(4) \otimes \mathbf{v}^T(2) + \dots + \mathbf{v}(M) \otimes \mathbf{v}^T(M-2)) \quad (7)$$

с очевидными добавлениями, если требуется записать циклическую последовательность. Матрица T_2 связывает между собой любой образ последовательности с образом, отстающим на два такта.

Учет предыстории (в данном случае ещё одного более состояния) позволяет повысить надёжность воспроизведения последовательностей. Численные эксперименты, проведенные при тех же значениях N , a , что и для рис. 1, дают результат, отображённый на рис. 5. Сравнение рис. 1 и 5 показывает увеличение ёмкости сети в полтора раза. Увеличение небольшое, но не бесполезное.

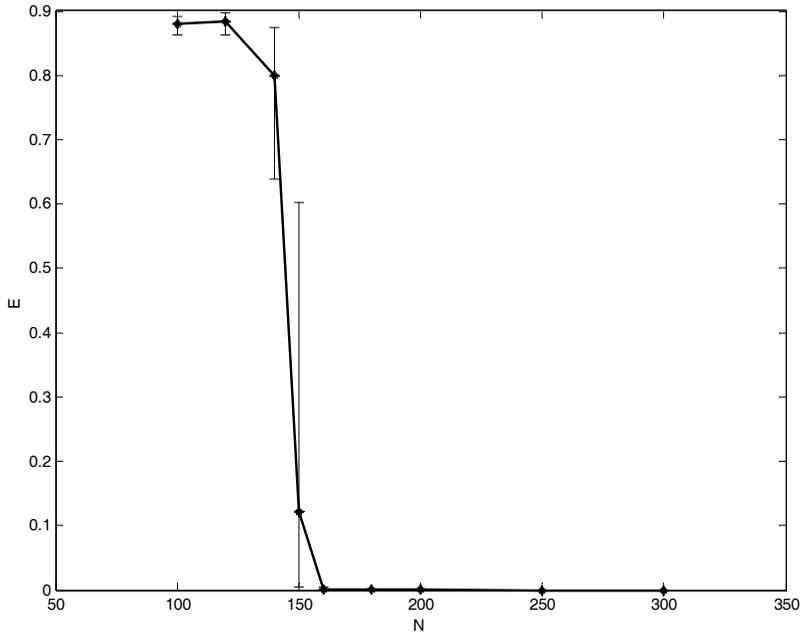


Рис. 5. Ошибка воспроизведения последовательности в зависимости от числа нейронов

Более существенно, что использование нейронов с двумя входами позволяет устранить неоднозначность при записи одной или нескольких последовательностей с совпадающими (или близкими) образами. Если образы перед совпадающими образами не совпадают, то именно они являются идентификаторами последовательностей. Их учёт при вычислении образа, следующего за общим образом последовательностей, не позволяет перескочить на другую последовательность. Численные эксперименты, проведённые при условиях, при которых получены рис. 2-4, неизменно приводили к результатам, отображенным на рис. 2.

Заметим, что при совпадении пар последовательных образов описанная РНС не справляется с неоднозначностью определения образа, следующего за такой парой. Необходимо учитывать ещё одно (или больше) состояний. Часто оказывается полезным использование для второго входа суммирования по нескольким предыдущим состояниям. Другой способ решения проблемы – включение ещё одного входа (или нескольких входов), зависящих от более ранних состояний.

Заключение

Таким образом, использование в РНС нейронов с двумя входами вместо нейронов с одним входом позволяет увеличить общую длину записываемых последовательностей и устранить проблему неоднозначности, возникающую при записи последовательностей с одинаковыми образами.

РНС с усовершенствованными нейронами с полным правом может рассматриваться в качестве кандидата на роль ГПВО. Чтобы получить простейший гиппокамп, остаётся только организовать связи (в обе стороны) между нейронами РНС и нейронами, несущими предназначенную для записи информацию. При этом можно использовать как описанные входы для нейронов РНС, так и организовать отдельный вход (входы) для внешних образов.

Список литературы

1. Striedter G.F. Principles of Brain Evolution. Sunderland, MA, USA: Sinauer Associates, 2005.
2. The Hippocampus Book. /Ed. by P. Andersen, R. Morris, D. Amaral, T. Bliss, J. O'Keefe. Oxford University Press, 2007.
3. Котов В.Б., Политова С.В. Нейронные системы для моделирования причинности. // Радиотехника и электроника, 2004. Т. 49. № 12. С. 1452-1462.
4. Котов В.Б., Давыдова С.В. Причинность и нейронные сети. Волгоград: «Принт», 2006.
5. Осовский С. Нейронные сети для обработки информации / Пер. с польского И.Д. Рудинского. М.: Финансы и статистика, 2002.

Г. С. ВОРОНКОВ

Московский государственный университет имени М.В. Ломоносова
av13675@yandex.ru

**МАЛОИЗВЕСТНЫЙ ЗАГАДОЧНЫЙ ФЕНОМЕН В ЗРЕНИИ:
ОПИСАНИЕ И ПОПЫТКА АНАЛИЗА**

Описывается феномен, состоящий в зрительном ощущении, что в малом отверстии на просвет имеет место пятно, напоминающее паутинное сплетение, с включениями двух основных типов, статичными и динамичными. Помимо описаний формы и условий проявления, в работе описывается ряд обнаруженных загадочных свойств пятна и проводится их анализ; делается заключение о составной природе картины пятна и высказываются предположения, объясняющие ряд свойств пятна; используются представления из оптики, физиологии и офтальмологии.

Ключевые слова: *интерференция, ощущение видения, дефицит зрения, стабилизированное изображение, константный экран.*

G.S. VORONKOV

Lomonosov Moscow State University
av13675@yandex.ru

**LITTLE-KNOWN MYSTERIOUS PHENOMENON IN VISION:
DESCRIPTION AND AN ATTEMPT OF THE ANALYSIS**

The paper describes a phenomenon of visual perception: in a small peek-a-boo hole there exists a web-like patch that contains inclusions of two main types, static and dynamic. Besides a description of the patch form and manifestation conditions, the paper presents a number of disclosed enigmatic patch characteristics. Based on the performed analysis, it is concluded that the patch image has a composite nature. Suggestions are made to explain some characteristics of the patch. Evidence from the wave optics, vision neurophysiology, and ophthalmology is attracted for reasoning.

Keywords: *interference, vision perception, vision deficit, stabilized image, constant screen.*

Введение

Хотя описываемый здесь феномен известен в офтальмологии, его систематическое общепринятое описание и, главное, объяснение природы, по-видимому, отсутствуют¹. Не было найдено автором упоминания о нем также в руководствах и монографиях по физиологии зрения.

Причин такого "широкого невнимания" к этому феномену, по-видимому, несколько. Это специфичность условий проявления этого феномена, невозможность использовать объективные методы регистрации его проявления и ряд несоответствий свойств этого феномена привычным представлениям о работе зрительного аппарата.

Проявлением феномена является субъективное ощущение видения маленького темного пятна ("паучка") в малом отверстии на просвет (например, в игольном проколе в листе, освещенном с обратной стороны); при приближении листа с отверстием ближе к глазу пятно приобретает вид паутинового сплетения, содержащего включения; последние составляют два основных вида, статичные и динамичные. Сквозь отверстие с видимым пятном можно видеть объекты фона, например, буквы офтальмологической таблицы. Но пятно сильно затрудняет это видение. Пятно создает в этих условиях дефицит зрения, не обнаруживаемый в естественных условиях видения. По этой причине сначала этот феномен был именован как **специфический "дефицит зрения"** – СДЗ [2, 3]².

С точки зрения физиологии зрительной системы, наибольший интерес представляют, однако, трудно объяснимые с привычных позиций свойства пСДЗ. Их описание и анализ составляет основную задачу настоящей работы.

Описание способа наблюдений и объектов исследования

Для наблюдений использовали диафрагму из офтальмологического набора, а также непрозрачную пластинку или лист бумаги с отверстиями от 0,5 до 1,5 мм в диаметре. Фоном служил освещенный белый экран, офтальмологическая таблица или просто яркий источник света (солнце, небо). Испытуемый проводил разные манипуляции с диафрагмой, закреп-

¹ Сведения из офтальмологии, приводимые в статье, почерпнуты автором из книги [1] и бесед со многими врачами и научными сотрудниками – офтальмологами.

² В дальнейшем было сделано наблюдение, что глазу, видящему пятно СДЗ (пСДЗ) как значительно более плотное, чем пСДЗ, видимое другим глазом, соответствует значительно меньшая острота зрения. В связи с этим, в настоящей работе термин **специфический дефицит зрения** используется уже без кавычек.

ленной в штативе или находящейся непосредственно в руке (изменение расстояния до глаза, поворот и другие). Зрение осуществлялось монокулярно (одним глазом). Характеристики пСДЗ описывались испытуемыми устно, в виде ответов на вопросы экспериментатора, и в виде зарисовок. Всего опрошено семь испытуемых (6, 33, 35, 63, 69, 73 и 75 лет) с разной степенью остроты зрения. Глаз испытуемого, на основе субъективных отчетов которого сделано основное описание СДЗ в данной работе, имел рефракцию +1,75 и начальную стадию катаракты. Коррекция зрения очками не проводилась.

Общее описание пятна СДЗ

1. От расстояния диафрагмы/отверстия до глаза зависит различие деталей в паттерне пСДЗ (рис.1). На расстоянии вытянутой руки пСДЗ имеет вид темного "паучка" в светлом отверстии. При приближении диафрагмы пСДЗ приобретает очертания паутинового сплетения в светлом круге, в пятне становятся различимыми разного рода включения. Эти включения схематически изображены на рис. 2 (их свойства описываются ниже).

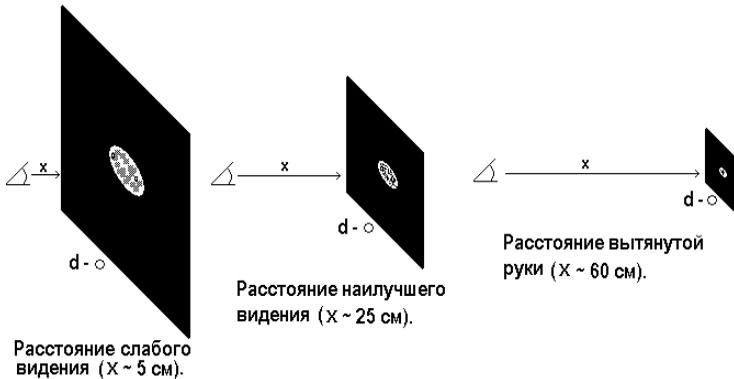


Рис. 1. Общий вид пятна СДЗ на месте отверстия при разном удалении последнего от глаза

Видимый светлый круг и пятно в нем значительно больше самого отверстия. Для представления о соотношении пятна и отверстия под каждым квадратом с изображением пСДЗ показан сравнительный размер отверстия (рис. 1, 2 и 3). Диаметр светлого круга и пятна СДЗ, видимых с расстояния около 25 см, составляет примерно 2,5 мм; по расчетам, проекция пСДЗ на сетчатке равна, примерно, размеру fovea.

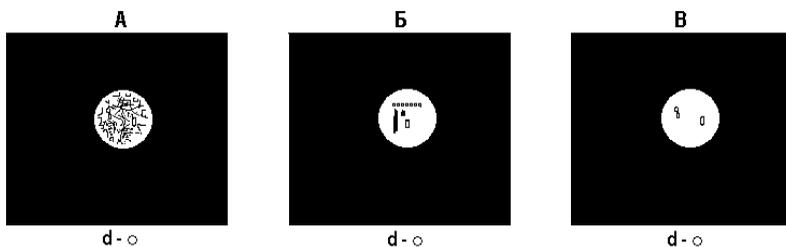


Рис. 2. Наиболее типичный паттерн пятна СДЗ (А) и изображенные отдельно разного рода динамические (Б) и статичные (В) включения в нем

2. Оптимальный диаметр отверстия (d) для восприятия типичного пСДЗ около 0,5 мм. В этом случае пСДЗ и светлый круг по размерам практически совпадают. Форма пСДЗ (круг) практически не зависит от формы оправы отверстия; в этом можно убедиться, рассматривая отверстие под лупой. Четкость паттерна пСДЗ зависит от освещенности фона за листом с отверстием.

3. С уменьшением или увеличением размера отверстия (по отношению к оптимальному ($d \sim 0,5$ мм)) соответственно изменяется размер светлого круга; само пСДЗ в круге при этом почти не меняется в размере, но соответственно либо темнеет и затем становится неразличимым, либо бледнеет и затем исчезает по частям (см. рис. 3).

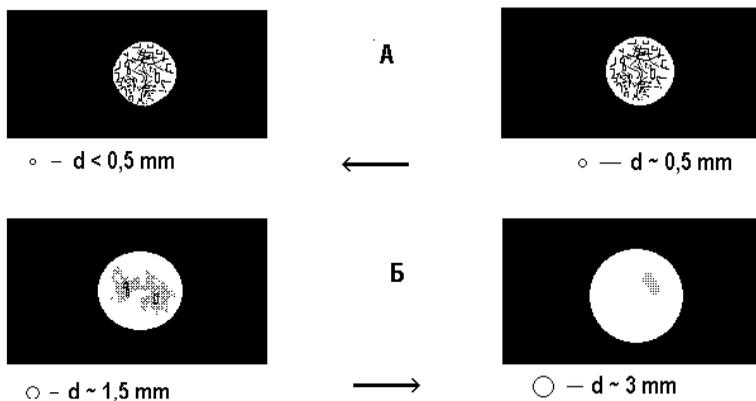


Рис. 3. Уменьшение и увеличение светлого круга и изменение пСДЗ в нем соответственно с уменьшением (А) и увеличением (Б) диаметра отверстия (d)

4. После мигания, сжимания век или надавливания на глазное яблоко в пятне СДЗ часто появляются включения (см. рис. 2, Б), которые плавно спускаются вниз и исчезают; иногда, они могут сохранять на некоторое время свое местоположение в пятне, но исчезают после очередного мигания, заменяясь другими. Эти включения могут быть разного размера и формы, быть тёмными или светлыми. Помимо этого, может наблюдаться несколько другая, но тоже динамичная картина; она напоминает волнами стекающую по паутинному сплетению пСДЗ, как по пятну на стекле, жидкость.

5. Некоторые включения в пСДЗ, например, напоминающие светлые "везикулы", могут быть стабильными, не зависящими от механических воздействий на глазное яблоко (см. рис.2, В). Они сохраняют свое местоположение в пСДЗ от сеанса к сеансу; и эти наблюдения составили по длительности уже многие месяцы. Этот пространственный паттерн "везикул" индивидуален для данного глаза и может служить его меткой.

6. Пятно СДЗ правого и пятно СДЗ левого глаза могут сильно различаться по плотности и конфигурации паттерна, в частности, меткой. Это отмечено, по крайней мере, для случая, когда глаза имели разную остроту зрения (по офтальмологическому показателю). Так глаз с заметно большей плотностью пСДЗ имел показатель 0,4 и содержал 4 везикулы в метке, другой глаз - соответственно 0,7 и 2.

7. Когда отверстий несколько, и они охватываются одним взором, одновременно в каждом из отверстий видны одинаковые картины пятна СДЗ. Это иллюстрирует рис. 4, А; для наглядности здесь картина каждого пСДЗ представлена только его меткой.



Рис. 4. Картины пятна СДЗ во множестве диафрагм (А), картина пятна СДЗ через сетчатые очки (Б) и видимый фон (буквы офтальмологической таблицы) сквозь пСДЗ (В)

8. Сквозь пСДЗ (через изъязны в нем) можно видеть объекты фона, например, буквы офтальмологической таблицы (см. рис. 4, В). Однако пСДЗ сильно мешает четкому их видению.

9. Если смотреть через очки, в которые вместо линз вставлена мелкоячеистая сеточка (диаметр ячеек порядка нескольких десятых мм), то картина пСДЗ видится кардинально видоизмененной: сетчатое пСДЗ представлено только четким сетчатым рисунком без каких-либо признаков динамических или стабильных включений «обычного» пСДЗ (Рис.4, Б). Сквозь ячейки этого сетчатого пСДЗ могут быть видны объекты фона так же, как они видны сквозь изъяны обычного пСДЗ.

При приближении/удалении **отверстия** от глаза соответственно увеличивается или уменьшается размер каждой ячейки сетчатого пСДЗ. Соответственно уменьшается или увеличивается число ячеек в самом сетчатом пятне. Размер пятна при этом практически не меняется.

При отодвигании **сеточки** от глаза ближе к отверстию, постоянно находящемуся от глаза на расстоянии наилучшего видения, изменения в картине сетчатого пСДЗ другие, чем при приближении/удалении диафрагмы к сетчатым очкам. Так, ячейки, составляющие сетчатое пСДЗ, при удалении сеточки от глаза к отверстию увеличиваются в размере, при этом увеличивается и расстояние между ячейками (размер сетчатого пСДЗ сохраняется), и наступает момент, когда вместо сетчатого пСДЗ появляется обычное пСДЗ, но затемненное, как если бы перед диафрагмой находилось вместо сеточки тонированное стекло.

10. Важная характеристика восприятия пСДЗ – пятно не смещается вместе со смещением зрака. Так, если фиксировать взор на одном объекте фона, видимом через один из изъянов в пСДЗ, и затем переместить взор на другой объект, видимый через другой изъян, само пятно пСДЗ не сместится при этом относительно этих объектов фона. Смещение пСДЗ по фону происходит только при перемещении самого отверстия. Образно говоря, пСДЗ и все включения в нем, статичные и динамичные проявляют себя во время смещения зрака так, как если бы это пятно находилось на стекле, вставленном в отверстие.

11. Однако при повороте (вращении) листа с отверстием пСДЗ не поворачивается вместе с оправой отверстия. По крайней мере, это можно с уверенностью утверждать в отношении его "метки" и направления движения динамичных включений.

12. В то же время, метка и направление движения динамичных включений воспринимаются как поворачивающиеся вместе с наклоном головы относительно оправы отверстия и направления силы тяжести. Так, при наклоне головы до плеча ($\sim 90^\circ$) паттерн метки и направление движения включений воспринимаются как изменившие направление на эти же $\sim 90^\circ$. При еще большем наклоне динамичные включения "стекают" уже вверх.

Объекты фона при этом воспринимаются как сохранившие положение относительно силы тяжести.

13. Сетчатое пятно СДЗ так же, как и обычное пСДЗ, не смещается вместе с взором; оно не поворачивается с поворотом оправы отверстия, но поворачивается вместе с наклоном головы; сетчатое пСДЗ поворачивается также вместе с поворотом сеточки очков.

Отличительной характеристикой этого сетчатого пятна СДЗ является то, что при сдвиге отверстия вверх/вниз или вправо/влево сдвигаются в этом же направлении ячейки сетчатого пСДЗ; образно говоря, передние ячейки словно выталкиваются вперед за пределы пятна, подпираемые сзади движущимися ячейками. Такого сдвига при смещении отверстия не проявляют элементы обычного пятна СДЗ.

Попытка анализа природы пятна СДЗ

1. Само наличие динамических и стабильных включений в пятне СДЗ и такие их свойства, как свойство поворачиваться вместе с поворотом головы и появляться при механическом воздействии на глазное яблоко (И(4)), свидетельствуют о зависимости создающейся картины этих включений в пСДЗ при восприятии от состояния самого воспринимающего зрительного аппарата и/или зрительной системы в целом. С другой стороны, в отношении паутинового сплетения пятна СДЗ подобные свойства обнаружить в четком виде не удалось. Поэтому нельзя исключить возможность, что паутиноое сплетение обусловлено внешним по отношению к зрительной системе фактором. По-видимому, единственным предположением в последнем случае может быть предположение, что вследствие волновых свойств света, в малом отверстии создается интерференционная картина – своего рода голограмма. Такое представление объясняет свойства сплетения, подобные свойствам пятна, как если бы пятно находилось на стекле, вставленном в отверстие (И(4 и 8)).

Таким образом, в отношении пСДЗ в целом следует предположить два основных определяющих картину пСДЗ фактора, один - внешний по отношению к зрительной системе и другой – внутренний, принадлежащий самой зрительной системе. Другими словами, следует предположить составную, комплексную природу феномена СДЗ.

2. Есть основания для нескольких возможных альтернативных предположений в отношении происхождения динамических картин пСДЗ. Общим моментом для этих альтернатив является очевидное допущение, что в проводящих свет структурах глаза имеет место ток жидкости с включе-

ниями, тени от которых создают динамические картины на рецепторном растре. Одним из мест, где имеет место такой ток жидкости, является отверстие зрачка, соединяющее переднюю камеру глаза с пространством перед хрусталиком [1]. При некоторых патологиях наблюдается также ток жидкости между телом и капсулой хрусталика; возможно движение влаги и за сетчаткой, перед отражающими свет образованиями. Однако, имеющихся данных пока не достаточно, чтобы однозначно идентифицировать место тока жидкости, создающей описанную картину динамических включений в пСДЗ.

3. При анализе особенностей восприятия стабильных картин в пСДЗ необходимым, по-видимому, является привлечение данных, полученных при изучении восприятия так называемых стабилизированных изображений (картин) на сетчатке [4]. Действительно, стабильные картины пСДЗ, которые создаются, предположительно, как тени на рецепторном растре от стабильных дефектов или включений в проводящих свет структурах глаза, по определению являются стабилизированными.

Согласно некоторым представлениям, имеющим экспериментальные основания [5], восприятие стабилизированных изображений длится непродолжительное время, несколько секунд. В отличие от них, **картины пСДЗ не исчезают со временем.**

Пятно СДЗ не есть исключение, когда стабилизированное изображение не исчезает со временем. До некоторой степени подобным примером может служить послеобраз [6]. Его длительность измеряется в минутах. В другом случае, в исследованиях [4], стабилизированные изображения сохранялись долго благодаря специальным приемам. Тем не менее, эти примеры показывают принципиальную возможность длительного восприятия (точнее, ощущения видения) стабилизированных изображений. **Свойство пСДЗ вообще не исчезать со временем – прямое, на наш взгляд, свидетельство такой возможности.** Выяснение условий (причин), которые обуславливают восприятие стабилизированных картин пятна СДЗ независимо от времени, может, по-видимому, внести положительный вклад в решение остающихся вопросов, связанных с темой "восприятие стабилизированных изображений".

4. Основное и интригующее свойство части стабильной картины (метки) пСДЗ, а также динамичной его картины состоит в том, что они не смещаются по фону, видимому сквозь пятно, вместе со смещением взгляда (I(10)). Действительно, в отличие от пСДЗ, создаваемые на сетчатке стабилизированные изображения типа послеобраза, например, смещаются по фону со смещением взгляда.

Видимо, для объяснения различия в свойствах пСДЗ и послеобраза необходимо привлечение сведений о работе зрительных центров более высокого уровня, чем сетчатка глаза. Попытка этого делается ниже.

Известен факт, что в условиях нормального зрения внешний зрительный мир воспринимается стабильным. Другими словами, несмотря на то, что при перемещении взора проекции объектов перемещаются по сетчатке, они воспринимаются как не изменяющие свое местоположение относительно субъекта¹. Сравнительно недавно получены нейрофизиологические данные [8], свидетельствующие с большой вероятностью, что за свойство воспринимать пространство стабильным ответственен так называемый **константный экран - КЭ** [6]. **КЭ** представлен структурой новой коры, являющейся иерархически, функционально выше стриарной коры (**КЭ** представлен морфологически, вероятно, в заднетеменной коре)². Можно сказать, что **КЭ** имеет связанную, по сути, единую со зрительным миром систему координат.³

Ощущение видения картины пСДЗ (по крайней мере, картин его стабильных и динамических включений) лишь частично сходно с ощущением видения, которое создает **КЭ**. Так, пСДЗ тоже, как и мир, не смещается вместе со смещением взора (I(10)); однако, пСДЗ поворачивается вместе с поворотом сетчатки (при наклоне головы (I(12)), тогда как мир (фон, видимый сквозь пСДЗ) воспринимается стабильным – он не поворачивается при этом вместе с сетчаткой. Эти различия в свойствах восприятия картины пСДЗ и картины фона позволяют полагать, что ощущение видения фона и ощущение видения пСДЗ создаются разными центральными структурами. Мы предполагаем, что если ощущения видения фона создается посредством **КЭ**, то ощущение видения стабилизированных картин пСДЗ создается, какой-то одной из ретинопических проекций (например, в НКТ или новой коре). Примеры того, что ощущение видения может быть комплексным, создаваемым одновременно разными зрительными структурами (экранами) известны. Особенно много примеров такого рода даёт анализ феноменов бинокулярного зрения [см. 9]. В то же время,

¹ Это свойство зрения - восприятие зрительного пространства стабильным - было отмечено уже Гельмгольцем, в девятнадцатом веке (см. [7]).

² В отношении архитектуры нейронного механизма, обеспечивающего свойства **КЭ** пока лишь высказаны некоторые предположения [8].

³ Важно заметить, что объекты мира воспринимаются не только как сохраняющие свое местоположение в зрительном мире при перемещении взора, они воспринимаются также как сохраняющие свое положение относительно направления силы тяжести при повороте сетчатки.

ощущение видения стабилизированных изображений, в частности, послеобраза создается в обычных условиях, в отличие от пСДЗ, видимо, посредством КЭ. Это представление объясняет различие свойств пСДЗ и послеобраза.

Заключение

Сделанное в данной статье описание и проведенный первичный анализ позволили составить представление о природе проявления феномена СДЗ (пятне СДЗ (пСДЗ)) как комплексной, обусловленной несколькими, внешним и внутренними факторами. Описанные неожиданные свойства пСДЗ, обусловленные внутренними факторами, потребовали для их объяснения привлечения сведений и представлений о работе центральных структур зрительной системы. Попытка такого анализа свойств пСДЗ, проведенного здесь, дала основание предположить, что ощущение видения картин пСДЗ и ощущение видения сквозь пСДЗ картины фона создаются одновременно двумя разными центральными структурами - соответственно, одной из ретинотопических проекций и константным экраном. Многие из описанных в статье свойств пСДЗ не нашли ещё своего объяснения. По-видимому, расшифровка загадок СДЗ может внести свой вклад как в теорию – в физиологию зрения, так и в практику – в раннюю диагностику в офтальмологии.

Список литературы

1. Копаева В.Г. Глазные болезни. М.: Медицина, 2002.
2. Воронков Г.С. Специфический "дефицит зрения": описание и первичный анализ // X Международный Междисциплинарный Конгресс Нейронаука для Медицины и Психологии. Судак, Крым, Россия, 2-12 июня 2014. С. 106-107.
3. Voronkov G.S. Specific "vision deficit": description and analysis attempt // Int. J. Psychophysiology, 2014. V. 94 (2). Proceedings of the 17th World Congress of Psychophysiology (IOP 2014).
4. Зинченко В.П., Вергилес Н.Ю. Формирование зрительного образа (исследование деятельности зрительной системы). М.: Изд-во МГУ. 1969.
5. Ярбус А..Л. Роль движений глаз в процессе зрения. М.: Наука, 1965.
6. Зенкин Г. М., Петров А.П. Преобразования последовательного образа при движениях наблюдателя, константность зрительного поля и непредметные механизмы инвариантности // Физиология человека, 1976. Т. 2, № 6. С. 925-931.
7. Логвиненко А.Д. Зрительное восприятие пространства. М.: Изд-во МГУ, 1981.

8. Пигарев И.Н. Нейронные механизмы константности зрительного восприятия пространства. Док. дис. М., МГУ, 1989.

9. Рожкова Г.И. Бинокулярное зрение // Физиология зрения. Ред. А.Л. Бызов. М.: Наука, 1992. (Руководство по физиологии). С. 586-664.

В. В. ЛАВРОВ¹, А. В. РУДИНСКИЙ²

¹Институт физиологии им. И.П. Павлова РАН, Санкт-Петербург

²Центр системного консультирования и обучения "Synergia", Санкт-Петербург
vasilylavrov@yandex.ru

МЕЖНЕЙРОННАЯ КОММУНИКАТИВНАЯ СИСТЕМА: КОНТЕКСТНОЕ ПОЛЕ КОДИРОВАНИЯ ИНФОРМАЦИИ

Обнаруженное соответствие сверхмедленных волн биопотенциалов, обусловленных регуляторными процессами, и частотно-временных параметров мультিকлеточной импульсации кортикальных нейронов противоречит мнению о существовании специфических форм импульсного кодирования информации. Излагается гипотеза о том, что обмен информацией в нервной сети обеспечивается коммуникативной системой, создаваемой соответствием контекстов источника и приемника сигналов – то есть, при возникновении контекстного поля.

Ключевые слова: *сверхмедленные волны биопотенциалов, мультиклеточная импульсация, коммуникативная система, контекстное поле, кодирование информации.*

V.V. LAVROV¹, A.V. RUDINSKY²

¹Pavlov Institute of Physiology, Russian Academy of Sciences, St.Petersburg

²Center of System Consulting And Education "Synergia", St.Petersburg
vasilylavrov@yandex.ru

INTERNEURONAL COMMUNICATION SYSTEM: A CONTEXTUAL FIELD IN INFORMATION CODING

The discovered conformity between superslow waves of biopotentials (caused by regulatory processes) and frequency-temporal parameters of multicellular impulses of cortical neurons contradicts to the opinion that there exist specific forms of information coding by impulse streams. A hypothesis is put forward that the exchange of information in a nervous network is implemented

by a communication system that is formed due to the conformity context of the source and receiver signals, that is under the control of the contextual field.

Keywords: *superslow waves of biopotentials, multicellular impulses, communication system, contextual field, information coding.*

Введение

На раннем этапе изучения коммуникации нервных клеток проблема передачи информации ограничивалась выяснением особенностей импульсации нейронов в зависимости от параметров предъявленных стимулов. В дальнейшем проблема усложнилась в связи с исследованием закономерностей вовлечения нейронов в выполнение поведенческих актов. Усложнение усугубилось пониманием тройственного характера передаваемой информации, имеющей вид команды на выполнение стандартных действий, регулятора состояния или сигнала, мобилизующего на принятие самостоятельного решения [1]. Обращение к нейронаукам, остающимся на механистичной теоретической платформе, не проясняет проблему. В частности, нейробиология, направляя усилия на изучение функциональных отношений мозговых структур, фактически игнорирует вопросы, обусловленные дискретностью информации и системным управлением информационными процессами в мозге. Она концентрирует внимание на структурах, активируемых при выполнении функции, исходя из предположения, что эти структуры ответственны за функцию, не учитывая, что в реальности мозг действует как единое целое, а ответственность имеет пластичную форму. Зачастую концентрация внимания на роли той или иной структуры затрудняет изучение целостной системной коммуникации. Например, после обнаружения нейронов, активируемых при конструктивном диалоге и проявлениях эмпатии, было высказано предположение о существовании «зеркальных нейронов», обеспечивающих взаимопонимание при общении [2]. Такое предположение, предусматривающее наличие промежуточного «зеркального» элемента, опосредующего получение информации, по сути, открывает побочное направление исследований, которое затрудняет рассмотрение природы диалога.

Понимание организации межнейронной коммуникации зависит от выяснения принципов восприятия сигнальной (специфической / семантической и неспецифической/регуляторной) значимости информации при учете следующих обстоятельств: во-первых, изменения состояния органоидов и мембраны нервных клеток под воздействием получаемого и посылаемого сигнала, во-вторых, многообразия частотно-временных характе-

ристик импульсных потоков и, в-третьих, пространственно-временных отношений нейронов в рамках модулей и макроструктур. Здесь было бы уместно рассмотреть возникшие в связи с достижениями криптографии предположения по поводу возможных типов импульсного кодирования сигналов, однако это невозможно сделать из-за ограниченных размеров статьи. Авторов предположений объединило одно – они концентрировали внимание на стандартных ситуациях и не предусматривали изменения кодирования при возникновении новых не прогнозируемых ситуаций. При рассмотрении коммуникативной системы авторы, чаще всего, ограничиваются оценкой надежности каналов связи и поиском стандартных способов сигнального (знакового, символического и т.д.) кодирования в рамках предполагаемых множественных «языков мозга» [3]. При этом вне поля зрения остается соответствие контекстов взаимодействующих нейронов. В отсутствие такого соответствия, даже при полной надежности канала связи, в контекстном поле существует барьер, который препятствует правильному восприятию полученных информационных посылок.

Проблема преодоления контекстного барьера и включения коммуникации нейронов является одной из основополагающих в изучении мозга. Говоря о «временной связи» И.П. Павлов [4] имел в виду «проторение» нервного канала и возникновение контакта между нейронами. В настоящее время, когда известно, что в мозге имеется избыточность контактов, его идея может быть интерпретирована как «проторение» согласованности между источником и приемником импульсных посылок. Вполне вероятно, что П.К. Анохин [5], разрабатывая теорию функциональных систем и обращая внимание на системоорганизующую консолидирующую роль мотивации на достижение полезного результата, также имел в виду соответствие контекстов нейронов и формирование коммуникативной системы, без которой невозможно согласованное взаимодействие при выполнении поведенческих актов.

Постановка задачи

Первый этап данной работы посвящен проверке достоверности мнения о существовании в мозге универсальных способов кодирования специфической информации посредством частотно-временных параметров импульсных потоков. Обратились к электрофизиологическим данным, сопоставляя нейронную активность и макропотенциалы мозга, природа которых известна. Имелись в виду сверхмедленные волны биопотенциалов (СМВ), обусловленные функциональным состоянием мозга. Формулируя задачу исследования, руководствовались следующим рассуждением. Если

характер импульсации нейронов до, после и во время обучения будет стабильно оставаться в зависимости от СМВ и зависимость в ходе обучения принципиально не изменится, то будет логично полагать, что импульсные потоки отражают *неспецифические* процессы. Поэтому мнение об импульсном кодировании *специфической* информации следует пересмотреть. Возникает вопрос, как объяснить передачу специфической информации, если будет установлено, что частотно-временные параметры импульсных потоков, прежде всего, обусловлены регуляторными неспецифическими процессами. Второй этап работы – формулирование гипотезы о том, что межнейронное «взаимопонимание» обеспечивается соответствием контекстов. Гипотеза является альтернативой мнению о существовании универсальных «языков» [3], обеспечивающих межнейронный обмен информацией. Согласно гипотезе, выделение специфической информации из поступающих импульсных потоков обеспечивается селекцией на основе матриц, задаваемых обучением. Такие матрицы, по сути, представляют собой контекст [6], при сопоставлении с которым выявляется специфический сигнал.

Первая задача данной работы состояла в оценке мнения о существовании специфических форм импульсного кодирования информации. Эта задача решалась при исследовании соотношения параметров мультисклеточной импульсации (МКИ) кортикальных нейронов и СМВ в процессе обучения животных дифференцированию положительного светового сигнала от отрицательных. Вторая задача заключалась в формулировании гипотезы, объясняющей принципы коммуникации нейронов в отсутствие специфических форм кодирования информации.

Методика

Эксперименты проведены на 28 животных (кошки, самцы весом 3.5-4.0 кг), находящихся в экранированной звукоизолированной камере в состоянии бодрствования в условиях свободного поведения. Провели 900 исследований МКИ 120 пунктов сенсомоторной коры больших полушарий до, во время и после обучения дифференцировать отрицательные световые сигналы от положительного, подкрепляемого пищей. Подачу раздражения производили засветкой матового диска, угловые размеры которого относительно глаз животного составляли 120 градусов. Интенсивность зрительного раздражения измеряли в лк с помощью люксметра на уровне глаз животного. Положительный световой сигнал 30 лк длительностью 3 с подкреплялся кусочком мяса (вес порядка 3 г). Животное обучалось самостоятельно открывать крышку и доставать мясо из кормушки.

Эксперименты с регистрацией мозговых реакций чередовались с тренировочными опытами без регистрации. Заключение о достижении обучения принималось после того, как количество ошибочных ответов на положительный сигнал (пропуск пищедобывательной реакции) и отрицательные (попытка открыть кормушку и достать кусочек мяса) уменьшалось до 15% от общего числа предъявлений сигналов. Положительный сигнал в случайном порядке сочетался с грубым дифференцировочным 250 лк и средне дифференцировочным 120 лк.

Регистрация МКИ, ЭЭГ и СМВ производилась одновременно. При этом следили за поведением и контролировали функциональное состояние, отмечая ритмику сердечных сокращений и дыхания. *Принципиальная особенность* экспериментов состояла в контроле фонового состояния, предшествовавшего предъявлению сигналов. В качестве контроля служила ЭЭГ, отводимая от пункта в передней сигмовидной извилине левого полушария. Все стимулы испытывались в условиях фона покоя, когда в ЭЭГ доминировали медленные альфа- и тета-ритмы (частота менее 12 Гц). Соблюдение такого условия обеспечивало сравнимость реакций на сигналы. В качестве СМВ отмечали колебания биопотенциалов с периодом от 2 до 12 с.

Используемые методы дискриминации МКИ позволяли выделять 3 популяции нейронов (отношение амплитуд 1:2:4), находящихся под одним электродом. Если уровень шума (менее 5 мкВ) взять за 100%, то для первой популяции уровень амплитуды импульсов равнялся 200-250%, для второй 250-400% и для третьей от 400 до 800%. Сравнивая активность 3 групп между собой, а также выясняя уровень зависимости каждой группы от активационных влияний и сверхмедленных потенциалов, можно было сделать заключение о принципах организации нейрональной активности при разном функциональном состоянии мозга и на разных этапах поведенческих актов.

Интервал между началом опытов и операцией, в ходе которой вживляли электроды в мозг, составлял не менее двух недель, чтобы исключить влияние наркоза. Все операции проводились с соблюдением биоэтических норм в стерильных условиях под наркозом (нембутал 25 мг на кг веса, внутривенно). Ранее [7, 8] детально изложен процесс изготовления макроэлектродов (нихромовая проволока диаметром 0,1 мм в стеклянной изоляции, платинированная активная часть, закрепление на пластмассовой платформе), а также микроэлектродов, в качестве которых служили отрезки нихромовой проволоки диаметром 35-50 мк в лаковой изоляции. Чтобы надежно закрепить поверхностные корковые полумикроэлектроды, их размещали на общей миниатюрной пластмассовой платформе в коли-

честве от 3 до 6. Совместно с ними монтировали макроэлектрод, создавая таким образом единый блок, который жестко фиксировали в костях черепа. Животным вживляли 19 электродов, провода от которых были припаяны к полуразъему, закрепленному в кости над лобной пазухой. Два индифферентных электрода размещались в кости лобной пазухи. Перед началом эксперимента закрепленный в кости черепа полуразъем, к которому были подсоединены вживленные электроды, подключали к коммутатору. В камере находилось 2 коммутатора: коммутатор макроэлектродов и коммутатор микроэлектродов, который позволял выбрать нужный микроэлектрод и подать с него импульсацию на усиление и компьютерную обработку – подсчет импульсов селектированных по уровню амплитуды.

СМВ и результаты компьютеризированной обработки МКИ сопоставлялись при одновременной регистрации с помощью 13-канального энцефалографа. Проверку достоверности различия результатов наблюдений производили по критерию Стьюдента (уровень значимости 0.05). Определяя достоверность события, использовали критерий знаков.

Результаты исследования и обсуждение

В ходе эксперимента отметили, что включение световых сигналов вызвало изменение фоновых колебаний частоты МКИ при одновременной активации мозга, отражавшейся в ЭЭГ преобладанием быстрой бетаритмики. Для выявления особенностей ответных реакций сравнили параметры МКИ, отводимой от трех групп нейронов, расположенных под одним электродом. Выраженность реакций оценивали, сопоставляя характер волнообразных колебаний частоты МКИ, отмеченной в фоне и после стимула. Производили сравнительный анализ амплитуды и периода колебаний. Выраженность ответных изменений амплитуды волнообразных колебаний частоты МКИ, отводимой от группы нейронов с наименьшей величиной импульсов, не была равна реакциям нейронов, которые относились к другим группам с большей величиной импульсов и, по всей видимости, более приближенных к электроду. При этом характер реакций (активация или торможение), а также длительность колебаний были одинаковыми у всех трех групп. Во всех случаях световой сигнал вызывал увеличение периода первого колебания частоты МКИ на 2-4 с. Возвращение длительности последующих колебаний к уровню фона было неровным – например, третье колебание, хотя и было меньше первого, но могло превосходить второе.

Перед началом обучения тестировали световые стимулы без подкрепления. Световые стимулы (30, 120 и 250 лк) отличались по физической интенсивности, и выраженность изменения длительности первого колебания, по сравнению с фоновыми, находилась в прямой зависимости от физической интенсивности. После завершения обучения зависимость проявилась по-иному. Выращенность изменений длительности была наибольшей при действии положительного сигнала (хотя его физическая интенсивность была самой слабой), меньше при среднем дифференцировочном и еще меньше при грубом. То есть, после обучения выраженность зависела от биологической значимости сигналов, что соответствовало ранее установленной закономерной зависимости активации мозга [9].

В 60% случаев включение светового сигнала до, в ходе обучения и после его завершения вызывало увеличение амплитуды колебания частоты МКИ в 2-5 раз по отношению к фону. В 30% случаев амплитуда колебания частоты МКИ возрастала менее, чем в 2 раза или оставалась на неизменном уровне. В 10% наблюдений действие сигнала подавляло частоту МКИ, и ответная реакция выражалась в снижении амплитуды первого колебания частоты МКИ, после чего происходило постепенное восстановление фоновых параметров колебаний в течение 20-30 с.

При регистрации СМВ отметили, что световые стимулы вызывали значительное увеличение амплитуды и периода первого колебания потенциала в 60% наблюдений, в 30% случаев увеличение было слабым, а в 10% – амплитуда снижалась. Последующие колебания СМВ постепенно в течение 20-30 с восстанавливались до исходного уровня. До обучения выраженность ответных изменений СМВ зависела от физической интенсивности стимулов, а после – от биологической значимости.

Сопоставление колебательных процессов СМВ и МКИ показало, что они коррелируют по времени. В случае, если ответная реакция МКИ характеризовалась повышением частоты импульсации, выраженность амплитуды колебаний частоты МКИ также соответствовала амплитуде вызванных изменений СМВ.

Таким образом, в результате проведенных экспериментов было показано, что импульсные потоки, распространяемые между нейронами, находятся в соответствии с СМВ, обусловленными неспецифическими регуляторными процессами [10, 11]. До обучения и обретения стимулами сигнальной значимости частотно-временные параметры нейрональной импульсации отражают физическую интенсивность, а после – сигнальную (биологическую) значимость. В процессе обучения после начального генерализованного восприятия сигналов происходит их дифференциация, о

чем свидетельствует зависимость выраженности нейрональных реакций от биологической значимости.

Принципиальный момент проведенных наблюдений – отмечено, что частотно-временные характеристики нейронной импульсации вместе с выраженностью ЭЭГ реакций, а также СМВ приобретали новую зависимость, но их параметры оставались в рамках тех значений, которые существовали до обучения. Еще раз подчеркивается, что характер нейронной импульсации постоянно определялся неспецифическими образованиями мозга. Нейроны, находящиеся в общем функциональном поле под одним электродом, не отличались по характеру реагирования. Полученные данные, продемонстрировавшие однородность и цикличность импульсных потоков, противоречат мнению о жестко установленных формах кодирования сигнала, поэтому гипотеза о кодирования специфической информации посредством импульсных паттернов требует пересмотра.

Предлагается альтернативное объяснение принципов передачи специфической информации. Главное внимание обращается на коммуникативную систему, которая складывается при соответствии контекстов источника и приемника. Под термином «контекст» понимается совокупность обстоятельств, определяющих восприятие целостной информационной посылки и ее фрагментов [6]. Контекст отдельного нейрона имеет вид матрицы, определяющей восприятие поступающих импульсных потоков и ответную реакцию. Соответствие контекстов и возникновение контекстного поля можно трактовать как возникновение коммуникативной системы с использованием разных способов передачи сигнала. В табл. 1 приводится перечень возможных способов кодирования информации при коммуникации нейронов.

По всей видимости, при коммуникации в той или иной мере степени могут применяться все способы, и задача исследования заключается в выяснении их сочетания при изменении ситуации. Гипотеза о существовании контекстного поля и матрицах, определяющих целостное восприятие информационной посылки, складывающейся из множества фрагментов, расширяет перспективу понимания принципов восприятия информации и принятия решений. Можно объяснить, каким образом нейрону, обладающему ограниченным функциональным ресурсом, удастся справиться с задачей интеграции множества воздействий – нейрон использует матрицы для выделения информации. Матрицы формируются в процессе обучения под управлением регуляторного аппарата мозга. При этом специфические и неспецифические элементы составляют целостную информационную посылку не только при коммуникации нейронов, но и при любом другом диалоге.

Способы межнейронной передачи информации

Носитель информации	Возможные способы кодирования
Частотно-временные параметры импульсации	Амплитуда и длительность колебания частоты импульсного потока
	Включение и выключение импульсации
	Частота и количество импульсов в «пачке»
	Комплекс «пачек» в сигнальной посылке
Химизм синаптической передачи	Специфичность медиатора и количество медиатора
	Сочетание биологически активных веществ в комплексе с медиатором
Пространственное положение синапса на теле и отростках нейрона	Дендритное расположение синапса
	Расположение на аксоне
	Локализация на соме нейрона
Прямое электрическое воздействие	Параметры электрического импульса
Химизм внешней нейронной среды	Биологически активные вещества в межклеточном пространстве
Пространственно-временные особенности импульсных потоков	Сочетание во времени импульсных потоков, поступающих по входным каналам
Контекстное поле коммуникативной системы	Информация считывается с матрицы, активированной комплексом полученных импульсов

Попытка разделять эти элементы [12] с предположением о существовании двух коммуникативных систем (специфической/лингвистической и неспецифической/экспрессивной) препятствует пониманию целостности информации в диалоге.

Представление о контекстном поле коммуникативной системы создает предпосылку для ответа на вопрос, который интересует исследователей [13, 14]. Имеется в виду неопределенность принципов взаимодействия нейронов в рамках целостной мозговой деятельности и модуля, когда нейрон получает информацию по множеству каналов. Каким образом одновременное сочетание стимулов поступивших по множеству каналов образует целостный интегративный сигнал? Мало вероятно, что нейрон способен одновременно вести отдельное считывание информации, содержащейся в импульсных потоках, поступающих по каждому каналу, а за-

тем интегрировать результаты. Вероятнее всего, нейрон использует шаблоны/матрицы, которые заготовлены в процессе формирования коммуникативной системы, выделяя командные послылки, регуляторные и те, которые формулируют задачу для принятия решения [13].

Гипотеза о контекстном поле коммуникативной системы концентрирует внимание на принципиальной особенности любого эффективного диалога. Имеется в виду соответствие контекстов источника и приемника информации. Соответствие посылаемого сигнала тому, который воспринимается нейроном при получении, равно как и взаимопонимание сторон в процессе переговоров, достигается благодаря тому, что стороны находятся в общем контекстном поле. Гипотеза позволяет по-новому подойти к решению задачи по созданию устройства, имитирующего мозговую деятельность с учетом множественности каналов коммуникации и соответствия контекстов\матриц взаимодействующих элементов.

Заключение

Изучение характера импульсных потоков, распространяющихся между нейронами во время обучения, ведет к пониманию принципов формирования и восприятия информационных посылок в нервной сети. Проведенное исследование показало соответствие СМВ и частотно-временных параметров МКИ нейронов, находящихся в кортикальных модулях. Имеется в виду, что до начала обучения, при его проведении и после завершения колебания частоты МКИ соответствовали СМВ. Выраженность колебаний зависела от физической интенсивности стимулов до обучения и обрела зависимость от биологической значимости сигналов после обучения. Поскольку СМВ обусловлены регуляторными процессами, сделан вывод, что частотные, пространственные и временные параметры импульсных потоков отражают неспецифические регуляторные влияния. Ответ на вопрос о принципах передачи сочтанной специфической и неспецифической информации по общему каналу приходится искать вне упрощенной схемы кодирования/декодирования. Предлагается гипотеза о том, что обмен информацией в нервной сети обеспечивается коммуникативной системой, создаваемой благодаря соответствию контекстов источника и приемника сигналов – то есть, при возникновении контекстного поля. Гипотеза объясняет сочетание специфической и неспецифической информации в импульсных послылках, которые формируются и воспринимаются в соответствии с сигнальными матрицами, хранящимися в памяти нейрона.

Список литературы

1. Rizzolatti G., Craighero L. The Mirror-neuron system // Annual Rev. Neurosci., 2004. V. 27. P. 169-192.
2. Лавров В.В., Рудинский А.В. Стратегии управления обработкой фрагментированной сенсорной информации // Нейроинформатика-2014. Ч. 2. М.: НИЯУ МИФИ, 2014. С. 214-225.
3. Прибрам К. Языки мозга. М.: Прогресс. 1975.
4. Павлов И.П. (1923) Двадцатилетний опыт объективного изучения высшей нервной деятельности (поведения) животных. М.-Л.: АН СССР. 1949. Т.3.
5. Анохин П.К. Очерки по физиологии функциональных систем. М.: Медицина, 1985. 444 с.
6. Торсуева И.Г. Контекст // Лингвистический энциклопедический словарь. М.: СЭ. 1990. С. 238-239.
7. Лавров В.В. Динамика сверхмедленных колебаний мультинейронной активности и биоэлектрических потенциалов мозга кошки при неподкрепляемом световом раздражении // Физиол. журн. СССР, 1989. Т.75. № 7. С. 890-897.
8. Лавров В.В. Мозг и психика. СПб.: РГПУ, 1996.
9. Кратин Ю.Г., Зубкова Н.А., Лавров В.В., Сотниченко Т.С., Федорова К.П. Зрительные пути и система активации мозга. Л.: Наука, 1982.
10. Хомская Е.Д. Мозг и активация. М.: Изд-во МГУ, 1972.
11. Аладжалова Н.А. Психофизиологические аспекты сверхмедленной ритмической активности головного мозга. М.: Наука, 1979.
12. <http://journal.frontiersin.org/Journal/10.3389/fpsyg.2014.00564/full>
13. Wolpert D.H. Stacked generalization // Neural Networks, 1992. V. 5. P. 241-259.
14. Николлс Дж.Г., Мартин А.Р., Валлас Б.Дж., Фукс П.А. От нейрона к мозгу. М.: Едиториал УРСС. 2003.

И. А. СМИРНИТСКАЯ

Научно-исследовательский институт системных исследований РАН, Москва
i.a.i.a@mail.ru

**ОБ ОДНОМ РАСПРОСТРАНЕННОМ НЕЙРОСЕТЕВОМ
МОТИВЕ**

Описан часто встречающийся мотив строения симметричной нейронной сети. Две самые распространенные функции такой сети – управление ритмичными движениями и организация поворотов во время ритмичного движения. Приводятся примеры функционирования сетей у позвоночных и беспозвоночных животных. Обсуждаются варианты преобразования

входной сенсорной информации для управления направлением движения. Оценивается характер участия сетей такого рода в осуществлении поведенческого выбора.

Ключевые слова: *движение, билатеральная симметрия, управление поведенческим выбором.*

I.A.SMIRNITSKAYA

Scientific Research Institute for System Analysis RAS, Moscow
i.a.i.a@mail.ru

ABOUT ONE WIDELY USED NEURAL CIRCUIT MOTIF

A widely used symmetric neural circuit structure is described. Most appropriate functions of such a circuit are the locomotion control and the control of turns. Examples of this circuit functioning in vertebrates and invertebrates are described. Different types of sensory input transformation for the control of motion direction are discussed. Assumptions about the application of such a circuit for behavioral choice are made.

Keywords: *motion, bilateral symmetry, behavioral choice.*

Введение

Билатеральная симметрия, возникшая для управления движениями, подчинила себе все строение нервной системы позвоночных животных. Однако, явно наблюдаемая в крупном масштабе, проявляющая себя наличием двух полушарий с дублированными отделами, на нейросетевом уровне она обнаруживается лишь в некоторых случаях. А именно, симметричной является сеть, управляющая локомоцией билатерально симметричных животных (рис. 1). В случае прямолинейного движения (рис. 1, а) управляющая сеть должна поочередно возбуждать левый и правый мотонейроны, и, соответственно тормозить мотонейрон противоположной стороны. Если необходим поворот (рис. 1, б), сравниваются сенсорные сигналы с противоположных сторон. Происходит торможение нижележащей нейронной активности от слабого сигнала активностью от более сильного сенсорного сигнала.

Рассмотрим примеры того, как на самом деле происходит управление движением, и поворотом в сторону более привлекательного сигнала.

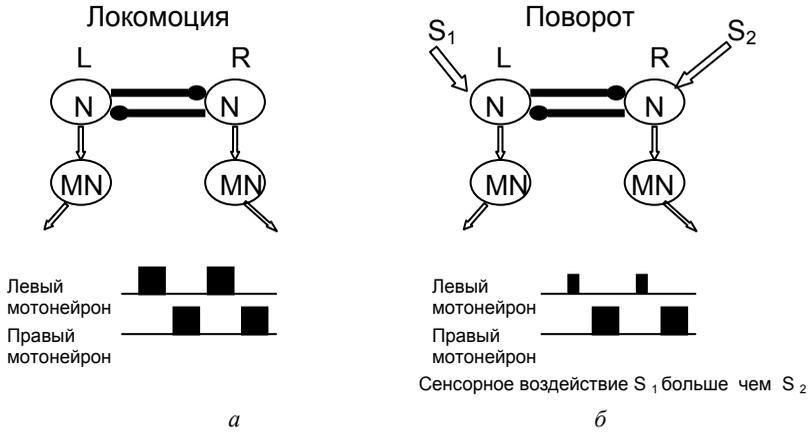


Рис. 1. Обобщенная схема управления прямолинейным движением и поворотом: N – командный нейрон, MN – мотонейрон, S – сенсорный вход. S_1 и S_2 не равные воздействия. Стрелками обозначены возбуждающие воздействия, черными кружками – тормозные

Управление ритмическими движениями

На рис. 2 приведена локомоторная схема одного сегмента миноги. Видно, что это устройство гораздо более сложное, чем на рис. 1.

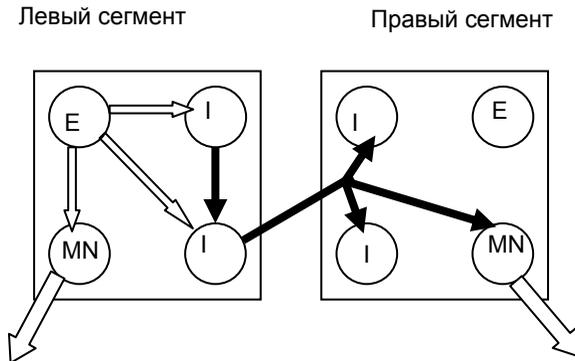


Рис. 2. Модель управления движением у миноги (по [1,4]). Открытые стрелки – возбуждающие воздействия, сплошные – тормозные воздействия. Связи, идущие внутри и от правого сегмента, не показаны

В действительности тормозных интернейронов по крайней мере в 2 раза больше, чем приведено на рис. 2 [4], в частности из-за того, что нужно не только возбуждать в нужной фазе нейроны двух симметричных половинок одного сегмента, но и согласовывать движения разных сегментов.

Управление поворотом

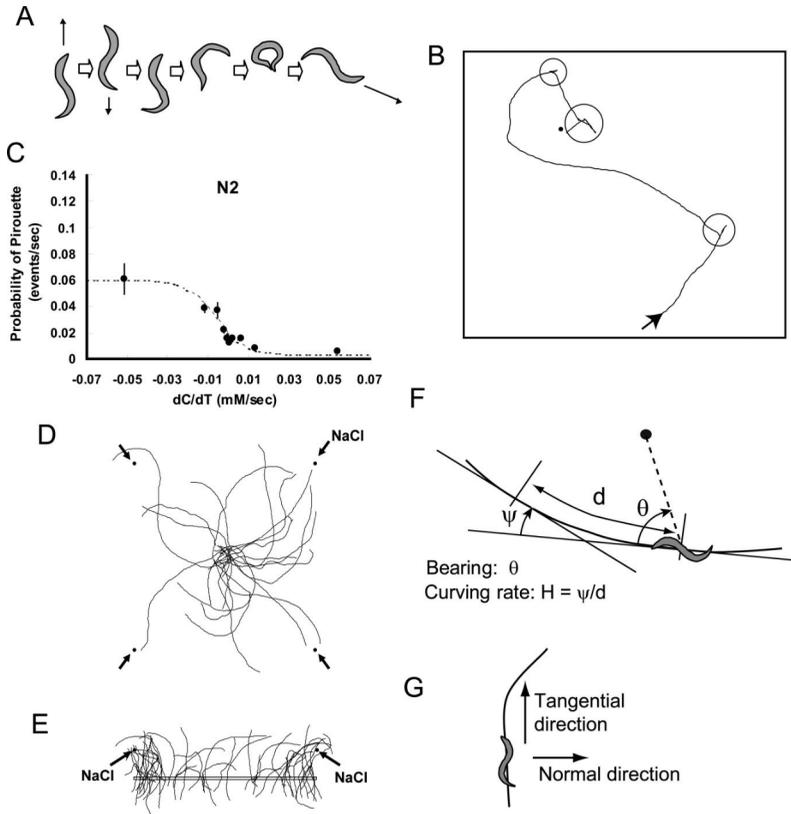
Казалась бы, что управлять поворотом можно с помощью той же схемы управления ритмическим движением, просто подавая несимметричный сенсорный вход (см. рис. 1). Оказывается, это совсем не так.

Удобной моделью для изучения навигации животных в среде с градиентами концентраций химических аттрактантов является почвенная нематода *Caenorhabditis elegans*, или коротко, *C. Elegans*. Ее хеморецепторы в частности, чувствительны к различной концентрации соли (NCI). Помещая нематоду в плоскую чашку с желеподобным раствором, в который внедрены пятна соли, можно изучать, как характеристики среды определяют выбор направления движения (рис. 3). Длина животного около 1 мм, она движется на боку, извиваясь, то сгибая, то разгибая мышцы спины и живота, и по ходу движения определяет градиент концентрации соли, двигаясь в сторону увеличения. Она последовательно сравнивает два измерения концентрации: в положении, когда ее шея разогнута и когда согнута. Амплитуда движения шеи примерно 0.2 мм.

В целом, будучи слегка хаотичным, движение животного направлено в сторону увеличения концентрации привлекательного для него вещества. Достигается это путем коррекции направления движения, если оно идет не в сторону увеличения градиента концентрации. Используются две дополняющие друг друга стратегии.

Первая стратегия заключается частой смене направления движения (т.н. пируэты). Другая стратегия – последовательное искривление траектории движения в сторону увеличения концентрации. При этом животное учитывает только градиент концентрации, перпендикулярный направлению своего движения (рис 3.F и рис. 3G). Вычисление градиента концентрации основано на том, что хемочувствительные клетки *C. Elegans* реагируют на увеличение или уменьшение концентрации.

Другой, относящийся уже к позвоночным, пример изменения направления движения в зависимости от концентрации аттрактанта – движение акулы. Считается, что акулы обладают исключительным обонянием, способны примчаться по кровяному следу к добыче, находящейся на расстоянии в несколько километров от нее.

Рис. 3. Движение *C. Elegans* [2]:

A – зарисовка исполнения пируэта. Исходное направление движения – вверх, затем животное останавливается, потом начинает двигаться назад, затем сгибается, поворачивает, и в итоге меняет направление движения, в данном случае более, чем на 90° ; B – траектория движения, кружком обведены пируэты; C – вероятность выполнения пируэта как функция градиента концентрации; D – второй механизм коррекции направления движения (флюгерного типа) – искривление траектории. Здесь точками в углах отмечены места повышенной концентрации соли. В данных траекториях пируэты не отмечены; E – нанесены траектории, искривляющиеся к местам максимальной концентрации (слева и справа); F – параметры, характеризующие траекторию движения: азимут, скорость искривления; G – направление движения животного обозначено как тангенциальное, направление искривления траектории (нормальное)

Ранее полагали, что акула выбирает направление, сравнивая интенсивности запаха, поступающего справа и слева. В работе [3] сравнивали число поворотов акулы в сторону а) увеличения концентрации запаха, б) в сторону с которой запах поступил раньше. Оказалось, что если в одну ноздрю животного подавали запаховую порцию в интервале 0.1 - 0.5 с. раньше, чем в другую, то животное поворачивало в эту сторону примерно в 5 раз чаще. Причем, даже если в сторону с более ранней подачей поступало 100-кратно разведенное пахучее вещество, все равно акула поворачивала именно в эту сторону.

Задача поиска хемоаттрактанта как задача выбора сиюминутной поведенческой цели

Известно, что хеморецепция связана с выделением наиболее значимых объектов. Вкусовая рецепция осуществляет оценку съедобности объектов внешнего мира. Обонятельная рецепция является древней дистантной рецепцией, у позвоночных животных связанные с обонянием корковые области являются самыми старшими из корковых областей, а возникшая на основе обонятельной рецепции миндалина выполняет функцию оценки жизненной важности событий внешнего мира. Известно, также, что в поведенческом выборе позвоночных животных большую роль играет медиальная префронтальная кора, область мозга, расположенная вокруг оси симметрии мозга. Пытаясь оценить ее функцию, полезно сравнить функционирование этой области префронтальной коры с работой других билатерально симметричных нейронных сетей, принадлежащих билатерально симметричным животным.

Для нематоды *C. Elegans* движение по градиенту концентрации является одним из наиболее важных доступных типов поведения. Ее выбор направления движения аналогичен по важности выбору поведенческой программы у позвоночных.

Как упоминалось выше, *C. Elegans* использует два способа коррекции направления движения: Один – увеличение частоты резких поворотов, а другой – плавное искривление линии курса в сторону увеличения концентрации аттрактанта. Ранее предполагалось, что управление движением путем сравнения концентраций в последовательные моменты времени осуществляется на сетевом уровне [5,6]. Но было экспериментально обнаружено, что вычисление производной $dC(t)/dt$ выполняется у *C. Elegans* на уровне «клеточного hardware», специальные клетки – хемосенсорные нейроны, отвечают на увеличение и уменьшение концентрации, т.н. «оп-клетки» и «off-клетки» [9] (рис. 4). Дальнейшее управление поворотом

происходит примерно так же, как на схеме поворота (рис.1), за исключением того, что взаимного торможения противоположных входов не требуется, on- и off- клетки имеют противоположные знаки влияния [7]. Кроме того, поскольку нематода движется на боку, симметрия схемы управления не право-левая, а дорсо-вентральная.

Для использования другого способа коррекции направления движения нематоды – увеличения числа пируэтов, сенсорный вход поступает с тех же on- и off- клеток. Сеть, управляющая этим типом поведения, хорошо исследована [8].

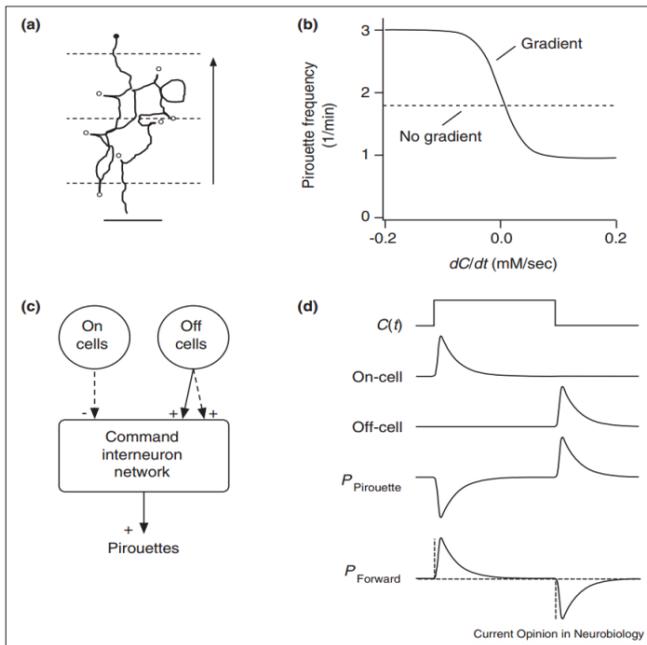


Рис. 4. Выполнение пируэтов [7]:

a – концентрация возрастает в направлении вверх; b – схематическое представление данных рис. 2; c – очень схематичное изображение сети, управляющей выполнением пируэта. «+» возбуждающие воздействия, «-» тормозные, сплошная стрелка – моносинаптический вход, пунктирная – полисинаптический; d – влияние изменения концентрации хемоаттрактанта $c(t)$ на срабатывание сенсорных on- и off- клеток. Если животное движется в сторону увеличения концентрации, оно редко меняет направление (вероятность пируэтов мала), если движется в сторону уменьшения, смены направления движения становятся более вероятными

Для обоих рассмотренных типов движения определяющую роль играет не пространственная симметрия или антисимметрия, а изменение внешней ситуации во времени. Интересно, что сенсорные рецепторы, отвечающие на увеличение концентрации $dC(t)/dt > 0$ (on-клетки), расположены слева, а рецепторы, отвечающие на уменьшение концентрации $dC(t)/dt < 0$, (off-клетки), расположены справа.

В случае акул, поворачивающих в сторону раньше пришедшего обонятельного стимула, фактически, происходит такое же вычисление изменения концентрации запаха со временем. В данном случае, по-видимому, важен учет фактора турбулентности среды обитания акулы, который лишает значимости абсолютные показатели концентрации. Какая нейронная сеть решает в данном случае задачу управления, экспериментально пока не выяснено, поскольку исследований на акуле гораздо меньше, чем на *C. Elegans*.

Заключение

В конечном счете хочется попытаться представить своего рода инверсный подход: если имеются данные, что у билатерально симметричного животного, имеющего симметрично устроенную нейронную сеть, эта сеть выполняет некую операцию, в данном случае билатеральное сравнение сенсорных сигналов, то может ли из этого следовать, что другие симметрично устроенные нервные сети других, эволюционно более молодых животных выполняют такую же операцию? Абсурдно искать в нервной системе закономерность такого рода, как общую закономерность, но какие-то аналогии строить можно.

Хотя из приведенных выше данных о навигации основанной на хеморецепции видно, что в разных случаях устройства нервных сетей различны, во всех случаях поведенческий выбор, то есть принятие решения о смене направления движения, происходит не на основании того что с этой стороны сенсорный вход более сильный, а на основании временного хода сенсорной информации. Конечно, в данном случае отсчеты значений концентрации в зависимости от времени появляются только потому, что животное уже движется, но мы здесь обсуждаем задачу рулежки, изменения направления движения, а про сам запуск движения известно, что он осуществляется другими механизмами.

Если строить прямые аналогии, то можно утверждать, что участвующая в поведенческом выборе у позвоночных медиальная префронтальная кора занимается сравнением временного хода каких-то специфических для каждой задачи переменных.

Список литературы

1. Buchanan J., Grillner S. 1987 Newly identified glutamate interneurons and their role in locomotion in the lamprey spinal cord// *Science*, 236, 312–314.
2. Iino Y., Yoshida K. Parallel Use of Two Behavioral Mechanisms for Chemotaxis in *Caenorhabditis elegans*// *The Journal of Neuroscience*, 2009. 29(17):5370–53802.
3. Gardiner J.M., Atema J. The Function of Bilateral Odor Arrival Time Differences in Olfactory Orientation of Sharks// *Current Biology*, 2010. 20. P. 1187– 1191.
4. Lockery S.R. The computational worm: spatial orientation and its neuronal basis in *C. elegans* // *Current Opinion in Neurobiology*, 2011. 21. P. 782–790.
5. Parker D. Complexities and uncertainties of neuronal network function// *Phil. Trans. R.Soc. B*. 2006. 361, 81–99.
5. Dunn N.A., Lockery S.R., Pierce-Shimomura J.T., Conery J.S: A neural network model of chemotaxis predicts functions of synaptic connections in the nematode *Caenorhabditis elegans* // *J Comput Neurosci*, 2004, 17:137-147.
6. Dunn N.A., Conery J.S., Lockery S.R. Circuit motifs for spatial orientation behaviors identified by neural network optimization// *J. Neurophysiol*, 2007. 98:888-897.
7. Thiele T.R., Faumont S., Lockery S.R. The neural network for chemotaxis to tastants in *Caenorhabditis elegans* is specialized for temporal differentiation// *J Neurosci*, 2009. 29:11904-11911.
8. Faumont S., Lindsay T.H., Lockery S.R. Neuronal microcircuits for decision making in *C. elegans* // *Curr Opin Neurobiol*, 2012. 22(4): 580–591.
9. Suzuki H., Thiele T.R., Faumont S., Ezcurra M., Lockery S.R., Schafer W.R. Functional asymmetry in *Caenorhabditis elegans* taste neurons and its computational role in chemotaxis// *Nature*, 2008. 454:114-117.

А. Н. ПОКРОВСКИЙ

Санкт-Петербургский государственный университет
anpokrovski@gmail.com

**ПРЕСИНАПТИЧЕСКИЕ КОМПОНЕНТЫ ВЫЗВАННОГО
ПОТЕНЦИАЛА КОРЫ МОЗГА**

Рассматривается задача выделения пресинаптических компонентов различного происхождения из записей вызванного потенциала коры мозга. Вызванные потенциалы обычно регистрируются на многих уровнях коры одновременно; зависимость сигналов от времени на разных уровнях глубины коры достаточно сложная. Цель работы – полное разделение «пресинаптических» участков вызванного потенциала (ВП) на компоненты.

Ключевые слова: *нейронные сети, вызванные потенциалы, пресинаптические компоненты.*

A.N. POKROVSKY

Sanct-Petersburg State University
anpokrovski@gmail.com

PRESINAPTIC COMPONENTS OF EVOKED POTENTIALS OF THE BRAIN CORTEX

The problem of separation of presynaptic components in the records of evoked potentials of the brain cortex is considered. Usually the evoked potentials are registered simultaneously at many cortical levels. The dependence of the signals on time at different levels of the cortex is rather complex. The work is aimed to realize the full separation of the evoked potential components.

Keywords: *neural networks, evoked potential, presynaptic components.*

Введение

Рассмотрим начальный участок классического набора вызванных потенциалов коры мозга [1], представляющий собой совокупность 16-ти синхронных кривых, каждая из которых описывает изменение во времени значения начального участка вызванного потенциала на соответствующей глубине коры (рис. 1, слева). Шкала амплитуд в милливольтгах, шкала времени – в миллисекундах. Шкала времени, как и в [1], [9], начинается не с момента начала стимула, а на три миллисекунды позже. Выделять пресинаптические компоненты этой записи будем в той же шкале.

Уменьшению измеренного суммарного внеклеточного потенциала соответствует увеличение внутриклеточного потенциала нейронов и их отсрочек, то есть, возбуждение нейронов. Тормозящие сигналы могут снижать внутриклеточный потенциал нейронов и повышать измеряемый средний внеклеточный потенциал.

В первом приближении желательно использовать максимальную редукцию этой громоздкой задачи разделения начального участка ВП на компоненты. Вообще говоря, измеренные ВП являются функциями трёх координат и времени. Для уменьшения размерности задачи будем использовать модель плоской (по x, y) коры и считать, что потенциалы не зависят от координат (x, y). Вблизи электрода это приблизительно так, а влиянием удалённых участков пренебрегаем.

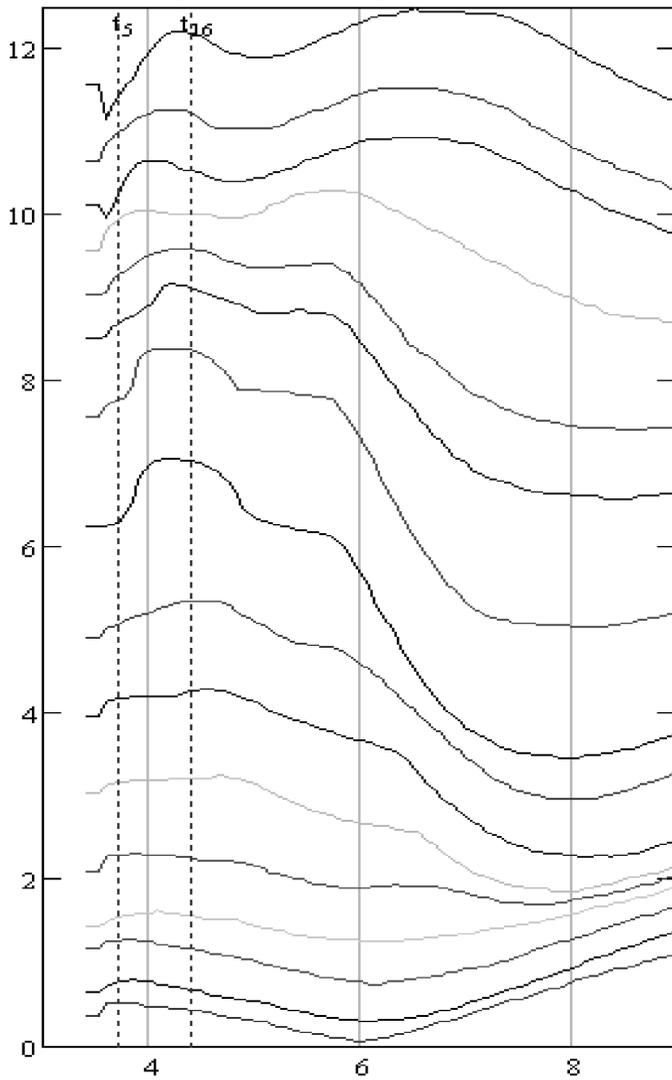


Рис. 1

У соседних по глубине кривых на некоторых участках есть сходство. Авторы [1] выделили в средних слоях коры самый большой компонент этого вызванного потенциала. С выделением других компонентов всё оказалось сложнее, и полное разделение этого ВП на компоненты разных типов синапсов затянулось почти на полвека ([1] – [9]).

В начале данной записи ВП возможны, по-видимому, не синаптические («пресинаптические») компоненты. Похоже, что таких компонентов несколько, и они (как и синаптические) регистрируются, как правило, на нескольких уровнях глубины коры, то есть на сигналах двух или более электродов. Целью данной работы является выделение (если существуют) пресинаптических компонентов из начального участка данной записи («классической») вызванных потенциалов. Следует отметить, что автор не встречал в научной литературе публикаций о разделении пресинаптических компонентов ВП.

Результаты вычислений

При вычислениях пресинаптических компонентов ВП нет необходимости оперировать с поздними компонентами ВП. Поэтому на рисунках графики кривых «растянуты» с 3-й до 9-й миллисекунды после стимула.

На рис. 1 представлен набор начальных участков вызванных потенциалов коры мозга, скопированный из ([1] – [9]) и «растянутый» по оси времени (шкала амплитуд в милливольтгах, шкала времени в миллисекундах от начала стимула). В одной миллисекунде содержится 16 точек каждой из кривых графика. Отметим, что все кривые (кроме 8-й сверху) начинаются с 3-й миллисекунды от начала записи; 8-я - позже.

На рис. 2 представлен тот же вызванный потенциал, что и на рис. 1, но с вычтенными двумя самыми первыми синаптическими компонентами, найденными в [9].

На рис. 3 из записи вызванных потенциалов вычтен самый ранний пресинаптический компонент в средних и нижних слоях коры. На верхних трёх уровнях записи ВП дело обстоит сложнее. Вероятно, там возникают одновременно три сигнала: пресинаптический компонент, синаптический возбуждающий и синаптический тормозящий, и регистрируется сумма этих сигналов.

На рис. 4 выделен самый ранний положительный пресинаптический компонент записи ВП, имеющийся на нижних уровнях коры, но вероятно отсутствующий на верхних уровнях. Самый ранний компонент ВП.

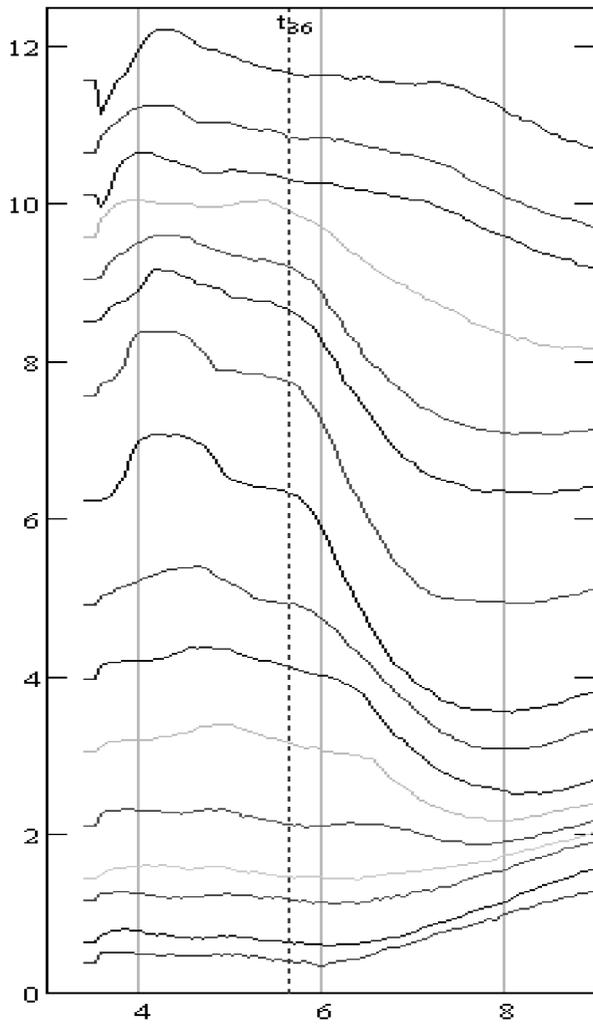


Рис. 2

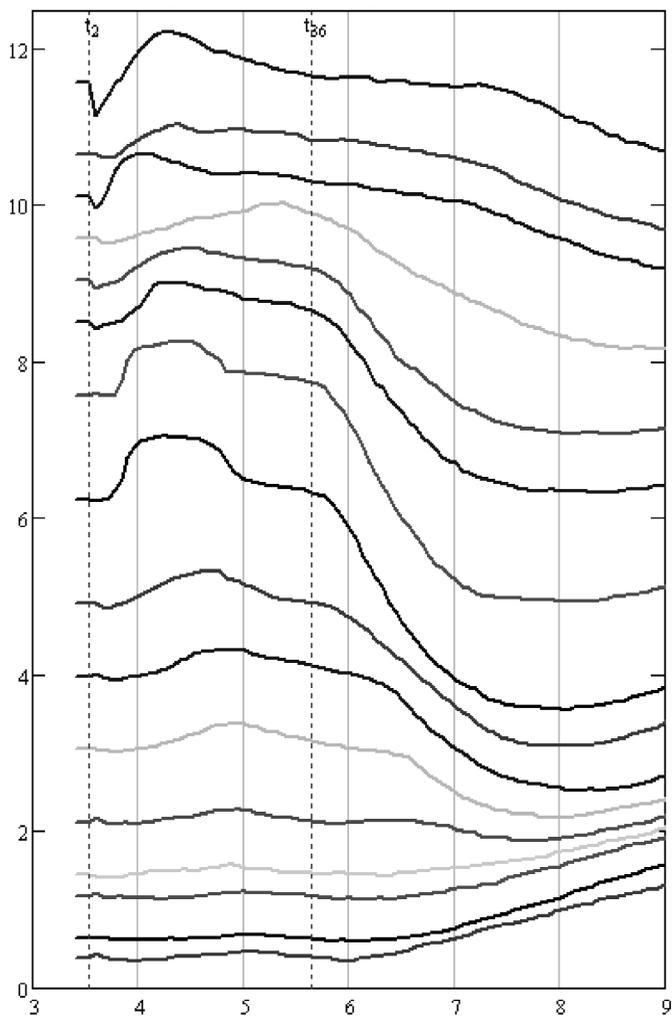


Рис. 3

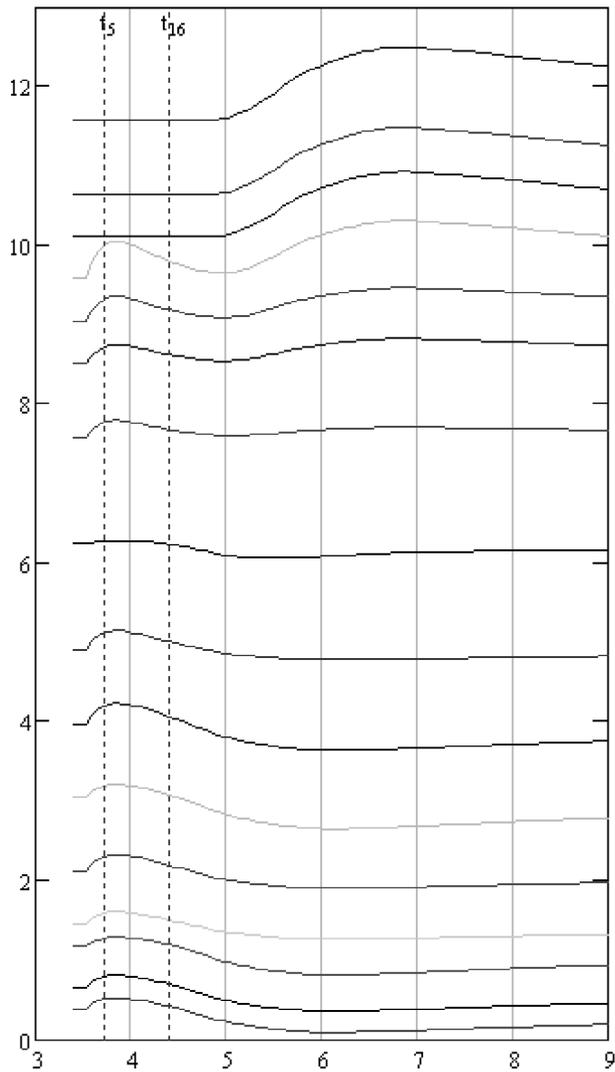


Рис. 4

Выводы

Показана возможность выделения из довольно сложного вызванного потенциала коры мозга пресинаптического компонента. Предложенный алгоритм показал свою эффективность. Удалось удовлетворительно подобрать как форму компонента, так и его амплитуду. Удалось выделить только один пресинаптический компонент.

Из этого результата следует как необходимость полной автоматизации такого рода вычислений компонентов вызванных потенциалов, так и возможность их достаточно широкого применения в различных задачах исследования нервных систем людей и животных.

При исследовании компонентов вызванных потенциалов в каком-либо месте коры мозга обязательно возникнет вопрос о выяснении полного набора компонентов в данном месте коры. Этот вопрос, очевидно, связан с морфологией распределения синапсов аксонов в коре, но ответ на него вероятно проще будет получить физиологическими методами, чем морфологическими.

Заключение

Прежде всего, необходимо будет решить проблему полной автоматизации вычислений для подбора компонентов каждого вызванного потенциала. В результате должна бы появиться программа, автоматически (без участия экспериментатора) вычисляющая набор компонентов каждой записи вызванных потенциалов в каждом эксперименте. При современном быстродействии ЭВМ это вполне возможно.

Следующим шагом в рассматриваемом направлении должно быть применение стандартной программы автоматического анализа записей (разделение на компоненты) вызванных потенциалов (пока что отсутствующей) как в новых экспериментах, так и (прежде всего) для анализа уже существующих записей. Для каждого компонента должна быть вычислена последовательность амплитуд (для каждого стимула), и эти последовательности должны будут сравниваться. Вероятно, среди компонентов обнаружатся и более стабильные, и более вариабельные компоненты.

Далее, при численном исследовании компонентов вызванных потенциалов могут возникнуть дополнительные вопросы. Например, где находятся нейроны, спайки которых вызывают данный компонент данного вызванного потенциала. Каждому компоненту ВП соответствует популяция нейронов, импульсы которых вызывают этот компонент. Эта популяция

ция может оказаться в том же месте коры, где отводится вызванный потенциал, но может и оказаться в любом другом месте в нервной системе изучаемого животного. Таким образом, каждому набору компонентов вызванного потенциала соответствует набор популяций нейронов (и мест расположения этих популяций в организме), таких, что активность каждой из них вызывает появление своего компонента ВП.

При разных стимулах в одном и том же месте коры будут возникать, вообще говоря, разные вызванные потенциалы. Набор компонентов у них может совпадать, частично или полностью, или полностью различаться. Поэтому возникнет необходимость создания полной «коллекции» компонентов в каждом изучаемом месте коры. А также выяснение полной «коллекции» источников этих компонентов.

Список литературы

1. Andersen P., Eccles J. C., Loyning Y. // Nature (Lond.), 1963. V. 198. P. 541-542.
2. Pokrovsky A. N. Non-homogeneous renewal point process as a model of a neuronal spike train // Mathematical Biosciences, 1972. V. 14. P. 49-58.
3. Покровский А.Н. Математическая модель генерации импульсов нейроном тонического типа // Биофизика, 1973. Т. 18. № 4. С. 700-705.
4. Покровский А.Н., Прохоренко Ю.П., Торнуев Ю.В. О происхождении раннего положительного компонента первичного ответа // Нейрофизиология, 1974. Т. 6, № 4. С. 455-458.
5. Покровский А.Н. Латентные периоды компонентов вызванных потенциалов // Доклады Академии Наук РФ, 2002. Т. 384, № 5. С.708-711.
6. Покровский А.Н. Обратные задачи на конечном графе // Материалы ВВМШ "Понтрягинские чтения -XIV", Воронеж, 2003. С.116-117.
7. Покровский А.Н. Функциональные состояния синаптически управляемой возбудимой мембраны // Доклады Академии Наук РФ, 2004. Т. 395, № 3. С. 421-423.
8. Покровский А.Н. Возможность восстановления синаптических токов по вызванным потенциалам коры мозга. // Нейроинформатика-2011, сборник научных трудов, часть 1. М.: НИЯУ МИФИ, 2010. С. 201-208.
9. Покровский А.Н. Компоненты вызванного потенциала коры мозга // Нейроинформатика-2014, сборник научных трудов, часть 2. М.: НИЯУ МИФИ, 2013. С. 158-166.

Стендовая сессия 5

Теория нейронных сетей

В. И. ГОЛОЩАПОВ

Научно-культурный центр SETI, Москва
kraidiky@gmail.com

АНСАМБЛИ СИНАПСОВ КАК КАНДИДАТЫ НА РОЛЬ СТРУКТУР, КОДИРУЮЩИХ ПРИЗНАКИ В ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЯХ

Рассматривается проблема поиска в ИНС структурных элементов, распутывающих признаки входного сигнала и непосредственно кодирующих реакцию на них на выходе сети. Показано, что для некоторого типа рекуррентных сетей такими структурными элементами могут быть ансамбли синапсов. Рассмотрены возможные способы кодирования признаков в ансамблях синапсов. На примере обученной сети показано существование таких ансамблей и значительные различия между ролью синапсов, входящих и не входящих в ансамбли.

Ключевые слова: ансамбли синапсов, кодирование признаков, искусственная нейронная сеть, аппроксимация многомерной функции.

V.I. GOLOSHCHAPOV

Scientific and cultural center SETI, Moscow
kraidiky@gmail.com

ENSEMBLES OF SYNAPSES AS CANDIDATES FOR THE ROLE OF STRUCTURES THAT ENCODE SEMANTIC PROPERTIES IN ARTIFICIAL NEURAL NETWORKS

This research addresses the issue of searching ANN structural elements which disentangle semantic properties of the input signal and directly encode network responses at the output. It is shown that ensembles of synapses in ANN could be such structural elements for some types of networks. Possible

ways of semantic properties encoding in ensembles of synapses were analyzed. By the example of a trained ANN, the author proves the existence of such ensembles and shows a significant difference between the role of synapses placed both within and outside of the ensembles.

Keywords: *ensembles of synapses, encoding semantic properties, artificial neural network, the approximation of multivariate functions.*

Введение

В настоящее время в научной среде активные дискуссии вызывает вопрос, происходит ли выделение отдельных семантических признаков изучаемой нейронной сетью предметной области на отдельные структурные элементы сети. Чаще всего, под такими элементами понимаются отдельные нейроны, которые должны активироваться при предъявлении сети данных, содержащих семантически значимые единицы. Поиск таких ситуаций занимается целый ряд исследователей [1–3], а авторы других научных работ видят в этом ошибку интерпретации наблюдателя [4]. В то же время, некоторые исследователи приходят к более строгому выводу – показывают, что ничего подобного не наблюдается в узких частных случаях [5]. Выделение семантически значимых признаков наиболее часто связывают с рекуррентными сетями Хопфилда или Машиной Больцмана. Примеры вычленения символов производятся также на основе сетей Кохонена. В некоторых работах предполагается, что эффект, может быть вызван конкуренцией нейронов в одном слое [6], что, формально говоря, также можно считать рекуррентным отношением.

В данной работе на реальном примере показано, что в обычной рекуррентной сети может иметь место процесс выделения ограниченного количества элементов, отвечающих выборочно на один из семантически значимых признаков. Вероятно, что те же самые явления можно обнаружить – в большей или меньшей степени – в самых разных сетях, обладающих достаточной глубиной и выучивших много информации, близко к максимуму возможностей сети.

В этом исследовании в качестве носителя информации о семантически значимом признаке рассматривается не нейрон, а ансамбль синапсов, таких, что их согласованное изменение значимо влияет только на выбранный признак, несущественно изменяя ответ сети на другие данные. При этом можно непосредственно наблюдать действие ансамбля синапсов на обработку данных.

Пример задачи и обученной сети

Наиболее часто нейронная сеть используется для классификации. На вход ей подаётся множество входных зашумлённых образов, а на выходе она должна их успешно классифицировать по малому количеству признаков. Например, присутствует ли на картинке кошка или нет. Эта типовая задача неудобна для поиска внутри сети осмысленных признаков во входных данных по целому ряду причин. Первая из них в том, что отсутствует возможность строго наблюдать взаимосвязь между семантическим признаком и состоянием какого-нибудь внутреннего элемента. Кроме того, огромные размеры сетей, связанные с реальными практическими задачами [4, 5], не позволяют просмотреть данные по всем нейронам и поиск становится вынужденно случайным.

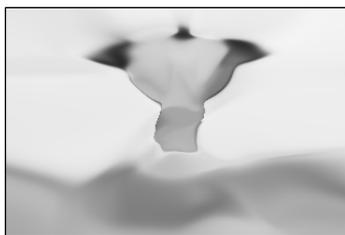


Рис. 1. Карта активации 31-го нейрона

Прием, используемый во многих исследованиях [1-4] при выявлении данных, активирующих нейрон, не подходит для случаев с беспороговой функцией активации, поскольку на нормальных данных нейрон может работать не на максимуме возбуждения. Более того, информацию могут нести не те области, где нейрон активен, а напротив, области, где он не активен (рис 1).

В данном исследовании выбрана задача аппроксимации сетью двумерной функции. Экспериментатор задает определенное изображение. На два входа сети подаются два действительных числа – координаты X и Y . А на трёх выходах R , G и B мы будем ожидать предсказание, какого цвета точка должна находиться на картинке в этих координатах. Все величины отнормированы на отрезок $(-1; 1)$. В качестве основного критерия успешности обучения используется суммарная среднеквадратичная ошибка по



Рис. 2. Результаты обучения

всем точкам (RMSE). На рис. 2 показано исходное изображение – летящий павлин, и изображение, которое рисует обученная сеть. В результате обучения, нейронная сеть научилась достаточно точно передавать нюансы цвета павлина, но, к сожалению, на чёрно-белой иллюстрации этого не видно.

В статье используется рекуррентная сеть обычных нейронов с гипертангенсом

в качестве сигмоиды. Выбранная ИНС отличается от обычного многослойного перцептрона только своей топологией, а именно – характеризуется значительной глубиной по сравнению со своими размерами. Максимальная глубина используемой ИНС составляет 28 нейронов, при размере в 37 нейронов, и средневзвешенной глубине в 4 скрытых слоя. Сеть содержит 460 синапов. Для обучения ИНС использовался метод обратного распространения ошибки в версии Mini-Batch и дополнительный алгоритм, являющийся дальним родственником алгоритмам ограничения энергии, но не использующий для ограничения синапов информации нижележащих нейронов, то есть не дающий эффекта рекурсии даже в самом широком толковании. Учитывая очень скромные размеры сети, качество достигнутого ею приближения является значительным.



Рис. 3. 33-й нейрон



Рис. 4. 29-й нейрон

Карты активации нейронов показывают уровень возбуждения нейрона при разных входных данных. Для многих нейронов карты активации можно трактовать как содержащие семантически значимые свойства. Например, на рис. 3 – контур птицы остается без деталей расцветки и без головы, а на рис. 4 – тело птицы без головы. При этом на рис. 1 можно увидеть основания крыльев и потерянную голову. Однако при просмотре цветного изображения возможна другая интерпретация изображения – как карты расположения на рисунке тёмно-синих пятен. Таким образом, можно заключить, что используемая сеть хорошо подходит для поиска семантически значимой информации.

Предположения о механизмах кодирования

Воспользуемся идеями обратной разработки. Представим, что перед нами поставили задачу: без какого-либо обучения сконструировать из нейронов классификатор, определяющий, где находится входная точка – выше или ниже прямой, проходящей через точку $(0,0)$. Для решения такой задачи достаточно одного нейрона (рис. 5). Веса синапов соотносятся как

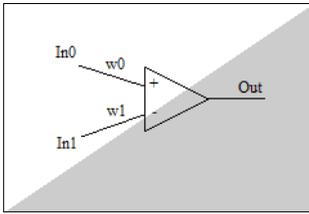


Рис. 5

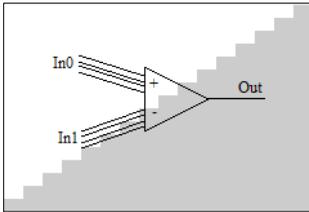


Рис. 6

коэффициент наклона прямой и имеют разные знаки. Знак потенциала на выходе будет ответом.

Теперь существенно усложним задачу. Необходимо также сравнивать пары величин. Однако теперь входные значения будут поступать в виде двоичного числа. Например, 4-битного. Следует отметить, что с такой задачей справится уже далеко не каждый алгоритм обучения. Тем не менее, ответ очевиден (рис. 6). Как и в предшествующей задаче, достаточно одного нейрона. У первой четверки синапсов, принимающих первую величину, веса соотносятся как 8:4:2:1, у второй – то же самое, но отличающееся в $-k$ раз. Разнести решение этой задачи в два отдельных нейрона значит усложнить решение задачи, если только входное значение, преобразованное из двоичного кода, не необходимо где-то ещё в другой части сети.

В результате решения задачи получается следующее: с одной стороны, нейрон один, но, с другой стороны, у него обнаруживается два совершенно отдельных ансамбля синапсов, представляющих обработку разных свойств входных данных. Отсюда следуют первые предположения:

- за представление свойств в нейронной сети могут отвечать не нейроны, а группы (ансамбли) синапсов;
- в одном нейроне мы часто видим комбинацию результатов работы нескольких ансамблей синапсов.

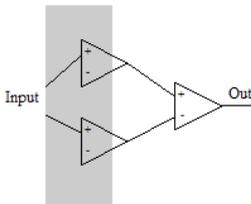


Рис. 7

Проведем третий мысленный эксперимент. Допустим, у нас есть всего один вход и нам необходимо, чтобы нейрон активировался только на одном диапазоне значений. Такую задачу решить на одном нейроне с монотонной функцией активации не получится. Нам потребуется три нейрона (рис. 7). Первый будет активироваться на первой границе, и активировать выходной нейрон, второй – активироваться при большем входном значении и тормозить выходной нейрон, третий – активироваться на второй границе.

Этот мысленный эксперимент позволяет нам сформулировать вторую группу предположений:

- ансамбль синапсов может захватывать несколько нейронов;
- если в системе есть несколько синапсов, меняющих некоторую границу с разной интенсивностью и в разный момент, ансамбль синапсов, включающий их оба, может использоваться для того чтобы управлять новым свойством «промежуток между границами».

Наконец, поставим последний четвёртый мысленный эксперимент. Допустим, нам требуется включить выходной нейрон на двух независимых и неперекрывающихся участках. Решить задачу можно, пользуясь 4 нейронами. Первый нейрон активируется и активирует выходной нейрон. Вторым нейрон активируется частично и тормозит выходной нейрон. В это время активируется третий, вновь активируя выходной нейрон. Второй нейрон набирает максимальную активацию и за счёт большего веса своего синапса вновь тормозит выходной нейрон. В таком случае 1-я граница почти полностью зависит от первого нейрона, а четвёртая – от последнего в первом слое. Вместе с тем, положение второй и третьей границ можно изменить, не затрагивая других границ, но для этого придётся согласованно менять веса нескольких синапсов.

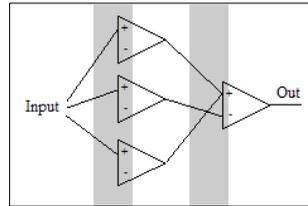


Рис. 8

Несмотря на то, что каждый синапс в сети такого типа влияет на обработку всего сигнала, только немногие из них влияют на отдельные свойства сильно, обеспечивая их представление и изменение. Воздействие большинства синапсов оказывается существенно менее сильным. Если пытаться повлиять на свойство, меняя такие «слабые» синапсы, то те свойства, в управление которыми они вовлечены сильно, изменятся неприемлемо гораздо раньше.

Этот мысленный эксперимент позволил сформулировать последние предположения относительно свойств ансамблей синапсов:

- ансамбль работает только в рамках существующего около него окружения других нейронов и синапсов. При этом работа ансамбля почти не зависит от малых изменений окружения.

Ансамбли синапсов, характеризующиеся описанными свойствами, мы и будем искать в нашей сети, чтобы подтвердить возможность их существования на реальном примере.

Наблюдение синаптических ансамблей

Малые размеры сети, используемой в исследовании, дают возможность непосредственно изучить, как изменение веса каждого из синапсов

влияет на картинку, порождаемую сетью. Начнём с самого первого синапса, номера 0. Этот синапс в одиночку отвечает за наклон тела птицы в левую сторону (рис 9). Справа на рисунке разность между исходным и изменённым изображением. Никакой другой синапс не принимает участия в формировании этой опорной линии. И голова птицы оказывается за ней.

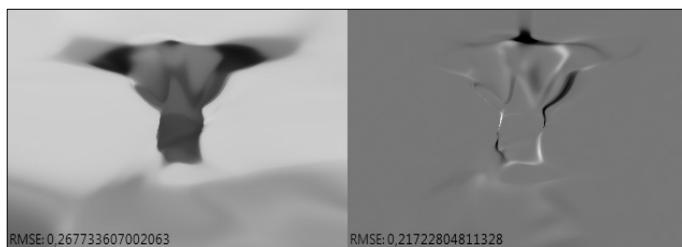


Рис. 9. Изменение ответа сети при изменении синапса номер 0



Рис. 10. Нейрон 0



Рис. 11. Синапс 418

Взглянув на карту активации нейрона, к которому ведёт синапс 0 (рис. 10), можно предположить, что второй синапс этого нейрона также будет управлять наклоном первой опорной линии, вокруг которой строится вся геометрия птиц. Однако это неверно: изменения веса второго синапса приводит к изменению другого свойства – ширины тела птицы.

Здесь надо отметить, что воздействие близко расположенных синапсов на несколько свойств часто можно интерпретировать как отдельное свойство. Однако в общем случае это неверно. Например, посмотрим на карту изменений, вызываемых 418-м синапсом, являющимся частью ансамбля, контролирующего баланс зелёного цвета. На рис. 11 представлен зелёный цветовой канал, на синий канал он влияет незначительно, а на красный вообще никак.

Если мы попытаемся двигать сеть вдоль базиса, состоящего из 0-го и 418-го синапсов, станет видно, как птица наклоняется влево и становится всё менее зелёной. Однако вряд ли возможно считать это одним свойством. В работе [4] утверждалось, что с помощью натурального базиса, связанного

с одним из элементов нейронной сети, исследователь может «найти» столько же семантически значимой информации, сколько и с помощью базиса, связанного с линейной комбинацией нескольких элементов. Это чаще всего верно для нейронов и для влияния нескольких синапсов, входящих в один или несколько близких синаптических ансамблей. Но мы видим, что это неверно, когда речь идёт о синапсах, относящихся к ансамблям, кодирующим сильно отличающиеся свойства. В этом случае смешение не помогает в них запутаться.

Теперь рассмотрим более сложное свойство, затрагивающее малую часть картинки. Например, размеры и форму областей под крыльями, где у птицы короткие хвостовые перья. Выпишем все нейроны, которые влияют на эти области напрямую (например, на левую из них), а именно, отвечают за изменение отдельных частей птицы, а не её общую геометрию. Получится, что в ансамбль входят синапсы 21, 22, 23, 24, 25, 26, 27.

К примеру, 23-й и 24-й синапсы, увеличивают длину и ширину выбранной нами области, противоположным образом влияя на длину всего крыла (рис. 12). Так что, изменяя их одновременно, можно менять область под крылом, не влияя на длину крыла (рис. 13). Синаптический ансамбль ведёт себя как в предложенном ранее четвёртом мысленном эксперименте.

Все указанные синапсы ведут к нейрону номер 5, и при взгляде на его карту активации (рис 14) практически невозможно предположить, что он участвует в контроле этого свойства изображения. Что говорит в пользу эффективности предложенного в данном исследовании способа визуализации.

Если мы посмотрим, какие синапсы влияют на размер и форму этой области совместно с другими областями, то обнаружим еще несколько десятков: 37-46 (8-й нейрон), 70-83 (11 и 12-й нейроны), 90-94 (12 и 13-й

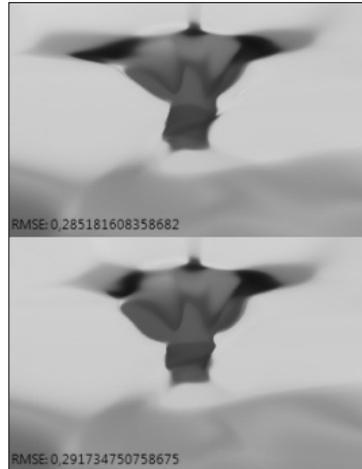


Рис. 12. Синапсы 23 и 24



Рис. 13. Синапсы 23 и 24 совместно

нейроны), 129-138 (16-й нейрон), а также ряд отдельных синапсов, например, 178-й (19-й нейрон). При этом остальные синапсы могут изгибать почти всё изображение, но выбранную область почти не затрагивать, как, например, 28-й синапс (6-й нейрон), даже если за него сильно подёргать (рис 15).



Рис. 14. Синапс 28

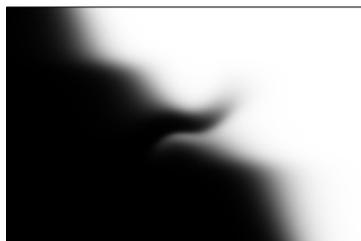


Рис. 15. Нейрон 5

Подведем итоги. Мы обнаружили ансамбль синапсов, регулирующий выбранное нами свойство. Сеть при необходимости компенсирует его влияние на другие свойства согласованным изменением весов синапсов в ансамбле, или используя другие ансамбли. Ансамбль синапсов задействует, по меньшей мере, 7 нейронов. Это пятая часть всех нейронов сети и они также используются многими другими ансамблями.

Точно также можно подробно рассмотреть синапсы, влияющие на цвет областей, или форму маховых перьев, или на многие другие признаки, присутствующие на изображении. Не все признаки кодируются компактными ансамблями. Например, на наличие у птицы головы влияет разными способами почти треть всех синапсов сети.

В заключение раздела, вернемся к рассмотрению карт активации последних нейронов в сети (см. рис. 1, 3, 4). Нейронная сеть может приближаться к требуемой от неё функции в виде суммы функций, эффективно аппроксимирующих отдельные участки. Но чем больше данных выучивает сеть, тем меньше она может выделить своих структурных элементов на то, чтобы кодировать каждый отдельный признак. Если нужно осуществить простую классификацию, имея миллиард настраиваемых

параметров, как в некоторых сетях работы [4], каждый из них, скорее всего, будет управлять свойством только на одном маленьком участке и только вместе с сотнями других таких же. Однако если сеть размером примерно четыре десятка нейронов заставить выучить картинку, в которой под сотню значимых свойств, она или не справится или выделит синтаксически значимые признаки в отдельные структурные единицы, где их будет легко обнаружить. Выходные нейроны сети связаны с не очень большим количеством нейронов, и для формирования картинки с таким большим количеством значимых элементов, сети пришлось на предпоследних нейронах собирать результаты работы нескольких ансамблей синапсов вместе. Нейронам 29, 31 и 33 повезло, в них собрались геометрические данные, которые легко распознать и мы сразу обратили на них внимание. Нейронам 27, 28 или 32 повезло меньше, в них собралась информация о расположении цветочных пятен на картинке – в этом случае понять, в чем смысл полученных карт активации не представляется возможным (рис. 16).



Рис. 16. Карты активации нейронов 27, 28, 32

Заключение

Элементы, кодирующие семантически значимые признаки, могут присутствовать в нейронной сети. Однако это будут не нейроны, как предполагается в ряде современных исследований, а ансамбли синапсов разного размера.

Большинство нейронов участвуют сразу в нескольких ансамблях синапсов. Поэтому, при изучении условий активации отдельного нейрона обнаруживается комбинация влияния этих ансамблей, что сильно затрудняет определение роли нейронов.

Такой результат, с одной стороны, позволяет оппонировать популярной интерпретации условий активации отдельных нейронов как *отдель-*

ных семантически значимых признаков, а с другой – понять ее причину. Комбинация семантически значимых признаков часто может восприниматься как отдельный семантически значимый признак. Становится также понятным, почему для разных исследований, посвящённых этой теме, характерны настолько разные и трудно интерпретируемые результаты.

В результате проведённого исследования имеются основания полагать, что формирование компактных ансамблей синапсов возможно даже в самых простых рекуррентных сетях при условии достаточной их глубины, а также в случае, если сеть обучается значительному количеству информации, так что перед ней возникает необходимость кодировать в маленьком количестве структурных элементов большое количество информации.

Список литературы

1. Girshick R., Donahue J., Darrell T., Malik J. Rich feature hierarchies for accurate object detection and semantic segmentation. // arXiv preprint, 2013. arXiv:1311.2524.
2. Zeiler M.D., Fergus R. Visualizing and understanding convolutional neural networks. // arXiv preprint, 2013. arXiv:1311.2901.
3. Goodfellow I., Quoc Le, Saxe A., Lee H., and Y Ng A. Measuring invariances in deep networks. // Advances in neural information processing systems, 2009. V. 22 P. 646–1.
4. Szegedy C., Zaremba W., Sutskever I., Bruna J., Erhan D., Goodfellow I., Fergus R. Intriguing properties of neural networks // arXiv preprint, 2014 arXiv:1312.6199
5. Mikolov T., Chen K., Corrado G., Dean J. Efficient estimation of word representations in vector space. // arXiv preprint, 2013. arXiv:1301.3781.
6. Чернявский Д.С., Карп В.П., Никитин А.П., Щепетов Д.С., Чернявская О.Д. Естественно-конструктивистский подход к моделированию мышления: анализ динамики процесса формирования символов. // Сб. науч. трудов «Нейроинформатика 2014». Ч. 3. М.: НИЯУ МИФИ, 2014. С. 29-39.

З.М. ШИБЗУХОВ¹, Д.Ю. ЧЕРЕДНИКОВ²

¹Научно-исследовательский институт прикладной математики и автоматизации Кабардино-Балкарского научного центра РАН, Нальчик

²Московский педагогический государственный университет
szport@gmail.com

**О МОДЕЛЯХ ИСКУССТВЕННЫХ НЕЙРОНОВ
АГРЕГИРУЮЩЕГО ТИПА**

В настоящей работе описывается новый класс моделей искусственных нейронов агрегирующего типа. Модели такого типа основаны на предположении о том, что: 1) все вклады синапсов суммируются при помощи некоторой агрегирующей операции; 2) вклады простых синапсов, которые образуют сложный синапс или синаптический кластер, преобразуются также при помощи некоторой другой агрегирующей операции. Они охватывают большую часть моделей искусственных нейронов функционального типа.

Ключевые слова: *нейронная сеть, модель нейрона, агрегирующая операция.*

Z.M. SHIBZUKHOV¹, D.Y. CHEREDNIKOV²

¹ Scientific Research Institute of Applied Mathematics and Automation,
Kabardino-Balkar Scientific Center of the RAS, Nalchik

² Moscow State Pedagogical University
szport@gmail.com

**ABOUT MODELS OF ARTIFICIAL NEURONS
OF AGGREGATIONAL TYPE**

In this work we describe a new class of artificial neurons models of the aggregational type. These models are based on the following assumptions: 1) all the synapses contributions are summed with the aid of a certain aggregation operation; 2) contributions of elementary synapses that form a complex synapse or a synaptic cluster are also computed with the aid of another aggregation operation on the set of simple synapses. These models include a big part of known functional models of neurons.

Keywords: *neural networks, neuron model, aggregation operation.*

Введение

Классический подход к нейронным сетям рассматривает их как сеть нейронов. Каждый нейрон в сети имеет: 1) несколько входов от других нейронов или от входов сети и 2) только один выход, который может разветвляться для передачи на вход других нейронов или на выход сети.

Значительные класс нейронных сетей – нейронные сети прямого пространства. Они разделяются на слои, так что: 1) нейроны, принадлежащие одному слою, не связаны друг с другом по входам и выходам, 2) выходы нейронов в слое поступают на вход нейронов из другого слоя или на выход сети. Слои пронумерованы, так что на вход нейронов, могут поступать сигналы из слоя только с меньшим номером или от входов сети. В рамках такого функционального подхода нейронные сети реализуют функциональные преобразования, которые представляют собой композицию функций, реализуемых отдельными нейронами сети.

Нейроны являются сложными элементами нейронной сети. Они имеют разветвленную дендритную систему, в которую сигналы передаются при помощи синапсов. Синапсы могут быть как простые, когда в их образовании участвует единственный вход, так и сложные, когда в их образовании участвуют одновременно несколько входов. Также могут иметь место пространственно-локализованные синаптические кластеры, которые образуют зоны дендритной системы, в которых обработка информации ведется независимо от других зон.

Для описания преобразования сигналов в нейроне вводится понятие суммарного потенциала нейрона, который преобразуется в выход нейрона. Входы нейрона преобразуются посредством синапсов и вносят определенный вклад в увеличение или уменьшение суммарного потенциала нейрона. Дендритная система нейрона агрегирует вклады синапсов и формирует суммарный потенциал нейрона. На его основе генерируется выходной сигнал нейрона.

Различные модели нейрона получаются в зависимости от того: 1) каким образом моделируются простые и сложные синапсы, 2) какая модель используется для описания синаптических кластеров, 3) каким образом агрегируются вклады синапсов.

В данной работе описываются функциональные модели нейронов, которые основаны на применении агрегирующих операций для вычисления суммарного потенциала нейрона и вклада сложных синапсов и синаптических кластеров. Эти модели обобщают классические модели искусственных нейронов, которые лежат в основе моделирования искусственных нейронных сетей. Диапазон классических моделей весьма ограничен, что

накладывает ограничения на виды нейросетевых моделей, которые можно реально использовать для восстановления неизвестных зависимостей. Как известно, одной из причин переобучения является неверно «угаданная» модель зависимости, из-за чего в процессе обучения происходит восстановление не столько модели зависимости в данных, сколько моделируются сами имеющиеся данные. Один из способов преодоления этой проблемы состоит в использовании нестандартных типов моделей искусственных нейронов. Таким образом на основе теории агрегирующих операций и функций можно строить очень широкий диапазон моделей нейронов.

Общая функциональная модель нейрона

Пусть значения, передаваемые между нейронами, принадлежат сегменту $Y \subset R$ (например, $[0,1]$ или $[-1,1]$), а значения суммарного потенциала нейрона – сегменту $U \subseteq R$. Входные сигналы посредством синапсов преобразуются в соответствующий вклад в суммарный потенциал нейрона при помощи преобразования

$$\text{syn} : Y \rightarrow U \quad (1)$$

в случае простого синапса или

$$\text{syn} : Y \times \dots \times Y \rightarrow U \quad (2)$$

в случае сложного синапса или синаптического кластера.

Сложный синапс и синаптический кластер можно рассматривать как композицию простых синапсов:

$$\text{syn}(x_{i(1)}, \dots, x_{i(m)}) = \eta \{ \text{syn}_1(x_{i(1)}), \dots, \text{syn}_n(x_{i(n)}) \}, \quad (3)$$

где $\text{syn}_1, \dots, \text{syn}_n$ – функции преобразования простых синапсов, входящих в сложный синапс или синаптический кластер, η – функция, агрегирующая вклады простых синапсов в синаптическом кластере.

Функция суммарного потенциала *агрегирует* все вклады простых, сложных синапсов и синаптических кластеров, реализуя преобразование:

$$\text{Agg} : U \times \dots \times U \rightarrow U, \quad (4)$$

Agg – агрегирующая операция [1,2]. Функция выхода

$$\text{out} : U \rightarrow Y \quad (5)$$

задает закон преобразования суммарного потенциала нейрона в его выход.

В описанной модели нейрон осуществляет цепочку преобразований:

$$u_j = \text{syn}_j \{ x_{i(j,1)}, \dots, x_{i(j,n_j)} \} \quad (6)$$

или

$$u_j = \text{syn}_j \{ x_{i(j)} \}; \quad (7)$$

$$s = \text{Agg}\{u_1, \dots, u_2\}; \quad (8)$$

$$y = \text{out}\{s\}, \quad (9)$$

где x_1, \dots, x_n – входы, а y – выход нейрона; $i(j, t)$ – индекс t -го входа, j -го синаптического кластера; $i(j)$ – индекс входа j -го простого синапса; u_1, \dots, u_m – вклады синапсов и синаптических кластеров; s – суммарный потенциал нейрона.

Модели нейрона с простыми синапсами

Классическая модель синапса линейная, т.е. $\text{syn}(x, w) = ax$. Классический нейрон имеет только простые синапсы и реализует преобразование

$$y = \text{out}\left(\theta + \sum_{i=1}^n w_i x_i\right), \quad (10)$$

где w_i – вес i -го синапса, слагаемое $w_i x_i$ соответствует преобразованию в i -м синапсе, суммарный потенциал нейрона есть арифметическая сумма вкладов простых синапсов и смещения θ (потенциал нейрона в состоянии покоя).

Эта модель является частным случаем более общей модели нейрона с простыми синапсами:

$$y = \text{out}\left(\theta + \sum_{i=1}^n \text{syn}(x_i, w_i)\right), \quad (11)$$

где $\text{syn}(x, w)$ – нелинейная скалярная функция преобразования простого синапса, w – параметр (синаптический вес). При построении нелинейных моделей простых синапсов будем исходить из того, что синаптическая функция ограниченная и неубывающая.

Пусть $Y = [0, 1]$, $U = [0, c]$, где $c \geq 1$, $\gamma \geq 0$. Приведем примеры:

$$1) \text{syn}(x, w) = \min\{c, wx^\gamma\};$$

$$2) \text{syn}(x, w) = \min\{c, 1 - e^{-wx^\gamma}\};$$

$$3) \text{syn}(x, w) = \min\{c, e^{-wx^\gamma} - 1\}.$$

Обобщением взвешенного арифметического суммирования, которое сохраняет все его привычные алгебраические свойства, является, так называемое, g -суммирование [3,4]:

$$\left(\theta + \sum_{i=1}^n w_i u_i\right)_g = g^{-1}\left(\tilde{\theta} + \sum_{i=1}^n \tilde{w}_i g(u_i)\right), \quad (12)$$

где $\tilde{\theta} = g(\theta)$, $\tilde{w} = g(w_i)$, $g: U \rightarrow R$ – монотонная обратимая функция. Оно является точным аналогом арифметического суммирования.

Модель классического нейрона, в котором вместо обычного суммирования используется g -суммирование принимает следующий вид:

$$y = out \circ g^{-1} \left(\theta + \sum_{i=1}^n w_i g(u_i) \right), \quad (13)$$

где символ \circ обозначает операцию композиции функций, $u_i = syn(x_i, w_i)$ Теорема Акцеля [5] объясняет, почему выделяется g -суммирование: всякая непрерывная и ассоциативная агрегирующая операция на сегменте $U \subset R$ представляет собой некоторое g -суммирование.

Классическую модель нейрона с простыми синапсами можно обобщить до модели нейрона агрегирующего типа с простыми синапсами, заменив сумму на произвольную симметричную агрегирующую функцию Agg :

$$y = out \circ Agg \{ \theta, u_1, \dots, u_n \}, \quad (14)$$

где $u_i = syn(x_i, w_i)$ – вклад простого синапса с входом x_i и весом w_i в суммарный потенциал нейрона.

Модель $\Sigma\Pi$ -нейрона со сложными синапсами

Примером нейрона со сложными синапсами является $\Sigma\Pi$ -нейрон. Эта модель нейрона впервые было предложена в [6] и использовалась как модель, которая отражает локальное взаимодействие входов в сложных синапсах и простых синапсов в синаптических кластерах [7]. В работах [8, 9] было показано, что модель $\Sigma\Pi$ -нейрона наиболее адекватно соответствует процессам обработки информации, протекающих в коре головного мозга. Достоинством этой модели является ее относительная простота и выразительность. Например, в модели $\Sigma\Pi$ -нейрона с функцией выхода, принимающей значения в $\{0,1\}$, можно представить любую логическую функцию. Сплайны для аппроксимации непрерывных функций многих переменных можно рассматривать как $\Sigma\Pi$ -нейрон, на вход которого подаются сигналы, предварительно преобразованные при помощи скалярных усечено-степенных функций. В работе [10] показано, что адекватная функциональная модель обучения нейронов коры головного мозга получается в случае, когда на вход $\Sigma\Pi$ -нейрона подаются сигналы, предварительно преобразованные при помощи радиальных функций. Более под-

робный анализ моделей со сложными синапсами и синаптическими кластерами можно найти в [11].

ΣП-нейрон имеет сложные синапсы, которые реализуют преобразование вида:

$$\text{syn}(u_1, \dots, u_n) = \prod_{i=1}^m u_i. \quad (11)$$

Суммарный потенциал по-прежнему есть арифметическая сумма вкладов простых синапсов и смещения θ :

$$y = \text{out}(\theta + \sum_{k=1}^m w_k \prod_{i \in i_k} u_{ki}), \quad (12)$$

где $i_k \subseteq \{1, \dots, n\}$, w_k – вес k -го синаптического кластера, $u_{ki} = \text{syn}(x_i, w_{ki})$ – скалярная синаптическая функция k -го сложного синапса с входом x_i , а w_{ki} – его синаптический вес.

Нетрудно заметить, что сложный синапс в ΣП-нейроне реализует агрегирующую функцию. Поэтому ΣП-нейрон можно представить двуслойной сетью, где в первом слое вычисляются вклады сложных синапсов при помощи агрегирующей функции, а во втором вклады синапсов агрегируются при помощи взвешенного суммирования. В [15] показано, что обобщенная модель ΣП-нейрона способна представлять дискретные зависимости, а также приближать непрерывные функции из очень широких классов.

Модель нейрона с агрегирующими сложными синапсами

Модель ΣП-нейрона является частным случаем следующей модели нейрона со сложными синапсами:

$$y = \text{out}(\theta + \sum_{k=1}^m \omega_k u_k), \quad (15)$$

где ω_k – вес k -го агрегирующего синапса, а u_k – его вклад:

$$u_k = \sum_n \{u_i : i \in i_k\} = h^{-1}(\sum_{i \in i_k} w_{ki} h(u_{ki})), \quad (16)$$

Σ_h – квази-арифметическая агрегирующая функция, $h : U \rightarrow R$ – обратимая монотонная функция масштабирования.

Другие модели получаются путем выбора соответствующей функции масштабирования h .

В общем случае можно определить модель нейрона с агрегирующими сложными синапсами:

$$y = out \left(\theta + \sum_{k=1}^m w_k Agg \{ u_{ki} : i \in i_k \} \right), \quad (17)$$

где Agg – симметричная агрегирующая функция.

Таблица 1

Примеры моделей с соответствующей функцией масштабирования h

$h(u)$	Суммарный потенциал нейрона
$\ln u$	$\theta + \sum_{k=1}^m w_k \prod_{i \in i_k} u_{ki}$
$u^{(p)} = \text{sign } u \cdot u ^p$	$\theta + \sum_{k=1}^m w_k \left(\sum_{i \in i_k} u_{ki}^{(p)} \right)^{(1/p)}$
e^{pu}	$\theta + \sum_{k=1}^m w_k \frac{1}{p} \ln \left(\sum_{i \in i_k} e^{pu_{ki}} \right)$
$\ln(1 + e^{pu})$	$\theta + \sum_{k=1}^m w_k \frac{1}{p} \ln \left(-1 + \prod_{i \in i_k} (1 + e^{pu_{ki}}) \right)$

Двухслойная модель нейрона со сложными синапсами

В общем случае модель нейрона со сложными синапсами можно записать в следующем виде:

$$y = out \circ Agg_1 \{ \theta, s_1, \dots, s_m \}, \quad (18)$$

$$s_k = Agg_2 \{ u_{ki} : i \in i_k \}, \quad k = \overline{1, m}, \quad (19)$$

где Agg_1 – агрегирующая операция для вычисления суммарного потенциала нейрона, Agg_2 – агрегирующая операция для вычисления общего вклада простых синапсов, входящих в состав сложного синапса, в суммарный потенциал нейрона.

Таким образом, приходим к двухслойной модели нейрона, в которой: 1) во входном слое вычисляются отдельные вклады простых синапсов; 2) в первом слое вычисляются вклады сложных синапсов при помощи агрегирующей операции Agg_2 ; 3) во втором слое вычисляется суммарный потенциал нейрона при помощи агрегирующей Agg_1 .

Значительный класс таких моделей можно получить, используя квазиарифметические агрегирующие операции. Пусть $g, h : U \rightarrow R$ – пара обратимых скалярных функций,

$$Agg_1 \{ \theta, s_1, \dots, s_m \} = g^{-1} \left(\theta + \sum_{k=1}^m w_k g(s_k) \right), \quad (20)$$

$$Agg_2 \{ u_{ki} : i \in i_k \} = h^{-1} \left(\sum_{i \in i_k} h(u_{ki}) \right). \quad (21)$$

Тогда модель нейрона имеет вид:

$$y = out \circ g^{-1} \left(\theta + \sum_{k=1}^m w_k g(s_k) \circ h^{-1} \left(\sum_{i \in i_k} h(u_{ki}) \right) \right). \quad (22)$$

Связь с другими моделями

Классическая модель нейрона с простыми синапсами по форме идентична обобщенной линейной модели [12], которая имеет статистическую природу. В ней функция связи соответствует функции выхода и отражает связь между математическим ожиданием целевой переменной и взвешенной линейной комбинацией предикторов. В линейной модели нелинейным преобразованием признаков [13] наоборот учитывается функция распределения значений входных предикторов. Объединение этих двух моделей дает статистическую модель, которая похожа на модель нейрона с простыми нелинейными синапсами (10). Двуслойная модель нейрона вида (22), по существу, представляет собой двуслойную сеть, состоящую из нейронов с линейной функцией суммарного потенциала.

Заключение

В настоящей работе описаны новые классы моделей нейронов агрегирующего типа, которые включают в себя классические функциональные модели нейронов, в том числе со сложными синапсами. Различные модели нейрона расположены в определенной иерархии, так что при необходимости можно переходить от более простых моделей нейронов к более сложным. Это практически важно, когда необходимо расширять возможности модели при необходимости.

В дальнейшем предстоит теоретическое и экспериментальное исследование возможностей таких моделей нейронов по аппроксимации различных типов зависимостей. Так как модели $\Sigma\Pi$ -нейронов и некоторые их обобщения показали очень хорошие способности по аппроксимации многих типов зависимостей [14, 15, 16], то не меньших способностей можно ожидать и от моделей нейронов агрегирующего типа.

Также предстоит исследовать эффект от применения различных классов агрегирующих функций как для агрегирования вкладов в сложных

синапсах и синаптических кластерах, так и для агрегирования всех вкладов в суммарный потенциал нейрона.

Список литературы

1. Mesiar R., Komornikova M., Kolesarova A., Calvo T. Aggregation functions: A revision. In H. Bustince, F. Herrera, J. Montero // *Fuzzy Sets and Their Extensions: Representation, Aggregation and Models*. Springer, Berlin, Heidelberg, 2008.
2. Grabich M., Marichal J.-L., Pap E. Aggregation Functions // *Series: Encyclopedia of Mathematics and its Applications, No.127* // Cambridge University Press, 2009.
3. Pap E. g-calculus // *Univ. u Novom Sadu Zb. Rad. Prirod.-Mat. Fak. Ser. Mat.*, 1993. 23,1. PP. 145-150.
4. Pap E. Applications of the generated pseudo-analysis to nonlinear partial differential equations // *Preprint ESI 1448*. Vienna, 2004.
5. Acz'el J. Lectures on functional equations and their applications // *Academic Press*, New York, 1966.
6. Feldman J.A., Ballard D.H. Connectionist models and their properties // *Cognitive Science*. 1982. No.6. PP.205-254.
7. Rumelhart D. E., Hinton G., Williams R. Learning internal representation by error propagation // *Parallel Distributed Processing*. Cambridge, MA: MIT Press, 1986. V. 1 Foundations. P. 318-362.
8. Mel B. W. The sigma-pi column: A model of associative learning in cerebral Neocortex // *California institute of technology. cns memo no. 6: Tech. rep. Pasadena, California 91125*: 1990.
9. Mel B. W. The sigma-pi model neuron: Roles of the dendritic tree in associative learning // *Soc. Neuroscience Abstr.*, 1990. V. 16. P. 205.4.
10. Mel B. W, Koch C. Sigma-pi learning: on radial basis functions and cortical associative learning // *In Advances in neural information processing systems San Mateo, CA: Morgan Kaufmann*, 2000. V. 2. P. 474- 481.
11. Mel B.W. Why have dendrites? A computational perspective // *In Dendrites (2nd Edition)*, Oxford University Press, 2007.
12. McCullagh P., Nelder J. Generalized Linear Models // *Second Edition*. Boca Raton: Chapman and Hall/CRC, 1989.
13. Hasti T., Tibshirani R. Generalized Additive Models. // *Statistical Science*, 1986. V. 1, No. 3. P. 297-318.
14. Шибзухов З. М. Рекуррентный метод конструктивного обучения некоторых сетей алгебраических СП-нейронов и СП-нейромодулей. // *Журнал вычислительной математики и математической физики*, 2003. № 43. С. 1298-1310.
15. Шибзухов З.М. Конструктивные методы обучения СП-нейронных сетей. М.: МАИК, Наука, 2006.
16. Шибзухов З. М. О некоторых конструктивных и корректных классах алгебраических СП-алгоритмов // *Доклады РАН*, 2010. Т. 432 С. 465-468.

М.В. КИСЕЛЕВ

ООО «Мегапьютер Интеллидженс», Москва
mkiselev@megaputer.ru

ПРИМЕНЕНИЕ ЭМПИРИЧЕСКИХ МОДЕЛЕЙ ДЛЯ ПОСТРОЕНИЯ ИМПУЛЬСНЫХ НЕЙРОННЫХ СЕТЕЙ С ЗАДАНЫМИ СВОЙСТВАМИ

Даже для простейших моделей нейрона и однородных импульсных нейронных сетей зависимости между свойствами нейрона, структурными характеристиками сети и ее поведением не могут быть получены в явном аналитическом виде. Предлагается использовать для этой цели эмпирические модели, найденные с помощью методов data mining, в частности, множественных адаптивных регрессионных сплайнов. Этот подход иллюстрируется на примере однородной хаотической сети, состоящей из нейронов – пороговых интеграторов с гомеостатическими свойствами.

Ключевые слова: *импульсные нейронные сети, адаптивный порог возбуждения, кратковременное синаптическое подавление.*

M.V. KISELEV

Megaputer Intelligence, Moscow
mkiselev@megaputer.ru

CREATION OF SPIKING NEURAL NETWORKS WITH DESIRED PROPERTIES USING EMPIRICAL MODELS

Relations between neuron properties, structural characteristics of a spiking neural network and its behavior cannot be obtained in explicit analytical form even for simplest neuron models and homogenous networks. For this purpose, we propose to use empirical models produced, for example, by multiple adaptive regression splines and other data mining methods. As an illustration we discuss a spiking neural network consisting of LIF neurons with homeostatic properties.

Keywords: *spiking neural network, empirical model, dynamic threshold, short term synaptic depression, decision tree, multiple adaptive regression splines.*

Введение

В настоящее время большие импульсные нейронные сети (ИНС) [1] рассматриваются не только как реалистичные модели нейронных ансамблей мозга, но и как технологическая база для создания робототехнических систем, обучаемых автоматических систем управления, биометрических устройств и других прорывных технологий близкого будущего. Вероятно, уже в этом десятилетии будет возможно построение вычислительных систем, способных в реальном времени реализовывать функционирование нейронных сетей, состоящих из $10^7 - 10^8$ (или даже 10^9) нейронов, что уже близко к размеру человеческого мозга. Однако, наличие мощных массивно параллельных вычислителей является лишь необходимым, но отнюдь не достаточным условием. Для того, чтобы сеть демонстрировала желаемое (или хотя бы просто нетривиальное) поведение, ее структурные характеристики, параметры составляющих ее нейронов, константы, входящие в законы синаптической пластичности и т.д. должны быть достаточно тонко настроены. Таким образом, приобретает все большую и большую актуальность задача нахождения зависимости различных свойств сети как целого от этих параметров. Вследствие большого размера сети точная спецификация ее детальной структуры абсолютно невозможна. Могут быть заданы лишь параметры законов распределения синаптических весов, задержек, вероятности интернейронных связей, другие общие структурные характеристики сети, в то время как детальная конфигурация сети строится случайным образом на основе этих законов распределения. Следовательно, рассматриваемую проблему можно сформулировать следующим образом. Как, зная константы, входящие в модель нейрона, законы распределения величин, определяющих связи нейронов, и общие характеристики входного сигнала (далее мы будем именовать эти параметры входными), предсказать параметры активности сети в терминах частоты генерации спайков, их корреляции, реакции на вариации входного сигнала и т.п. (далее – выходные параметры)?

Эта задача оказалась очень сложной даже для простейших моделей нейрона и полностью однородных сетей. Наиболее популярный подход к ее решению основан на так называемых уравнениях среднего поля [2]. Однако его применимость остается весьма ограниченной по целому ряду причин. Даже для относительно простых моделей нейронов уравнения среднего поля имеют вид сложных интегро-дифференциальных уравнений, которые не допускают аналитического решения. Этот подход основан на предположениях, которые часто нельзя назвать реалистичными, – напри-

мер, о бесконечном размере сети. Однако показано [3], что эффекты конечного размера сети могут быть очень существенными даже для больших сетей. Есть и другие ситуации, нарушающие условия применимости этого метода, – например, наличие небольших популяций нейронов с высоко коррелированной активностью [4]. Как правило, построение и анализ уравнений среднего поля требует значительных усилий. Небольшое усложнение решаемой задачи, скажем, введение корреляций в первоначально чисто случайный внешний сигнал, часто приводит к кардинальному усложнению уравнений.

Основная идея данной работы заключается в том, что основным инструментом для построения ИНС с заданными свойствами могли бы быть эмпирические модели – формулы, выражающие зависимости между выходными и входными параметрами сети. Эти формулы должны получаться в результате автоматизированного анализа экспериментальных данных методами *data mining*. Предполагается, что процедура построения эмпирических моделей должна включать следующие шаги.

1. Определение входных и выходных параметров, которые должны фигурировать в искомым моделях. Для входных параметров необходимо также задать диапазоны их вариации. Входные параметры не должны включать величин, напрямую зависящих от размеров сети. Например, вместо абсолютного числа тормозящих нейронов должна использоваться доля тормозящих нейронов в сети. Это необходимо, чтобы результаты, полученные для сетей небольшого размера, были бы применимы к большим сетям.

2. Проведение экспериментов с различными комбинациями входных параметров. Число этих экспериментов должно быть достаточным, чтобы покрыть всю интересующую область значений входных параметров и избежать опасности переобучения алгоритмов *data mining*. Очень важен выбор размера ИНС для этих экспериментов. Так как многие интересные процессы в ИНС имеют статистическую природу, бессмысленно экспериментировать с маленькими сетями и ожидать, что результаты можно будет распространить на большие. С другой стороны, размер сетей в этих экспериментах должен быть гораздо меньше, чем у сетей, для которых требуется построить искомые зависимости, – иначе потеряет смысл весь процесс из-за его вычислительной трудоемкости. Вероятно, численность нейронов порядка нескольких тысяч может быть хорошим компромиссом во многих случаях. Значения входных параметров могут выбираться в соответствии с различными стратегиями – случайная генерация, выбор точек на регулярных решетках и т.д.

3. Анализ таблиц, состоящих из значений входных параметров и соответствующих им выходных параметров, измеренных в экспериментах, с помощью алгоритмов data mining – этот шаг будет рассмотрен в следующих секциях.

4. Верификация масштабируемости модели. Даже если модель не включает переменных, зависящих напрямую от размера сети, возможно, размер сети был недостаточен для выявления важных статистических эффектов или вызывал слишком сильные статистические флуктуации. Для того чтобы проверить масштабируемость результатов, должно быть проведено ограниченное число экспериментов с сетями большего размера.

Эта схема имеет ряд очевидных преимуществ. Она, по сути, является полуавтоматической и может быть единообразно применена для большого разнообразия сетевых архитектур, входных сигналов и т.д. Результирующая модель представляется в явном аналитическом виде, подходящем для использования в последующем анализе. Кроме того, зачастую найденные зависимости поддаются непосредственной интерпретации, тем самым способствуя интуитивному пониманию процессов, происходящих в сети.

В работе приводится пример применения этой методологии для решения следующей весьма общей проблемы. Разумеется, различные ИНС могут вести себя совершенно по-разному. Однако, есть по крайней мере три типа активности сети, совершенно бесполезных с любой точки зрения: нулевая активность – полное отсутствие генерации спайков, взрывной необратимый рост активности до максимально возможного уровня и мощные глобальные осцилляции – когда (почти) все нейроны генерируют спайки с течение коротких временных интервалов, разделенных периодами (почти) полного молчания. Наша задача состоит в нахождении условий, при которых сеть с высокой вероятностью избегает этих негативных сценариев и, следовательно, имеет шанс демонстрировать некую нетривиальную реакцию на внешний сигнал.

Нейрон LIF с динамическим порогом и кратковременным синаптическим подавлением

Сначала рассмотрим модель нейрона, используемую в данном исследовании. Она является обобщением часто используемой модели порогового интегратора с утечкой (leaky integrate-and-fire – LIF) и имеет две дополнительные черты, имеющие целью поддержание частоты генерации спайков в нужных пределах. Это – динамический порог [5] и кратковременное синаптическое подавление [6] (хотя используется упрощенная

реализация этого механизма). Эта модель допускает эффективную программную реализацию и позволяет воспроизводить многие интересные нелинейные эффекты. Она ранее использовалась мной в различных работах по моделированию ИНС [7, 8]; здесь приводится лишь ее краткое формальное описание, так как она фигурирует здесь только для иллюстрации предлагаемой идеи.

Состояние нейрона включает две компоненты: динамическая часть порога h ($h \geq 0$) и вклад отдельных синапсов в мембранный потенциал v_i ($0 \leq v_i \leq 1, 1 \leq i \leq n$, где n – общее число синапсов). Если вес i -ого синапса w_i , то текущее значение мембранного потенциала может быть записано как $u = \sum w_i v_i$. Значение мембранного потенциала покоя принято за 0, а значение порога генерации спайка после долго периода неактивности – за 1. Кроме w_i , свойства нейрона описываются двумя временными константами: τ_h и τ_v , определяющими скорость возвращения h и v_i соответственно к значениям покоя.

Таким образом, динамика нейрона описывается уравнениями (стрелка здесь означает присваивание значения):

$$\frac{dh}{dt} = -\frac{h}{\tau_h}, \quad \frac{dv_i}{dt} = -\frac{v_i}{\tau_v};$$

$$v_i \leftarrow 1 \text{ когда } i\text{-й синапс получает спайк}; \quad (1)$$

если $\sum w_i v_i = 1 + h$, нейрон генерирует спайк: $h \leftarrow h + 1, v_i \leftarrow 0$.

Мы видим, что изменение мембранного потенциала при получении синапсом i спайка меньше, чем w_i , если этот же синапс короткое время назад уже получал спайк.

В этой работе считаем все синапсы непластичными.

Сеть

Рассматривается полностью однородная и хаотическая ИНС, состоящая из возбуждающих и тормозящих нейронов. Их доли всегда соответствуют отношению 10:3. Все возбуждающие (E) и тормозящие (I) нейроны имеют одинаковые параметры. Таким образом, имеется 4 вида синапсов: $E \rightarrow E, E \rightarrow I, I \rightarrow E, I \rightarrow I$. Все возбуждающие нейроны имеют одинаковые количества EE и IE синапсов. Это же верно и для тормозящих нейронов. Все синапсы одного типа имеют одинаковый вес.

Синаптические задержки являются случайными величинами, распределенными логнормально со стандартным отклонением логарифма, рав-

ным 1. Возбуждающие связи – более медленные (средняя задержка 5 мс), чем тормозящие (средняя задержка 1,5 мс), что наблюдается и в живом мозге. Множество пресинаптических нейронов выбирается абсолютно случайно для всех нейронов сети. Таким образом, сеть характеризуется 12 параметрами: временными константами $\tau_{hE}, \tau_{hI}, \tau_{vE}, \tau_{vI}$, количествами синапсов $n_{EE}, n_{EI}, n_{IE}, n_{II}$ и синаптическими весами $w_{EE}, w_{EI}, w_{IE}, w_{II}$.

Рассматривается ситуация, когда ИНС получает чисто случайный внешний сигнал. Его источником являются *входные узлы* сети, испускающие спайки с некоторой постоянной средней частотой, одинаковой для всех входных узлов. Возбуждающие нейроны соединены со случайно выбираемыми множествами входных узлов через возбуждающие синапсы (мы будем их называть афферентными синапсами). Количество афферентных синапсов было равно 30 во всех экспериментах.

Цель – избегание негативных сценариев

Во Введении было упомянуто о трех типах нежелательной активности сети. Наша задача – найти условия на значения ее параметров, при которых эти сценарии станут невозможными или, по крайней мере, маловероятными.

Избегание первого из них (полного «молчания» сети) не вызывает проблем – это просто вопрос достаточной силы стимуляции сети, так что, рассмотрим второе. Мы изучаем выполнение даже более сильного условия – а именно, требуем, чтобы реакция сети на любой стимул после его окончания либо полностью затухала, либо возвращалась к некоторой небольшой фоновой активности. Проверка этого условия выглядела следующим образом. После периода стимуляции сети внешний сигнал отключался, и активность сети измерялась на протяжении длительного времени. Если средняя частота спайков в этот период не превышала 30 Нз (для стимуляции любой силы), то сеть признавалась принадлежащей к классу S^+ («хорошей»). Иначе, ее относили к классу S^- .

Для идентификации мощных осцилляций, подавляющих любую другую активность сети, использовался параметр, который далее будет именоваться Относительная Сила Осцилляций – ОСО. Он вычислялся следующим образом:

1. Для каждого дискретного шага времени t эксперимента фиксируется количество испущенных спайков $F(t)$.
2. Для $F(t)$ вычисляется автокорреляционная функция $A(t)$.

3. Пусть T – наименьшее значение t , для которого $A(t)$ становится от-
рицательной. Обозначим T_{OSC} точку максимума $A(t)$ на (T, ∞) .

4. Допустим, полное время эксперимента равно nT_{OSC} , где n – целое
число. Вычислим значения $C(t) = \sum_{i=1}^n F(t + iT_{OSC})$ для $0 < t < T_{OSC}$.

5. Разобьем интервал $(0, T_{OSC})$ на 10 равных отрезков, для каждого из
которых вычислим среднее значение $C(t)$. Если наименьшее среди этих
значений c_{min} , наибольшее – c_{max} , то $OSO = (c_{max} - c_{min}) / c_{max}$.

Итак, требуется решить две задачи: оценить условную вероятность
 $P(A|S^+)$, что при данном векторе входных параметров A сеть принадлежит
 S^+ , и предсказать значение OSO .

Основная серия экспериментов

Основная серия экспериментов проводилась с ИНС, состоящими из
1000 возбуждающих нейронов и 300 тормозящих. Входные параметры
варьировались в следующих пределах: 3 – 100 мс – для всех временных
констант, 10 – 300 – для количества возбуждающих синапсов, 3 – 100 –
для количества тормозящих синапсов, 0,03 – 0,3 – для весов возбуждаю-
щих синапсов, 0,1 – 10 – для весов тормозящих синапсов. Интенсивность
стимуляции и веса афферентных синапсов выбирались так, чтобы средняя
частота генерации спайков для изолированного нейрона лежала в диапа-
зоне 2 – 300 Hz.

Серия включала 202332 экспериментов. Были протестированы 27572
комбинации параметров сети при разных величинах силы стимуляции.

Построение эмпирических моделей

1. *Классификация на S^+ и S^-* . Итак, обучающая выборка была представ-
лена 27572 векторами параметров ИНС, 9255 из которых принадлежали к
 S^- . Поскольку результат очевидно должен зависеть от общего уровня воз-
буждения и торможения в сети, вычислялись отражающие их производ-
ные параметры $s_{AB} = n_{AB} w_{AB}$, где A и B принадлежат к $\{E, I\}$.

В результате предварительных проб было обнаружено, что наилучшие
результаты достигаются одним из наиболее популярных алгоритмов data
mining, деревьями решений (проверялись только те методы, которые
представляют результат в явной аналитической форме, – поэтому такие
методы, как машины опорных векторов или нейронные сети, не использо-
вались). Получившаяся древовидная классификационная модель дает
7,21 % ошибку. Важно, что дерево решений может быть использовано для

оценки $P(A|S^-)$. Примеры ее зависимости от силы положительной обратной связи в сети для 3 разных комбинаций других параметров показаны на рис. 1. Хорошее качество модели иллюстрируется резким переходом этой вероятности от 0 к 1.

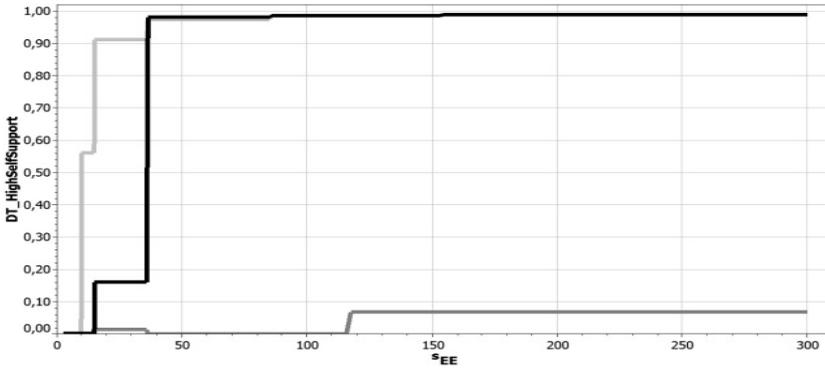


Рис. 1. Примеры зависимости $P(A|S^-)$ от силы положительной обратной связи в сети для 3 различных комбинации других параметров

Полученная модель может быть представлена в символической форме и в виде программы на языке С. Более того, использованная реализация алгоритма деревьев решений оценивает относительное влияние разных параметров сети на результат классификации. Оно представлено в форме гистограммы на рис. 2.

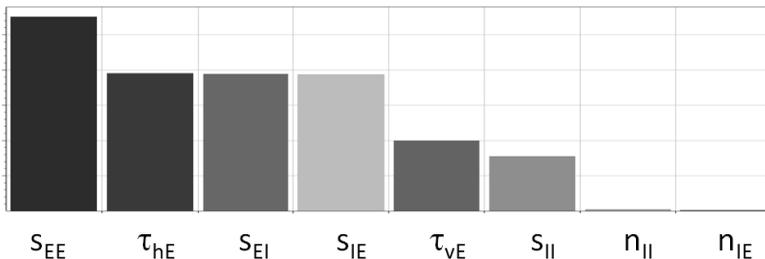


Рис. 2. Относительная важность различных параметров сети для ее отнесения к классам S^- и S^+

2. *Прогноз значения ОСО.* На этот раз были использованы алгоритмы data mining, находящие числовые зависимости в явной символической форме. Лучшим среди таких алгоритмов оказался алгоритм множественных адаптивных регрессионных сплайнов (МАРС) [9]. Этот метод ищет зависимости в форме кусочно-непрерывных полиномов. Стандартное отклонение найденной модели, равное 0,28 ($R^2 = 0,45$), не выглядит очень впечатляющим, однако на деле она оказывается весьма полезной. Например, малое значение прогнозируемой ОСО ($< 0,1$) гарантирует с очень высокой вероятностью, что график частоты спайков не показывает сильных осцилляций. Как и дерево решений, этот алгоритм оценивает относительный вклад отдельных предикторов. Он показан на рис. 3. Примеры зависимости ОСО от главного фактора, τ_{HE} , для разных комбинаций значений других предикторов показаны на рис. 4.

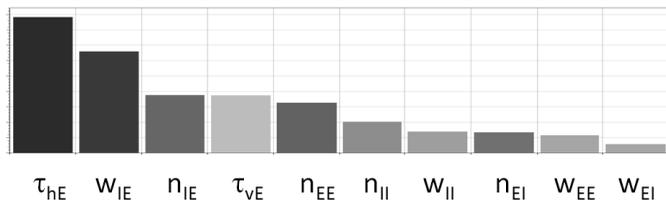


Рис. 3. Относительный вклад параметров сети в вариацию предсказанных значений ОСО

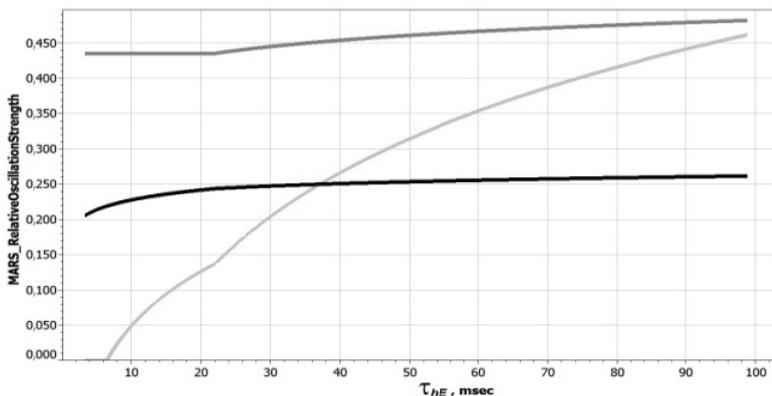


Рис. 4. Примеры зависимости значений ОСО от τ_{HE} для различных комбинаций других параметров сети

Проверка масштабируемости

Так как найденные модели не содержат в явном виде величин, напрямую зависящих от размера сети, есть основания надеяться, что они могут применяться и для гораздо больших сетей.

Как практический критерий для отнесения ИНС к S^+ использовалось правило, что предсказанное значение $P(A|S^+)$ не должно превышать 0,3. Для небольших сетей (1300 нейронов) оно дает примерно 3 % ошибок. Это правило было протестировано на 152 в 10 раз больших сетях. Неожиданным оказалось то, что ни одна из сетей, удовлетворяющих этому критерию, не принадлежала S^+ .

Схожая ситуация была и с предсказанием значений ОСО. Из практического использования этого параметра следует, что критическим значением для него является 0,3. Для небольших сетей 15 % комбинаций входных параметров с прогнозируемым значением ОСО, меньшим 0,3, показывают реальное значение ОСО, большее 0,3. В то же время, для больших сетей эта ошибка падает до 10,5 %.

Хотя проведенные тесты возможно недостаточны, они все же свидетельствуют, что эмпирические модели, полученные на небольших сетях, вполне могут быть применены и к сетям существенно большего размера. Более того, на больших по размеру сетях эти модели могут даже оказаться более точными – по всей видимости, вследствие меньшей относительной величины статистических флуктуаций.

Выводы

В данной работе мне бы хотелось обратить внимание исследователей ИНС на важность эмпирических моделей как методологии изучения ИНС и построения ИНС с заданными свойствами. Этот подход является практичной альтернативой теоретическому анализу, основанному на уравнениях среднего поля, часто предполагающему работу со сложными интегро-дифференциальными уравнениями. Привлекательность предложенной методологии особенно очевидна в случаях, когда необходимо анализировать или строить разнообразные ИНС в сочетании с меняющимися свойствами входного сигнала.

В работе обсуждалась типовая стратегия применения этой методологии на простом и в то же время важном с научной точки зрения примере. Эмпирические зависимости, обсуждаемые в данной работе, были получены алгоритмами data mining, реализованными в системе PolyAnalyst™ производства компании Megaputer Intelligence Ltd.

Список литературы

1. Gerstner W., Kistler W. Spiking Neuron Models. Single Neurons, Populations, Plasticity. Cambridge University Press, 2002.
2. Baladron J., Fiaschi D., Faugetas O., and Touboul J. Mean-field description and propagation of chaos in networks of Hodgkin-Huxley and FitzHugh-Nagumo neurons // J. of Mathematical Neuroscience, 2012. V. 2. No. 10. doi:10.1186/2190-8567-2-10.
3. Touboul J., Ermentrout G. Finite-size and correlation-induced effects in mean-field dynamics // J. of Computational Neuroscience, 2011. V. 31. No. 3. P. 453-484. DOI:10.1007/s10827-011-0320-5.
4. Izhikevich E. Polychronization: Computation With Spikes // Neural Computation, 2006. V. 18 P. 245-282.
5. Benda J., Maler L., Longtin A. Linear versus nonlinear signal transmission in neuron models with adaptation currents or dynamic thresholds // J. of Neurophysiology. 2010. V. 104. P. 2806-2820.
6. Rosenbaum R., Rubin J., Doiron B. Short Term Synaptic Depression Imposes a Frequency Dependent Filter on Synaptic Information Transfer // PLoS Comput Biol., 2012. V. 8. N. 6. e1002557. doi:10.1371/journal.pcbi.1002557.
7. Kiselev M. Self-organized Spiking Neural Network Recognizing Phase/Frequency Correlations // Proceedings of IJCNN'2009, Atlanta, Georgia, 2009. P. 1633-1639.
8. Kiselev M. Self-organized Short-Term Memory Mechanism in Spiking Neural Network // Proceedings of ICANN'2011 Part I, Ljubljana. P. 120-129.
9. Friedman J. Multivariate Adaptive Regression Splines // Annals of Statistics, 1991. V. 19. N. 1. P. 1-141.

Стендовая сессия 6

Адаптивное поведение и эволюционное моделирование

С.В. АНФИЛЕЦ, В.Н. ШУТЬ

Брестский государственный технический университет, Беларусь
anfilets_sv@mail.ru, lucking@mail.ru

ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННЫХ ИММУННЫХ СИСТЕМ ДЛЯ ОПТИМИЗАЦИИ УПРАВЛЕНИЯ СВЕТОФОРНЫМ ЦИКЛОМ

Рассматривается задача адаптивного управления на светофорном объекте. Метод управления основывается на расчете длин фаз для цикла регулирования. Для расчета используются прогнозируемые значения интенсивностей транспортных потоков на перекрестке и алгоритм искусственных иммунных систем.

Ключевые слова: *искусственные иммунные системы, адаптивное управление, светофорное регулирование.*

S.V. ANFILETS, V.N. SHUTS

Brest State Technical University, Belarus
anfilets_sv@mail.ru, lucking@mail.ru

THE USE OF ARTIFICIAL IMMUNE SYSTEM TO OPTIMIZE THE MANAGEMENT OF TRAFFIC LIGHTS CYCLE

The focus of this article is the problem of adaptive control at traffic light object. Control method is based on calculating the length of the cycle phases. Used method for the calculation phases based on the predicted values of traffic at the intersection and algorithm of artificial immune systems.

Keywords: *artificial immune systems, adaptive control, traffic light control.*

Введение

Искусственная иммунная система (ИИС) – это адаптивная вычислительная система, использующая модели, принципы, механизмы и функции, описанные в теоретической иммунологии, которые применяются для решения прикладных задач [1]. Искусственная иммунная система относится к классу автоматизированных вычислительных интеллектуальных систем, использующих принципы иммунной системы позвоночных [2].

Несмотря на то, что природные иммунные системы все ещё не полностью изучены, на сегодня существуют как минимум три теории, объясняющие функционирование иммунной системы и описывают взаимодействие ее элементов, а именно: теория отрицательного отбора, теория клональной селекции и теория иммунной сети. Они легли в основу создания трех алгоритмов функционирования ИИС. Сфера применения ИИС включает такие области (но не ограничивается ими): методы вычислений, когнитивные модели, обнаружения аномалий и неполадок, мультиагентные системы, модели самоорганизации, модели коллективного интеллекта, системы поиска и оптимизации, модели автономных распределенных систем, модели искусственной жизни, системы компьютерной безопасности, методы получения информации, обработка сигналов и изображений.

Методы ИИС используют специфические иммунологические теории, объясняющие функции и поведение адаптивной иммунной системы млекопитающих.

Подобно искусственным нейронным сетям, ИИС могут накапливать новую информацию и, используя предварительно изученную информацию, осуществлять распознавание образов децентрализованным способом. Иммунная система выполняет несколько функций. Вместе с другими системами организма она поддерживает устойчивое состояние жизненных функций, названный гомеостазом.

Рассматривая вычислительные аспекты парадигмы иммунных систем, можно выделить следующие элементы иммунных алгоритмов: множество способов представления компонентов системы, множество механизмов, позволяющих оценить взаимодействие индивидуумов с окружающей средой и друг с другом, процедуры адаптации, которые управляют динамикой системы.

Постановка задачи и описание алгоритма

ИИС осуществляет целенаправленный поиск локального экстремума, сочетается с возможностью поиска глобального экстремума. Метод нахо-

ждения оптимального решения базируется на использовании операторов клонального отбора, мутации и негативной селекции. Каждое из антител оценивается мерой пригодности согласно тому, насколько “хорошо” соответствующее ей решение задачи. Наиболее подходящие антитела получают возможность “воспроизводить” потомство с помощью гипермутации. Это приводит к появлению новых антител, которые в процессе гипермутации улучшают своё соответствие целевой функции. Антитела с худшей аффинностью замещаются случайно сгенерированными антителами, равномерно распределенными по всей области определения целевой функции, что позволяет не замыкаться на локальных экстремумах, а исследовать все пространство области определения целевой функции. Таким образом, происходит итеративный процесс воспроизведения новых популяций из лучших представителей предыдущего поколения. Каждое новое поколение содержит более высокое соотношение характеристик, которыми обладают лучшие члены предыдущих поколений.

Основные шаги алгоритма сводятся к следующей последовательности.

1. Сгенерировать начальную популяцию антител – P , $t = 0$.
2. Для каждого i -го ($i = 1, N$) антитела определить направления мутации и вычислить аффинность – $\Phi(q)$.
3. Упорядочить антитела популяции P по значению $\Phi(q)$ в возрастающем порядке.
4. Отобрать для клонирования k антител с самой низкой аффинностью
5. Получить популяцию измененных клонов с помощью механизма мутации. Для каждого параметра x_i , будем оценивать два значения Δq_{ji} при $x_i = x_i + hi$ и $x_i = x_i - hi$ для всех $j = 1, n$: $\Delta q_{ji} = \sum_j q_{ji} t+1 - \sum_j q_{jit}$. Из двух значений x_i выбираем то, для которого $\Phi(q)$ min. В результате применения данной процедуры ко всем x_i , для которых улучшено значение аффинности, будут выбраны направления hi мутации антитела и вычислено значение аффинности $\Phi(q)$ на t -й итерации. Соответствующие признаки pi устанавливаются в единицу – $pi = 1$. Признак стимулируемости антитела становится равным $\text{Aff} = \sum_i pi$.
6. Заменить в исходной популяции антитело новым клоном. Сформировать второй клон путем изменения параметров x_i , по которым получено улучшение аффинности по правилу: $x_i = x_i + hi/2$. Вычислить аффинность клона. Добавить данный клон в популяцию клонов C . Повторить пункты 5,6 алгоритма для всех k антител.
7. Объединить исходную измененную и сформированную популяцию клонов: $P = P \cup C$. Выполнить упорядочивание популяции, аналогично пункту 3 алгоритма.

8. Проверить условия окончания алгоритма: $t + 1 = T$. Если достигнуто максимальное число эпох, то завершаем работу алгоритма, иначе переход на пункт 9.

9. Выполнить операцию негативной селекции. Удалить из популяции нестимулируемые антитела, у которых значение $\text{Aff} = 0$. Если множество P оказалось пустым, то перейти на пункт 1 алгоритма. Иначе – пусть число оставшихся антител будет kc . Если $kc > N$, то удалить из популяции антитела с худшей аффинностью и заменить d худших новыми сгенерированными антителами. В противном случае обновить d худших антител. Выполнить пункт 2 для вновь сгенерированных антител, чтобы определить их аффинность.

10. $t = t + 1$, переход на п.3 алгоритма.

Для задачи адаптивного регулирования на перекрестке необходимо рассчитать такие длительности фаз в цикле, при которых минимизируется средняя задержка транспорта. Для расчета задержки на перекрестке в одном направлении применяют формулу Вебстера (1):

$$e = 0.45 \cdot \left(\frac{C \cdot (1 - \lambda^2)}{1 - \lambda x} + \frac{x^2}{q_i \cdot (1 - x)} \right), \text{ с/авт.}, \quad (1)$$

где C – продолжительность светофорного цикла, с; λ – доля зеленого сигнала для данного направления в цикле; q_i – интенсивность движения в данном направлении, авт./с; x – коэффициент загрузки полосы движением.

Как видно из формулы расчета, средняя задержка зависит от длительностей разрешающих сигналов и интенсивностей потока. Продолжительность цикла равна сумме разрешающих сигналов и переходных интервалов. Доля зеленого сигнала равна отношению разрешающего сигнала в одном направлении к длительности цикла. Коэффициент загрузки полосы равен отношению текущей интенсивности к произведению доли разрешающего сигнала и пропускной способности перекрестка в данном направлении движения. Таким образом, задача оптимизации светофорного цикла выглядит как (2):

$$f = \sum e_i(t_{zi}, q_i) \rightarrow \min. \quad (2)$$

Минимизируемая функция равна сумме средних задержек по каждому из направлений, для расчета которых нужно знать интенсивность входных потоков. Для каждого из направлений можно назначить весовые коэффициенты, которые характеризуют значимость данного направления. Необходимо подобрать такой набор значений разрешающих сигналов t_{zi} , что бы выполнялось (2).

Для решения задачи оптимизации необходимо применять эффективные методы прогнозирования транспортных потоков. Для этих целей эффективно применяются нейросетевые подходы: многослойный персептрон, RBF-сети [3,4]. Для задачи адаптивного управления прогнозирование носит краткосрочный характер, например на ближайшие 15 мин. Таким образом, пересчет длительностей фаз может выполняться каждые 15 минут.

Моделирование работы алгоритма

Для проверки работы алгоритма разработана модель перекрестка, для которого можно задавать разные длительности разрешающих сигналов во время его работы. Необходимо формальное описание логики функционирования исследуемого объекта, характера взаимодействия его элементов во времени, учитывающее существенные причинно-следственные связи объекта. В области создания новых систем моделирование является одним из основных средств исследования.

Моделирование основывается на теории массового обслуживания. Перекрёсток можно представить как систему с четырьмя обслуживающими приборами и четырьмя потоками заявок. Время задержки в обслуживающих устройствах зависит от времени зелёных и красных фаз светофора, а так же времени переходного процесса. В модель вводится аналог дорожного контроллера: блок управления фазами (рис. 1). Таким образом, поступающие заявки в систему первым делом анализируют текущую фазу и в зависимости от неё либо ожидают в очереди, либо проходят далее в обслуживающее устройство. В такой модели роль обслуживающего устройства заключается в реализации задержки, вызванной прохождением перекрёстка транспортными средствами, данный параметр будет зависеть от пропускной способности перекрестка, т. е. его физических характеристик.

Именно в блоке управления фазами закладывается логика работы светофорного объекта. Если это жесткое регулирование, то задаётся количество фаз и их длительности. Если гибкое регулирование, то задаются основные параметры алгоритма. Для моделирования гибкого регулирования, основанного на искусственных иммунных системах, заносились рассчитанные длительности фаз, которые активировались в нужный момент моделирования. Интенсивности транспортного потока, спрогнозированные на 15-минутные интервалы, заданы в табл. 1. Они служат входными данными для работы адаптивного алгоритма.

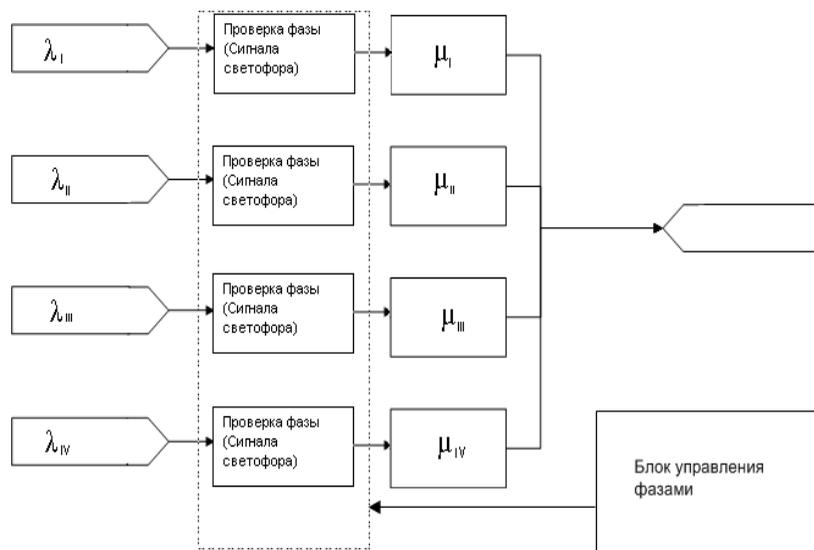


Рис.1. Схема имитационной модели

Таблица 1

Спрогнозированные интенсивности

№	Интенсивность i -го потока, 15 мин			
	1	2	3	4
1	153	89	167	131
2	147	149	169	108
3	138	162	172	115
4	158	148	154	127
5	162	158	147	139
6	148	145	143	125
7	135	124	146	112
8	169	164	151	127

Программа рассчитывает длительности разрешающих сигналов на следующий интервал. Примеры расчет длительностей фаз приведены в табл. 2. Номер фазы обозначает номер направления движения, для которого работает разрешающий сигнал. Фазы 1+3 и 2+4 означают, что разрешающий сигнал работает для двух направлений.

Моделирование проводилось для светофорного объекта с режимом регулирования с жесткими фазами и адаптивными, рассчитанными на основании прогнозируемых интенсивностей с использованием искусственных иммунных систем.

Одними из основных характеристик для оценки качества управления потоками на перекрестке являются: среднее время пребывания в очередях и среднее значение длины очереди.

Рассчитанные длительности фаз

№	Длительность i -й фазы, светофорного цикла					
	1	2	3	4	1+3	2+4
1	18	0	27	30	33	14
2	39	0	0	17	14	14
3	19	21	27	0	16	14
4	38	18	19	0	0	15
5	0	0	0	29	31	14
6	18	0	36	0	15	25
7	0	0	22	0	26	14
8	0	0	0	0	19	19

Сравнительные характеристики очередей на светофорном объекте приведены на рис. 2. Среднее время пребывания в очередях для метода управления с жесткими светофорными фазами 24 с, для адаптивного управления – 9 с. Среднее значение длин очередей для жесткого управления составило 46 единиц, для адаптивного – 24.

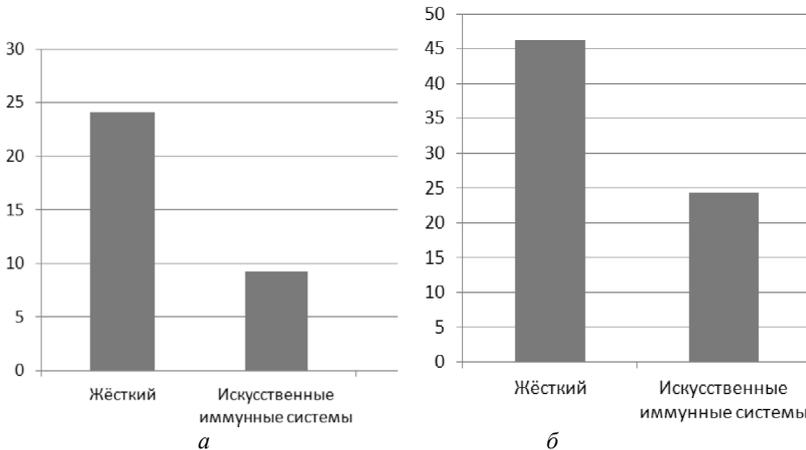


Рис. 2. Среднее время пребывания в очередях (а) и среднее значение длин очередей (б)

Выводы

Из графиков можно сделать вывод, что алгоритм искусственных иммунных значительно улучшил пропускную способность светофорного объекта с жестким режимом управления.

Среднее время пребывания в очереди на перекрестке уменьшилось на 62 % в среднем за время испытаний. Средняя длина очереди сократилась на 47 %. Алгоритм адаптивного управления показывает лучшие результаты, потому что располагает информацией об изменяющейся интенсивности. Благодаря гибкости алгоритма адаптации на основе искусственных иммунных систем в целевую функцию могут быть введены ограничения необходимые для конкретной задачи. Это может быть ограничение на длительность цикла или на максимальную длительность сигнала, или использование фиксированной длительности цикла. Дальнейшее развитие использования такого адаптивного алгоритма может лежать в поиске расчета длительностей сигналов групп перекрестков. Такая задача значительно увеличивает требования к вычислительным мощностям и поэтому предполагает использование сервера в центрах управления светофорными объектами.

Список литературы

1. De Castro L.N., Timmis J. Artificial Immune Systems //A New Computational Intelligence Approach. New York: Press. 2002. P.357.
2. Fogel D. B. Evolutionary Computation // Toward a New Philosophy of Machine Intelligence. New York: Press. 2000. P.328.
3. Jia Zheng Zhu, Jin Xio Cao, Yuan Zhu. Traffic volume forecasting based on radial function neural network with the consideration of traffic flows at the adjacent intersections // Transportation Research, Part C. 2014
4. Liang-liang Zhang, Yuan-hua Jia, Zhong-haiNiu, Hua-nan Li. Research on Short-term Traffic Flow Forecasting for Junction of Isomerism Road Network Based on Dynamic Correlation // Proceedings of 9th International Conference on Traffic & Transport Studies (ICTTS'2014). P.446-451.

**В.Г. РЕДЬКО¹, В.А. НЕПОМНЯЩИХ², Е.А. ОСИПОВА²,
Т.И. ШАРИПОВА¹, Г.А. БЕСХЛЕБНОВА¹**

¹ Научно-исследовательский институт системных исследований РАН, Москва

² Институт биологии внутренних вод им. И.Д. Папанина РАН, п. Борок,
Ярославская обл.
vcredko@gmail.com

МОДЕЛИРОВАНИЕ ФОРМИРОВАНИЯ ПРЕДСКАЗАНИЙ У РЫБ, ИЗУЧАЮЩИХ ЛАБИРИНТЫ¹

Представлен начальный этап моделирования познавательных способностей рыб, изучающих лабиринты. Построена модель формирования предсказаний рыбами. Согласно модели уверенность рыб в предсказаниях постепенно возрастает. Результаты компьютерного моделирования качественно согласуются с экспериментальными биологическими данными.

Ключевые слова: *моделирование поведения животного, исследовательское поведение, мотивация.*

**V.G. RED'KO¹, V.A. NEPOMNYASHCHIKH², E.E. OSIPOVA²,
T.I. SHARIPOVA¹, G.A. BESKHLEBNOVA¹**

¹Scientific Research Institute for System Analysis RAS, Moscow

²I.D. Papanin Institute for Biology of Inland Waters, Russian Academy of Sciences,
Borok, Yaroslavl region
vcredko@gmail.com

MODELING OF PREDICTIONS BY FISHES STUDYING LABYRINTHS

The initial stage of modeling of cognitive abilities of the fishes studying labyrinths is presented. The model of the generation of fish's predictions is constructed. According the model, fish prediction assurance increases. The results of computer simulations agree qualitatively with experimental biological data.

Keywords: *computer simulation of animal behavior, exploratory behavior, motivation.*

¹ Работа выполнена при поддержке РФФИ, проект № 13-01-00399.

Введение

В поведении животных постоянно присутствуют две противоположные тенденции, не связанные непосредственно с физиологическими потребностями. Одна из них – поиск новой, *непредсказуемой* стимуляции, выражающийся в исследовательском поведении, а другая – стремление *предсказывать* результаты своего поведения [1-3].

Постоянная мотивация к сбору информации об окружающей среде преобладает, если основные потребности (например, в пище) удовлетворены (гипотеза «уменьшения неопределенности», [4, 5]). Исследовательское поведение животного приводит в этом случае к уменьшению неопределенности. В ситуации, когда животное сильно голодно и видит пищу, исследовательское поведение отсутствует [4].

Стремление животных к предсказуемости результатов своих действий дает им возможность контролировать окружающую среду. Важная роль накопления знаний для жизни биологических организмов подчеркивается в работах А.А. Жданова [6].

Эти две тенденции (стремление и к новизне, и к предсказуемости) в поведении животных являются на первый взгляд противоречащими друг другу. Однако между новизной и предсказуемостью устанавливается определенный баланс. Представления о балансе новизны и предсказуемости в поведении животных были успешно реализованы в программах управления робота – «собаки» Aibo [7, 8].

Важно подчеркнуть, что накопление знаний при исследовательском поведении животных является предшественником развития знаний человека при его творческой поисковой активности.

В настоящей работе строится компьютерная модель предсказательной способности рыб. При моделировании учитывается то, что в поведении животных постоянно присутствуют две указанные противоположные тенденции: 1) поиск новой, непредсказуемой стимуляции и 2) стремление предсказывать результаты своего поведения. Результаты компьютерного моделирования сопоставляются с данными биологического эксперимента.

Биологический эксперимент. Поведение рыб в лабиринтах

Модель основана на биологическом эксперименте, в котором изучалось поведение рыб данио рерио в незнакомой им среде – лабиринтах двух типов: в простом крестообразном лабиринте с 4-мя коридорами (рис. 1) и в более сложном лабиринте с 11-ю коридорами (рис. 2). Подробное описание биологического эксперимента приведено в [9].

Значительная часть перемещений рыб между коридорами подчинялась простым правилам. Такие типичные перемещения мы будем называть мотивами:

1. Самый заметный мотив – повторяющиеся челночные переходы между смежными коридорами, например, 12121212 или 141414...

2. Менее частый мотив – повторяющиеся челночные переходы между противоположными коридорами: 131313 и 242424.

3. Изредка наблюдались последовательные переходы из одного коридора в другой смежный по часовой стрелке (1234) или в противоположном направлении (3214) и переходы с «возвратом», например, 12321 или 14341.

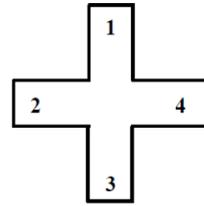


Рис. 1. Крестообразный лабиринт

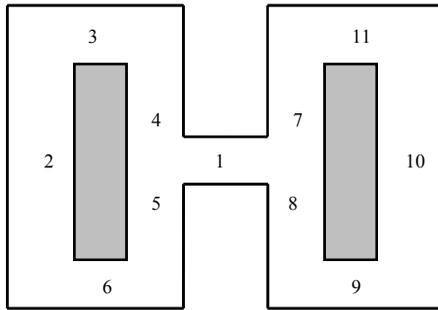


Рис. 2. Лабиринт с 11-ю коридорами. Серым показаны непрозрачные барьеры внутри левого и правого отсеков

Кроме мотивов, у рыб наблюдаются и такие последовательности посещения коридоров, которые не подчиняются каким-либо явным правилам, например, 231421. Характерный пример последовательности посещаемых рыбой коридоров:

2121212121232323422323232313232323232132312313412341234123423232
32323132143141214121212341212121212313212121234123432424242413
131312424243121324121412312.

Подчеркнуты цепочки, соответствующие указанным мотивам.

В лабиринте с 11-ю коридорами (см.рис. 2) рыбы были такими же (с теми же размерами), как и в случае крестообразного лабиринта. Описание лабиринта, а также характерные упорядоченные движения рыб можно

найти в [9]. Результаты первых исследований рыб в лабиринте с 11-ю коридорами показали, что значительная часть передвижений рыб не была случайной. В поведении рыб наблюдались упорядоченные передвижения, подчиняющиеся определенным правилам. При этом рыба могла постоянно игнорировать один и тот же внешний ориентир (вход в коридор 1) и проходить мимо него при выполнении одной последовательности, но регулярно реагировать на него же и входить в этот коридор при выполнении другой последовательности.

Помимо упорядоченных передвижений наблюдались и разнообразные передвижения между коридорами, не подчиняющиеся явно каким-либо правилам, например, 6518987...

Подчеркнем, что крестообразный лабиринт и лабиринт с 11-ю коридорами существенно различаются: все коридоры в крестообразном лабиринте видны рыбе после первого ее появления в центре, а коридоры в лабиринте, представленном на рис. 2, заранее рыбе неизвестны.

В настоящей работе построена и исследована модель для простого крестообразного лабиринта и намечены подходы для построения модели для лабиринта с 11 коридорами.

Модель предсказаний для движения рыб по крестообразному лабиринту

Была построена компьютерная модель, в которой рассчитывалась уверенность агентов (модельных рыб) в предсказаниях будущих ситуаций. Уверенность характеризовалась величиной, меняющейся от 0 до 1. Время в модели дискретно: $t = 0, 1, 2, \dots$. Модель строилась для простого случая крестообразного лабиринта (рис. 1). Модель предполагала, что имеются исходные ситуации S_t (каждая ситуация соответствует коридору, в котором агент находится, число различных ситуаций равно числу коридоров и равно 4). В каждой ситуации агент может выполнять три действия A_t : при выходе из коридора, агент может 1) повернуть в правый коридор, 2) пройти в противоположный коридор, 3) повернуть в левый коридор. Отметим, что рыбы так редко возвращаются в коридор, из которого только что вышли, что этим действием в модели пренебрегаем. При выполнении действия агент предсказывает, в какой ситуации S_{t+1} он дальше окажется (таких новых ситуаций 4). В некоторой степени это предсказание подобно формированию простого акцептора результата действия в теории функциональных систем П.К. Анохина.

Далее агент определяет, сбылось ли его предсказание. Если предсказание сбылось, то уверенность в данном предсказании увеличивается, если

предсказание не сбылось, то такая уверенность уменьшается. Таким образом, формируются уверенности в предсказании конечного элемента цепочки $\{S_t, A_t\} \rightarrow S_{t+1}$. Конечно, в данном простом лабиринте рыбе почти нечего предсказывать, тем не менее, она не уверена до конца, что в том коридоре, в котором она уже несколько раз побывала, не появилось чего-либо нового. Поэтому компьютерная модель содержит естественную динамику уверенностей предсказания.

В модели была введена следующая эвристика. Предполагалось, что когда уверенность агента в текущем предсказании мала (меньше определенного порога Th), агент стремится повторить только что пройденный маршрут, т.е. агент из того коридора, в котором он в данный момент времени t находится, возвращается в тот коридор, в котором он был в предыдущий момент $t-1$. А если уверенность агента в текущем предсказании больше порога Th , то агент совершает случайное действие, для которого уверенность агента в предсказываемом результате, как правило, невелика.

Данная эвристика соответствует отмеченным выше двум противоположным тенденциям: 1) стремлению предсказывать результаты своего поведения (при этом уверенности при правильном предсказании усиливаются), и 2) поиску новой, непредсказуемой ситуации (что соответствует выполнению случайного действия при достижении высокой текущей уверенности).

Множество уверенностей для всех возможных цепочек $\{S_t, A_t\} \rightarrow S_{t+1}$ запоминалось агентом. Кроме того, считалось, что уверенности в предсказании ожидаемого результата для всех цепочек $\{S_t, A_t\} \rightarrow S_{t+1}$ все время немного уменьшаются.

Также предполагалось, что когда агент делает предсказание для данного канала и действия, он предсказывает ожидаемый результат действия в соответствии с имеющимися у него уверенностями такого предсказания: для уверенностей, близких к 1, он однозначно предсказывает результат, а для малых уверенностей, он предсказывает результат вероятно.

Основные параметры расчета в компьютерной модели были таковы: типичное увеличение/уменьшение уверенности при правильном/неправильном предсказании составляло 0.3, порог Th , с которым сравнивается уверенность предсказания, равен 0.9, характерное время уменьшения всех уверенностей составляло 200 тактов времени.

Характерный пример последовательности посещаемых агентом коридоров таков:

43434342424341414121212124341313131312123232323232313123234343
43131312123243434313141414142424242421212121313131314143434343
23232323212121232323.

Как и для реальных рыб (см. изложение результатов биологического эксперимента выше), подчеркнуты цепочки, соответствующие отмеченным выше мотивам. Видно, что последовательности посещаемых коридоров для модельных агентов и для реальных рыб аналогичны друг другу. Для агентов не встречаются только редкие для рыб цепочки движения «по кругу», такие как 1234. По-видимому, этот редко встречающийся у рыб мотив можно учесть и для агентов, вводя дополнительную эвристику, специфичную для ряда животных: преимущественное перемещение вдоль выбранной стенки.

В компьютерной модели несложно проследить динамику суммарной уверенности агента A_S в предсказании для всего лабиринта, суммируя уверенность для всех возможных цепочек $\{S_t, A_t\} \rightarrow S_{t+1}$. Зависимость от времени t суммарной уверенности в предсказаниях для всего лабиринта показана на рис. 3. В начале расчета уверенность для всех возможных предсказаний агента была равна 0. В дальнейшем уверенность растет. Для каждого коридора и каждого действия только одно предсказание будущей ситуации является правильным. Поэтому максимально возможное число правильных предсказаний равно суммарной уверенности для всего лабиринта. С учетом числа коридоров и действий для всех возможных цепочек $\{S_t, A_t\} \rightarrow S_{t+1}$ это число равно $4*3 = 12$. Это максимально возможное значение суммарной уверенности в предсказаниях не достигается из-за того, что все уверенности постоянно немного уменьшаются. После достижения определенного уровня суммарная уверенность выходит на насыщение и случайно колеблется (рис. 3).

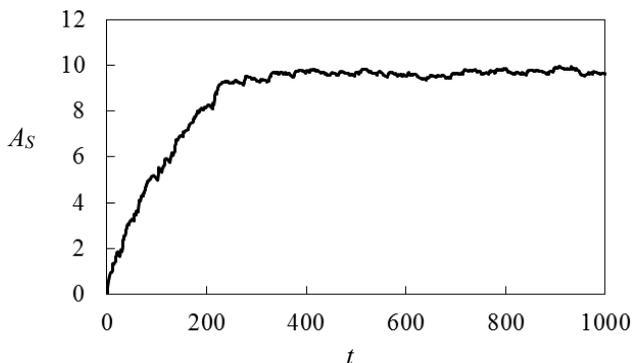


Рис. 3. Зависимость суммарной уверенности агента в предсказаниях для всего лабиринта от времени

Результаты компьютерной модели качественно согласуются с экспериментальными биологическими данными: качественно подобны последовательности посещаемых коридоров и цепочки, соответствующие мотивам перемещения по смежным коридорам и перемещения по противоположным коридорам. Также зависимость суммарной уверенности агента в предсказаниях для всего лабиринта от времени согласуется с представлением о том, какой должна быть эта зависимость у рыб.

Таким образом, построена модель усовершенствования уверенностей рыб в будущих событиях для крестообразного лабиринта. Для лабиринта с 11-ю коридорами также можно построить аналогичную модель следующим образом.

Считаем, что имеется две стадии познания лабиринта. На первой стадии агенты (модельные рыбы) познают общие черты лабиринта, при этом знания обо всех проходимых ими коридорах увеличиваются. Такой процесс накопления знаний обо всех коридорах моделировался в нашей предыдущей работе [9]. В результате первой стадии агент знает достаточно обо всех коридорах.

На второй стадии для текущей ситуации и текущего действия агента формируются предсказания в будущих ситуациях, аналогично тому, как это происходит в изложенной выше модели для крестообразного лабиринта. Ситуации при этом соответствуют коридору, в котором агент находится, и той развилке коридора, в которой расположен в текущий такт времени. Например, агент может находиться в самой верхней точке коридора 2 или в самой правой точке коридора 1 (в последнем случае агент может дальше переместиться в коридоры 7 или 8). То есть, число возможных ситуаций S_t возрастает по сравнению с крестообразным лабиринтом. А действия A_t остаются такими же: пойти направо/налево или пойти прямо. В итоге агент должен формировать уверенности в предсказании конечных элементов цепочек: $\{S_t, A_t\} \rightarrow S_{t+1}$.

Существенное различие для двух лабиринтов – крестообразного лабиринта и лабиринта с 11-ю коридорами – состоит в том, что в крестообразном лабиринте рыбы с самого начала, зайдя в центр лабиринта, могут видеть все коридоры. А для лабиринта с 11-ю коридорами рыбы должны предварительно получить начальные знания обо всех коридорах – для этого и целесообразно ввести в модель первую стадию для такого более сложного лабиринта.

Заключение

Поведение рыб в крестообразном лабиринте характеризуется такими важными понятиями, как модель и предсказание. В научном познании

также формируются модели внешнего мира и делаются предсказания на основе этих моделей [10, 11]. Конечно, уверенность рыб основана на простом индуктивном обобщении опыта, а уверенность ученого в предсказаниях при построении модели (например, модели механики И. Ньютона) формируется на базе сопоставления многих фактов, концепций и теорий. И различие между творческим процессом познания природы человеком и предпосылками этих процессов у рыб огромно. Пока видны только важные общие черты этих процессов.

Список литературы

1. Непомнящих В.А. Адаптация к решению частных задач и «глобальные» цели в поведении животных // *Нейроинформатика (электронный журнал)*, 2012. Т. 6. № 1. С. 12–22.
URL: <http://www.niisi.ru/iont/ni/Journal/V6/N1/Nepomnyashchikh.pdf>
2. Непомнящих В.А. Адаптация и автономия в поведении животных // XV Всероссийская научно-техническая конференция «Нейроинформатика–2013»: Лекции по нейроинформатике. М.: НИЯУ МИФИ, 2013. С. 106–123.
3. Непомнящих В.А. Связь между автономным и адаптивным поведением у искусственных агентов и животных // *Подходы к моделированию мышления* (Под ред. Редько В.Г.). М.: УРСС, 2014. С. 9–28.
4. Inglis I.R., Langton S., Forkman B., Lazarus J. An information primacy model of exploratory and foraging behaviour // *Animal Behaviour*, 2001. V. 62. No. 3. P. 543–557.
5. Inglis I.R., Forkman B., Lazarus J. Free food or earned food: a review and fuzzy model of contrafreeloading // *Animal Behaviour*, 1997. V. 53. No. 6. P. 1171–1191.
6. Жданов А.А. Автономный искусственный интеллект. М.: Бином, 2008.
7. Oudeyer P.-Y., Kaplan F. Intelligent adaptive curiosity: a source of self-development // *Proceedings of the 4th International Workshop on Epigenetic Robotics* (Eds. Berthouze L. et al.). Lund University Cognitive Studies, 2004. V. 117. P. 127–130.
8. Oudeyer P.-Y., Kaplan F. What is intrinsic motivation? A typology of computational approaches // *Frontiers in Neurorobotics*. 2009. V. 1. Article 6. URL: <http://journal.frontiersin.org/Journal/10.3389/neuro.12.006.2007/full>
9. Непомнящих В.А., Осипова Е.А., Редько В.Г. и др. Модель навигации животных в лабиринтах. // XVI Всероссийская научно-техническая конференция «Нейроинформатика-2014» с международным участием. Сборник научных трудов. Ч. 1. М.: НИЯУ МИФИ, 2014. С. 109–117.
10. Редько В.Г. Эволюция, нейронные сети, интеллект. Модели и концепции эволюционной кибернетики. М.: УРСС, 2005.
11. Турчин В.Ф. Феномен науки. Кибернетический подход к эволюции. М.: Наука, 1993. См. также: <http://www.refal.ru/turchin/phenomenon/>

М.Н. АНОХИН

Институт сферы обслуживания и предпринимательства (филиал) ДГТУ
в г. Шахты
anohin.mihail@gmail.com

РАЗРАБОТКА НЕЙРОПОДОБНОЙ СИСТЕМЫ УПРАВЛЕНИЯ МОДЕЛЬНЫМ АГЕНТОМ В ДИНАМИЧЕСКОЙ СРЕДЕ

В статье рассматривается процесс построения и архитектурные особенности нейросетевой системы управления телом анимата, помещённого в динамическую среду. Тело анимата представляет собой сложный динамический объект с множеством степеней свободы. Каждый компонент тела сам по себе является динамическим объектом. Таким образом, рассматриваемая система управления решает две задачи: увязывает компоненты тела между собой в единую систему, а также обеспечивает базовые реакции тела анимата на внешние динамические воздействия.

Ключевые слова: *мягкие вычисления, динамическое моделирование, адаптивное поведение, генетические алгоритмы, системогенез, аниматы.*

M.N. ANOKHIN

Institute of the Service Sector and Entrepreneurship of DSTU, Shakhty
anohin.mihail@gmail.com

DEVELOPMENT OF NEURON-LIKE CONTROL SYSTEM FOR DUMMY AGENT IN A DYNAMIC ENVIRONMENT

The article discusses the process of building and architectural features of the neural network control system of the animat body placed in dynamic environment. Animat body is a complex dynamic object with many degrees of freedom. Considered control system solves two problems: links body components together into a single system and provides basic body reactions to external dynamic influences.

Keywords: *soft computing, dynamic modeling, adaptive behavior, genetic algorithms, systemogenesis, animat.*

Введение

В настоящий момент существует заметная тенденция сближения кибернетики и биологии. В результате такой конвергенции возник целый ряд междисциплинарных подходов. На сегодняшний день не все из них успели оформиться в отдельные направления. Среди них и относительно новое, которое может быть названо системогенезом, по аналогии с тем, как этот термин использовался в работе [1]. Однако в современном виде он приобретает более общее значение и включает в себя не только изучение синтеза биологических систем, но и искусственных систем, основанных на знаниях, полученных при исследовании биосистем. По существу, в современном представлении системогенез – это наука, изучающая процесс преобразования статического вида системы, при котором она существует только в виде описания (кода), к динамическому, в котором система наделена структурой и функцией и может рассматриваться как функциональная система [2].

Основным методом новой дисциплины стало компьютерное моделирование. Это объясняется двумя факторами: с одной стороны, физические системы моделирования (роботы) имеют не достаточную «гибкость», чтобы воплощать идеи авторов, с другой – существенно возросшая доступность вычислительных систем с массовым параллелизмом. Динамические модели, необходимые при изучении системогенеза, обладают внутренне присущим параллелизмом в силу однотипности поведения входящих в них компонентов, что и позволяет выполнять их эффективное моделирование на современных графических ускорителях поддерживающих технологию GPGPU [3].

При изучении системогенеза широко используются мягкие вычисления. Этот подход позволяет создавать системы более близкие по своим свойствам естественным системам. Динамические модели, дополненные мягкими системами управления, позволяют изучать широкий класс самоорганизующихся систем [4,5,6].

Изучение системогенеза тесно связано с исследованиями в области адаптивного поведения и искусственной жизни. Фактически, оно является составной частью последней, однако не исчерпывает её [7, 8].

При изучении искусственной жизни исследователь сталкивается с необходимостью разрабатывать системы управления сложными объектами с множеством степеней свободы. Поскольку биологические системы и биоподобные модели строятся на основе большого числа однотипных компонентов. Функциональность этих систем складывается из совокупной

функциональности большого числа входящих в них элементов, но не исчерпывается их суммой. Из имеющихся на сегодня методов управления, искусственные нейронные сети наиболее подходят для создания систем управления такими объектами [9, 10].

Для изучения вопросов адаптивного поведения используются модели динамических сред. В этих средах проектируются и создаются сложные системы, модельные организмы - аниматы. На сегодня актуальными для изучения остаются вопросы, связанные со всеми аспектами таких моделей: проектирования будущего анимата, изучение процессов формирования тела анимата под воздействием среды, исследования развития и деятельности системы управления анимата [11].

Целью данной работы ставилось проектирование архитектуры тела анимата, удобной для исследований системогенеза, а также создание базовой системы управления двигательным поведением анимата, которая позволит гибко надстраивать любые системы управления, обеспечивающие целеполагание и адаптацию.

Модель динамической среды

Традиционные работы по адаптивному поведению базировались на клеточных компьютерных моделях, в которых объект имел целочисленные координаты. С ростом производительности ЭВМ на смену этому классическому подходу пришли модели с более свободной координатной сеткой, в которых координаты объектов выражаются числами с плавающей точкой. Классическая плоская клеточная модель, в которой каждая клетка имеет ограниченное число соседей (рис. 1) сменилась двумерной или трёхмерной системой координат, в которой объект может быть позиционирован в непрерывной среде [2,12].

При моделировании аниматов сегодня принято использовать компьютерные модели с элементами физики мягких тел. Это новое направление в моделировании физических процессов позволяет более точно отражать физические свойства предметов, благодаря чему точность модели существенно возрастает.

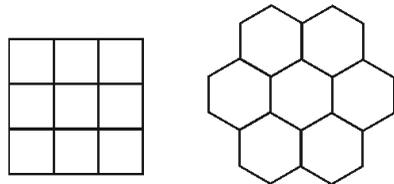


Рис. 1. Примеры решёток классических клеточных моделей

Одним из хорошо зарекомендовавших себя подходов при моделировании мягкого тела является использование в качестве базового объекта

модели круга или шара в зависимости от размерности пространства модели [2]. Такие круги принято называть клетками, поскольку в моделях аниматов они часто выполняют роль биологических клеток. Клетки обладают свойством отталкивать от себя другие клетки. Для сцепления клеток между собой используются упругие нити, как показано на рис. 2.

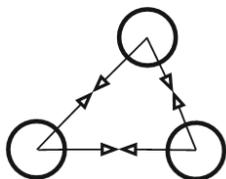


Рис. 2. Базовые примитивы динамической среды при использовании физики мягкого тела

Стрелками указаны направления сил, с которыми нити воздействуют на клетки. Таким образом, силам отталкивания, действующим между клетками, противодействуют упругие силы нитей, которые стремятся стянуть их вместе. Объединяя множество клеток с помощью нитей, можно получать тела с разнообразными свойствами, которые зависят от модельных свойств клеток и их функциональных возможностей, опреде-

ляемых алгоритмами, которые им сопоставлены.

Подобного рода модели можно считать многоагентными, поскольку каждая клетка может иметь по существу любой сценарий функционирования, от пассивного компонента физического объекта, до сложного поведения биологической клетки.

Проблема моделирования двигательного поведения в динамической среде

Существенным аспектом, который выходит на первый план, при переходе к многоагентным динамическим моделям является необходимость учёта не только функциональных особенностей агента, но и его структуры. Собранные из базовых примитивов (клеток) агенты, могут становиться составной частью более сложных агентов, например в виде органов, или особей рода. В системе возникает своего рода иерархия, в основании которой находятся базовые агенты (клетки), а на разных уровнях сложные системы, составленные из этих базовых компонентов, и имеющие целостную структуру и функцию.

На данном этапе основной интерес представляет наблюдение и изучение сложных агентов, составленных из сотен более простых. Например, это может быть агент, составленный из базовых агентов и реализующий примитивные поведенческие акты, вроде движения, питания и размножения.

Среди перечисленных видов активности движение является основополагающим поведенческим актом, и при моделировании аниматов должно являться первым этапом на пути разработки любой модели [11]. Посколь-

ку питание и размножение являются более сложными актами, базирующимися на двигательном поведении. Кроме того их рассмотрение связано с более сложными вопросами системогенеза и адаптации. Поэтому их разработка будет производиться в последующих работах. В данной работе рассматриваются только вопросы, связанные с разработкой системы двигательного поведения.

В моделях на основе клеток движение моделируется изменением упругости связей между клетками. В результате таких изменений в теле анимата возникают силы, напоминающие двигательные акты многоклеточных организмов обладающих мускулатурой.

Нейроподобная система управления аниматом в динамической среде

Двигательное поведение, реализуемое изложенным выше способом, приводит к необходимости решать задачу многомерного управления, поскольку фактическое число степеней свободы системы равно количеству соединений между клетками тела анимата.

Для решения такого рода задач могут быть эффективно применены искусственные нейронные сети. Этот вывод можно сделать просто на том основании, что их изначальный биологический прототип решает именно эту задачу.

Входными данными сети являются данные с сенсоров анимата. Эти сенсоры могут улавливать всевозможные изменения среды, а выход сети это воздействия, которые преобразуются в изменения упругости связей между клетками. Общая схема изображена на рис. 3.

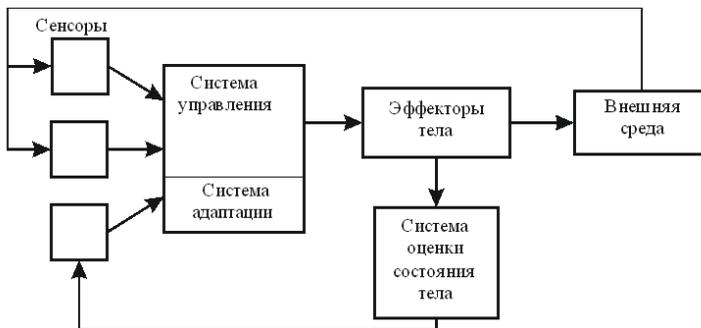


Рис. 3. Общая схема системы управления аниматом

Система управления реализуется в виде многоуровневой нейронной сети с вертикальными и горизонтальными связями между слоями. Существует целый ряд концепций нейронных сетей, позволяющих реализовывать различные иерархические структуры [10,13]. Сенсоры могут иметь различную реализацию. Внутренние сенсоры передают в систему управления информацию о состоянии тела. Тело может иметь общебиологические потребности, которые позволят формулировать функционалы для работы системы адаптации, например, голод. Кроме того к внутренним состояниям относятся состояния связей между клетками. Внешние сенсоры получают информацию об объектах, не входящих в тело анимата. Например, зрение. Этот сенсор может формировать интегрированную информацию о положении объектов в пространстве на определённом удалении от тела анимата. Внешние сенсоры более удобно реализовывать в виде функционалов, закреплённых за отдельными клетками тела.

Эффекторы преобразуют энергию на выходе специального слоя нейронной сети в энергию связей. Таким образом, благодаря сенсорам и эффекторам в системе происходит непрерывное преобразование физической энергии в энергию межнейронных взаимодействий и обратно.

Динамическая модель червеобразного анимата

На рис. 4 представлена общая структура червеобразного анимата, взятого в качестве основы для исследования систем управления. Анатомия червей хорошо известна, и они имеют простой интуитивно понятный способ передвижения. Кроме того, перистальтика характерна для многих органов, и разработка её модели облегчит в дальнейшем создание аниматов со сложной внутренней структурой включающей органы полости тела. Эти факторы обусловили выбор дождевого червя в качестве прототипа для исследуемой модели анимата.

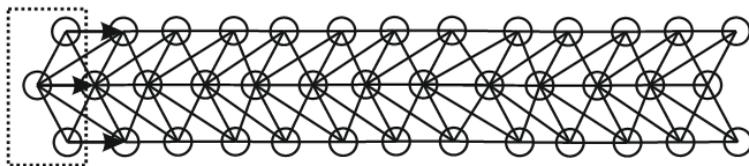


Рис. 4. Структура тела анимата

Тело анимата состоит из сегментов. Первый сегмент выделен на рисунке пунктирной рамкой. Известно, что черви передвигаются, попеременно сокращая поперечные и продольные мышцы тела. Однако в первой

разработанной модели эти сокращения моделировались только удлинением и сокращением связей между отдельными сегментами. Стрелки на рисунке показывают направление распространения сигнала по телу червя.

Каждая связь между клетками сегментов оснащена нейроном. На рис. 5 показано, как нейроны связаны между собой синапсами. Заштрихованные квадраты обозначают целевые нейроны, а не заштрихованные, соответственно, нейроны-источники сигнала.

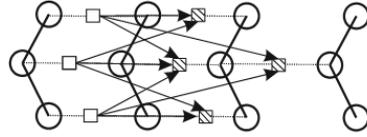


Рис. 5. Схема соединения нейронов

Каждый сегмент имеет по три нейрона. Нейроны распространяют сигнал на последующие сегменты тела. Дальность, на которую может распространяться сигнал, определяется радиусом синаптических контактов нейрона и обозначается буквой R . От него зависит плавность движения червя в пространстве. Чем на большее количество сегментов распространяется сигнал, тем более плавными и равномерными являются его движения.

В сети использовались нейроны с классической структурой: сумматор и активационная функция. В качестве активационной функции была выбрана линейная функция (рис. 6).

Алгоритм работы нейрона:

1. Рассчитывается взвешенная сумма входных значений нейрона

$$I = \sum_{j=1}^K w_j O_j,$$

где I – вход нейрона, w – это вес j -го входного синапса, O – выход нейрона связанного с нейроном через j -й синапс, K – число входных нейронов.

2. Рассчитывается максимальный возможный вход нейрона

$$I^m = \sum_{j=1}^K w_j O_j^m,$$

где I^m – максимально возможный вход нейрона, O^m – максимально возможный выход j -го связанного нейрона.

3. Рассчитывается коэффициент наклона графика активационной функции

$$k = \frac{O^m}{I^m}.$$

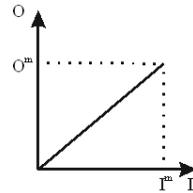


Рис. 6. Вид графика активационной функции

4. Рассчитывается выходное значение нейрона

$$O = Ik .$$

5. Активность нейрона конвертируется в силу упругости связи, между клетками которой он соответствует.

В ходе первого этапа моделирования иницирующий сигнал равномерно подавался на первые три нейрона сети. От них по сети он распространялся дальше по телу, вызывая плавные перемещения червя на небольшое расстояние в пространстве. Дальность перемещения зависела от заданной силы изменения упругости связей под воздействием активности нейронов. Однако в результате такого рода операций анимат мог двигаться только в прямом направлении. Этого было явно недостаточно. По условиям эксперимента требовалось обеспечить ему возможность перемещаться также и в продольных направлениях. Кроме того, животные в естественной среде двигаются согласно внутренним потребностям, а не по внешним командам. Поэтому анимат нуждался в возможности самостоятельно вырабатывать стимулы к движению.

Для решения этих задач на втором этапе передние нейроны были оснащены сенсорами, как показано на рис. 7, а. Структура работы сенсора показана на рис. 7, б. Сенсор обнаруживает объект в определённом радиусе и конвертирует расстояние до объекта в сигнал для нейрона. Как видно из рисунка, чем ближе объект, тем большую интенсивность сигнала он вызывает. По оси аппликат откладывается интенсивность выходного сигнала сенсора.

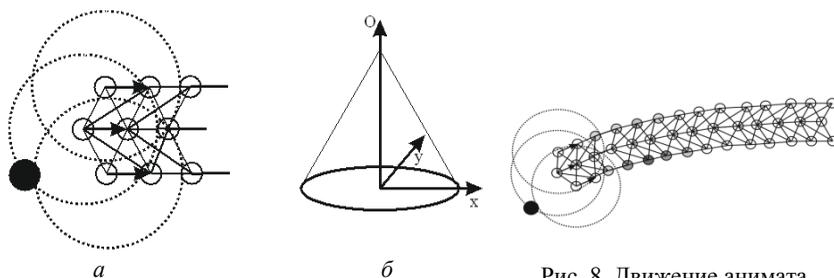


Рис. 7. Структура рецепторов анимата

Рис. 8. Движение анимата при повороте

На рис. 8 показано движение анимата при повороте к объекту. Цветом показана интенсивность воздействия нейронов на связи между клетками.

Результаты экспериментов с различными архитектурами сетей представлены в табл. 1 и 2. Из представленных данных видно, что радиус ох-

вата и распределение весов связей оказывают непосредственное влияние на скорость движения анимата. Характер этой зависимости нелинейный, однако, можно заметить, что превышение определённого порогового значения приводит к снижению скорости.

Таблица 1

Изменение скорости анимата с квадратичным законом убывания весов синапсов

Скорость движения анимата, пкс/мин	Радиус синаптических контактов нейрона	Закон распределение весов синапсов
100	3	$1-r^2/9$
130	4	$1-r^2/16$
200	5	$1-r^2/25$
150	6	$1-r^2/36$
140	7	$1-r^2/49$

Таблица 2

Изменение скорости анимата с линейным законом убывания весов синапсов

Скорость движения анимата, пкс/мин	Длина синаптических соединений нейрона	Закон распределение весов синапсов
80	3	$1-r/3$
100	4	$1-r/4$
170	5	$1-r/5$
120	6	$1-r/6$
120	7	$1-r/7$

Заключение

Предложенная в работе модель является базовой. Полученные двигательные рефлексы могут быть использованы в качестве двигательной основы для более сложной системы управления. Для этого в первую очередь будет расширена сенсорная система тела, а также определены внутренние состояния, которые позволят формировать потребности анимата для выживания. В данный момент разрабатываются модели, включающие сенсоры: растяжения и сокращения связей (для определения внешних динамических воздействий на тело), голода (для определения функций оптимальности управления). В дальнейшем планируется разработка аниматов

с более сложной архитектурой тела, включающие разные типы мышц (продольные и поперечные), сложные компоненты полости тела (органы).

Список литературы

1. Анохин П.К. Очерки по теории функциональных систем / П.К. Анохин — М.: Медицина, 1975.
2. Reneg Doursat, Carlos Sarnchez Growing Fine-Grained Multicellular Robots. SOFT ROBOTICS V. 1, Number 2, 2014.
3. Simon Green. Particle Simulation using CUDA // Лидер в области визуальных вычислений GPU и процессоры NVIDIA. 2012. URL: http://docs.nvidia.com/cuda/samples/5_Simulations/particles/doc/particles.pdf (дата обращения: 19.10.2014)
4. Murata S., Yoshida E., Kamimura A., Kurokawa H., Tomita K., Kokaji S. M-TRAN: Self-reconfigurable modular robotic system. // IEEE/ASME Trans Mechatronics 2002. 7. P. 431–441.
5. O’Grady R., Christensen AL., Dorigo M. SWARMORPH: multirobot morphogenesis using directional self-assembly. // IEEE Trans Robotics 2009. 25. P. 738–743.
6. Joachimczak M., Kowaliw T., Doursat R., Wrobel B. Evolutionary design of soft-bodied animats with decentralized control. // Artif Life Robotics, 2013. 18 P.152–160.
7. Редько В.Г. Эволюция, нейронные сети, интеллект: модели и концепции эволюционной кибернетики – 6-е изд. М.: КД «ДИБРОКОМ», 2009.
8. Жданов А. Автономный искусственный интеллект. М.: БИНОМ Лаборатория знаний, 2009.
9. Schramm L, Jin Y, Sendhoff B. Emerged coupling of motor control and morphological development in evolution of multi-cellular animats. // G Kampis et al. (Eds). Advances in Artificial Life: Darwin Meets von Neumann. Berlin: Springer-Verlag, 2011. P. 27–34.
10. Бодянский Е.В., Руденко О.Г. Искусственные нейронные сети: архитектура, обучение, применение. СПб.: Питер, 2008.
11. Амосов Н.М. и др. Автоматы и разумное поведение. Киев: Наукова думка, 1973.
12. Rafler S. Generalization of Conway's "Game of Life" to a continuous domain – SmoothLife // Cornell University. 2011. URL: <http://arxiv.org/pdf/1111.1567v2.pdf> (дата обращения: 19.10.2014)
13. Dileep George. Towards a Mathematical Theory of Cortical Micro-circuits // PLOS Computational Biology. 2009. URL: <http://www.ploscompbiol.org/article/info%3Adoi%2F10.1371%2Fjournal.pcbi.1000532#abstract0> (дата обращения: 19.10.2014).

Секция 6

Нейробиология

В.В. КОЗУНОВ¹, А.Е. ОСАДЧИЙ²

¹Центр нейрокогнитивных исследований Московского городского психолого-педагогического университета (МЭГ-Центр)

²Национальный исследовательский университет
«Высшая школа экономики», Москва
kozunov.vladimir@gmail.com

GALA: НОВЫЙ ПОДХОД К РЕШЕНИЮ ОБРАТНОЙ ЗАДАЧИ В РАМКАХ ГРУППОВОГО ИССЛЕДОВАТЕЛЬСКОГО АНАЛИЗА МЭГ ДАННЫХ*

Предлагается новый подход к решению обратной задачи Group Analysis Leads to Accuracy (GALA) в рамках эксплоративного анализа МЭГ данных, полученных на группе испытуемых. Делается предположение, что различия в ответах на уровне сенсоров у разных испытуемых в первую очередь вызваны индивидуальными вариациями геометрии коры и положений относительно сенсоров при записи данных, активации же коры у всех испытуемых в значительной мере сходны. Это позволяет снизить присущую обратной задаче неопределенность и повысить точность нахождения как локализации, так и временного поведения ответов мозга.

Ключевые слова: *МЭГ, обратная задача, число эффективных сенсоров, структура ковариации, максимизация правдоподобия.*

* Работа выполнена при поддержке гранта РГНФ № 14-06-00086 на базе УНУ "МЭГ-центр" МГППУ, финансируемой Минобрнауки России РФ (уникальный идентификатор RFMEF161914X0006).

V.V. KOZUNOV¹, A.E. OSSADTCHI²

¹Neurocognitive Research Center (MEG Center), Moscow

²National Research University «Higher School of Economics», Moscow
kozunov.vladimir@gmail.com

GALA: GROUP ANALYSIS LEADS TO ACCURACY, A NOVEL APPROACH FOR SOLVING THE INVERSE PROBLEM IN EXPLORATORY ANALYSIS OF GROUP MEG RECORDINGS

Although MEG/EEG signals are highly variable between subjects, they allow characterizing systematic changes of cortical activity in both space and time. Traditionally, to discover sources of such activity a two-step procedure is used. The first step is a transition from sensor to source space by the means of solving an ill-posed inverse problem for each subject individually. The second step is mapping of cortical regions consistently active across subjects. In practice, however, the first step often leads to a set of active cortical regions whose location and activation timecourses display a great amount of interindividual variability hindering the subsequent group analysis. Here we propose Group Analysis Leads to Accuracy (GALA) - a solution that combines the two basic steps into one. In contrast to many other methods GALA takes advantage of individual variations of cortical geometry and sensor locations. Our method exploits the ensuing variability in electromagnetic forward model as a source of additional information. We assume that for different subjects functionally identical cortical regions are located in close proximity and partially overlap and their time courses are correlated (but not identical). This relaxed similarity constraint on the inverse solution can be expressed within a solid probabilistic framework, allowing the development of an algorithm to solve the inverse problem jointly for all subjects.

Keywords: *MEG, inverse problem, group analysis, effective sensor number, covariance model, maximum likelihood.*

Введение

В настоящее время магнитная энцефалография (МЭГ) является одним из самых плодотворных методов нейровизуализации, используемых для изучения когнитивных процессов в мозге человека. Наряду с электроэнцефалографией (ЭЭГ) МЭГ обладает высоким временным разрешением, необходимым для непосредственной регистрации нейронных процессов в реальном масштабе времени. При этом ткани головы человека представляют для магнитного поля более однородную среду, чем для электрического, а зна-

чит, вычисление магнитного поля требует более простой прямой модели, чем для вычисления электрического потенциала [1]. Как результат, МЭГ потенциально позволяет добиваться более точной локализации источников кортикальной активности, чем ЭЭГ.

Между тем, измерения в энцефалографии производятся за пределами коры головного мозга, и искомая активность участков коры должна быть найдена в процессе решения обратной задачи. Этот факт определяет основные проблемы, с которыми сталкиваются исследователи при использовании МЭГ. Наиболее очевидной проблемой является непосредственно локализация участков коры, активность которых порождает измеряемые магнитные поля. Однако существует и вторая проблема, неразрывным образом связанная с первой, но которую, тем не менее, хотелось бы обозначить отдельно. Неопределенность в выборе границ активного участка порождает неопределенность в сопоставлении активностей у различных испытуемых [2].

Мы поставили перед собой цель разработать метод решения обратной задачи, позволяющий с одной стороны, улучшить точность локализации и определения временного поведения множества одновременно работающих источников нейронной активности. С другой стороны, метод должен позволять решать задачу нахождения функционально эквивалентных для всех испытуемых единиц активности. Основная идея рассматриваемого ниже подхода заключается именно в том, что совместное решение этих проблем позволяет улучшить решение каждой из них. В этом подходе то, что обычно является источником дополнительных трудностей для анализа, а именно значительная вариативность измеренных данных от индивидуальных испытуемых, превращается в дополнительный источник информации, позволяющий наилучшим образом произвести декомпозицию этих данных на функциональные компоненты.

Описание алгоритма

Для решения недоопределенной обратной задачи необходимо использовать модельные предположения, ограничивающие область решений и, в конечном итоге, позволяющие выбрать единственное решение. Точность решения кардинальным образом зависит от физиологической правдоподобности этих модельных предположений.

В предлагаемом подходе мы делаем два основных предположения. Во-первых, мы считаем, что функционально эквивалентные единицы мозговой активности для различных испытуемых локализованы на участках коры, которые имеют не полностью совпадающее, но близкое относительно друг друга расположение. Во-вторых, мы считаем, что данные активности у раз-

ных испытуемых развертываются во времени в значительно сходной манере, что выражается в высоком коэффициенте корреляции соответствующих временных последовательностей.

Для того чтобы говорить о близости расположения активных участков на поверхностях коры мозга различных испытуемых, прежде всего, должна быть решена задача установления анатомического (в отличие от функционального) соответствия между ними. Обычной практикой является представление коры мозга триангуляционной решеткой, тогда вопрос нахождения соответствия между поверхностями коры мозга формулируется в терминах установления мер близости между вертексами соответствующих решеток. В настоящее время нами освоены два подхода к решению данной задачи. Первый основан на трансформации шаблонной сетки "канонического" мозга [3]. Во втором используются индивидуально построенные с помощью ПО FreeSurfer [4] сетки, а значения активностей в узлах сопоставляются на основе карты анатомической близости и процедуры интерполяции. Опуская детали, можно сказать, что оба подхода позволяют установить повертексное соответствие между анатомически эквивалентными участками коры мозга у разных испытуемых.

Величина потока магнитного поля регистрируемого сенсорами МЭГ может быть вычислена с помощью квазистатической аппроксимации уравнений Максвелла в форме закона Био-Савара [5]. Тогда для i -го ($i = 1, \dots, N$, N – число испытуемых) испытуемого можно записать классическую прямую модель формирования измеряемых на сенсорах данных

$$Y_i = L_i J_i + \varepsilon_i,$$

где $Y_i \in R^{c \times t}$ – вектор измерений, $L_i \in R^{c \times n}$ – прямой оператор (lead-field матрица), содержащий значения, вычисленные по закону Био-Савара для единичных токов для каждого из вертексов триангуляционной решетки, $J_i \in R^{n \times t}$ – вектор значений токов для каждого из вертексов триангуляционной решетки, при этом генераторы токов считаются расположенными в сером веществе коры с фиксированной ориентацией нормально к ее поверхности, $\varepsilon_i \in R^{c \times t}$ – вектор шума на сенсорах, c – число каналов, t – число моментов времени, n – число вертексов триангуляционной решетки.

Для локализации источников кортикальной активности необходимо решить обратную задачу, т.е. оценить J_i по известным Y_i . Проблема заключается в том, что ранг матрицы L_i существенно меньше n , и нахождение обратного оператора сопровождается существенной неопределенностью, которая обычно разрешается с помощью минимизации какой-либо нормы

получаемого решения. Стоит отметить, что условие минимизации квадратичной или иной нормы само по себе не является физиологически диктуемым требованием и применяется за неимением лучших ограничивающих факторов. Следовательно, если имеется возможность снизить неопределенность за счет физиологически правдоподобных ограничений, то возможно получать более точное решение.

Чтобы наиболее наглядным образом показать, за счет чего в нашем методе осуществляется увеличение точности решения обратной задачи, мы для начала сделаем маловероятное предположение, что активности всех испытуемых в точности повертексно совпадают, т.е. для каждого испытуемого их можно представить единственным вектором $\bar{J} \in R^{n \times l}$. Тогда можно записать:

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_N \end{bmatrix} = \begin{bmatrix} L_1 \\ \vdots \\ L_N \end{bmatrix} \bar{J} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_N \end{bmatrix}.$$

В такой модели можно надеяться, что ранг конкатенированного прямого оператора будет выше ранга любого индивидуального прямого оператора. И первым пунктом результатов, мы покажем, что это действительно так.

К сожалению, предположение о повертексном совпадении активностей каждого испытуемого является нереальным и должно быть ослаблено. Чтобы сделать это, мы переформулируем данную модель с помощью вероятностного подхода. Сначала запишем прямые модели для каждого испытуемого в объединенной форме:

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_N \end{bmatrix} = \begin{bmatrix} L_1 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & L_N \end{bmatrix} \begin{bmatrix} J_1 \\ \vdots \\ J_N \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_N \end{bmatrix}.$$

Оценка токов в этой модели может быть найдена с помощью максимизации апостериорной вероятности (МАР оценка) распределения и позволяет учитывать имеющуюся информацию об априорном распределении токов путем накладывания определенной структуры на их матрицу ковариации. Легко проверить, что использование матрицы ковариации $Q \in R^{Nn \times Nn}$ в форме:

$$\begin{bmatrix} I & \dots & I \\ \vdots & \ddots & \vdots \\ I & \dots & I \end{bmatrix},$$

где I – единичная матрица размерности $n \times n$ сводит данную модель к вышеуказанной с конкатенированным прямым оператором. Преимуществом данного подхода является то, что он позволяет задавать с помощью соответствующих матриц ковариаций практически любые априорные данные о распределении искомым активаций.

Более того, появляется возможность оптимизации структуры самой матрицы ковариации при условии, что она представляется как композиция некоторых базовых элементов

$$Q = \sum_{i=1}^q h_i C_i,$$

где C_i – известные матрицы, которые представляют наши ограничения на структуру ковариации токов, а h_i – неизвестные параметры, часто называемые гиперпараметрами [6]. Чтобы определить Q , можно использовать оценку, основанную на максимизации правдоподобия [7]. В предположении нормального распределения верно

$$p(Y | h) \propto N(Y; 0, \Sigma_y) \propto |\Sigma_y|^{-\frac{1}{2}} \exp(-\frac{1}{2} Y^T \Sigma_y^{-1} Y),$$

где $\Sigma_y = \Sigma_\epsilon + LQL^T$. В результате, гиперпараметры находятся как аргументы, максимизирующие целевую функцию логарифма правдоподобия

$$2 \ln(p(Y | h)) = -\text{trace}(C_y \Sigma_y^{-1}) - \ln |\Sigma_y|,$$

где $C_y = YY^T$ – эмпирическая ковариация данных. Данная процедура часто обозначается в литературе как максимизация правдоподобия второго типа [8].

Основной наш вклад заключается в предложении выбора базовых элементов структуры ковариации, который бы, с одной стороны, обеспечивал максимальную схожесть активаций у различных испытуемых, а с другой – позволял индивидуальную вариативность как в локализации, так и во временной динамике активаций. Для этого мы предлагаем использовать два базовых компонента. Первый компонент, накладывающий требование по вертексному совпадению активаций, практически совпадает с описанным выше, с тем лишь дополнением, что мы еще используем требование корреляции смежных вертексов, для чего единичные матрицы сворачиваем с гауссовым ядром. Второй компонент, учитывающий индивидуальную вариативность активаций, практически совпадает с классическим компонентом, используемым в решении, соответствующем минимизации квадратичной нормы, с тем дополнением, что мы также накладываем требование корреляции смежных вертексов. Упрощенная структура этих компонентов приведена на рис. 1. Найденная с помощью максимизации правдоподобия ком-

бинация этих компонентов на следующем шаге используется для нахождения MAP оценки искомых активаций коры.

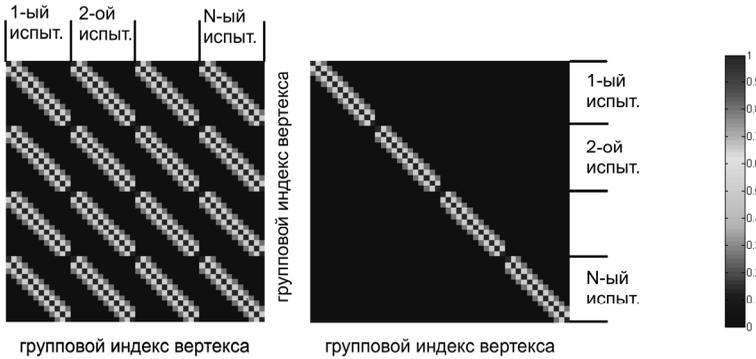


Рис. 1. Диаграмма, иллюстрирующая матричные компоненты ковариации. Для целей визуализации матрицы содержат уменьшенное число вертексов и получены с помощью сворачивания с гауссовым ядром, соответствующим упрощенной схеме смежности между вертексами (смежными являются последовательные индексы)

Результаты

На рис. 2, *a* представлена зависимость числа эффективных сенсоров (ранга матрицы прямого оператора) от числа испытуемых, для которых проводилось решения обратной задачи. Как и ожидалось, увеличение числа конкатенированных прямых операторов приводит к заметному увеличению ранга результирующей матрицы. В зависимости от порога, определяемого по нормализованным собственным значениям, при увеличении испытуемых в 9 раз ранг увеличивается в 4 раза при высоком пороге и в 6 раз при низком.

Для систематического изучения точности локализации мы проводили симуляцию активных участков на коре, и с помощью прямого оператора рассчитывали модельные данные на сенсорах. Для каждого участка сначала выбирался вертекс, который служил центром притяжения для соответствующих участков всех испытуемых. Относительно этого центра определялись все сдвиги индивидуальных участков. Параметры сдвига определяли новое положение центра индивидуального участка. Затем вокруг центра выбирались вертексы, лежащие от него на заданном расстоянии, определяющем протяженность участка.

Для оценки точности решения обратной задачи мы использовали меру $M1$, основанную на идее учета соотношения числа правильно определенных вертексов к числу ошибочно определенных, но свободную от проблемы произвольности выбираемого порога. Мера $M1$ может иметь значения от 0, когда сравниваемые активации полностью совпадают, до 2, когда они полностью не совпадают.

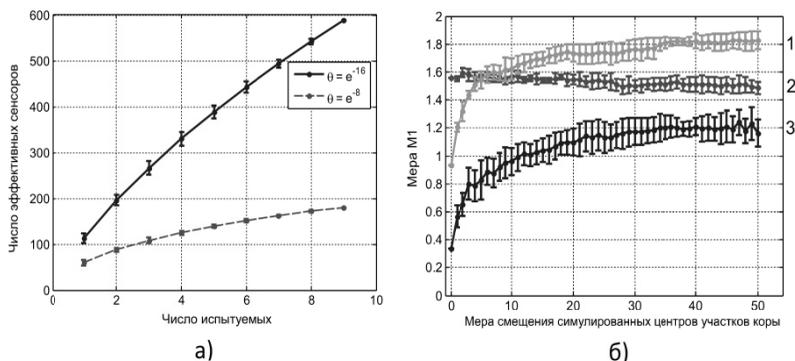


Рис. 2. Число эффективных сенсоров как функция от числа испытуемых (а) (показаны результаты для двух различных порогов собственных значений) и зависимость меры $M1$ (б) (меньшее значение соответствует большей точности локализации - определению в тексте) от смещения модельных активных участков коры. Обозначены графики: 1 – модель с конкатенированным прямым оператором; 2 – модель с минимизацией квадратичной нормы; 3 – GALA

На рис. 2, б мы приводим зависимость влияния смещения центров участков на точность локализации для случая, когда активными были по 3 участка для каждого испытуемого. По оси абсцисс откладывается величина, прямо пропорциональная среднему расстоянию между центрами участков для разных испытуемых.

Первое, что необходимо отметить, что модель с конкатенированными прямыми операторами, давая значительно лучшую точность локализации относительно модели минимальной нормы при нулевом и близких к нему смещениях, при заметных смещениях центров участков перестает удовлетворительно работать и дает локализацию хуже, чем модель с минимальной нормой.

GALA, в отличие от модели с конкатенированными прямыми операторами, позволяет снять ограничение на точное совпадение положений соответствующих участков у разных испытуемых и на всем диапазоне исследованных смещений обеспечивает большую точность локализации по сравне-

нию с моделью минимальной нормы. Нетривиальным фактом является то, что точность локализации GALA не приближается асимптотически к модели минимальной нормы при смещении центров участков превосходящих размеры самих этих участков, а остается значительно выше (значение меры $M1$ при этом ниже).

Для демонстрации возможности использования GALA для определения специфичной для изучаемого процесса, а значит, общей для всех испытуемых активности, мы провели моделирование для девяти испытуемых с максимально приближенными к реальным данным параметрами симуляции. Общая для всех испытуемых активность была промоделирована с помощью пяти участков кортикальной активности. Участки для каждого испытуемого были получены сдвигом на величину от 1 до 3 узлов триангуляционной решетки относительно общих центров притяжения. Временное поведение активности в этих участках было в достаточной мере коррелированным между различными испытуемыми, но не совпадало в точности.

Для моделирования интерферирующей неспецифичной для изучаемого процесса активности мы для каждого испытуемого добавляли по 3 дополнительных участка. Для усложнения условий, мы выбирали эти участки также перекрывающимися для некоторых испытуемых, однако активность в них была в высокой степени некоррелированной.

Генерация модельных данных на сенсорах производилась с помощью оператора прямой задачи с числом вертексов 8196, в то время как решение обратной задачи осуществлялось на основе оператора прямой задачи с числом вертексов 5124. Это делалось для моделирования неточностей, возникающих при восстановлении поверхностей мозга индивидуальных испытуемых по МРТ образам. На уровне сенсоров был добавлен белый шум, отфильтрованный с частотой отсечки 30 Гц с максимальной амплитудой 30% относительно максимальной амплитуды сигнала.

Мы сравнивали алгоритм GALA с итерационным методом, теоретически соответствующим алгоритму FOUSS-LORETA [9], и с классическим вариантом решения на основе минимизации квадратичной нормы. Результаты приведены на рис. 3.

Для метода FOUSS-LORETA, даже безотносительно к низкой точности локализации активности, существенной проблемой является нахождение функционально эквивалентных участков у разных испытуемых. Участки, найденные с помощью этого метода для разных испытуемых, для большинства из них не перекрываются, и их число различно.

Решение, найденное с помощью классической минимизации квадратичной нормы, является распределенным по всему кортексу и, соответственно,

интерпретация его результатов крайне затруднена и требует выбора произвольных порогов, необходимых для выделения конкретных областей интереса и определения их временной динамики.

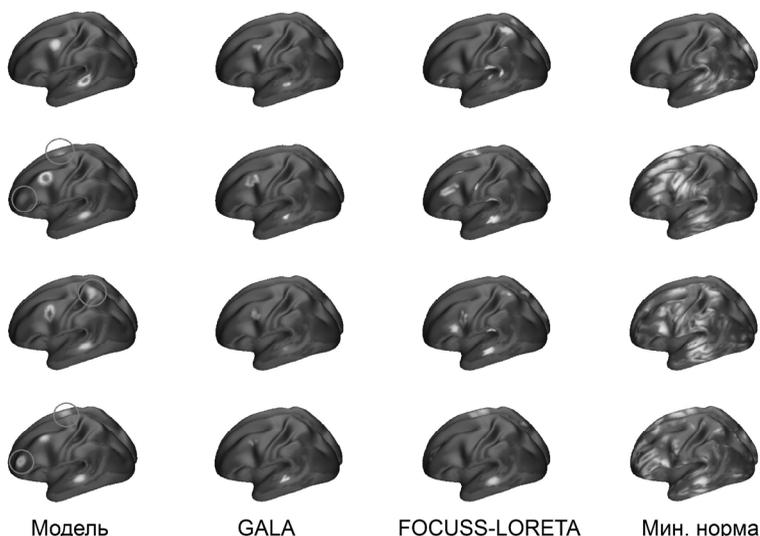


Рис. 3. Результаты локализации активности для левого полушария, полученные для четырех из девяти случайно выбранных испытуемых тремя различными методами. Ряды – различные испытуемые. Первый столбец – известная в симуляции модельная активность. Овалами обозначены интерферирующие (шумовые) участки коры

Алгоритм GALA позволяет хорошо восстановить как локализацию, так и временное поведение активности, общей для всех испытуемых. При этом интерферирующая активность исключается из найденного решения. Локализация найденных участков активности для данного алгоритма сопровождается возможностью их точного соотнесения между всеми испытуемыми.

Выводы

Основной целью создания алгоритма GALA было не столько разработка нового метода решения обратной задачи, сколько решение более широкой проблемы – разработки подхода для эксплоративного анализа МЭГ данных, полученных на группе испытуемых. Обычно различия между испытуемыми

в группе в геометрии индивидуальных кор и различного положения головы испытуемых внутри шлема, содержащего магнитоэнцефалографические сенсоры, представляют сложности для выделения активности соответствующей изучаемому процессу, поскольку затрудняют выделение функциональных единиц активности коры и их соотнесения между собой для разных испытуемых. Мы здесь предлагаем использовать эту дополнительную информацию для повышения точности восстановления как локализации, так и временного поведения источников кортикальной активности. Чтобы добиться этого, мы сформулировали ряд модельных предположений и продемонстрировали, что в их рамках можно значительно улучшить точность решения обратной задачи.

Список литературы

1. Sarvas J. Basic mathematical and electromagnetic concepts of the biomagnetic inverse problem // *Physics in Medicine and Biology*, 1987. V. 32(1) P.11-22.
2. Lee A.K.C., Hamalainen M.S., Dyckman K.A., Barton J.J.S., Månsson D.S. Saccadic preparation in the frontal eye field is modulated by distinct trial history effects as revealed by magnetoencephalography // *Cerebral Cortex*. 2011. V. 21(2) P. 245-253.
3. Mattout J., Henson R.N., Friston K.J. Canonical source reconstruction for MEG // *Computational intelligence and neuroscience*, 2007.
4. Fischl B. FreeSurfer // *Neuroimage*, 2012. V. 62(2). P. 774-781.
5. Hämäläinen M., Hari, R., Ilmoniemi R.J., Knuutila J., Lounasmaa O.V. Magnetoencephalography - theory, instrumentation, and applications to noninvasive studies of the working human brain // *Reviews of modern Physics*, 1993. V. 65(2). P. 413-497.
6. Friston K.J. Bayesian estimation of dynamical systems: an application to fMRI // *NeuroImage*, 2002. V. 16(2). P. 513-530.
7. Harville D.A. Maximum likelihood approaches to variance component estimation and to related problems // *Journal of the American Statistical Association*. 1977. V. 72(358). P. 320-338.
8. Wipf D., Nagarajan S. A unified Bayesian framework for MEG/EEG source imaging // *Neuroimage*, 2009. V. 44(3). P. 947-966.
9. Liu H., Gao X., Schimpf P.H., Yang F., Gao S. A recursive algorithm for the three-dimensional imaging of brain electric activity: shrinking LORETA-FOCUSS // *Biomedical Engineering, IEEE Transactions on Biomedical Engineering*, 2004. V. 51(10). P. 1794-1802.

А.С. РАТУШНЯК, А.Л. ПРОСКУРА, Т.А. ЗАПАРА

Конструкторско-технологический институт вычислительной техники СО РАН,
Новосибирск
Ratushniak.Alex@gmail.com

**АНАЛИЗ И ВОЗМОЖНЫЕ ПУТИ РЕИНЖЕНЕРИНГА
САМООРГАНИЗУЮЩИХСЯ НЕЙРОННЫХ СИСТЕМ
НА ОСНОВЕ КОНВЕРГЕНЦИИ ТЕХНОЛОГИЙ**

Анализ устройства внутриклеточных информационных сетей нейрона позволяет выявить основы ассоциативных, предсказательных свойств живых систем на молекулярном уровне. Это, вероятно, сделает возможным на основе конвергенции технологий разрабатывать молекулярные нейроподобные информационные ядра, способные, как и их живые прототипы, к самоорганизации в комплексы с функциональной архитектурой, подобной мозгу, и способностью осуществлять достаточно сложные когнитивные функции.

Ключевые слова: *нейроны, молекулярные информационные системы, когнитивные свойства, макрокомплексы НМДА рецепторов.*

A.S. RATUSHNYAK, A.L. PROSKURA, T.A. ZAPARA

Design Technological Institute of Digital Techniques SB RAS, Novosibirsk
Ratushniak.Alex@gmail.com

**ANALYSIS AND POSSIBLE DIRECTIONS
OF THE REENGINEERING OF SELF-ORGANIZING NEURAL
SYSTEMS BASED ON CONVERGENCE TECHNOLOGIES**

Analysis of mechanisms of neuron's intracellular information networks allow to reveal the basics of associative and predictive properties of living systems at the molecular level. On the basis of the convergence of technologies it is likely to make it possible to develop molecular neural information nuclei capable as their living prototypes of self-organization in complex with the functional architecture like a brain and the ability to perform fairly complex cognitive functions.

Keywords: *neurons, molecular information systems, cognitive properties of NMDA receptors macrocomplexes.*

Введение

Непрерывно возрастающее количество информационных потоков выдвигает задачи их обработки, анализа, принятия решений, предсказания последствий. Осуществление таких задач являются насущной необходимостью во всех сферах деятельности человека и практически невозможно без использования систем, обладающих свойствами, сводимыми к понятию когнитивность. Прогресс в разработках новых поколений электронных информационных комплексов пробудил оптимизм относительно возможности создания устройств, прототипом которых являются биологические нейронные системы, наделенные этим свойством. При этом информационные мощности современных систем обработки информации в известной мере приближаются к предельным возможностям и понятно, что существующие концепции их развития требуют серьезных изменений. По существующим оценкам способность биологических систем обрабатывать информационные потоки на много порядков превосходят потенциальные возможности вычислительных машин, основанных на архитектуре последовательного типа, созданной Джоном фон Нейманом ещё 1945 году. В качестве возможного решения этих проблем представляется создание новой биологически инспирированной архитектуры информационных систем, обладающих, в том числе, таким свойством, как когнитивность.

Задача реинженеринга когнитивных систем требует, прежде всего, определение самого этого понятия. Изначально этот термин сформирован в областях психологии и философии и подразумевал процессы мышления, образного восприятия, обучения и памяти, ассоциативности и опережающего отражения (предсказания) и др. Однако при этом анализ физических предпосылок возникновения этого явления, как правило, не рассматривался. Упускалось из вида, что в целом это явление возникло из базовых свойств живых систем, основанных на поддержании своей структурно-функциональной организации (гомеостаза). Такая стабилизация базируется на предсказании состояния внешней и внутренней среды, понижения внутренней энтропии молекулярной системы. Именно с молекулярного уровня начинается построение систем, которые по мере усложнения в соответствии с принципами эмерджентности приобретают весь комплекс свойств, обозначаемый термином когнитивность.

Сейчас в мире на решение задач реинженеринга когнитивных систем направлены значительные силы и выделяются многомиллиардные средства. Однако основной вектор работ, основанных на структурно-функциональном анализе мозга, направлен на создание его имитационных моделей при достаточно упрощенных представлениях о базовом элементе –

нейроне. При этом не кажется перспективным то, что основное направление работ все же ориентировано на создание программных продуктов, которые, как предполагается, будучи реализованными на существующих достаточно мощных вычислительных комплексах с архитектурой последовательного типа, позволят им приобрести необходимые свойства. Использование архитектур, наиболее приближенных к биологическим прототипам, например Dataflow, при таких предпосылках тоже не привели пока к значительным успехам.

Поэтому основной, наиболее важной целью таких работ представляется выявление не только особенностей архитектуры биологических информационных систем, но и информационные свойства и молекулярная конструкция основных элементарных ячеек, образующих эту архитектуру – нервных клеток. В существующих моделях не учитывается один из самых важных аспектов – активное взаимодействие нейронов с внешней средой, направленное на предсказание будущего состояния этой среды. Биологический нейрон является по существу молекулярной (наноуровневой) информационной системой, состоящей из многих десятков тысяч рецепторных входов, примерно такого же количества эффекторов (например, ионных каналов, других транспортеров), систем внутриклеточной передачи, усиления, анализа сигналов способной к предсказанию будущего состояния и принятия решения. Созданию более совершенной модели нервной клетки препятствует практическое отсутствие методико-технологической базы, учитывающей сложности этих молекулярных машин. Такая база может быть создана, только опираясь на наноразмерные устройства, соизмеримые с исследуемым объектом. Изучением функциональной активности нервных клеток, опосредованной электрическими потенциалами, занимаются достаточно давно, однако, до сих пор не удалось разработать интерфейс регистрации сигналов живых клеток, отвечающий уровню решаемой задачи. Для адекватного взаимодействия с молекулярными системами нейрона требуются соответствующие инструменты – массивы датчиков микро и наноразмеров, малоинвазивные и обеспечивающие достаточную величину получаемого и передаваемого клетке сигнала. Необходимо развитие методов визуализации информационных процессов, происходящих на молекулярном уровне как в упрощенных, редуцированных нейронных системах, так и в целом мозге.

Огромное количество аналитических, экспериментальных данных (в год в области нейронаук выходит более 100 тысяч статей) требует их интеграции с преобразованием в систему знаний. В последние годы появились данные, показавшие возможность ассоциативных процессов в молекулярной системе отдельного синапса, что свидетельствует о существенной недо-

оценке функциональных свойств этих систем. Приблизиться к решению задач интеграции можно преобразованием данных из символического описания в системы динамической графики, легче воспринимаемой мозгом и более доступной для перевода в знания. Развитие методов анализа и синтеза данных позволит выявить принципы и системную организацию внутриклеточных молекулярных машин, с помощью которых реализуется базовая функция – опережающего отражения (предсказания).

Основной задачей на данном этапе является разработка методами теоретико-экспериментального анализа молекулярной структурно-функциональной модели нейрона и его элементов, ориентированной на технологические возможности молекулярного конструирования, создания элементарной ячейки биологически инспирированной информационной системы. Именно по такому вектору сейчас развиваются работы в ведущих центрах. Подобные – когнитивные ядра активно разрабатывает, например, компания IBM. Однако пока такие ядра базируются на стандартной математической модели нейрона (с некоторыми вариациями) с использованием кремниевых технологий. Основные принципы молекулярной организации нейрона пока не реализованы. Функциональность таких модулей в сравнении с биологическим нейроном существенно ограничена.

Современное состояние исследований и биоинформационный анализ межбелковых взаимодействий в макрокомплексах НМДА рецепторов

Одним из важнейших информационных процессов, лежащих в основе опережающего отражения на уровне мозга, является память. По современным представлениям, память, или элемент знаний, определяется структурой связей в сетях нейронов, которые опосредуют поведение, и основаны на молекулярных перестройках внутриклеточных сигнальных и эффекторных систем. Межнейронные связи в мозге образуются, усиливаются и становятся более обширными в результате синаптических модуляций, зависящих от опыта [1]. Каждый нейрон имеет множество синапсов как стабильных, так и формируемых за десятки секунд при функциональных процессах. При этом клетка может быть членом множества различных ассоциативных сетей и, следовательно, разнообразных элементов знания. Становится очевидным, что связи в сетях мозга, в том числе ассоциативные, возникают в пределах нейрона благодаря свойствам его молекулярных систем, реакциям, которые приводят к реорганизации внутриклеточных молекулярных конструкций. Все это, в конечном счете, служит базисом анализа и дополнения образа внешнего (и внутреннего) сигнала, обеспечивая опережающее отражение

(предсказание состояния) среды, основанное на обучении и запоминания на молекулярном уровне.

Одним из основных структурно-функциональным элементом нейрона, вовлеченным в осуществлении им базовых информационных функций, являются межклеточные контакты – синапсы. Синаптические процессы наиболее изучены в гиппокампе, который вовлечён в процессы восприятия информации, её распознавания, анализа и запоминания [2; 3].

Нами проанализированы и реконструированы белок-белковые взаимодействия субъединиц ионотропных глутаматных НМДА рецепторов, которые обеспечивают их подвижность и закрепление на синаптической мембране, а также функциональную роль в процессах изменения и поддержания эффективности синаптической передачи в гиппокампе. Выделено три группы белков, которые обеспечивают формирование макрокомплексов НМДА рецепторов в глутаматергических синапсах, в частности, нейронов CA1 поля гиппокампа. Белки сгруппированы по их функции в комплексах на основании информации из баз данных (главным образом Swiss-Prot, String, Kegg, GeneCards) научных статей (включая как экспериментальные, так и обзорные публикации), в которых охарактеризована структура гена и белка, экспрессия в мозге, в особенности на возбуждающих синапсах гиппокампа, роль в процессах синаптической пластичности. Особое внимание уделялось белкам, для которых установлена связь с различными когнитивными нарушениями.

Первую группу представляют мембранные мультидоменные белки, обеспечивающие сцепление пре- и постсинаптической мембраны, формирование кластеров рецепторов, объединение различных синаптических трансмембранных рецепторов в функциональные комплексы (белки LRFN, PRR7, MPDZ, NETO1, INADL и пр.).

Вторая – скаффолд-белки ПСУ. Ключевым в данной категории выступает белок PSD95, член семейства MAGUK, который часто рассматривается как маркер ПСУ [4]. Семейство Sapap (Dlgap 1, 2, 3, 4 (Disks large-associated protein)) объединяет скаффолды семейства MAGUK между собой. Белки Begain (Brain-enriched guanylate kinase-associated protein) формируют троичный комплекс между белками PSD95 и Dlgap1, выступая в роли каркасной решетки ПСУ [5]. Основная роль данной группы белков – закрепление рецепторов через взаимодействие с их цитоплазматическими доменами. Скаффолды являются наиболее представленной группой. Масс-спектрометрия и другие методы дают оценку примерно в 60-400 главных молекул скаффолд-белков ПСУ [6]. Часть скаффолдов можно рассматривать как слоты для посадки трансмембранных рецепторов синапса, их пространственное закрепление в пределах синапса, например, за счет взаимо-

действия с интегринами. Причем, некоторые скаффолды объединяются с рецепторами еще в эндоплазматическом ретикулуме и контролируют, таким образом, их доставку к синапсам и закрепление на ПСУ. Известно, что скаффолд Sap102 (Dlg3) играет ключевую роль именно в доставке NR2B-содержащих НМДА рецепторов, а PSD95 – в их закреплении на синаптической мембране в центре ПСУ [6].

Третью группу представляют адаптерные, или вспомогательные, белки. Эти белки, по сути, являются функциональными элементами, благодаря которым происходит объединение структурно функциональных сигнальных, эффекторных молекул в головке дендритного шипика в процессе НМДА зависимой индукции синаптической пластичности. В литературе нет четкого разделения между скаффолдами и адаптерами. Адаптеры, согласно нашему мнению, выступают скорее в роли динамичных площадок для временного или постоянно закрепления киназ, фосфатаз, малых ГТФаз, регуляторов их активности, молекул сигнальных путей, играя при этом ключевую роль в формировании функциональных комплексов разнообразных белков, межбелковые взаимодействия между которыми обеспечивают изменение и поддержание синаптической эффективности. Основными представителями данной группы в глутаматэргических синапсах выступают белки семейств Homer (Homer protein homolog 1), Baiap (Brain-specific angiogenesis inhibitor 1-associated protein), GIT (G protein-coupled receptor kinase-interactor 1). Мультимеризуясь, эти белки могут быстро перестраивать набор макрокомплекса, временно объединять белки различных сигнальных каскадов для определенных процессов. То есть, если во второй группе белки формируют устойчивые связи с определенным набором белков, играя главным образом, каркасную роль в ПСУ, то адаптеры, объединяясь с предыдущей группой, предоставляют площадки для динамичного закрепления молекул, обеспечивающих функциональную и структурную (основанную на активном цитоскелете) пластичность синапса.

NR1 субъединицы являются облигаторными и объединяются с двумя копиями NR2 (NR1/NR2) либо NR3 (NR1/NR3) субъединиц (дигетеромерные комплексы НМДА рецепторов). Существуют варианты тригетеромерных комплексов НМДА рецепторов (NR1/NR2/NR3) [7]. Спорадические мутации в гене *Grin1* опосредуют, как считается, не синдромные интеллектуальные нарушения. При этом наблюдается значительное снижение интеллектуального уровня и нарушение адаптивного поведения [8].

Ди-гетеромерные комплексы NR1/NR2A доминируют в мозге взрослых млекопитающих, популяция NR2B-содержащих рецепторов имеет главным образом не синаптическое расположение [7].

Нами проанализирован набор белков из указанных трех групп для субъединиц NR1, NR2A и NR2B НМДА рецепторов.

NR1 субъединица объединяется с белками, которые отвечают за адгезию синаптической щели и взаимодействие с ключевыми скаффолд белками ПСУ.

Белки SALM3 и SALM5 (семейство LRFN), как считается, участвуют в индукции пресинаптической дифференцировки у контактирующих с дендритами аксонов. Взаимодействие SALM1 через С-терминальный PDZ мотив с белком ПСУ PSD95 важно для встраивания и кластеризации на синаптической мембране НМДА рецепторов. LRFN1 (SALM2) также способен взаимодействовать с GluR1 субъединицей АМПА рецепторов, чем способствует объединению НМДА и АМПА рецепторов в единый функциональный комплекс на синаптической мембране. Таким образом, SALM1 обеспечивает раннее формирование синапсов, а SALM2 обеспечивает созревание уже существующих дендритных шипиков через со-кластеризацию АМПА и НМДА рецепторов [9]. Хромосомная транслокация t(14;21)(q21.1;p11.2) приводит к нарушению экспрессии гена, кодирующем LRFN5, что связано с аутизмом [10].

Интересно отметить роль предшественника амилоида APP695 для экспрессии НМДА рецепторов на синаптической мембране. Считается, что APP695 взаимодействует с NR1 субъединицей [11] и при этом играет существенную роль в доставке во взрослые синапсы NR1/NR2A рецепторов, вероятно, через взаимодействие с трансмембранными белками NETO, которые взаимодействуют с NR2A субъединицами [12]. У *Neto1* (-/-) мышей наблюдается нарушение долговременной потенциации и связанного с работой НМДА рецепторов пространственного обучения и запоминания [13].

Субъединицы NR2A и NR2B непосредственно взаимодействуют с ключевым белком ПСУ – PSD95. При этом участки цитоплазматических доменов, отвечающие за данные взаимодействия, различаются у субъединиц [14].

Цитоплазматические домены NR2B и NR2A взаимодействуют с различным, но пересекающимся, набором дендритных белков.

Трансмембранные белки INADL (InaD-like protein, Channel-interacting PDZ domain-containing protein) выступают каркасом, объединяющим структурно разные, но связанные функционально белки на синаптической мембране: субъединицы НМДА рецепторов (NR2A, NR2B, NR2C, NR2D), калиевые каналы, немедиаторные рецепторы, белки клеточной адгезии. Адаптерный белок KIBRA взаимодействует с INADL и вовлечен в процессы нейропластичности, апоптоза и ремоделирования цитоскелета [15]. В гиппокампальных нейронах эти белки распределены в соматодендритных компартаментах в виде гомодимеров, а также хорошо представлены в ПСУ ден-

дритных шипиков, объединяя сигнальные молекулы с элементами цитоскелета [16]. Имеются данные, что KIBRA прямо связывается с protein interacting with C-kinase 1 (PICK1) и формирует комплексы с АМПА рецепторами [17]. Показана взаимосвязь генетической вариабельности KIBRA и риском возникновения болезни Альцгеймера с возрастом [18], депрессией [19].

NR2A-специфическими белками выступают NETO1 и S-SCAM. NETO1 хорошо представлен в дендритных шипиках возбуждающих синапсов, в частности в CA1 поле гиппокампа, и является крайне важным для поддержания NR2A-содержащих НМДА рецепторов на синаптической мембране и вовлечен в процессы обучения и формирования памяти [13]. В литературе обсуждается его роль в качестве вспомогательной субъединицы НМДА рецепторов и взаимодействие с предшественником амилоидного белка [20].

Заключение

Анализ интерактома сенсорных элементов нейронов позволяет предположить, что их функциональная роль не сводится только к изменению его эффективности под действием стимуляции, но может распространяться на более сложные информационные процессы ассоциативной обработки рецептивного сигнала и определение его функциональной значимости [21].

Дендриты нейронов экспрессируют потенциалзависимые каналы, которые обеспечивают возбудимость и распространение сигнала к соме [22-23], обратное распространение потенциалов действия и создают возможность инициировать локальные дендритные спайки [24]. Кроме того, потенциалзависимый Mg^{2+} блок синаптических NMDA рецепторов может также инициировать дендритные спайки и поддерживать нелинейную синаптическую интеграцию [25]. Следствием такой организации является то, что хотя небольшие (подпороговые) сигналы вносят вклад только в зоне инициации спайков, сигнал о том, что вход достиг порога в одной зоне, быстро распространяется в другую зону. Это обеспечивает возможность для ассоциативных взаимодействий внутри нейрона, когда активность одной области может снизить порог для генерации активности в другой области. Концептуальная важность этого механизма заключена в способности на его основе обнаружить совпадение, ассоциацию сигнала на входах от сенсорных органов и входах от структур мозга. Возникает ассоциативный механизм на клеточном уровне для объединения информации прямой и обратной связи [26]. Обратная связь, в этой схеме, служит «предсказанием» [27], должен ли конкретный пирамидный нейрон (или микроколлонка пирамидных нейронов) формировать результирующий обработку сигнал [28].

Задача создания молекулярной модели нейрона, пока, вероятно, превосходит существующие технологические возможности. Однако развитие в последние годы таких методов и технологий позволяет надеяться на достижения необходимого уровня. Например, теоретически и экспериментально была выявлена возможность использования в молекулярных конструкциях микротрубочек, состоящих из димеров белка тубулина. Показано, что, как и в нейронах, они могут обладать эффектом памяти с многоуровневым резистивным переключением, при этом количество разрешимых уровней сопротивления не менее 500 [29]. Подобными физическими свойствами обладают и многие другие молекулярные элементы клетки. Ведутся разработки систем подобных мемристорным элементам памяти и обработки информации на основе подобных молекул.

Анализ системы межбелковых взаимодействий в макрокомплексах субъединиц НМДА рецепторов позволит приблизиться к пониманию принципов и молекулярной реализации, основных функций нейронов (обучения, опережающего отображения, памяти). Кроме того, такие знания раскрывают механизмы развития патологических состояний, позволяют вести направленный поиск фармакологических и терапевтических мишеней их коррекции.

Конвергенция технологий и методов молекулярного дизайна, клеточного инженеринга, создания наноустройств, модификации внутриклеточных сигнальных путей и др. с использованием знаний об устройстве внутриклеточных информационных систем в нейроне, вероятно, сделает возможным разработку молекулярного нейроподобного информационного ядра, способного, как и нейроны, к самоорганизации в системы, осуществляющие достаточно сложные когнитивные функции с минимальными энергетическими, временными и др. затратами.

В работе использованы материалы, полученные при выполнении базового проекта 35.1.5., интеграционного проекта Президиума СО РАН №136, гранта РФФИ № 12-01-00639-а.

Список литературы

1. Fuster J.M. Cortex and Memory: Emergence of a New Paradigm // J. Cognitive Neurosci, 2009. 21. P. 2047–2072.
2. Kjelstrup K.B., Solstad T., Brun V.H. et al. Finite scale of spatial representation in the hippocampus // Science, 2008. 321. P. 140-143.
3. Hawley D.F., Morch K., Christie B.R. et al. Differential response of hippocampal subregions to stress and learning // PLoS One, 2012. 7. P. E53126.
4. Chen X., Winters C., Azzam R. et al. Organization of the core structure of the postsynaptic density // Proc. Natl. Acad. Sci. 2008. 105. P. 4453-4458.
5. Deguchi M., Hata Y., Takeuchi M. et al. BEGAIN (brain-enriched guanylate

kinase-associated protein), a novel neuronal PSD-95/SAP90-binding protein. // *J. Biol Chem.*, 1998. 273. P. 26269-72.

6. Chen X., Winters C., Azzam R. et al. Organization of the core structure of the postsynaptic density // *Proc. Natl. Acad. Sci.*, 2008. 105. P. 4453-4458.

7. Paoletti P., Bellone C., Zhou Q. NMDA receptor subunit diversity: impact on receptor properties, synaptic plasticity and disease // *Nat Rev Neurosci*, 2013. 14. P. 383-400.

8. Hamdan F.F., Gauthier J., Araki Y. et al. Excess of de novo deleterious mutations in genes associated with glutamatergic systems in nonsyndromic intellectual disability // *Am J Hum Genet.*, 2011. 88. P. 306-316.

9. Nam J., Mah W., Kim E. The SALM/Lrfrn family of leucine-rich repeat-containing cell adhesion molecules // *Semin Cell Dev Biol.*, 2011. 22. P. 492-498.

10. De Bruijn D.R., van Dijk A.H., Pfundt R. et al. Severe Progressive Autism Associated with Two de novo Changes: A 2.6-Mb 2q31.1 Deletion and a Balanced t(14;21)(q21.1;p11.2) Translocation with Long-Range Epigenetic Silencing of LRFN5 Expression // *Mol Syndromol.*, 2010. 1. P. 46-57.

11. Cousins S.L., Hoey S.E., Stephenson F.A. et al. Amyloid precursor protein 695 associates with assembled NR2A- and NR2B-containing NMDA receptors to result in the enhancement of their cell surface delivery // *J. Neurochem.*, 2009. 111. P. 1501-1513.

12. Cousins S.L., Innocent N., Stephenson F.A. Neto1 associates with the NMDA receptor/amyloid precursor protein complex // *J. Neurochem.*, 2013. 126. P. 554-564.

13. Ng D., Pitcher G.M., Szilard R.K. et al. Neto1 is a novel CUB-domain NMDA receptor-interacting protein required for synaptic plasticity and learning // *PLoS Biol.*, 2009. 7. P. e41.

14. Cousins S.L., Kenny A.V., Stephenson F.A. Delineation of additional PSD-95 binding domains within NMDA receptor NR2 subunits reveals differences between NR2A/PSD-95 and NR2B/PSD-95 association // *Neuroscience*, 2009. 158. P. 89-95.

15. Lauriat T.L., Dracheva S., Kremerskothen J. et al. Characterization of KIAA0513, a novel signaling molecule that interacts with modulators of neuroplasticity, apoptosis, and the cytoskeleton // *Brain Res.*, 2006. 1121. P. 1-11.

16. Johannsen S., Duning K., Pavenstädt H. et al. Temporal-spatial expression and novel biochemical properties of the memory-related protein KIBRA // *Neuroscience*, 2008. 155. P. 1165-1173.

17. Makuch L., Volk L., Anggono V. et al. Regulation of AMPA receptor function by the human memory-associated gene KIBRA // *Neuron*. 2011. 71. P. 1022-1029.

18. Burgess J.D., Pedraza O., Graff-Radford N.R. et al. Association of common KIBRA variants with episodic memory and AD risk. // *Neurobiol Aging.*, 2011. 32. 557.e1-557.e9

19. Galecki P., Szemraj J., Florkowski A. et al. Single nucleotide polymorphism of the KIBRA gene in recurrent depressive disorders. // *Neuro Endocrinol Lett.*, 2010. 31. P. 97-102.

20. Molnár E. Are Neto1 and APP auxiliary subunits of NMDA receptors? // *J Neurochem.*, 2013. 126. P. 551-553.

21. Smith S.L., Smith I.T., Branco T. et al. Dendritic spikes enhance stimulus selectivity in cortical neurons in vivo. // *Nature*, 2013. 503. P. 115-120.

22. Stuart G.J., Sakmann B. Active propagation of somatic action-potentials into neocortical pyramidal cell dendrites. // Nature, 1994. 367. P. 69–72
23. Stuart G., Spruston N., Sakmann B. et al. Action potential initiation and propagation in rat neocortical pyramidal neurons. // J. Physiol., 1997. 505. P. 617–632
24. Johnston D., Narayanan R. Active dendrites: colorful wings of the mysterious butterflies. // Trends Neurosci., 2008. 31. P. 309–316
25. Schiller J., Major G., Koester H. J. et al. NMDA spikes in basal dendrites of cortical pyramidal neurons. // Nature, 2000. 404. P. 285–289
26. Larkum M.E., Senn W., Luscher H.R. Top-down dendritic input increases the gain of layer 5 pyramidal neurons. // Cereb. Cortex, 2004. 14. P. 1059–1070
27. Rao R.P., Ballard D.H. Predictive coding in the visual cortex: a functional interpretation of some extra-classical receptive-field effects. // Nat. Neurosci., 1999. 2. P. 79–87
28. Larkum M. A cellular mechanism for cortical associations: an organizing principle for the cerebral cortex. // Trends Neurosci., 2013. 36. P. 141–51.
29. Slyadnikov E., Geiko P. Quantum Model and Memory of Informative Biomacromolecules. // J. Optical Memory Neural Networks, 2009. 18. P. 93–100.
30. Shaposhnikov A.S., Perevalov T.V., Gritsenko V.A. et al. Mechanism of GeO₂ resistive switching based on the multi-phonon assisted tunneling between traps. // Appl. Phys. Lett., 2012. 100. P. 243506.

А.В. ЧИЖОВ

Физико-технический институт им. А.Ф. Иоффе РАН, С.-Петербург
anton.chizhov@mail.ioffe.ru

АНАЛИЗ ЧУВСТВИТЕЛЬНОСТИ НЕЙРОНА К ВХОДНЫМ СИГНАЛАМ С ПОМОЩЬЮ МОДЕЛИ АНСАМБЛЯ НЕЙРОНОВ

С помощью модели статистического ансамбля реалистичных нейронов типа Ходжкина-Хаксли, сформулированной в терминах рефрактерной плотности, проводится анализ чувствительности ответов единичного нейрона к входным сигналам. Варьируется амплитуда стимула-ступеньки тока и амплитуда шума. Модель воспроизводит известные экспериментальные данные многократных измерений спайковой активности в единичном нейроне, которые характеризуются быстротой популяционного спайкового ответа.

Ключевые слова: *модель Ходжкина-Хаксли, модель статистического ансамбля, измерения патч-кламп.*

A.V. CHIZHOV

Ioffe Physical Technical Institute, Russian Academy of Sciences, St Petersburg
anton.chizhov@mail.ioffe.ru

ANALYSIS OF NEURONAL SENSITIVITY TO INPUT SIGNALS WITH THE HELP OF NEURONAL ENSEMBLE MODEL

Analysis of neuronal sensitivity to input signals is performed by using a realistic model of the statistical ensemble of Hodgkin-Huxley-type neurons, formulated in terms of the refractory density. The amplitude of current step stimuli and the noise amplitude are varied. The model reproduces known experimental data of many-trial patch-clamp recordings of spiking activity in single neurons, which reveal rapid reaction of the population firing rate to the stimulus changes.

Keywords: *Hodgkin-Huxley model, model of neural populations, patch-clamp recordings.*

Введение

В работе [1] с помощью электрофизиологических патч-кламп измерений мембранного потенциала в единичном нейроне изучена чувствительность вероятностного спайкового ответа нейрона к быстрому, но слабому изменению входного сигнала. Показано, что в то время как характерное время изменения мембранного потенциала определяется мембранной временной постоянной ($\tau_m = C/G$, где C – мембранная ёмкость, G – проводимость мембраны), на постстимульной гистограмме спайковых ответов наблюдаются скачки, т.е. популяционный спайковый ответ оказывается гораздо быстрее ответа в виде мембранного потенциала. В работе [2] показано, что для возникновения такого быстрого ответа необходима быстрая активация натриевых каналов при достижении мембранным потенциалом порогового уровня. В настоящей работе упомянутые экспериментальные записи воспроизведены с помощью математической модели статистического ансамбля нейронов типа Ходжкина-Хаксли, предложенной в работе [3]. Кроме быстрых компонентов популяционных ответов, модель отражает и медленные. Показано, что для отражения медленных компонентов существенным свойством модели является способность учитывать действие каналов медленной спайковой адаптации (АНР-каналы).

Экспериментальные записи воспроизведены на рис. 1 слева. На рис. 1, А слева показаны ответы нейрона на стимул-ступеньку тока разной

амплитуды. Далее подавалась серия ступенек тока и цветного гауссова шума (рис. 1, В слева).

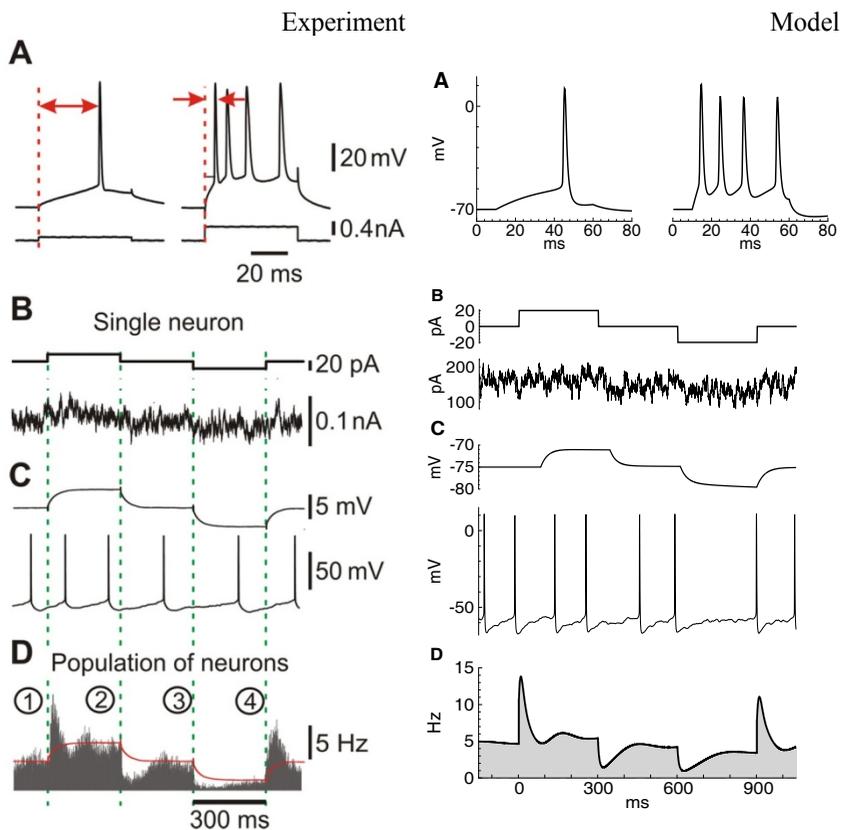


Рис. 1. Эксперимент [1] (слева) и модель (справа):

A – ответы регистрируемого нейрона на подачу ступеньки тока;
 B – ступеньки стимулирующего тока (сверху) и ступеньки тока с наложенным цветным шумом (снизу; $\tau = 5$ ms, амплитуда 20 pA); C – ответы нейрона на стимулы с нижнего и верхнего графиков рисунка B; D – популяционный ответ в виде частоты спайков

Уровень деполяризации нейрона задавался таким, чтобы обеспечить низкочастотную спонтанную спайковую активность. Амплитуда ступенек была небольшой, т.е. вызвала небольшое изменение стационарной

частоты спайков. Пассивный ответ нейрона в случае без дополнительной деполяризации показан на верхнем графике рис. 1, С слева, а активный спайковый ответ в условиях деполяризации – на нижнем графике рис. 1, С слева. Для разных реализаций шума моменты времени спайков получались разными. В качестве популяционного ответа рассматривалось множество ответов одного нейрона на многократное повторение стимула, т.е. гистограмма спайкового ответа или популяционная частота спайков. На рис. 1, D слева показан ответ популяции на стимул, состоящий из ступеней слабого тока и цветного шума. В популяционном ответе можно наблюдать всплески популяционной частоты, причём время возникновения всплесков существенно меньше мембранной постоянной нейрона.

Наиболее эффективной математической моделью популяционных ответов является модель единичной популяции или статистического ансамбля нейронов [3], где под популяцией понимается математическая абстракция – статистический ансамбль бесконечного числа несвязанных друг с другом нейронов, получающих одинаковые входные сигналы и различный для каждого шум. Выходной характеристикой активности популяции является популяционная частота спайков, определяемая как предел числа спайков N нейронов популяции, произошедших в интервал времени Δt при устремлении Δt к нулю и N – к бесконечности.

Популяционные модели можно разбить на два класса. К первому классу так называемых частотных моделей следует отнести те, которые задают связь входных сигналов с мгновенной частотой посредством обыкновенных дифференциальных уравнений или алгебраических соотношений. Второй класс составляют модели, описывающие эволюцию распределения нейронов в пространстве состояний. Такие модели сводятся к одному или нескольким уравнениям в частных производных. Модель, предложенная в наших работах [3,4], в отличие от других, применима к достаточно произвольным реалистичным нейронам типа Ходжкина-Хаксли.

В то же время, она математически выражается в виде одномерных уравнений в частных производных, т.е. обладает высокой вычислительной эффективностью. Такой подход называется Conductance-Based Refractory Density (CBRD) Approach – подход на основе рефрактерной плотности. Эволюция рефрактерной плотности описывается уравнением переноса в пространстве t^* . Также к уравнениям переноса сводится параметризация переменных состояния средних по реализациям шума для нейрона в точке t^* . Именно реализация этого подхода позволяет согласовывать модели нейросети как с регистрациями свойств отдельных нейронов, так и с регистрациями эффектов сетевой активности взаимодействующих популяций [5].

В настоящей работе этот подход применён для анализа активности одиночного нейрона. Следует отметить, что требование быстрой активации натриевых каналов для воспроизведения быстрых популяционных ответов на ступенчатый стимул априори выполнено в популяционной модели, поскольку она использует пороговую редукцию модели типа Ходжкина-Хаксли, т.е. предполагает мгновенную активацию натриевых каналов.

Сравнение CBRD-модели адаптивных нейронов с экспериментом

Экспериментальные записи (см. рис. 1, D слева) хорошо воспроизводятся CBRD-моделью (см. рис. 1, D справа) с параметрами из работы [3]. Следует отметить, что в состоянии низкочастотной активности популяция практически мгновенно реагирует на изменение стимула, причём с явным всплеском активности в ответ на увеличение стимулирующего тока и с временным «торможением» в ответ на гиперполяризационный ток. В то время, потенциал нейрона изменяется медленно, т.е. классические частотные модели, считающие частоту функцией либо тока либо потенциала, принципиально не способны воспроизвести наблюдаемые ответы. Этот факт свидетельствует о преимуществе CBRD-модели в сравнении с частотными моделями.

В численных экспериментах обнаружилось, что для воспроизведения медленных компонент популяционных ответов требуется учёт медленных токов спайковой адаптации (АНР-каналов). Эти АНР-каналы, учтённые в модели, отражают эффективное действие кальций-зависимых калиевых каналов и кинетику кальциевой концентрации. Действительно, как видно из экспериментального рис. 1, А слева, зарегистрированный нейрон характеризовался регулярным паттерном спайковой активности с адаптацией межспайковых интервалов в ответ на стимуляцию ступенькой тока. Такой паттерн активности свидетельствует о действии кальций-зависимых калиевых каналов. Тем самым, моделирование указывает на ещё один механизм, определяющий характер популяционных ответов.

С помощью CBRD-модели можно успешно исследовать реакцию популяции на изменение амплитуды вариаций стимула. Как показано на рис. 2 снизу, наблюдается всплеск популяционной частоты при увеличении амплитуды шума и «торможение» в ответ на уменьшение амплитуды. Модель хорошо воспроизводит экспериментальные наблюдения, показанные на рис. 2 сверху.

Модель позволяет проанализировать условия возникновения скачкообразного популяционного ответа в режимах, отличных от условий экспери-

мента из [1]. Для упрощения, в качестве базового нейрона популяции рассмотрим нейрон-пороговый интегратор с белым гауссовым шумом со следующими параметрами: мембранной константой времени $\tau_m = 10 \text{ ms}$, разностью порога генерации спайка и потенциала покоя $V^T - V_{rest} = 10 \text{ mV}$ и амплитудой шума σ .

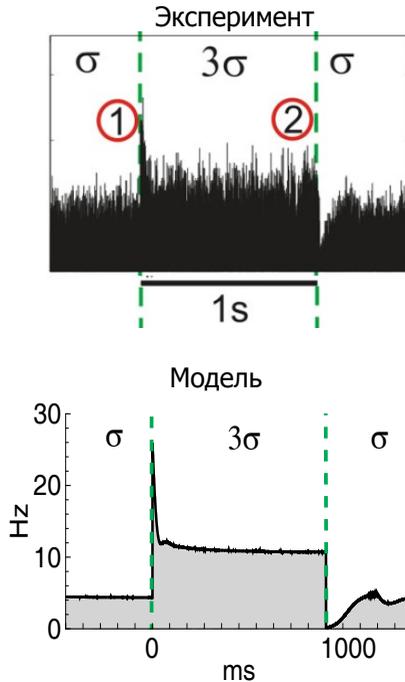


Рис. 2. Ответ регистрируемого нейрона на подачу зашумлённого тока с переменной амплитудой шума σ [1]

Уровень предстимульной спайковой активности зададим посредством уровня деполяризации V_0 , который установился бы на нейроне при отсутствии порогового условия генерации. Ответы CBRD-модели популяции нейронов-пороговых интеграторов показаны на рис. 3 для разных условий предстимульной спайковой активности, определяемой разностью $V_0 - V^T$ и амплитудой шума. На верхних графиках предстимульная активность является подпороговой, т.е. генерация спайков происходит за счёт достижения порога с помощью шума. На нижних графиках предстимульная активность

существенно сверхпороговая. Видно, что скачкообразные ответы популяционной частоты сильнее проявляются в случаях сверхпороговой предстимульной активности, а всплески частоты проявляются в условиях малой амплитуды шума.

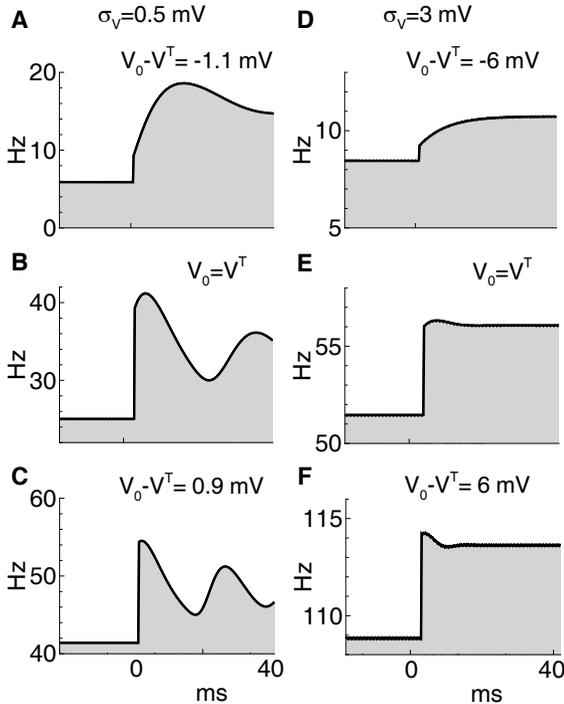


Рис. 3. Изменение спайковой частоты популяции нейронов-пороговых интеграторов в ответ на стимуляцию ступенькой тока в условиях различных значений амплитуды вариаций потенциала σ_V (амплитуда шума $\sigma = \sigma_V \sqrt{2}$) и подпороговой деполяризации V_0 , сравниваемой с пороговым значением V^T

Заключение

Актуальным вопросом нейрофизиологии является описание экспериментальных знаний с помощью математических моделей. В данной работе показано, что ранее предложенная популяционная модель [3] хорошо воспроизводит экспериментальные данные работы [1], указывает на

роль механизма адаптации в формировании медленных компонентов популяционных спайковых ответов и позволяет проанализировать зависимость от параметров характера ответов в более простой модели популяции нейронов-пороговых интеграторов.

Список литературы

1. Tchumatchenko T., Malyshev A., Wolf F., Volgushev M. (2011) Ultrafast population encoding by cortical neurons. //J. Neurosci, 31: 12171–12179.
2. Ilin V., Malyshev A., Wolf F., Volgushev M. (2013) Fast Computations in Cortical Ensembles Require Rapid Initiation of Action Potentials. // J. Neurosci, 33: 2281–2292.
3. Chizhov A.V., Graham L.J. Population model of hippocampal pyramidal neurons, linking a refractory density approach to conductance-based neurons. //Physical Review E., 2007. V.75. 011924.
4. Chizhov A.V., Graham L.J: Efficient evaluation of neuron populations receiving colored-noise current based on a refractory density method // Phys. Rev. E, 2008. 77: 011910.
5. Chizhov A.V. Conductance-based refractory density model of primary visual cortex. // J. Comp. Neuroscience, 2014. V. 36(2). P. 297-319.

Н.Г. БИБИКОВ, С.В. НИЗАМОВ

Акустический институт им. акад. Н.Н. Андреева, Москва
nbibikov1@yandex.ru

**ВРЕМЕННЫЕ ПРИЗНАКИ ЗВУКА, ВЫЗЫВАЮЩИЕ
ОТВЕТЫ НЕЙРОНОВ СЛУХОВОЙ СИСТЕМЫ**

В головном мозге позвоночных животных существуют несколько последовательно расположенных ядер, осуществляющих анализ информации о принимаемом звуке, сводящийся, в основном к выявлению временных особенностей сигнала в отдельных частотных каналах. В связи с нелинейностью нейрональной обработки, корреляционный подход недостаточен для понимания этих процессов. Предложены методики, позволяющие оценить вклад текущей амплитуды и текущей скорости изменения амплитуды в реакцию клетки, и приведен пример их применения.

Ключевые слова: *нейрон, слуховая система, кодирование огибающей, обратная триггерная корреляция, амфибии, адаптация.*

N.G. BIBIKOV, S.V. NIZAMOV

N.N. Andreyev Acoustics Institute, Moscow
nbibikov1@yandex.ru

SOME TEMPORARY FEATURES, THOSE EVOKES RESPONSES OF NEURONS IN THE AUDITORY SYSTEM

In the vertebrate brain there are several consecutive nuclei those proceed the analysis of the received sound. This analysis based mainly on the identification of temporal characteristics of the signal in different frequency channels. Due to the nonlinearity of neuronal processing, correlation approach is insufficient for understanding these processes. Some methods to assess the contribution in the neuronal response the instantaneous amplitude and the rate of amplitude changes. The example of their application is presented.

Keywords: *neuron, auditory system, coding envelope, backward triggered correlation, amphibians, adaptation.*

Введение

При исследовании и моделировании преобразования сигналов в слуховой системе обычно предполагают, что образцом эффективного анализа звука являлся метод Фурье – разложение временной функции изменения давления на барабанной перепонке по определенным математическим правилам на множество компонент, соответствующих различным несущим частотам звукового сигнала. Весьма ярко это предположение было сформировано еще в гипотезе Гельмгольца о существовании подобия струн в улитке внутреннего уха. Относительно структур, расположенных во внутреннем ухе, эта гипотеза оказалась верна. Однако она касалась, естественно, только приемной части системы и никак не затрагивала функционирование слухового анализатора головного мозга. Более того, при дальнейшем развитии эта гипотеза приобрела несколько неожиданное приложение в виде акустического закона Ома, который гласил, что слуховая система использует только амплитудный спектр поступающего стимула, игнорируя соотношение фаз между частотными компонентами. Несмотря на то, что абсурдность этого положения в общем виде представляется очевидной (квазичастотная модуляция не похожа на амплитудную, последовательность щелчков не похожа на непрерывный шум и т.д.), оно до сих пор фигурирует в некоторых учебных пособиях.

Более того, в 60-80-е годы прошлого столетия усилия значительного числа физиологов слуха были направлены на изучение гипотетических механизмов, обеспечивающих повышение частотной избирательности нейронов слуховой системы на участках от улитки внутреннего уха до слуховой зоны коры головного мозга. В принципе, подобные механизмы могут существовать, например, за счет эффектов латерального торможения между нейронами с близкими оптимальными частотами. Они, возможно, даже реализуются, например, в узкоспециализированной зоне коры усатой летучей мыши, эффективно использующей Допплеровский сдвиг частоты излучаемого моночастотного сигнала для вычисления скорости сближения с источником эхосигнала [1]. Однако в современных публикациях найти нейроны с высокой частотной избирательностью в слуховой коре других животных фактически не удастся. Более того, при популяционных исследованиях вырисовывается прямо противоположный результат: острота частотной настройки отдельных нейронов и точность тонопической организации каждого отдела монотонно падают от слухового нерва до вторичных корковых зон [2]. При использовании методов функционального магнитного резонанса обнаружилось, что частотная организация слуховой поры человека представляет собой крайне сложную мозаику, в которой только лишь иногда удастся выявить упорядоченное расположение нейронов с монотонно изменяющейся частотной настройкой. Кроме того, оказалось, что распределение локусов с разными частотными настройками сугубо индивидуально и различается у разных индивидуумов не только количественно, но и качественно [3].

Если подойти к работе слуховой системы с точки зрения здравого смысла, то эти результаты представляются вполне естественными. В самом деле, задача слуховой системы не сводится к оптимальному различению частоты тональных сигналов. Такие требования принципиальны, быть может, для профессиональных музыкантов. Для подавляющего числа животных и человека функция слуховой системы сводится к адекватному распознаванию сигналов, жизненно важных для существования. Наряду с коммуникационными сигналами, это множество сигналов окружающей среды, характеризующих ее состояние, сигнализирующих о появлении опасности. Эти сигналы, как правило, характеризуются сложной частотно-временной конфигурацией. Для них весьма характерно наличие частотной и амплитудной модуляции в сравнительно низкочастотном диапазоне. Напомним, что при несущей частоте сигнала, не воспроизводимой в импульсации одиночного нейрона, после фильтрации в улитке частотная модуляция фактически также сводится к модуляции амплитуды сигнала в отдельных волокнах. Отметим также, что после этой фильтрации сигнал любой сложности представлен в виде набора тональных сигналов, модулированных по амплитуде низ-

кочастотным шумом в полосе от нуля до ширины пропускания фильтра. Именно набор таких сигналов и поступает в мозг в виде импульсного кода популяции волокон слухового нерва.

Вся дальнейшая обработка сигнала в ядрах головного мозга, включенных в слуховой путь, сводится к выявлению особенностей временного течения стимула в отдельных частотных каналах и в сопоставлении этого течения для различных частотных полос. Как осуществляется этот анализ, до сих пор остается малоизученным. Наиболее распространенным способом выявления временных особенностей сигнала, вызывающих реакцию исследуемого нейронного элемента, был и остается метод обратной триггерной корреляции, сводящийся к синхронному усреднению формы сигнала, непосредственно предшествующей генерации спайка [4]. Метод чаще всего применяют с использованием широкополосных входных сигналов, суммируя предшествующий спайку сигнал не целиком, а по отдельным частотным каналам [5,6]. В результате получают так называемое двумерное спектрально-временное рецептивное поле клетки, демонстрирующее, на какие частотные области и с каким временным течением амплитуды сигнала в этой области возникает реакция исследуемого нейрона. Аргументация, на которой построен этот метод, фактически также исходит из методологии преобразования Фурье. Несмотря на определенные успехи, достигнутые с использованием данной методики, последующий анализ показал весьма умеренную эффективность частотно-временного рецептивного поля для предсказания ответа клетки на реальные сигналы, амплитуда которых может хаотически изменяться во времени, причем обычно с довольно низкими частотами. Причины этих результатов кроются в существенной нелинейности систем обработки информации нейронами слухового пути. Помимо очевидной нелинейности, связанной с порогом генерации спайка, существует еще множество нелинейных операций, осуществляемых и в каждом конкретном нейроне и в ансамбле нейронов. Часть этих операций, связанных с пластичностью синаптической передачи и процессами, сопровождающими генерацию спайка, включают в себя и элементы памяти. Эти влияния могут определяться длительностью времени после разряда нейрона, числом предшествующих спайков и рядом других причин. Стоит подчеркнуть, что они никак не сводятся только к учету величины одного или двух предшествующих интервалов, которые могут применяться при использовании методики, основанной на Марковских процессах [7].

В этой связи мы поставили задачу прямой непосредственной оценки тех особенностей огибающей звукового стимула, которые вызывают ответ нейрона. На первом этапе мы постарались выяснить два простых вопроса. Первый из них сводится к тому, осуществляет ли нейрон операцию детектиро-

вания огибающей, то есть, отслеживает ли от изменения амплитуды при ее значениях меньше среднего. Второй, непосредственно связанный с этим, вопрос заключается в том, отвечает ли нейрон на мгновенную амплитуду тонального сигнала, модулированного низкочастотным шумом, или на производную амплитуды, то есть скорость ее изменения во времени.

Методика

Работа велась на нейронах продолговатого и среднего мозга травяных лягушек, и особенности предъявления звуковых сигналов и методики регистрации внеклеточной активности одиночных нейронов многократно описывались ранее [8-11]. Сигналами служили длительные (минуты) тоны, которые были модулированы по амплитуде повторяющимися отрезками низкочастотного шума. Использовались три полосы этого шума: 0–15; 0–50 и 0–150 Гц и для каждой из этих полос длительность повторяющихся структуры отрезков сигнала могли принимать несколько фиксированных значений в интервале от 256 до 4028 мс. Стимулы подавались на ухо, которое являлось возбуждающим для исследуемой нейронной структуры. Несущая частота сигнала (не воспроизводимая во временном распределении нейрональной активности) составляла от 0,5 до 2,4 кГц и всегда соответствовала оптимальной частоте исследуемой клетки. Среднее значение уровня превышало порог реакции на 20–30 дБ, а глубина модуляции, измеряемая в терминах среднеквадратичного отклонения шума, составляла 20–30 %. Во всех исследованных случаях получали взаимно корреляционную функцию между формой повторяющегося участка модуляции и гистограммой распределения вероятности появления спайков на этом участке (циклическая гистограмма реакции).

В рамках настоящего исследования мы постарались оценить зависимость вероятности генерации спайка одновременно от двух параметров: мгновенной амплитуды сигнала и мгновенной скорости ее изменения. Кроме того, нас интересовал вопрос: осуществляется ли в нейронных структурах слухового пути детектирование не только несущей, но и огибающей сигнал? Для указанных целей было использовано два достаточно прямых метода. В соответствии с первым из них мы представили огибающую сигнала на повторяющемся участке огибающей в виде двумерной функции в координатах амплитуда сигнала – скорость ее изменения.

На рис. 1, а приведена форма одного из использованных повторяющихся участков модуляции, Здесь же показан спектр модулирующей функции и ее двумерное представление, которое и использовали в данном методе. Характеристики нормированы таким образом, что экстремальные значение имеют единичный модуль.

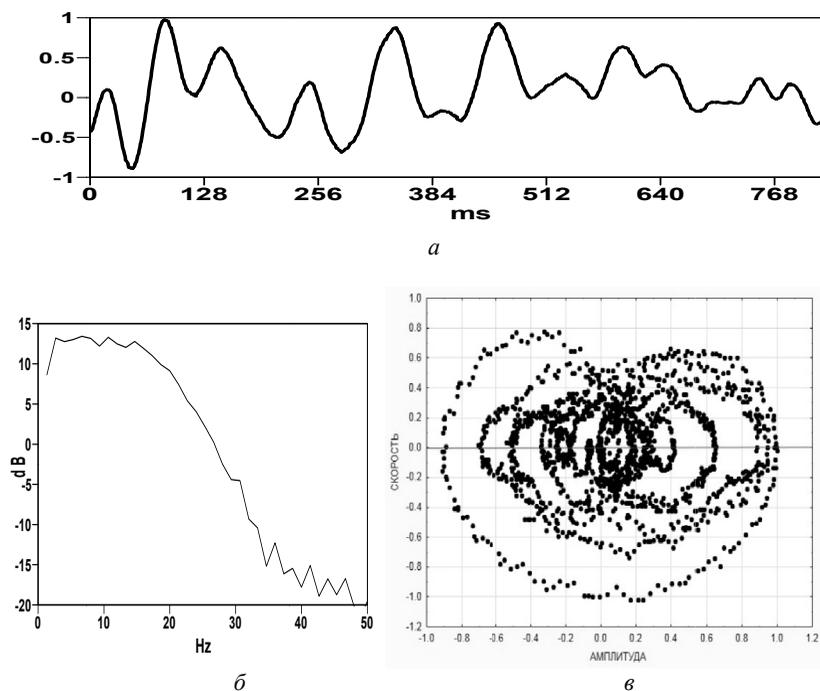


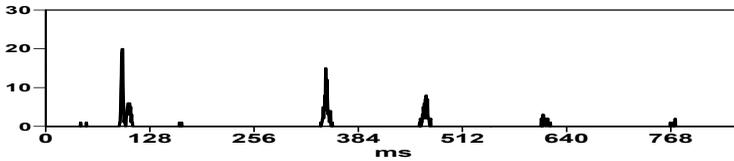
Рис. 1. Характеристики использованного повторяющегося отрезка модулирующего сигнала: форма модуляции (а), ее спектр (б) и двумерное представление огибающей в координатах «амплитуда – скорость ее изменения» (в)

В соответствии со вторым методом мы разделяли тот же период модуляции на четыре участка: нарастание амплитуды от минимума до среднего значения, нарастание амплитуды от среднего значения до максимума, падение амплитуды от максимума до среднего значения и падение амплитуды от среднего значения до минимума. После окончания эксперимента суммировались все значения циклической гистограммы реакции, попадающие на каждый из этих четырех участков огибающей. Вначале такой подсчет осуществлялся без относительного сдвига сигнала и реакции, а затем осуществлялся их циклический сдвиг друг относительно друга. Производимая операция эквивалентна получению четырех корреляционных функций между циклической гистограммой и функцией, представленной единичными значениями только на участках сигнала с каждой из указанных особенностей огибающей. После этого осуществлялся поиск наибольшего значения, для

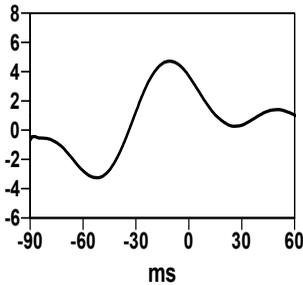
каждой из четырех этих функций и выбирался наибольший из этих экстремумов, причем фиксировалось, при каком значении задержки он наблюдался. Фиксировался также и второй по величине максимум, наблюдавшийся для одного из других участков огибающей.

Результаты

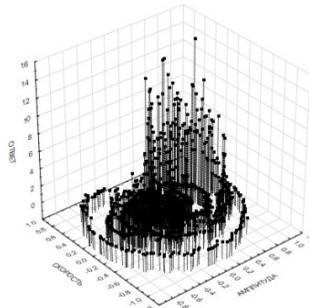
В настоящей работе мы рассмотрели только один пример использования всех описанных выше методов. Иллюстрируемая клетка слухового центра среднего мозга имела характеристическую частоту 1.05 кГц и ее реакция на тональный отрезок, хотя и продолжалась все время воздействия имела выраженную адаптацию. На рис. 2, *a* приведена циклическая гистограмма ответа этой клетки на сигнал характеристической частоты, модулированный повторяющимися участками низкочастотного шума, иллюстрированного на рис. 1. Внизу слева приведена функция корреляции между циклической гистограммой и периодом огибающей.



a



b



c

Рис. 2. Характеристики реакции нейрона, расположенного в слуховом центре среднего мозга травяной лягушки, на тональный сигнал с повторяющимися отрезками огибающей, иллюстрированных рис. 1:

a – форма циклической гистограммы реакции; *b* – корреляционная функция;

c – трехмерное представление реакции нейрона в координатах «амплитуда сигнала – скорость ее изменения»

Обычно такая форма корреляционной функции интерпретируется следующим образом: на нейрон поступает возбуждающее воздействие с весьма незначительной задержкой, после чего следует тормозное воздействие с задержкой порядка 50 мс. Ясно, что такое объяснение плохо соответствует возможной реальной картине входного возбуждения. В частности, обращает на себя внимание нереально малая задержка между максимумом сигнала и максимумом ответа. Заметим, что в некоторых других нейронах такая задержка отсутствовала вовсе или даже принимала отрицательные значения.

Представляется разумным рассмотреть ту же реакцию с учетом не только амплитуды воздействия, но и скорости ее изменения. Трехмерный график на рис. 2, *в* представляет зависимость реакции клетки (вертикальная ось) сразу от двух координат. Заметим, что на этом графике отсутствует сдвиг между ответом и реакцией, причем любая задержка ответа должна приводить к повороту ответной реакции в направлении против часовой стрелки. Однако даже в такой конфигурации хорошо видно, что ответ возникает, прежде всего, на участках, соответствующих положительным значениям скорости изменения амплитуды.

Еще более четко эта особенность ответа проявляется при раздельном рассмотрении реакций на четыре, выделенных нами участка огибающей. Полученные в результате такого анализа результаты сведены в табл. 1. Из приведенных данных вытекает, что оптимальным для вызова ответа клетки оказывается участок нарастания амплитуды от минимума до среднего значения. При этом оптимальная задержка реакции на этот участок составляет 42 мс, при относительной величине ответа 75. Вторым по эффективности генерации спайка является участок нарастания амплитуды от среднего значения до максимума при задержке 22,5 мс.

Таблица 1

Сравнительная эффективность четырех участков огибающей

	Нар. ниже ср.	Нар. выше ср.	Сп. выше ср.	Сп. ниже ср.
I-выбор	75/42 мс	0.19	0.02	0.18
II-выбор	0.07	58/22.5 мс	0.06	0.04

В остальных ячейках таблицы указаны нормированные по отношению к максимуму значения, существующие при соответствующих величинах задержки для трех остальных участков огибающей. Как следует из данных, представленных в таблице, при указанных выше задержках остальные участки сигнала, вызывали ответы, по крайней мере, в пять раз слабее оптимума. Таким образом, результаты проведенного анализа позволяют утверждать, что при данных условиях стимуляции реакция данной клетки опре-

деляется не амплитудой сигнала, а скоростью ее изменения. При этом наиболее эффективный ответ вызывается сигналом, имеющим амплитуду ниже средней, то есть на начальном участке нарастания амплитуды. Это вполне соответствует обнаруженному нами ранее эффекту реакции нейронов этого ядра на одиночный декремент амплитуды [11].

Заметим, что приведенный результат служит только для иллюстрации общих положений, сформулированных в начале работы. Популяционные данные свидетельствуют как о значительном разнообразии характеристик нейронов при действии одного и того же сигнала, так и о возможности существенного изменения в выборе предпочтительного участка при смене спектра модулирующей функции. Изменения среднего уровня несущей и глубины модуляции играют значительно меньшую роль.

Заключение

Для изучения механизмов анализа нейронами слухового пути временных признаков звука было осуществлено прямое сопоставление реакции, как с мгновенной амплитудой тонального сигнала, модулированного фиксированными отрезками низкочастотного шума, так и со скоростью изменения амплитуды. Показано, что в адаптированном режиме для некоторых клеток возбуждение обусловлено не столько абсолютной амплитудой сигнала, сколько скоростью ее изменения. Признаки звукового сигнала, определяющие ответ нейрона, могут меняться при изменении временных особенностей модулирующей функции.

Работа поддержана грантом РФФИ 12-04-01370.

Список литературы

1. Suga N. Amplitude spectrum representation in the Doppler-shifted-CF processing area of the auditory cortex of the mustache bat // *Science*, 1977. V. 196. №. 4285. P. 64-67.
2. Atencio C.A., Sharpee V. O., Schreiner C.E. Receptive field dimensionality increases from the auditory midbrain to cortex // *J. of neurophysiology*, 2012. V. 107. № 10. P. 2594-2603.
3. Moerel M., De Martino F., Santoro R., Ugurbil K., Goebel R., Yacoub E. Formisano E.. Processing of natural sounds: characterization of multippeak spectral tuning in human auditory cortex // *J. of Neuroscience*, 2013. V. 33. №. 29. P. 11888-11898.
4. De Boer E., De Jongh H.R. On cochlear encoding: Potentialities and limitations of the reverse-correlation technique // *J. of the Acoustical Society of America*, 1978. V. 63. № 1. P. 115-135
5. Zhao L., Zhaoping L. Understanding auditory spectro-temporal receptive fields and their changes with input statistics by efficient coding principles // *PLoS computational biology*, 2011. V. 7. №. 8. P. e1002123.

6. Bandyopadhyay S., Young E.D. Nonlinear temporal receptive fields of neurons in the dorsal cochlear nucleus // *J. of neurophysiology*, 2013. V. 110. №. 10. P. 2414-2425.
7. Britvina T., Eggermont J. J. A Markov model for interspike interval distributions of auditory cortical neurons that do not show periodic firings // *Biological cybernetics*, 2007. V. 96. №. 2. С. 245-264.
8. Бибиков Н.Г., Стогова Е.В. Временные особенности реакции нейронов слуховой системы лягушки на тональные отрезки с разной частотой модуляции // *Ж. эвол. биох. физиол.*, 2009. Т. 45. № 1. С. 80-91.
9. Бибиков Н.Г., Низамов С.В. Анализ активности слуховых нейронов продолговатого мозга лягушки при действии тонов, модулированных низкочастотным шумом // *Биофизика*, 2009. Т. 54. № 5. С. 921-934.
10. Бибиков Н.Г. Корреляция нейронных реакций кохлеарного ядра с низкочастотной амплитудной модуляцией тонального сигнала // *Акустич. журнал*, 2014. Т. 60. № 5. С.555-566.
11. Бибиков Н.Г. Реакция нейронов слухового центра среднего мозга лягушки на временное уменьшение амплитуды сигнала – некоторые нейрофизиологические корреляты слуховой иллюзии и фонемного различения // *Сенсорные системы*, 2007. Т. 21. №1. С. 72-86.

О.Е. ДИК¹, А.Л. ГЛАЗОВ²

¹ Институт физиологии им. И.П. Павлова РАН, Санкт-Петербург,

² Физико-технический институт им. А.Ф. Иоффе РАН, Санкт-Петербург
dickviola@gmail.com

МУЛЬТИФРАКТАЛЬНЫЙ АНАЛИЗ ТРЕМОРА РУКИ ЧЕЛОВЕКА ПРИ ДВИГАТЕЛЬНОЙ ПАТОЛОГИИ*

Исследованы мультифрактальные свойства произвольных колебаний (тремора), возникающих при выполнении человеком определенной двигательной задачи (при поддержании изометрического усилия пальцами руки). Определены вейвлетные и мультифрактальные параметры, позволяющие находить корреляции между клиническими проявлениями тремора до начала лечения, их уменьшением после приема лекарственных препаратов и изменением этих параметров. Предложенный аналитический подход к изучению интегративной деятельности центральной нервной системы в ходе реализации двигательной задачи, позволяет количественно оценить степень отклонения двигательной функции от нормы.

* Данная работа выполнена при поддержке Программой Президиума РАН “Фундаментальные науки – медицине в 2014”.

Ключевые слова: *непроизвольные колебания, первичный паркинсонизм, степень мультифрактальности, глобальный вейвлетный спектр.*

O.E. DICK¹, A.L. GLAZOV²

¹Pavlov Institute of Physiology, Russian Academy of Sciences, St. Petersburg

²Toffe Physical Technical Institute, Russian Academy of Sciences, St. Petersburg
dickviola@gmail.com

MULTIFRACTAL ANALYSIS OF TREMOR OF THE HUMAN HAND UNDER THE MOTOR DYSFUNCTION

Multifractal properties of involuntary shaking (tremor) arising during the performance of the motor task (sustaining effort of fingers under isometric conditions) have been examined. The wavelet and multifractal parameters have been gained. These parameters allow us to find correlations between clinic symptoms of tremor before the antiparkinsonian treatment, their decrease after drug administration and changes of the parameters. The suggested analytic approach for study of integrative activity of the central nervous system during realization of the motor task enables to estimate quantitatively the degree of deviation of the motor function from the healthy one.

Keywords: *involuntary oscillations, primary parkinsonism, degree of multifractality, global wavelet spectrum.*

Введение

Известно, что колебательные ритмы сердца, мозга, дыхания, шаговый ритм при движении человека вариабельны, т.е. проявляют нерегулярные флуктуации, зависящие от возраста и состояния здоровья [1, 2]. Эти флуктуации обладают свойством фрактальности, демонстрируя некоторую повторяемость в широком диапазоне масштабов. Эта повторяемость не является полной, но сохраняется после усреднения статистически независимых выборок временного ряда, описывающего колебательный процесс. Непроизвольные колебания (тремор), возникающие при выполнении человеком определенных двигательных задач, например, при поддержании усилия пальцами руки, также обладают свойствами фрактальной динамики [3]. Тремор может быть вызван разными причинами, например, механическим резонансом в мышцах и подвижных звеньях скелета, или разрядами в транскортикальной петле между соматосенсорной и двигательной зонами

коры [4]. Важно, что в нормальных условиях произвольные колебания имеют малую амплитуду и не мешают выполнению движения. В силу сочетания кратковременной декорреляции биологических паттернов, обусловленной их зашумленностью, и долговременной корреляции, связанной с фрактальной структурой паттернов, биологические сигналы демонстрируют различный локальный скейлинг [5]. Динамика таких колебаний может быть описана с помощью техники мультифракталов. Мультифрактальность здорового мозга обнаруживается при выполнении сложных зрительно - двигательных задач [6], во время различных фаз сна [7], во время эпилептических разрядов мозга [8, 9] и в паттернах ЭЭГ у пациентов с неврологическими нарушениями, связанными с тревожно-фобическими расстройствами [10]. Однако вопрос о мультифрактальных особенностях тремора остается открытым.

Цель работы – исследовать мультифрактальные характеристики тремора руки здорового человека и пациентов с двигательной патологией для выявления количественных различий в возможностях человека выполнять определенную двигательную задачу. В качестве патологии рассматриваются нарушения, связанные с болезнью Паркинсона.

Методика

Для анализа произвольных колебаний использованы результаты тестирования 11 здоровых испытуемых в возрасте от 45 до 56 лет и 11 больных первичным паркинсонизмом в возрасте от 41 до 63 лет с двусторонними проявлениями акинезии и тремора. Двигательная задача заключалась в управлении изометрическим напряжением мышц с возможностью слежения за величиной усилия по смещению меток на экране монитора. Испытуемые сидели за столом перед монитором и нажимали пальцами рук на платформы с тензочувствительными датчиками, которые преобразовывали силу давления каждой руки в электрический сигнал. Жесткость платформ обеспечивала регистрацию усилия в изометрическом режиме, то есть без видимого смещения пальцев в точке контакта с измерительным элементом. Регистрация изометрического усилия производилась в течение 50 секунд в двух типах тестов: в первом испытуемый удерживал усилие пальцами снизу вверх, а тыльная сторона ладони обеих выпрямленных рук прижималась к основанию платформы; во втором тесте усилие удерживалось сверху вниз пальцами выпрямленных вперед рук. В день наблюдения пациентами с болезнью Паркинсона до момента регистрации усилия никакие лекарства не применялись. Обычно такие пациенты для возмещения дефицита дофамина получали антипаркинсонический препарат мадопар (комбинация леводопы

с бенсаразидом в дозе 200/50 мг) или наком (комбинация леводопы с карбидопой в дозе 250/25 мг). Бенсаразид и карбидопа являются ингибиторами дофа-декарбоксилазы, снижающими образование дофамина в периферических тканях, что косвенным образом приводит к повышению количества леводопы, поступающей в ЦНС. в которой она превращается в дофамин, и, пополняя его запасы в базальных ганглиях, стимулирует дофаминовые рецепторы, обеспечивает лечебный эффект при паркинсонизме.

Регистрируемая траектория изометрического усилия содержала медленный тренд и быструю произвольную компоненту (тремор), которая была выделена из полученной траектории с помощью процедуры MATLAB.

Для оценивания степени различия физиологического и патологического тремора был применен метод максимумов модулей вейвлет преобразования [11].

Запишем вейвлет преобразование временного ряда $x(t)$, описывающего исследуемый тремор

$$W(a, t_0) = (1/a) \int_{-\infty}^{+\infty} x(t) \psi^*((t-t_0)/a) dt,$$

где a – параметр масштаба, t_0 – параметр временного сдвига, $\psi((t-t_0)/a)$ – вейвлет функция, полученная из базисного вейвлета $\psi(t)$ путем масштабирования и сдвига по времени, символ * означает комплексное сопряжение. Таким образом, вейвлет преобразование тремора состоит в разложении его на элементарные функции, связанные с масштабированием и сдвигом базисной функции. В качестве базисной функции используем комплексный

вейвлет Морле $\psi(t) = \pi^{-1/4} e^{i\omega t} e^{-t^2/2}$. Значение $\omega = 2\pi$ обеспечивает простое соотношение между масштабом a и частотой f : $f = 1/a$.

Величина модуля вейвлетного спектра $|W(f, t_0)|$ характеризует наличие и интенсивность частоты f в момент t_0 в анализируемом треморе, а величина $|W(f, t_0)|^2$ описывает мгновенное распределение энергии тремора по частотам, то есть локальный спектр энергии тремора в момент времени t_0 . Инте-

$$E(f) = \int_{t_1}^{t_2} |W(f, t_0)|^2 dt_0$$

грал определяет глобальный вейвлетный спектр, то есть интегральное распределение энергии вейвлетного спектра тремора по частотам в интервале времени $[t_1, t_2]$.

Информация о возможной мультифрактальной структуре исследуемого сигнала и ее локализации t_0 отражается в асимптотическом поведении коэффициентов $|W(f, t_0)|$ при малых значениях a , и, соответственно, больших значениях f . Чем быстрее уменьшаются вейвлет коэффициенты при $a \rightarrow 0$, тем более регулярен сигнал в окрестности точки t_0 . Медленное уменьшение

вейвлет коэффициентов при $a \rightarrow 0$ в окрестности точки t_0 свидетельствует о наличии сингулярности (особенности в виде изрезанности сигнала) в этой точке. Таким образом, скорость изменения модуля вейвлет коэффициентов позволяет определять наличие или отсутствие сингулярностей сигнала. Степень сингулярности сигнала $x(t)$ в точке t_0 описывается экспонентой Гельдера, $h(t_0)$, то есть наибольшей экспонентой, при которой анализируемый сигнал может быть представлен суммой компонент: полинома $P_n(t)$, описывающего регулярное поведение и слагаемого, описывающего нерегу-

лярное поведение: $x(t) = P_n(t) + c|t - t_0|^{h(t_0)}$. В силу простой зависимости

$W(a, t_0) \sim a^{h(t_0)}$ при $a \rightarrow 0$, экспонента Гельдера может быть вычислена

$h(t_0) \sim \log_{10} W(a, t_0) / \log_{10} a$. Однако при возрастании величины a влияние соседних сингулярностей может приводить к неточности вычисления, поэтому, мы определяли экспоненты Гельдера на основании статистического описания локальных сингулярностей с помощью частичных функций [11].

С использованием глобальных вейвлетных спектров и метода максимумов модулей вейвлет преобразования, были получены значение максимума глобальной энергии сигнала E_{\max} и два мультифрактальных параметра: а) ширина спектра сингулярности $\Delta h = h_{\max} - h_{\min}$, б) асимметрия спектра сингулярности $\Delta = |\Delta_2 - \Delta_1|$, где $h_{\max} = h(q = -5)$ и $h_{\min} = h(q = 5)$ – максимальное и минимальное значения экспоненты Гельдера, соответствующие минимальной и максимальной флуктуациям тремора, $\Delta_1 = h_{\max} - h_0$ и $\Delta_2 = h_0 - h_{\min}$, $h_0 = h(q = 0)$.

Ширина спектра сингулярности Δh характеризует степень мультифрактальности (чем больше Δh , тем больше степень мультифрактальности). Параметр асимметрии спектра Δ определяет где, в области сильных сингулярностей (при $q > 0$), или в области слабых сингулярностей (при $q < 0$), в основном находятся экспоненты Гельдера.

Для сравнения средних значений в каждой из исследуемых групп применялся критерий Стьюдента.

Результаты

Примеры тремора колебаний траектории изометрического усилия для больного с дрожательной формой болезни Паркинсона показаны на рис. 1. Амплитуда тремора для больного в 2,5 раза превышает амплитуду тремора здорового добровольца. Различия в спектрах мощности тренда были незначительны, а для тремора наблюдалось значительное увеличение спектральной плотности энергии в частотном диапазоне от 1 до 6 Гц по сравнению с

этим показателем для здорового человека.

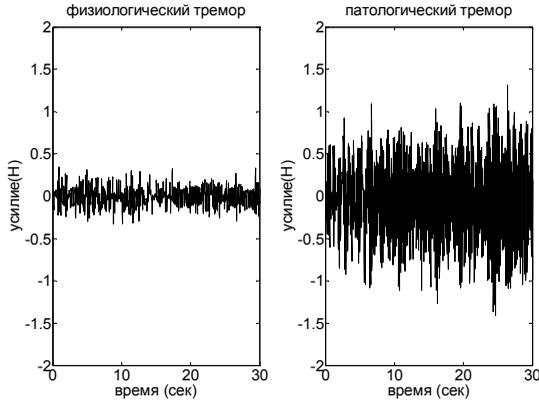


Рис. 1. Примеры тремора руки здорового человека и больного первичным паркинсонизмом

Нелинейные зависимости $\tau(q)$, представленные на рис. 2, свидетельствуют о большом числе экспонент Гельдера $h(q)$ для тремора.

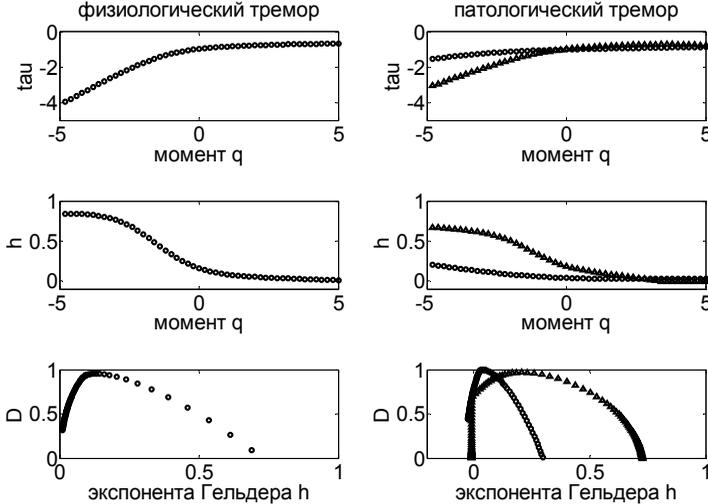


Рис. 2. Мультифрактальные характеристики тремора. На рисунках справа – характеристики для больного с дрожательной формой болезни Паркинсона до и после приема больным антипаркинсонического препарата

(линии, обозначенные маркером “о” и “Δ” соответственно)

Мультифрактальность характерна как для патологического, так и для физиологического для тремора руки человека. Однако произвольные колебания руки здорового человека, возникающие при выполнении поставленной двигательной задачи, характеризуются большей, по сравнению с тремором руки больного с синдромом паркинсонизма, шириной спектра сингулярности и, следовательно, большей степенью мультифрактальности. Уменьшение ширины спектра сингулярности показывает уменьшение неоднородности паркинсонического тремора и снижение степени мультифрактальности. Асимметрия спектра сингулярности также больше для физиологического тремора ($\Delta \approx 0,4$), а для патологических колебаний величина Δ не превышает 0,2. Уменьшение обоих мультифрактальных параметров для тремора пациентов с болезнью Паркинсона происходит благодаря снижению вклада слабых флуктуаций (при $q < 0$). Широкий спектр сингулярности физиологического тремора соответствует как антикоррелированной динамике последовательных значений траектории изометрического усилия (при $h < 0,5$), так коррелированной (при $h > 0,5$). Уменьшение h_{\max} при паркинсоническом треморе по сравнению с физиологическим свидетельствует о повышении степени антикорреляции, то есть колебания становятся менее гладкими и более случайными.

Через три часа после приема больным антипаркинсонического препарата в привычной для него дозе наблюдается увеличение ширины и асимметрии спектра сингулярности, что означает приближение значений этих мультифрактальных параметров к значениям, характерным для тремора руки здорового человека.

Нахождение мгновенного распределения энергии тремора по частотам $|W(f, t_0)|^2$ и интегрального распределения энергии вейвлетного спектра тремора по частотам в интервале времени $[t_1, t_2]$, то есть глобального вейвлетного спектра, $E(f)$, позволило определить значительное повышение максимума глобальной энергии тремора E_{\max} для пациента с болезнью Паркинсона по сравнению с этим значением, полученным для здорового человека (рис. 3).

Максимальное значение E_{\max} для физиологического тремора находится в диапазоне альфа ритма. Для патологического тремора это значение сдвинуто в диапазон тета ритма. После действия антипаркинсонического препарата происходит многократное уменьшение глобальной энергии вейвлетного спектра практически до значения, соответствующего здоровому добровольцу. Подобная динамика энергетических и мультифрактальных параметров наблюдалась в произвольных колебаниях у 65 % пациентов с синдромом

паркинсонизма. В треморе остальных 35 % больных найдены менее значительные изменения параметров.

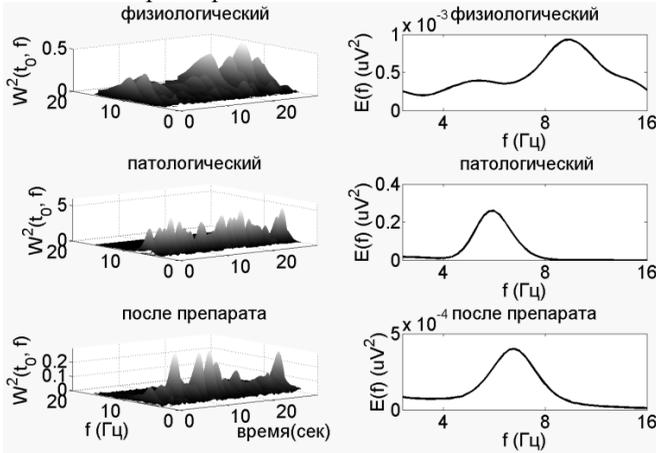


Рис. 3. Примеры частотно-временных распределений энергии $|W(a, t_0)|^2$ тремора и глобальных вейвлетных спектров для здорового человека и больного, страдающего синдромом паркинсонизма до и после приема больным антипаркинсонического препарата

На рис. 4 представлены сравнительные усредненные данные. Значимые отличия между состояниями (патологический или физиологический тремор) выявляются по всем рассматриваемым параметрам E_{\max} , Δh и Δ . Статистика $p < 0,05$ получена для обеих рук в двух тестах. Во всех тестах глобальная энергия физиологического тремора ($E_{\max} \approx 8 \times 10^{-4}$) намного ниже энергии паркинсонического тремора ($E_{\max} \approx 2 \times 10^{-1}$). Ширина и асимметрия спектра сингулярности, наоборот, наибольшие ($\Delta h \approx 0,8$ и $\Delta \approx 0,4$) для произвольных колебаний руки здорового человека.

Клинические проявления патологического тремора коррелировали во-первых, со значительным повышением глобальной энергии вейвлетного спектра и, во-вторых, с уменьшением ширины и асимметрии спектра сингулярности. Исчезновение клинических признаков патологического тремора, регистрируемое у 65 % пациентов с синдромом паркинсонизма на фоне приема антипаркинсонических препаратов, сопровождалось приближением мультифрактальных и энергетических параметров к значениям, характерным для здоровых лиц. Для 35 % пациентов через 3 часа после приема лекарственного препарата глобальная энергия физиологического тремора или не снижалась, или снижалась в меньшей степени, а мультифрактальные

параметры, увеличиваясь, не достигали физиологических значений. Таким образом, улучшение функционального состояния (снижение амплитуды патологического тремора) соответствовало уменьшению случайности “up-down patterns” и появлению долговременных корреляций.

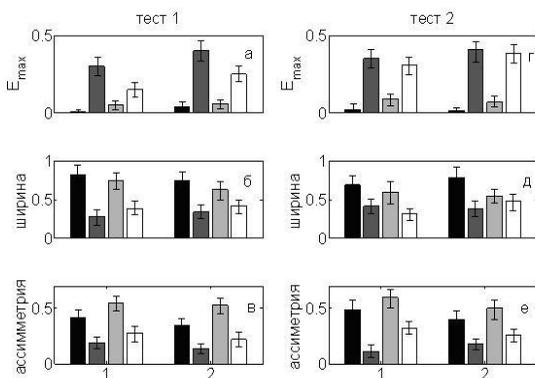


Рис. 4. Сравнение средних значений максимумов энергии вейвлетного спектра, ширины и асимметрии спектра сингулярности (усреднение внутри каждой группы исследуемых). Маркеры цветов: для здоровых лиц (черный цвет), для пациентов с синдромом паркинсонизма до приема антипаркинсонических препаратов (темно – серый), после такого приема у 65 % больных (светло – серый) и у 35 % больных (белый). Цифрами обозначены усредненные данные для тремора левой (1) и правой (2) руки соответственно. Достоверность различий между двумя средними величинами составляет не менее 95 % ($p < 0,05$)

Повреждения мозга, приводящие к развитию болезни Паркинсона, вероятно, обуславливают нарушения долговременных корреляций в электрической активности. В связи с этим мультифрактальные параметры, определяющие изменения в долговременных корреляциях, могут быть полезны для обнаружения дисфункций центральной нервной системы. Долговременные корреляции могут быть связаны с фрактальностью внутриклеточных процессов, определяющих амплитуду и скорость проведения потенциалов действия. Так, в работе [12] показаны долговременные корреляции последовательностей времен жизни ионных каналов и динамики изменения концентрации мембранно-связанного кальция. Наличие долговременной памяти в динамике ионных каналов приводит к памяти во флуктуациях возбудимости нервного волокна [13]. Увеличение числа возбужденных волокон при проведении импульсации сопровождается уменьшением долговременных корреляций в последовательностях амплитуд потенциалов действия и увеличением корреляции для скоростей проведения потенциалов действия [14]. Это может лежать в основе уменьшения долговременной памяти

при паркинсоническом повреждении центрального управления движениями, о чем свидетельствует возрастающая синхронизация и уменьшение мультифрактальности произвольных колебаний.

Выводы

Энергетические и мультифрактальные параметры могут служить оценкой моторной дисфункции человека, так как их значения количественно отражают степень отклонения патологических произвольных колебаний от колебаний, регистрируемых у здоровых добровольцев.

Список литературы

1. Oudjemia, S., Zaylaa, A., Haddab, S., et al., Coarse-grained multifractality analysis based on structure function measurements to discriminate healthy from distressed foetuses // Computational and mathematical methods in medicine, 2013. V. 2013. P.152.
2. Diosdado M.A. Analysis of the relation between complexity and multifractality in cardiac interbeat intervals time series // IFMBE Proceedings, 2010, V. 25. P.1506.
3. Dick, O.E., Romanov, S.P., Nozdrachev, A.D., Energy and Fractal Characteristics of Physiological and Pathological Tremors of the Human Hand // Human Physiology, 2010. V. 36. P. 203.
4. McAuley, J.H., Marsden, C.D., Physiological and pathological tremors and rhythmic central motor control // Brain, 2000. V. 123. P. 1545.
5. Павлов, А.Н., Анищенко, В.С., Мультифрактальный анализ сложных сигналов // Успехи физических наук, 2007, V.177, p.859.
6. Bullmore, E., Barnes, A., Danielle S. et al., Generic aspects of complexity in brain imaging data and other biological systems // Neuroimage, 2009. V. 47. P.1125.
7. Yeh, J.R., Peng, C.K., Lo, M.T., et al., Investigating the interaction between heart rate variability and sleep EEG using nonlinear algorithms // J. Neurosci. Methods, 2013. V. 219. P.233.
8. Zhang, T., Xu, K., Multifractal analysis of intracranial EEG in epileptic rats // Lecture Notes in Computer Sciences, 2011. V. 7062. P. 345.
9. Uthayakumar, R., Easwaramrthy, E., Epileptic seizure detection in EEG signals using multifractal analysis and wavelet transform // Fractals, 2013. V. 21. P. 24.
10. Dick, O.E., Svyatogor, I.A., Potentialities of the wavelet and multifractal techniques to evaluate changes in the functional state of the human brain // Neurocomputing Journal, 2012, V. 82, p. 207.
11. Muzy, J.F., Bacry, E., Arneodo, A., Multifractal formalism for fractal signals: the structure-function approach versus the wavelet-transform modulus-maxima method // Phys. Rev. E, 1993. V. 47. P. 875.
12. Varanda, W.A., Liebovitch, L.S., Figueroa, J.N., Nogueira, R.A., Hurst analysis applied to the study of single calcium - activated potassium channel kinetics // J. Theor. Biol., 2000. V. 206. P. 343.
13. Xu, Y., Ma, Q.D.Y., Schmitt, D.T. et al., Effects of coarse-graining on the scaling behavior of long-range correlated and anti-correlated signals // Physica A, 2011. V. 390. P. 4057.

14. Brazhe, A.R., Maksimov, G.V., Self – organized critical gating of ion channels: on the origin of long – term memory in dwell time series // Chaos, 2006. V. 16. P. 33129.

**Л.Н. ПОДЛАДЧИКОВА, Т.И. КОЛТУНОВА,
Д.Г. ШАПОШНИКОВ**

НИИ нейрокибернетики им. А.Б. Когана Южного федерального университета,
Ростов-на-Дону
lnp@nisms.krinc.ru

**ОСОБЕННОСТИ ЛОКАЛЬНЫХ ЭЛЕМЕНТОВ ТРАЕКТОРИЙ
ОСМОТРА ИЗОБРАЖЕНИЙ:
ОБЪЕКТНО-ВОЗВРАТНЫЕ ФИКСАЦИИ ВЗГЛЯДА***

Представлены результаты анализа экспериментальных данных об особенностях возвратных фиксаций взгляда при просмотре сложных изображений и текстур. Показано, что длительность фиксаций и амплитуда саккад в окрестностях возвратных фиксаций отличаются от средних значений этих параметров. Рассматривается возможность использования полученных результатов для разработки модели, обеспечивающей реалистическую имитацию траекторий осмотра в конкретных психофизических тестах.

Ключевые слова: *траектория осмотра изображений, локальные элементы, объектно-возвратные фиксации взгляда, длительность фиксаций, амплитуда саккад.*

**L.N. PODLADCHIKOVA, T.I. KOLTUNOVA,
D.G. SHAPOSHNIKOV**

A.B. Kogan Research Institute for Neurocybernetics Southern Federal University,
Rostov-on-Don
lnp@nisms.krinc.ru

**THE PECULIARITIES OF THE VIEWING TRAJECTORY
LOCAL ELEMENTS: OBJECT-RETURN GAZE FIXATIONS**

The results of experimental data analysis about the features of the return fixations during the complex images and textures viewing are presented. It is shown

*Исследование выполнено в рамках базовой части внутреннего гранта ЮФУ № 213.01-2014/001ВГ.

that the duration of fixations and saccadic amplitude in the vicinity of the return fixations differ from the average values of these parameters. The possibility of using the results obtained to develop a model that provides a realistic simulation of the viewing trajectories in specific psychophysical tests is considered.

Keywords: *image viewing trajectory, local elements, object-return gaze fixations, fixation duration, saccadic amplitude.*

Введение

Начиная с работ Buswell [1], Ярбуса [2] и Stark [3, 4] траектория осмотра сложных изображений рассматривается как возможный ключ к объективной оценке когнитивных процессов. Однако в современных исследованиях получены данные как *pro* [5-11], так и *contra* [12] этого представления. Особенности инструкций перед тестом, наличие сообщения испытуемого после теста и, прежде всего, математические методы, использованные для количественной оценки траекторий осмотра, рассматриваются как возможные причины противоречивости результатов. В частности, анализ первичных данных Грина с соавт. [12] с помощью различных нелинейных методов [11, 13] выявил значимую связь между паттернами глазных движений и зрительной задачей, которая определялась инструкцией. Более того, показана возможность кодирования, распознавания и классификации изображений на основе траекторий осмотра [5, 10, 14-16].

В противоположность детальному изучению траекторий осмотра в целом, известны лишь единичные исследования локальных элементов паттернов движений глаз [17-20]. До настоящего времени, как в экспериментальных, так и в модельных исследованиях, остается актуальным решение нескольких задач. В частности, необходим поиск параметров глазных движений, которые позволяют количественно оценить специфику зрительной задачи, решаемой на данном этапе динамического процесса осмотра изображений. Кроме того, актуальна разработка критериев определения вклада доминирующего компонента зрительного внимания [21-26].

В данной работе представлены результаты анализа частного вида локальных элементов траекторий осмотра, включающих возвратные фиксации на только что осмотренных областях изображений. Они позволяют развить наш подход к изучению механизмов осмотра сложных изображений, основанный на тесном двустороннем взаимодействии экспериментальных исследований и моделирования [20, 27-29], и представлении *Facilitation of Return* (Облегчение Возврата) [30-32] в противоположность классической концепции *Inhibition of Return* (Торможение Возврата) [33]. Несмотря на то,

что накапливается все больше фактов о выраженности феноменов *Facilitation of Return*, особенно при решении сложных зрительных задач, до настоящего времени доминирует представление *Inhibition of Return* [23, 32]. Анализируются окуломоторные, эндогенные и экзогенные факторы, обуславливающие возникновение торможения возврата, его пространственные и временные свойства [15, 23, 30-32]. Кроме того, в моделях распознавания изображений [21, 24, 27], основанных на имитации механизмов биологического зрения, вводится эмпирический коэффициент торможения возврата для предотвращения циклического характера модельных траекторий осмотра. Детальное исследование соотношения феноменов облегчения и торможения возврата, наряду с пониманием динамических механизмов осмотра изображений человеком, даст возможность в перспективе разработать реалистическую модель зрения.

В наших исследованиях предположение о наличии возвратных фиксаций взгляда на только что осмотренных областях изображений возникло при разработке методов классификации траекторий осмотра изображений [28] и идентификации, в частности, траекторий объектно-возвратного типа (рис. 1). Было обнаружено, что такие траектории глазных движений формируются при решении частных зрительных задач, определенных инструкцией, и на некоторых этапах процесса свободного осмотра изображений.

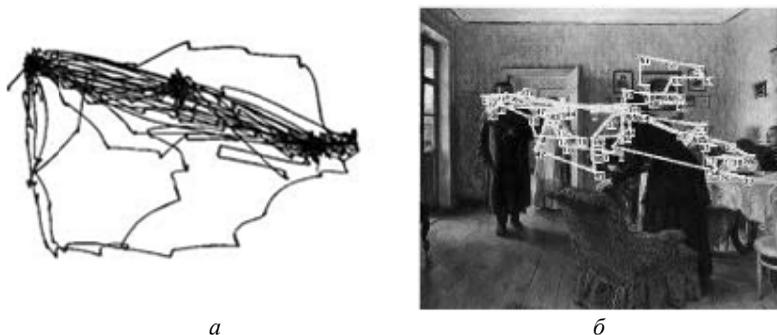


Рис. 1. Примеры траекторий осмотра объектно-возвратного типа (модифицированный рис. 3 из [28]):
 а – результаты А.Л. Ярбуса ([2], фрагмент рис. 109);
 б – результаты наших психофизических тестов

Методика

Для поиска и анализа возвратных фиксаций использованы результаты, полученные в двух сериях психофизических тестов. В качестве стимула в

первой серии тестов использовалось изображение из исследований А.Л. Ярбуса [2], а именно, картина «Не ждали» И.Е.Репина (16° x 15°). Эти тесты состояли из двух этапов: 1) свободный осмотр изображения; 2) поиск измененных фрагментов – размытых областей размером 1,5°. Во второй серии тестов для свободного осмотра предъявлялись четыре текстурных изображения [20], имеющие регулярную пространственную структуру и различный набор первичных признаков. В первой серии принимали участие 8 испытуемых, во второй – 3 испытуемых.

Движения глаз регистрировались с помощью системы iView X Hi-Speed 1250 Гц фирмы SMI. Расстояние между монитором и испытуемым составляло 80 см, размер монитора – 375 мм по горизонтали и 300 мм по вертикали (26° и 20° поля зрения для выбранного расстояния).

На данном этапе возвратные фиксации взгляда определялись согласно схеме, представленной на рис. 2, I. Фиксация (точка 3 на схеме) рассматривалась как возвратная, если она располагалась после возвращающей саккады (серая линия со стрелкой на схеме) в пределах фовеальной окрестности (серый круг на схеме с радиусом $r = 2^\circ$) предшествующей фиксации (точка 1 на схеме).

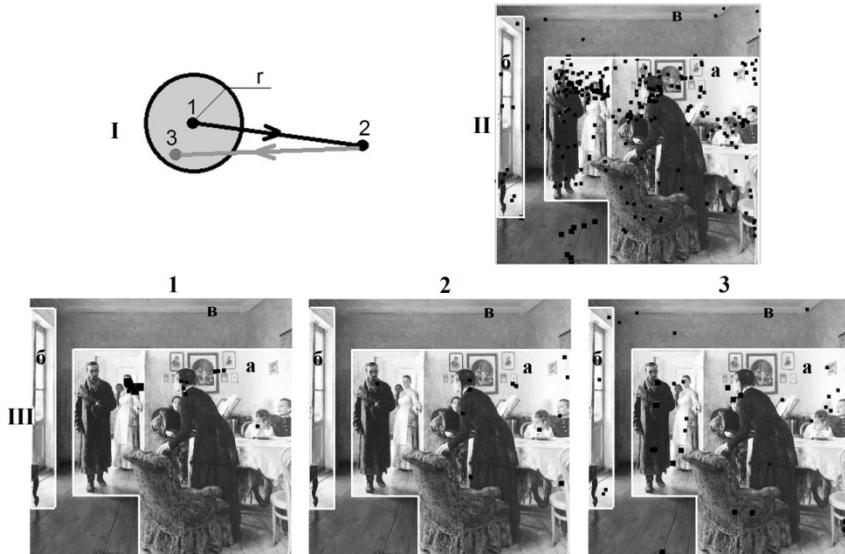


Рис. 2. Схема определения возвратных фиксаций (I), накопленная карта ($n = 15$) распределения возвратных фиксаций (II, черные малые квадраты) и примеры (1–3) карт распределения возвратных фиксаций у отдельных испытуемых (III)

Затем определялись вероятность и пространственное расположение возвратных фиксаций, а также длительность фиксаций и амплитуда саккад в триадах последовательностей (точки 1, 2 и 3 на схеме).

Результаты и обсуждение

С помощью описанного метода анализа экспериментальных данных обнаружены возвратные фиксации взгляда на только что осмотренных областях изображений, имеющие относительно низкую вероятность. Она варьировалась в диапазоне от 0,03 до 0,15 и зависела от типа теста, изображения и индивидуальных особенностей испытуемых. Так, при решении зрительных задач свободного осмотра и поиска измененных фрагментов на сложном изображении вероятность составила, в среднем, 0,10 (всего общее количество регулярных и возвратных фиксаций, $n = 1\ 471$) и 0,08 ($n = 1283$), соответственно. В свою очередь, у отдельных испытуемых при решении этих зрительных задач вероятность возвратных фиксаций варьировалась в диапазоне от 0,03 до 0,14; а при свободном просмотре текстур - от 0,09 до 0,15 (в среднем, 0,12).

Возвратные фиксации имели характерные пространственные и временные свойства. В частности, большинство из них приурочено к областям интереса, идентифицированным с помощью метода группирования точек фиксации [28] на текстурных изображениях, или к семантически значимым объектам на сложном изображении (рис. 2, II и III).

На рис. 2 как в накопленной, так и в индивидуальных картах, заметна концентрация возвратных фиксаций в пределах области «а», в которой расположены семантически значимые объекты. Напротив, в областях «б» и «в», малое количество возвратных фиксаций коррелирует с не выраженностью однозначных объектов. Об этом свидетельствуют также сводные количественные данные в табл. 1.

Таблица 1

Вероятность возникновения возвратных фиксаций взгляда в различных областях изображения («а», «б», «в» на рис. 2, II и III)

Область изображения	«а»	«б»	«в»
Всего фиксаций в области	2075	176	523
Вероятность возвратных фиксаций	0.11	0.06	0.05

Таблица 2

Длительность фиксации взгляда в последовательностях точек фиксации, включающих возвращающую саккаду, в тестах с предъявлением изображения картины И.Е. Репина «Не ждали»

Параметры	Расположение точек фиксации в триадах			Фиксации вне триад
	Первая фиксации	Промежуточная фиксации	Возвратная фиксации	
Длительность фиксации, мс	519±24	524±22	568±26	428±15
Количество фиксации, <i>n</i>	265	265	265	509

Из данных, представленных в табл. 2 и 3, видно, что длительность возвратных фиксации взгляда несколько больше, чем у предшествующих фиксации (для изображения картины И.Е. Репина «Не ждали» – 568±26 мс против 519±24 мс; для текстур – 358±35 мс против 292±20 мс).

Кроме того, обнаружено, что саккады, после которых возникают возвратные фиксации взгляда, имеют меньшую амплитуду, чем средние значения (для сложного изображения – $2,57 \pm 0,32^\circ$ против $3,55 \pm 0,05^\circ$; для текстур – $2,0 \pm 0,16^\circ$ против $3,09 \pm 0,09^\circ$).

Таблица 3

Длительность фиксации взгляда в последовательностях точек фиксации, включающих возвращающую саккаду, в тестах с предъявлением текстур

Параметры	Расположение точек фиксации в триадах			Фиксации вне триад
	Первая фиксации	Промежуточная фиксации	Возвратная фиксации	
Длительность фиксации, мс	292±20	360±26	358±35	333±26
Количество фиксации, <i>n</i>	63	63	63	63

Проведенный анализ данных, полученных в психофизических тестах с использованием сложного изображения и текстур, позволил выявить специфический вид локальных элементов траекторий осмотра - возвратные фиксации взгляда человека. Обнаружено, что они имеют относительно низ-

кую вероятность (не более 0,15 от общего количества точек фиксации). Такие элементы траекторий при осмотре как сложных (картин), так и простых (текстуры) изображений проявляют комплекс пространственных и временных свойств, отличающих их от регулярных фиксаций.

Полученные результаты могут быть сопоставлены в нескольких отношениях с известными данными в рамках исследований *Inhibition of Return* [15, 23, 26, 33] и *Facilitation of Return* [30-32]. В большинстве известных исследований для идентификации возвратных фиксаций (саккад) при осмотре сложных изображений используются иные методы, чем в нашей работе. Несмотря на это вероятность возникновения возвратных фиксаций, обнаруженная в различных работах, достаточно низка. Так, из данных, представленных на рис. 3 в работе [32], можно определить, что в различных тестах вероятность варьируется на уровне средней величины, равной 0,08; аналогичные данные приводятся в работе [30, в тестах осмотра и поиска она находилась в диапазоне от 0,02 до 0,12]. Кроме того, описано также [23, 30] аналогичное различие длительностей возвратной и первичной фиксаций взгляда. В ряде исследований предполагается, что доминирование механизмов *Inhibition of Return* проявляется в большей мере при решении задач поиска и при осмотре простых изображений [15, 23, 26, 30]. Напротив, при решении различных зрительных задач при осмотре сложных изображений и сцен нередко обнаруживается *Facilitation of Return* [31, 32].

В плане развития представления *Facilitation of Return* наиболее интересны два новых факта, обнаруженные в данной работе: 1) приуроченность возвратных фиксаций к только что осмотренным семантически значимым объектам на сложном изображении и областям интереса на относительно простых стимулах (текстурах); 2) малая амплитуда возвращающих саккад по сравнению со средней их величиной.

Представленные результаты о свойствах возвратных фиксаций, наряду с другими данными об особенностях локальных элементов траекторий осмотра [20], будут использованы для модификации поведенческой модели зрения [27, 28]. Предполагается, что эти модификации, включая реалистическую динамику коэффициентов облегчения и торможения возврата в процессе осмотра изображения, обеспечат возможность реалистической имитации траекторий осмотра в конкретных психофизических тестах.

Очевидно, что в дальнейшем возвратные фиксации взгляда и механизмы их возникновения должны быть детально исследованы с помощью экспериментальных методов и моделирования, поскольку этот феномен может дать важный ключ к количественной объективной оценке динамики зрительного внимания и обращения к кратковременной памяти на различных этапах решения текущей зрительной задачи.

Выводы

1. При решении зрительных задач свободного осмотра и поиска измененных фрагментов изображений обнаружены возвратные фиксации взгляда на только что осмотренных областях изображений, имеющие, в среднем, низкую вероятность. Вероятность (p) возвратных фиксаций варьировалась в зависимости от характера теста, типа изображения и индивидуальных особенностей испытуемого (диапазон вариаций p – от 0,03 до 0,15).

2. Несмотря на низкую вероятность, возвратные фиксации имеют характерные пространственные и временные свойства. В частности, большинство возвратных фиксаций приурочено к областям интереса и семантически значимым объектам на изображениях.

3. Длительность возвратных фиксаций взгляда больше, чем у предшествующих фиксаций (для сложного изображения – 568 ± 26 мс против 519 ± 24 мс; для текстур – 358 ± 35 мс против 292 ± 20 мс).

4. Саккады, после которых возникают возвратные фиксации взгляда, имеют меньшую амплитуду, чем средние значения (для сложного изображения – $2,57 \pm 0,32^\circ$ против $3,55 \pm 0,05^\circ$; для текстур – $2,0 \pm 0,16^\circ$ против $3,09 \pm 0,09^\circ$).

Список литературы

1. Buswell G. T. How people look at pictures. Chicago: University of Chicago Press, 1935.
2. Ярбус А.Л. Роль движений глаз в процессе зрения. М.: Наука. 1965.
3. Noton D., Stark L. (1971). Scanpaths in eye movements during pattern perception // Science. New Series., 1971. V. 171. № 3968. P. 308-311.
4. Privitera C.M., Stark L. Scanpath theory, attention and image processing algorithms for prediction of human eye fixations // Neurobiology of Attention. L. Itti, G. Rees, J.K. Tsotsos (Eds), Elsevier, Academic, 2005. P. 296-299.
5. Oyekoya O., Stentiford F. Perceptual image retrieval using eye movements // Int. J. Computer Mathematics, 2007. V. 84. № 09. P. 1379-1391.
6. DeAngelus M., Pelz J.B. Top-down control of eye movements: Yarbus revisited // Visual Cognition. 2009. V. 17. № 6-7. P. 790-811.
7. Tatler B.W., Wade N.J., Kwan H., Findlay J.M., Velichkovsky B.M. Yarbus, eye movements, and vision // Perception, 2009. V.1. № 1. P. 7-27.
8. Harding G., Bloj M. Real and predicted influence of image manipulations on eye movements during scene recognition // J. Vision, 2010. V. 10. N. 2. iss. 8. P. 1-17.
9. Jacobs R.H., Renken R., Thumfart S., Cornelissen F. W. (). Different judgments about visual textures invoke different eye movement patterns // J. Eye Movement Research, 2010. V. 3. № 4. iss. 1. P. 1-13.
10. Humphrey K., Underwood G. The potency of people in pictures: Evidence from sequences of eye fixations // J. Vision, 2010. V. 10. № 10. iss. 19. P. 1-10.

11. Borji A., Itti L. Defending Yarbus: Eye movements reveal observers' task // *J. Vision*, 2014. V. 14. № 3. P. 1-29.
12. Greene M.R., Liu T., Wolfe J.M. Reconsidering Yarbus: A failure to predict observers' task from eye movement patterns // *Vision Research*. 2012. V. 62. P. 1–8.
13. Kanan C., Ray N. A., Bseison D. N. F., Hsiao J.H., Cottrell G.W. Predicting an observer's task using multi-fixation pattern analysis // *Proc. ACM Symp. Eye Tracking Research and Applications (ETRA-2014)*, 2014. P. 287-290.
14. West J.M., Haake A.R., Rozanski E.P., Karn K.S. eyePatterns: software for identifying patterns and similarities across fixation sequences. // *Proc. 2006 Symposium on Eye tracking research & applications*, 2006. P. 149-154.
15. Weger U.W., Abrams R.A., Law M.B., Pratt J. Attending to objects: Endogenous cues can produce inhibition of return // *Visual Cognition*. 2008. V. 16. № 5. P. 659-674.
16. Hayes T.R., Petrov A.A., Sederberg P.B. A novel method for analyzing sequential eye movements reveals strategic influence on Raven's Advanced Progressive Matrices // *J. Vision*, 2011. V. 11. № 10. P. 1–11.
17. Hafed Z.M., Clark J.J. Microsaccades as an overt measure of covert attention shifts // *Vision Research*, 2002. V. 42. № 22. P. 2533-2545.
18. Pastukhov A., Braun J. Rare but precious: Microsaccades are highly informative about attentional allocation // *Vision Research*, 2010. V. 50. P. 1173–1184.
19. Pannasch S., Schulz J., Velichkovsky B.M. On the control of visual fixation durations in free viewing of complex images // *Attention, Perception, & Psychophysics*, 2011. V. 73. № 4. P. 1120-1132.
20. Осинов В.А., Шапошников Д.Г., Колтунова Т.И., Подладчикова Л.Н. Динамика пространственно-временных характеристик осмотра изображений: модель и эксперимент // *Нейроинформатика*. Эл. рецензир. журнал, 2012. Т.6. № 1. С. 1-11.
21. Navalpakkam V., Itti L. Modeling the influence of task on attention // *Vision Research*, 2005. № 45. P. 205-231.
22. Wolfe J.M., Birmkrant R.S., Kunar M.A., Horowitz T.S. Visual search for transparency and opacity: attentional guidance by cue combination? // *J. Vision*. 2005. № 5. P. 257-274.
23. Lupianez J., Klein R.M., Bartolomeo P. Inhibition of return: Twenty years after // *Cognitive Neuropsychology*, 2007. V. 23(7). P. 1003-1014.
24. Walther D.B., Koch C. Attention in hierarchical models of object recognition // *Progress in Brain Research*. 2007. № 165. P. 57-78.
25. Carrasco M. Visual Attention: The past 25 years // *Vision Research*. 2011. № 51. P. 1484-1525.
26. Wang Z., Theeuwes J. Dissociable spatial and temporal effects of Inhibition of Return // *PloS one*, 2011. V.7(8).
27. Rybak I., Gusakova V., Golovan A., Podladchikova L., Shevtsova N. Attention-guided recognition based on «What»; and «Where» representations: a behavioral model // *Neurobiology of Attention*, 2005. P. 663-670.
28. Podladchikova L.N., Shaposhnikov D.G., Tikidgji-Hamburyan A.V., Koltunova T.I., Tikidgji-Hamburyan R.A., Gusakova V.I., Golovan A.V. Model-based approach to study the mechanisms of complex image viewing // *J. Optical Memory and Neural Networks (Information Optics)*, 2009. V. 18. №2. P. 114-121.

29. Podladchikova L.N., Shaposhnikov D.G., Koltunova T.I., Dyachenko A.V., Gusakova V.I. Temporal dynamics of fixation duration, saccade amplitude, and viewing trajectory // *J. Integrative Neuroscience*, 2009. V.8. № 4. P. 487–501.

30. Hooge I.Th.C., Over E.A.B., van Wezel R.J.A, Maarten A., Frens M.A. Inhibition of return is not a foraging facilitator in saccadic search and free viewing // *Vision Research*, 2005. № 45. P. 1901–1908.

31. Dodd M.D, Van der Stigchel S., Hollingworth A. Novelty is not always the best policy. Inhibition of return and facilitation of return as a function of visual task // *Psychological Science*, 2009. V. 20. № 3. P. 333-339.

32. Luke S.G., Schmidt J., Henderson J.M. Temporal oculomotor inhibition of return and spatial facilitation of return in a visual encoding task // *Frontiers in Psychology*. 2013. № 4, paper 400. P. 1-8.

33. Posner M.I., Rafal R.D., Choate L.S., Vaughan J. Inhibition of return: Neural basis and function // *Cognitive neuropsychology*, 1985. V.2. № 3. P. 211-228.

ИМЕННОЙ УКАЗАТЕЛЬ АВТОРОВ

- А –
Анохин М. Н. 153
Анфилец С. В. 137
- Б –
Бахчина А. В. 21
Бесхлебнова Г. А. 145
Бибииков Н. Г. 191
- В –
Воронков Г. С. 69
- Г –
Глазов А. Л. 200
Голощапов В. И. 106
- Д –
Дик О. Е. 200
- Ж –
Желавская И. С. 11
- З –
Запара Т. А. 174
- И –
Ивашина Е. А. 29
- К –
Киселев М. В. 126
Ковальчук А. В. 21
Козунов В. В. 163
Колтунова Т. И. 210
Корлякова М. О. 29
Котов В. Б. 59
Крыжановский В. М. 11
- Л –
Лавров В. В. 79
- М –
Мальсагов М. Ю. 11
Милов В. Р. 50
- Н –
Непомнящих В. А. 145
Низамов С. В. 191
- О –
Осадчий А. Е. 163
Осипова Е. А. 145
- П –
Подладчикова Л. Н.
210
- Покровский А. Н. 97
Полевая С. А. 21
Прокопов Е. Ю. 29
Проскура А. Л. 174
- Р –
Ратушняк А. С. 174
Редько В. Г. 145
Рудинский А. В. 79
- С –
Савченко А. В. 50
Смирнитская И. А. 89
- Ч –
Чередников Д. Ю. 117
Чижов А. В. 184
- Ш –
Шапошников Д. Г. 210
Шарипова Т. И. 145
Шибзухов З. М. 117
Шуть В. Н. 137
- Э –
Энгель Е. А. 38