

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**

ЛЕКЦИИ ПО НЕЙРОИНФОРМАТИКЕ

По материалам Школы-семинара
«Современные проблемы нейроинформатики»

Москва

УДК 001(06)+004.032.26 (06) Нейронные сети
ББК 72я5+32.818я5
М82

XVII ВСЕРОССИЙСКАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ С МЕЖДУНАРОДНЫМ УЧАСТИЕМ «НЕЙРОИНФОРМАТИКА–2015»: ЛЕКЦИИ ПО НЕЙРОИНФОРМАТИКЕ. – М.: НИЯУ МИФИ, 2015. – 276 с.

В книге публикуются тексты приглашенных докладов и лекций Школы-семинара «Современные проблемы нейроинформатики» из числа входящих в программу XVII Всероссийской конференции с международным участием «Нейроинформатика–2015», НИЯУ МИФИ, 19–23 января 2015 года.

Материалы докладов и лекций связаны с рядом проблем, актуальных для современного этапа развития нейроинформатики, включая ее взаимодействие с другими научно-техническими областями.

Ответственный редактор
Ю. В. Тюменцев, кандидат технических наук

Статьи получены до 26.10.2014

ISBN 978–5–7262–2046–8

© *Национальный исследовательский
ядерный университет «МИФИ», 2015*

Содержание

Предисловие	8
<i>С. А. Шумский. Реинжиниринг архитектуры мозга: роль и взаимодействие основных подсистем</i>	13
Введение	14
Кора: ассоциативная модель мира и способов взаимодействия с ним	17
Базальные ганглии: обучение ценностям	24
Мозжечок: закрепление пройденного	32
Абстрактное мышление: виртуальная реальность	35
Заключение. Новая старая архитектура	39
Литература	42
<i>В. А. Головки. От многослойных персептронов к нейронным сетям глубокого доверия: парадигмы обучения и применение</i>	47
Введение	48
Однослойный персептрон	50
Многослойный персептрон	55
Нейронные сети глубокого доверия	59
Автокодерный метод обучения	62
Ограниченная машина Больцмана	63
Обучение нейронной сети глубокого доверия на основе RBM	68
Альтернативный взгляд на ограниченную машину Больцмана	69
Применение нейронных сетей глубокого доверия	75
Сжатие данных	76
Визуализация данных	77
Распознавание образов	78
Заключение	81
Литература	82
УДК 001(06)+004.032.26 (06) Нейронные сети	3

М. В. Киселев. Компьютерное моделирование импульсных нейронных сетей	85
Введение. Импульсные (спайковые) нейронные сети — их особенности и мотивация их изучения	86
Модели импульсных нейронов	91
Детектор совпадений	91
Пороговый интегратор с утечкой	91
Двумерные модели	92
Детальная модель Ходжкина-Хаксли	94
Более сложные модели синапсов	95
Архитектуры ИНС	96
Кодирование информации в ИНС	97
Асинхронные методы кодирования информации в ИНС	97
Синхронные методы кодирования информации в ИНС	98
Эволюция и обучение ИНС, синаптическая пластичность	100
Модельные эксперименты с ИНС — некоторые проблемы, которые требуется решать	105
Моделирование информационной среды ИНС	105
Мониторинг и интерпретация процессов, происходящих в ИНС	106
Длительность моделирования	107
Выбор параметров нейронов и всей сети	108
Программные и аппаратные средства, используемые для моделирования ИНС	108
Многоядерный ПК, распараллеливание средствами ОС	109
Многоцелевые графические процессоры (GPGPU)	109
Многоцелевые суперкомпьютеры	110
Специализированные архитектуры на базе ПЛИС	110
Нейроморфные компьютеры на основе специализированных интегральных микросхем	111
Основные цели и задачи моделирования ИНС в настоящее время	114
Моделирование обработки сенсорной информации	114
Моделирование механизмов памяти	115
Исследование кодирования информации в ИНС и конвертации между разными способами кодирования	116
Применение ИНС в системах автоматического управления	116
Нейропротезирование и интерфейсы «мозг-компьютер»	116

Изучение общих проблем самоорганизации ИНС, теоретических принципов обработки информации ими	118
Перспективы. Чего можно ожидать в близком будущем	118
Заключение. Выводы	119
Литература	120
С. Б. Парин, С. А. Полевая. Информация и управление в живых системах (легенды и мифы когнитивной науки)	123
Введение: постановка задачи	124
Микрогlossарий	126
Проблема 1 — подмена понятий	127
Проблема 2 — мифотворчество	130
Миф 1	131
Легенда 1	133
Мифы 2 и 3	136
Миф 4 — очень популярный	141
Легенда 2	143
Еще немного о мифах	148
Вместо заключения — ключевые вопросы	149
Литература	149
А. В. Карговский, Ю. М. Романовский, В. П. Трифоненков, А. В. Трифоненков. Стохастическая динамика внутринейронного транспорта	156
О чем пойдет речь?	157
Общая схема транспорта внутри нейрона	157
Образы молекулярных моторов: кинезина, миозина V и динеина	161
Как работает кинезин	161
Оценка энергии, необходимой для преодоления стокового сопротивления при «шагании» кинезина	165
Математическая модель шагания кинезина	167
Миозин V шагает по актиновым филаментам	173
Исходные оценки параметров и формулировка модели	176
Результаты моделирования шагания миозина V	178
Теперь критика нашей упрощенной модели	180
Литература	182

А. А. Фролов, А. В. Александров, П. Д. Бобров, Е. В. Бирюкова. Биологически адекватные принципы управления движениями экзоскелетов конечностей человека	185
Введение	186
Уравнения движения системы связанных твердых тел	188
Уравнения движения робота при ограничении числа степеней свободы	193
Управление движением робота в сагиттальной плоскости	196
Собственные векторы уравнения движения	197
Анализ устойчивости управления	200
Опыт управления роботом	204
Принцип управления по собственным векторам уравнения движения в общем случае	205
Заключение	213
Литература	215
Ю. И. Нечаев. Контроль чрезвычайных ситуаций в интегрированной среде виртуального полигона на основе современной теории катастроф	220
Введение	221
Концепция виртуального полигона при реализации методов теории катастроф в сложных динамических средах	222
Топологическое пространство преобразования информации на основе современной теории катастроф	225
Интерпретация топологического пространства при функционировании ND-системы	229
Пространство и время в ND-системах	229
Топологическое пространство динамической модели катастроф	231
Топологическое пространство фрактальных структур при исследовании динамики ND-систем	233
Аксиоматический базис топологического пространства ND-систем	238
Аксиоматическое представление знаний	240
Аксиоматический базис фрактальной геометрии	241
Управление и принятие решений при функционировании ND-системы в виртуальной среде	244
Реализация принципов функционирования ND-системы в высокопроизводительной среде виртуального полигона	246

Интеллектуальные технологии ND-системы при моделировании морских динамических объектов	247
Когнитивная парадигма при обработке информации ND-систем	247
Контроль поведения ND-системы в процессе эволюции в сложной динамической среде	251
ND-системы при интерпретации поведения морских ДО в процессе эволюции в нестационарной среде	252
Система виртуального моделирования при функционирования ВП на основе методов теории катастроф	253
Визуализация модели внешней среды и динамики взаимодействия	254
Визуализация результатов функционирования динамической базы знаний ВП	255
Интерпретация режимов движения ДО на основе моделей ND-систем	258
Контроль режима функционирования ВП при оценке поведения ДО	259
Обнаружение изменений в процессе эволюции системы	260
Моделирование объектов социальной среды при функционировании ВП	261
Критериальный базис оценки адекватности ND-систем в условиях неопределенности и неполноты исходной информации	263
Формализация неопределенности в ND-системах	264
Особенности преобразования информации в NN-системах	265
Алгоритм преобразования информации при функционировании NN-систем	266
Формализованное ядро теории нормирования ND-систем	267
Оценка адекватности конкурирующей вычислительной технологии	269
Реализация принципа конкуренции на основе модифицированной схемы оценки адекватности	269
Заключение	271
Литература	272

ПРЕДИСЛОВИЕ

1. В этой книге содержатся тексты части лекций, прочитанных на Пятнадцатой Школе-семинаре «Современные проблемы нейроинформатики», проходившей 19–23 января 2015 года в НИЯУ МИФИ в рамках XVII Всероссийской научно-технической конференции «Нейроинформатика–2015», а также тексты двух лекций, представленных на Школе–2014, но не вошедшие в состав ее сборника.

При отборе и подготовке материалов для лекций авторы и редактор следовали принципам и подходам, сложившимся при проведении четырнадцати предыдущих Школ.

А именно, основной целью Школы было, как всегда, рассказать слушателям о современном состоянии и перспективах развития важнейших направлений в теории и практике нейроинформатики, о ее применениях.

Основной задачей лекторов, входящих в число ведущих специалистов в области нейроинформатики и ее приложений, смежных областей науки, было дать живую картину современного состояния исследований и разработок, обрисовать перспективы развития нейроинформатики в ее взаимодействии с другими областями науки.

2. В программу Пятнадцатой Школы-семинара «Современные проблемы нейроинформатики» вошли следующие лекции:

1. *В. Л. Ушаков.* Визуализация крупномасштабных сетей головного мозга человека.
2. *С. А. Шумский.* Реинжиниринг архитектуры мозга: роль и взаимодействие основных подсистем.
3. *М. В. Киселев.* Компьютерное моделирование импульсных нейронных сетей.
4. *Я. Б. Казанович.* Как животные ориентируются в пространстве? Экспериментальные факты и модели.
5. *А. А. Фролов, А. В. Александров, П. Д. Бобров, Е. В. Бирюкова.* Биологически адекватные принципы управления экзоскелетом руки человека.

6. *В. А. Головки*. От многослойных персептронов к нейронным сетям глубокого доверия: парадигмы обучения и применение.
7. *Н. Г. Макаренко*. Статистическая топология, персистентные ландшафты и случайные поля.
8. *Ю. И. Нечаев*. Контроль чрезвычайных ситуаций в интегрированной среде виртуального полигона на основе современной теории катастроф.

Часть лекций из этого перечня, а именно, первая (*В. Л. Ушаков*), четвертая (*Я. Б. Казанович*) и седьмая (*Н. Г. Макаренко*), предполагается опубликовать в сборнике следующего года, остальные лекции из перечисленных выше публикуются в данном сборнике.

Кроме того, как отмечалось выше, в данном сборнике публикуются тексты двух лекций из числа представленных ранее, на Школе–2014:

1. *С. Б. Парин, С. А. Полевая*. Информация и управление в живых системах.
2. *А. В. Карговский, Ю. М. Романовский, В. П. Трифоненков, А. В. Трифоненков*. Стохастическая динамика внутринейронного транспорта.

3. В лекции *С. А. Шумского* «Реинжиниринг архитектуры мозга: роль и взаимодействие основных подсистем» представлена схема распределения ролей и взаимодействия друг с другом основных подсистем мозга млекопитающих. Это обучающаяся без учителя кора, кодирующая характерные паттерны входных и управляющих потоков информации; базальные ганглии, выделяющие полезные для выживания паттерны поведения в процессе обучения с подкреплением; а также мозжечок, использующий кору в качестве учителя, для улучшения контроля над рутинными навыками. Модульная организация взаимодействия этих подсистем позволяет наращивать возможности мозга за счет роста числа модулей в ходе эволюции млекопитающих. Этот же принцип можно использовать и для создания масштабируемых адаптивных управляющих систем.

4. Лекция *В. А. Головки* «От многослойных персептронов к нейронным сетям глубокого доверия: парадигмы обучения и применение» посвящена рассмотрению и анализу основных парадигм обучения персептронных нейронных сетей: от однослойного персептрона к многослойным сетям глубокого доверия, которые считаются революционным шагом в области интеллектуальной обработки данных. Показана несостоятельность некоторых мифов о возможностях персептронных нейронных сетей и обосно-

ываается переход к сверхбольшим персептронным сетям глубокого доверия. Рассмотрены основные модели обучения нейронных сетей глубокого доверия, базирующиеся на ограниченной машине Больцмана (RBM) и автоассоциативном подходе. Предложен новый метод для обучения ограниченной машины Больцмана и показано, что правило обучения ограниченной машины Больцмана является частным случаем предложенного метода обучения, который базируется на минимизации суммарной квадратичной ошибки восстановления информации. Доказана эквивалентность максимизации вероятности распределения данных в ограниченной машине Больцмана и минимизации суммарной квадратичной ошибки восстановления информации в слоях RBM. Рассматривается применение нейронных сетей глубокого доверия для сжатия, визуализации и распознавания данных.

5. Цель обзорной лекции *М. В. Киселева* «Компьютерное моделирование импульсных нейронных сетей» — рассмотреть текущее состояние раздела нейронауки, занимающегося построением и изучением компьютерных моделей импульсных нейронных сетей, класса нейросетевых моделей, наиболее близко соответствующих нейрофизиологической реальности. Обсуждаются различные модели импульсных нейронов, а также построенных из них сетевых структур. Описываются универсальные и специализированные компьютеры, применяющиеся для моделирования импульсных нейросетей, методология этого моделирования. Лекция завершается рассмотрением практических применений таких сетей и возможных перспектив развития этого направления.

6. Лекция *С. Б. Парина, С. А. Полевой* «Информация и управление в живых системах» посвящена обсуждению ключевых вопросов исследования информационных процессов в живых системах: нематериальной сущности информации как таковой и вытекающих из этого проблем объективного измерения субъективных явлений (в том числе, так называемой «психики»). Рассматриваются особенности биологических кодов разного уровня, материальные носители биологической информации (мембранные электрические потенциалы и информоны), а также условия и способы измерения их параметров. Затрагиваются распространенные ошибки и ситуации подмены понятий при изучении информации в живых системах. Анализируются возможные пути оптимизации и конкретизации исследований информационных процессов в живых системах различного уровня сложности.

7. В лекции *А. В. Карговского, Ю. М. Романовского, В. П. Трифоненкова, А. В. Трифоненкова* «Стохастическая динамика внутринейронного транспорта» представлен обзор внутринейронного транспорта нейромедиаторов, митохондрий и пр. Представлены физические основы функционирования и математические модели шагающих молекулярных моторов: кинезина и миозина V с учетом флуктуаций.

8. Предметом лекции *А. А. Фролова, А. В. Александрова, П. Д. Боброва, Е. В. Бирюковой* «Биологически адекватные принципы управления экзоскелетом руки человека» является проблема восстановления движений как одна из важнейших задач нейрореабилитации после инсульта. Для ее решения в настоящее время активно разрабатываются экзоскелеты конечностей, управляемые интерфейсом «мозг-компьютер». Однако прогресс в разработке таких экзоскелетов упирается в недостаточное применение принципов управления движениями человека со стороны центральной нервной системы (ЦНС). При разработке биологически адекватных экзоскелетов предполагается использовать два таких принципа: формирование двигательных синергий — координации суставных углов и моментов сил в суставах при движениях многосуставной конечности, а также управление моментом сил в суставах по обратной связи от суставных углов с задержкой по времени.

9. В лекции *Ю. И. Нечаева* «Контроль чрезвычайных ситуаций в интегрированной среде виртуального полигона на основе современной теории катастроф» обсуждается проблема контроля чрезвычайных ситуаций на основе виртуального полигона (ВП). Структура ВП интегрирует модели знаний с использованием графо-аналитической и нейродинамической систем (GA и ND-системы). Синтез осуществлен в рамках методов теории катастроф. Высокопроизводительная среда ВП обеспечивает моделирование и визуализацию чрезвычайных ситуаций в условиях непрерывного изменения динамики объекта и внешней среды. Концепция ВП реализует обработку информации при интерпретации нелинейных нестационарных систем в режиме реального времени. Формальная модель топологической динамики ND-системы предусматривает использование фрактальной геометрии и энтропийного подхода. Сформулирован общий подход к созданию критериального базиса ND-системы в условиях неопределенности и неполноты исходной информации. Компьютерное моделирование динамики взаимодействия проведено применительно к морским динамическим объектам (ДО) при различном уровне внешних возмущений.

* * *

Перечень проблем нейроинформатики и смежных с ней областей, требующих привлечения внимания специалистов из нейросетевого и родственных с ним сообществ, далеко не исчерпывается, конечно, вопросами, рассмотренными в предлагаемом сборнике, а также в сборниках предыдущих Школ.

В дальнейшем предполагается расширение данного списка за счет рассмотрения насущных проблем собственно нейроинформатики, проблем «пограничного» характера, особенно относящихся к взаимодействию нейросетевой парадигмы с другими парадигмами, развиваемыми в рамках концепций вычислительного интеллекта и мягких вычислений, проблем использования методов и средств нейроинформатики для решения различных классов прикладных задач. Не будут забыты и взаимодействия нейроинформатики с такими важнейшими ее «соседями», как нейробиология, нелинейная динамика, численный анализ и т. п.

Замечания, пожелания и предложения по содержанию и форме лекций, перечню рассматриваемых тем и т. п. просьба направлять электронной почтой по адресу tium@mai.ru *Тюменцеву Юрию Владимировичу*.

Редактор материалов выпуска,
кандидат технических наук *Ю. В. Тюменцев*
E-mail: tium@mai.ru

С. А. ШУМСКИЙ

Физический институт им. П. Н. Лебедева РАН, Москва
E-mail: Serge.shumsky@gmail.com

**РЕИНЖИНИРИНГ АРХИТЕКТУРЫ МОЗГА: РОЛЬ И
ВЗАИМОДЕЙСТВИЕ ОСНОВНЫХ ПОДСИСТЕМ**

Аннотация

Представлена схема распределения ролей и взаимодействия друг с другом основных подсистем мозга млекопитающих. Это: (i) обучающаяся без учителя кора, кодирующая характерные паттерны входных и управляющих потоков информации; (ii) базальные ганглии, выделяющие полезные для выживания паттерны поведения в процессе обучения с подкреплением; и (iii) мозжечок, использующий кору в качестве учителя, для улучшения контроля над рутинными навыками. Модульная организация взаимодействия этих подсистем позволяет наращивать возможности мозга за счет роста числа модулей в ходе эволюции млекопитающих. Этот же принцип можно использовать и для создания масштабируемых адаптивных управляющих систем.

S. A. SHUMSKY

Lebedev Physics Institute, Moscow, Russia
E-mail: Serge.shumsky@gmail.com

**REVERSE-ENGINEERING THE BRAIN ARCHITECTURE:
ROLE AND CO-OPERATION OF MAIN SUBSYSTEMS**

Abstract

We study the role and co-operation of the main subsystems of mammalian brain. Namely: (i) unsupervised learning of typical patterns in afferent and efferent signals in neocortex; (ii) reinforcement learning of biologically relevant behavior in basal ganglia; and (iii) supervised learning of routine behavior in cerebellum. Parallel organization of such co-operation allows for enhancing brain capabilities by increasing the number of modules in course of mammalian evolution. The same principle of Deep Control may be used in constructing adaptive controllers with scalable architecture.

Введение

В последние годы мы являемся свидетелями быстрого превращения машинного обучения в одну из ключевых технологий современного мира. Ведущие специалисты в этой области один за другим переходят из академических лабораторий на ведущие позиции в Google, Microsoft, Facebook, Amazon, Baidu и других лидерах компьютерной индустрии.

Широкополосный интернет, переполненный неструктурированной информацией, инициировал распознавание образов в промышленных масштабах. В 2006–2007 гг. почти одновременно в нескольких лабораториях были разработаны основные принципы *глубокого обучения* (Deep Learning) [1–3]. В этой парадигме оказалось возможным эффективно обучать многослойные нейронные сети, содержащие миллионы весов. И нейронные сети стали неотъемлемой компонентой промышленных систем обработки данных.

Сегодня их основная работа — распознавание образов. Во многих областях уже на уровне человека [4–7]. Но вычислительные мощности продолжают умножаться и дешеветь. И возникает вопрос: что будет дальше? Логично предположить, что следующим шагом будет переход от решения отдельных прикладных задач распознавания образов к созданию автономных управляющих систем, способных обучаться в процессе всего жизненного цикла, непрерывно накапливая предметные знания в масштабах, которые сейчас даже трудно себе представить. Но закон Мура подводит нас именно к такому сценарию — переходу от Deep Learning к Deep Control¹.

В науке это приведет к смещению акцентов с изучения отдельных алгоритмов обучения на уровень архитектуры обучающихся систем, содержащих множество взаимодействующих обучающихся модулей. До сих пор такие системы мы наблюдали лишь в живой природе. Речь идет, конечно же, о мозге. Возникает естественное желание продвинуться в этом направлении путем реинжиниринга *вычислительной архитектуры мозга* — больше нам учиться не у кого.

Подчеркнем, что речь идет именно о взгляде на мозг «с высоты птичьего полета». Именно здесь — в понимании общих принципов организа-

¹Предвестником этого тренда можно считать недавнее приобретение компанией Google за 400 млн. фт. ст. небольшого английского стартапа DeepMind, основанного в 2011 г., вскоре после публикации ими технического отчета [8] об алгоритме, способном обучаться играть в различные компьютерные игры на уровне человека, основываясь лишь на динамической картинке с компьютерного монитора.

ции работы мозга — в последние годы наметился определенный прогресс [9–11]. На более низких уровнях — от моделирования работы нейронных ансамблей, до деталей клеточных и генетических механизмов памяти, вопросов еще куда больше, чем ответов. И мы можем еще десятилетия углубляться в тонкие детали устройства мозга. Но с практической точки зрения, в свете вышесказанного, имеет смысл сосредоточиться именно на системном уровне.

В этом и состоит задача данного обзора — дать непротиворечивое описание современных представлений о глобальной архитектуре мозга, обобщив имеющиеся в литературе данные и теории.

В самом общем виде эту идею иллюстрирует картинка из работы [12], где показано, какие типы обучения характерны для таких крупных подсистем мозга, как кора, таламус, базальные ганглии и мозжечок.

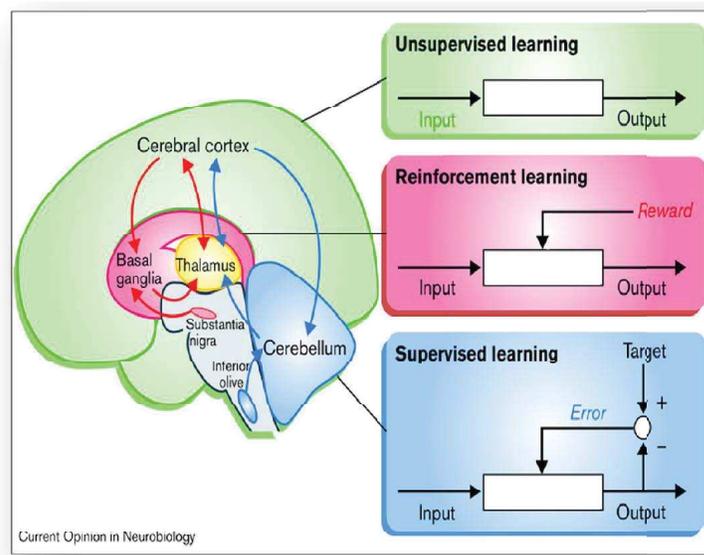


Рис. 1. Взаимодействие и схемы обучения основных подсистем мозга

В этой логике мы и построим свое изложение. А именно, попытаемся понять, в чем состоит задача каждой из этих подсистем, как эта задача выполняется и как эти подсистемы взаимодействуют друг с другом.

То, что они друг без друга «не живут», следует хотя бы из того эмпирического факта, что практически каждый элемент коры одновременно участвует в трех основных управляющих контурах [13]:

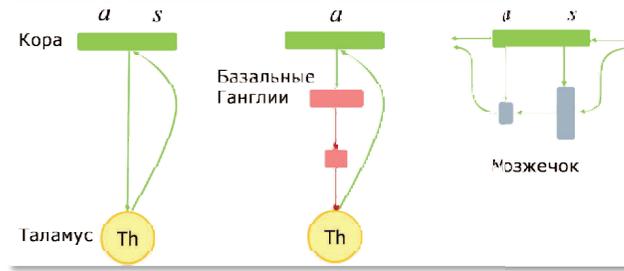


Рис. 2. Главные управляющие контуры мозга (*s*, *a* — области коры, распознающие ситуацию и вырабатывающие реакцию на нее, соответственно)

Кора накапливает знания о внешнем мире и способах взаимодействия с ним. Положительная обратная связь коры с таламусом обеспечивает поддержание активности коры в течение более-менее продолжительного времени, необходимого для согласования работы разных отделов коры. Базальные ганглии могут тормозить или растормаживать эту положительную связь, играя роль арбитра в соревновании активности разных участков коры. Наконец, мозжечок помогает осуществлять управление рутинными действиями, перенимая решения, ранее найденные корой и базальными ганглиями в процессе обучения.

В следующих разделах мы представим модели этих функциональных подсистем и их связь между собой, начиная с принципов работы самой эволюционно молодой и одновременно самой большой подсистемы человеческого мозга — коры². В частности, мы постараемся объяснить, в чем мозг млекопитающих качественно превосходит мозг рептилий. Аналогично, затем мы рассмотрим, в чем принципиальное отличие человеческого мозга от мозга других млекопитающих.

Наконец, в заключение мы обратимся к практическим аспектам нашего «архитектурного» подхода, а именно, в каком направлении следует разви-

²Точнее — таламо-кортикальной системы, в силу очень тесной функциональной связи таламуса с корой [14].

вать фон-неймановскую архитектуру наших компьютеров на пути к искусственному интеллекту.

Кора: ассоциативная модель мира и способов взаимодействия с ним

Кора мозга человека это тонкая (2–3 мм) двумерная нейронная ткань, общей площадью $2000 \pm 500 \text{ см}^2$. Она устроена на удивление единообразно, имея более или менее ярко выраженную слоистую и ячеистую структуры.

Качественные различия существуют лишь между более древними частями коры (*палеокортекс* и *архикортекс*) и более молодым *неокортексом*, преобладающим у человека (около 95% площади). Они различаются, в частности, числом слоев. Неокортекс, о котором, в основном, и пойдет речь далее, содержит шесть слоев клеток, тогда как более древние разделы имеют тем меньшее число слоев, чем они древнее. Чтобы понять, в чем эволюционный смысл увеличения числа слоев, остановимся сначала на слоистой структуре коры.

Как показано на рис. 3, разные слои коры играют разную роль при взаимодействии различных участков коры друг с другом, а также с подкорковыми структурами.

Верхние слои коры (II–III) принимают и передают сигналы между разными ее участками. Средний (IV) слой служит основным приемником информации от подкорковых структур и интегрирует ее с информацией от других участков коры. Результат транслируется в подкорковые структуры последовательно через слой V в базальные ганглии и затем через слой VI в таламус [15].

Интересно, что при передаче возбуждения в VI слой нейроны V слоя образуют своего рода «линию задержки», срабатывая примерно каждые 100 мс (на альфа-частоте ~ 10 Гц), тогда как активность в более высоких слоях коры обычно сосредоточена в гамма-диапазоне (~ 40 Гц) [16]. Теория этого явления появилась совсем недавно [17] и она стоит того, чтобы остановиться на ней более подробно, так как она очень многое объясняет.

Для лучшего понимания основной идеи теории, напомним сначала о технике *автокодирования*, когда слой скрытых нейронов в процессе обучения находит экономное кодирование, позволяющее восстанавливать входные сигналы сети.

Автокодирование можно получить, например, на скрытом слое двух-

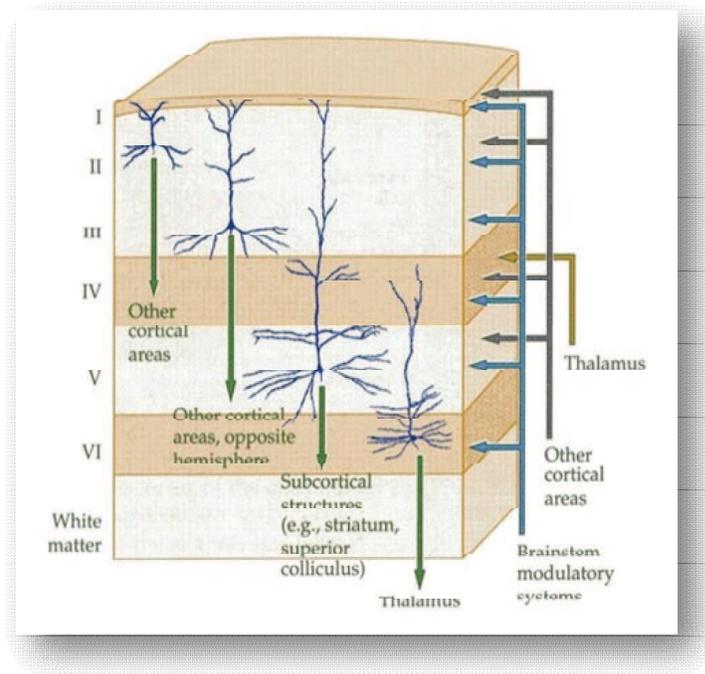


Рис. 3. Взаимодействие нейронов различных слоев неокортекса

слоистой перцептрона (рис. 4), обученном воспроизводить на выходах сети ее входы. Известно, однако, что аналогичного результата можно добиться и простым хеббовским обучением однослойной сети, дополнив его латеральным торможением для организации конкуренции между нейронами кодирующего слоя [18, 19]. Предельно упрощенная, но биологически обоснованная версия хеббовского обучения имеет следующий вид:

$$\delta W^{ij} \propto x^i y^j - \langle x^i y^j \rangle.$$

Здесь W^{ij} — матрица синаптических весов, x^i, y^j — активности входного и кодирующего слоев, а адаптивный порог $\langle x^i y^j \rangle$, зависящий от уровня межклеточного кальция, определяется средним по времени значением, которое является естественным ориентиром ожидаемой корреляции между

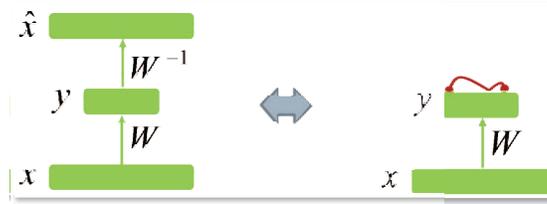


Рис. 4. Схема простого автокодирования: обучение с учителем и конкурентное обучение без учителя

данными входом и выходом. Обучение, таким образом, происходит лишь на неожиданных событиях [20].

Посмотрим теперь, что произойдет, если для автокодирования вместо обычной сети прямого распространения взять рекуррентную сеть (рис. 5) [21].

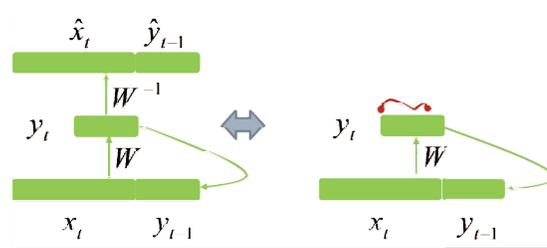


Рис. 5. Схема рекуррентного автокодирования: обучение с учителем и конкурентное обучение без учителя

В этом случае кодирующий слой также будет содержать сжатое представление, но уже не текущего *состояния*, а его *истории*. Как видно из левой части рис. 5, зная y_t можно последовательно восстановить не только x_t , но и все предыдущие входы сети (естественно, лишь приближенно). Применительно к машинному зрению такое кодирование в неявном виде содержит не только координаты предметов, но и их скорости. А это очень существенно, как для правильного выделения предметов, так и для предсказания развития событий. Не случайно в последние годы победителями различных соревнований все чаще становятся именно сети с рекуррент-

ным автокодированием (см. например [22, 23])³.

Авторы [17] считают, что именно такая схема и реализована в неокортексе млекопитающих (рис. 6). Роль кодирующего слоя играют нижние слои коры, которые через обратную связь с таламусом дополняют входы IV слоя закодированным в них локальным историческим контекстом.

Характерное время задержки (100 мс) позволяет собрать на входах IV слоя информацию с достаточно далеких участков неокортекса, с тем, чтобы сжать ее вместе с имеющейся предысторией на следующей итерации. На достаточно реалистичной модели зрительной коры авторы убедительно показали, что такое кодирование резко повышает качество распознавания предметов в сложных динамично меняющихся сценах.

Возможно, именно эта эволюционная новация сделала неокортекс настолько эффективным, что он начал интенсивно наращивать свою долю и роль в мозге млекопитающих.

Обратимся теперь к ячеистой структуре неокортекса, которая является следствием временных дисбалансов возбуждения и торможения в коре. Эксперименты свидетельствуют, что основным функциональным элементом неокортекса являются так называемые *колонки*, диаметром 300–500 мкм, содержащие $\sim 10^4$ нейронов [25]⁴. Каждая такая колонка «откликается» на определенную комбинацию своих входных сигналов. Размер колонки определяется расстоянием, на которое успевает распространиться возбуждение, прежде чем с некоторым запаздыванием включатся тормозные нейроны [26].

Из-за наличия локальной конкуренции в радиусе ~ 1 мм (характерный размер локальных аксонов пирамидальных нейронов коры [27]) победите-

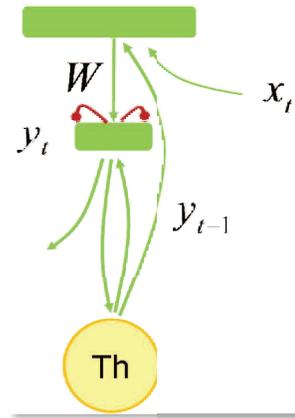


Рис. 6. Рекуррентный автоэнкодер в неокортексе: вверх входной слой (IV), вниз кодирующий слой (V–VI)

³Отметим также недавний успех команды Google, научившей рекуррентную нейросеть генерировать словесные описания фотографий [24].

⁴Не путать с минимальным структурным элементом неокортекса, *мини-колонкой*, содержащей около 100 нейронов.

лем оказывается лишь одна из нескольких десятков соседних колонок.

Предельно огрубляя, можно представить человеческий неокортекс как состоящий из $\sim 10^5$ *гиперколонок* (локальных рекуррентных самоорганизующихся карт [28]), каждая из которых распознает одно из нескольких десятков значений какого-то признака (атрибута). Например, 32 румба при ориентации в пространстве или одну из нескольких десятков фонем, букв алфавита, нот в октаве, аккордов и т. д. Ситуация в целом описывается набором таких признаков в схеме разреженного кодирования (рис. 7).

Таким образом, новая кора обладает *категориальной* памятью. Она представляет текущую ситуацию в виде устойчивых сочетаний признаков, обладающих предсказательной силой. Все случайное неокортексом отсеивается, остается лишь суть событий.

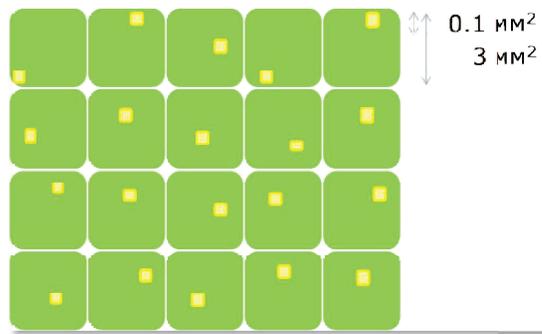


Рис. 7. Участок неокортекса, разбитый на гиперколонокки — области локальной конкуренции соседних колонок

По всей видимости, предки млекопитающих были лишены этой способности. Мы можем судить об этом по участку старой коры (архикортекс), *гиппокампу*⁵. В нем отсутствует ячеистая структура неокортекса, а связи между нейронами гораздо более разреженные и дальнедействующие. По современным представлениям, гиппокамп реализует ассоциативную память типа разреженной сети Хопфилда⁶. И если новая кора видит в окружающем мире лишь знакомые ей *типовые* паттерны, то древняя кора способна запоминать *произвольные* паттерны и их временные последова-

⁵Гиппокамп имеется у амфибий, но получил развитие уже у рептилий.

⁶См., например, [29, 30].

тельности. В мозге млекопитающих гиппокамп служит временным хранилищем нашей личной *эпизодической* памяти, фиксируя значимые для нас (об этом позже) события. Только у нас в эту память попадает уже осмысленная новой корой *семантическая* информация: входами в гиппокамп являются ассоциативные области коры. Со временем, память переходит из гиппокампа, имеющего ограниченную емкость памяти⁷, в новую кору, емкость которой ограничена лишь ее размерами. Этот процесс, называемый *консолидацией*, иллюстрирует рис. 8. Консолидация основана на способности гиппокампа проигрывать запомненное им по много раз, постепенно обучая неокортекс, например во время сна [31, 32].

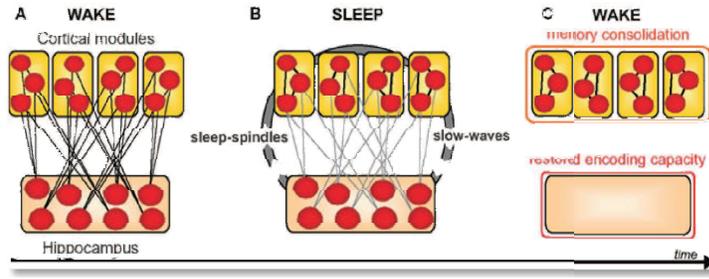


Рис. 8. Консолидация эпизодической памяти из гиппокампа в неокортекс во время сна (иллюстрация из [32])

Вернемся к неокортексу, который в процессе эволюции наращивал свои возможности с ростом своей поверхности. В человеческой коре выделяют несколько сотен функциональных областей⁸, которые, в свою очередь, объединяются в более крупные функциональные модули, примерно соответствующие зонам Бродмана. Наконец, корреляционный анализ активности коры позволяет выделить семь глобальных динамических функциональных сетей [9], о чем еще пойдет речь ниже.

Отметим пока лишь, что все модули коры образуют две тесно связанные друг с другом иерархии — сенсорную и моторную (рис. 9) [34].

При этом популярную сегодня технологию глубокого обучения, когда многослойные сети обучаются последовательно слой за слоем кодировать

⁷Емкость разреженной модели Хопфилда пропорциональна числу синапсов у отдельных нейронов и ограничена несколькими десятками тысяч паттернов [30].

⁸Например, авторы [33] выделяют 264 такие области.

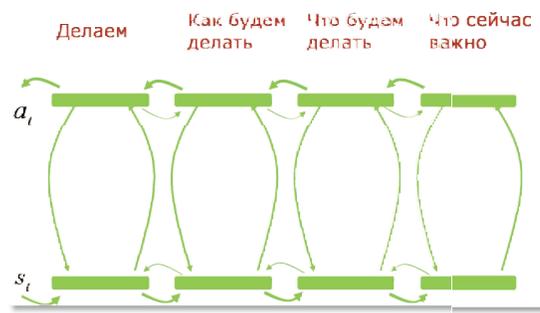


Рис. 9. Иерархическая обработка информации в коре. Внизу — иерархия признаков во входном потоке, вверх — иерархия ответных реакций. Вершина сенсорной иерархии — гиппокамп (справа внизу). Вместе с поясной извилиной (справа вверх) они образуют *лимбический* модуль коры.

и распознавать все более сложные признаки, можно считать принципиальной моделью сенсорной иерархии. Родоначальники Deep Learning черпали свои идеи из работ по моделированию зрительной системы для нужд компьютерного зрения [35–37]. И основная сфера применения Deep Learning — задачи распознавания образов — соответствует специализации сенсорной коры. Отметим, в частности, недавние успешные примеры глубокого обучения рекуррентных сетей [38] в полном соответствии с описанной выше рекуррентной моделью коры.

Между тем, вторая, дополнительная иерархия коры — организация сложного целенаправленного поведения сверху вниз — пока еще не вошла в практику прикладного машинного обучения. Хотя биологический прообраз такого обучения — обучение с подкреплением в базальных ганглиях, уже достаточно хорошо изучен.

Переходя от коры к базальным ганглиям, заметим, что в силу своей ассоциативной природы, кора сама по себе не способна обеспечить мышление, так как в ней отсутствует механизм концентрации. Подобно волнам на воде, в ней постоянно порождаются расходящиеся волны ассоциаций. Чтобы сконцентрироваться, подчинить действия единому плану, должен быть какой-то способ управления этими ассоциациями для организации целенаправленного поведения. Целью которого является не просто реакция на внешний стимул и не удовлетворение сиюминутных потребностей

организма, а именно *долговременная польза*, с учетом отдаленных последствий своих действий.

Такой механизм целенаправленного глобального управления различными областями коры обеспечивают базальные ганглии. Эта более древняя подсистема мозга сформировалась еще у рептилий в процессе эволюционной адаптации амфибий к жизни на суше. Именно эта подсистема обеспечила динозаврам доминирование на Земле в течение очень длительного времени. Без особых изменений сохранилась она и у современных млекопитающих [39]. В каком-то смысле даже у человека последнее слово в выборе поведения по-прежнему играет «мозг ящера», к рассмотрению которого мы и переходим.

Базальные ганглии: обучение ценностям

Как и полагается командному пункту, базальные ганглии спрятаны под поверхностью коры (рис. 10), большинство областей которой «докладывает» им о своем состоянии через выходные нейроны V слоя. Эти сигналы фокусируются на внешнюю поверхность базальных ганглий (в так называемый *стриатум*) в основном параллельными пучками аксонов из фронтальной коры, ответственной за поведение и мышление, и возвращаются в то же место, откуда начинались, через таламо-кортикальные связи. Через эти замкнутые управляющие контуры и осуществляется основной контроль за состояниями коры (см. рис. 11). Дополнительные диффузные связи (на рис. 11 опущены) снабжают стриатум контекстной информацией из других областей коры.

В каждый конкретный момент кора предлагает различные варианты возможных действий. Базальные ганглии оценивают ожидаемую пользу от каждого, и выбирают наилучший, с их точки зрения, вариант. Для соответствующего действия управляющий контур открывается, а для всех остальных — перекрывается. Решающую роль в этом выборе играет *допаминовая система* — комплекс нейронов, управляющий обучением стриатума (и в меньшей степени — лобной доли коры), впрыскивая в их синапсы мощный нейромедиатор *допамин*.

Рис. 12 иллюстрирует, как работают эти управляющие контуры [41]. Слева изображены основные возбуждающие (стрелки) и тормозные (точки) связи между различными подсистемами базальных ганглий. Как видно из рисунка, базальные ганглии содержат главным образом тормозные ней-

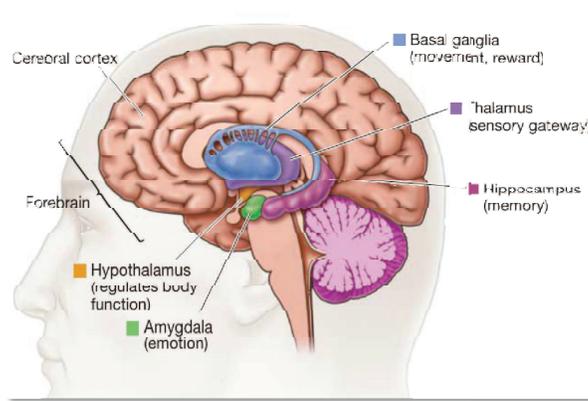


Рис. 10. Основные подсистемы управляющего контура базальных ганглий

роны. Это самая сильная тормозная подсистема мозга.

Возбуждение из коры (вверху) передается на две популяции нейронов стриатума, которые по-разному реагируют на выбросы допамина: D1 и D2 — два типа допаминовых рецепторов. Первых он усиливает, а вторых — подавляет. Уровень возбуждения D1 и D2 нейронов (на рисунке $Q^+(a, s)$ и $Q^-(a, s)$ соответственно), как мы увидим, дает верхнюю и нижнюю оценку полезности действия a в контексте s .

Единственным источником возбуждения в базальных ганглиях является субталамическое ядро, которое отражает средний уровень возбуждения конкурирующих между собой активностей коры (на рисунке: \bar{Q}). Если ожидаемая полезность данного действия меньше средней, то доминирует субталамическое ядро, и таламус тормозится (центральная часть рисунка). Напротив, для наиболее полезных действий таламус растормаживается, включая их в контур положительной обратной связи.

Так базальные ганглии регулируют активность коры, организуя глобальную конкуренцию между ее различными участками. Причем, конкурентная борьба может продолжаться и несколько раундов, пока не останется одно, потенциально самое полезное в данном контексте действие. Именно это мы испытываем в случае т. н. «трудного выбора».

Как нейроны стриатума оценивают полезность тех или иных действий? Через усиление или ослабление своих синаптических связей с корой в про-

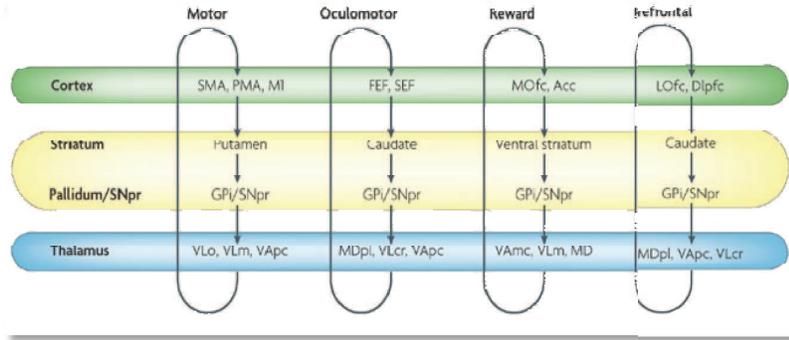


Рис. 11. Параллельные управляющие контуры. Верхний слой — фронтальная кора, средний слой — базальные ганглии, нижний слой — таламус [40]

процессе обучения с подкреплением. Соответствующий алгоритм обучения иллюстрирует рис. 13.

Обучение базируется на подкрепляющих сигналах r_t , получаемых от еще более древних управляющих систем мозга. Это, во-первых, *гипоталамус* (Ht), отвечающий за гомеостаз организма и выполнение генетических программ (врожденных рефлексов). И, во-вторых, *амигдала* (Am), которая учится в процессе жизни ассоциировать врожденные оценки с внешними сигналами (приобретенные рефлексы). Эти древние управляющие воздействия нацеливают организм на удовлетворение его сиюминутных потребностей (бежать, нападать и т. д.⁹) и определяют эмоциональную окраску каждого момента нашей жизни.

Базальные ганглии с помощью допаминовой системы вырабатывают более дальновидное поведение, с учетом возможных будущих выгод и потерь, обеспечивая тем самым преимущество в борьбе за существование.

Причем механизм обучения на удивление прост. Допаминовые нейроны (SNc) получают на вход возбуждения от двух популяций нейронов стриатума с разным знаком и текущий подкрепляющий сигнал (см. рис. 13):

$$\delta_t = r_t + Q_t^- - Q_t^+.$$

⁹Кроме центральной для обучения допаминовой системы, у млекопитающих существуют еще шесть врожденных базовых эмоций, которые и определяют разнообразие индивидуальных темпераментов [42].

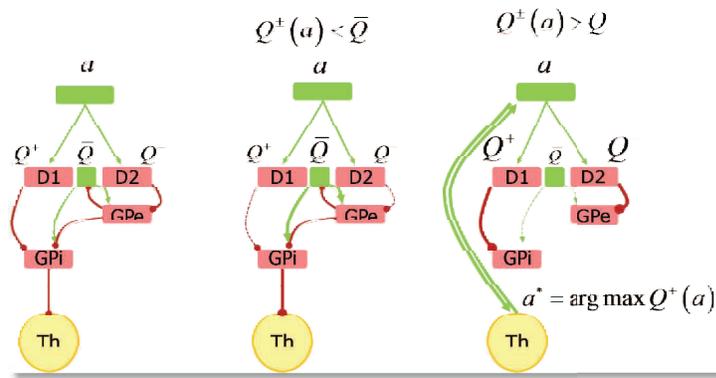


Рис. 12. Организация управляющего контура базальных ганглий. Слева: возбуждающие (стрелки) и тормозные (точки) связи. В середине: Низкая оценка полезности решения a , таламус заторможен, решение затухает. Справа: высокая оценка решения a , таламус расторможен, решение усиливается.

Уровень выделяемого ими в стриатуме допамина пропорционален именно этой комбинации. Назовем ее *радостью*, поскольку именно такие ощущения вызывают у нас выбросы допамина. Нейроны D1 усиливают, а нейроны D2 ослабляют свои синаптические связи с корой пропорционально уровню выделяемого допамина:

$$Q_{t+1}^+ = Q_t^+ + \alpha \cdot \delta_t,$$

$$Q_{t+1}^- = Q_t^- - \beta \cdot \delta_t.$$

Переходя к непрерывному времени, получим для разности $\Delta Q_t = Q_t^+ - Q_t^-$:

$$\Delta \dot{Q}_t + \gamma \Delta Q_t = \gamma r_t,$$

$$\Delta Q_t = \gamma \int^t dt' \cdot e^{\gamma(t'-t)} r_{t'} = \langle r_t \rangle.$$

Таким образом, в результате обучения разность ΔQ_t дает ожидаемую из прошлого опыта оценку подкрепления $\langle r_t \rangle$, усредненного за характерное время обучения $\gamma^{-1} = (\alpha + \beta)^{-1}$.

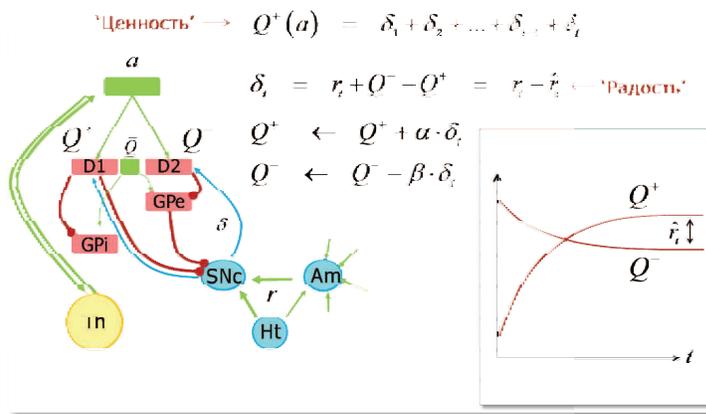


Рис. 13. Организация обучения с подкреплением в базальных ганглиях. Слева: Допаминовые нейроны *Substantia Nigra compacta* (SNc) получают подкрепляющий сигнал r_t от гипоталамуса (Ht) и амигдалы (Am), а также его ожидаемую оценку от стриатума: $\langle r_t \rangle = (Q^+ - Q^-)$. В середине: Выброс допамина в стриатуме пропорционален разности между наградой и ее ожиданием. Увеличение весов в области D1 и ослабление весов в области D2 под действием допамина. Справа: верхние и нижние оценки ценности решения a в контексте s по мере накопления опыта.

Ощущение радости мы испытываем при выбросе допамина, когда неожиданно получаем больше, чем рассчитывали:

$$\delta_t = r_t - \langle r_t \rangle.$$

Заметим, что, как и в случае с корой, обучение происходит при отклонении от средних (ожидаемых) значений. Ожидаемая награда не вызывает эмоций и не приводит к обучению, а завышенные ожидания — источник разочарований.

Две оценки ценности, определяющие выбор поведения, можно назвать *накопленной* и *обещанной* радостью при выборе данного поведения:

$$Q_t^+ = \alpha \int_0^t dt' \cdot \delta_{t'}, \quad Q_t^- = \beta \int_t^T dt' \cdot \delta_{t'}.$$

В обоих случаях мы имеем интегральные оценки суммарного количества получаемого от данного действия допамина. Все мы, млекопитающие — это подсевшие на допамин наркоманы и все наше поведение определяется жадной получить как можно большую дозу этого «гормона радости».

Заметим существенное отличие такой мотивации от понятия ценности в теории обучения с подкреплением, где ее обычно понимают как оценку всех будущих подкреплений: $Q_t(a) = \int_t^T dt' \cdot r_{t'}$. Но в биологии, видимо, все же «рулит» субъективная радость, а не объективная польза. Не зря же крысы могут до полного изнеможения стимулировать инъекции допамина в свой мозг в известных опытах, когда ни о какой пользе от этой деятельности уже не может быть и речи.

Подведем промежуточные итоги. В самой коре имеется лишь локальная конкуренция. Глобальную конкуренцию обеспечивают базальные ганглии, определяющие единственную доминантную активность с максимальной в данных обстоятельствах ценностью.

Поскольку базальные ганглии гораздо меньше коры, они не могут управлять мелкомасштабной активностью коры, решая по-крупному, какие области коры подключать в каждый момент времени. А уж те области, которым «дано добро», сами вырабатывают все детали поведения. Эту ситуацию иллюстрирует рис. 14.

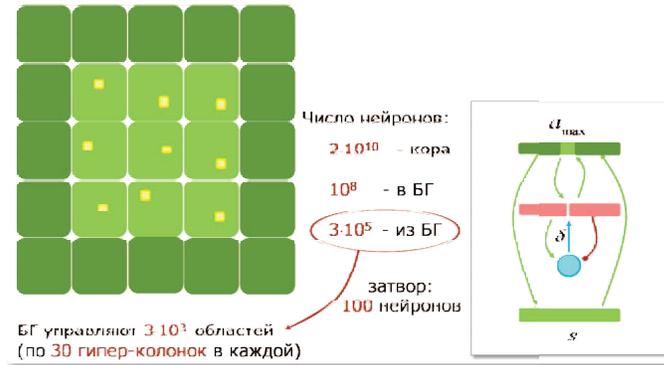


Рис. 14. Слева: участок коры, расторможенный базальными ганглиями — несколько десятков гиперколонок. Справа: схематическое изображение элементарной ячейки управляющего кортико-базального контура (таламус объединен с корой в качестве ее «седьмого слоя»)

Схема справа иллюстрирует общую картину взаимодействия коры, базальных ганглий и допаминовой системы. Итогом этого взаимодействия является выбор наиболее перспективного с точки зрения ожидаемого допаминового вознаграждения «разрешенного окна» в котором кора определяет оптимальное поведение a_{\max} в ситуации s .

Мы можем оценить нижнюю границу размера такого окна, которая определяется разрешающей способностью выходного модуля базальных ганглий, нейроны которого определяют степень торможения таламуса. Известно, что таких нейронов у человека около $3 \cdot 10^5$ [43]. Нейроны в мозгу работают не поодиночке. Они организованы в ансамбли, чтобы гибель какой-то их части в процессе жизни не сказывалась на функциональности. Если принять, что рабочий элемент на выходе состоит хотя бы из 100 нейронов (а это, по-видимому, минимальный нейронный ансамбль, соответствующий мини-колонке коры), то таких управляющих элементов на выходе из базальных ганглий будет около $3 \cdot 10^5 / 100 = 3000$. И вряд ли это число сильно меньше, так как у человека более 600 мускулов, которые надо избирательно контролировать, а управляющая ими моторная кора занимает лишь небольшую часть фронтальной коры¹⁰.

Если принять эту оценку в качестве рабочей гипотезы, то размер расторможенного базальными ганглиями окна будет $1/3000$ лобной доли, и оно будет содержать всего несколько десятков гиперколонок ($\sim 10^5 / 3000 = 30$), в каждой из которых кора самостоятельно выберет локальную колонку победителя. Все вместе они будут кодировать различные компоненты выбранного поведения в данных конкретных условиях.

Мы можем также оценить, какую часть коры базальные ганглии реально тормозят. Для этого воспользуемся оценками энергетических затрат, связанных с нейронными возбуждениями в коре. Согласно [44], средняя интенсивность срабатывания нейронов в коре человека составляет 0.16 спайков/с/нейрон, тогда как активность интенсивно работающих участков коры впятеро больше: 0.8 спайков/с/нейрон¹¹. Это значит, что одновременно с такой интенсивностью могут работать не более 20% мозга. И то, если принять, что остальные 80% полностью пассивны. С учетом ненулевого уровня спонтанных разрядов нейронов, доля «активных пятен» в коре

¹⁰ Действительно во фронтальной коре обнаружены анатомические области (stripes) объединенные в кластеры, которые по размерам и количеству соответствуют гиперколонкам и контролируемым базальными ганглиями модулям из нескольких десятков гиперколонок [15,43].

¹¹ Такая энергетика характерна для первичной зрительной коры в рабочем состоянии.

снижается. Если же учесть, что существенную часть этой активности составляют неподконтрольные базальным ганглиям высоконагруженные первичные сенсорные области, можно предположить, что базальные ганглии держат под замком более 90% контролируемой ими площади коры.

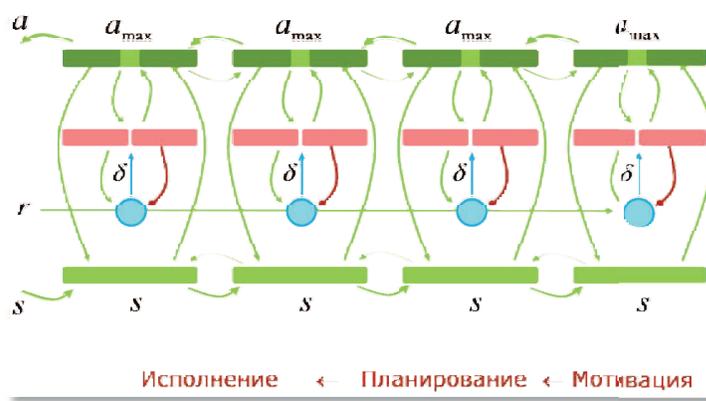


Рис. 15. Иерархия управляющих контуров в архитектуре *Deep Control*

Энергетические ограничения позволяют также оценить, сколько нейронов срабатывает в возбужденной колонке, основном рабочем элементе коры. В активной гиперколонке первичной коры частота спайков, как уже говорилось, 0.8 спайков/с/нейрон. Известно, что первичная кора различает примерно 16 направлений (соответствующих 32 румбам), т.е. состоит из примерно 16 конкурирующих между собой колонок. Соответственно, активность в колонке-победителе в 16 раз выше, чем в среднем по гиперколонке, т.е. около 10 спайков/с/нейрон. Если принять, что активный нейрон генерирует порядка 100 спайков/с¹², то в активной колонке одновременно должно срабатывать порядка 10% нейронов (10³ из 10⁴ нейронов).

Резюмируя этот раздел, вспомним об иерархическом устройстве коры: каждый раздел базальных ганглий контролирует свои области коры. В итоге вырисовывается следующая модульная вычислительная архитектура мозга, назовем ее для краткости архитектурой *Deep Control* (рис. 15).

Она включает в себя распознавание ситуации в виде согласованной

¹²Самый высокий диапазон активности коры — high-gamma: 80–200 Гц.

снизу вверх иерархии признаков (сенсорная кора), и выработку адекватного поведения, также организованного иерархически и согласованного сверху вниз (лимбическая, ассоциативная, премоторная и моторная кора). Обучение такой системы происходит постоянно в режиме он-лайн в процессе тесного взаимодействия с внешней средой.

Такая самообучающаяся иерархическая управляющая система способна одновременно оперировать на многих временных масштабах. Как наш мозг одновременно и согласованно координирует целенаправленные активности в диапазоне от десятых долей секунды до минут, часов, дней и лет¹³.

Мозжечок: закрепление пройденного

Кора и базальные ганглии отлично дополняют друг друга. Кора формирует и распознает полезные признаки текущей ситуации и предлагает возможные варианты ответов. Базальные ганглии выбирают из них те, которые обещают организму максимальный драйв.

Но обе эти подсистемы насыщены положительными и отрицательными обратными связями, порождающими богатую всевозможными ритмами хаотическую динамику активности мозга [49]. В итоге выработка ответа в них может занимать достаточно длительное время. В условиях жесткой борьбы за существование, когда промедление смерти подобно, мозг сформировал дополнительную подсистему «быстрого реагирования». Она запоминает найденные корой решения и реализует их с максимально возможной скоростью — в один проход, без всяких обратных связей. Значение этой системы подчеркивается тем фактом, что в ней содержится большая часть всех клеток головного мозга¹⁴.

Речь идет, конечно же, о мозжечке, который с вычислительной точки зрения представляет собой обычный перцептрон. Но этот перцептрон очень правильно, «с умом» включен в «первичную» кортико-базальную систему управления, у которой он постоянно учится, перенимая ее опыт и постепенно замещая ее управляющие сигналы своими [50].

На вход мозжечок получает ту же входную информацию, что и первичная управляющая система, а также выходную информацию о принятых

¹³Иерархическое обучение с подкреплением с привязкой к основным подсистемам мозга рассмотрено, например, в работах [45–48].

¹⁴У млекопитающих размер мозжечка коррелирует с размером коры и он содержит примерно в 3–4 раза больше нейронов, чем кора.

ею решениях (рис. 16). Последняя используется им в качестве шаблона ошибки, для тренировки своих настроечных весов. Выходы из мозжечка дополняют выходы его «учителя». В идеале, при стремлении ошибки к нулю, результатом такого обучения была бы полная разгрузка «учителя». В реальности, ошибка, конечно же, всегда остается, но жизнь «учителя» существенно упрощается. Все, что может сделать простой персептрон с одним скрытым слоем, он берет на себя.

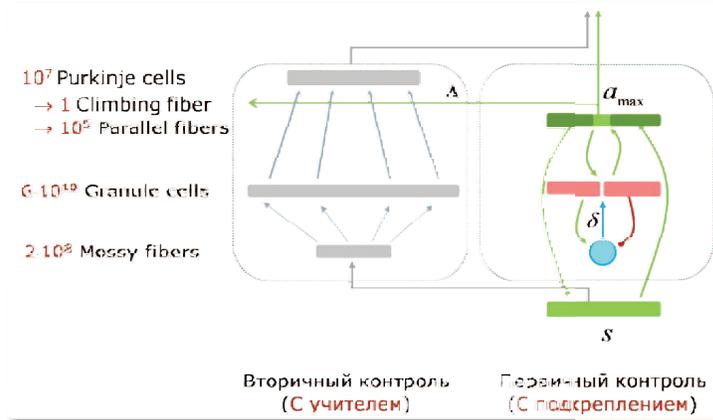


Рис. 16. Мозжечок: вторичный контроллер, перенимающий контроль у первичного контроллера (кора + базальные ганглии) в процессе обучения

Организована эта изящная схема следующим образом. В мозжечок через примерно 200 млн. *мшистых* волокон поступает очень подробная первичная сенсорная информация как непосредственно из спинного мозга, так и, главным образом, из коры, о распознанных ею простых и сложных признаках, описывающих ситуацию¹⁵. Эта информация распределяется случайным образом по очень большому числу нейронов *скрытого слоя*, так называемых *гранулярных* клеток. Каждая из них представляет собой какую-то одну (случайную) комбинацию нескольких входных признаков. Чем больше таких признаков, тем выше возможности персептрона.

¹⁵Число входов в мозжечок примерно равно числу аксонов в *мозолистом теле*. Т.е. мозжечок интегрирован с корой так же тесно, как правое и левое полушария друг с другом.

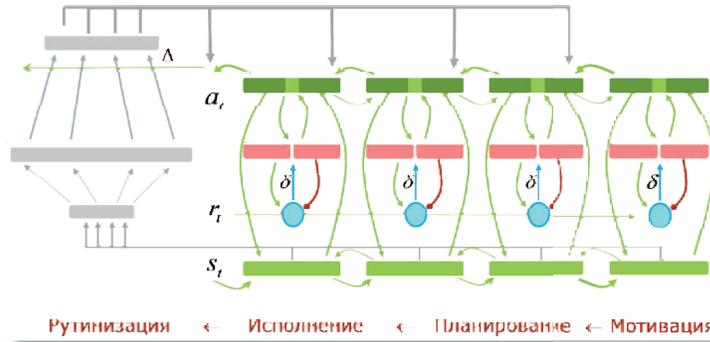


Рис. 17. Мозжечок перехватывает управление рутинными операциями мышцами (на выходе из коры) и мыслями (в самой коре)

Вот для чего нужно такое громадное число гранулярных клеток (которые по необходимости имеют минимально возможные размеры).

Выходной слой персептрона формирует около 15 млн. постоянно работающих очень крупных клеток Пуркинье с очень развитой дендритной системой. Каждая такая клетка складывает сигналы от порядка 10^5 синаптических связей с различными гранулярными клетками, т. е. учитывает при выборе решения именно такое число настроечных параметров. Кроме того, каждая клетка Пуркинье изредка (раз в секунду) получает очень мощный «учебный» сигнал от одного единственного *лазающего волокна*, которое дублирует информацию о принятых «учителем» решениях. Этот учебный сигнал гарантированно заставляет клетку Пуркинье сработать и в этот момент происходит обучение тех из 10^5 ее синапсов, которые соединяли ее с активными в этот период гранулярными клетками.

Итоговый алгоритм обучения:

$$\delta W^{ij} \propto x^i (y_0^j - y^j) = -\frac{1}{2} \frac{\partial (y_0^j - y^j)^2}{\partial W^{ij}},$$

(где $x, y = Wx$ — активности соответственно гранулярных клеток и клеток Пуркинье, а y_0 — обучающий сигнал от лазающего волокна), является типичным обучением с учителем, которое прекращается лишь тогда, когда мозжечок полностью копирует управляющие решения, ранее найденные

корой и базальными ганглиями¹⁶.

Выходной сигнал из мозжечка формируют не сами клетки Пуркинье, а интегрирующие их сигнал нейроны глубоких ядер¹⁷, число которых на порядок меньше числа клеток Пуркинье [51, 52]. Таким образом, число выходов из мозжечка сравнимо с общим числом выходных волокон из моторной коры (и то и другое $\sim 10^6$). То есть, похоже на то, что основная задача мозжечка — действительно эмулировать эфферентные управляющие сигналы от моторной коры. Кроме того, часть выходов от мозжечка поступает во фронтальные отделы коры через таламус, ускоряя процесс принятия решений в самой коре¹⁸.

Теперь мы можем представить архитектуру Deep Control с учетом роли и взаимодействия всех трех основных подсистем мозга (рис. 17). Лимбическая система (самый правый блок в цепочке) на основании самой общей информации о состоянии мира и нуждах организма задает текущую цель, инициирующую разработку в префронтальной коре планов поведения. Та с помощью ассоциативных разделов коры вырабатывает замысел и цепочку промежуточных целей. Премоторная кора вместе со вторичными сенсорными областями разворачивает каждую из них в цепочку конкретных действий, спускаемых для исполнения в сенсомоторный блок. Все найденные ранее управляющие воздействия по возможности запоминаются и воспроизводятся мозжечком с минимальными задержками, разгружая кору от контроля над рутинными операциями.

Абстрактное мышление: виртуальная реальность

Хотя все численные оценки до сих пор и относились к человеческому мозгу, описанная нами архитектура — общая для всех млекопитающих. Количественные различия могут быть очень большие, но качественно мозг мыши и мозг человека имеют один и тот же базовый дизайн — Deep Control.

Тем не менее, нельзя отрицать, что между человеком и мышкой, и даже между человеком и шимпанзе, есть качественные различия. Хотя до

¹⁶В реальности, обучение синаптических весов уменьшает активность клеток Пуркинье, но поскольку последние являются тормозными, итоговый эффект обучения — усиление выходного возбуждения пропорционально обучающему сигналу.

¹⁷Мы описали работу мозжечка в несколько упрощенном варианте, достаточном для понимания общих принципов.

¹⁸Мозжечок активно участвует во многих когнитивных процессах [13].

двух лет детеныши шимпанзе и человека развиваются примерно по одному сценарию, далее траектории их развития кардинально расходятся, даже если они живут бок о бок. Что же отличает наш мозг с точки зрения его архитектурных особенностей?

Терренс Дикон очень удачно определил наш вид, как «symbolic species» [53], в том смысле, что нашей главной отличительной чертой является способность оперировать абстрактными символами, способность к абстрактному мышлению.

Анатомически это выражается в существенном увеличении ассоциативных областей коры, в особенности префронтальной коры. Причем в этих эволюционно самых молодых областях коры пирамидальные нейроны 3-го слоя, осуществляющие связь между различными разделами коры, существенно крупнее, чем в остальных [15]. Т. е. эволюция явно шла по пути увеличения связности мозга.

Новые данные об анатомической и функциональной связности различных областей коры (определяемой через корреляцию их активностей) однозначно свидетельствуют в пользу теории «малого мира» [54]. Согласно этой концепции, различные части коры могут эффективно обмениваться информацией через небольшое число *хабов*, образующих в совокупности *глобальное рабочее пространство* [55]. Наличие сознания характеризуется глобальными корреляциями мозговой активности, тогда как в бессознательных состояниях мозговая активность асинхронна [56].

Исследования последних лет позволили выявить в коре несколько функциональных систем, состоящих из областей, обычно коррелирующих свою активность. У людей наиболее развита так называемая *лобно-теменная система* (Frontoparietal Network), основным хабом которой является *латеральная префронтальная кора* (Lateral Prefrontal Cortex). Эта система отвечает за решение когнитивных задач и шире — за принятие решений в незнакомых ситуациях [57].

Она включается тогда, когда интуитивные решения, основанные на прошлом опыте, не решают поставленной задачи сходу. *Даниэль Канеман* называет режим интуитивного принятия решений, функционирование которого мы до сих пор и описывали, *Системой-1*. Когда мы «включаем логику», вступает в действие *Система-2*, т. е. активизируется лобно-теменная система. Она последовательно разбивает незнакомые задачи на более простые и знакомые, запоминает и сводит промежуточные решения воедино [58].

Лобно-теменная система обладает максимальной связностью, т. е. име-

ет доступ к самому большому числу областей мозга, которые она может при необходимости подключать к решению конкретных задач. Это своего рода *Универсальная машина Тьюринга* в нашем мозгу¹⁹.

Известно, что индивидуальный IQ коррелирует со степенью связности лобно-теменной системы [9]. Естественно предположить, что и уровень нашего видového интеллекта определяется именно этой системой.

Рис. 18 иллюстрирует функционирование мозга в режиме *Системы-1* (стимул-реакция) и в режиме *Системы-2* (перебор вариантов и выбор наилучшего). В последнем режиме *сознательного мышления* часть мозга по возможности отключается от внешнего мира и стремится в своем воображении смоделировать различные варианты развития событий. Лобно-теменная система организует своего рода «виртуальную реальность», в которой можно рисковать «виртуальными жизнями» без риска лишиться реальной.

С точки зрения теории управления, мы переходим от ситуативного управления (model-free) к управлению с моделированием (model-based) [59].

Мощные связи внутри коры позволяют учитывать воображаемые последствия тех или иных решений и управлять поведением уже не на уровне отдельных действий, а на уровне их цепочек, т. е. замыслов и планов. Пока не будет найдено приемлемое решение, которое базальные ганглии допустят к исполнению. Таким образом, вместо фиксированного набора действий перед нами открывается бесконечный мир их комбинаций.

Наш мозг способен запоминать и повторно использовать эффективные способы решения различных задач, формируя свои *навыки мышления* аналогично *навыкам поведения* в реальном мире. Для работы в виртуальном мире кора формирует абстрактные символы различных классов предметов и способы действий с ними²⁰. Способность к абстрактному мышлению ограничивается лишь нашей способностью сосредотачиваться на символах, отвлекаясь от реального мира, и глубиной нашей *рабочей памяти*.

Последняя основана не на долговременных изменениях синаптических связей, а на текущей активности различных областей коры. По мере того, как базальные ганглии переключают внимание с анализа одного варианта на анализ другого, активность временно отключенных участков коры зату-

¹⁹Только с весьма ограниченной памятью, почему компьютеры настолько сильнее нас в исполнении любых формальных алгоритмов.

²⁰Так, архикортекс задействует свои древние механизмы навигации в пространстве для ориентации в символьных когнитивных структурах [60].

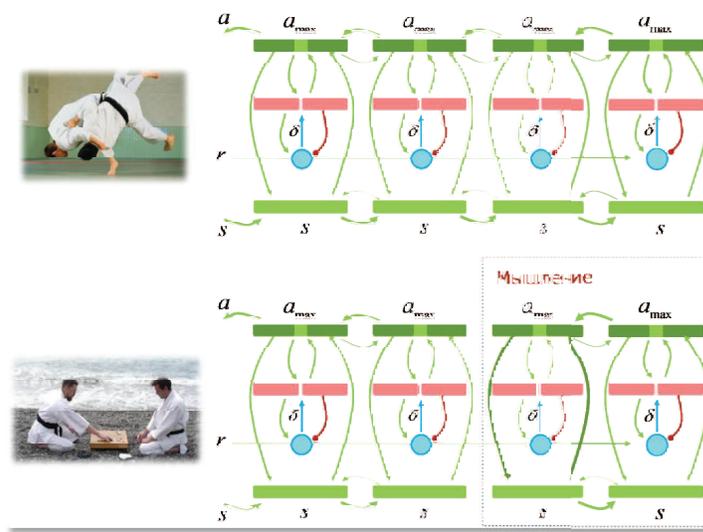


Рис. 18. Два режима функционирования мозга. Вверху — реактивный режим on-line реагирования на внешнюю ситуацию. Внизу — выработка решений off-line путем моделирования последствий возможных действий

хает. Чтобы одновременно держать в уме несколько объектов, приходится постоянно переключаться между ними в процессе «умственного жонглирования». Т. е. известный закон Миллера о емкости оперативной памяти относится к нашей способности умственно жонглировать не более чем 7 ± 2 предметами²¹.

Итак, абстрактное мышление использует механизмы выработки решений, перенесенные из мира реальных вещей в мир нашего воображения. Сознательное мышление *Системы-2* организует свою «виртуальную реальность», где под управлением префронтальной коры сравниваются между собой различные способы достижения заданной цели. Однако большую часть времени мы решаем рутинные задачи привычными способами в режиме *Системы-1*.

²¹ Модель, объясняющая это известное ограничение емкости рабочей памяти, представлена в [61], а в [62] предложен биологически обоснованный алгоритм функционирования рабочей памяти.

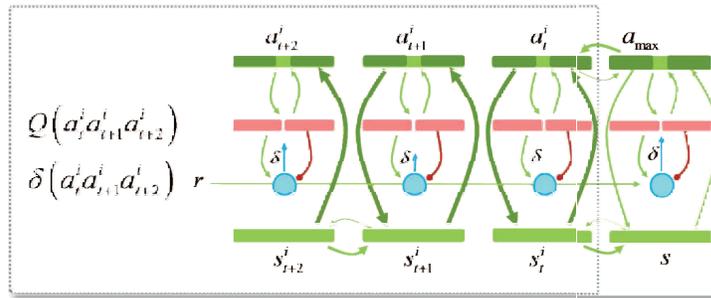


Рис. 19. Планирование поведения на несколько шагов вперед

Заключение. Новая старая архитектура

В заключение подытожим, к чему мы пришли и что это нам дает с точки зрения понимания интеллекта природного и создания интеллекта искусственного.

Прежде всего, оказалось, что наших знаний о мозге уже хватает, чтобы, пусть и в самых общих чертах, «на живую нитку», описать принципы работы его основных подсистем.

Это, прежде всего, кора, содержащая основную часть синапсов $\sim 10^{14}$, в которых и хранится подавляющая часть нашей памяти. Память организована иерархически и имеет две тесно взаимодействующих ветви. Первая запоминает паттерны (часто повторяющиеся комбинации) признаков, а также паттерны этих паттернов и т. д. в потоке входной информации. Вторая вырабатывает управляющие паттерны (комбинации координированных действий), а также паттерны этих паттернов и т. д. в потоке выходной информации.

Соответственно, в отличие от компьютерной, наша память активна. В ней постоянно возбуждаются волны ассоциаций по всем возможным объяснениям происходящего и всем возможным вариантам поведения. Чтобы выбрать и осуществить какой-то один из них, ассоциативную память необходимо дополнить системой жесткой селекции, тормозящей любую активность коры, кроме одной — доминантной. Эту роль выполняет основная тормозная система мозга, базальные ганглии. Критерием отбора служит максимизация *ожидаемой суммарной радости* — встроенной в наш мозг базовой эмоции, определяемой выбросами допамина в моменты, когда на-

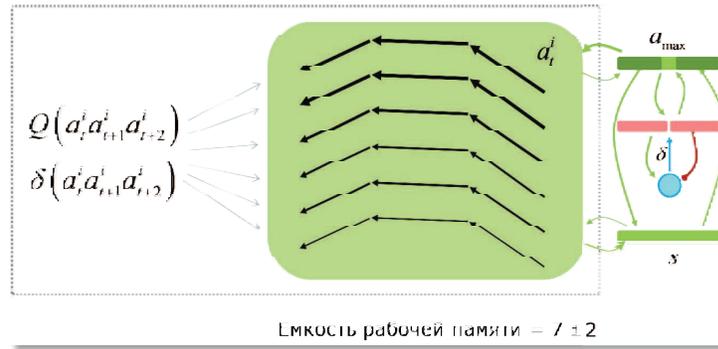


Рис. 20. Удержание в рабочей памяти нескольких вариантов решения при последовательном переключении между ними (жонглирование мыслями)

града (подкрепление от остальных эмоций) превышает ожидания. Таким образом, базальные ганглии обеспечивают достижение долгосрочных целей, а не только удовлетворение текущих потребностей организма.

Наконец, подсистема, содержащая максимальное число нейронов мозга — мозжечок, берет на себя управление в типовых ситуациях, освобождая ресурсы коры и базальных ганглий от рутинной работы. Он просто запоминает управляющие действия коры в типовых ситуациях и эмулирует их, сокращая до минимума время принятия типовых решений.

Такое распределение ролей между основными подсистемами объясняет базовые механизмы их обучения: выделение типовых признаков в коре через конкурентное *обучение без учителя*, выбор поведения в базальных ганглиях через *обучение с подкреплением*, а также аппроксимацию функции через *обучение с учителем* в мозжечке.

Понимание назначения основных подсистем задает рамку, контекст, в который можно вписывать многочисленные частные факты и модели. Подобно тому, как картинка на обложке пазла существенно облегчает его сборку из разрозненных и бессмысленных каждая по отдельности частей.

Ну а с практической точки зрения: что нам дает понимание архитектуры нашего мозга? Во-первых, понятно направление, в котором имеет смысл двигаться. Ведь эта архитектура кардинально отличается от архитектуры современных компьютеров, которая в основных чертах сохрани-

лась с момента публикации в 1946 г. фон Нейманом наброска ее основных принципов.

В существующих компьютерах активный процессор взаимодействует с пассивной памятью, где хранятся алгоритмы, определяющие ход вычислений. Подразумевается, что они задаются извне — программистами. Соответственно и компьютерный интеллект, если таковой и появится, должен быть привнесен в машину извне.

Мышление, как биологический феномен, устроено по-другому. Природный интеллект не может возникнуть извне. Поэтому архитектура мозга включает в себя не только процесс *исполнения* алгоритмов, но и процесс их *порождения* — путем обучения. Интеллект формируется постепенно в процессе активного взаимодействия с миром, путем постоянного тестирования и отбора адекватных моделей мира и стратегий поведения в нем.

Соответственно, в этой архитектуре должен быть предусмотрен источник активности — *драйв*, стремление учиться и получать радость от неожиданных открытий. Память должна быть активной, способной порождать новые варианты поведения в незнакомых ситуациях. Наконец, ограниченные ресурсы для этой творческой работы необходимо освобождать от загрузки рутинной.

Таким образом, на пути к искусственному интеллекту нам предстоит ни много ни мало, как «вдохнуть душу» в компьютеры, заменив их бездушную, механическую фон-неймановскую архитектуру на гораздо более человеческую архитектуру природного интеллекта млекопитающих.

Более того, у нас даже имеется подсказка, как именно этого можно достигнуть. Одной из важнейших эволюционных находок млекопитающих оказалась *масштабируемая архитектура* их мозга, состоящего из однотипных модулей. Такая модульная архитектура позволяет наращивать возможности мозга простым увеличением числа модулей, каждый из которых может специализироваться на определенной задаче. Что, по всей видимости, и происходило в ходе эволюции от первых грызунов до приматов и человека.

Если нам удастся перенять у природы этот модульный дизайн, мы получим в свое распоряжение *масштабируемый* искусственный интеллект. Остается только спросить себя, а можно ли вообще получить такой интеллект «в свое распоряжение»?

Литература

1. Hinton G. et al. A fast learning algorithm for deep belief nets // *Neural Computation*. – 2006. Vol. 18, No. 7. – pp. 1527–1554.
2. Bengio Y. et al. Greedy layer-wise training of deep networks // *Advances in Neural Information Processing Systems (NIPS)*. – 2007. – Vol. 19. – pp. 153–161.
3. Литература Lee H., Ekanadham R., Ng A. Sparse deep belief net model for visual area V2 // *Advances in Neural Information Processing Systems (NIPS)*. – 2007. – Vol. 7. – pp. 873–880.
4. Lu C., Tang X. Surpassing human-level face verification performance on LFW with GaussianFace. – arXiv:1404.3840 [cs.CV] 16 Jun 2014.
5. Ferrucci D. et al. Building Watson: An overview of the DeepQA project // *AI Magazine*. – 2010. – Vol. 31, No. 3. – pp. 59–79.
6. Ciresan D. et al. Multi-column deep neural network for traffic sign classification // *Neural Networks*. – 2012. – Vol. 32. – pp. 333–338.
7. Ciresan D. et al. Mitosis detection in breast cancer histology images with deep neural networks / In: *Proc. MICCAI*. – 2013. – Vol. 2. – pp. 411–418.
8. Mnih V. et al. Playing Atari with deep reinforcement learning. – Technical Report arXiv:1312.5602 [cs.LG], Deepmind Technology. Dec 2013.
9. Koziol L.F. et al. Structure and function of large-scale brain systems // *Applied Neuropsychology: Child*. – 2014. – Vol. 3. – pp. 236–244.
10. Koziol L.F. et al. The small-world organization of large-scale brain systems and relationships with subcortical structures // *Applied Neuropsychology: Child*. – 2014. – Vol. 3. – pp. 245–252.
11. Koziol L.F. et al. Large-scale brain systems and subcortical relationships: The vertically organized brain // *Applied Neuropsychology: Child*. – 2014. – Vol. 3. – pp. 253–263.
12. Doya K. Complementary roles of basal ganglia and cerebellum in learning and motor control // *Current Opinon in Neurobiology*. – 2000. – Vol. 10. – pp. 732–739.
13. Koziol L. F., Budding D. E., Subcortical Structures and Cognition. Implications for Neurophysiological Assessment. – Springer, 2009.
14. Izhikevich E. M., Edelman G. M. Large-scale model of mammalian thalamocortical systems // *PNAS*. – 2008. – Vol. 105, No. 9. – pp. 3593–3598.
15. Solari S., Stoner R. Cognitive consilience: primate non-primary neuroanatomical circuits underlying cognition // *Frontiers in Neuroanatomy*. – 2011. – Vol. 5, Article 65.

16. Spaak E. et al. Layer-specific entrainment of gamma-band neural activity by alpha rhythm in monkey visual cortex // *Current Biology*. – 2012. – Vol.22, No.24. – pp. 2313–2318.
17. O'Reilly R. et al. Learning through time in the thalamocortical loops. – arXiv:1407.3432v1 [q-bio.NC] 13 Jul 2014.
18. Oja E. Simplified neuron model as a principal component analyzer // *Journal of Mathematical Biology*. – 1982. – Vol. 15, No. 3. – pp.267–273.
19. Baldi P. Autoencoders, unsupervised learning, and deep architectures // In: *Proc. Workshop on Unsupervised and Transfer Learning*. – 2012. – Vol. 27. – pp.37–50.
20. O'Reilly et al. Computational cognitive neuroscience. – 2012.
URL: <http://www.amazon.com/Computational-Cognitive-Neuroscience-ebook/dp/B007H9YWAG>
21. Elman J.L. Finding structure in time // *Cognitive Science*. – 1990. – Vol. 14. – pp. 179–211.
22. Mikolov T. Statistical language models based on neural networks. – PhD Thesis, Brno University of Technology, 2012.
23. Schmidhuber J. Deep learning in neural networks: An overview. – Technical Report IDSIA-03-14 / arXiv:1404.7828 v3 [cs.NE], 2014.
24. Vinyals O. et al. Show and tell: A neural image caption generator. – arXiv:1411.4555v [cs.CV] 17 Nov 2014.
25. Mountcastle V. The columnar organization of neocortex // *Brain*. – 1997. – Vol. 120. – pp. 701–722.
26. Derdikman D. et al. Imaging spatiotemporal dynamics of surround inhibition in the barrels somatosensory cortex // *The Journal of Neuroscience*. – 2003. – Vol. 23, No. 8. – pp. 3100–3105.
27. Boucsein C. et al., Beyond the cortical column: abundance and physiology of horizontal connections imply a strong role for inputs from the surround // *Front. Neurosci.* – 01 April 2011 | doi: 10.3389/fnins.2011.00032.
28. Tino P., Farkas I., van Mourik J. Dynamics and topographic organization of recursive self-organizing maps // *Neural Comput.* – 2006. – Vol. 18, No. 10. – pp. 2529–2567.
29. Rolls E. A computational theory of episodic memory formation in the hippocampus // *Behavioural Brain Research*. – 2010. – Vol. 215. – pp. 180–196.
30. Rolls E. A quantitative theory of the functions of the hippocampal CA3 network in memory // *Frontiers in Cellular Neuroscience*. – 2013. – Vol. 7, Article 98.
31. Battaglia F. et al. The hippocampus: hub of brain network communication for memory // *Trends in Cognitive Sciences*. – 2011. – Vol. 15, No. 7. – pp. 310–318.

32. *Saletin J., Walker M.* Nocturnal mnemonics: sleep and hippocampal memory processing // *Front. Neurology*. – 2012. doi: 10.3389/fneur.2012.00059.
33. *Power J.D. et al.* Functional network organization of the human brain // *Neuron*. – 2011. – Vol. 72. – pp. 665–678.
34. *Fuster J.M.* Cortex and mind. Unifying cognition. – Oxford Univ. Press, 2003.
35. *Dileep G.* How the brain might work: A hierarchical temporal model for learning and recognition. – Ph.D. Thesis. Stanford University, 2008.
36. *Gorder P.* Computer vision, inspired by the human brain // *Computing in Science & Engineering*. – Mar/Apr. 2008. – pp. 6–11.
37. *Poggio T. et al.* The computational magic of the ventral system. – MIT-CSAIL-TR-2012-035 December 29, 2012.
38. *Graves A.* Speech recognition with deep recurrent neural networks // In: *Proc. of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. – 2013. – pp. 6645–6649.
39. *Reiner A. et al.* Structural and functional evolution of the basal ganglia in vertebrates // *Brain Research Reviews*. – 1998. – Vol. 28. – pp. 235–285.
40. *Kringelbach M.L. et al.* Translational principles of deep brain stimulation // *Nature Reviews Neuroscience*. – 2007. – Vol. 8. – pp. 623–635.
41. A computational model of action selection in basal ganglia. I. A new functional anatomy // *Biol. Cybern.* – 2001. – Vol. 84. – pp. 401–410.
42. *Panksepp J. and Biven L.* The archaeology of mind: Neuroevolutionary origins of human emotions. – N.Y.: Norton, 2012.
43. *Frank M. et al.* Interactions between frontal cortex and basal ganglia in working memory: A computational model // *Cogn. Affect Behav. Neurosci.* – 2001. – Vol. 1, No. 2. – pp. 137–160.
44. *Lennie P.* The cost of cortical computation // *Current Biology*. – 2003. – Vol. 13. – pp. 493–497.
45. *Botvinick M.* Hierarchical reinforcement learning and decision making // *Current Opinion in Neurobiology*. – 2012. – Vol. 22. – pp. 956–962.
46. *Ito M., Doya K.* Multiple representations and algorithms for reinforcement learning in the cortico-basal ganglia circuit // *Current Opinion in Neurobiology*. – 2011. – Vol. 21. – pp. 368–373.
47. *Reynolds J., O'Reilly R.* Developing PFC representations using reinforcement learning // *Cognition*. – 2009. – Vol. 113. – pp. 281–292.
48. *Frank M., Badre D.* Mechanisms of hierarchical reinforcement learning in corticostriatal circuits 1: computational analysis // *Cerebral Cortex*. – 2012. – Vol. 22. – pp. 509–526.

49. *Buzhaki G.* Rhythms of the brain. – Oxford University Press, 2006.
50. *Kawato M.* Cerebellum: Models // In: *Squire L.R.* (ed.) Encyclopedia of Neuroscience. V. 2. – Oxford: Academic Press, 2009. – pp. 757–767.
51. *Palkovits M. et al.* Quantitative histological analysis of the cerebellar nuclei in the cat. I. Numerical data on cells and on synapses // *Exp. Brain.* – 1977. – Vol. 28. – pp. 189–209.
52. *Uusisaari M., Schutter E.* The mysterious microcircuitry of the cerebellar nuclei // *J. Physiol.* – 2011. – Vol. 589, No. 14. – pp. 3441–3457.
53. *Deacon T.W.* The symbolic species: The co-evolution of language and the brain. – N.Y.: Norton, 1997.
54. *Hagmann P. et al.* Mapping the structural core of human cerebral cortex // *PLoS Biology.* – 2008. – Vol. 6, No. 7. – pp. 1479–1493.
55. *Baars B. et al.* Global workspace dynamics: cortical “binding and propagation” enables conscious contents // *Frontiers in Psychology.* – 2013. – Vol. 4, Article 200.
56. *Dehaene S.* Consciousness and the brain. Deciphering how the brain codes our thoughts. – N.Y.: Viking, 2014.
57. *Cole M. et al.* Multi-task connectivity reveals flexible hubs for adaptive task control // *Nature Neuroscience.* – 2013. – Vol. 16. – pp. 1348–1355.
58. *Kahneman D.* Thinking, fast and slow. – Macmillan, 2011.
59. *Khamassi M., Humphries M.* Integrating cortico-limbic-basal ganglia architectures for learning model-based and model-free navigation strategies // *Frontiers in Behavioral Neuroscience.* – 2012. – Vol. 6, Article 79.
60. *Buzhaki G., Moser E.* Memory, navigation and theta rhythm in the hippocampal-entorhinal system // *Nature Neuroscience.* – 2013. – Vol. 16, No. 2. – pp. 130–138.
61. *Ashby F.G. et al.* FROST: A distributional neurocomputational model of working memory maintenance // *Journal of Computational Neuroscience.* – 2005. – Vol. 17, No. 11. – pp. 1728–1743.
62. *O'Reilly R., Frank M.* Making working memory work: A Computational model of learning in the prefrontal cortex and basal ganglia // *Neural Computation.* – 2006. – Vol. 18. – pp. 283–328.

Сергей Александрович ШУМСКИЙ, старший научный сотрудник Физического Института РАН, кандидат физико-математических наук, автор более 70 научных публикаций. Специалист в области машинного обучения и искусственного интеллекта. Член президиума Российской Ассоциации Нейроинформатики. Автор учебных курсов по нейрокомпьютерингу в МФТИ и МИФИ, соавтор учебника «Нейрокомпьютеринг и его применения в экономике и бизнесе». Имеет благодарность Президента РАН за цикл работ в области машинного обучения. В 90-х годах являлся руководителем проектов Международного Научно-Технического Центра по разработке нейросетевой ассоциативной памяти и созданию системы распознавания русской речи. С 1998 года — соучредитель и руководитель нескольких венчурных компаний в области высоких технологий. С 2009 г. — Председатель Совета директоров ЗАО «Айкумен», разрабатывающего корпоративные экспертные системы с использованием технологий машинного обучения.

В. А. ГОЛОВКО

Брестский государственный технический университет

E-mail: gva@bstu.by

**ОТ МНОГОСЛОЙНЫХ ПЕРСЕПТРОНОВ К НЕЙРОННЫМ
СЕТЯМ ГЛУБОКОГО ДОВЕРИЯ: ПАРАДИГМЫ ОБУЧЕНИЯ И
ПРИМЕНЕНИЕ**

Аннотация

В данной лекции рассматриваются и анализируются основные парадигмы обучения перцептронных нейронных сетей: от однослойного перцептрона к многослойным сетям глубокого доверия, которые считаются революционным шагом в области интеллектуальной обработки данных. Показана несостоятельность некоторых мифов о возможностях перцептронных нейронных сетей и обосновывается переход к сверхбольшим перцептронным сетям глубокого доверия. Рассмотрены основные модели обучения нейронных сетей глубокого доверия, базирующиеся на ограниченной машине Больцмана (RBM) и автоассоциативном подходе. Предложен новый метод для обучения ограниченной машины Больцмана и показано, что правило обучения ограниченной машины Больцмана является частным случаем предложенного метода обучения, который базируется на минимизации суммарной квадратичной ошибки восстановления информации. Доказана эквивалентность максимизации вероятности распределения данных в ограниченной машине Больцмана и минимизации суммарной квадратичной ошибки восстановления информации в слоях RBM. Рассматривается применение нейронных сетей глубокого доверия для сжатия, визуализации и распознавания данных.

V. A. GOLOVKO
Brest State Technical University
E-mail: gva@bstu.by

FROM MULTILAYER PERCEPTRONS TO DEEP BELIEF NEURAL NETWORKS: TRAINING PARADIGMS AND APPLICATION

Abstract

This lecture discusses and analyzes the basic paradigm of learning perceptron neural networks: from single layer perceptron to multilayer deep belief neural networks, which are considered now as a revolution in the field of data mining. It is shown the inconsistency of some of the myths about the possibilities of perceptron neural networks and is substantiated the transition to deep belief neural networks. The basic models of deep belief neural networks training are examined, which are based on the restricted Boltzmann machine(RBM) and auto-associative approach. A new method for training of RBM is proposed and it is shown that traditional approach for restricted Boltzmann machine training is a particular case of proposed technique, which is based on minimization of reconstruction square error. It is proved the equivalence of maximizing the probability distribution of the data in a restricted Boltzmann machine and the minimization of the total reconstruction squared error in layers of RBM. The application of deep belief neural network for compression, visualization and data recognition is considered.

Введение

Нейронные сети имеют различные периоды своего развития, связанные с оптимистичным и пессимистичным взглядом на эволюцию данной технологии в контексте развития систем искусственного интеллекта. Так, в 1958 г. *Ф. Розенблатт* предложил однослойный перцептрон [1], который затем был подвергнут критике из-за неспособности решать линейно неразделимые задачи [2]. Хотя, как будет показано в данной лекции, однослойный перцептрон с сигнальной функцией активации способен решить задачу «исключающее или». После этого наступил период спада в области перцептронных нейронных сетей и только с 1986 г. начался подъем, связанный с разработкой алгоритма обратного распространения ошибки для

многослойных перцептронов. При этом в научной среде вплоть до 2006 г. господствовало убеждение, что не имеет смысла использовать более двух скрытых слоев в перцептроне. Это было связано с тем, что алгоритм обратного распространения ошибки не давал никакого выигрыша в решении задач при обучении перцептрона с более чем двумя скрытыми слоями. Также данная парадигма базировалась на теореме об универсальной аппроксимации перцептроном с одним или двумя скрытыми слоями любой функции со сколь угодно высокой заданной точностью. В результате использования перцептронов с малым количеством скрытых слоев сложилось мнение, что его возможности в основном исчерпаны. Тем более, что появились машины опорных векторов (Support Vector Machine — SVM), которые показывали часто более высокую эффективность на операциях распознавания образов по сравнению с перцептроном. Поэтому интерес к многослойным перцептронам стал постепенно спадать. И только начиная с 2006 г., благодаря работам [3–6] Дж. Хинтона (J. Hinton), начался новый этап в развитии многослойных перцептронов, теперь под названием «нейронные сети глубокого доверия» (deep belief neural networks). Эти сети в общем случае представляют собой дальнейшее развитие многослойных перцептронов и интегрируют различные парадигмы обучения нейронных сетей. Такие сети, благодаря многослойной архитектуре, позволяют обрабатывать и анализировать большой объем данных, а также моделировать когнитивные процессы в различных областях. В настоящее время большинство высокотехнологичных компаний в США (Microsoft, Google и т. д.) используют нейронные сети глубокого доверия для проектирования различных интеллектуальных систем. По мнению ученых Массачусетского технологического института (США), нейронные сети глубокого доверия входят в список 10 наиболее прорывных высоких технологий, способных в недалеком будущем в значительной степени преобразить повседневную жизнь большинства людей на нашей планете. В настоящее время нейронные сети глубокого доверия считаются революционным шагом в области интеллектуальной обработки данных.

В данной лекции рассматриваются и анализируются основные парадигмы обучения перцептронных нейронных сетей: от однослойного перцептрона к многослойным сетям глубокого доверия. Показана несостоятельность некоторых мифов о возможностях перцептронных нейронных сетей и обосновывается переход к сверхбольшим перцептронным сетям глубокого доверия.

Рассмотрены основные модели обучения нейронных сетей глубокого

доверия, базирующиеся на ограниченной машине Больцмана (Restricted Boltzmann Machine — RBM) и автоассоциативном подходе. Предложен новый метод обучения ограниченной машины Больцмана и показано, что правило обучения ограниченной машины Больцмана является частным случаем предложенного метода обучения, который базируется на минимизации суммарной квадратичной ошибки восстановления информации. Доказана эквивалентность максимизации вероятности распределения данных в ограниченной машине Больцмана и минимизации суммарной квадратичной ошибки восстановления информации в слоях RBM. Рассматривается применение нейронных сетей глубокого доверия для решения различных задач.

Однослойный персептрон

В данном разделе рассматривается однослойный персептрон, его обучение и возможности. В настоящее время существует устойчивое мнение, что однослойный персептрон не может решить задачу «исключающее или». Однако это справедливо только для персептрона с пороговой или монотонно возрастающей функцией активацией. При использовании сигнальной или унимодальной функции активации с одним максимумом однослойный персептрон, как будет показано далее, способен решить проблему «исключающее или».

Однослойный персептрон принято изображать в виде двухслойной нейронной сети, где первый слой нейронных элементов является распределительным, а второй — обрабатывающим. Распределительный слой передает входные сигналы на обрабатывающий слой нейронных элементов, который преобразует входную информацию в соответствии с синаптическими связями и функцией активации (рис. 1). При этом каждый нейрон распределительного слоя имеет синаптические связи со всеми нейронами обрабатывающего слоя.

Выходное значение j -го нейронного элемента второго слоя можно представить как

$$y_j = F(S_j) = F\left(\sum_{i=1}^n w_{ij}x_i - T_j\right), \quad (1)$$

где T_j — порог j -го нейронного элемента выходного слоя; w_{ij} — сила синаптической связи между i -м нейроном распределительного слоя и j -м

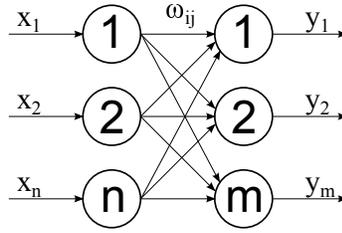


Рис. 1. Однослойный перцептрон

нейроном обрабатывающего слоя, F — оператор нелинейного преобразования или функция активации нейронных элементов.

Рассмотрим правило обучения однослойного перцептрона, который имеет линейную функцию активации. Такое правило обучения называется дельта-правилом (delta rule) и может использоваться как для обучения линейного перцептрона, так и для перцептрона с пороговой функцией активации. Дельта-правило было предложено в 60-х гг. *Ф. Розенблаттом* [1] для перцептрона с пороговой функцией активации, а для линейной сети его предложили *Б. Видроу* (B. Widrow) и *Т. Хофф* (T. Hoff) [10].

Выходное значение линейного однослойного перцептрона определяется, как

$$y_j = \sum_{i=1}^n w_{ij} x_i - T_j. \quad (2)$$

Дельта-правило предполагает минимизацию суммарной среднеквадратичной ошибки нейронной сети, которая для L входных образов определяется соотношением:

$$E_s = \sum_{k=1}^L E(k) = \frac{1}{2} \sum_{k=1}^L \sum_{j=1}^m (y_j^k - e_j^k)^2, \quad (3)$$

где $E(k)$ — среднеквадратичная ошибка сети для k -го образа; y_j^k и e_j^k — соответственно выходное и эталонное значение нейронной сети для k -го образа.

Для минимизации суммарной квадратичной ошибки используется метод градиентного спуска. Существует два основных подхода к обучению однослойного перцептрона: последовательное обучение (online learning) и

групповое обучение (batch learning). При последовательном обучении модификация синаптических связей происходит после подачи каждого образа из обучающей выборки на нейронную сеть. В этом случае в методе градиентного спуска используется квадратичная ошибка нейронной сети для одного входного образа:

$$E = \frac{1}{2} \sum_{j=1}^m (y_j - e_j)^2. \quad (4)$$

Тогда в соответствии с методом градиентного спуска, весовые коэффициенты и пороги нейронной сети необходимо изменять с течением времени по следующим выражениям:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha \frac{\partial E}{\partial w_{ij}(t)}, \quad (5)$$

$$T_j(t+1) = T_j(t) - \alpha \frac{\partial E}{\partial T_j(t)}, \quad (6)$$

где α — скорость или шаг обучения.

Отсюда можно получить **дельта-правило** для последовательного обучения:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha (y_j - e_j) x_i, \quad (7)$$

$$T_j(t+1) = T_j(t) + \alpha (y_j - e_j). \quad (8)$$

Величина адаптивного шага при последовательном обучении [3]:

$$\alpha(t) = \frac{1}{1 + \sum_i x_i^2(t)}.$$

При использовании группового обучения модификация синаптических связей будет происходить после подачи на вход сети L образов. В этом случае дельта-правило можно представить следующим образом [11]:

$$w_{ij}(L) = w_{ij}(0) - \alpha(t) \sum_{k=1}^L (y_j^k - e_j^k) x_i^k, \quad (9)$$

$$T_j(L) = T_j(0) + \alpha(t) \sum_{k=1}^L (y_j^k - e_j^k).$$

Величина адаптивного шага при групповом обучении [11]:

$$\alpha(t) = \frac{\sum_k \sum_j (y_j^k - e_j^k) a_j^k}{\sum_k \sum_j (a_j^k)^2},$$

$$a_j^k = \sum_p (y_j^p - e_j^p) \left(1 + \sum_i x_i^p x_i^k\right).$$
(10)

Однослойный перцептрон с пороговой функцией активации формирует линейную разделяющую поверхность с точки зрения классификации образов и поэтому не может решить задачу «исключающее или». Это в свое время показали американские ученые *М. Минский* и *С. Пейперт* [2], которые сделали пессимистические выводы насчет дальнейшего развития нейронных сетей. Однако последнее утверждение справедливо только для однослойного перцептрона с пороговой или монотонной непрерывной функцией активации (например, сигмоидной). При использовании функции активации Гаусса или сигнальной функции однослойный перцептрон может решить задачу «исключающее или». Покажем это для сигнальной функции активации. В этом случае, необходимо выделить область единиц или нулей при помощи двух прямых (рис. 2).

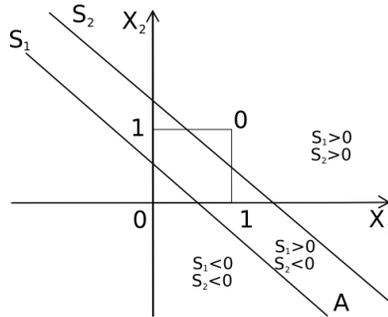


Рис. 2. Решение задачи «исключающее или»

Область *A*, которая определяет класс единиц, характеризуется условиями $S_1 > 0$ и $S_2 < 0$. Уравнения прямых можно представить следующим образом:

$$S_1 = X_2 + X_1 - 0.5,$$

$$S_2 = X_2 + X_1 - 1.5.$$

Отсюда можно получить, что $S_2 = S_1 - 1$ (рис. 3).

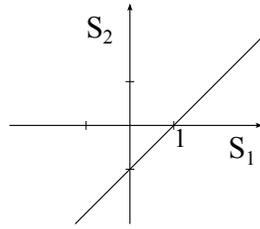


Рис. 3. Зависимость S_2 от S_1

Тогда, если $S_1 > 0$ и $S_2 < 0 \rightarrow 0 < S_1 < 1$ и можно получить следующую функцию активации (рис. 4):

$$y = F(S) = F(S_1) = \begin{cases} 1, & \text{если } 0 < S_1 < 1, \\ 0, & \text{в противном случае} \end{cases} \quad (11)$$

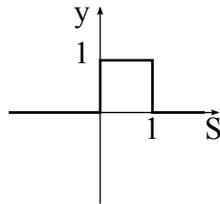


Рис. 4. Сигнальная функция активации

В результате однослойный персептрон для решения задачи «исключающее или» будет иметь следующие веса и порог (рис. 5):

Таким образом, при использовании сигнальной функции активации однослойный персептрон может решить задачу «исключающее или», так как она разбивает входное пространство образов на классы при помощи двух прямых. При использовании однослойного персептрона с радиально базисной функцией активации для решения данной задачи необходимо принимать выходное значение персептрона равным единице, если оно больше определенного значения.

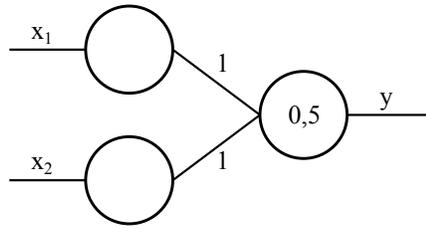


Рис. 5. Однослойный перцептрон для решения задачи «исключающее или»

Многослойный перцептрон

В 1986 г. рядом авторов (*D. Rumelhart, G. Hinton, R. Williams*) независимо друг от друга был предложен алгоритм обратного распространения ошибки (backpropagation algorithm), который стал эффективным средством обучения многослойных нейронных сетей [12]. Перцептрон с одним скрытым слоем изображен на рис. 6.

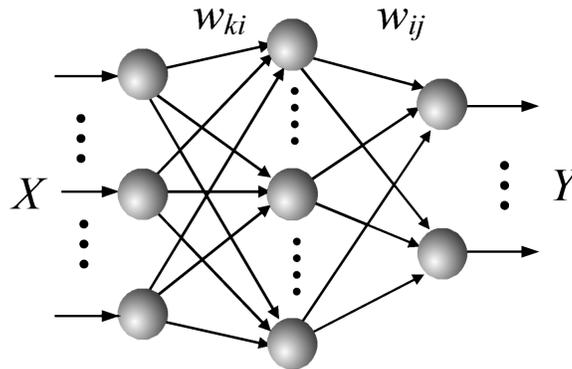


Рис. 6. Перцептрон с одним скрытым слоем

Выходное значение j -го нейрона последнего слоя определяется как

$$y_j = F(S_j),$$

$$S_j = \sum_i w_{ij} y_i - T_j.$$

Аналогичным образом для скрытого слоя

$$y_i = F(S_i),$$

$$S_i = \sum_k w_{ki} y_k - T_i,$$

где S_j — взвешенная сумма j -го нейрона, w_{ij} — весовой коэффициент от i -го к j -му нейрону, T_j — порог j -го нейрона последнего слоя.

Целью обучения является минимизация суммарной квадратичной ошибки сети:

$$E_s = \frac{1}{2} \sum_{k=1}^L \sum_j (y_j^k - e_j^k)^2, \quad (12)$$

где L — размерность обучающей выборки, y_j^k и e_j^k — соответственно выходное и эталонное значение нейронной сети для k -го образа.

Для минимизации квадратичной ошибки сети весовые коэффициенты и пороги нейронных элементов должны изменяться с течением времени следующим образом:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha \gamma_j F'(S_j) y_i,$$

$$T_j(t+1) = T_j(t) + \alpha \gamma_j F'(S_j),$$

где $\frac{\partial E}{\partial S_j} = F'(S_j)$, γ_j — ошибка j -го нейрона j -го слоя.

Для выходного слоя

$$\gamma_j = y_j - e_j.$$

Для любого скрытого слоя ошибка i -го нейронного элемента в нем определяется рекурсивным образом через ошибки всех m нейронов следующего слоя:

$$\gamma_i = \sum_{j=1}^m \gamma_j F'(S_j) w_{ij}, \quad (13)$$

где m — количество нейронов в слое, следующем за тем, который содержит i -й нейрон; w_{ij} — синаптическая связь между i -м и j -м нейроном различных слоев; S_j — взвешенная сумма j -го нейрона.

Данное правило обучения многослойных нейронных сетей называется **обобщенным дельта-правилом**.

Для группового обучения, когда модификация синаптических связей происходит после подачи L образов на нейронную сеть:

$$w_{ij}(L) = w_{ij}(0) - \alpha(t) \sum_k \gamma_j^k F'(S_j^k) y_i^k,$$

$$T_j(L) = T_j(0) + \alpha(t) \sum_k \gamma_j^k F'(S_j^k).$$

Рассмотрим возможности многослойного персептрона в зависимости от количества скрытых слоев. В литературе существует много ошибочных утверждений по данному вопросу. Так, например, *Р. Липманн* (R. Lippmann) утверждал в работе [13], что персептрон с одним скрытым слоем может формировать только выпуклую разделяющую поверхность с точки зрения классификации образов. Позже было показано, что такой персептрон может формировать произвольную разделяющую поверхность, однако данная ошибка попала и попадает во многие учебники. Прежде всего, следует отметить, что возможности персептрона с одним скрытым слоем различаются в зависимости от используемой функции активации. В 1989 г. *G. Cybenko* [14], доказал теорему об универсальной аппроксимации:

Теорема 1. Любая функция может быть аппроксимирована персептроном с одним скрытым слоем и сигмоидной функцией активацией нейронных элементов с любой степенью точности при достаточном количестве нейронов в скрытом слое.

Данная теорема является основной для аппроксимации функций при помощи многослойных нейронных сетей. При этом точность аппроксимации зависит от количества нейронов в скрытом слое. Чем больше количество нейронных элементов в скрытом слое, тем больше точность. Однако при слишком большой размерности скрытого слоя может наступить явление, которое называется перетренировкой сети, когда сеть имеет плохую обобщающую способность. Таким образом, нейронная сеть с одним скрытым слоем позволяет осуществить любое отображение входных сигналов в выходные при использовании сигмоидной или любой ограниченной, монотонно возрастающей функции активации. Поэтому, такая сеть является

также универсальным классификатором, то есть она способна формировать произвольную разделяющую поверхность в пространстве решений.

Рассмотрим теперь другой случай, когда в качестве функции активации нейронных элементов используется пороговая функция. Здесь ситуация меняется. Персептрон с одним скрытым слоем и пороговой функцией активации нейронных элементов не способен формировать произвольную разделяющую поверхность и поэтому не является универсальным классификатором. В данном случае, только персептрон с двумя скрытыми слоями способен формировать произвольную разделяющую поверхность. Покажем это на примере решения простой задачи бинарной классификации (рис. 7).

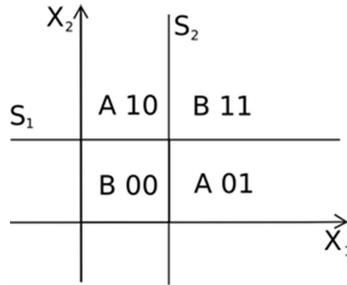


Рис. 7. Задача бинарной классификации двух классов и

Как видно из рис. 7, классы разделяются двумя прямыми S_1 и S_2 . Уравнения прямых будут следующими: $S_1 = X_2 - 1$ и $S_2 = X_1 - 1$. В результате, данная задача сводится к проблеме «исключающее или». Поэтому персептрон для ее решения будет состоять из двух скрытых слоев, где первый скрытый слой формирует разделяющие линии S_1 и S_2 (рис. 8).

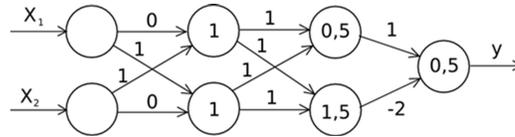


Рис. 8. Персептрон с двумя скрытыми слоями для решения задачи бинарной классификации

Рассмотрим еще один случай, когда используется сигнальная функция

активации в отдельных слоях нейронных элементов. Тогда для решения приведенной выше задачи классификации достаточно перцептрона с одним скрытым слоем и сигнальной функцией активации в выходном нейроне, как это показано на рис. 9. Здесь нейроны скрытого слоя формируют дискриминантные линии S_1 и S_2 , а выходной нейронный элемент с сигнальной функцией активации формирует окончательное решение задачи.

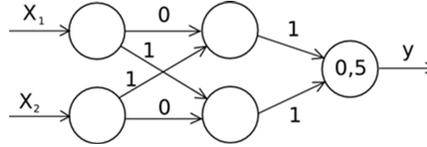


Рис. 9. Перцептрон с одним скрытым слоем для решения задачи бинарной классификации

Таким образом, основная научная парадигма состояла в том, что перцептрон с одним или максимум двумя скрытыми слоями является достаточным для решения различных задач. Использование перцептрона с более чем двумя скрытыми слоями не имеет большого смысла.

Нейронные сети глубокого доверия

В общем случае нейронные сети глубокого доверия (deep belief neural networks) представляют собой перцептрон с множеством слоев нейронных элементов [3–9]. До 2006 г. в научной среде была приоритетной парадигма, в рамках которой многослойный перцептрон с одним, максимум двумя скрытыми слоями является более эффективным для нелинейного преобразования входного пространства образов в выходное по сравнению с перцептроном с большим количеством скрытых слоев. Считалось, что перцептрон с более чем двумя скрытыми слоями не имеет смысла применять. Данная парадигма базировалась на теореме о том, что перцептрон с одним скрытым слоем является универсальным аппроксиматором. Другой аспект этой проблемы заключается в том, что все попытки использовать алгоритм обратного распространения ошибки (error backpropagation algorithm) для обучения перцептрона с тремя и более скрытыми слоями не привели к улучшению решения различных задач. Это связано с тем, что алгоритм обратного распространения ошибки является неэффективным для

обучения перцептронов с тремя и более слоями. В 2006 г. Дж. Хинтон (G. Hinton) предложил «жадный» алгоритм послойного обучения (greedy layer-wise algorithm) [3], который стал эффективным средством обучения нейронных сетей глубокого доверия, которые как уже отмечалось, представляют собой перцептрон с большим количеством слоев. Было показано, что нейронная сеть глубокого доверия имеет большую эффективность нелинейного преобразования и представления данных по сравнению с традиционным перцептроном. Такая сеть осуществляет глубокое иерархическое преобразование входного пространства образов. В результате первый скрытый слой выделяет низкоуровневое пространство признаков входных данных, второй слой детектирует пространство признаков более высокого уровня абстракции и т. д. [5].

Как уже отмечалось, нейронная сеть глубокого доверия содержит множество скрытых слоев (рис. 10) и осуществляет глубокое иерархическое преобразование входного пространства образов.

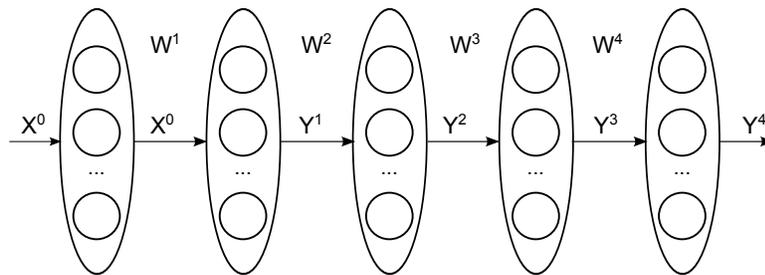


Рис. 10. Нейронная сеть глубокого доверия

Выходное значение j -го нейрона k -го слоя определяется следующим образом:

$$y_j^k = F(S_j^k), \quad (14)$$

$$S_j^k = \sum_{i=1} w_{ij}^k y_i^{k-1} + T_j^k, \quad (15)$$

где F — функция активации нейронного элемента, S_j^k — взвешенная сумма j -го нейрона k -слоя, w_{ij}^k — весовой коэффициент между i -м нейроном $(k-1)$ -го слоя и j -м нейроном k -го слоя, T_j^k — пороговое значение j -го нейрона k -го слоя.

Для первого (распределительного) слоя

$$y_i^0 = x_i. \quad (16)$$

В матричном виде выходной вектор k -го слоя имеет вид

$$Y^k = F(S^k) = F(W^k Y^{k-1} + T^k), \quad (17)$$

где W — матрица весовых коэффициентов, Y^{k-1} — выходной вектор $(k-1)$ -го слоя, T^k — вектор пороговых значений нейронов k -го слоя. Если нейронная сеть глубокого доверия используется для классификации образов, то выходные значения сети часто определяются на основе функции активации **softmax**:

$$y_j^F = \text{softmax}(S_j) = \frac{e^{S_j}}{\sum_l e^{S_l}}. \quad (18)$$

Процесс обучения нейронных сетей глубокого доверия в общем случае состоит из двух этапов:

- 1) предобучение нейронной сети методом послойного обучения, начиная с первого слоя (pre-training); данный этап обучения осуществляется без учителя;
- 2) настройка синаптических связей всей сети (fine-tuning) при помощи алгоритма обратного распространения ошибки или алгоритма «бодрствования и сна» (wake-sleep algorithm).

Важным этапом обучения нейронных сетей глубокого доверия является предобучение слоев нейронной сети. Существует два основных подхода к предварительному обучению слоев нейронных сетей глубокого доверия (рис. 11).

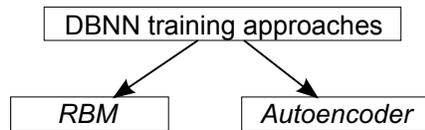


Рис. 11. Методы предварительного обучения сетей глубокого доверия

Первый подход называется автоэнкодерным и базируется на представлении каждого слоя в виде автоассоциативной нейронной сети (рециркуляционная или PCA нейронная сеть). Второй подход базируется на представлении каждого слоя нейронной сети в виде ограниченной машины Больцмана (RBM).

Автоэнкодерный метод обучения

В этом случае вначале обучается первый слой как автоассоциативная нейронная сеть с целью минимизации суммарной ошибки реконструкции информации, затем второй слой и так далее. Для обучения каждого слоя можно использовать алгоритм обратного распространения ошибки. После этого осуществляется точная настройка синаптических связей всей сети (fine tuning), используя алгоритм обратного распространения ошибки.

Рассмотрим персептрон с тремя скрытыми слоями (рис. 12). Тогда, в соответствии с автоэнкодерным методом, прежде всего берутся первые два слоя нейронной сети (1 и 2) и на базе их конструируется автоассоциативная (рециркуляционная) нейронная сеть (1–2–1), то есть добавляется восстанавливающий слой (рис. 13). Затем происходит обучение, например, при помощи алгоритма обратного распространения ошибки, такой сети с целью минимизации ошибки реконструкции информации. Продолжительность обучения обычно составляет не больше, чем 100 эпох.

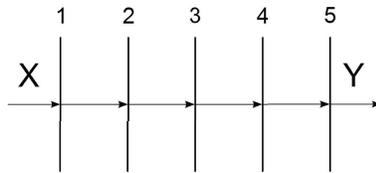


Рис. 12. Персептрон с тремя скрытыми слоями

После этого отбрасывается восстанавливающий слой (последний слой), фиксируются веса скрытого слоя, и конструируется автоассоциативная сеть из следующих двух слоев нейронной сети (2–3–2), которая обучается на основе данных поступающих с предыдущего (2-го слоя). Процесс продолжается до последнего или предпоследнего слоя, как это схематично изображено на рис. 13. В результате послойного обучения получается предвари-

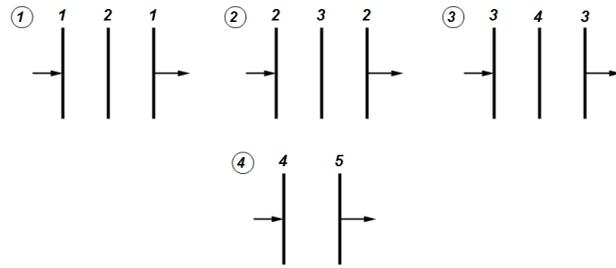


Рис. 13. Автоэнкодерный метод обучения

тельно обученная нейронная сеть. Далее осуществляется точная настройка (fine tuning) посредством, например, алгоритма обратного распространения ошибки с учителем.

Данный процесс можно представить в виде следующего алгоритма:

1. Конструируется автоассоциативная сеть с входным слоем X , скрытым слоем Y и выходным слоем X .
2. Обучается автоассоциативная сеть, например при помощи алгоритма обратного распространения ошибки (как правило не более 100 эпох) и фиксируются синаптические связи первого слоя W_1 .
3. Берется следующий слой и формируется автоассоциативная сеть аналогичным образом.
4. Используя настроенные синаптические связи предыдущего слоя W_1 , подаем входные данные на вторую автоассоциативную сеть и обучаем ее аналогичным образом. В результате получают весовые коэффициенты второго слоя W_2 .
5. Процесс продолжается до последнего слоя нейронной сети.
6. Берется последний слой нейронной сети и обучается с учителем.
7. Обучается вся сеть для точной настройки параметров при помощи алгоритма обратного распространения ошибки.

Ограниченная машина Больцмана

Как уже отмечалось, данный подход базируется на представлении каждого слоя нейронной сети в виде ограниченной машины Больцмана (RBM).

Ограниченная машина Больцмана состоит из двух слоев стохастических бинарных нейронных элементов, которые соединены между собой двуправленными симметричными связями (рис. 14). Входной слой нейронных элементов называется видимым (слой X), а второй слой — скрытым (слой Y). Нейронную сеть глубокого доверия можно представить как совокупность ограниченных машин Больцмана. Ограниченная машина Больцмана может генерировать (представить) любое дискретное распределение, если используется достаточное количество нейронов скрытого слоя [7].

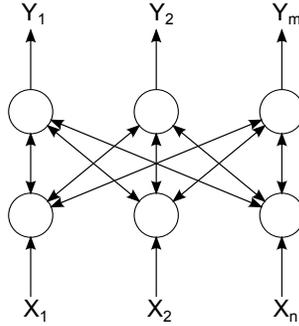


Рис. 14. Ограниченная машина Больцмана

Данная сеть является стохастической нейронной сетью, в которой состояния видимых и скрытых нейронов меняются в соответствии с вероятностной версией сигмоидной функции активации:

$$p(y_j|x) = \frac{1}{1 + e^{-S_j}}, \quad S_j = \sum_i^n w_{ij} x_i + T_j, \quad (19)$$

$$p(x_i|y) = \frac{1}{1 + e^{-S_i}}, \quad S_i = \sum_j^m w_{ij} y_j + T_i. \quad (20)$$

Состояния видимых и скрытых нейронных элементов принимаются независимыми:

$$P(x|y) = \prod_{i=1}^n P(x_i|y),$$

$$P(y|x) = \prod_{j=1}^m P(y_j|x).$$

Таким образом, состояния всех нейронных элементов ограниченной машины Больцмана определяются через распределение вероятностей. В RBM нейроны скрытого слоя являются детекторами признаков, которые сохраняют закономерности входных данных. Основная задача обучения состоит в воспроизведении распределения входных данных на основе состояний нейронов скрытого слоя как можно точнее. Это эквивалентно максимизации функции правдоподобия путем модификации синаптических связей нейронной сети. Рассмотрим этот вопрос подробнее. Вероятность нахождения видимого и скрытого нейрона в состоянии (x, y) определяется на основе распределения Гиббса:

$$P(x, y) = \frac{e^{-E(x, y)}}{Z},$$

где $E(x, y)$ — энергия системы в состоянии (x, y) , Z — параметр, который определяет условие нормализации вероятностей, то есть, чтобы сумма вероятностей равнялась единице. Данный параметр определяется следующим образом:

$$Z = \sum_{x, y} e^{-E(x, y)}.$$

Вероятность нахождения видимых нейронов в определенном состоянии равняется сумме вероятностей конфигураций $P(x, y)$ по состояниям скрытых нейронов:

$$P(x) = \sum_y P(x, y) = \sum_y \frac{e^{-E(x, y)}}{Z} = \frac{\sum_y e^{-E(x, y)}}{\sum_{x, y} e^{-E(x, y)}}.$$

Для нахождения правила модификации синаптических связей необходимо максимизировать вероятность воспроизведения состояний видимых нейронов $P(x)$ ограниченной машиной Больцмана. Для того, чтобы определить максимум функции правдоподобия распределения данных $P(x)$, будем использовать метод градиентного спуска в пространстве весовых коэффициентов и пороговых значений сети, где в качестве градиента применим функцию логарифмического правдоподобия:

$$\ln P(x) = \ln \sum_y e^{-E(x, y)} - \ln \sum_{x, y} e^{-E(x, y)}.$$

Тогда градиент равен

$$\frac{\partial \ln P(x)}{\partial w_{ij}} = \frac{\partial}{\partial w_{ij}} \ln \sum_y e^{-E(x,y)} - \frac{\partial}{\partial w_{ij}} \ln \sum_{x,y} e^{-E(x,y)}.$$

Преобразуя последнее выражение, получим

$$\begin{aligned} \frac{\partial \ln P(x)}{\partial w_{ij}} = & -\frac{1}{\sum_y e^{-E(x,y)}} \sum_y e^{-E(x,y)} \frac{\partial E(x,y)}{\partial w_{ij}} + \\ & + \frac{1}{\sum_{x,y} e^{-E(x,y)}} \sum_{x,y} e^{-E(x,y)} \frac{\partial E(x,y)}{\partial w_{ij}}. \end{aligned}$$

Так как

$$P(x, y) = P(y|x)P(x),$$

то

$$P(y|x) = \frac{P(x, y)}{P(x)} = \frac{(1/Z)e^{-E(x,y)}}{(1/Z) \sum_y e^{-E(x,y)}} = \frac{e^{-E(x,y)}}{\sum_y e^{-E(x,y)}}.$$

В результате можно получить следующее выражение:

$$\frac{\partial \ln P(x)}{\partial w_{ij}} = -\sum_y P(y|x) \frac{\partial E(x, y)}{\partial w_{ij}} + \sum_{x,y} P(x, y) \frac{\partial E(x, y)}{\partial w_{ij}}.$$

В данном выражении первое слагаемое определяет позитивную фазу работы машины Больцмана, когда сеть работает на основе образов из обучающей выборки. Второе слагаемое характеризует негативную фазу функционирования, когда сеть работает в свободном режиме независимо от окружающей среды.

Рассмотрим энергию сети RBM. С точки зрения энергии сети задача обучения состоит в том, чтобы на основе входных данных найти конфигурацию выходных переменных с минимальной энергией. В результате на обучающем множестве сеть будет иметь меньшую энергию по сравнению с другими состояниями. Функция энергии бинарного состояния (x, y) определяется аналогично сети Хопфилда:

$$E(x, y) = -\sum_i x_i T_i - \sum_j y_j T_j - \sum_{i,j} x_i y_j w_{ij}. \quad (21)$$

В этом случае

$$\frac{\partial E(x, y)}{\partial w_{ij}} = -x_i y_j$$

и

$$\frac{\partial \ln P(x)}{\partial w_{ij}} = \sum_y P(y|x) x_i y_j - \sum_{x, y} P(x, y) x_i y_j.$$

Так как математическое ожидание равняется:

$$E(x) = \sum_i x_i P_i,$$

то

$$\frac{\partial \ln P(x)}{\partial w_{ij}} = E[x_i y_j]_{data} - E[x_i y_j]_{model}.$$

Аналогичным образом можно получить градиенты для пороговых значений:

$$\begin{aligned} \frac{\partial \ln P(x)}{\partial T_i} &= E[x_i]_{data} - E[x_i]_{model}, \\ \frac{\partial \ln P(x)}{\partial T_j} &= E[y_j]_{data} - E[y_j]_{model}. \end{aligned}$$

Как следует из последних выражений, первое слагаемое характеризует работу сети на основе данных из обучающей выборки, а второе — работу сети на основе данных модели (данные, генерируемые сетью), то есть в свободном режиме, независимо от окружающей среды.

Так как вычисление математического ожидания на основе RBM-сети является очень сложным, Дж. Хинтон предложил использовать аппроксимацию данных слагаемых, которую он назвал контрастным расхождением (contrastive divergence (CD)) [3]. Такая аппроксимация основывается на дискретизаторе Гиббса (Gibbs sampling). В этом случае первые слагаемые в выражениях для градиента характеризуют распределение данных в момент времени $t = 0$, а вторые — реконструированные или генерируемые моделью состояния в момент времени $t = k$. Исходя из этого, CD-k процедура может быть представлена следующим образом:

$$x(0) \rightarrow y(0) \rightarrow x(1) \rightarrow y(1) \rightarrow \dots \rightarrow x(k) \rightarrow y(k). \quad (22)$$

В результате можно получить следующие правила для обучения RBM сети. В случае применения CD-1, $k = 1$ и учитывая, что в соответствии с

методом градиентного спуска

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \frac{\partial \ln P(\nu)}{\partial w_{ij}(t)},$$

можно получить, что

$$\begin{aligned} w_{ij}(t+1) &= w_{ij}(t) + \alpha(x_i(0)y_j(0) - x_i(1)y_j(1)), \\ T_i(t+1) &= T_i(t) + \alpha(x_i(0) - x_i(1)), \\ T_j(t+1) &= T_j(t) + \alpha(y_j(0) - y_j(1)). \end{aligned}$$

Аналогичным образом, для алгоритма CD-k:

$$\begin{aligned} w_{ij}(t+1) &= w_{ij}(t) + \alpha(x_i(0)y_j(0) - x_i(k)y_j(k)), \\ T_i(t+1) &= T_i(t) + \alpha(x_i(0) - x_i(k)), \\ T_j(t+1) &= T_j(t) + \alpha(y_j(0) - y_j(k)). \end{aligned}$$

Из последних выражений видно, что правила обучения ограниченной машины Больцмана минимизируют разницу между оригинальными данными и данными, генерируемыми моделью. Генерируемые моделью данные получаются при помощи сэмплирования Гиббса.

Обучение нейронной сети глубокого доверия на основе RBM

Обучение нейронной сети глубокого доверия происходит на основе «жадного» алгоритма послойного обучения (greedy layer-wise algorithm). В соответствии с ним вначале обучается первый слой сети как RBM-машина. Для этого входные данные поступают на видимый слой нейронных элементов и используя CD-k процедуру вычисляются состояния скрытых $p(y|x)$ и видимых нейронов $p(x|y)$. В процессе выполнения данной процедуры (не более 100 эпох) изменяются весовые коэффициенты и пороговые значения RBM-сети, которые затем фиксируются. Затем берется второй слой нейронной сети и конструируется RBM-машина. Входными данными для нее являются данные с предыдущего слоя. Происходит обучение и процесс продолжается для всех слоев нейронной сети, как показано на рис. 15 [15]. В результате такого обучения без учителя можно получить подходящую начальную инициализацию настраиваемых параметров сети глубокого доверия. На заключительном этапе осуществляется точная настройка параметров всей сети при помощи алгоритма обратного распространения ошибки или алгоритма «бодрствования и сна» (wake-sleep algorithm).

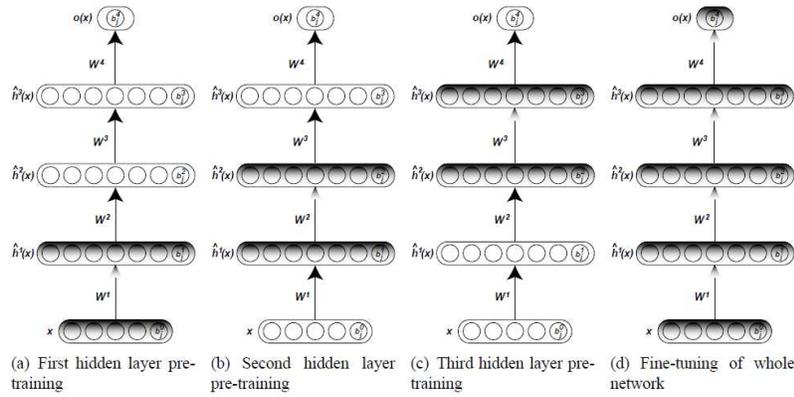


Рис. 15. Greedy layer-wise algorithm [Journal of Machine Learning Research 1 (2009) 1-40]

Альтернативный взгляд на ограниченную машину Больцмана

В данном разделе рассматривается альтернативный взгляд на ограниченную машину Больцмана как автоассоциативную нейронную сеть, которая может работать с любыми данными, как бинарными, так и числовыми. Предлагается новый метод получения правила обучения ограниченной машины Больцмана [16]. Он базируется на минимизации ошибки реконструкции видимых и скрытых образов, которую можно получить, используя итерации сэмплирования Гиббса. По сравнению с традиционным подходом — методом, основанным на энергии (energy-based method), который базируется на линейном представлении нейронных элементов, предложенный метод позволяет учитывать нелинейную природу нейронных элементов.

Рассмотрим ограниченную машину Больцмана, которую будем представлять в виде трех слоев нейронных элементов [17]: видимый, скрытый и видимый (рис. 16).

Сэмплирование Гиббса заключается в следующей процедуре. Пусть $x(0)$ входной вектор, который поступает на видимый слой в момент времени 0. Тогда выходные значения нейронов скрытого слоя:

$$y_j(0) = F(S_j(0)), \tag{23}$$

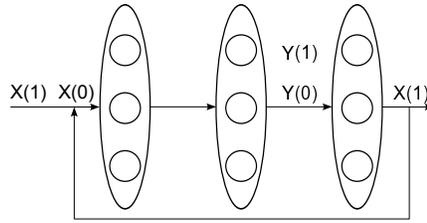


Рис. 16. Представление RBM в виде рециркуляционной сети

$$S_j(0) = \sum_i w_{ij} x_i(0) + T_j. \quad (24)$$

Инверсный (последний) слой реконструирует входной вектор на основе данных со скрытого слоя. В результате получается восстановленный вектор $x(1)$ в момент времени 1:

$$x_i(1) = F(S_i(1)), \quad (25)$$

$$S_i(1) = \sum_j w_{ij} y_j(0) + T_i. \quad (26)$$

Затем вектор $x(1)$ поступает на видимый слой и вычисляются выходные значения нейронов скрытого слоя:

$$y_j(1) = F(S_j(1)), \quad (27)$$

$$S_j(1) = \sum_i w_{ij} x_i(1) + T_j. \quad (28)$$

Продолжая данный процесс, можно получить на шаге k :

$$y_i(k) = F(S_i(k)), \quad S_j(k) = \sum_i w_{ij} x_i(k) + T_j,$$

$$x_i(k) = F(S_i(k)), \quad S_i(k) = \sum_j w_{ij} y_j(k-1) + T_i.$$

Целью обучения ограниченной машины Больцмана является минимизация суммарной квадратичной ошибки реконструкции данных на скрытом и

восстанавливающим слое, которая в случае CD-k определяется следующим образом:

$$E_s = \frac{1}{2} \sum_{l=1}^L \sum_{j=1}^m \sum_{p=1}^k (y_j^l(p) - y_j^l(p-1))^2 + \frac{1}{2} \sum_{l=1}^L \sum_{i=1}^n \sum_{p=1}^k (x_i^l(p) - x_i^l(p-1))^2.$$

В случае CD-1 суммарная квадратичная ошибка

$$E_s = \frac{1}{2} \sum_{l=1}^L \sum_{j=1}^m (y_j^l(1) - y_j^l(0))^2 + \frac{1}{2} \sum_{l=1}^L \sum_{i=1}^n (x_i^l(1) - x_i^l(0))^2, \quad (29)$$

где L — количество входных образов.

Как следует из приведенных выше выражений, ошибка состоит из двух частей: ошибки восстановления информации на скрытом и на выходном слое.

Теорема 2. Максимизация функции правдоподобия распределения данных $P(x)$ в пространстве синаптических связей ограниченной машины Больцмана эквивалентна минимизации суммарной квадратичной ошибки сети в том же пространстве при использовании линейных нейронов.

Доказательство. Рассмотрим последовательное обучение RBM, когда модификация синаптических связей происходит после подачи каждого входного образа на сеть. В соответствии с методом градиентного спуска для минимизации суммарной квадратичной ошибки сети, синаптические связи должны изменяться следующим образом:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha \frac{\partial E}{\partial w_{ij}(t)}, \quad (30)$$

$$T_i(t+1) = T_i(t) - \alpha \frac{\partial E}{\partial T_i(t)}, \quad (31)$$

$$T_j(t+1) = T_j(t) - \alpha \frac{\partial E}{\partial T_j(t)}. \quad (32)$$

В случае CD-k квадратичная ошибка E для одного образа:

$$E = \frac{1}{2} \sum_{j=1}^m \sum_{p=1}^k (y_j(p) - y_j(p-1))^2 + \frac{1}{2} \sum_{i=1}^n \sum_{p=1}^k (x_i(p) - x_i(p-1))^2.$$

Тогда

$$\begin{aligned} \frac{\partial E}{\partial w_{ij}} &= \frac{\partial E}{\partial y_j(p)} \frac{\partial y_j(p)}{\partial S_j(p)} \frac{\partial S_j(p)}{\partial w_{ij}} + \frac{\partial E}{\partial x_i(p)} \frac{\partial x_i(p)}{\partial S_i(p)} \frac{\partial S_i(p)}{\partial w_{ij}} = \\ &= \sum_{p=1}^k (y_j(p) - y_j(p-1)) x_i(p) F'(S_j(p)) + \\ &\quad + \sum_{p=1}^k (x_i(p) - x_i(p-1)) y_j(p-1) F'(S_i(p)). \end{aligned}$$

Если ограниченная машина Больцмана использует линейные нейроны с линейной функцией активации, то

$$F'(S_j(p)) = \frac{\partial S_j(p)}{\partial w_{ij}} = F'(S_i(p)) = \frac{\partial S_i(p)}{\partial w_{ij}} = 1,$$

Тогда

$$\begin{aligned} \frac{\partial E}{\partial w_{ij}} &= \sum_{p=1}^k (y_j(p) x_i(p) - y_j(p-1) x_i(p-1)) = \\ &= y_j(k) x_i(k) - y_j(0) x_i(0). \end{aligned}$$

В результате можно получить CD-k правило обучения RBM:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha (x_i(0) y_j(0) - x_i(k) y_j(k)).$$

Аналогичным образом для пороговых значений:

$$\begin{aligned} T_j(t+1) &= T_j(t) + \alpha (y_j(0) - y_j(k)), \\ T_i(t+1) &= T_i(t) + \alpha (x_i(0) - x_i(k)). \end{aligned}$$

Как видно, последние выражения совпадают с классическим правилом обучения ограниченной машины Больцмана для CD-k. Отсюда следует, что для линейной RBM максимизация функции правдоподобия распределения данных $P(x)$ эквивалентна минимизации суммарной квадратичной ошибки сети. Теорема доказана.

Следствие 1. Линейная ограниченная машина Больцмана с точки зрения обучения эквивалентна автоассоциативной нейронной сети при использовании в ней при обучении сэмплирования Гиббса.

Следствие 2. Для нелинейной ограниченной машины Больцмана правило модификации синаптических связей в случае CD-k будет следующим:

$$\begin{aligned}
 w_{ij}(t+1) &= w_{ij}(t) - \\
 &\quad - \alpha \left[\sum_{p=1}^k (y_j(p) - y_j(p-1)) x_i(p) F'(S_j(p)) + \right. \\
 &\quad \left. + (x_i(p) - x_i(p-1)) y_j(p-1) F'(S_i(p)) \right], \\
 T_j(t+1) &= T_j(t) - \alpha \left[\sum_{p=1}^k (y_j(p) - y_j(p-1)) F'(S_j(p)) \right], \\
 T_i(t+1) &= T_i(t) - \alpha \left[\sum_{p=1}^k (x_i(p) - x_i(p-1)) F'(S_i(p)) \right].
 \end{aligned}$$

Следствие 3. Для нелинейной ограниченной машины Больцмана правило модификации синаптических связей в случае CD-1 будет следующим:

$$\begin{aligned}
 w_{ij}(t+1) &= w_{ij}(t) - \alpha ((y_j(1) - y_j(0)) F'(S_j(1)) x_i(1) + \\
 &\quad + (x_i(1) - x_i(0)) F'(S_i(1)) y_j(0)), \\
 T_i(t+1) &= T_i(t) - \alpha (x_i(1) - x_i(0)) F'(S_i(1)), \\
 T_j(t+1) &= T_j(t) - \alpha (y_j(1) - y_j(0)) F'(S_j(1)).
 \end{aligned}$$

Если используется групповое обучение (batch learning), то в этом случае метод градиентного спуска записывается следующим образом:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha \frac{\partial E_s}{\partial w_{ij}(t)}, \quad (33)$$

$$T_i(t+1) = T_i(t) - \alpha \frac{\partial E_s}{\partial T_i(t)}, \quad (34)$$

$$T_j(t+1) = T_j(t) - \alpha \frac{\partial E_s}{\partial T_j(t)}. \quad (35)$$

Теорема 3. При использовании CD-k для нелинейной ограниченной машины Больцмана в случае группового обучения правило модификации

синаптических связей определяется на основе следующих выражений:

$$\begin{aligned}
 w_{ij}(t+1) &= w_{ij}(t) - \\
 &\quad - \alpha \left[\sum_{l=1}^L \sum_{p=1}^k (y_j^l(p) - y_j^l(p-1)) x_i^l(p) F'(S_j^l(p)) + \right. \\
 &\quad \quad \quad \left. + (x_i^l(p) - x_i^l(p-1)) y_j^l(p-1) F'(S_i^l(p)) \right], \\
 T_j(t+1) &= T_j(t) - \alpha \left[\sum_{l=1}^L \sum_{p=1}^k (y_j^l(p) - y_j^l(p-1)) F'(S_j^l(p)) \right], \\
 T_i(t+1) &= T_i(t) - \alpha \left[\sum_{l=1}^L \sum_{p=1}^k (x_i^l(p) - x_i^l(p-1)) F'(S_i^l(p)) \right].
 \end{aligned}$$

Процесс доказательства данной теоремы аналогичен доказательству теоремы 2.

Следствие 4. При использовании CD-1 для нелинейной ограниченной машины Больцмана в случае группового обучения правило модификации синаптических связей определяется на основе следующих выражений:

$$\begin{aligned}
 w_{ij}(t+1) &= w_{ij}(t) - \alpha \left[\sum_{l=1}^L (y_j^l(1) - y_j^l(0)) x_i^l(1) F'(S_j^l(1)) + \right. \\
 &\quad \quad \quad \left. + (x_i^l(1) - x_i^l(0)) y_j^l(0) F'(S_i^l(1)) \right], \\
 T_j(t+1) &= T_j(t) - \alpha \left[\sum_{l=1}^L (y_j^l(1) - y_j^l(0)) F'(S_j^l(1)) \right], \\
 T_i(t+1) &= T_i(t) - \alpha \left[\sum_{l=1}^L (x_i^l(1) - x_i^l(0)) F'(S_i^l(1)) \right].
 \end{aligned}$$

Следствие 5. При использовании CD-k для линейной ограниченной машины Больцмана в случае группового обучения правило модификации синаптических связей определяется следующими выражениями:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \sum_{l=1}^L (x_i^l(0) y_j^l(0) - x_i^l(k) y_j^l(k)),$$

$$T_j(t+1) = T_j(t) + \alpha \sum_{l=1}^L (y_j^l(0) - y_j^l(k)),$$

$$T_i(t+1) = T_i(t) + \alpha \sum_{l=1}^L (x_i^l(0) - x_i^l(k)).$$

Следствие 6. При использовании CD-1 для линейной ограниченной машины Больцмана в случае группового обучения правило модификации синаптических связей определяется выражениями:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \sum_{l=1}^L (x_i^l(0)y_j^l(0) - x_i^l(1)y_j^l(1)),$$

$$T_j(t+1) = T_j(t) + \alpha \sum_{l=1}^L (y_j^l(0) - y_j^l(1)),$$

$$T_i(t+1) = T_i(t) + \alpha \sum_{l=1}^L (x_i^l(0) - x_i^l(1)).$$

В данном разделе получены правила обучения для ограниченной машины Больцмана, которые базируются на минимизации квадратичной ошибки восстановления информации в скрытом и видимом слоях. Предложенный метод позволяет учитывать нелинейную природу нейронных элементов. Показано, что классические выражения для обучения ограниченной машины являются частным случаем предложенного метода. Доказана теорема об эквивалентности максимизации функции правдоподобия распределения данных $P(x)$ в пространстве синаптических связей и минимизации суммарной квадратичной ошибки сети в том же пространстве для линейной ограниченной машины Больцмана.

Применение нейронных сетей глубокого доверия

Нейронные сети глубокого доверия применяются для сжатия и визуализации данных (автоэнкодерные сети), распознавания образов, обработки речи и т.д. Рассмотрим вначале применение автоэнкодерных сетей глубокого доверия для сжатия данных и сравнительного анализа различных алгоритмов.

Таблица 1. Сравнение RBM и REBA методов

Training procedure	MSE	MS
RBM	1,367	1,291
REBA	1,189	1,119

Сжатие данных

Рассмотрим систему трех динамических уравнений [18], где параметр времени t генерируется в диапазоне $[-1, 1]$:

$$\begin{cases} x_1 = \sin(\pi t) + \mu, \\ x_2 = \cos(\pi t) + \mu, \\ x_3 = t + \mu. \end{cases}$$

Здесь μ — гауссовский шум с нулевым средним и квадратичным отклонением равным 0.05. Нелинейный автоэнкодер, который состоит из семи слоев нейронных элементов, изображен на рис. 17.

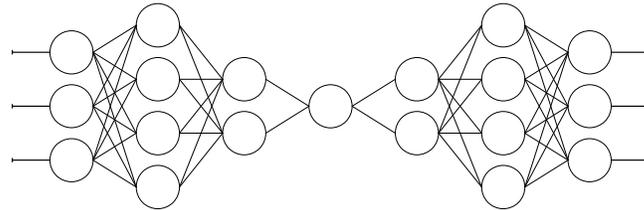


Рис. 17. Автоассоциативная нейронная сеть глубокого доверия

Для обучения использовалась выборка, состоящая из 1000 тренировочных наборов. Тестирование сети проводилось на данных, не входящих в обучающую выборку, количество которых составило 1000 образов. В качестве функции активации для всех слоев кроме сжимающего использовалась сигмоидная функция. Для сжимающего нейрона использовалась линейная функция активации. Для обучения каждого слоя нейронной сети использовалось 50 эпох, а для точной настройки параметров сети при помощи алгоритма обратного распространения ошибки использовалось 200

эпох. Результаты экспериментов приведены в табл. 1. Здесь MSE — суммарная квадратичная ошибка на тренировочном наборе, MS — суммарная квадратичная ошибка на тестовом наборе, RBM — метод обучения на основе ограниченной машины Больцмана, REBA — предложенный метод.

Как следует из табл. 1, предложенный подход REBA показывает более высокую обобщающую способность по сравнению с RBM.

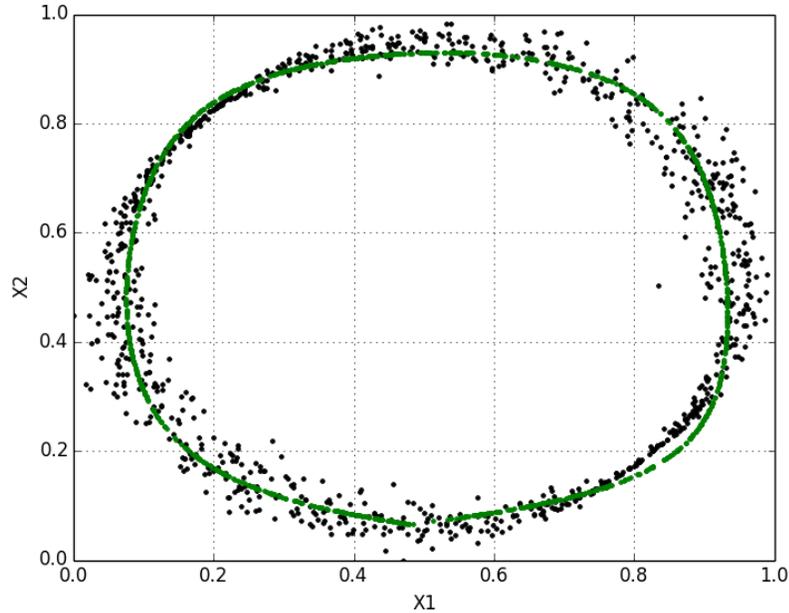


Рис. 18. Нелинейная ось первой главной компоненты в двумерном пространстве

На рис. 18 и 19 изображена нелинейная ось первой главной компоненты, на которую проецируется входное пространство образов.

Визуализация данных

На рис. 20 изображен пример визуализации документов при помощи сети 2000–500–250–2–250–500–2000. Обучающая выборка состояла из 400000

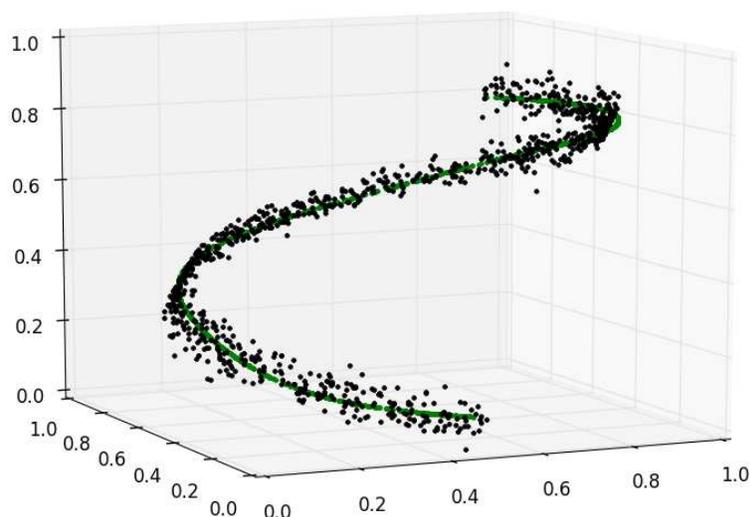


Рис. 19. Нелинейная ось первой главной компоненты в трехмерном пространстве

документов [5]. Как видно из этого рисунка, нейронная сеть глубокого доверия довольно точно осуществляет разделение документов на различные классы.

Распознавание образов

Предложенный альтернативный подход был использован при обучении глубокой нейронной сети для распознавания рукописных цифр базы MNIST. Для этого в качестве базовой модели использовалась нейронная сеть с архитектурой 784–300–100–10. Для обучения использовалась выборка образцов из 1000 первых элементов. На этапе тестирования также использовалась выборка из 1000 первых элементов. Основные параметры обучения: групповое обучение по 10 элементов в каждой группе, скорость обучения для этапа преднастройки (pretraining) весов — 0.05 (REBA — 0.05), для этапа финальной настройки (fine-tuning) — 0.7, ограничения на количество эпох обучения: pretraining — 6/10 эпох, fine-tuning — 50 эпох.

В процессе выполнения экспериментов было установлено, что предло-

Autoencoder 2-D Topic Space

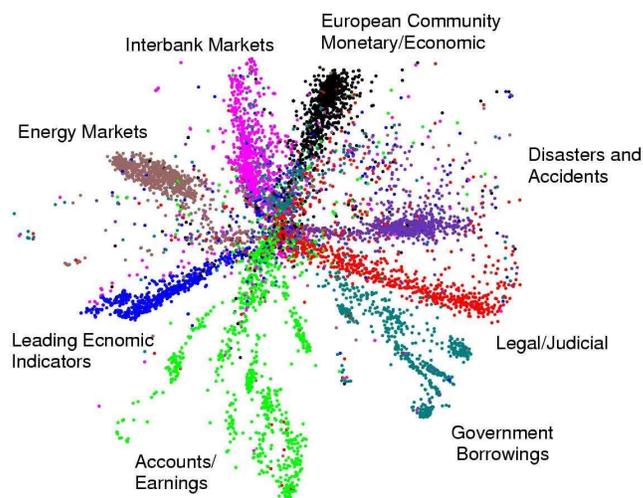


Рис. 20. Визуализация документов

женный метод достигает меньшего значения ошибки обобщения при разумном ограничении количества эпох предобучения на первом слое НС. В табл. 2 отображены результаты, полученные для одинакового количества эпох предобучения для первого и второго слоев сети, а в табл. 3 — для разных.

Визуализация весов первого слоя нейронной сети, полученная после этапа обучения, представлена на рис. 21.

Помимо этих экспериментов, проводились исследования предложенно-

Таблица 2. REBA с одинаковым числом эпох обучения

Метод	Ошибка обучения, %	Ошибка тестирования, %
Classic	1,62	12,56
REBA	1,44	13,14

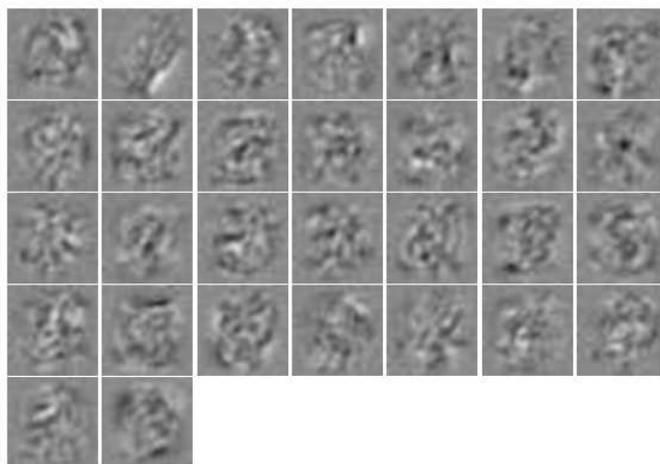


Рис. 21. Визуализация весовых коэффициентов первого слоя

Таблица 3. REBA с разным числом эпох обучения

Метод	Ошибка обучения, %	Ошибка тестирования, %
Classic	1,71	12,77
REBA	1,33	12,38

го метода на простейшей задаче распознавания цифр (см.: *W. Ertel. Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung*). Оригинальный и тестовый наборы изображений представлены на рис. 22. Задача решалась на обучающей выборке из 10 элементов и тестировалась на тестовом наборе из 100 элементов с 10% искажениями. Архитектура сети: 100–75–50–25–10 с сигмоидными функциями активации. Основные параметры: CD-1, скорость обучения: 0.05 (0.9 для REBA), ограничение количество эпох предобучения: 50.

Сравнительные результаты, полученные для этой задачи, представлены в табл. 4.

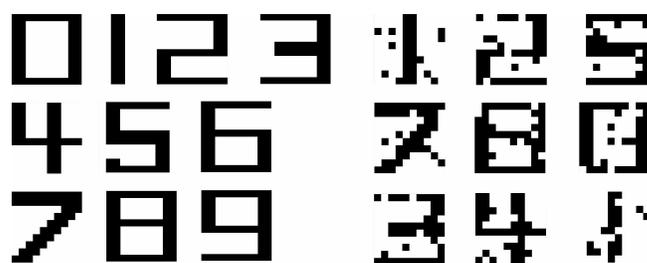


Рис. 22. Оригинальный набор и фрагмент тестового набора изображений

Таблица 4. Сравнение методов (в процентах верно распознанных изображений)

Подход	Ограничение количества эпох обучения		
	100	200	300
RBM	74	84	88
RBM	76	85	87
VBP	50	75	86

Заключение

В данной лекции рассматриваются и анализируются основные парадигмы обучения персептронных нейронных сетей: от однослойного персептрона к многослойным сетям глубокого доверия. Показана несостоятельность некоторых мифов о возможностях персептронных нейронных сетей и обосновывается переход к сверхбольшим персептронным сетям глубокого доверия.

Рассмотрены основные модели обучения нейронных сетей глубокого доверия, базирующиеся на ограниченной машине Больцмана (Restricted Boltzmann Machine (RBM)) и автоассоциативном подходе. Предложен новый метод для обучения ограниченной машины Больцмана и показано, что правило обучения ограниченной машины Больцмана является частным случаем предложенного метода обучения, который базируется на миними-

зации суммарной квадратичной ошибки восстановления информации. Доказана эквивалентность максимизации вероятности распределения данных в ограниченной машине Больцмана и минимизации суммарной квадратичной ошибки восстановления информации в слоях (RBM). Рассматривается применение нейронных сетей глубокого доверия для решения различных задач. Из-за ограниченности времени автор не успел рассмотреть «wake-sleep» алгоритм и рекуррентные нейронные сети глубокого доверия.

Результаты, приведенные в данной лекции, получены в результате научных исследований по данной тематике и чтении автором специального курса лекций «Deep belief neural systems: theory and application» в Варшавском технологическом университете как приглашенный профессор. Автор благодарит профессора С. Янковского из Варшавского технологического университета за плодотворные дискуссии и аспиранта кафедры «Интеллектуальные информационные технологии» Брестского государственного технического университета А. А. Крощенко за помощь в подготовке данной лекции.

Литература

1. Розенблатт Ф. Принципы нейродинамики: Персептрон и теория механизмов мозга: Пер. с англ. – М.: Мир. – 1965. – 480 с.
2. Minsky M., Papert S. Perceptrons: An introduction to computational geometry. – The MIT Press, 1969.
3. Hinton G. E., Osindero S., Teh Y. A fast learning algorithm for deep belief nets // *Neural Computation*. – 2006. – Vol. 18. – pp. 1527–1554.
4. Hinton G. Training products of experts by minimizing contrastive divergence // *Neural Computation*. – 2002. – Vol. 14. – pp. 1771–1800.
5. Hinton G., Salakhutdinov R. Reducing the dimensionality of data with neural networks // *Science*. – 2006. – **313** (5786). – pp. 504–507.
6. Hinton G. E. A practical guide to training restricted Boltzmann machines. – Tech. Rep. 2010-000. Toronto: Machine Learning Group, University of Toronto, 2010.
7. Bengio Y. Learning deep architectures for AI // *Foundations and Trends in Machine Learning*. – 2009. – **2**(1). – pp. 1–127.
8. Bengio Y., Lamblin P., Popovici D., Larochelle H. Greedy layer-wise training of deep networks // In B. Schölkopf, J.C. Platt, T. Hoffman (Eds.), *Advances in Neural Information Processing Systems*, **11**. – MA: MIT Press, Cambridge, 2007. – pp. 153–160.

9. Erhan D., Bengio Y., Courville A., Manzagol P.-A., Vincent P., Bengio S. Why does unsupervised pre-training help deep learning? // *Journal of Machine Learning Research*. – 2010. – **11**. – pp. 625–660.
10. Widrow B., Hoff M. Adaptive switching circuits // In 1960 IRE WESCON Convention Record. –DUNNO. – 1960. – pp. 96–104.
11. Головки В. А. Нейронные сети: обучение, организация и применение. Учеб. пособие для вузов / Общая ред. А. И. Галушкина. – М.: ИПРЖР, 2001. – 256 с.
12. Rumelhart D., Hinton G., Williams R. Learning representation by backpropagation errors // *Nature*. – 1986. – no 323. – pp. 533–536.
13. Lippmann R. P. An introduction to computing with neural nets // *IEEE ASSP Mag.* – 1987. – Vol. 4, no. 2. – pp. 4–22.
14. Cybenko G. Approximations by superpositions of a sigmoidal function // *Math. Contrl., Signals, Syst.* – 1989. – Vol. 2. – pp. 303–314.
15. Hinton G. Greedy layer-wise algorithm // *Journal of Machine Learning Research*. – 2009. – Vol. 1. – pp. 1–40.
16. Golovko V. A Learning technique for deep belief neural networks / V. Golovko, A. Kroshchanka, U. Rubanau, S. Jankowski // In book: *Neural Networks and Artificial Intelligence*. – Springer, 2014. – Vol. 440. *Communication in Computer and Information Science*. – pp. 136–146.
17. Golovko V., Vaitsekhovich H., Apanel E., Mastykin A. Neural network model for transient ischemic attacks diagnostics // *Optical Memory and Neural Networks (Information Optics)*. – 2012. – **21** (3). – pp. 166–176.
18. Scholz M., Fraunholz M., Selbig J. Nonlinear principal component analysis: neural network models and applications // In book: *Principal Manifolds for Data Visualization and Dimension Reduction*. – Berlin-Heidelberg: Springer, 2008. – pp. 44–67.

Владимир Адамович ГОЛОВКО, доктор технических наук, профессор, заведующий кафедрой «Интеллектуальные информационные технологии» и научно-исследовательской лабораторией «Искусственные нейронные сети» Брестского государственного технического университета. Область научных интересов — искусственный интеллект, нейронные сети, искусственные иммунные системы, хаотические процессы, обработка биомедицинских сигналов, обнаружение и распознавание атак и вирусов на компьютерные системы, автономное управление мобильными роботами, прогнозирование. Рецензент журналов *IEEE Transaction on Neural Networks*, *Neuro-*

computing and Knowledge-Based Systems. Организатор международной конференции в Беларуси International Conference on Neural Networks and Artificial Intelligence (ICNNAI). Автор трех монографий, пяти глав в книгах и более 250 научных публикаций.

М. В. КИСЕЛЕВ

ООО «Мегапьютер Интеллидженс», г. Москва

E-mail: mkiselev@megaputer.ru

КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ ИМПУЛЬСНЫХ НЕЙРОННЫХ СЕТЕЙ

Аннотация

В данной обзорной лекции рассматривается текущее состояние раздела нейронауки, занимающегося построением и изучением компьютерных моделей импульсных нейронных сетей, класса нейросетевых моделей, наиболее близко соответствующих нейрофизиологической реальности. Обсуждаются различные модели импульсных нейронов, а также построенных из них сетевых структур. Описываются универсальные и специализированные компьютеры, применяющиеся для моделирования импульсных нейросетей, методология этого моделирования. Лекция завершается рассмотрением практических применений таких сетей и возможных перспектив развития этого направления.

M. V. KISELEV

Megaputer Intelligence Ltd, Moscow

E-mail: mkiselev@megaputer.ru

COMPUTER SIMULATION OF SPIKING NEURAL NETWORKS

Abstract

This review is devoted to a branch of neuroscience targeted at computer simulation of spiking neural networks, the most biologically plausible class of neural networks. Various models of spiking neurons and networks are discussed. General purpose and specialized neuromorphic computers used for their simulation, methodology for this simulation are described. The final part of the review is devoted to practical applications of spiking neural networks and possible perspectives of this research field.

Введение. Импульсные (спайковые) нейронные сети — их особенности и мотивация их изучения

Когда давно уже ставшие классиками науки исследователи, *У. МакКаллок*, *С. Питтс*, *Ф. Розенблатт*, *Дж. Хопфилд* и другие, в 50–80-х годах прошлого века развивали теорию искусственных нейронных сетей и создавали программную реализацию нейросетевых алгоритмов, главной их движущей идеей была попытка имитировать процессы обработки информации в биологическом мозге для применения к задачам распознавания образов, прогноза, кластеризации и т. д. Всем известно, что их усилия оказались очень плодотворны, привели к созданию целой индустрии программирования с многочисленными примерами успешного применения в самых разных областях. Но вот чего не удалось сделать в рамках этого направления, охватывающего несколько первых поколений нейросетевых моделей, — это, как ни странно, добиться даже отдаленного сходства процессов в них с работой нейронных ансамблей в биологическом мозге.

Для того чтобы понять причины этого, нам потребуется краткое описание принципов функционирования биологических нейронов и их взаимодействия. Хотя даже единичный нейрон, по всей видимости, представляет собой весьма сложный процессинговый элемент, реалистичная модель его функционирования известна с достаточно большой степенью уверенности. Как информационная система, нейрон имеет входы, называемые синапсами, тело (сому), реализующее обработку информации, и выход — аксон. Можно считать, что все связи между нейронами однонаправленны — информация передается от одного нейрона через аксон и синапс с другим нейроном. Первый нейрон в этой связи называется пресинаптическим, второй — постсинаптическим. Одно из главных отличий вышеупомянутых традиционных нейросетевых моделей от биологической реальности состоит именно в природе сигналов, передаваемых от одного нейрона к другому. Эти модели основаны на том, что в каждый квант дискретного времени от нейрона к связанному с ним другому нейрону передается некая величина, выражаемая действительным числом. При этом суть обработки информации сетью состоит в синхронном пересчете всеми нейронами своего состояния на основе этих величин, поступивших за последний такт, выработке выходного значения и передаче его дальше по цепи межнейронных связей (или на выход всей системы в целом). Биологические нейроны вместо этого обмениваются короткими импульсами, называемыми спайками, в полностью асинхронном режиме. При этом ни длительность спайков (она очень

мала), ни их амплитуда (она всегда одинакова) не имеют значения. Имеют значение точная позиция отдельных спайков во времени и/или их средняя частота. Так как все нейроны работают совершенно асинхронно друг по отношению к другу, фактор времени в таких нейронных сетях (мы далее будем называть их импульсными, термин «спайковый» представляется все же очень неестественным с языковой точки зрения) становится крайне важным — важны задержки распространения импульсов в межнейронных связях, временные характеристики отдельных нейронов как динамических систем и т. д. Далее, для краткого обозначения этого класса нейронных сетей будет использоваться сокращение ИНС. Обычно это сокращение означает «искусственные нейронные сети», но так как под словосочетанием «нейронные сети» далее будут пониматься именно искусственные нейронные сети (для их биологических прототипов будет применяться термин «нейронные ансамбли»), то первая И в этом сокращении будет обозначать «импульсная». Подробное обсуждение особенностей ИНС можно найти в [1] или в несколько более старой книге [2].

Из различия в способе передачи информации между нейронами вытекают следующие существенные преимущества импульсных нейронных сетей:

- Возможность естественного учета не только пространственной, но и временной структуры входного сигнала. Богатство возможных реакций ИНС на динамические внешние стимулы определяется тем, что сеть теперь сама является динамической системой — черта, которой лишь в очень ограниченном виде обладают некоторые архитектуры рекуррентных традиционных сетей (например, АРТ-сети).
- Простота и экономичность сигнальных линий, связывающих нейроны. Если говорить об аппаратной реализации, то здесь преимущества несомненны. Традиционные нейросети требуют либо многоканальных связей между нейронами — для числовой передачи реальнозначных сигналов, либо сложного помехозащищенного канала, поддерживающего с нужной точностью величину сигнала в аналоговом варианте. В ИНС каждому синапсу соответствует только одна сигнальная линия, причем она почти всегда неактивна, и, следовательно, не рассеивает энергию. Наличие или отсутствие калиброванного спайка надежно фиксируется даже при наличии значительного шума. Аналоговые контуры, ответственные за генерацию и прием таких импульсов, очень просты. Все эти факторы делают вполне реальным создание ИНС, включающих миллиарды нейронов. Хотя размер сети

не есть достаточное условие для выполнения ей сложных интеллектуальных функций, он является необходимым условием (представляется несомненным, что мозг, состоящий не из десятков миллиардов нейронов, а, скажем, из миллиона, не мог бы реализовывать высшие психические функции, даже при наличии сколь угодно сложной структурной организации). Построение традиционных нейронных сетей, даже отдаленно приближающихся по масштабам к этому количеству нейронов, вряд ли возможно.

- Отсутствие необходимости какой-либо синхронизации работы нейронов. Это еще более облегчает создание очень больших моделей ИНС.

Имеется еще одно важное следствие такого способа передачи информации. Единичный спайк сам по себе малоинформативен — в силу его «атомарности» информация может быть заключена лишь во времени его появления. Однако это время подвержено сильным случайным колебаниям, так как единичный нейрон — не очень надежный, сильно «шумящий» элемент. Поэтому в кодировании отдельных логических единиц информации (мы рассмотрим механизмы этого кодирования ниже), как правило, участвуют значительные нейронные ансамбли. Это тоже имеет свою положительную сторону — возрастает устойчивость по отношению к шуму и отказам, однако одновременно накладывает ограничения на размер сети. Если традиционные нейронные сети могут включать всего несколько десятков нейронов и при этом выполнять нетривиальные полезные задачи, то ИНС такого размера вряд ли могут демонстрировать какое-то интересное поведение. Это общая идея ИНС — устойчивая помехозащищенная обработка информации большим ансамблем неточных и ненадежных элементов. Все процессы в ИНС имеют статистический характер, и поэтому разумный порядок размера ИНС, с которыми можно экспериментировать, это тысячи нейронов и более. Кстати говоря, необходимость в большой группе нейронов для кодирования каждой единицы информации не накладывает сильных ограничений на информационную емкость сети, так как один нейрон может входить в большое число таких групп.

Неизбежный большой размер ИНС проявляется в еще одной специфической черте, касающейся алгоритмов их настройки, обучения. Для того чтобы традиционная нейронная сеть стала способна решать требующуюся задачу, производится подстройка параметров связей между нейронами (их весов). Когда этих связей относительно немного (скажем, не более несколь-

ких тысяч) вполне реально запустить какой-то глобальный оптимизационный процесс, подстраивающий значения этих параметров в направлении уменьшения разницы между реальным сигналом на выходе сети и ожидаемым правильным сигналом, например, с помощью известного алгоритма обратного распространения ошибки. Однако этот подход абсолютно неприменим даже для небольших ИНС, где количество межнейронных связей исчисляется миллионами. Совершенно невозможно оценить влияние изменения одного синапса из миллиона на глобальный результат работы сети. Поэтому обучение ИНС должно основываться на других принципах. Должен выполняться принцип локальности: все изменения параметров нейронов и их синапсов должны определяться активностью их непосредственных соседей — пре- и постсинаптических нейронов. Таким образом, важнейший вопрос, на который требуется ответить при создании ИНС, выполняющей какую-либо нужную функцию — какими должны быть эти локальные законы изменения свойств нейронов, чтобы эволюция сети в соответствии с ними приводила к приближению поведения всей сети к желаемому.

Резюмируем все вышесказанное. Импульсные нейронные сети — это класс моделей нейронных сетей, наиболее точно воспроизводящих их биологический прототип. Этот факт определяет два основных класса целей, достигающихся исследовательскими проектами в области моделирования ИНС:

- Собственно моделирование нейронных ансамблей головного мозга. Главный критерий здесь — это как можно большая близость свойств вычислительных моделей к измеренной в экспериментах нейрофизиологической реальности. Главные цели — понимание функционирования разных подсистем мозга и мозга в целом, моделирование и нахождение причин патологий ЦНС, объяснение нейрофизиологических основ высших психических функций.
- Использование бионического подхода к созданию сложных нейросетевых интеллектуальных систем. Абсолютная точность воспроизведения нейрофизиологических феноменов здесь не является основным критерием. Критерий — это выполнение сетью заданных функций. Важнейшая проблема — выбор оптимального уровня абстракции, близости к биологическому прототипу. Так как мозг представляет собой пример фантастических возможностей по анализу огромных потоков многомодальной информации, запоминанию, принятию оптимальных решений в сочетании с недостижимой для современной техники энергоэкономичностью и помехозащищенностью, оче-

видно, что имитация его построения должна быть достаточно близкой, но насколько близкой? Основной областью приложения этих исследований сейчас является робототехника, а также системы искусственного зрения, биометрические системы. Мои исследования также относятся к этому направлению.

Оба направления предполагают глубокое изучение свойств ансамблей импульсных нейронов, для чего принципиально, есть, по крайней мере, три основных пути:

Изучение нейронных ансамблей живого мозга. Это очень интенсивно развивающееся в наши дни направление, источник ценной и наиболее достоверной информации. Но, несмотря на большой прогресс, изучение свойств ансамблей нейронов остается технически очень сложным, а возможности экспериментирования в строго контролируемых условиях — очень ограниченными.

Изучение культур нейронов. Это направление оказалось очень полезным для детального исследования свойств индивидуальных нейронов, однако лишь немногие коллективы применяют такой подход для изучения нейронных ансамблей как целого. Экспериментальные сложности здесь также очень велики, хотя и при наличии гораздо большей свободы в планировании экспериментов. К тому же, имеется пока не решенный вопрос, насколько полученные результаты могут распространяться на поведение нейронных ансамблей *in vivo*.

Компьютерное моделирование. Этот подход привлекателен в первую очередь потому, что позволяет легко варьировать любые схемы экспериментов и измерять все интересующие величины с любой степенью детализации. Хотя информация для построения моделей берется из нейрофизиологических измерений, моделирование может дать результаты, которые в принципе не могли бы быть получены существующей техникой таких измерений. Компьютерное моделирование позволяет верифицировать и определять границы валидности теоретических моделей. С точки зрения задачи исследования мозга его недостатком является то, что неясно, насколько наше незнание точных параметров нейронов и межнейронных связей влияет на реалистичность моделирования. Однако для создания практически применимых ИНС компьютерное моделирование является основным инструментом. Именно ему в основном и посвящена данная лекция.

Модели импульсных нейронов

Так как нейронные сети состоят из нейронов, сначала рассмотрим несколько наиболее часто применяемых моделей отдельных нейронов (всего таких моделей предложено великое множество, их подробный анализ и систематизация могли бы быть предметом толстой монографии). Модели различаются, прежде всего, степенью их детализации и соответствия нейрофизиологическим данным. Рассмотрим их в порядке увеличения их сложности и, соответственно, уровня нейрофизиологического реализма.

Детектор совпадений

Нейрон-детектор совпадений устроен крайне просто. Он полностью описывается набором значений весов его синапсов и значением его порога. Эта модель работает в дискретном времени. Если сумма весов синапсов, на которые в течение данного кванта времени пришли спайки, превышает порог, нейрон сам генерирует спайк, в противном случае — остается неактивным. Эта модель имитирует только одно, хотя и важное свойство нейрона, а именно то, что он испускает спайк как результат синхронного прихода нескольких спайков на его синапсы, имеющие большие веса. Так как веса бывают и положительными и отрицательными (соответствующие синапсы называются возбуждающими и тормозящими), то необходимо еще отсутствие спайков на сильных тормозящих синапсах. Используется эта модель весьма редко, в основном для изучения влияния процессов изменения синаптических весов на общие теоретико-информационные свойства сети, особенно для больших сетей.

Пороговый интегратор с утечкой

Вероятно, это наиболее часто используемая модель. Нейрон имеет меняющуюся во времени величину, характеризующую его состояние. Она называется мембранным потенциалом. В отсутствие пресинаптических спайков она равна 0. Каждый пресинаптический спайк изменяет ее на величину, равную весу синапса. Между приходами спайков мембранный потенциал экспоненциально стремится к 0 с временной константой, являющейся, наряду с порогом, постоянной для данного нейрона величиной. Если после прихода очередного спайка мембранный потенциал становится превышающим порог, нейрон сам генерирует спайк, и его мембранный потенци-

ал становится нулевым. Модель реализует примерно ту же идею, что и предыдущая, только в непрерывном времени. Она допускает простую реализацию в виде аналоговой электронной схемы (рис. 1). В самом деле, накопление значения мембранного потенциала от приходящих токов — пре-синаптических спайков, осуществляется конденсатором, его постепенный распад к нулю — параллельным резистором, а генерация выходного спайка — параллельным пороговым элементом. Модель очень проста, однако ансамбли таких нейронов способны демонстрировать очень интересные эффекты, потенциально применимые для различных процедур обработки информации. Интересно, что теоретический анализ поведения сетей даже таких простых нейронов уже является весьма сложной задачей.

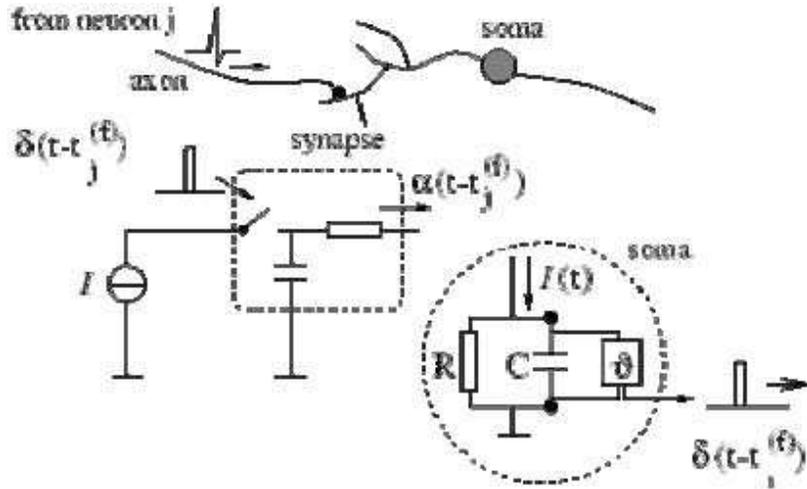


Рис. 1. Аналоговая схема, реализующая модель порогового интегратора с утечкой (цит. по [1])

Двумерные модели

Это весьма многочисленный класс моделей, в которых состояние нейрона описывается двумя параметрами. Такие модели достаточно просты, чтобы быть эффективно реализованными алгоритмически и, в тоже время, по крайней мере качественно, воспроизводят основные типы активности ней-

ронов, известные из нейрофизиологических измерений. Мы рассмотрим две из них: модель Ижикевича [3] (вероятно, самую популярную модель этого класса) и модель с адаптивным порогом возбуждения. Смысл введения второго компонента в модель — придание нейрону свойства «памяти». В предыдущей модели при генерации спайка нейрон устанавливается в одно и то же начальное состояние, так что любая информация о его предыдущей истории полностью стирается. В модели Ижикевича, описываемой следующими уравнениями динамики

$$\begin{cases} \frac{dV}{dt} = 0.04V^2 + 5V + 140 - V, \\ \frac{dU}{dt} = a(bV - U), \end{cases} \quad (1)$$

если $V \geq 30$,

$$\begin{cases} V \leftarrow c, \\ U \leftarrow U + d, \end{cases}$$

дополнительно к мембранному потенциалу V вводится еще переменная U , как раз и обеспечивающая эту память. В зависимости от констант модели нейрон может проявлять весьма разнообразную активность [4], основные типы которой показаны на рис. 2.

Модель с адаптивным порогом возбуждения [5] существенно проще. В этой модели порог возбуждения не является константой. После долгого периода неактивности он равен некоторому своему базовому значению.

Если нейрон генерирует спайк, значение порога увеличивается на некоторую постоянную величину, в период между генерациями спайков его значение экспоненциально стремится к базовому. Это нужно, в первую очередь, для придания нейрону гомеостатических свойств — при сильном увеличении частоты пресинаптических спайков частота генерации спайков растет гораздо медленнее из-за того, что нейрон становится менее возбудимым. При этом нейрон более акцентированно реагирует на динамическую, чем на статическую стимуляцию — как мы это видим на верхнем графике рис. 3 (h обозначает порог возбуждения), показывающем реакцию нейрона на начало его стимуляции (нижний график). В начале стимуляции частота генерации спайков гораздо выше, потом нейрон «устает» генерировать спайки.

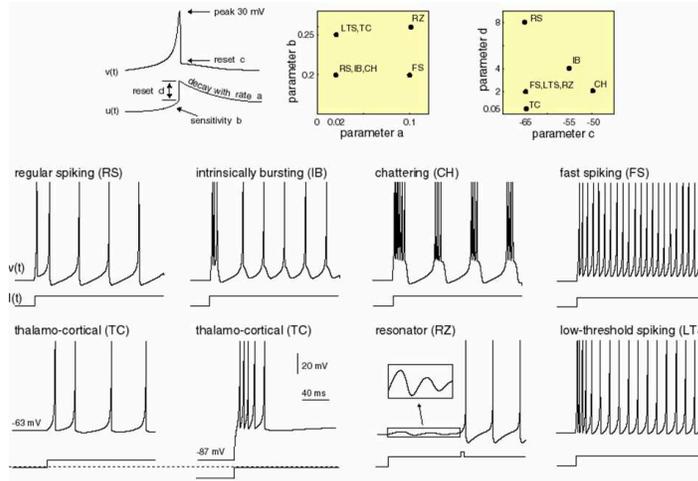


Рис. 2. Основные типы нейронной активности, воспроизводимые моделью Ижикевича при разных значениях входящих в нее параметров (цит. по [1])

Детальная модель Ходжкина-Хаксли

Это наиболее физиологически реалистичная модель, формулируемая в терминах различных ионных токов, проводимостей ионных каналов и прочих элементов детальной теории клеточной мембраны. Она описывается довольно сложной системой нелинейных дифференциальных уравнений, включающих большое количество констант и эмпирически подбираемых функций:

$$\begin{aligned}
 C \frac{dv}{dt} &= -\underline{g}_{Na} m^3 h (v - V_{Na}) - \underline{g}_K n^4 (v - V_K) - g(v - V_r) + I_{op}, \\
 \frac{dn}{dt} &= \alpha_n(v)(1 - n) - \beta_n(v)n, \\
 \frac{dm}{dt} &= \alpha_m(v)(1 - m) - \beta_m(v)m, \\
 \frac{dh}{dt} &= \alpha_h(v)(1 - h) - \beta_h(v)h.
 \end{aligned} \tag{2}$$

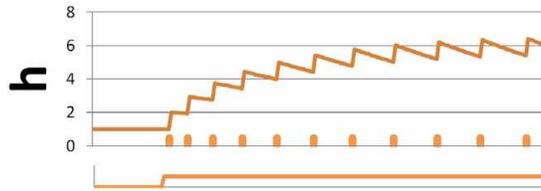


Рис. 3. Ответ нейрона с динамическим порогом возбуждения на начало его постоянной стимуляции

По этой причине уравнения (2) мало пригодны для моделирования ансамблей импульсных нейронов, особенно больших. Комментирование точного смысла данных уравнений заняло бы слишком много места и времени. Не будучи непосредственно связаны с темой лекции, они приведены здесь только с иллюстративной целью.

Более сложные модели синапсов

В заключение этого раздела нельзя не сказать о классе моделей нейронов, в которых состоянием обладает не только тело нейрона, как в случае рассмотренных выше моделей (они называются точечными), но и каждый синапс в отдельности. Конечно детальное описание нейронов, многие из которых имеют не только сложную внутреннюю организацию, но и огромную по клеточным масштабам пространственную протяженность (миллиметры и даже более) не может не включать пространственную разность потенциалов, вариабельность ионных токов в разных частях его мембраны, неоднородность плотности различных рецепторов на ней и т. д. Очевидно, однако, что решая задачу моделирования больших популяций нейронов, неизбежно приходится абстрагироваться от этих деталей, оставляя лишь минимальный набор черт, совершенно принципиальных с точки зрения моделирования. В простейшем варианте таких моделей вводится набор изменяющихся во времени числовых величин по одной для каждого синапса. Причем, в отличие от веса синапса, эти величины изменяются быстро, в той же временной шкале, что и мембранный потенциал. Хотя и увеличивая существенно количество ассоциированных с нейроном хранимых величин, это дополнение, как мы увидим, дает модели нейрона много ценных качеств. Например, оно позволяет придать нейрону гомеостатиче-

ские свойства, ограничив вклад одного синапса в мембранный потенциал даже при условии очень сильной стимуляции этого синапса. Обозначим эту быстро меняющуюся величину, характеризующую состояние i -го синапса, как v_i . После долгого отсутствия сигналов она равна 0, при приходе пресинаптического спайка скачком возрастает до 1, а в промежутках между пресинаптическими спайками экспоненциально приближается к 0. При этом вклад пресинаптического спайка в мембранный потенциал в этой модели [6] равен значению $w_i(1 - v_i)$ на момент прихода спайка (здесь w_i — вес синапса). Очевидно, что при очень частых пресинаптических спайках вклад каждого спайка делается малым. Данное утверждение можно рассматривать как простую модель так называемого кратковременного синаптического подавления [7], эффекта, который действительно наблюдается у некоторых типов синапсов. Еще одно полезное свойство такой модели, как мы увидим — это удобство моделирования механизма синаптической пластичности.

Архитектуры ИНС

Если в используемых моделях индивидуальных импульсных нейронов царит большое разнообразие, то систематизировать сетевые структуры, создаваемые из этих нейронов в разных целях, вообще не представляется возможным. В отличие от традиционных нейронных сетей, где сетевая структура жестко связана и определяется алгоритмом обучения (например, иерархические слои для метода обратного распространения ошибки или слои с возбуждающими восходящими связями и тормозящими латеральными — в сетях Кохонена), для ИНС такой связи, вообще говоря, нет, и выбранная топология сети целиком определяется конкретной задачей моделирования.

Часто в архитектуре сети воспроизводится в той или иной степени детализации структура связей отдельных регионов мозга — когда решается задача моделирования процессов в мозге. Делались даже попытки моделирования мозга в целом — как в знаменитом эксперименте Ижикевича [8], когда на суперкомпьютере просчитывалась одна секунда работы всего мозга человека с максимально известной на тот момент детализацией связей между нейронными ансамблями мозга (одна секунда оказалась равна 50 дням счета на кластерном суперкомпьютере Beowulf). Исследуются структуры, воспроизводящие шестислойное построение серого вещества коры

и/или его колончатую организацию. Исследования, где для анализа активности больших нейронных ансамблей привлекается теория поля и теория сплошных сред, оперируют с пространственно-регулярным расположением нейронов (обычно двумерным). При этом выбор связей между нейронами имеет статистический характер: вероятность связи между нейронами определяется лишь расстоянием между ними (и плотности этих вероятностей различны для возбуждающих и тормозящих связей — как правило, тормозящие связи более короткие). Исследуются и абсолютно хаотические сети. Так как основная цель моих исследований — это изучение процессов самоорганизации в ИНС, я чаще всего работаю именно с такими моделями.

Кодирование информации в ИНС

Фундаментальное различие между традиционными и импульсными нейронными сетями в способе передачи сигналов между нейронами влияет и на то, как представляется обрабатываемая сетью информация. Про традиционные нейросети нельзя даже сказать, что информация в них как-то кодируется. Распространяющиеся в них значения (действительные числа) и есть обрабатываемая информация. Поскольку в ИНС элементарным сигналом является спайк, который, как уже говорилось, сам по себе мало информативен, то для представления какой-то информационной единицы, например, числовой величины, требуется, как правило, много спайков. То, каким образом в совокупности спайков представлена эта информационная единица и называется методом кодирования информации в ИНС. И эти методы, как следует из нейрофизиологических данных, достаточно разнообразны. Их можно разбить на две группы — асинхронные и синхронные. Различаются они тем, что вторая группа методов, в отличие от первой, использует точное расположение спайков на временной оси.

Асинхронные методы кодирования информации в ИНС

К асинхронным относятся следующие методы кодирования информации в ИНС:

Частотное кодирование. Это самый изученный метод кодирования. Он состоит в том, что значение какой-либо величины, например, сила

стимула пропорциональна количеству спайков, поступающих на синапс или генерируемых нейроном в единицу времени. Это простой метод кодирования, концептуально близкий к тому, как информация передается в традиционных нейросетях. Этот метод широко используется нервной системой для передачи сенсорной информации и мышечных команд. Его главный недостаток — плохие временные характеристики. Для того чтобы точно закодировать значение непрерывной величины, надо набрать значительную статистику числа импульсов, а значит этот метод не пригоден для точного кодирования значения быстро меняющихся величин.

Популяционное кодирование. Здесь в кодировании участвует группа нейронов. Количество активных в течение некоторого временного окна нейронов из данной группы и является представлением величины сигнала. Этот способ, очевидно, имеет гораздо лучшие временные характеристики, чем предыдущий. Хотя в реальности они часто комбинируются, так что числовое значение кодируется количеством спайков, испущенных данной группой нейронов в единицу времени. Поэтому можно говорить о комбинированном популяционно-частотном кодировании.

Позиционное кодирование. В этом подходе группа нейронов образует некоторый порядок и значение числовой величины кодируется расположением активного нейрона или нейронов в этом порядке. Например, расположение рецептора на улитке уха соответствует значению частоты, на которую данный рецептор реагирует наиболее сильно.

Синхронные методы кодирования информации в ИНС

К числу синхронных относятся следующие методы кодирования информации в ИНС:

Интервальное кодирование. Числовая величина кодируется в виде интервала между спайками, испущенными некоторыми двумя нейронами или запаздывания последовательностей спайков, испущенными двумя нейронами друг относительно друга. Это не очень надежный метод кодирования, так как чтобы он имел приемлемые временные характеристики, кодирование должно осуществляться очень короткими интервалами, а значит, время генерации спайков должно иметь очень маленькие случайные отклонения, что трудно выполнить для

реальных нейронов, где всегда имеются флуктуации потенциалов, ионных токов и т. д. Тем не менее, показано, что это метод используется для определения направления звука у сов [9] и, вероятно, не только у них.

Фазовое кодирование. Для реализации этого метода нужен некий периодический процесс, охватывающий значительную часть сети. Временное положение спайка или спайков по отношению к фазе этого процесса кодирует значение некоторой величины. Недостатка в таких глобальных периодических процессах в центральной нервной системе млекопитающих нет. Всем известен такой феномен как ритмическая активность значительных нейронных популяций, целых зон мозга, проявляющаяся в виде альфа, бета, гамма, тэта-ритмов и т. д. Например, экспериментально доказана корреляция фазы тэта-ритма, в которой преимущественно генерируют спайки определенные нейроны гиппокампа крысы, с пространственными положениями ее тела [10].

Пространственно-временное кодирование. Этот метод наиболее удобен для кодирования дискретных величин, хотя, возможно, его модификации подходят и для кодирования непрерывно меняющихся значений. Он состоит в том, что наличие, например, некоторого специфического стимула кодируется появлением последовательности спайков, испущенных определенными нейронами в строгой последовательности и с фиксированными временными интервалами между спайками в этой последовательности (появление таких устойчивых пространственно-временных конфигураций спайков *Евгений Ижикевич* назвал *эффектом полихронизации* [11, 12]). Предполагается, что эта последовательность включает много спайков, так что помехозащищенность и надежность такого способа кодирования обеспечивается допустимостью неточного временного позиционирования некоторой небольшой части спайков или даже их отсутствия. Кроме помехозащищенности, преимуществом этого метода является его очень большая информационная емкость (правда, проявляющаяся только в больших ИНС). Мало того что один нейрон может входить в группы, кодирующие разные стимулы (называемые полихронными группами), но даже одна и та же группа нейронов может кодировать разные стимулы за счет разной последовательности спайков, генерируемых разными нейронами группы, как это показано на рис. 4. Тем самым, количество разных стимулов, которое может быть закодировано дан-

ным большим ансамблем нейронов может превосходить не только количество нейронов, но даже количество синапсов в этом ансамбле! Сейчас накоплено большое количество нейрофизиологических данных, свидетельствующих в пользу распространенности такого метода кодирования в коре головного мозга (см., например, [13]).

В значительной степени нерешенной остается до настоящего времени проблема перекодирования из одной формы представления в другую. Очевидно, что если разными подсистемами ЦНС используется разная кодировка, должны существовать нейронные ансамбли, осуществляющие соответствующую конверсию. Преобразованию из синхронной формы в асинхронную был посвящен ряд работ, исследовавших нейросетевые структуры, способные выполнять такое преобразование (см., например, [14, 15]). В отличие от этого, реалистичные модели ИНС, эффективно реализующие обратную конверсию (в особенности это касается пространственно-временного кодирования) пока предложены не были, хотя определенные шаги в этом направлении уже проделаны [11, 16].

Эволюция и обучение ИНС, синаптическая пластичность

Здесь мы подошли, вероятно, к важнейшему вопросу теории импульсных нейронных сетей. Уже для традиционных нейросетей выбор адекватного алгоритма обучения не менее важен, чем вопрос о топологии сети, ее размерах, передаточной функции нейрона и прочего. Но если практически невозможно создать готовую для решения какой-то задачи сеть традиционного типа, состоящую из сотни нейронов, вместо этого она должна приобрести нужные свойства, эволюционировав из первоначального более или менее хаотического состояния, то уж тем более это невозможно даже для небольших ИНС с миллионами синапсов. Тем самым, все громадные усилия по построению, в том числе аппаратно-реализованных, сверхбольших ИНС окажутся совершенно бесполезными, если не будет найден способ эффективно запустить их эволюцию к состоянию, успешно взаимодействующему с окружающей средой с целью решения поставленной задачи.

Как уже кратко упоминалось во вводной части лекции, принципы обучения импульсных нейронных сетей должны быть существенно отличными от обучения традиционных нейросетей, хотя и там и там в основе этого процесса лежит модификация синаптических весов. А именно, невозможность реализации обычного оптимизационного подхода (в силу исключи-

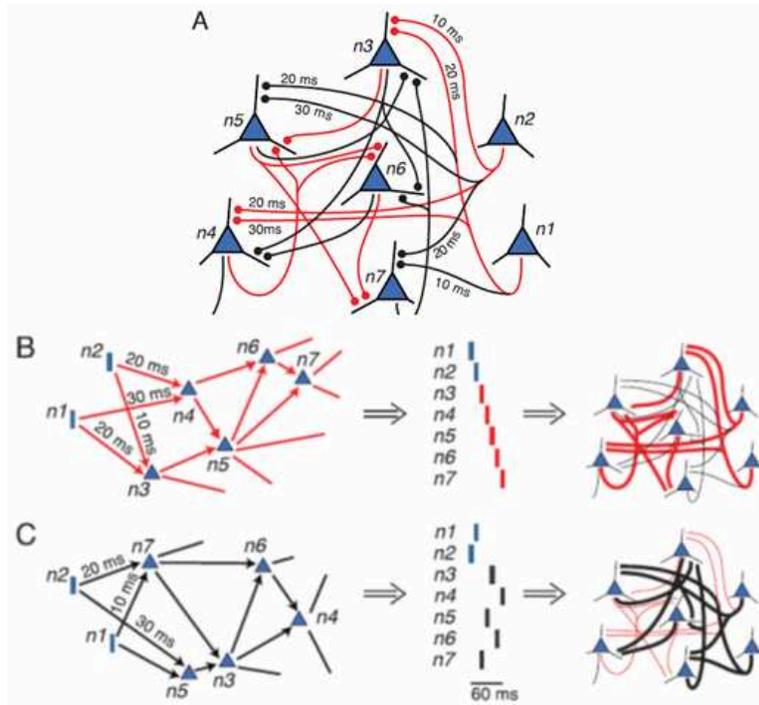


Рис. 4. Иллюстрация того, что одна и та же группа нейронов (А) может кодировать несколько разных стимулов (в данном случае — 2, В и С) (цит. по [12])

тельно высокой размерности пространства оптимизируемых параметров) приводит к необходимости выполнения принципа локальности, в соответствии с которым изменения значений синаптических весов должны определяться историей активности пресинаптического и постсинаптического нейронов (в некоторых моделях эта зависимость еще модулируется некоторыми общими характеристиками активности всего нейронного ансамбля, либо временем, как в моделях «старения» нейронов), а не непосредственно результатами функционирования нейросети как целого.

Общий принцип модификации синаптических весов (синаптической пластичности) был предложен в середине прошлого века *Дональдом Хеб-*

бом. Он звучит так: «Связь между нейронами, демонстрирующими синхронную активность, должны усиливаться, а между нейронами с некоррелированной активностью — ослабляться». Учитывая однонаправленную передачу сигналов в синапсе, более корректная формулировка этого принципа должна отражать причинно-следственную связь активности пресинаптического и постсинаптического нейронов: «Синапс, который часто участвует в генерации постсинаптического спайка (то есть, на который часто приходят спайки перед генерацией постсинаптического спайка) должен усиливаться, остальные синапсы должны ослабляться». Конкретные модели синаптической пластичности, реализующие этот принцип, принято называть *хеббовскими моделями пластичности*.

Важные экспериментальные подтверждения того, что этот принцип действительно реализуется в биологических нейронных сетях, были получены в конце прошлого века Марккрамом, Беллом, Пу и другими исследователями. Их измерения, проводимые главным образом на культурах нейронов, привели к открытию так называемой *синаптической пластичности, зависящей от времени спайков* (spike-timing dependent synaptic plasticity — STDP) [17]. Этот эффект заключается в том, что если нейрон генерирует спайк, то веса синапсов, получивших спайки незадолго до этого, увеличиваются, причем тем сильнее, чем меньше время, прошедшее с момента получения спайка (это называется долговременным усилением синапса — long term potentiation — LTP). А веса синапсов, получающих спайки в течение некоторого времени после генерации спайка, наоборот, ослабляются, и величина этого ослабления тем больше, чем меньше прошло времени с момента генерации спайка (рис. 5), что есть проявление другой стороны этого эффекта — долговременного ослабления синапса (long term depression — LTD). С тех пор существование этого эффекта многократно подтверждено в экспериментах с самыми разными нейронами. Однако справедливости ради надо заметить, что для некоторых типов синапсов наблюдался и прямо противоположный эффект. Тем не менее, STDP является сейчас основной общепринятой моделью синаптической пластичности.

Формально, изменение синаптического веса Δw в модели STDP описывается следующей формулой:

$$\Delta w = \begin{cases} A_+ e^{-(\Delta t/\tau_+)}, & \text{если } \Delta t > 0, \\ -A_- e^{-(\Delta t/\tau_-)}, & \text{если } \Delta t < 0, \end{cases} \quad (3)$$

где A_+ , A_- , τ_+ , τ_- — константы, а Δt — разность во времени между пост-

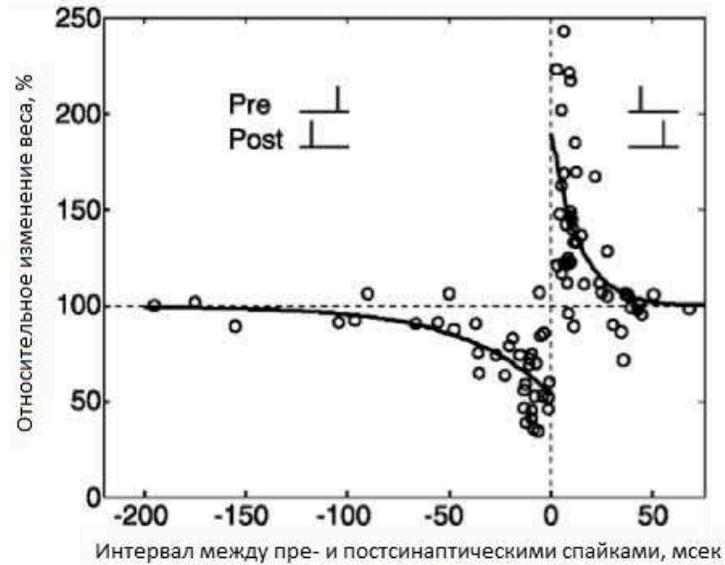


Рис. 5. Экспериментальные измерения эффекта STDP (видоизмененный рисунок из [17])

синаптическим и пресинаптическим спайками.

Несмотря на общее признание модели STDP, нетрудно заметить, что ее классическая формулировка ведет к трудно решаемым проблемам, препятствующим ее непосредственному применению в моделируемых ИНС. Во-первых, очевидно, что рост (как и уменьшение) синаптического веса не может быть безграничным, поэтому w должно как-то зависеть от самого Δw . Во-вторых, этот закон содержит в себе неконтролируемую положительную обратную связь. Действительно, допустим, ИНС содержит в себе замкнутый цикл, состоящий из возбуждающих нейронов, и нейроны этого цикла часто генерируют спайки, по кругу стимулируя друг друга. Тогда в соответствии с STDP синапсы, входящие в этот цикл, будут усиливаться, а это, в свою очередь, приведет к еще более интенсивной активности в этом цикле, и, следовательно, еще большему усилению весов. Таким образом, STDP делает неустойчивыми ИНС со значительным количеством замкнутых контуров возбуждающих нейронов.

Первая из этих проблем обычно решается введением жесткого верхнего предела значения синаптического веса. Однако такое решение приводит к физически необъяснимому разрыву в величине изменения веса. Поэтому более реалистичным представляется другой путь — считать, что в результате STDP увеличивается и уменьшается не сам синаптический вес, а некоторая непрерывно и монотонно связанная с ним величина. Назовем ее *синаптическим ресурсом* W [18]. Поставленная цель достигается, например, при следующей связи w и W :

$$w = w_{\min} + \frac{(w_{\max} - w_{\min}) \max(W, 0)}{w_{\max} - w_{\min} + \max(W, 0)}. \quad (4)$$

Очевидно, что $w_{\min} \leq w < w_{\max}$ и w монотонно растет с ростом W . При малых положительных W его изменение примерно равно изменению w , но с увеличением W рост w замедляется. Этот подход позволяет решить еще одну проблему, актуальную для самых разных типов нейросетей — а именно, проблему баланса обучения и забывания. Как сделать так, чтобы нейросеть не потеряла ценных приобретенных навыков, например, в условиях сильно зашумленного внешнего сигнала, но в то же время могла модифицировать свое поведение в условиях произошедших долговременных изменений? Рассматриваемый подход может дать ответ на этот вопрос, так как синаптический ресурс определяет не только величину синаптического веса, но и его **стабильность**. Действительно, при отрицательных или больших положительных величинах W , он определяет не само значение w , а то, сколько раз должно быть применено, соответственно, LTP или LTD, чтобы значение w начало (существенно) меняться.

Для решения второй проблемы было предложено множество механизмов. Один из наиболее очевидных — ограничение суммарного синаптического веса нейрона (или суммарного синаптического ресурса) с помощью процедуры *ренормализации* синаптических весов. В одной из недавних работ [19] приводятся аргументы в пользу того, что проведение такой ренормализации есть одна из основных функций сна. Рассматривались модели, где эффективность LTP резко падала с ростом частоты генерации спайков [20]. Перспективным представляется подход, в котором эффективность LTP модулируется активностью синапсов определенного типа (что подтверждается многочисленными нейрофизиологическими измерениями [21, 22]). В отсутствие этих сигналов неограниченный рост силы синапсов в упомянутых контурах положительной обратной связи становится невозможным. Эти стабилизирующие поправки к закону STDP отчасти дости-

гают своей цели, однако все они пока недостаточно хорошо изучены теоретически и не могут претендовать на универсальное решение этой очень серьезной проблемы.

И, это особо хочется подчеркнуть, очень далек от разрешения в его обобщенной формулировке главный вопрос: какими чертами должен обладать закон синаптической пластичности, чтобы обеспечить устойчивый рост в первоначально хаотической сети разного рода структур, выполняющих нетривиальную и полезную обработку информации — распознавание, запоминание, реагирование (принятие решений) и т. д.

Модельные эксперименты с ИНС: некоторые проблемы, которые требуется решать

Теперь обсудим несколько вопросов, связанных с практической реализацией вычислительных экспериментов по моделированию ИНС.

Моделирование информационной среды ИНС

Любая ИНС «живет» не в вакууме. Ее задача, обобщенно говоря, обработка информации. Она получает из внешнего мира какую-то стимуляцию и должна на нее как-то отвечать. Моделирование этого информационного окружения часто представляет собой довольно нетривиальную задачу. ИНС оперирует спайками и принимает на входе последовательности спайков. Вспомним наше обсуждение способов кодирования информации в ИНС. Так вот, входные сигналы должны быть закодированы одним из этих способов. Даже в случае самого концептуально простого частотного кодирования требуется ответить на вопрос, как отобразить силу кодируемого стимула на частоту входных спайков. Должна ли быть шкала кодирования логарифмической (как для многих биологических рецепторов) или линейной? Какой частоте спайков должна соответствовать максимально возможная стимуляция? Чтобы ответить на эти вопросы, нужна хорошая теоретическая модель исследуемой ИНС. Однако, к сожалению, такие модели не могут быть построены даже для сетей, составленных из простейших моделей нейронов. Один из популярных способов построения этих моделей основан на так называемых уравнениях среднего поля [23]. Основная идея этого подхода — заменить рассмотрение парных взаимовлияний отдельных нейронов взаимодействием единичного нейрона и его среды, формализу-

емой как усреднение по всей сети ее общих теоретико-информационных параметров. При этом получается две группы уравнений. Одна описывает поведение нейрона, определяемое этой средой, а вторая — формирование параметров среды, исходя из усредненного по ансамблю поведения его нейронов. Этот подход много дал нейронауке, но у него есть три базовых недостатка:

- 1) даже в простых случаях эти уравнения не допускают аналитического решения;
- 2) они основываются на часто нереалистичных предположениях (бесконечный размер сети, отсутствие небольших субпопуляций нейронов с резко отличным от большинства поведением);
- 3) их построение — трудоемкая задача, которая часто должна быть проделана почти полностью заново даже при небольших изменениях модели.

Зачастую неплохие оценки могут быть получены эмпирическими моделями, на основе вычислительных экспериментов предсказывающих свойства сети в целом как функцию параметров модели нейрона и структуры сети, но и этот путь не очень прост.

Мониторинг и интерпретация процессов, происходящих в ИНС

На самом деле, мониторинг процессов, происходящих в ИНС, а также их интерпретация далеко выходят за рамки чисто технической задачи построения соответствующих алгоритмов. Учитывая большой размер сети, распределенное по своей сути кодирование информации в ней, зачастую, невозможность выделить в ней какие-то четкие подсистемы, структуры, отвечающие за отдельные элементы или стадии обработки информации, приходится признать, что основной научный метод — анализ, разбиение одного сложного явления на суперпозицию простых, часто оказывается здесь малоэффективным или даже неприменимым. Максимальным выражением этой идеи служит тезис: «Единственной адекватной моделью большой нейросети является она сама».

Разумеется, собрать общую статистику активности сети в терминах частоты спайков, ее варибельности, цикличности, корреляции с внешними стимулами не представляет проблемы. Если от сети требуется выполнять некоторую обработку информации с четко обозначенным выходным сигналом, то критерии качества этой обработки тоже, как правило, бывают весь-

ма точно и легко вычислимыми. Проблемы начинаются, если мы пытаемся разобраться, **почему** сеть не демонстрирует ожидаемого поведения. Например, мы ожидаем реакции сети на некоторый стимул, закодированной в виде пространственно-временного паттерна спайков (пространственно-временное кодирование). Заранее не известны ни состав соответствующей полихронной группы нейронов, ни точные величины задержек генерируемых ими спайков друг относительно друга. Учитывая то, что спайки, составляющие искомый пространственно-временной паттерн, могут составлять незначительную долю всех спайков, генерируемых в сети (за счет шума, или реакции сети на другие стимулы), а также то, что точная последовательность спайков в этом паттерне может раз от раза отличаться, задача нахождения в сети этой полихронной группы оказывается крайне нетривиальной и может требовать времени счета, сравнимого с самим моделированием.

Длительность моделирования

Как уже говорилось, сеть должна достигать состояния, реализующего некоторую полезную функциональность, в результате процесса модификации синаптических весов. Для этого, как правило, создается модель информационного окружения сети, которая является в некотором смысле стационарной, т. е. любые усредненные по большому периоду времени характеристики входного сигнала не меняются на протяжении эксперимента. Предполагается, что взаимодействуя с этой информационной средой, в результате постепенной модификации синаптических весов сеть достигнет некоторого целевого равновесного состояния. Вопрос в том, как определить момент достижения этого состояния. Будучи сложной динамической системой, большая ИНС даже после бесконечного времени ее эволюции может демонстрировать самое разнообразное поведение кроме асимптотического приближения ее параметров к равновесным значениям. Это могут быть и осцилляции разной силы и разного периода, и даже случайные блуждания. Поэтому вопрос, когда останавливать эксперимент, также очень нетривиален. Даже если сеть достигает состояния, решающего поставленную задачу, часто нет уверенности, что дальнейшая коррекция весов его не разрушит.

Выбор параметров нейронов и всей сети

Наконец, рассмотрим важнейший вопрос выбора параметров модели нейрона, структурных параметров всей сети и констант, входящих в закон синаптической пластичности, оптимальных с точки зрения скорости и устойчивости достижения нейросетью желаемого состояния (что, правда, не столь актуально для собственно нейрофизиологического моделирования, так как там все эти параметры просто устанавливаются наиболее близкими к значениям, полученным из измерений). Этот вопрос был бы решен при наличии хорошей теоретической модели поведения сети и ее эволюции, но, как уже говорилось, удовлетворительные модели такого рода отсутствуют даже для однородных нейросетей, построенных из достаточно простых нейронов. Приемлемой альтернативой могло бы стать использование эмпирических моделей, связывающих параметры, которые могут варьироваться экспериментатором, с величинами, характеризующими активность сети, в том числе, напрямую связанными с поставленной задачей. Однако для получения этих моделей нужно также проводить вычислительные эксперименты. В случае, когда варьируемых параметров значительное число, этих экспериментов потребуется настолько много, что построение хотя бы сколько-нибудь точной эмпирической модели становится невозможным. В этом случае приходится применять многомерные оптимизационные методы, например генетические алгоритмы.

Таким образом, моделирование ИНС не только требует наличия мощных (и желательно массивно-параллельных, как мы увидим) вычислительных систем, но и требует решения многих пока еще не очень разработанных методологических вопросов.

Программные и аппаратные средства, используемые для моделирования ИНС

Если взглянуть на моделирование ИНС с точки зрения его программной реализации, то, прежде всего, очевиден невероятно высокий уровень логической параллельности алгоритмов, осуществляющих это моделирование. Обычно эксперименты с моделированием ИНС — это вычислительные эксперименты с дискретным временем. Каждый квант этого дискретного времени (для сопоставимости с нейрофизиологическими данными удобно считать, что он равен 1 мс, что соответствует самым быстрым процессам,

которые могут происходить в нервной системе) включает реализацию двух процедур:

- обновление состояния каждого нейрона и определение факта генерации им спайка;
- распространение спайков, генерируемых в данный квант времени нейронами, по синапсам.

Первая из этих процедур идеально распараллеливается, так как нейроны функционируют совершенно независимо друг от друга и используют для вычислений только их локальные данные. Вторая распараллеливается чуть хуже, так как возможны конфликты по доступу к памяти между нейронами с одним и тем же пресинаптическим нейроном, либо конфликт по обновлению формируемого списка пакетов сгенерированных спайков для распространения по синапсам. Но, тем не менее, очевидно, что для ИНС, включающей уже 10000 нейронов, вполне оправдано распараллеливание алгоритма, по крайней мере, на тысячи потоков. Поэтому эффективно и удобно реализованный параллелизм является ключевым требованием к программно-аппаратной среде, в которой осуществляется моделирование ИНС. Рассмотрим, какие вычислительные средства применяются для решения этой задачи.

Многоядерный ПК, распараллеливание средствами ОС

Это самый неподходящий вариант для решения рассматриваемой задачи вследствие совершенно недостаточного уровня параллелизма, так как эффективно реализуемый уровень параллельности в этом случае составляет десяток потоков. Единственный плюс этого подхода — дешевизна и отсутствие необходимости в какой-то специализированной программной платформе. С помощью него могут исследоваться лишь общие теоретико-информационные свойства небольших сетей (сотни и тысячи нейронов), как правило, в отсутствие синаптической пластичности.

Многоцелевые графические процессоры (GPGPU)

На данный момент, такая аппаратная платформа, вероятно, соответствует максимальному соотношению производительность/цена для задач этого рода. Для наиболее мощных GPGPU компании NVIDIA достигим уровень параллелизма в десятки тысяч потоков даже при размещении нескольких

(в настоящее время — до 4) графических процессоров на одном ПК. Это вполне позволяет экспериментировать с ИНС, включающими десятки тысяч (и может быть, даже сотни тысяч) нейронов, в том числе и для изучения синаптической пластичности и процессов самоорганизации в ИНС. Интересно, что вследствие специфики этой платформы удобно выделять один поток на обслуживание синапса, а не целого нейрона. Безусловным плюсом является предоставление компанией NVIDIA бесплатной среды программирования, отладки и профилирования для таких устройств, называемой CUDA. Разумеется, возможно создание кластера таких компьютеров, так что это можно назвать масштабируемым решением. К минусам данной платформы можно отнести серьезную трудность программирования. Уровень абстракции, предлагаемый средой CUDA, пока явно недостаточен. В процессе программирования приходится учитывать многочисленные нюансы организации разных видов памяти на GPGPU, использовать низкоуровневые средства межпроцессного взаимодействия и другие специфические и непортативные механизмы.

Многоцелевые суперкомпьютеры

Использование многоцелевых суперкомпьютеров — весьма популярный подход к моделированию больших ИНС. Наличие удобной программной поддержки распараллеливания (например, библиотеки MPI) делает разработку и модификацию вычислительных экспериментов очень быстрой. Разумеется, стоимость таких проектов очень велика, но на данный момент это вполне конкурентоспособный метод. Один из самых известных примеров — это Blue Brain [24], совместный проект IBM и Политехнического университета Лозанны). На данный момент в рамках этого проекта идут попытки крупномасштабного моделирования мозга мелких млекопитающих (~100 миллионов нейронов, ~100 миллиардов синапсов).

Специализированные архитектуры на базе ПЛИС

Современная технология ПЛИС (программируемых логических интегральных схем) в принципе дает возможность строить специализированные массивно-параллельные нейроподобные вычислители исследовательским группам даже с весьма умеренным уровнем финансирования. Уровень распараллеливания может при этом достигать сотен тысяч. Требуется специаль-

ного объяснения тот факт, что построение таких систем не стало сколь угодно распространенным подходом к моделированию ИНС, хотя отдельные группы в различных университетах и разрабатывают подобные устройства. Вероятно, ответ заключается в недостаточной гибкости этой платформы. В условиях, когда теория импульсных нейронных сетей еще далека от зрелости, очень сложно гарантировать, что выбранная модель нейрона и сети в целом окажется удачной и не потребует внесения корректив по ходу проекта. А внесение таких корректив в специализированные вычислители на базе ПЛИС может потребовать от разработчиков очень существенных усилий и времени.

Нейроморфные компьютеры на основе специализированных интегральных микросхем

Это направление испытывает сейчас столь бурный рост, что вследствие своей важности и разнообразия предлагаемых идей и технологических решений заслуживает отдельной лекции. Хотя, разумеется, разработки в этой области по силам лишь исследовательским группам с хорошим долговременным финансированием, этот путь представляется наиболее перспективным с точки зрения приближения к моделированию сверхбольших ИНС размера человеческого мозга.

По методу аппаратной реализации модели нейрона создаваемые нейрочипы можно классифицировать на аналоговые, цифровые и гибридные. Впрочем, отметим, что и аналоговые чипы имеют цифровую компоненту, реализующую маршрутизацию спайков от нейрона к нейрону. Выбор аналогового либо числового подхода основан на обычных критериях — скорости, относительной дешевизне и малом энергопотреблении аналоговых схем и гибкости конфигурирования и модификации цифровых.

Отдельно надо сказать о реализации системы распространения спайков по сети. Несмотря на простоту сигнальных линий, требуемых для передачи спайков, современная технология не может предоставить средств для физического соединения миллионов и более модулей, реализующих отдельные нейроны, в отличие от того, как это имеет место в реальном мозге. В особенности сложной эта проблема является в архитектурах, где ИНС распределена по большому количеству нейрочипов, каждый из которых содержит свое подмножество нейронов. Для поддержки обмена спайками в таких системах был предложен так называемый протокол AER (address-event representation — представление «адрес-событие»), который позволяет

многим передающим и принимающим модулям использовать одну и ту же шину данных псевдопараллельным образом с сохранением в среднем правильной последовательности и запаздываний в распространении спайков. Это цифровой протокол, который оперирует пакетами, представляющими единичные спайки, приходящие на один синапс. Каждый пакет содержит адрес (уникальный идентификатор) нейрона, испустившего спайк, адрес принимающего нейрона, номер его синапса и дополнительную информацию, связанную со спайком, например, точное время прихода спайка на синапс (для моделирования синаптических задержек). Это прекрасно масштабируемый подход: за счет многоуровневой маршрутизации таких пакетов количество физических связей между нейронами даже в полностью связанной сети с N нейронами может быть $\mathcal{O}(N \log N)$ вместо $\mathcal{O}(N^2)$.

Наиболее известные проекты, направленные на разработку таких нейроморфных вычислителей:

SyNAPSE (Systems of Neuromorphic Adaptive Plastic Scalable Electronics — системы адаптивной пластичной масштабируемой электроники) [25]. Совместный проект американского агентства перспективных оборонных исследовательских проектов (DARPA) и IBM. Поскольку проект финансируется министерством обороны США, о нем известно очень немного. Известно, что это долгосрочный (2008–2016 гг.) проект с очень значительным финансированием (до настоящего момента получено около 110 млн. долл.). Основные исполнители — IBM и HRL Laboratories, которые, в свою очередь, привлекают субподрядчиков из различных американских университетов. Конечная цель проекта — создание нейроморфного компьютера масштаба человеческого мозга, содержащего 10 млрд. нейронов, 100 трлн. синапсов, потребляющего 1 кВт энергии и занимающего менее 2 дм³ пространства. Хотя есть некоторые сомнения в достижимости этой цели, недавно проект дал первый впечатляющий результат — выпуск компанией IBM нейрочипа TrueNorth. В его состав входит 1 млн. программируемых нейронов и 256 млн. программируемых синапсов. Чип полностью цифровой. Моделирование обеспечивается 4096 параллельно работающими ядрами на каждом чипе. Он является чемпионом во многих отношениях: содержит 5.4 млрд. транзисторов и потребляет всего 70 мВт энергии! По экономичности этот показатель уже приближается к биологическим нейронным сетям. На данный момент построены системы, включающие 16 таких чипов на одной плате, причем теоретически масштабируемость таких нейрокомпьютеров не огра-

ничена. Детали построения и функционирования этого чипа пока не раскрываются, однако известно, что он способен эмулировать различные модели синаптической пластичности и, в частности, STDP. В прикладной области применения TrueNorth сейчас сосредоточены главным образом в разработках систем обработки видеоинформации, но конкретные данные о решаемых задачах и достигнутом прогрессе пока не обнародуются.

Neurogrid [26]. Проект ведется Стэнфордским университетом и использует аналоговый подход к моделированию нейронов. Разработанный в рамках данного проекта нейрокомпьютер эмулирует в реальном времени работу сети из 1 млн. нейронов и 6 млрд. синапсов. Каждый нейрон эмулируется отдельной аналоговой схемой. Все нейроны в сети описываются одной моделью и имеют одинаковые параметры, но эти параметры многочисленны и могут варьироваться, что позволяет изучать ансамбли нейронов самых разных типов. Главная проблема этого проекта — устаревшая технологическая база. Уже в его начале применяемая технология производства микросхем не могла быть названа современной. Поэтому сейчас, по-видимому, реализация проекта затормозится в связи с переходом на новые технологии. В приложениях этого нейрокомпьютера основной упор делается на нейропротезирование, в чем, правда, пока не достигнуто значительных успехов.

SpiNNaker [27]. Хотя проект реализуется в Манчестерском университете, он имеет общеевропейскую поддержку, будучи направлен на создание нейроморфной аппаратной платформы для реализации грандиозного европейского проекта «Человеческий мозг» (Human Brain Project). Этот проект основывается на использовании специализированных цифровых чипов с возможностью построения из них высокомасштабируемых модульных систем с различной топологией их соединения. Каждый чип содержит 16 независимо работающих процессоров ARM9 и может эмулировать в реальном времени работу десятков тысяч нейронов. Эффективно работающий роутер обеспечивает доставку в пределах чипа 5 млрд. спайков в секунду (в терминах «один отправитель–один получатель»). На одной плате монтируется 48 таких чипов, спаренных с микросхемами SDRAM. С помощью этой архитектуры сейчас проводятся эксперименты в рамках шестислойной модели таламокортикальных связей, предложенной *Евгением Ижикевичем*.

BrainScaleS [28]. Базой проекта является Гейдельбергский университет, но принимают участие в нем 19 исследовательских групп из 10 европейских стран. Этот проект нацелен непосредственно на изучение и моделирование работы мозга человека, он также ассоциирован с проектом «Человеческий мозг». В рамках проекта создан гибридный цифро-аналоговый нейрочип. Построенные из таких чипов системы применяются для моделирования ИНС, включающих 200 тыс. нейронов и 50 млн. синапсов.

В заключение этого раздела следует с сожалением признать, что о подобных проектах, реализуемых в России, ничего не известно . . .

Основные цели и задачи моделирования ИНС в настоящее время

Назовем некоторые наиболее актуальные на данный момент научные задачи, решаемые исследовательскими проектами по моделированию ИНС.

Моделирование обработки сенсорной информации

Вероятно, это самое значительное по объему исследований направление. В первую очередь это касается компьютерного моделирования зрения (как об этом уже говорилось в предыдущем разделе). Распознавание зрительных образов и анализ сцен всегда были пробным камнем, на котором испытывались разнообразные нейросетевые технологии. Естественный для ИНС динамический характер обработки информации делает их перспективной базой для анализа сложных меняющихся во времени изображений, а также систем активного зрения, где положение фиксирующих изображение камер управляемо варьируется для получения наиболее информативных ракурсов и разрешений. К тому же данная прикладная область обещает наиболее быструю отдачу от внедрения в связи с высокой востребованностью этих технологий. Впрочем, компьютерное зрение — это огромная область нейросетевых технологий, требующая отдельного рассмотрения. Все вышесказанное относится, хотя и в меньшей степени, также и к моделированию слуха. В качестве примера может быть назван проект SCANDLE [29], направленный на создание средств автоматического распознавания структуры смешанных звуковых образов при наличии шума. Координация проекта

осуществляется Центром робототехники и нейронных систем университета в Плимуте (Великобритания), в нем участвует ряд европейских исследовательских центров. Для нужд проекта разработан специализированный аналоговый чип, моделирующий ансамбль нейронов-пороговых интеграторов с утечкой и синаптическую пластичность в рамках модели STDP.

Моделирование механизмов памяти

Это направление имеет два аспекта:

- 1) построение биологически реалистичных моделей механизмов рабочей и кратковременной памяти мозга;
- 2) достижение понимания общих принципов того, как недавно полученная информация могла бы комбинироваться с приходящими позднее стимулами для их совместной обработки и создания непрерывного внутреннего представления происходящих во внешней среде процессов.

Асинхронный характер функционирования ИНС приводит к необходимости распознавать и реагировать на стимулы, отдельные информационные составляющие которых могут быть сдвинуты друг относительно друга и растянуты во времени. Механизм рабочей памяти должен сохранять их и интегрировать в единую картину. Механизм кратковременной памяти мог бы соотносить недавно полученные стимулы и реакцию сети на них со следующими с некоторой задержкой сигналами наказания и поощрения для реализации направленного обучения. Какие структуры сети могут служить носителем этих механизмов? Как они могли бы формироваться в первоначально однородной сети? Чем определяется длительность памяти, ее устойчивость, информационная емкость? На эти вопросы ответов пока еще нет и найти их — задача исследований, относящихся к данному направлению. Предлагались модели, где запоминание основывается на длящейся в течение некоторого времени постоянной активности определенных замкнутых контуров в нейросети [30], предлагалось также основывать эти механизмы на кратковременных отличиях некоторых синаптических весов от медленно меняющегося базового уровня, а также на комбинации этих эффектов [12]. Однако пока эти исследования остаются на уровне скорее демонстрации возможности реализации кратковременной памяти в моделях ИНС.

Исследование кодирования информации в ИНС и конвертации между разными способами кодирования

Основные принципы кодирования информации в ИНС были рассмотрены выше, в разделе «Кодирование информации в ИНС». Они достаточно надежно установлены и вряд ли можно ожидать в этом вопросе каких-то революционных открытий. Однако соотношение разных схем кодирования в мозге и, главное, способы трансформации одной кодировки в другую пока остаются неясными. Один из интереснейших вопросов здесь — каким образом первичная популяционно-частотно-кодированная сенсорная информация преобразуется в пространственно-временную кодировку, требующуюся для эффективного обучения сети на основе STDP, ее интеграции с другими сенсорными потоками, а также для другой сложной обработки в коре головного мозга [16].

Применение ИНС в системах автоматического управления

Здесь, прежде всего, речь идет о робототехнике — области технологий, где ожидается наиболее скорая реальная отдача от применения ИНС. Собственно говоря, уже сейчас несколько коллективов, работающих в области робототехники, могут продемонстрировать простых роботов, управляемых ИНС. Один из наиболее успешных примеров автор данной лекции видел своими глазами во время визита в американскую исследовательскую компанию Brain Corrogation. Продемонстрированный робот мог передвигаться по комнате, обходить (точнее, объезжать) препятствия, передвигаться к стенам, покрашенным в определенные цвета. Однако надо отметить, что пока уровень адаптивности, обучения в этих робототехнических системах очень низок. Чтобы построить полноценный обучающийся замкнутый контур управления на базе ИНС, надо иметь гораздо большее представление о том, как формировать различные нейросетевые структуры, реализующие отдельные компоненты этого контура, т. е. решить задачи, упомянутые в этом разделе (а также множество других). Таким образом, это задача не для настоящего момента, а скорее для близкого будущего.

Нейропротезирование и интерфейсы «мозг-компьютер»

Так как известны принципы кодирования сенсорной информации, поступающей в мозг, естественным образом возникла идея эмулировать сигнала-

лы пораженных болезнью, травмированных или ампутированных органов чувств и подавать их через электроды на нервы, идущие от этих органов чувств или даже непосредственно в регионы коры головного мозга, ответственные за обработку соответствующей сенсорной информации. Аналогично этому, знание кодирования команд, поступающих от мозга к мышцам, дает возможность их интерпретации специальными протезами, управляемыми микропроцессорами, которые воспроизводят действия в нормальном случае выполняемые здоровой конечностью.

Это направление сейчас активно развивается. Уже более 10 лет существуют зрительные нейропротезы, которые подают сигналы от матриц светочувствительных элементов, закодированные в виде последовательностей спайков в зрительные отделы коры совершенно слепых пациентов, давая им возможность ориентироваться в пространстве и даже читать. Еще дольше и успешнее история применения слуховых нейропротезов у пациентов с полной потерей слуха (в том числе, глухих от рождения!). Дальнейший успех в этом направлении в большой степени определяется уровнем понимания процессов первичной обработки сенсорной информации в мозге, чему посвящено много экспериментов по компьютерному моделированию.

История создания механических двигательных протезов в наше время только начинается, хотя уже имеются впечатляющие достижения, например, управление искусственной рукой непосредственно сигналами нейронов двигательной коры. Один из упомянутых выше проектов, Neurogrid, имеет целью построение комплексного интерпретатора мозговых команд для полностью парализованных людей.

Еще одним направлением нейропротезирования, имеющим более чем 10-летнюю историю успешного применения, является прямая электростимуляция мозга. Посылка последовательностей спайков через электроды, вживленные в определенные глубинные структуры мозга, такие как глобус паллидус, таламус, гипоталамические ядра, помогает облегчить или полностью устранить симптомы болезни Паркинсона, дистонии, хронической боли и даже психиатрических заболеваний (маниакально-депрессивный психоз, шизофрения). Здесь речь уже идет о прямом направленном вмешательстве в работу мозга. И опять же, прогресс этих методов напрямую связан с пониманием взаимодействия соответствующих мозговых структур, достигаемым, в том числе, с помощью компьютерного моделирования.

Изучение общих проблем самоорганизации ИНС, теоретических принципов обработки информации ими

Хотя этот ряд задач поставлен последним в данном списке, он представляется важнейшим. Не слишком впечатляющие пока успехи на перечисленных выше направлениях объясняются как раз отсутствием хорошего теоретического базиса, позволяющего строить нейросети и задавать законы синаптической пластичности так, чтобы сеть начинала выполнять требующуюся от нее задачу. Какие свойства нейрона являются с этой точки зрения совершенно необходимыми, а от каких можно абстрагироваться? Как черты модели синаптической пластичности могут обеспечивать рост и стабилизацию структур сети, осуществляющих требуемые операции? Как связан размер сети и ее функциональные возможности? Один из путей к ответам на эти вопросы лежит через проведение модельных экспериментов с разнообразными нейросетевыми структурами, не обязательно точно имитирующими структуры мозга.

Перспективы. Чего можно ожидать в близком будущем

Технологии в области импульсных нейронных сетей столь быстро и столь неравномерно развиваются, что очень трудно делать обоснованные прогнозы. Пожалуй, наиболее определенный прогноз можно сделать в области прогресса нейроморфных вычислителей. Многие согласны в том, что нейроморфные системы для моделирования ИНС размера человеческого мозга будут созданы в течение 10 ближайших лет (см., например, интересную количественную оценку в [31]). Однако, как уже несколько раз здесь говорилось, это отнюдь не означает возможности искусственного воспроизведения высших психических функций мозга и, в первую очередь, сознания. Из-за сильного отставания теоретического базиса имеются сомнения, что даже в более исследованных областях, таких как обработка и интеграция разнообразной сенсорной информации или запоминание, искусственные нейросети в ближайшие 10 лет приобретут возможности, хотя бы отдаленно близкие к человеческим.

Вместе с тем, огромные усилия, которые направлены сейчас на построение детальных моделей мозга (то, что называется «обратным реинжинирингом» мозга), несомненно, принесут свои плоды. Вопрос в том, даст ли это детальное *знание* еще и *понимание* того, как эти системы работают.

Сейчас обращает на себя внимание сильный разрыв между весьма значительными ресурсами (в том числе и финансовыми), выделяемыми на исследования и моделирование импульсных нейронных сетей и почти полным отсутствием значимых практических результатов. Есть все основания надеяться, что этот разрыв исчезнет (или, по крайней мере, будет значительно сокращен) в ближайшее десятилетие. Главную роль в этом, по-видимому, сыграет робототехника. Роботы, способные совершенно автономно решать ограниченный круг задач, взаимодействуя с окружающим миром посредством разнообразных сенсоров и эффекторов, будут, скорее всего, управляться именно нейроморфными процессорами, эмулирующими импульсные нейронные сети.

Пока очень трудно сказать, найдут ли ИНС в близком будущем массовое применение в каких-то бытовых устройствах, в области телекоммуникаций, биометрических технологий и прочего, хотя многое говорит о том, что это может произойти. Несомненно одно: так как сверхцелью исследований по моделированию ИНС является понимание функционирования самого сложного из известных нам объектов во Вселенной — человеческого мозга, достижение этой цели явится очередной технологической (и, скорее всего, не только технологической) революцией, превосходящей по масштабам использование парового двигателя, электричества или компьютеров. Понимание того, что есть личность, сознание, создание путей прямого информационного взаимодействия мозга с другим мозгом или компьютером, переход на принципиально новую ступень информационной интеграции человечества — кто знает, какими еще дарами или ловушками чреват этот путь. Однако рассуждения об этих перспективах относятся уже скорее к жанру научной фантастики, чем научного исследования.

Заключение. Выводы

В данной лекции сделана попытка показать современное состояние целой небольшой области науки с ее успехами, проблемами и перспективами, поэтому выводы из этого изложения можно сделать самые разнообразные.

Однако все же хотелось бы акцентировать внимание на трех тезисах, наиболее актуальных, так сказать, здесь и сейчас:

- Складывается сильная диспропорция между аппаратными возможностями по моделированию очень больших ИНС и пониманием, что с этими возможностями делать. Это все более и более повышает важ-

ность как модельных экспериментов, направленных на изучение общих свойств информационных процессов в ИНС, условий для их самоорганизации, так и разработки теоретического базиса для их описания. Возможно, это потребует каких-то новых способов формализации этих явлений, совсем новой математики для их анализа.

- Успешное продвижение в этой области более, чем во многих других требует междисциплинарного подхода. Нейрофизиология, теория нелинейных динамических систем, математическая статистика, теория высокопроизводительных вычислений, проектирование сверхбольших интегральных микросхем, робототехника, биокибернетика — вот далеко не полный перечень дисциплин, чьи методы и подходы естественным образом переплетены в этом направлении исследований.
- Мы видим, как складывается научное направление, от успехов которого может существенным образом зависеть технологический прогресс, международный престиж, а возможно и безопасность государства. Гонка к достижению вычислительной мощности, сравнимой с вычислительной мощностью человеческого мозга ничуть не менее амбициозна, чем, в свое время, космическая гонка или соревнование по синтезу трансурановых элементов. К сожалению, эта гонка требует сравнимых по масштабу с этими двумя историческими примерами усилий и невозможна без поддержки государства. Очень хочется надеяться, что эта поддержка будет оказана, и в перечень проектов, приведенный выше, можно будет включить проект, выполняющийся на базе российских университетов, исследовательских центров и/или коммерческих структур.

Литература

1. Gerstner W., Kistler W. Spiking neuron models. Single neurons, populations, plasticity. – Cambridge University Press, 2002.
2. Maas W., Bishop Ch. (Eds.) Pulsed neural networks. – MIT Press, 1998.
3. Izhikevich E. Simple model of spiking neurons // *IEEE Trans. on Neural Networks.* – 2003, **14**:1569–1572.
4. Izhikevich E. Which model to use for cortical spiking neurons? // *IEEE Trans. on Neural Networks.* – 2004, **15**:1063–1070.
5. Benda J., Maler L., Longtin A. Linear versus nonlinear signal transmission in neuron models with adaptation currents or dynamic thresholds // *Journal of Neurophysiology.* – 2010, **104**:2806–2820.

6. Kiselev M. Self-organized spiking neural network recognizing phase/frequency correlations // *Proc. of IJCNN'2009*, Atlanta, Georgia, 2009. – pp. 1633–1639.
7. Rosenbaum R., Rubin J., Doiron B. Short term synaptic depression imposes a frequency dependent filter on synaptic information transfer // *PLoS Comput Biol.* – 2012, **8**(6):e1002557. doi:10.1371/journal.pcbi.1002557.
8. Izhikevich E., Edelman G. Large-scale model of mammalian thalamocortical systems // *Proc. of The National Academy of Sciences.* – 2008, **105**:3593–3598.
9. Konishi M. Coding of Auditory Space // *Annu. Rev. Neurosci.* – 2003, **26**:31–55.
10. Ahmed O., Mehta M. The hippocampal rate code: anatomy, physiology and theory // *Trends in Neuroscience.* – 2009, **32**(6):329–338.
11. Izhikevich E. Polychronization: Computation with spikes // *Neural Computation.* – 2006, (18):245–282.
12. Szatmary B., Izhikevich E. Spike-timing theory of working memory // *PLoS Computational Biology.* – 2010, **6**(8):e1000879.
13. Butts D., Weng C., Jin J., Yeh C., Lesica N., Alonso J., Stanley G. Temporal precision in the neural code and the timescales of natural vision // *Nature.* – 2007, **449**(7158):92–95.
14. Samengo I., Montemurro M. Conversion of phase information into a spike-count code by bursting neurons // *PLoS ONE.* – 2010, **5**(3):e9669.
15. Mehta M., Lee A., Wilson M. Role of experience and oscillations in transforming a rate code into a temporal code // *Nature.* – 2002, **417**(6890):741–746.
16. Kiselev M. Homogenous chaotic network serving as a rate/population code to temporal code converter // *Computational Intelligence and Neuroscience.* – 2014:476580, doi:10.1155/2014/476580.
17. Bi G., Poo M. Synaptic modifications in cultured Hippocampal neurons: dependence on spike timing, synaptic strength, and postsynaptic cell type // *J. Neurosci.* – 1998, **18**:10464–10472.
18. Киселев М.В. Однослойная самоорганизующаяся сеть импульсных нейронов, распознающая нечеткую синхронию во входном сигнале // *Нейрокомпьютеры.* – 2009, № 10. – с. 3–11.
19. Fink C., Murphy G., Zochowski M., Booth V. A dynamical role for acetylcholine in synaptic renormalization // *PLoS Computational Biology.* – 2013, **9**(3):e1002939.
20. Pfister J., Gerstner W. Triplets of spikes in a model of spike timing-dependent plasticity // *J. Neurosci.* – 2006, **26**:9673–9682.
21. Pawlak V., Kerr J. Dopamine receptor activation is required for corticostriatal spike-timing-dependent plasticity // *J. Neurosci.* – 2008, **28**:2435–2446.

22. Zhang J., Lau P., Bi G. Gain in sensitivity and loss in temporal contrast of STDP by dopaminergic modulation at hippocampal synapses // *Proc. of The National Academy of Sciences*. – 2009, **106**:13028–13033.
23. Baladron J., Fiaschi D., Faugeras O., Touboul J. Mean-field description and propagation of chaos in networks of Hodgkin-Huxley and FitzHugh-Nagumo neurons // *The Journal of Mathematical Neuroscience*. – 2012, **2**(10):10.1186/2190-8567-2-10.
24. URL: <http://bluebrain.epfl.ch/>
25. [http://www.darpa.mil/Our_Work/DSO/Programs/Systems_of_Neuromorphic_Adaptive_Plastic_Scalable_Electronics_\(SYNAPSE\).aspx](http://www.darpa.mil/Our_Work/DSO/Programs/Systems_of_Neuromorphic_Adaptive_Plastic_Scalable_Electronics_(SYNAPSE).aspx)
26. URL: <http://news.stanford.edu/pr/2014/pr-neurogrid-boahen-engineering-042814.html>
27. URL: <http://apt.cs.manchester.ac.uk/projects/SpiNNaker/>
28. URL: <https://brainscales.kip.uni-heidelberg.de/index.html>
29. URL: <http://scandle.eu/>
30. Kiselev M. Self-organization process in large spiking neural networks leading to formation of working memory mechanism // *Proc. of IWANN 2013 in LNCS 7902, Part I*. 2013. – pp. 510–517.
31. URL: http://www.izhikevich.org/human_brain_simulation/why.htm

Михаил Витальевич КИСЕЛЕВ, кандидат технических наук, генеральный директор компании ООО «Мегасьютер Интеллидженс» (с 1993 года), доцент Чувашского государственного университета (с 2013 года), член международного Института информационных технологий, управления и коммуникаций (INSTICC) (с 2014 года), руководитель проекта создания системы data mining PolyAnalyst (с 1992 года), автор нескольких оригинальных алгоритмов анализа данных и текстов, а также научных работ по компьютерному моделированию больших импульсных нейронных сетей (с 2004 года), руководитель проекта ArNI по созданию программно-аппаратной платформы для моделирования импульсных нейронных сетей (с 2012 года).

С. Б. ПАРИН^{1,2}, С. А. ПОЛЕВАЯ^{1,2}

¹Нижегородский государственный университет им. Н. И. Лобачевского

²Нижегородская государственная медицинская академия

E-mail: parins@mail.ru

**ИНФОРМАЦИЯ И УПРАВЛЕНИЕ В ЖИВЫХ СИСТЕМАХ
(ЛЕГЕНДЫ И МИФЫ КОГНИТИВНОЙ НАУКИ)**

Аннотация

В лекции обсуждаются ключевые вопросы исследования информационных процессов в живых системах: нематериальная сущность информации как таковой и вытекающие из этого проблемы объективного измерения субъективных явлений (в том числе, так называемой «психики»). Рассматриваются особенности биологических кодов разного уровня, материальные носители биологической информации (мембранные электрические потенциалы и информоны), а также условия и способы измерения их параметров. Затрагиваются распространенные ошибки и ситуации подмены понятий при изучении информации в живых системах. Анализируются возможные пути оптимизации и конкретизации исследований информационных процессов в живых системах различного уровня сложности.

S. B. PARIN^{1,2}, S. A. POLEVAIA^{1,2}

¹ N.I.Lobacytsky State University of Nizhny Novgorod

² Nizhny Novgorod State Medical Academy

E-mail: parins@mail.ru

**INFORMATION AND CONTROL IN LIVING SYSTEMS (MYTHS
AND LEGENDS OF COGNITIVE SCIENCE)**

Abstract

Discusses the key research questions of information processes in living systems: the immaterial essence of the information and the consequent problems of objective measurement of subjective phenomena (including so-called “psychic”). The features of the biological codes of different levels, material carriers of biological information (membrane electrical potentials and informons), as well as the conditions and methods of measurement of their parameters; the common mistakes and situations substitution of concepts in the study of information in living systems. The possible ways to optimize the research of information processes in living systems at various levels of complexity.

Введение: постановка задачи

Эта лекция не преследует цели подробного описания механизмов информационных процессов в живых системах. Задача стоит другая: попытаться обсудить тот комплекс противоречий, который всё более разрастается в нейронауках и угрожает разрушить и без того хрупкое и недостроенное здание, именуемое когнитивной наукой. Сама идея мультидисциплинарности является безусловно прогрессивной, однако в ней всегда присутствует «синдром вавилонской башни» — опасность смешения языков и, как следствие, взаимонепонимания. С одной стороны, это вполне понятно и объективно детерминировано чрезвычайным многообразием сленгов, свойственных разным наукам. С другой стороны, в любой области науки, наряду с объективно установленными фактами и закономерностями, в большей или меньшей мере присутствуют гипотезы, призванные (за неимением объективных данных) связать разрозненные знания в целостную систему взглядов. Это естественный, закономерный и, похоже, единственно возможный

путь к познанию законов мира. И чем сложнее предмет изучения данной конкретной науки, тем большим количеством гипотез залатываются прорехи в наших знаниях. Неслучайна обижающая гуманитариев шутка, что физики (химики, отчасти биологи и др.) оперируют знаниями, а лирики (историки, философы, социологи, лингвисты, отчасти — увы — нейробиологи и особенно психологи) — мнениями. В предлагаемой лекции мы проиллюстрируем данную мысль некоторыми наиболее вопиющими примерами. Повторим, в этом не было бы ничего страшного, если бы в условиях мультидисциплинарности мы сплошь и рядом не встречались с «убедительными» утверждениями, которые на поверку оказываются не более чем домыслами. В полной мере это касается проблемы работы (получения, обработки, хранения, реализации) живых систем с информацией.

Название данной лекции почти дословно воспроизводит фрагмент определения кибернетики как науки, данного её отцом *Норбертом Винером*. Действительно, проблемы информации и управления в живых системах являются ключевыми для различных биологических и психологических наук на протяжении многих десятилетий. Об информации, как свойстве живого, написана масса книг, это главный предмет обсуждения на множестве конференций и симпозиумов. Именно информационные процессы являются главным объектом внимания когнитивной науки.

Хорошо известно, что сегодня в когнитивной науке сосуществуют три базовых направления:

1. HOT (Higher-Order Thought) — теория (*Armstrong, Lycan, Byrne, Carruthers, Rosenthal* и др.), относящая предмет когнитивных исследований к наивысшей идеальной сфере (многие её сторонники склонны даже не рассматривать первичные когнитивные функции) и хорошо перекликающаяся со старой доброй идеей гештальта. Соответственно, измерению когнитивные процессы не подлежат (не считать же измерителями пресловутые психологические опросники и тесты) и опора возможна только на феноменологическое описание и попытки проникновения в замысел (или умысел) эволюции, породившей сознание.
2. Теория Global Workspace (*Crick, Koch, Baars, Tononi, Edelman, А. М. Иваницкий, К. В. Анохин, Александров, Hawkins, Block, Damasio, Engel, Dehaene, Changeux, Seth, Редько, Жданов, Сергин, Яхно* и многие другие) проросла из бихевиоризма (включая протобихевиоризм Павлова), впитала теорию функциональных систем *Петра Кузьмича Анохина* и базируется сегодня на системном (кибернетическом)

подходе. Соответственно, сознание рассматривается как высший (информационный) продукт физиологической активности систем мозга (на всех уровнях их организации), его отдельные проявления поддаются косвенному измерению и математическому моделированию (в нейросетевой парадигме, прежде всего). «На выходе», таким образом, можно ожидать создание силиконового разума, обладающего признаками человеческого сознания.

3. Биологическая (или нейробиологическая) теория (*Smart, Kirk, Hobbes, Heeger, Pascual-Leone, Kobaishi, Alkire, Silvanto* и мн. др.) восходит к воинствующей материалистической парадигме *Демокрита* и постулирует возможность познания механизмов когнитивных функций исключительно через прямое измерение режимов работы нейрональных модулей, отдельных нейронов и их молекулярных элементов, а также через математическое моделирование этих процессов, протекающих на нано- и микроуровнях. По существу, мысль здесь является таким же порождением работы мозга, как желчь — печени.

Нетрудно заметить, что первое направление является типичным примером «гуманитарного» обсуждения проблемы, тогда как второе и третье (при адекватной, естественно, постановке вопроса) в полной мере опираются на известный девиз *Галилео Галилея*: «Задача исследователя — измерить всё, что измеряемо, и сделать измеряемым всё остальное».

Путеводитель по литературе. Базовая классификация направлений когнитивной науки достаточно подробно анализируется в публикациях [1] и [2]. Основные положения теории функциональных систем на академическом и популярном уровнях представлены в прижизненных монографиях *П. К. Анохина* [3, 4]. Образцы творчества ряда ведущих представителей современной когнитивной науки можно почерпнуть из публикаций [5–27].

Микрогlossарий

В данной лекции мы будем использовать ряд рабочих определений, облегчающих понимание наших положений:

- ЗНАНИЕ — результат ИЗМЕРЕНИЯ, то есть сравнения конкретного параметра исследуемого объекта с эталоном;
- МИФ — полная выдумка, основанная исключительно на МНЕНИЯХ авторитетов (не обязательно криминальных);

- ЛЕГЕНДА — гибрид ЗНАНИЯ и МИФА, то есть приукрашенное, неполное и поэтому искажённое знание;
- МОДЕЛЬ (для нашей аудитории тема притягательная и заслуживающая особого обсуждения), в целом, — это отображение значимых свойств одного объекта в свойствах другого объекта, например:
- ХОРОШАЯ МОДЕЛЬ — ЛЕГЕНДА, основанная на ограниченных ЗНАНИЯХ об объекте, и призванная указать, где конкретно ЗНАНИЯ заменены МИФОМ (путеводитель для дальнейшего поиска ЗНАНИЙ);
- ПЛОХАЯ МОДЕЛЬ — хорошо формализованный и потому особо убедительный МИФ (вещь в себе);
- ИДЕАЛЬНАЯ МОДЕЛЬ — исчерпывающее формализованное описание объекта исследования (не бывает).
- ИНФОРМАЦИОННЫЙ ОБРАЗ — отображение объектов и событий в пространстве признаков.
- ИНФОРМАЦИЯ — мера упорядоченности ОБРАЗОВ (не путать с энтропией!).
- КОДИРОВАТЬ информацию — записывать её по ПРАВИЛАМ.
- СОЗНАНИЕ — механизм СОГЛАСОВАНИЯ индивидуального и коллективного ОПЫТА с использованием внешних носителей информации.

Проблема 1 — подмена понятий

Казалось бы, второе и третье направления когнитивных исследований вполне удовлетворительно ложатся в русло естественнонаучного подхода. Однако при анализе бесчисленных публикаций, выполненных в рамках третьего направления, возникает, мягко говоря, недоумение. На максимально достижимых для каждого периода развития науки методических рубежах детально исследуются электрические и химические процессы в живых системах (начиная от ионного, молекулярного и субклеточного уровней и заканчивая системным и популяционным), но обсуждаются при этом сугубо информационные проблемы. Насколько обоснованной является такая экстраполяция? Насколько адекватны используемые (повторим — самые передовые) методы задаче изучения информационных процессов? Попытаемся ответить на эти вопросы в рамках, естественно, субъективной авторской модели проблемы.

Прежде всего: насколько физико-химическая методология способна решать информационные вопросы? Речь не обо всем известной проблеме эмерджентности (здесь всё очевидно: биологическое никак не сводится к сумме физического и химического — как бы это ни было досадно физикам и химикам; соответственно, информационное — никоим образом не сумма биологического, физического и химического), а о проблеме информации как таковой. Хорошо известно, что информация вопиющим образом не желает подчиняться законам материального мира. Так, категорически не складываются у нее отношения с законом сохранения материи: и появляется информация неведь откуда, и исчезает неведомо куда (рукописи, вопреки мнению классика, горят, и очень жарко горят — вспомните пожар Александрийской библиотеки). Информация не существует без материального носителя: она обязательно должна быть на чем-то записана (не исключено, конечно, что мы просто не знаем фактов, подтверждающих обратное, и понятия «души», «информационного поля планеты» и т. д. не столь уж и наивны, но на сегодняшний день эта альтернативная гипотеза не представляется перспективной). С другой стороны, для информации безразличен характер материального носителя, будь то папирус, береста, бумага, нейронная сеть или магнитный диск. Еще одна особенность информации — необходимость наличия субъекта, способного ее считать с носителя и зависимость от этого субъекта. В самом деле, информация абсолютно лишена смысла при отсутствии у субъекта необходимых знаний о кодах, с помощью которых она записана (современные студенты — «жертвы ЕГЭ» — в полной мере подтверждают эту закономерность). При всей спорности «компьютерной метафоры» в данном случае она весьма показательна: даже самому начинающему юзеру не придёт в голову смешивать «железо» и программное обеспечение в одной задаче.

Тогда на каком основании мы переносим наши знания (очень поверхностные пока, надо признать) о технических (электрических, химических) характеристиках «живых компьютеров» на их информационные, «программные» свойства?! — Да, наши представления о физическом (электрическом) и химическом устройстве нервной системы за прошедшие с начала её систематического естественно-научного исследования два столетия существенно расширились. Сегодня нам известно множество вариантов электрических процессов в живых системах: мембранные потенциалы (ПП, ПД, МПКП, ВПСР, ТПСР и др.), суммарные потенциалы (ВП, ССП, медленные волны и др.), ритмические процессы (например, в ЭЭГ, ЭНМГ или ЭКГ) и многие другие. В некоторой степени мы продвинулись в по-

нимании молекулярных и ионных механизмов этих процессов: вспомним, хотя бы, как несколько десятилетий настройки модели Ходжкина-Хаксли привели к обнаружению целого «зоопарка ионных каналов» на мембране нейрона, количество видов которых уже перевалило за полторы сотни. В 60–70 годах прошлого столетия стало очевидным, что глиальные клетки выполняют не только механическую, иммунную и трофическую функции, но и участвуют в электрических процессах в нервной системе. Многие тысячи работ посвящены описанию и исследованию характеристик поздних ответов ССП и гамма-ритма ЭЭГ. Примеров можно привести множество. Однако имеем ли мы право на основании этих работ судить о механизмах переработки информации в живых системах? Можем ли мы, измеряя электрические параметры микросхем нашего ноутбука, обсуждать хотя бы, какие программы на нём установлены, и которые из них в данный момент активированы? – Хотелось бы напомнить чрезвычайно эпатававшее полвека назад электрофизиологическое сообщество предположение *П. К. Анохина* о том, что импульсная активность нейронов — не более чем внешний отблеск тех сложных метаболических процессов, которые сопровождают (но не обеспечивают) процесс обработки информации. Или любимую фразу одного из ведущих в мире нейрофизиологов *Александра Яковлевича Каплана*: «ЭЭГ — не более чем шум от паровоза». Необходимо подчеркнуть, что речь не идёт о принижении огромного значения современных электрофизиологических исследований для понимания тонких механизмов работы нервной системы; речь — о вольной или невольной подмене понятий, потому что измерение электрических параметров на субклеточном, клеточном и органном (нервная система в целом или её модули) уровнях не есть исследование информационных процессов в этой нервной системе.

Не лучше обстоит дело с химическими параметрами нервной системы. В бесчисленном многообразии химических реакций, протекающих в живых организмах, для начала необходимо выделить те, которые имеют прямое отношение к переработке информации. Чуть менее полвека назад академиком АМН СССР *Игорем Петровичем Ашмариним* такая попытка была концептуально реализована: в научный лексикон вошло понятие *информонов*, то есть химических соединений, участвующих в передаче информации в живых системах. В этот класс вошли такие вещества, как:

- нуклеиновые кислоты: хранители и переносчики наследственной и, не в меньшей мере, прижизненной информации (ДНК, РНК — как «молекулы памяти»);

- циклические нуклеотиды, некоторые белки и сложные липиды: внутриклеточные переносчики информации (цАМФ, цГМФ, кальмодулин, инозитолтрифосфат, c-fos, NO и др. — так называемые вторые мессенжеры);
- некоторые аминокислоты и их производные — биогенные амины, многие олигопептиды и др.: межклеточные синаптические переносчики информации (норадреналин, серотонин, глицин, ГАМК, мет- и лей-энкефалины, кортиколиберин, субстанция Р и мн. др. — более 4000 — медиаторы, или нейротрансмиттеры);
- производные некоторых аминокислот, многие белки и пептиды, стероиды: переносчики информации между клетками дистантно (инсулин, кортизол, тестостерон, эстрадиол, АКТГ, адреналин и мн. др. — гормоны);
- терпены: переносчики информации между особями одного вида (феромоны), и т. д., и т. п.

Список видов и разновидностей информонов очень обширен и перманентно пополняется, что, безусловно, является позитивным явлением, однако вновь приходится признать, что связь между описанием их физико-химических свойств и механизмами переработки информации весьма и весьма опосредованная.

Таким образом, хотим мы того или нет, но мы коллективно впадаем в один из смертных научных грехов, пестуя, лелея и холя не более чем легенду, и подменяя одни понятия другими: активно и успешно исследуя «материальную часть живого компьютера», мы заявляем об изучении информационных закономерностей. Если бы этот грех был единственным!..

Путеводитель по литературе. Проблема взаимосвязи «тела» и «души», в частности, обсуждаются в [21] [23]. О том, как «шум от паровоза» можно превратить в информацию для управления материальными объектами, описано, например, в [28]. Понятие *информонов* присутствует во многих трудах *И. П. Ашмарина* и его последователей, например в [29].

Проблема 2 — мифотворчество

Вторая проблема выглядит куда более устрашающей. Во введении мы её уже обозначили: в связи с тем, что в мультидисциплинарной когнитивной науке, в условиях узкой специализации, невозможно быть знатоком всех

научных направлений, мы (чаще всего без злого умысла) с лёгкостью подменяем знания мнениями или, точнее, мифами. Ещё раз подчеркнём: речь не о гипотезах или моделях, без которых процесс познания, в лучшем случае, неконструктивен. Проблема в том, что с течением времени многие рабочие гипотезы, объективно способствовавшие прогрессу естественнонаучного познания, имеют тенденцию к «бронзовению», превращаясь в красивые легенды, в памятники самим себе и становясь помехой на пути дальнейшего развития науки. Ещё трагичнее ситуация, когда такого рода гипотезы изначально рождены из сугубо умозрительных, зачастую идеологически ангажированных построений: такого рода «теории» в итоге становятся мифами, не имеющими под собой реальных доказательств, и, в силу своей принципиальной ущербности, — особо агрессивными.

Позволим себе проиллюстрировать эти, не претендующие на оригинальность, мысли некоторыми примерами, напрямую связанными с темой информации в живых системах. Начнём именно с мифов, учитывая их особую вредоносность.

Путеводитель по литературе. Сомнительность, мягко говоря, многих наших мультидисциплинарных конструктов обсуждается перманентно, например, [8, 30, 31].

Миф 1

«Сознание есть присущее только человеку свойство активного отражения действительности». Это определение с небольшими вариациями кочует по учебной литературе на протяжении многих десятилетий. Если мы вспомним, что всякое определение — уже модель, попробуем выяснить, что же это за модель: знание, легенда или миф. То, что это не может быть основано на знаниях, совершенно очевидно: для доказательства подобного утверждения необходимо, например, проверить других животных на наличие или отсутствие этого самого сознания, что само по себе труднодостижимо из-за отсутствия более или менее консенсусного определения данного загадочного явления природы. В самом деле, попытки формализовать сознание через язык («вербализую — значит, сознаю») не выглядят состоятельными, потому что мы сегодня уже имеем множество примеров невербализованного использования понятий и невербализованного мышления. Далеко не всегда «вербализовать» значит «осознавать». Кроме того, многочисленные сегодня доказательства наличия у различных животных — по крайней мере, высокоорганизованных — собственных языков (последняя сенсация: дель-

фины дают своим детёнышам имена собственные, с которыми те живут всю жизнь!) не способствуют усилению этой позиции.

Ещё одним ударом по столь любимому психологами и философами мифу стало возникновение на Земле на границе двух тысячелетий целого «стада» (несколько десятков особей!) животных разных видов, способных вести весьма осмысленные, эмоционально и интеллектуально насыщенные беседы с человеком. Напомним, что семь лет назад действительно прогрессивное человечество с должной скорбью откликнулось на многочисленные некрологи, в которых сообщалось, что 30 октября 2007 года в Вашингтоне (США, округ Колумбия) на 42 году жизни скончалась первая в истории человечества обезьяна, установившая прямой вербальный контакт с человеком. Шимпанзе Уошо (Washoe) к концу своей более чем продолжительной для диких приматов жизни активно пользовалась словарём, включающим около 350 слов. Сегодня это далеко не предел для наших ближайших родственников: лидер проекта «Животное-переводчик» шимпанзе-бонобо Кэнзи свободно использует более 1000 слов, что уже вполне сопоставимо с лингвистическим ресурсом современных студентов. В компании «говорящих обезьян» есть не только представители двух видов шимпанзе (Bonobo и Troglodites), но и орангутаны (например, Чатек) и гориллы (ещё одна звезда проекта — Коко). Более того, известный орнитолог *Ирэн Пеппенберг*, используя оригинальную конкурентную методику обучения, смогла добиться разумного — именно разумного! — использования английского лексикона даже от попугаев.

Таким образом, вербализация с очевидностью выпадает из списка различий человека и других животных. Придётся или признать этот критерий не имеющим отношение к сознанию, или принять как данность наличие сознания и у других животных.

Дальше — больше. Вслед за языком (именно языком, а не сигнализацией!) рухнули такие мощные редуты мифа о нашей исключительности, как трудовая деятельность (животные изготавливают орудия труда, в том числе, впрямь, и могут осуществлять бартерные операции, очень напоминающие те, через которые наша страна прошла совсем недавно), социум со всеми его атрибутами, включая сменяемость иерархов и разделение труда, «культурные навыки», узнавание себя в зеркале, абстрактное и категоричное мышление, способность к экстраполяции, устный счёт и мн. др.

Таким образом, первый столп общераспространённого мифа оказался откровенно трухлявым: или сознание — это что-то другое, или надо признать, что оно не является прерогативой исключительно человека. Со вто-

рой опорой ситуация сложнее.

Путеводитель по литературе: по вопросу об уникальности человека как вида можно познакомиться с очень разными позициями — [8, 9, 30, 32–34].

Легенда 1

Да, «ленинская теория отражения» долгие десятилетия была для отечественных психологов, философов, нейробиологов, психофизиологов «единственно правильной, потому что она была единственно верной». Вину за железобетонность этого постулата сегодня принято валить на *В. И. Ленина*, хотя в данном конкретном случае он ни о чем плохом не думал. Просто, будучи человеком хорошо образованным и любознательным, Владимир Ильич живо заинтересовался квазикартезианством в целом и рефлекторным учением, в частности, и честно (возможно, со словарём) перевёл: «рефлектор — отражатель», «рефлекс — отражение». И пошло это кривое зеркало бродить по страницам статей, монографий, учебников и диссертаций, обеспечивая эффективный вынос мозга и его функций за пределы естественнонаучного знания. . .

Казалось бы, в XXI веке достаточно оснований хотя бы задуматься о смысловом наполнении этого взлёта философской мысли, но рефлекторное определение сознания продолжает тиражироваться, и далеко не только в нашей стране. Эта легенда, даже будучи деидеологизированной, что как раз вполне естественно для поиска знаний, продолжает властвовать умами многих серьёзных исследователей. И для этого есть весомые основания.

Едва ли найдётся мало-мальски образованный человек, который будет отрицать рефлексы как таковые. Этот древний и примитивный механизм сопровождает весь процесс эволюции, начиная от простейших. Более того, практически на всех уровнях эволюции сегодня обнаружены условные рефлексы, что противоречит представлениям *И. П. Павлова* о необходимой сохранности коры больших полушарий головного мозга для формирования условных рефлексов (какая уж тут кора, если у плоских червей, например, нет не только больших полушарий, но и головного мозга, да и вообще мозга как такового — одни ганглии). Однако в целом особых оснований для сомнений в адекватности наших представлений о рефлексах не видно: это не легенда и не миф, а вполне реальные знания.

Тогда в чём проблема? — Дело в том, что линейная, по определению, структура рефлекторных актов противоречит тем скоростным режимам,

которые мы демонстрируем при решении сложных поведенческих задач. Сегодня, когда мы научились с достаточно высокой точностью мерить временные параметры различных поведенческих реакций (а рефлекс — это сугубая реакция), к вящему удивлению обнаружилась невозможность теоретически уложить даже достаточно простые поведенческие акты в несколько десятков миллисекунд, регистрируемых в реальности: нервная система — чрезвычайно медленный «компьютер» (на каждом синапсе идёт потеря, как минимум, 5 миллисекунд, а моносинаптических рефлексов у нас — по пальцам перечесть, да и то они не совсем «моно-»: в том же коленном рефлексе один синапс — центральный, а второй — нервно-мышечный). Что же тогда говорить о сложных актах сознания?! — Например, разнообразные эксперименты с применением, прежде всего, ритмической стимуляции позволяют зафиксировать нижнюю границу «окна» осознания примерно на уровне 30 мс: если второй сигнал подаётся раньше этого интервала, он или не распознаётся, или вытесняет первый.

Именно попытки объяснить сложные психические (и поведенческие — как внешнее проявление психики) акты с позиций рефлекторной теории привели к низведению вполне доброкачественного многовекового знания до уровня, в лучшем случае, легенды, то есть полуправды.

Между тем, еще в 30-х годах прошлого века родилась альтернативная теория, по мере развития измерительных методов получавшая всё больше объективных доказательств. Созданная *П. К. Анохиным*, его теория функциональных систем успешно пережила периоды жесточайшей критики и в последние десятилетия стала стратегической методологией исследования психики и поведения.

Принципиальные отличия теории функциональных систем от рефлекторного («отражательного») подхода заключаются в следующем:

- если согласно рефлекторной парадигме поведение формируется в ответ на внешние воздействия (стимул — реакция), то основой поведения при системно-функциональном подходе является целенаправленная активность организма, основанная на моделях желаемого результата, формируемых в процессе деятельности или извлекаемых из памяти;
- рефлекторная концепция предполагает линейное распространение возбуждения (очевидную неэффективность и нереальность этого механизма мы уже затрагивали), альтернативная же теория постулирует синхронную активность элементов системы (принципиально важ-

ным является сосуществование нескольких активных функциональных систем в один и тот же момент времени);

- концептуальным фундаментом рефлекторной теории является локализационизм (желающих отсылаем к френологическим картам, где они успешно обнаружат центры радости, веры, надежды, любви к царю-батюшке или рок-музыке и т. п.), принципом же теории функциональных систем является распределённость элементов системы.

Можно резюмировать, что в русле рефлекторной теории основой для поведенческих актов, включая осознанные, являются события внешнего мира (стимулы), запускающие специализированные реакции на них. При использовании функционально-системного подхода источником поведенческой активности становятся разноуровневые потребности самого субъекта, реализующиеся благодаря наличию персонального опыта и «навигирующих» сигналов из внешнего мира (например, в зоопсихологии давно введено понятие релизера, обозначающее простой сигнал о наличии возможности удовлетворения конкретной потребности). Да простят нас специалисты по робототехнике, но рефлекторный механизм, по сути, описывает поведение жёстко алгоритмизированного робота, тогда как в теории функциональной системы ясно просматриваются мотивы нейросетевого самообучения. Самообучения, которое осуществляется с помощью циклических механизмов, обеспечивающих постоянное сопоставление желаемого (спрогнозированного) результата и текущего — акцептора результата действия и параметров результата действия, соответственно, по *П. К. Анохину*. Принципиально: наш мозг не реагирует, а прогнозирует.

Но почему же всё-таки мы сочли необходимым охарактеризовать второй компонент необоснованно популярного определения сознания именно как легенду? — На наш взгляд, рефлекторный механизм является одним из ряда инструментов, обеспечивающих формирование поведения — и это не миф и не легенда, а знание. Но предпринимавшиеся на протяжении не одного столетия попытки представить этот частный примитивный линейный механизм в качестве принципа (главного, а порой и единственного) организации психики, поведения и даже сознания низводят имеющиеся знания именно до уровня легенды, причём легенды малоправдоподобной.

Возникает естественный вопрос: а есть ли у авторов конкретные предложения по определению сознания? — Хотелось бы напомнить, что на одной из недавних конференций по нейроинформатике эта проблема была вынесена на отдельную дискуссию, что не привело к желательному ре-

зультату. С одной стороны, это вполне объяснимо, потому что все мы впервые столкнулись с задачей, живо напоминающей циклическую ссылку: с помощью сознания определить, что такое сознание. С другой стороны, если уж замахиваться на исследование феномена столь глобального уровня (а все программы формата «Brain and Mind» претендуют именно на это), желательно иметь хотя бы рабочее определение, от которого можно отталкиваться и которое можно корректировать по мере накопления новых знаний. Не претендуя на особую оригинальность, авторы готовы предложить такой, достаточно локальный вариант: «Сознание — механизм согласования индивидуального и коллективного опыта с использованием внешних носителей информации». Заявленная тема лекции не позволяет нам углубиться в детальное рассмотрение данного предложения, однако рекомендуем читателям поискать аргументы для возможного расширения граничных условий предлагаемой модели.

Здесь же предлагаем рассмотреть ещё несколько расхожих мифов и легенд.

Путеводитель по литературе. Утверждение альтернативной рефлекторному подходу теории предсказания (прогнозирования) — самая обсуждаемая сегодня в когнитивной науке тема. Предлагаем всего несколько работ из огромного списка: [3–5, 8, 12, 14, 18, 21, 23, 26, 31, 35–38].

Мифы 2 и 3

Ещё одним поучительным примером мифотворчества является до сего дня присутствующее во многих отечественных и некоторых зарубежных учебниках и монографиях утверждение о существовании специфичных кожных и висцеральных рецепторов тепла, холода и боли (миф №2) и, соответственно, о таких специфических сенсорных модальностях, как боль и терморцепция (миф №3).

В основе этих двух мифов лежит *предположение* (а точнее, мечта) известного австрийского философа и естествоиспытателя конца XIX века барона *Максимилиана Рупперта Франца фон Фрея*, находившегося под большим влиянием модной тогда теории специфической психической энергии органов чувств *Иоганнеса Мюллера*. Суть его размышлений сводилась к тому, что, если бы существовали специализированные датчики, рецептирующие тепловые, холодовые и болевые стимулы, это существенно упростило бы объяснение способности животных (включая человека) воспринимать различные температуры и повреждающие воздействия. Интересно,

что задолго до этого, в том же XIX веке основатель психофизики и жестокый критик теории специфической энергии органов чувств *Эрнст Генрих Вебер* гениальными по простоте экспериментами полностью опроверг эту ещё не родившуюся наивную гипотезу. Не можем не напомнить один из самых демонстративных опытов.

Берутся три таза, в левый из которых наливается ледяная вода, в правый — горячая, а в средний — комнатной температуры. Руки испытуемого погружаются, соответственно, в крайние тазы и после непродолжительного периода адаптации перемещаются в средний. Гипотетические термометры кожи наших рук дают «абсолютно точный и объективный» результат: в среднем тазе вода фантастическим образом стратифицирована по горизонтали — левая рука сообщает нам, что она горячая, а правая — холодная.

Остаётся только изумляться прихотливости человеческой психики — в течение XX столетия изначально сомнительная гипотеза специфичности фон Фрея обрела статус теории. Этот путь должен привлечь внимание лингвистов: первые осторожные ссылки «как предполагал великий фон Фрей» постепенно эволюционировали в «как сказал», «как указал» и, наконец, «как доказал»!

Симптоматично, что практически одновременно, тоже в конце XIX века появилась альтернативная теория, одним из основателей которой принято называть крепкого немецкого физиолога *Адольфа Гольдшейдера*. Это была теория интенсивности, постулировавшая принципиальную бесполезность узкой специализации рецепторного аппарата и, по сути, предлагавшая принцип интегративного кодирования сенсорных сигналов от механорецепторов. Несмотря на значительную (особенно по сравнению с теорией специфичности) базу экспериментальных доказательств, теория интенсивности в XX веке была оттеснена на второй план.

Понадобилось почти целое столетие (!), чтобы исходно умозрительный и курьезный миф, рождённый *фон Фреем*, занял подобающее ему место в истории науки. До сих пор в некоторой учебной литературе мира можно увидеть удивительное раздвоение авторских личностей: в главах о центральной перцепции болевая и температурная чувствительность отнесены к «особым ощущениям» (вместе с жаждой, сексом и голодом) на основании отсутствия специализированного периферического рецепторного аппарата, а в разделах, посвящённых именно периферической сенсорике, осторожно описываются некие гипотетические термо- и ноцицепторы, правда, с аккуратным упоминанием, что их пока ещё не нашли, но в ближайшее

время обязательно найдут.

Между тем, накапливалось множество данных, жёстко отторгающих теорию специфичности. Например, в последней трети XX века замечательным ленинградским нейрофизиологом *Ефимом Михайловичем Цирульниковым* в методически очень точных экспериментах было показано, что при изменении интенсивности узко сфокусированного ультразвукового воздействия *на одну и ту же точку кожи* можно получить весь спектр субъективных ощущений — от лёгкого прикосновения до боли.

С гордостью нужно подчеркнуть, что одним из немногих исследователей, на протяжении более чем полувека продолжавших искать неопровержимые экспериментальные доказательства теории интегративного кодирования сенсорных сигналов, был наш соотечественник, основатель нижегородской нейробиологической школы, выдающийся нейрофизиолог *Александр Васильевич Зевеке*. Ему и его ученикам, применяя наиболее эффективные на тот период электрофизиологические, биохимические методы и математическое моделирование, удалось установить, что:

- формирование специфических ощущений (тепла, холода, прикосновения, давления, боли. . .) обусловлено специфическим рисунком распределения импульсной активности в волокнах нервов, передающих в мозг информацию *от различных* (инкапсулированных и неинкапсулированных) *механорецепторов*, распределённых по всей толще кожи. По существу, это главный результат, демонстрирующий принцип интегративного кодирования в каждом анализаторе, что вполне коррелирует с подобными механизмами, строго доказанными сегодня в приложении к зрительному и обонятельному сенсорным входам;
- пресловутые («пресловутые» — потому что на них любят ссылаться сторонники мифа о специфичности рецепторов) тепловые, холодовые и болевые точки на коже, оказывается, имеют обыкновение со временем свободно перемещаться на достаточно большие расстояния (на несколько миллиметров) — странное поведение для инкапсулированных и неинкапсулированных кожных датчиков, не находите?
- отсутствие в коже гипотетических термо-, баро-, вибро-, ноци- и других «специализированных» рецепторов в полной мере компенсируется пространственным распределением в толще кожи и характерными временами срабатывания механорецепторов;
- специфичность и характер активации различных механорецепторов обусловлены, прежде всего, высокой механолабильностью коллаге-

нового матрикса кожи. Именно этот уникальный по своим физико-химическим свойствам белок выступает в роли своеобразного ретранслятора, перекодирующего информацию о различных механических, температурных и химических воздействиях на кожу в характеристики рецепторных потенциалов расположенных в зоне воздействия механорецепторов.

У профессора *А. В. Зевеке* на доказательство никчёмности очевидного мифа ушла вся его длинная, героическая (он ушёл на вторую мировую войну прямо со студенческой скамьи) и счастливая жизнь, и нам остаётся только радоваться, что в последние годы он успел увидеть поднимающуюся волну публикаций в зарубежных журналах, полностью подтверждающих его правоту. Да, Земля, как выяснилось, всё-таки вертится. Но возникает недоумение: как могло случиться, что очевидное мифотворчество многие десятилетия могло заполнять страницы очень серьёзных и очень импактных (как мы знаем, эти две характеристики часто не совпадают) журналов? — Одна из версий, как ни странно, отсылает к пресловутой «бритве Оккама». Когда некоему сложному явлению удаётся найти простое объяснение, оно быстро приобретает популярность, а «доказательства», к сожалению, чаще всего рождаются из вольных трактовок вполне доброкачественных экспериментальных данных. Модель берёт верх над фактами. В принципе, это закономерно: в ряде работ крупнейшего психолога нашей страны *Виктора Михайловича Аллахвердова* убедительно продемонстрирована устойчивость и консервативность наших моделей, независимо от уровня их сложности и весомости противоречащих этим моделям аргументов.

Целое столетие на страницах журналов систематически появлялись сенсационные публикации об обнаружении термо- и, особенно, ноцицепторов. Спустя несколько лет каждый раз выяснялось, что в план эксперимента вкрались методические неточности и поэтому результаты нельзя считать окончательными, после чего очередной автор сенсации бесследно исчезал с научного поля, однако ссылки на его работы начинали размножаться. Самая распространённая методическая ошибка, повторявшаяся с завидным упорством — неаккуратный контроль. В публикации сообщалось, что обнаружены специализированные рецепторы, возбуждающиеся исключительно на, например, повреждающее воздействие. Вот они — долгожданные ноцицепторы! Проблема боли решена! Проходит 2–3 года, и выясняется, что эти же рецепторы с успехом возбуждаются и при давлении, и при дунове-

нии, и при охлаждении. Конфуз. . . Последний писк уходящего мифа (уже в нашем веке) — недавние работы с ментол-чувствительными и капсаицин-чувствительными ионными каналами. Публикации подавались как последнее и решающее доказательство правоты теории фон Фрея (авторов даже пытались номинировать на Нобелевскую премию), а оказались, по сути, последней каплей, перевернувшей износившуюся лодку. Достаточно быстро выяснилось, что, во-первых, использованные в экспериментах концентрации тест-веществ превышают все мыслимые и немыслимые физиологические нормы, а во-вторых, эти неспецифические Ca^{2+} -ионофоры обнаруживаются не только и не столько на мембранах предполагаемых тепловых и холодных рецепторов, сколько на мембранах клеток, к нервной системе отношения вообще не имеющих (например, в соединительной ткани).

Чтобы закрыть эту, ставшую одиозной, тему, предлагаем читателям самостоятельно ответить на несколько вопросов:

- 1) Может ли боль возникать *при отсутствии повреждения*?
- 2) Могут ли быть ситуации, когда *боль не возникает при наличии повреждения*?
- 3) Существуют ли *периферические анальгетики*, то есть лекарственные препараты, подавляющие исключительно болевую чувствительность, но не затрагивающие остальные ощущения (просим не путать с анестетиками — как раз лекарствами, блокирующими всякую чувствительность)?
- 4) Наконец, самое важное: можете ли Вы найти такую *физическую реальность*, как боль (по аналогии со светом, звуком, давлением)? Если можете, укажите, в каких единицах она измеряется.

Если на первые два вопроса Вы ответили положительно, а на последние два — отрицательно, значит, обсуждение 2 и 3 мифов прошло не зря. В завершение скажем, что сегодня боль принято рассматривать как типичный для циклических информационных систем пример обработки сигнала о рассогласовании между предсказанным паттерном (эталонным «образом тела» или «моделью тела» — по выражению *Евгения Николаевича Соколова*) и реальным паттерном от повреждённого участка тела. Тогда действие анальгетиков (как экзогенных, то есть принимаемых нами лекарств, так и эндогенных, например, эндорфинов) основывается на подавлении этого сигнала о рассогласовании. Соответственно, «тепло» и «холод» являются результатом центральной оценки динамики внутрикожного температурно-

го градиента, осуществляемой по рисунку импульсного паттерна от кожных механорецепторов.

Путеводитель по литературе. Этот, до недавнего времени спорный, вопрос широко обсуждается в современной литературе: [36, 38–52]. Хотелось бы обратить внимание читателей на работы профессора А. В. Зевеке и его учеников [39–41, 43–45, 51], сумевших отстоять правоту своих научных принципов в непростых условиях прессы умозрительной модели.

Миф 4 — очень популярный

Кто из нас не читал, что правое полушарие у человека является эмоционально-чувственным, а левое — абстрактно-логическим, и, соответственно, человек ещё до рождения обречён быть физиком или лириком?

Этот миф, родившийся из вполне доброкачественного знания, стал приобретать особо злобный характер, потому что проявил способность ломать человеческие судьбы. В целом ряде «развитых» стран появилась тенденция тестировать детей «на полушарность» и, исходя из выявленного доминирования правого или левого полушария, определять их в классы с физико-математическим или гуманитарным «уклоном». Возможно, в такой ранней специализации и не было бы ничего страшного, если бы жёсткая предрасположенность к определённому кругу будущих профессий не была неправдой.

Очень кратко проанализируем ситуацию. В 1981 году замечательному нейрофизиологу и нейропсихологу *Роджеру Волкотту Сперри* была присуждена Нобелевская премия за открытие межполушарной функциональной асимметрии. Именно после его работ и появилось утверждение, с которого мы начали обсуждения данного мифа. Так что же, это ещё один пример некомпетентности нобелевского комитета (между прочим, это распространённое мнение в среде практикующих нейропсихологов)? — Ничего подобного! *Роджер Сперри* был выдающимся и очень разносторонним исследователем. И свою позицию он основывал и на экспериментальных данных (полное рассечение у животных мозолистого тела — даже не кабели, а толстенной шины, обеспечивающей коммутацию левого и правого больших полушарий), и на клиническом материале. Нетрудно догадаться, что последнее представлялось наиболее важным, что и сыграло в итоге злую шутку с трактовкой концепции Сперри.

Дело в том, что в клинике *Р. Сперри* работал с очень эксклюзивным «материалом» — больными одной из наиболее тяжёлых форм эпилепсии,

которым для хотя бы частичного облегчения состояния была проведена операция тотальной каллозотомии (*Corpus callosum* — это и есть мозолистое тело). Ещё раз повторим: это были изначально неврологически очень тяжёлые пациенты, которым была проведена калечащая операция (кстати, у некоторых из «испытуемых» Сперри, кроме мозолистого тела, были перерезаны и вообще все комиссуры между полушариями, включая зрительную хиазму). Вот на этих инвалидах, а также на животных со сходными операциями и были получены главные результаты. И получены вполне аккуратно, что бы там ни говорили в дальнейшем.

Так что винить *Р. Сперри* в научной недобросовестности нет никаких оснований. А вот далекоидущие выводы — это уже результат мифотворчества многочисленных последователей. Казалось бы, совершенно очевидная мысль о недопустимости переноса этих знаний на здоровых людей почему-то были проигнорирована. В результате — нагромождение сомнительных теорий и, что наиболее грустно, вполне практических оргвыводов.

Да, действительно, функциональная межполушарная асимметрия как феномен существует. Однако это вовсе не означает, что определение полушарности субъекта — диагноз или приговор. За прошедшие с момента открытия *Р. Сперри* десятилетия выяснилось, что у здоровых людей текущее доминирование одного из полушарий может меняться в зависимости от контекста, что называется — под задачу; что право- или леворукость (и тем более — -ногость) вовсе не являются признаком, соответственно, лево- или правополушарности; что при стрессе межполушарные различия вообще сглаживаются; что и аффективные (то есть, эмоции), и когнитивные особенности субъекта являются интегральной функцией обоих полушарий и т. д.

По существу, мы снова видим пример того, как исходно вполне достоверные знания в результате искажённых трактовок и полёта фантазии становятся не более чем мифом, препятствующим дальнейшему развитию знаний.

Путеводитель по литературе. Эволюция эмпирического знания по проблеме функциональной межполушарной асимметрии и практических приложений к этой проблеме легко выстраивается даже на основании некоторых из следующих публикаций: [44, 53–58].

Легенда 2

Приближаясь к завершению нашей лекции, не можем не остановиться ещё на одном принципиально важном вопросе. Речь пойдёт о стрессе. Это понятие, введённое в мировую науку одним из величайших мыслителей современности *Гансом Селье* ещё в 30-е годы XX века, достаточно быстро вошло в повседневный обиход. С одной стороны, это свидетельство практической значимости данного понятия для каждого из нас, с другой, — это реальная угроза размывания понятия и опасность для самого существования теории стресса.

На данном примере мы хотим показать, как цельная теоретическая модель, основанная на конкретных и надёжных знаниях, по мере дальнейшего развития этих знаний может не только утрачивать свою цельность и логичность, но и всё более превращаться в легенду, то есть, напомним, полуправду.

К 80-м годам прошлого века теория стресса стала подвергаться всё более жестокой критике. Всё громче стали звучать мнения о том, что стресса как явления не существует, что вся эта теория не более чем выдумка. С сожалением надо признать, что в таком падении престижа концепции была и доля вины самого автора. Многие критики теории *Г. Селье* постоянно ссылались (и ссылаются до сих пор, надо заметить) на цитату из одной его поздней публикации, согласно которой «стресс есть неспецифический ответ организма *на любое* внешнее воздействие». В таком случае, — вполне справедливо отмечали критики — вся жизнь есть стресс, а всю жизнь исследовать невозможно, то есть это явление непознаваемо и, следовательно, серьёзной наукой рассматриваться не должно. Курьёзный факт: «Вся жизнь есть стресс» — стало на Западе одним из очень распространённых рекламных слоганов в аптечной сети. Нетрудно догадаться, что речь идёт о рекламе транквилизаторов.

Самое удивительное, что если не выдёргивать фразу из контекста, становится понятным, что *Г. Селье* имел ввиду совсем не этот смысл. Он пытался объяснить, что в каждом нашем специфическом действии обязательно присутствует неспецифический, общий для любой активности, компонент. Физиологи нас поймут: точно так же в каждом потенциале действия обязательно присутствует локальный ответ.

К сожалению, недостаточно аккуратное обращение выдающегося эндокринолога с терминами нередко давало повод для достаточно вольных трактовок его высказываний и, как следствие, искажения модели. В каче-

стве примера можно привести, пожалуй, самую разрушительную оговорку великого учёного: развёртывая понятие стресса, он применил уточняющее, как ему казалось, определение — «общий (или неспецифический) адаптационный синдром». Безусловно, стресс — это, в том числе, синдром, то есть комплекс симптомов — достаточно вспомнить классическую «триаду Селье», в которую входят: гипертрофия надпочечников, инволюция тимуса и язвообразование в желудочно-кишечном тракте. Безусловно, стресс неспецифичен, потому что на самые разные повреждающие воздействия ответ организма, по принципиальным параметрам, будет одинаковым. Но вот «адаптация»? . . . — Это слово переводится на русский язык как приспособление или привыкание. Других вариантов его понимания нет. Задумайтесь: можно ли привыкнуть или приспособиться к тому, что тебя убивают (не будем сейчас отвлекаться на ментальность нашего этноса)?! А ведь стресс — это, прежде всего, ответ на повреждение или его угрозу. Можно понять, откуда этот термин вплёлся в теорию стресса: в 30-е годы прошлого века чрезвычайной популярностью в научном мире пользовались очаровывавшие своей логикой и методическим остроумием эксперименты замечательного американского физиолога *Уолтера Кеннона*, главным направлением работы которого было как раз исследование механизмов адаптационных процессов. Но этот термин никоим образом не может характеризовать процессы, направленные не на приспособление, а на противодействие. И для такого рода процессов было точное определение — защита. Защита, предполагающая минимизацию информационных потоков (для противостояния нужно гораздо меньше знаний о ситуации, чем для приспособления), предполагающая изменения не только на функциональном, но и на структурном уровне (ещё раз вспомним гипертрофию надпочечников), предполагающая «принесение жертвы» (а теперь вспомним инволюцию тимуса и язвы желудка и тонкого кишечника), предполагающая максимальное упрощение и стандартизацию активности. Типичный бытовой пример защиты — ящерица, оставляющая хвост в зубах глупого котёнка; типичный медицинский пример — воспаление для избавления нашей кожи от инородного тела (занозы, например).

Просим понять нас правильно: мы затеяли обсуждение лингвистических вольностей, допущенных, действительно, одним из самых выдающихся учёных XX века (*Ганс Селье* относился к достаточно уникальному в науке — а в жизни, тем более — типу учёных-синтетиков. Все мы — в той или иной степени аналитики. Это у нас от наших четвероруких предков. А вот синтетики, способные увидеть лес за деревьями, рожда-

ются штучно в каждом столетии. Селье был именно таким), вовсе не с целью самоутверждения. На наш взгляд, это один из ярчайших примеров того, как незначительные, казалось бы, неточности в теоретической модели могут поставить под угрозу всю модель. В данном случае неосторожное использование популярной терминологии чуть было не привело к полному размыванию границ исследуемого феномена. А что такое правильно поставленные граничные условия для любой задачи, думается, никому не надо напоминать.

Чтобы не утомлять читателя излишними подробностями, как и в предыдущих главах, предлагаем наше видение возможных решений: в представленной ниже таблице 1 дан сравнительный анализ классических положений теории стресса и положений, основанных на современных знаниях (а со времени кончины Г. Селье прошло уже больше 30 лет) о структуре защитных процессов. Маленькое уточнение: аббревиатура САС означает симпатoadреналовую систему, ГГАС — гипоталамо-гипофизарно-адреналовую систему, ЭОС — эндогенную опиоидную систему (эта система известна широкому кругу читателей по одному из главных её компонентов — эндорфинам).

Таблица 1: Сравнительный анализ классических положений теории стресса (Г. Селье) и современных положений

Позиция	Классические положения	Современные положения
Определение стресса	Стресс (общий адаптационный синдром) — неспецифическая реакция организма на физическое или психологическое воздействие, нарушающее его гомеостаз.	Стресс является неспецифической стадийной системной защитной редуцированной психофизиологической реакцией организма на повреждение или его угрозу.
Стресс и шок	Шок — это стресс в крайней степени выраженности.	Шок — это стресс в крайней степени выраженности.

Неспецифическая	Стресс является неспецифической реакцией.	Стресс является неспецифической реакцией. Она развивается независимо от типа стресс-фактора. Это в корне отличается от разнообразных механизмов регуляции, которые реализуются в разных не экстремальных условиях.
Стадийная	Стресс является стадийной реакцией: – стадия тревоги – стадия резистентности – стадия истощения	Стресс является стадийной реакцией. Стадии стресса связаны с доминированием одной из стресс-реактивных систем: тревога — доминирование САС, резистентность — ГАС, истощение — ЭОС.
Системная	Стресс является реакцией, основанной на взаимодействии двух регуляторных стресс-реактивных систем: САС и ГАС.	Стресс является системной реакцией, основанной на динамическом взаимодействии трёх регуляторных стресс-реактивных систем: САС, ГАС и (что особенно важно) ЭОС.
Защитная	Стресс — адаптивная реакция.	Стресс не адаптивная реакция, но стресс защитная реакция (аналог — воспаление). Он основан не только на функциональных, но и на структурных изменениях. Например, «триада Селье».

Редуцированная	—	Стресс является обедненной реакцией на чрезвычайную ситуацию, в которой снижение индивидуальных отклонений психологических, физиологических, биохимических и других показателей является результатом истощения регуляторных механизмов (три нейроэндокринные стресс-реактивные системы имеют исключительное доминирование над остальными). Эта стандартизация обеспечивает неспецифическую защиту и является оптимальной только в чрезвычайных ситуациях.
Психофизиологическая	Стресс принято классифицировать как физический и психический (информационный, эмоциональный, экзаменационный и т. д.).	Стресс — это интегративная психофизиологическая реакция на повреждение или угрозы травмы. Его психологической составляющей является оценка степени угрозы и формирование стратегии выживания. Его физиологическая составляющая обеспечивает энергоснабжение когнитивных и двигательных функций за счет усиления регулирующих влияний САС, ГТАС и ЭОС.

Маркеры стресса	Эндокринные маркеры: повышение уровня кортизола, адреналина, норадреналина, АКТГ, кортиколиберина.	Эндокринные маркеры: повышение уровня кортизола, адреналина, норадреналина, АКТГ, кортиколиберина, энкефалинов, эндорфинов, динарфинов. Нейрофизиологический маркер: одновременное усиление индекса вегетативного баланса и падение общей мощности спектра variability ритма сердца.
Активация	Реакция организма на физическое или психологическое воздействие, нарушающее его гомеостаз.	Неспецифическое изменение активности организма в ответ на повреждение или его угрозу.

Путеводитель по литературе. Известно, что базовые положения теории всегда следует рассматривать, опираясь на первоисточники, поэтому для начала рекомендуем читателям опорные публикации *Г. Селье* [59–62]. Современные представления о механизмах экстремальных состояний и, особенно, о роли ЭОС в развитии стресса можно проанализировать по публикациям [34, 36, 37, 56, 63–67]. Некоторые из этих положений были запатентованы [68–71].

Ещё немного о мифах

Чтобы завершить обсуждение проблемы мифотворчества в когнитивной науке, приведём несколько совсем уж мелких, но до чрезвычайности распространённых мифов.

Например, «человек в процессе своей жизни использует только 10% (5%, 7%, 9% — дело вкуса) своих нейронов». Первый (и вполне очевидный) вопрос, который возникает: а как это можно измерить?! Ну и кроме того, благодаря развитию методов нейроимиджинга мы сегодня узнали, что деятельность нейронов связана с сугубо рыночными принципами: как нейрон отработает, так его и «накормят». Если нейрон «не используется»,

то есть не проявляет спайковой активности и, соответственно, не выделяет в окружающую среду медиаторы, нет никаких оснований снабжать его кровью. Следовательно, «не использующийся нейрон» — это мёртвый нейрон.

Ещё один сходный миф: «человек получает 90% (70%, 80%, 110% — опять дело вкуса) информации с помощью зрительного анализатора». Снова тот же самый вопрос: а каким образом это померено?

Проблема в том, что подобные удивительные откровения не только гуляют в сетях Интернета, но и проникают на страницы учебников и, что уж совсем поразительно, журналов и монографий. А это, в условиях мультидисциплинарности, становится опасным для развития науки.

Вместо заключения — ключевые вопросы

Как известно, вопросов бывает всегда два: кто виноват и что делать?

На первый вопрос авторы предпочли бы не отвечать. Во-первых, потому что ответ на него никогда ещё не приносил полезного приспособительного результата. А во-вторых, потому что винить, по сути, остаётся только эволюцию, так как именно она довела развитие живых информационных систем до такого уровня, на котором у них (систем, то есть) возникла потребность познать самоё себя. Мы уже упоминали, что задача эта безумно увлекательная, но и не менее трудная, потому что подозрительно напоминает циклическую ссылку.

На второй вопрос ответ уже прозвучал во введении: смириться с трудностями и честно мерить, благо, методы измерения информации в живых системах постоянно размножаются и совершенствуются. Не обманывать себя, считая, что измерение электрических и химических параметров живой информационной системы есть измерение информации в ней. И обязательно сопоставлять результаты измерений с результатами моделирования.

Только модели должны быть «хорошими».

Литература

1. *Block N. Comparing the major theories of consciousness // The Cognitive Neurosciences IV. M. Gazzaniga (ed.), MIT Press, 2009. — pp. 1111–1122.*

2. Seth A.K., Dienes Z., Cleeremans A., et al. Measuring consciousness: relating behavioural and neurophysiological approaches // *Trends in Cognitive Sciences*. – 2008. – Vol. 12, No. 8. – pp. 314–321.
3. Анохин П.К. Биология и нейрофизиология условного рефлекса. – М., Медицина, 1968, 548 с.
4. Анохин П.К. Теория отражения и современная наука о мозге. – М.: Знание, 1970, 47 с.
5. Александров Ю.И. Закономерности актуализации индивидуального опыта и реорганизации его системной структуры: комплексное исследование // *Труды Института системного анализа Российской академии наук*. – 2011. – Т. 61, №3. – с. 3–24.
6. Анохин К.В. Мозг и память: биология следов прошедшего времени // *Вестник Российской академии наук*. – 2010. – Т. 80, № 5–6: 455.
7. Созинов А.А., Крылов А.К., Александров Ю.И. Эффект интерференции в изучении психологических структур // *Экспериментальная психология*. – 2013. – Т. 6, № 1: 5–47.
8. Черниговская Т.В. Нить ариадны и пирожные «мадлен»: нейронная сеть и сознание // *В мире науки*. – 2012, №4: 40–47.
9. Черниговская Т.В. Мозг и язык: врождённые модули или обучающая сеть? // *Вестник Российской академии наук*. – 2010, № 5–6.
10. Carrera E., Tononi G. Diaschisis: past, present, future // *Brain*. – Sep. 2014, Vol. 137. – pp. 2408–2422.
11. Crick F. Visual perception: rivalry and consciousness // *Nature*. – February 1996, No 379. – pp. 485–486; doi:10.1038/379485a0.
12. Crick F., Koch C. A framework for consciousness // *Nature Neuroscience*. – 2003, Vol. 6. – pp. 119–126; doi:10.1038/nn0203-119.
13. Crick F., Koch C. Are we aware of neural activity in primary visual cortex? // *Nature*. – May 1995, No 375. – pp. 121–123; doi:10.1038/375121a0.
14. Crick F., Koch C. Consciousness and neuroscience // *Cerebral Cortex*. – March 1998, Vol. 8, Iss. 2. – pp. 97–107.
15. Crick F.C., Koch C. What is the function of the claustrum? // *Philosophical Transactions of the Royal Society by Biological Sciences*. – June 2005, Vol. 360, Iss. 1458. – pp. 1271–1279.
16. Edelman G.M. Perspective – Learning in and from brain-based devices // *Science*. – Nov 2007, Vol. 318, Iss. 5853. – pp. 1103–1105.
17. Faivre N., Koch C. Temporal structure coding with and without awareness // *Cognition*. – June 2014, Vol. 131, Iss. 3. – pp. 404–414.

18. *Izhikevich E. M., Edelman G. M.* Large-scale model of mammalian thalamocortical systems // *Proc. of the National Academy of Sciences of the United States of America*. – March 2008, Vol. 105, Iss. 9. – pp. 3593–3598.
19. *Kandel E. R., Markram H., Matthews P. M., Yuste R., Koch C.* Neuroscience thinks big (and collaboratively) // *Nat Rev Neurosci*. – Sep. 2013, Vol. 14, No. 9. – pp. 659–664; doi: 10.1038/nrn3578.
20. *Koch C., Reid C.* Neuroscience: Observatories of the mind // *Nature*. – March 2012, No. 483. – pp. 397–398; doi:10.1038/483397a.
21. *Koch C., Marcus G.* Cracking the brain's codes // *Technology Review*. – Jul-Aug 2014, Vol. 117, Iss. 4. – pp. 42–46.
22. *Koch C.; Tononi G.* A test for consciousness // *Scientific American*. – June 2011, Vol. 304, Iss. 6. – pp. 44–47.
23. *Koch C., Tononi G.* Can a photodiode be conscious? // *New York Review of Books*. – March 2013, Vol. 60, Iss. 4. – pp. 43–43.
24. *Koch C., Crick F.* The zombie within // *Nature*. – June 2001, Vol. 411, Iss. 6840. – pp. 893–893.
25. *Quiroga R. Q., Fried I., Koch C.* Brain cells for grandmother // *Scientific American*. – Feb. 2013, Vol. 308, Iss. 2. – pp. 30–35.
26. *Tononi G.; Cirelli C.* Sleep and the Price of Plasticity: From synaptic and cellular homeostasis to memory consolidation and integration // *Neuron*. – Jan. 2014, Vol. 81, Iss. 1. – pp. 12–34.
27. *Towal R. B., Mormann M., Koch C.* Simultaneous modeling of visual saliency and value computation improves predictions of economic choice // *Proc Natl Acad Sci USA*. – Oct. 2013, No 110(40). – pp. E3858–867. doi: 10.1073/pnas.1304429110. Epub 2013 Sep 9.
28. *Каплан А. Я.* Нейрокомпьютерный симбиоз: движение силой мысли // *НАВКА из первых рук*. – 2012, Т. 48, № 6: 26–39.
29. *Ashmarin I. P.* Structure-function classification of regulatory peptides: what should be included for minimum understanding by a wide variety of neurochemists, neurophysiologists, and senior and post-graduate students // *Neurochemical Journal*. – 2007, Vol. 1 (4). – pp. 334–338.
30. *Аллахвердов В. М.* За границей осознаваемого: радикальный когнитивизм о некоторых пределах нашей способности обработки информации // *Вестник Ярославского государственного университета им. П. Г. Демидова. Серия Гуманитарные науки*. – 2014, № 2: 72–80.
31. *Аллахвердов В. М.* Сквозь методологические тернии к светлому теоретическому будущему // *Вестник Санкт-Петербургского университета. Серия 16: Психология. Педагогика*. – 2012, № 4: 14–18.

32. Зорина З. А., Смирнова А. А. О чем рассказали «говорящие» обезьяны: способны ли высшие животные оперировать символами? – М.: Языки славянских культур. – 2006, 424 с.
33. Зорина З. А. Мышление животных: эксперименты в лаборатории и наблюдения в природе // *Зоологический журнал*. – 2005, Т. 84, № 1: 134–148.
34. Парин С. Б. Люди и животные в экстремальных ситуациях: нейрохимические механизмы, эволюционный аспект // *Вестник Новосибирского государственного университета*. – 2008, Т. 2, Вып. 2: 118–135.
35. Аллахвердов В. М. Во весь голос о сознании // *Петербургский психологический журнал*. – 2012, № 1: 1–14.
36. Кавамура К., Парин С. Б., Полевая С. А., Яхно В. Г. Возможность построения симуляторов осознания сенсорных сигналов: иерархия «распознающих ячеек», нейроархитектура, психофизические данные // Научная сессия МИФИ-2008. X Всероссийская научно-техническая конференция «Нейроинформатика – 2008»: Лекции по нейроинформатике. – М.: МИФИ, 2008. Ч. 1: 23–57.
37. Парин С. Б., Чернова М. А., Полевая С. А. Адаптивное управление сигналами о рассогласовании в когнитивных процессах: роль эндогенной опиоидной системы // *Известия вузов: Прикладная нелинейная динамика*. – 2011, Т. 19, № 6: 65–73.
38. Mudrik L.; Faivre N.; Koch C. Information integration without awareness // *Trends in Cognitive Sciences*. – Sep. 2014, Vol. 18, Iss. 9. – pp. 488–496.
39. Воловик М. Г., Габдуллина Е. Г., Зевеке А. В., Клейнбок И. Я., Колесов С. Н., Полевая С. А., Снежницкая И. В. Определение температуры в термочувствительных точках кожи человека // *Российский физиологический журнал им. И. М. Сеченова*. – 1998, Т. 84, № 3: 256–259.
40. Зевеке А. В., Полевая С. А. Модели кодов сенсорной информации периферического отдела кожного анализатора // *Сенсорные системы*. – 1992, Т. 6, № 4: 79–82.
41. Зевеке А. В., Полевая С. А. Иллюзия тепла при охлаждении кожи // *Российский физиологический журнал им. И. М. Сеченова*. – 1996, Т. 82, № 2: 104–111.
42. Цирульников Е. М. Соматосенсорное и слуховое восприятие по данным исследования с помощью фокусированного ультразвука // *Журнал эволюционной биохимии и физиологии*. – 1985, Т. 21, № 6: 591.
43. Зевеке А. В., Полевая С. А. Очувствленная кожа: Специфичность динамики пространственно-временных паттернов активности механорецепторов вместо «меченых линий» // *Известия вузов: Прикладная нелинейная динамика*. – 2011, Т. 19, № 6: 51–64.

44. Полевая С. А. Интегративные принципы кодирования и распознавания сенсорной информации. Особенности осознания световых и звуковых сигналов в стрессовой ситуации // *Вестник Новосибирского государственного университета*. – 2008, Т. 2, Вып. 2: 106–117.
45. Polevaya S., Nuidel I. The “Recognizing Cell” model for simulation of feed-forward interaction in the cognitive system: numerical experiment and psychophysical data // *J. Optical Memory & Neural Networks (Information Optics)*. – 2009, Vol. 18, No. 3. – pp. 195–202.
46. Banik R. K., Brennan T. J. Sensitization of primary afferents to mechanical and heat stimuli after incision in a novel in vitro mouse glabrous skin-nerve preparation // *Pain*. – 2008, Aug 31; 138(2). – pp. 380–391. doi: 10.1016/j.pain.2008.01.017.
47. Del Valle M. E., Cobo T., Cobo J. L., Vega J. A. Mechanosensory neurons, cutaneous mechanoreceptors, and putative mechanoproteins // *Microsc. Res. Tech.* – Aug. 2012, **75**(8). – pp. 1033–1043. doi: 10.1002/jemt.22028.
48. Legon W., Rowlands A., Opitz A., Sato T. F., Tyler W. J. Pulsed ultrasound differentially stimulates somatosensory circuits in humans as indicated by EEG and fMRI // *PLoS One*. – 2012; **7**(12) :e51177. doi: 10.1371/journal.pone.0051177.
49. Mouraux A., Plaghki L. Cortical interactions and integration of nociceptive and non-nociceptive somatosensory inputs in humans // *Neurosci.* – 2007; **150**(1). – pp. 72–81.
50. Xu F., Lu T. J., Seffen K. A. Thermally-induced change in the relaxation behavior of skin tissue // *J. Biomech. Eng.* – July 2009; **131**(7): 071001. doi: 10.1115/1.3118766
51. Zeveke A. V., Efes E. D., Polevaya S. A. An integrative framework of the skin receptors activation: Mechanoreceptors activity patterns versus “labeled lines” // *J. of Integrative Neuroscience*. – 2013, Vol. 12. – pp. 47–56.
52. Little J. W., Ford A., Symons-Liguori A. M., Chen Z., Janes K., Doyle T., Xie J., Luongo L., Tosh D. K., Maione S., Bannister K., Dickenson A. H., Vanderah T. W., Porreca F., Jacobson K. A., Salvemini D. Endogenous adenosine A3 receptor activation selectively alleviates persistent pain states // *Brain*. – 2014 (in press); DOI: 10.1093/brain/awu330.
53. Sperry R. W. The great cerebral commissure // *Scientific American*. – 1964, Vol. 210 (1). – pp. 42–52.
54. Спрингер С., Дейч Г. Левый мозг, правый, мозг: Пер. с англ. – М.: Мир, 1983. – 256 с.
55. Фокин В. Ф., Пономарева Н. В., Кротенкова М. В., Коновалов Р. Н., Танашиян М. М., Лагода О. В. Факторы, определяющие динамические свойства функциональной межполушарной асимметрии // *Асимметрия*. – 2011, Т. 5, № 1: 4–20.

56. *Polevaya S. A., Parin S. B., Chernova M. A.* The specific pattern of conscious perception of elementary visual and auditory signals of patients with schizophrenia diagnosis under psychotropic drugs // *International J. of Psychophysiology.* – Sept. 2012, Vol. 85, Iss. 3. – pp. 411–412.
57. *Щербаков В. И., Паренко М. К., Полевая С. А., Шеромова Н. Н.* Возрастные особенности структуры субъективного звукового поля человека // *Сенсорные системы.* – 2001, Т. 15, № 4: 309–315.
58. *Щербаков В. И., Шеромова Н. Н., Полевая С. А., Паренко М. К.* Способ исследования межполушарной сенсорной асимметрии. – Патент РФ № 2198589, 2003.
59. *Selye H.* A syndrome produced by diverse nocuous agents // *Nature.* – 1936. – **138**: 32.
60. *Selye H.* The general adaptation syndrome and the diseases of adaptation // *J. Clin. Endocrinol. Metab.* – 1946, Vol. 6. – pp. 117–230.
61. *Selye H.* The physiology and pathology of exposure to stress. – Montreal: Acta Inc., 1950.
62. *Selye H.* Stress and disease // *Science.* – 1955, Vol. 122. – pp. 625–631.
63. *Парин С. Б.* Нейрохимические и психофизиологические механизмы стресса и шока // *Вестник Нижегородского государственного университета им. Н. И. Лобачевского.* – 2001, № 2: 20–28.
64. *Рунова Е. В., Григорьева В. Н., Бахчина А. В., Парин С. Б., Шишалов И. С., Кожевников В. В., Некрасова М. М., Каратушина Д. И., Григорьева К. А., Полевая С. А.* Вегетативные корреляты произвольных отображений эмоционального стресса // *Современные технологии в медицине.* – 2013, Т. 5, № 4: 69–77.
65. *Parin S. B., Bakhchina A. V., Polevaia S. A.* A neurochemical framework of the theory of stress // *International J. of Psychophysiology.* – Nov. 2014, Vol. 94, Iss. 2. – p. 230.
66. *Polevaya S. A., Vetyugov V. V., Bakhchina A. V., Parin S. B.* Opioid-related cognitive and cardiovascular features // *International J of Psychophysiology.* – Nov. 2014, Vol. 94, Iss. 2. – pp. 257–258.
67. *Тиняков Р. Л., Парин С. Б., Беспалова Ж. Д., Крушинская Я. В., Соколова Н. А.* FMRFa и FMRFамид-подобные пептиды (FaRPs) в патогенезе шока // *Успехи физиологических наук.* – 1998, Т. 29, № 3: 56–65.
68. *Голанов Е. В., Калюжный Л. В., Парин С. Б., Судаков К. В.* Способ лечения шокового состояния. – Авторское свидетельство СССР № 1138165, 1984.
69. *Ашмарин И. П., Соколова Н. А., Зозуля М. А., Крылов В. Н., Парин С. Б., Кузьмин Е. Г.* Способ лечения геморрагического шока. – Патент России № 2033804, 1995.

70. Полевая С. А., Парин С. Б., Бахчина А. В., Некрасова М. М., Шишалов И. С., Рунова Е. В., Кожевников В. В. Система определения функционального состояния группы людей с обратной связью. – Патент РФ на полезную модель № 129681, 2013.
71. Некрасова М. М., Полевая С. А., Парин С. Б., Шишалов И. С., Бахчина А. В. Способ определения стресса. – Патент РФ № 2531443, 2014.

Сергей Борисович ПАРИН, доктор биологических наук, профессор кафедры психофизиологии, заведующий лабораторией когнитивной психофизиологии Нижегородского государственного университета им. Н. И. Лобачевского; старший научный сотрудник отдела нейрофизиологии ЦНИЛ Нижегородской государственной медицинской академии. Научные интересы: нейрофизиология, психофизиология боли и экстремальных состояний, когнитивные системы, нейронформатика. Автор более 200 научных работ.

Софья Александровна ПОЛЕВАЯ, доктор биологических наук, заведующий отделом нейрофизиологии ЦНИЛ Нижегородской государственной медицинской академии; профессор, заведующий кафедрой психофизиологии Нижегородского государственного университета им. Н. И. Лобачевского. Научные интересы: психофизиология сенсорных систем, когнитивные системы, когнитивная биофизика, моделирование информационных процессов. Автор более 180 научных работ.

**А. В. КАРГОВСКИЙ¹, Ю. М. РОМАНОВСКИЙ¹,
В. П. ТРИФОНЕНКОВ², А. В. ТРИФОНЕНКОВ²**

¹ Физический факультет МГУ им. М. В. Ломоносова

² Национальный исследовательский ядерный университет «МИФИ»

E-mail: yuromanovsky@yandex.ru

СТОХАСТИЧЕСКАЯ ДИНАМИКА ВНУТРИНЕЙРОННОГО ТРАНСПОРТА

Аннотация

В работе представлен обзор внутринейронного транспорта нейромедиаторов, митохондрий и пр. Представлены физические основы функционирования и математические модели шагающих молекулярных моторов: кинезина и миозина V с учетом флуктуаций.

**Yu. M. ROMANOVSKY¹, A. V. KARGOVSKY¹,
V. P. TRIFONENKOV², A. V. TRIFONENKOV²**

¹ Lomonosov Moscow State University, Russia

² National Research Nuclear University “MEPhI”, Russia

E-mail: yuromanovsky@yandex.ru

STOCHASTIC DYNAMICS OF INTRANEURONAL TRANSPORT

Abstract

The article focuses on intraneuronal transport of neuromediators, mitochondria etc. Physical principles of functioning of walking molecular motors: kinesin and myosin V are considered in the paper and their mathematical models considering the presence of fluctuations are analyzed.

О чем пойдет речь?

Каждый нейрон является сложным аналогово-вычислительным комплексом. Его функции обеспечиваются взаимодействием сотен ферментативных молекул, контролируемых геномом клетки. Строго говоря, каждая молекула фермента является молекулярной машиной (ММ), которая, вступая во взаимодействие с другими молекулами — «субстратами» ММ, преобразует их и после окончания ферментативного акта возвращается в свое исходное состояние.

Сейчас хорошо развита концепция «белок–машина» (см., например, [1, 2]). Даже когда еще не было известно устройство вращающихся мотор-генераторов АТФ-синтаза и шагающих ММ, авторы концепции понимали, что каждый цикл в работе ферментов связан с внутренними движениями отдельных молекулярных групп, которые не только вызывают изменения конфигурации электрических полей в карманах активных центров (АЦ), но и запасают упругую энергию в субглобулах, образующих ферменты.

В лекции пойдет речь о ММ, обеспечивающих транспорт внутри нейронов: кинезине (КН), миозине V (MV) и динеине (Д), а также о молекулярных «ножницах» — ацетилхолинэстеразе (АХЭ). Именно эти ММ обеспечивают, в основном, кругооборот нейромедиаторов и молекул-отходов при синаптической связи как между нейронами, так и между нейронами и другими клетками-мишенями.

Помимо описания физических принципов, определяющих работу этих ММ, будут представлены математические модели КН и MV, работающих при наличии случайных воздействий. Именно при построении математических моделей вырисовываются общие принципы, лежащие в основе их деятельности.

Ежегодно появляются сотни публикаций, посвященных ММ. Поэтому в лекции, помимо ссылок на конкретные работы и обзоры, мы приводим адреса сайтов наиболее известных лабораторий, в которых уже много лет проводятся как экспериментальные, так и теоретические исследования в этой области [3–7].

Общая схема транспорта внутри нейрона

Подробно со строением нейрона можно ознакомиться по многим литературным источникам (см., например, [8]). Здесь важно подчеркнуть, что по

его коротким отросткам — дендритам, окончаний которых достигают другие нейроны и образуют между ними синаптические щели, и по длинным аксонам, достигающим удаленные клетки, происходит непрерывное перемещение везикул-пузырьков с нейромедиаторами, митохондрий и других органелл от ядра клетки к ее периферии, а в сторону ядра перемещаются контейнеры с «отработанными» молекулами. Движение это осуществляют молекулярные «шагающие» моторы — кинезин и динеин. Движение происходит вдоль направляющих — тубулиновых микротрубочек (МТ) от ядра клетки к синаптическим окончаниям, а в самих синаптических окончаниях по сети актиновых филаментов (АФ) ходит переносчик — миозин V.

Прежде, чем говорить о том, как устроены кинезин, динеин и миозин V и как они функционируют, скажем о грузах, которые они перемещают. Это прежде всего везикулы или «пузырьки» с молекулами нейромедиаторов. Везикулы с нейромедиаторами непрерывно доставляются к синапсам, где прикрепляются вблизи мембраны синаптического окончания. При возбуждении мембраны нервным импульсом содержимое везикулы выплескивается в синаптическую щель. Нейромедиатор, например, ацетилхолин, достигает рецепторов на клетке-мишени, которые стимулируют выработку нервного импульса в этой клетке. Это один из важнейших типов взаимодействия нейронов. В мембране нейрона находятся также специальные молекулярные машины, а точнее сказать, молекулярные ножницы. Они разрезают на части молекулы отработавшего нейромедиатора, эти «осколки» попадают снова в окончание дендрита, запаковываются в везикулы и доставляются в обратном направлении по МТ к ядру на «переделку» [8, 9]. Помимо нейромедиаторов шагающие моторчики доставляют от ядра к периферии митохондрии, в мембранах которых работают другие замечательные электрические моторы-генераторы — F_0F_1 АТФазы, которые за счет мембранных потенциалов (~ 220 мВ) при своем вращении вырабатывают молекулы АТФ [5, 6, 10–13]. Сами же мембранные потенциалы вырабатываются за счет процессов окисления глюкозы. АТФ необходима для работы кинезина и других переносчиков, для роста МТ, для удлинения дендритов. Именно этот процесс необходим для жизни нейронов и образования новых связей в мозгу. Всего в организме человека в сутки синтезируется (и расходуется) около 50 кг АТФ. При этом на нервную ткань приходится около 20% этого количества.

На рис. 1 представлена схема синаптического окончания. Показаны МТ и сеть АФ (условно). «Контейнеры», доставляемые по МТ кинезинами затем перегружаются на «головы» MV. В качестве примеров взяты «грузы»

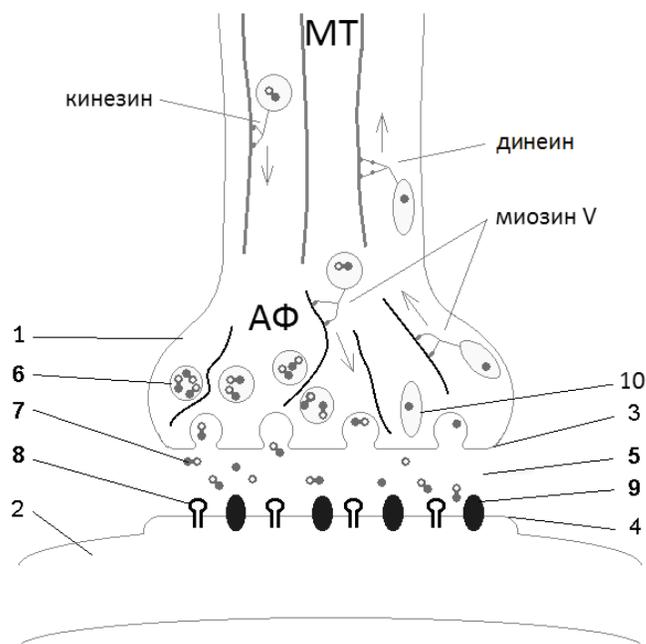


Рис. 1. Схема передачи нервного импульса в химическом синапсе. 1 — окончание пресинаптического нейрона; 2 — постсинаптический нейрон; 3 — пресинаптическая мембрана; 4 — постсинаптическая мембрана; 5 — синаптическая щель; 6 — пузырьки, содержащие нейромедиатор (ацетилхолин); 7 — высвобождаемый нейромедиатор; 8 — ацетилхолиновые рецепторы; 9 — фермент ацетилхолинэстераза; 10 — пузырьки, содержащие холин.

— везикулы, содержащие молекулы нейромедиатора — ацетилхолина (показаны «гантельками») и его «осколка» холина (показаны «кружочками»). Контейнеры (синаптические пузырьки-везикулы) при электрическом возбуждении мембраны выплескивают нейромедиатор — ацетилхолин в синаптическую щель, реагируют с рецепторами в мембране клетки-мишени и побуждают ее выработать импульс.

После этого ни в коем случае нельзя оставлять нейромедиатор в синаптической щели. Характерная частота прихода импульсов на мембране порядка 1 кГц. Придет следующий импульс — выплеснется новая порция

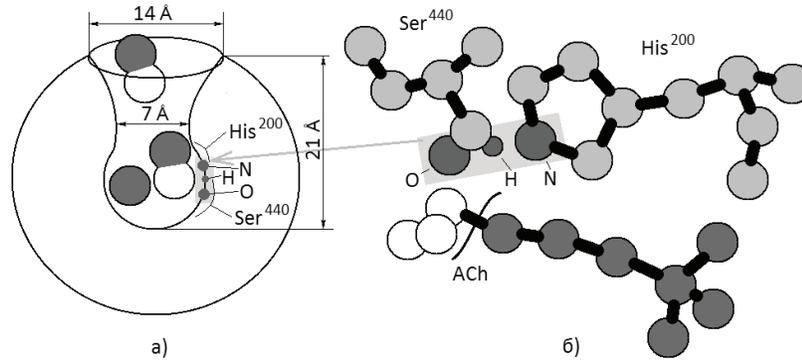


Рис. 2. Схема АХЭ. а) Гантелеобразные молекулы ацетилхолина (АХ) и дискообразные молекулы ацетила и холина в «горле» АЦ. б) АХ, связанный с каталитическим центром АХЭ. Волнистой линией показана разрываемая химическая связь.

нейромедиатора — а ничего не работает! Ведь в синаптической щели его уже много! Поэтому существуют «от бога» ММ — молекулярные ножницы АХЭ. Они быстро разрезают ацетилхолин пополам, образуются осколки — ацетат и холин, холин снова заключается в контейнеры, которые по встречным «рельсам» доставляются к ядру на переделку. На рис. 2 показана схема работы АХЭ. Заметим, что другой осколок — ацетат всегда находится в достаточном количестве в нейроплазме [14, 15].

Попав в результате диффузии и под действием электростатического поля, создаваемого молекулой АХЭ, АХ проникает в горло АЦ и «прилипает» к аминокислотным остаткам Ser и His. Ион кислорода O при тепловых колебаниях атакует химическую связь, показанную на рис. 2 волнистой линией, «разрыхляет» ее, и происходит реакция: $ACh \rightarrow A + Ch$. Продукты снова запаковываются в везикулы и т. д. Заметим, что действие нервно-паралитических отравляющих веществ сводится к ингибированию АХЭ, нервная система блокируется собственным «наркотиком» и организм погибает. В АЦ ММ всегда присутствуют группы, которые играют роль молекулярных ножниц. Именно благодаря их работе молекула АТФ распадается на АДФ и фосфат (P^-), эти осколки покидают АЦ и т. д.

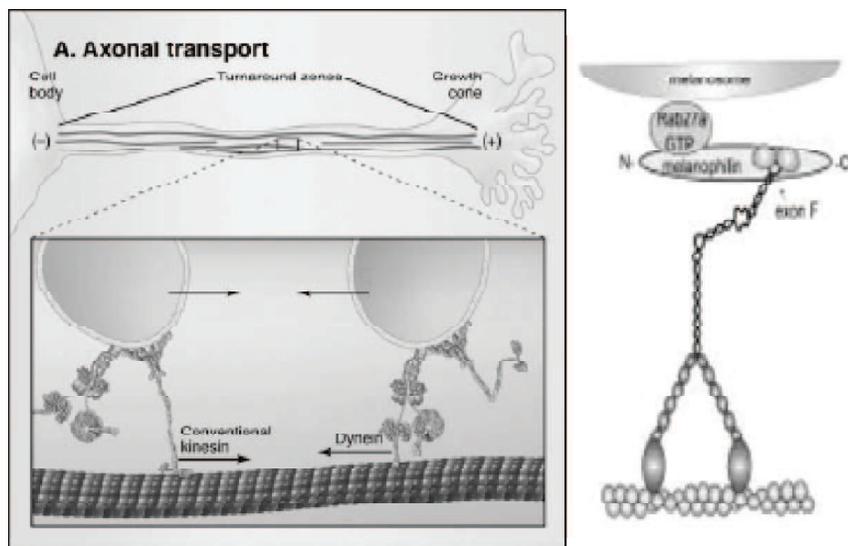


Рис. 3. Слева: прямой (от ядра клетки) и обратный транспорт по МТ. Прямой осуществляется кинезином, обратный — динеином (из обзора Vale [3]). Диаметр МТ ~ 5 нм. Справа: миозин V с грузом на актиновом филаменте. Расстояние между «головками или моторными доменами» миозина V ~ 36 нм [16].

Образы молекулярных моторов: кинезина, миозина v и динеина

Как работает кинезин

Молекула кинезина представляет собой димер, образованный двумя одинаковыми полипептидными цепями. На одной стороне каждой цепи образуется шаровидная голова (ГК) с размерами $7.5 \times 4.5 \times 4.5$ нм, в сочетании с длинным хвостом. Хвосты двух мономерных цепей, сплетены вместе и опираются в разных направлениях на ГК, образуя «вилку», которая взаимодействует с тубулиновой микротрубочкой (МТ), вдоль которой движется кинезин. Один шаг кинезина приводит к его смещению на расстояние около 8 нм, что в точности соответствует размеру двух мономерных глобул

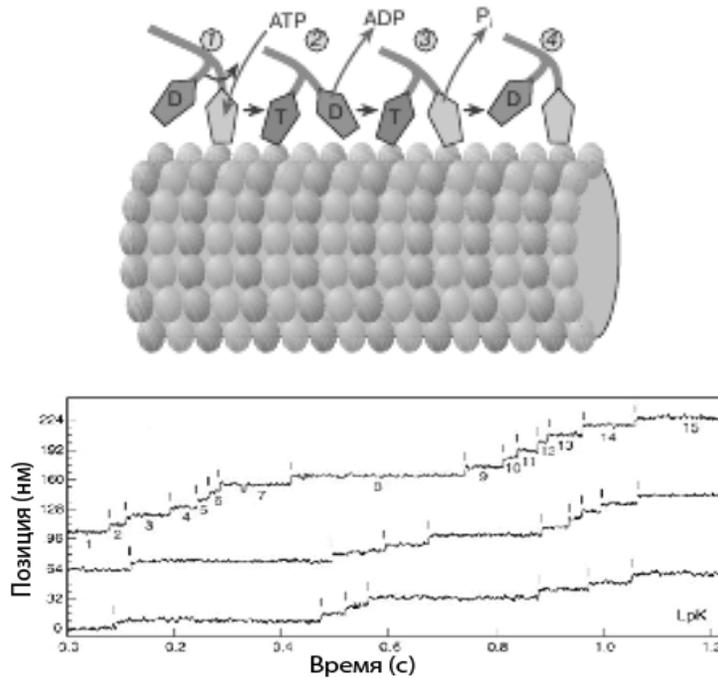


Рис. 4. Вверху: схема «шагания» кинезина [17]. Внизу: запись с высоким разрешением движения кинезина LpKbP из аксона кальмара. Вертикальные линии показывают шаги кинезина. Соответствующие интервалы «ожидания» пронумерованы [19].

тубулина, из которых построены МТ. Кинезин обычно за одну секунду совершает 100 шагов (800 нм) до полного отрыва от МТ [17]. Заметим, что на МТ имеется 11 независимых «путей», по которым могут параллельно передвигаться молекулы кинезина с грузом и при этом преодолевать стоксово сопротивление (рис. 4).

Об истории открытия кинезина *R. D. Vale* в аксоне кальмара и экспериментальных методах его изучения см., например, в [3, 4, 18].

Известно строение многих кинезинов. Например, в организме мыши насчитывается до 40 типов молекул кинезина [19]. В открытом доступе находится несколько мультфильмов, иллюстрирующих движение кинезина

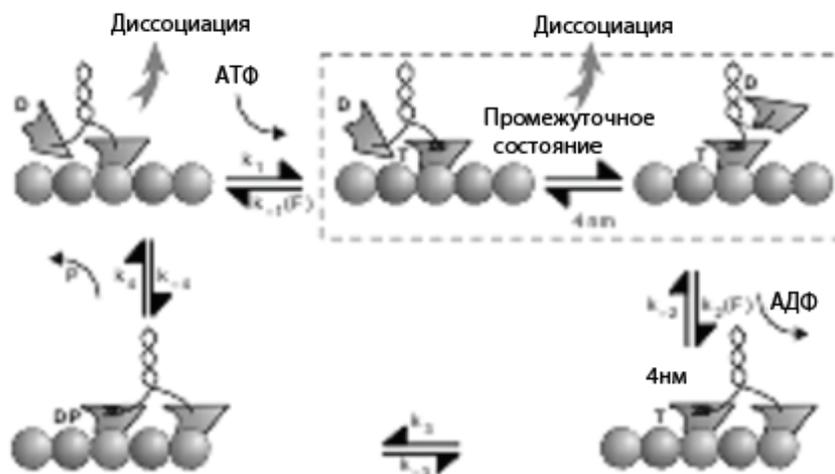


Рис. 5. Механохимический цикл кинезина. Две ГК связаны между собой соединяющими «шеями» и образуют «стебель», к которому может прикрепляться груз. Обозначения внутри АЦ: E — АТФ, D — АДФ, P — фосфат. Жесткое связывание ГК с МТ происходит, когда АЦ ГК пуст. При вхождении молекулы АТФ в АЦ в передней ГК развивается момент, который приводит к перебросу задней ГК вперед на 8 нм. Затем молекула АТФ в результате гидролиза разваливается в АЦ (АТФ → АДФ + P⁻), P покидает АЦ и процесс повторяется [20].

вдоль МТ (см. сайты *R. D. Vale* and *S. M. Block* [3, 4]).

На рис. 6 [21] приведена современная схема событий в ГК при ее взаимодействии с МТ и молекулами АТФ и АДФ, приводящих к рождению силового момента, продвигающего «стебель» с грузом. На нем представлен поперечный разрез МТ и строение ГК. Знак «+» показывает направление продвижения вперед вдоль МТ. Угол β (наклон), характеризует раскрытие АЦ и меняется от $\sim 30^\circ$ до 0° при сорбции АТФ в кармане АЦ.

Ниже, на рис. 7 [22], поясняющем предыдущие рисунки, показано «шагание» кинезина по МТ. Угол α , описывающий положение «шей», меняется на 180° , он пропорционален углу наклона элемента CNB или углу β на рис. 6.

Описанные процессы соответствуют изменению положений желтой и красной «шей» на кадрах из видеоиллюстрации *R. D. Vale* [3], которые ме-

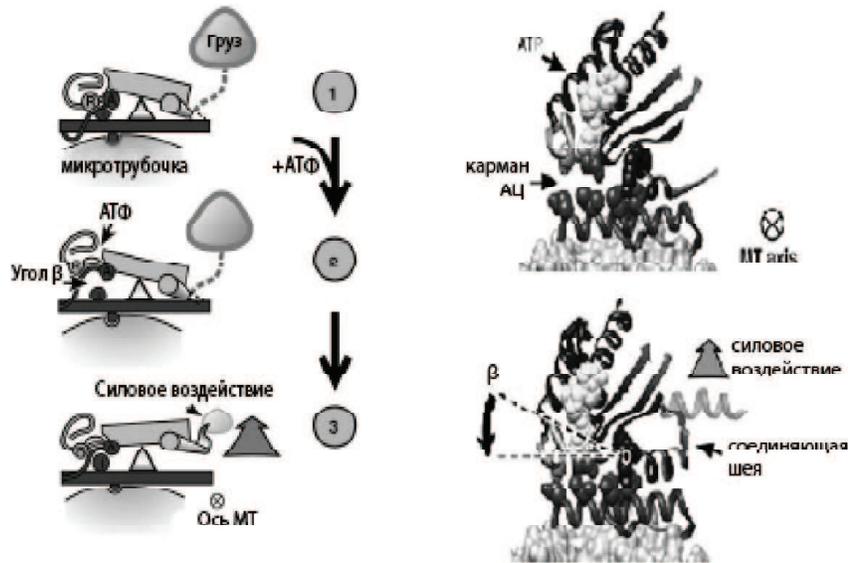


Рис. 6. На рисунке справа показана «молекулярная структура головки». Она соответствует схемам с «качелями», показанными слева. Стрелками показано изменение угла β . Качели передают усилие на рычаг, который продвигает груз, закрепленный на «шее» вдоль МТ по направлению к ее «+» концу. Важно, что качели прикреплены к МТ. После развала АТФ и при «дерганьи» задней головки кинезина передней головкой этот контакт разрывается. Головка отскакивает, протаскивается вперед вместе с грузом и затем, находясь в диффузионном движении, прикрепляется впереди работающей головки в следующей потенциальной яме на МТ.

няются местами и проворачиваются на 180° . Ниже, на рис. 8, показана на веерообразной поверхности траектория шарнира, к которому прикреплен «ствол» с грузом.

В работе [23] показано расположение «потенциальных ям» на МТ, минимумы которых находятся друг от друга на расстоянии 8 нм, в которых связывается ГК. Механизм связывания точно не известен.

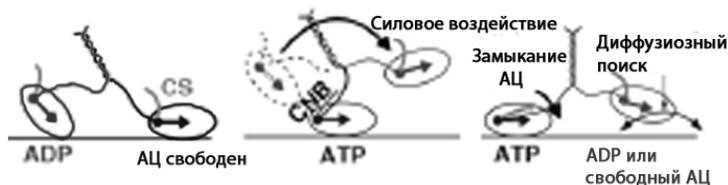


Рис. 7. CNB — структурный элемент, соответствующий плечу «качелей». Слева: выпуск P^- в задней головке приводит ее либо к диссоциации, либо, быть может, к ослаблению связывания с МТ. В середине: АТФ связывается с ведущей головкой и обеспечивает рабочий ход через формирование CNB, способствуя при этом отрыванию задней ГК от МТ и двигая ее вперед. Справа: оторванная «задняя» головка движется вместе с грузом и диффузионно ищет свой МТ сайт связывания, затем в слабо связанном или подвижном состоянии «ждет» пока АДФ выйдет из АЦ. Таким образом, угол α меняется в пределах от -90^0 до $+90^0$. Теперь АЦ готов принять АТФ, и начинается новый цикл.

Оценка энергии, необходимой для преодоления стокового сопротивления при «шагании» кинезина

Будем считать, что с момента открытия угла β_2 и выдергивания ГК-2 из потенциальной ямы в течение дальнейшего проворота шеи с грузом вплоть до прикрепления ГК-2 впереди ГК-1 действующий момент при закрывании β_1 все тот же, но коэффициенты трения (сопротивления) разные. Далее мы будем учитывать то обстоятельство, что момент, развиваемый при сорбции АТФ и закрытии угла β примерно в два раза больше момента, изменяющего угол α и продвижение груза. Ведь «силовой момент закрытия β_1 » должен еще вызвать открытие β_2 в ГК-2 и выдергивание ее из потенциальной ямы МТ.

Из эксперимента известно, что только половину энергии АТФ кинезин тратит на продвижение груза. Остальная энергия тратится на «выдергивания» задней ГК (второго «башмака»), перетаскивание башмака вперед и т. д. Поэтому мы выбираем соответствующие оценки для моментов. Еще раз: мы считаем, что момент (β) равен моменту (α) + Момент выдергивания, а сравнительно небольшой момент силы Стокса, действующий на перетаскиваемый задний башмак, суммируется с моментом, преодолеваю-

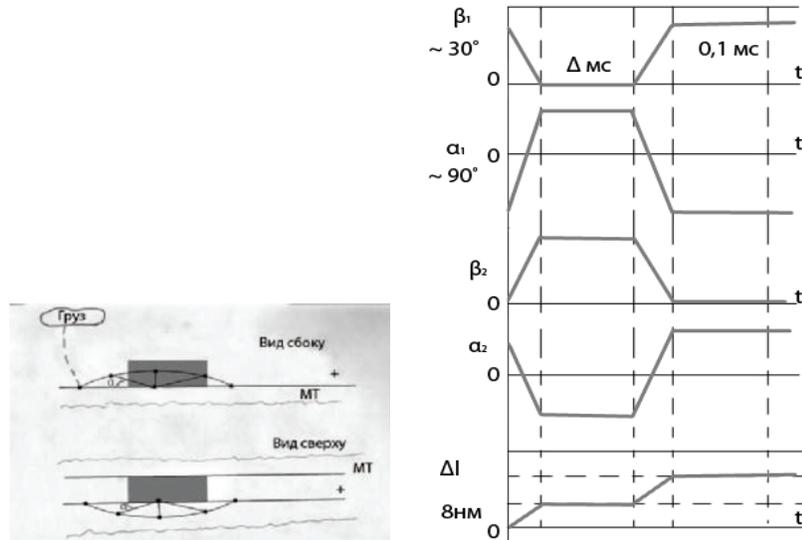


Рис. 8. Слева показана траектория шарнира на конце «связывающей шеи», к которому прикреплен «ствол» с грузом. Вращение осуществляется в результате воздействия на связывающую шею системы рычагов при закрытии угла β . Карман АЦ закрывается в результате сорбции молекулы АТФ. При этом угол β меняется от 30° до 0° . Соответственно, угол α меняется от -90° до $+90^\circ$. Траектория шарнира располагается на веерообразной поверхности. Справа показана качественная схема изменения углов β_1 , β_2 , α_1 , α_2 и смещения груза вдоль МТ $\Delta l = 8$ нм. Заметим, что плечо момента, который продвигает груз, равно $\Delta l/2 = 4$ нм.

щим силу Стокса груза. Сделаем соответствующие оценки.

При гидролизе АТФ \rightarrow АДФ + P^- освобождается около 40 кДж/моль энергии. Или на одну молекулу АТФ ~ 15 кТ. При протаскивании груза ведущей ГК на 8 нм при силе 5 пН совершается работа $4 \cdot 10^{-20}$ Дж (24 кДж/моль ~ 20 кТ). Значит, для «полезного шага» расходуется лишь половина энергии АТФ. Куда тратится вторая половина?

а) Потери на перетаскивание задней ГК.

Будем считать, что груз имеет радиус 0.1 мкм, ГК имеет характерный

«радиус» $3 \text{ нм} = 3 \cdot 10^{-3} \text{ мкм}$. Значит ее радиус меньше на два порядка, чем радиус груза. Поэтому работа по перетаскиванию задней, отделившейся от МТ, ГК много меньше работы по перетаскиванию груза. По всей видимости, почти все дополнительные усилия передней ГК уходят на отрыв задней головки от МТ.

- b) Оценим время нарастания ступени одного шага кинезина (или перетаскивания груза на расстояние $L = 8 \text{ нм}$). Пусть радиус груза $r = 0.1 \text{ мкм}$. По формуле Стокса

$$F = 6\pi rV\eta \quad (1)$$

(здесь $F \sim 6 \text{ пН}$, $r = 0.1 \text{ мкм}$, $\eta = 20 \cdot 10^{-3} \text{ Нс/м}^2$ — протоплазма имеет вязкость в 20 раз больше, чем вода, τ^* — время шага) получаем из равенства: $F\tau^* = 6\pi r\eta L$. Значит, $\tau^* \sim 50 \cdot 10^{-6} \text{ с}$. Если r больше, то и τ^* больше, и наоборот, если $r = 0.01 \text{ мкм}$, то $\tau^* = 5 \cdot 10^{-6} \text{ с}$ — меньше. Если «плато», или ширина ступени, 1 мс , то время нарастания ступени 0.05 от ее длительности.

- c) Теперь оценим значение размерного параметра ζ , учитывающего вязкое сопротивление среды и геометрические параметры рассматриваемой системы, используя сделанную выше оценку для времени уменьшения угла β от 30° до 0° .

Мы считаем, что для момента, который продвигает груз, плечо силы, или «шея», (см. рис. 8) равно $L/2 = 4 \text{ нм}$. Поэтому

$$\zeta d\alpha = F(L/2)dt. \quad (2)$$

Если β уменьшился на $\pi/6$, то α увеличивается на π и $\zeta\pi = F\tau^*(L/2)$. Отсюда и оцениваем размерную величину $\zeta = FL\tau^*/(2\pi)$.

Математическая модель шагания кинезина

Мы строим систему динамических уравнений для взаимодействия двух ГК по аналогии с системой, описывающей вращение ротора в молекулярном моторе F_1 АТФазы. Ротор вращается под действием моментов, которые по очереди создаются тремя идентичными β -субглобулами при сорбции в их АЦ молекул АТФ [11, 13, 24]. Связь между тремя β -субглобулами создается через ротор. Моменты в ГК и их упругие деформации создаются также по очереди при сорбции в их АЦ молекул АТФ. Силовая связь

между ГК создается через соединяющие их шейки и при этом возникает (через стебель) момент, продвигающий груз вдоль МТ (см. рис. 8). Система уравнений, описывающая шаг кинезина (угол β_1 закрывается, угол β_2 открывается) выглядит следующим образом:

$$\begin{aligned} \zeta \dot{\beta}_1 &= M(\beta_1) - \tau_1 + \varepsilon \dot{\beta}_2, & \zeta \dot{\beta}_2 &= M(\beta_2) - \tau_2 - \varepsilon \dot{\beta}_1, \\ \mu \dot{\tau}_1 &= k\beta_1 - \tau_1, & \mu \dot{\tau}_2 &= k\beta_2 - \tau_2. \end{aligned} \quad (3)$$

Здесь $\beta_1(t)$ и $\beta_2(t)$ — углы, описывающие закрытие карманов АЦ ГК при сорбции в них молекул АТФ; $\tau_1(t)$ и $\tau_2(t)$ — упругие напряжения, возникающие при деформации ГК. $\tau_1(t)$ и $\tau_2(t)$ запаздывают относительно упругих сил $k\beta_1$ и $k\beta_2$ из-за процессов гидролиза (развала) АТФ в АЦ. $M(\beta_1)$ и $M(\beta_2)$ — моменты, создающиеся в деформирующихся карманах АЦ при сорбции в них АТФ. Заметим, что углы β пропорциональны углам α (см. рис. 7). Значения ζ определяются стоковым сопротивлением при перемещении груза, величина μ определяется временем гидролиза АТФ, а k — упругостью ГК.

Соответствующая система уравнений в безразмерных переменных имеет вид:

$$\begin{aligned} \tilde{\zeta} \dot{\tilde{\beta}}_1 &= \tilde{M}(\tilde{\beta}_1) - \tilde{\tau}_1 + \tilde{\varepsilon} \dot{\tilde{\beta}}_2, & \tilde{\zeta} \dot{\tilde{\beta}}_2 &= \tilde{M}(\tilde{\beta}_2) - \tilde{\tau}_2 - \tilde{\varepsilon} \dot{\tilde{\beta}}_1, \\ \dot{\tilde{\tau}}_1 &= \tilde{k} \tilde{\beta}_1 - \tilde{\tau}_1, & \dot{\tilde{\tau}}_2 &= \tilde{k} \tilde{\beta}_2 - \tilde{\tau}_2, \end{aligned} \quad (4)$$

где взаимосвязь кинематических углов кинезина $\beta_{1,2}$ и соответствующих им безразмерных фазовых переменных системы уравнений описывается формулой

$$\beta_i = \frac{\pi}{12} (\tilde{\beta}_i + 1); \quad i = 1, 2. \quad (5)$$

Момент, определяемый силами сорбции молекул АТФ или продуктами гидролиза АДФ и неорганического фосфата P^- в АЦ ГК, задается формулой

$$\tilde{M}(\tilde{\beta}) = \tilde{\beta} - \frac{1}{n} \tilde{\beta}^n, \quad n = 3, 5, 7, \dots \quad (6)$$

причем $\tilde{M}(\tilde{\beta}) = M(\beta)/M_0$ (форма $M(\beta)$ приближается к N -образной при больших n). Другие безразмерные переменные определяются выражениями:

$$\tilde{t} = \frac{t}{\mu}, \quad \tilde{\zeta} = \frac{\zeta}{M_0 \mu}, \quad \tilde{\tau} = \frac{\tau}{M_0}, \quad \tilde{k} = \frac{k}{M_0}, \quad \tilde{\varepsilon} = \frac{\varepsilon}{M_0 \mu}. \quad (7)$$

Возьмем для примера численные значения коэффициентов: $\mu = 5$ мс, $M_0 = 80$ пН·нм, $\tilde{\zeta} = 0.05$, $\tilde{k} = 0.7$, $\tilde{\varepsilon} = 0.015$, близкие к модели F₁АТФазы [18, 24]. Примеры решения системы (5) приводятся ниже.

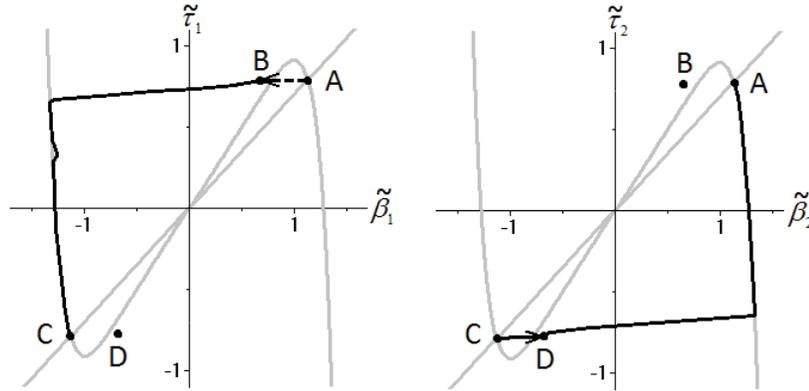


Рис. 9. Фазовые плоскости $(\tilde{\beta}, \tilde{\tau})$ для передней (слева) и задней (справа) ГК. Темные линии соответствуют фазовым траекториям, а светлые — изоклинам системы (4). Для закрытия угла $\tilde{\beta}_1$ необходимо, чтобы в АЦ сорбировалась молекула АТФ. Тогда возникают начальные условия в точке В и фазовая траектория идет от В до С (рисунок слева). При открытии угла $\tilde{\beta}_2$ нужно преодолеть порог (от С до D), чему может способствовать момент, передаваемый от передней ГК.

Переход из точки А в точку В на фазовой плоскости ГК-1 (см. рис. 9) соответствует приходу АТФ в АЦ первой (передней) ГК. Этот переход связан с некоторой задержкой, которая определяется концентрацией АТФ в среде (при максимальных концентрациях задержки практически не происходит). В случае избытка АТФ в среде задержки, связанные с ожиданием прихода АТФ в АЦ, становятся практически незаметными, и шагание кинезина по МТ при этом происходит периодически.

Ниже приведены статистические характеристики шагания кинезина, полученные при моделировании, и, для сравнения, экспериментальные значения скорости шагания кинезина по МТ. Подчеркнем еще раз, что переход А-В (см. фазовую плоскость слева на рис. 9) осуществляется лишь при сорбции АТФ в АЦ. Вероятность этого перехода зависит от концентрации АТФ в среде и при моделировании оценивалась, исходя из значений коэф-

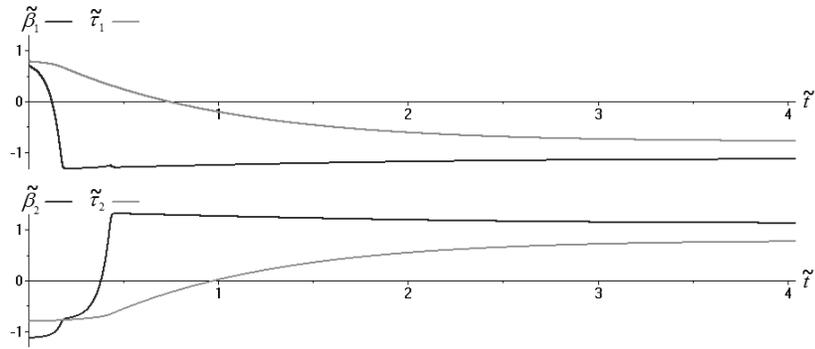


Рис. 10. Графики зависимости углов и напряжений от времени, соответствующие одному шагу кинезина, показанному на фазовых плоскостях рис. 9. Скачок в траектории $\tilde{\beta}_2$ соответствует переходу от С до D, связанному с отделением ГК-2 от МТ.

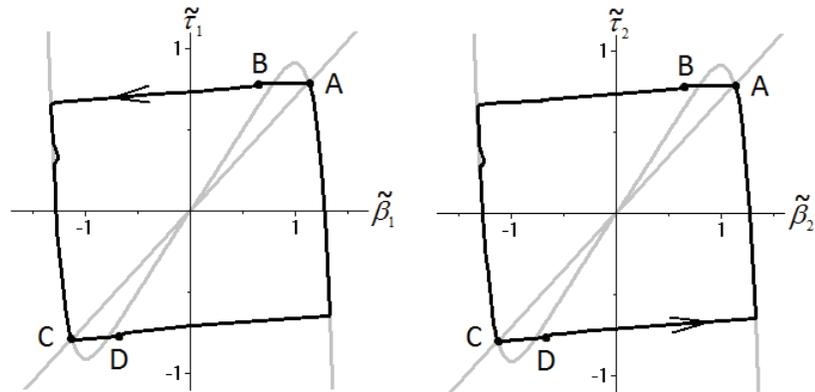


Рис. 11. Траектории на фазовых плоскостях ГК-1 и ГК-2 в случае избытка АТФ в среде. Стрелками указано направление движения соответствующих фазовых точек вдоль траекторий.

коэффициента диффузии АТФ в среде $\sim 1.5 \cdot 10^{-10} \text{ м}^2/\text{с}$ и площади входного отверстия «кармана» АЦ $\sim 2 \cdot 10^{-19} \text{ м}^2$.

В работе [25] экспериментально исследовалась зависимость скорости движения кинезина по микротрубочке с нагрузкой в виде бусинки из диок-

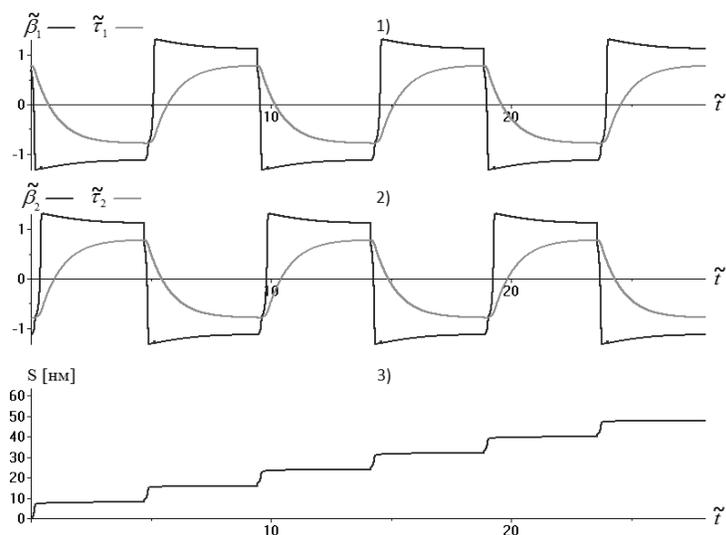


Рис. 12. 1), 2) — периодические (в противофазе) изменения углов $\tilde{\beta}_1$ и $\tilde{\beta}_2$, а также внутренних напряжений $\tilde{\tau}_1$ и $\tilde{\tau}_2$, соответствующие шагам кинезина в случае избытка АТФ в среде, изображенным на фазовых плоскостях рис. 11. 3) — продвижение кинезина вдоль МТ, соответствующее изменениям $\tilde{\beta}_1$ и $\tilde{\beta}_2$. Пройденный путь вычисляется как сумма всех произошедших шагов по 8 нм.

сида кремния (диаметр 0.5 мкм) от концентрации молекул АТФ. Движение бусинки контролировалось с помощью оптического пинцета с изменяемой силой [26]. Полученный нами результат качественно совпадает с экспериментальными данными, а именно, с увеличением концентрации АТФ скорость движения кинезина возрастает с тенденцией к насыщению. Однако, наши расчеты относятся к «реальному» случаю движения кинезина с грузом *in-vivo*, тогда как опыты в [25] проводились *in-vitro* при наличии постоянной силы, создаваемой лазерными пинцетами.

Окончим наш краткий анализ полученных решений следующей аналогией. «Шагание» кинезина с грузом по МТ подобно шаганию человека в акваланге по илистому дну водоема. Человек держит в вытянутой руке «груз» — баллон с водой. Так как и груз, и человека в воде можно считать невесомыми, то всю работу человек совершает против сил Стокса и на

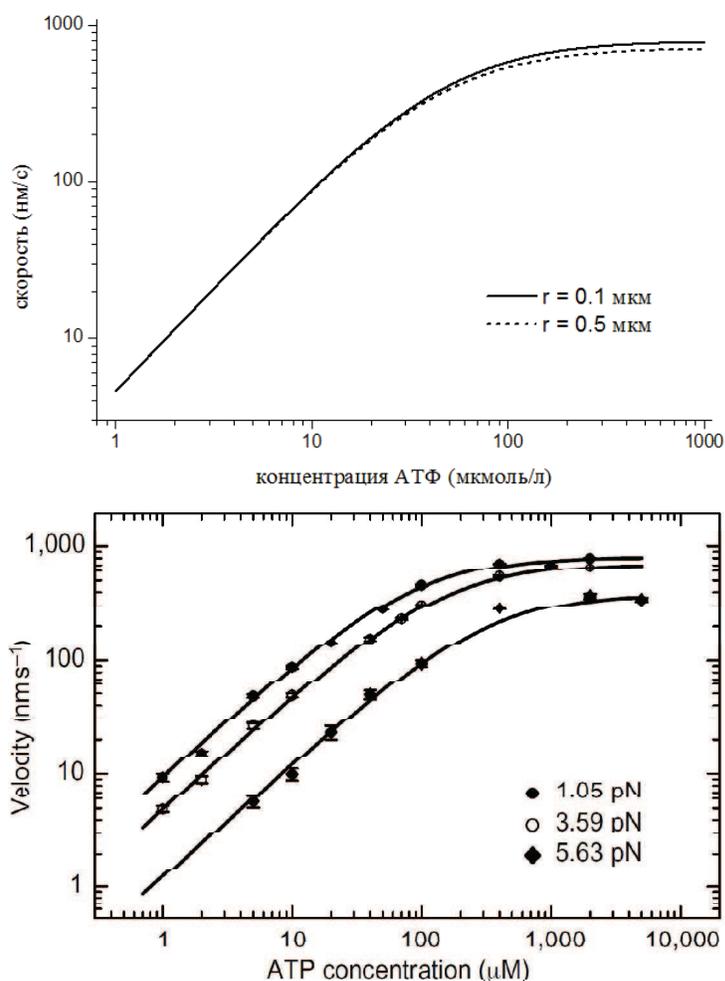


Рис. 13. Вверху: рассчитанные скорости шагания кинезина по МТ при разных концентрациях АТФ (r — радиусы переносимого груза). Внизу: экспериментальные кривые зависимости скорости от концентрации АТФ при разных действующих на груз силах [20].

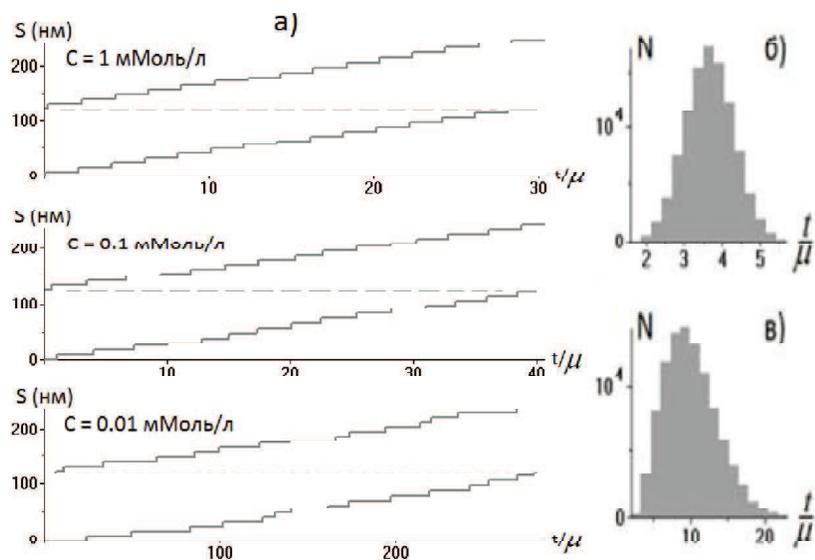


Рис. 14. а) развертки шагания кинезина при разных концентрациях АТФ (задержки, связанные с приходом АТФ в АЦ кинезина моделируются распределением Рэля и определяются концентрацией АТФ в среде); гистограммы длительности промежутков времени между шагами при концентрациях АТФ: б) 0.1 мМ/л, в) 0.01 мМ/л (параметры модели: $n = 11$, $k = 0.7$, $\zeta_1 = \zeta_2 = 0.002$, $\tilde{\epsilon}_1 = \tilde{\epsilon}_2 = 0.0007$, $\mu = 5$ мс).

выдергивание задней ноги из ила. В какой пропорции находятся энергии, затраченные на передвижение груза и на «выдергивание» ноги зависит от конкретных параметров системы.

Миозин V шагает по актиновым филаментам

Миозиновые моторы давно привлекают внимание исследователей, так как они играют главенствующую роль в мышечной подвижности [27]. В саркомерах мышечных клеток они работают сообща, обеспечивая проскальзывание АФ друг относительно друга. Но вот уже 20 лет известен индивидуально шагающий по АФ ММ — MV. Именно он участвует в транспор-

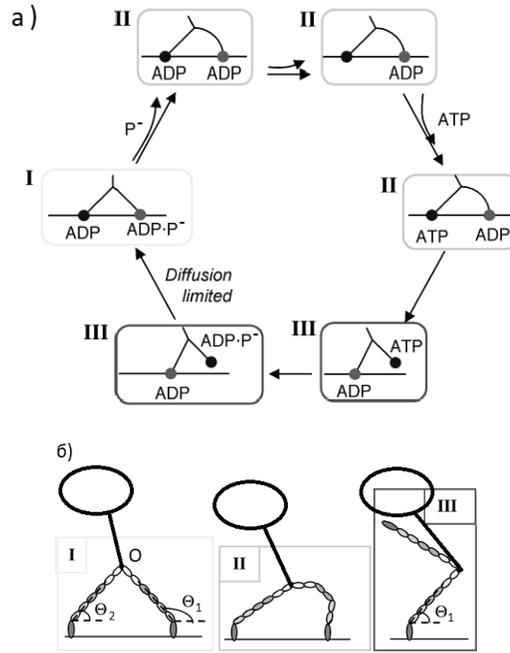


Рис. 15. Представлен механохимический цикл в соответствии с кинетической моделью MV [28]. На рис. а) показаны преобразования молекулы АТФ, попадающей в АЦ передней и задней головок (или моторных доменов MV), а на рис. б) показано, каким кинетическим переходам подвергается при этом димер MV через три различных механических состояния, а также продвижение груза.

те нейромедиаторов в синаптическом окончании. На рис. 15 представлена схема шагания MV из [27].

Ниже в качестве основных переменных мы будем принимать углы θ_1 и θ_2 (см. рис. 15). При этом в первом приближении считаем, что θ_1 меняется в пределах от 135° до 45° (или от $3\pi/4$ до $\pi/4$).

Важно заметить, что шарнир O на рис. 15, рис. 16 и груз движутся не в плоскостях рисунков, а так же, как и в случае кинезина (см. рис. 8), по веерообразным поверхностям. Соответствующее движение совершает и оторвавшаяся от АФ задняя головка. При этом переход MV из состо-

яния I в состояние III происходит с преодолением момента сил стокова сопротивления грузу, который по размерам превосходит «головку» на порядок. Таким образом, основное время шага при изменении Θ_1 от 135^0 до 45^0 определяется стоковым сопротивлением, тогда как поиск нового контакта задней оторвавшей головкой с АФ происходит в результате быстрой диффузии.

Ниже, на рис. 16, схематически представлена головка MV при ее контактах с АФ.

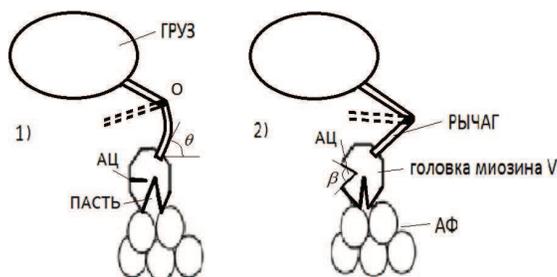


Рис. 16. Схема взаимодействия передней головки MV с АФ (по [27]).
 1) головка с открытой «пастью» контактирует с АФ, рычаг упруго деформирован. 2) в АЦ головки нет АТФ и продуктов реакции, пасть закрывается и стимулирует поворот рычага и продвижение груза.

Еще раз заметим, что при продвижении груза используется не только усилие рычага, но и момент упругих сил, порождаемый его деформацией (см. рис. 16 и [28]).

При сорбции АТФ в АЦ его карман закрывается (угол β на рис. 16 уменьшается), что вызывает открытие «пасти» и отсоединение головки от АФ. Для того, чтобы «пасть» снова закрылась с поворотом рычага в исходное положение, в АЦ должен произойти гидролиз АТФ и выход продуктов реакции из АЦ, а для этого требуется промежуток времени, который существенно больше, чем время протаскивания груза τ , определяемое и действующим моментом и стоковым сопротивлением грузу. После чего в случае нового контакта головки с АФ цикл повторяется.

Итак, головки MV работают поочередно. Будем считать, что при этом в передней головке АЦ происходит гидролиз АТФ и он освобождается от продуктов реакции, «пасть» закрывается и крепко связывается с АФ. Упругих усилий теперь достаточно, чтобы, во-первых, оторвать заднюю головку

от АФ, протаскать груз, который «на штанге» прикреплен к шарниру О (см. рис. 15), и забросить заднюю головку вперед. Как и в случае кинезина, задняя головка в результате диффузионного поиска находит очень быстро (за сотни пс) место прикрепления впереди на АФ.

Исходные оценки параметров и формулировка модели

Зададим следующие значения параметров, требуемых для моделирования:

- 1) длина шага $l = 36$ нм;
- 2) средняя сила по шагу F , действующая на груз, (измеряется лазерными пинцетами) от 1 до 1.5 пН;
- 3) энергия, затраченная на передвижение груза, $W = Fl \sim 4 \cdot 10^{-20}$ Дж;
- 4) длина плеча, продвигающего груз, $L = 20$ нм.

Мы считаем, что сила на протяжении шага действует неравномерно. Энергия АТФ $W_{\text{атф}} = 30.5$ кДж/моль $\sim 5 \cdot 10^{-20}$ Дж (см., например, [11]). Т. е. $W_{\text{атф}}$ примерно на 20% больше затрат на продвижение груза.

Оценим время одного шага, или «фронта ступеньки» (по аналогии с кинезином). Учитывая выражение (1) для силы Стокса, действующей на груз, получаем для момента силы Стокса, действующей против сил упругости при уменьшении угла Θ_1 :

$$M_c = 6\pi r (d\Theta_1/dt) L^2.$$

Пусть $r = 0.1$ мкм, $\eta = 20 \cdot 10^{-3}$ сН/м² (как и в [11]). Тогда время шага l равно:

$$\tau^* = 6\pi r l \eta / F \sim 1.5 \cdot 10^{-2} \text{ с.}$$

Тут мы не учитываем малое время на диффузионный поиск контакта «задней» с АФ. Длительность «плато ступеньки» $\sim 5 \cdot 10^{-2}$ с [28]. Отметим, что длительность плато много больше времени гидролиза АТФ. В действительности — это время высвобождения АЦ от осколков: АДФ и Р⁻.

Энергия растяжения линейной пружины: $K(\Delta x)^2/2 = W = 4 \cdot 10^{-20}$ Дж. Если $\Delta x = 0.5$ нм, то $K = 25 \cdot 10^{-2}$ Н/м.

Так как мы точно не знаем, как кинематически связаны углы закрытия АЦ при посадке в него АТФ и угол открытия «пасти», не знаем, как связано открытие «пасти» и напряжение пружины (дополнительное сжатие или растяжение), нам трудно описать зависимость момента, протаскивающего груз, от момента, который создает пружина с мало известными для

нас параметрами. Поэтому будем сразу оценивать эффективную упругую энергию, связанную с изменением угла Θ в передней ноге, которая и протаскивает груз при своем повороте на $\pi/2$.

Момент, который протаскивает груз, оценивается значением ~ 30 пН·нм. Это значение сравнимо с аналогичным и для АТФазы, и для кинезина. Будем считать, что упругая энергия, отдаваемая на перемещение груза, есть

$$K(\Delta\Theta)^2/2 = 0.8W_{\text{атф}} = 4 \cdot 10^{-20} \text{ Дж}; \quad (\Delta\Theta)^2 = (\pi/2)^2 \sim 2.5.$$

Значит, $K = (8/2.5) \cdot 10^{-20} \text{ Дж/рад}^2 \sim 0.3 \cdot 10^{-20} \text{ Нм}$. Заметим, что такое значение коэффициента упругости ниже оценок для модели F_1 АТФазы [11] и кинезина [18]. На самом деле, упругая энергия зависит от Θ нелинейно (см. расчеты в [28]). Поэтому, для полукачественных оценок можно принять и значение, большее в два раза.

Длительность «плато ступеньки» дает оценку параметра $\mu \sim 50$ мс. Момент силы Стокса, действующий на груз против момента сил упругости

$$M_1 = 6\pi rV\eta L = 6\pi r(d\Theta_1/dt)L^2\eta = \zeta_1(d\Theta_1/dt).$$

Момент силы Стокса при запасании упругой энергии

$$M_2 = 6\pi(0.1r)(d\Theta_2/dt)L^2\eta = \zeta_2(d\Theta_2/dt) = 0.1\zeta_1(d\Theta_2/dt).$$

Будем считать так, как и для кинезина, $r = 0.1$ мкм, $\eta = 20 \cdot 10^{-3} \text{ сН/м}^2$. Тогда получаем оценки параметров $\zeta_1 \sim 3 \cdot 10^{-23} \text{ сНм}$, $\zeta_2 \sim 3 \cdot 10^{-24} \text{ сНм}$.

Вводя безразмерное время и другие безразмерные величины подобно тому, как это сделано в случае кинезина (см. (7))

$$\tilde{t} = \frac{t}{\mu}, \quad \tilde{\zeta}_i = \frac{\zeta_i}{M_0\mu}, \quad \tilde{\tau}_i = \frac{\tau_i}{M_0}, \quad \tilde{k} = \frac{k}{M_0}; \quad i = 1, 2,$$

(где величина M_0 оценивается значением от 40 до 80 пНнм), получаем соответствующую систему уравнений в безразмерных переменных для одного шага MV:

$$\begin{aligned} \tilde{\zeta}_1 \dot{\tilde{\beta}}_1 &= \tilde{M}(\tilde{\beta}_1) - \tilde{\tau}_1 - \tilde{\varepsilon}_1 \dot{\tilde{\beta}}_2, & \tilde{\zeta}_2 \dot{\tilde{\beta}}_2 &= \tilde{M}(\tilde{\beta}_2) - \tilde{\tau}_2 + \tilde{\varepsilon}_2 \dot{\tilde{\beta}}_1, \\ \dot{\tilde{\tau}}_1 &= \tilde{k} \tilde{\beta}_1 - \tilde{\tau}_1, & \dot{\tilde{\tau}}_2 &= \tilde{k} \tilde{\beta}_2 - \tilde{\tau}_2. \end{aligned} \quad (8)$$

Здесь взаимосвязь кинематических углов MV и безразмерных фазовых переменных системы уравнений описывается формулой

$$\Theta_i = \frac{\pi}{4}(2 - \tilde{\beta}_i); \quad i = 1, 2. \quad (9)$$

Соответственно, во время шага Θ_1 уменьшается от $3\pi/4$ до $\pi/4$, а Θ_2 изменяется от $\pi/4$ до $3\pi/4$. Далее Θ_1 и Θ_2 меняются местами. Момент $\tilde{M}(\tilde{\beta})$ задается формулой (6). Значения безразмерных коэффициентов системы вычисляются с помощью полученных выше оценок для соответствующих размерных параметров модели.

Результаты моделирования шагания миозина V

Сначала, как и в случае кинезина, приведем фазовые плоскости модели и развертки решений для взаимодействующих моторных доменов (или головок) MV (рис. 17). Заметим, что решения или движения изображающей точки на фазовых плоскостях отмечены темной линией. При медленных движениях в силу релаксационности системы они практически совпадают с ветвями главных изоклин (изображены светлыми линиями).

Переход фазовой изображающей точки через барьер (от A до B) возможен только, если в открытый АЦ «задней» ноги пришла АТФ, карман АЦ закрывается, «пасть» открывается, энергия запасается при изменении Θ_B от $\pi/4$ до $3\pi/4$. Стоксова работа при этом очень мала.

Запасенная «упругая» энергия освобождается при осуществлении шага (переход от токи C до D) и идет на работу по протаскиванию груза и на «выдергивание» задней ноги (или головки) MV из потенциальной ямы на АФ.

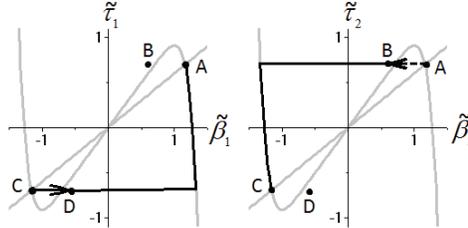


Рис. 17. Траектории шагов MV на фазовых плоскостях ГМ-1 (слева) и ГМ-2 (справа)

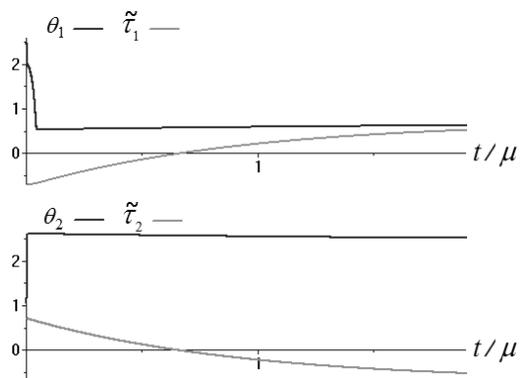


Рис. 18. Изменения кинематических углов Θ_1 и Θ_2 (в противофазе), а также упругих напряжений, соответствующие одному шагу MV, показанному на фазовых плоскостях ГМ-1, ГМ-2 рис. 17 (μ)

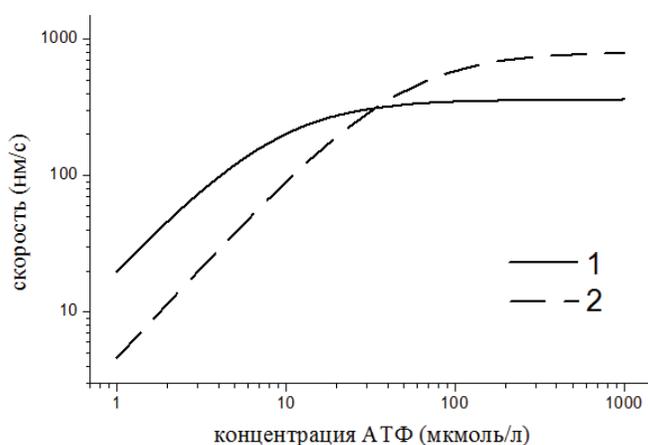


Рис. 19. Зависимость скорости шагания MV по АФ в зависимости от концентрации АТФ (1) и, для сравнения, соответствующие значения скорости кинезина (2), шагающего по МТ (в обоих случаях радиус перетаскиваемого груза $r = 0.1$ мкм). Параметры модели: $L = 20$ нм, $n = 11$, $\tilde{k} = 0.6$, $\tilde{\zeta}_1 = 0.015$, $\tilde{\zeta}_2 = 0.0015$, $\tilde{\varepsilon}_1 = 0.005$, $\tilde{\varepsilon}_2 = 0.0005$, $\mu = 50$ мс

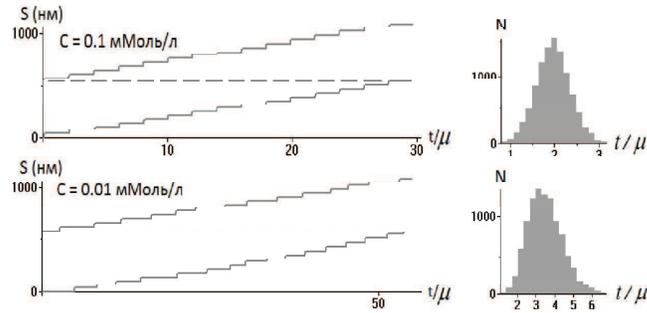


Рис. 20. Развертки шагов MV (слева) и гистограммы длительности промежутков времени между шагами (справа) при концентрациях АТФ: сверху — 0.1 мМ/л, внизу — 0.01 мМ/л ($\mu = 50$ мс). Задержки, связанные с приходом АТФ в АЦ MV моделируются распределением Рэля и определяются концентрацией АТФ в среде. Параметры модели такие же, как и на рис. 19

Основное отличие моделей кинезина и MV состоит в следующем. Сорбция АТФ в АЦ кинезина приводит к генерации момента, продвигающего груз против сил Стокса. Сорбция АТФ в АЦ MV приводит к запасанию упругой энергии. При этом внутренние потери на стоковое сопротивление малы. Шаг же MV и протаскивание груза осуществляет при расходовании запасенной энергии упругой деформации.

Теперь критика нашей упрощенной модели

За последние годы появились буквально сотни работ, посвященных экспериментальному и теоретическому изучению различных миозинов и, в том числе, миозину V. По сравнению с кинезином в этом деле есть следующие трудности и нерешенные проблемы:

- 1) Нет полного представления о кинематической связи АТФазного АЦ с раскрытием «пасти» и механизма создания запаса упругой энергии.
- 2) Нет хороших (для нас) сведений о взаимодействии головок миозина с АЦ актинового филамента в разных состояниях «пасти». Это связано с тем, что рентген делается для миозина, не соединенного с АФ.
- 3) Если кинезин шагает преимущественно строго по своим путям на

- МТ (а этих путей до 11!), то миозин шагает по АФ не обязательно по прямой. Прикрепление вдоль АФ может происходить по спирали.
- 4) Если движение шарнира с прикрепленным грузом у кинезина происходит преимущественно в одной плоскости, т. е. «по вееру» (см. рис. 8), то шарнир миозина V движется довольно сложно по двум координатам и неравномерно (в [29] это хорошо изучено с помощью точных лазерных пинцетов, измеряющих движения и усилия по двум направлениям).
 - 5) Многие авторы подчеркивают, что диффузионный поиск оторванной ноги после продвижения шарнира на 36 нм длится хотя и не долго, но может привести к ассоциации с АЦ АФ вовсе не в той «плоскости», в которой движется груз [30, 31].
 - 6) Для нас остается неясным, чем кодируется: формой «башмака» (т. е. головки или моторного домена) или же формой потенциальных ям на МТ или АФ направление движения как миозина V, так и кинезина. Кстати: как узнает перевозчик, какой груз и в какую сторону тащить (об этом см. [9])?
 - 7) Математическая модель для быстрых динеиновых моторов еще требует разработки.
 - 8) Интересно понять, как предложенные нами модели могут быть использованы в таких процессах, как митоз [7].

В заключение подчеркнем еще раз, какие трудности и нерешенные проблемы мешают усовершенствованию математических моделей ММ. Это прежде всего уточнение параметров μ и k . Для их определения необходимо применение методов молекулярной динамики (МД). Для определения развития усилий в кармане АЦ при сорбции в нем молекулы АТФ Дж. Остер [5] развивает методы, которые позволяют определять динамику образования многочисленных водородных связей, связывающих АТФ и продукты ее гидролиза АДФ и P^- с карманом АЦ. В его же трудах рассчитываются упругие напряжения в субглобулах ММ и, в частности, в АТФазе. Методы МД применяются школой Карплюса [22] с использованием данных не только биохимической кинетики, но и рентгеноструктурного анализа для изучения кинезина. В работах [32, 33] строятся модели подвижности «активных» броуновых частиц в различных потенциальных рельефах и изучаются общие свойства ММ в этих моделях.

Окончим лекцию следующим утверждением. Математические модели рассмотренных ММ так же, как и уравнения ФитцХью-Нагумо, и мно-

гие другие модели активных систем в биофизике, можно свести к системам двух или трех обобщенных уравнений Рэлея. При этом их параметры идентифицируются из экспериментальных данных [11, 24, 35].

Благодарности. Авторы благодарны *А. Н. Тихонову, А. К. Цатурияну, В. Эбелингу, Д. С. Чернавскому* и *А. В. Латанову* за консультации и дискуссии.

Работа поддержана грантом РФФИ 13-02-01177А.

Литература

1. Чернавский Д. С., Хургин Ю. И., Шноль С. Э. Об упругих деформациях белка-фермента // *Мол. биол.* – 1 (3), 419 (1967).
2. Чернавский Д. С., Чернавская Н. М. Белок-машина. Биологические и макромолекулярные конструкции. – М.: Янус-К, 1999.
3. R. D. Vale Lab.
URL: <http://valelab.ucsf.edu/>
4. S. M. Block Lab.
URL: http://stanford.edu/group/block_lab/
5. G. Oster Lab.
URL: <http://www.cnr.berkeley.edu/goster/home.html>
6. J. Walker Lab.
URL: <http://www.biosci.missouri.edu/Walker/>
7. Лаборатория Фазли Аталлуханова
URL: fazly.ru/index.php/ru
8. *Squire L. R., Berg D., Bloom F. E., du Lac S., Ghosh A., Spitzer N. C.* Fundamental neuroscience: 3rd Ed. – San Diego–London: Academic Press, 2008.
9. *Латанов А. В.* Курс лекций «Общая нейрофизиология». – МГУ, 2013.
10. *Xing J., Liao J.-C., and Oster G.* Making ATP // *Proc. Natl. Acad. Sci. USA.* – 2005, **102**. – pp. 16539–16546.
11. *Романовский Ю. М., Тихонов А. Н.* Молекулярные преобразователи энергии живой клетки. Протонная АТФ-синтаза — вращающийся молекулярный мотор // *УФН.* – 2010. 180. – С. 931–956.
12. *Тихонов А. Н.* Молекулярные моторы. Часть 1. Вращающиеся моторы // *Соровский образовательный журнал.* – 1999, № 6. – С. 8–16.
13. *Pogrebnaya A, Romanovsky Yu. and Tikhonov A.* Rotation of ATPase: The stochastic model. Fluctuation and noise Letters // *FNL.* – 2005. – Vol. 5, No 2. – pp. L217–L224.

14. *Ebeling W., Schimansky-Geier L., Romanovsky Yu. (eds.) Stochastic Dynamics of Reacting Biomolecules.* – Singapore: World Scientific, 2002, ISD 981-238-162-7.
15. Молекулярная динамика ферментов. Ред. Романовский Ю. М., Эбелинг В. Авторы: Валувев А. А., Гришанин Б. А., Йенсен М., Кроо С. В., Нетребко А. В., Нетребко Н. В., Подлипчук В. Ю., Романовский Ю. М., Сапежинский М. Г., Чикишев А. Ю., Чичигина О. А., Шиманский-Гайер Л., Шувалова Е. В., Эбелинг В. – Изд. МГУ, 2000. – 170 с.
16. *Kathleen M. Trybus. Myosin V from head to tail. // Cell Mol Life Sci.* – May 2008, **65**(9): 1378–1389. doi:10.1007/s00018-008-7507-6.
17. *Тихонов А. Н. Молекулярные моторы. Часть 2. Молекулярные основы биологической подвижности // Соровский образовательный журнал.* – 1999, № 6. – С. 17–24.
18. *Романовский Ю. М., Карговский А. В., Приезжев А. В., Трифоненков В. П. Внутриклеточная автоволновая гидродинамика и молекулярные моторы // Труды XII Международной научно-технической конференции Оптические методы исследования потоков 25–28 июня 2013 г. Изд-во «Перо».* – М. НИУ «МЭИ», с. 1–21.
19. *Asbury C. L., Fehr A. N., Block S. M. Kinesin moves by an asymmetric hand-over-hand mechanism // Science.* – 2003/, **302**. – pp. 2130–2134.
20. *Schnitzer M. J., Visscher K. and Block S. M. Mechanism of force production by single kinesin motors // Nature Cell Biology.* – 2000, **2**. – pp. 718–723.
21. *Sindelar C. V., Downing K. H. An atomic-level mechanism for activation of the kinesin molecular motor // Proc. Natl. Acad. Sci. USA.* – 2010, **107**. – pp. 4111–4116.
22. *Hwang W., Lang M. J. and Karplus M. Force generation in kinesin hinges on cover-neck bundle formation // Structure.* – 2008, **16**. – pp. 62–71.
23. *Sept T D., Backer N. A., Mccammon J. A. The physical basis of microtubule structure and stability // Protein Science.* – 2003, **12**. – pp. 2257–2261.
24. *Romanovsky Yu. M., Kargovsky A. V. and Ebeling W. Models of active brownian motors based on internal oscillations // European Physical Journal: Special Topics.* – 2013, **222**: 2465–2479.
25. *Visscher K., Schnitzer M. J., Block S. M. Single kinesin molecules studied with a molecular force clamp // Nature Lett.* – 1999, **400**, 184.
26. *Svoboda K., Block S. M. Biological applications of optical forces // Annu. Rev. Biophys. Biomol. Struct.* – 1994, **23**, 247.
27. *Кубасова Н. А., Цатурян А. К. Молекулярный механизм работы актин-миозинового мотора в мышце // УБН.* – 2011, **51**. – С. 233–282.

28. *Craig E. M. and Linke H.* Mechanochemical model for myosin V // *PNAS*. – October 27, 2009, Vol. 106. – pp. 18261–18266.
29. *Cappello G. et al.* Myosin V stepping mechanism // *PNAS*. – 2007, **104**(39). – pp. 15328–15333.
30. *Hinczewskia M., Tehverb R. and Thirumalaia D.* Design principles governing the motility of myosin V // *PNAS* | Published online. – October 7, 2013 | E4059–E4068.
31. *Watanabe T.M., Iwane A.H., Tanaka H., Ikebe M., Yanagida T.* Mechanical Characterization of One-Headed Myosin-V Using Optical Tweezers // *PLOS ONE*. – 1 August 2010, Vol. 5, Issue 8, e12224, pp. 1–8. URL: www.plosone.org
32. *Hänggi P., Marchesoni F.* Artificial Brownian motors: Controlling transport on the nanoscale // *Rev. Mod. Phys.* – 2009, **81**, 387–442.
33. *Romanczuk P., Baer M., Ebeling W., Lindner B., Schimansky-Geier L.* Active Brownian particles. From individual to collective stochastic dynamics // *Eur. Phys. J. Special Topics*. – 2012, **202**, 1.
34. *Romanczuk P., Ebeling W., Erdmann U., Schimansky-Geier L.* Activ particles with broken symmetry // *Chaos*. – 2011, **21**, 047517.
35. *Лаврова А. И., Постников Е. Б., Романовский Ю. М.* Брюсселятор — абстрактная химическая реакция? // *УФН*. – 2009, **179**. – С. 1327–1332.

Юрий Михайлович РОМАНОВСКИЙ, доктор физико-математических наук, профессор физического факультета МГУ им. М. В. Ломоносова, Москва. Область научных интересов: синергетика, биофизика, радиофизика, молекулярная динамика. Имеет более 200 публикаций.

Алексей Владимирович КАРГОВСКИЙ, кандидат физико-математических наук, доцент физического факультета МГУ им. М. В. Ломоносова, Москва. Область научных интересов: лазерная физика, молекулярная динамика, биофизика. Имеет более 50 публикаций.

Владимир Петрович ТРИФОНЕНКОВ, кандидат физико-математических наук, доцент НИЯУ «МИФИ», Москва. Область научных интересов: обратные задачи математической физики, биофизика, математическое моделирование в электронной микроскопии. Имеет более 40 публикаций.

Андрей Владимирович ТРИФОНЕНКОВ, аспирант НИЯУ «МИФИ», Москва. Область научных интересов: математическое моделирование переходных процессов в ядерных реакторах, биофизика. Имеет 4 публикации.

**А. А. ФРОЛОВ^{1,2}, А. В. АЛЕКСАНДРОВ¹,
П. Д. БОБРОВ¹, Е. В. БИРЮКОВА^{1,2}**

¹Институт высшей нервной деятельности и нейрофизиологии РАН,
Москва

²Российский национальный исследовательский медицинский университет
им. Н. И. Пирогова, Москва
E-mail: aafrolov@mail.ru

БИОЛОГИЧЕСКИ АДЕКВАТНЫЕ ПРИНЦИПЫ УПРАВЛЕНИЯ ДВИЖЕНИЯМИ ЭКЗОСКЕЛЕТОВ КОНЕЧНОСТЕЙ ЧЕЛОВЕКА

Аннотация

Восстановление движений — одна из важнейших задач нейрореабилитации после инсульта. Для ее решения в настоящее время активно разрабатываются экзоскелеты конечностей, управляемые интерфейсом «мозг-компьютер». Однако прогресс в разработке таких экзоскелетов упирается в недостаточное применение принципов управления движениями человека со стороны центральной нервной системы (ЦНС). При разработке биологически адекватных экзоскелетов предполагается использовать два таких принципа: 1) формирование двигательных синергий — координации суставных углов и моментов сил в суставах при движениях многосуставной конечности; 2) управление моментом сил в суставах по обратной связи от суставных углов с задержкой по времени.

**A. A. FROLOV^{1,2}, A. V. ALEXANDROV¹,
P. D. BOBROV¹, E. V. BIRYUKOVA^{1,2}**

¹Institute of Higher Nervous Activity and Neurophysiology
of the Russian Academy of Sciences, Moscow

²Pirogov Russian National Research Medical University, Moscow

E-mail: aafrolov@mail.ru

BIOLOGICALLY ADEQUATE PRINCIPLES OF MOVEMENT CONTROL OF HUMAN EXTREMITIES EXOSKELETONS

Abstract

Post-stroke movement recovery is an important task of neurorehabilitation. To solve it, exoskeletons of human extremities controlled by brain-computer interface are utilized. However the development of exoskeletons is restricted by not sufficient using the principles of human movement control by the central nervous system. Here, two such principles are suggested: 1) the creation of motor synergies, i.e. coordination of joint angles and joint torques during the movement of multi-joint human extremities; 2) joint torque control by a feedback from joint angles with the time delay.

Введение

В последние годы активно развивается применение роботов (ортезов, экзоскелетов) для двигательной реабилитации постинсультных и посттравматических больных. Одним из импульсов такого развития явилось обнаружение пластических изменений функциональной топографии первичной моторной коры в результате тренировки (Nudo et al., 1996). Довольно быстро было показано, что движение может восстановиться даже через несколько лет после того, как произошел инсульт (Bach-Y-Rita, 2001; Taub et al., 2002). Это открыло новые возможности для нейрореабилитации: были разработаны принципы интенсивной, регулярной и мотивированной тренировки движений (Kwakkel et al., 1999). Экзоскелеты оказались идеальным техническим устройствами, обеспечивающими реализацию этих принципов. Различные виды экзоскелетов уже активно применяются в клинике, а количество их разработок в последние 10 лет экспоненциально растет (Marchal-Crespo & Reinkensmeyer, 2009).

Можно привести следующие примеры экзоскелетов, успешно применяющихся для нейрореабилитации:

- ARM-Guide (Assistant Rehabilitation and Measurement Guide), который может активно способствовать (или препятствовать) движениям в локте и плече (Reinkensmeyer et al., 2000);
- MIME (Mirror-Image Movement Enabler), с помощью которого можно управлять движением предплечья и кисти по сигналам от здоровой руки (Lum et al., 2002);
- BI Manu Track, стимулирующий сгибание-разгибание кисти и пронацию-супинацию предплечья обеих рук (Hingtgen et al., 2006);
- NeRobot (Neuro Rehabilitation Robot), обеспечивающий движения в трех степенях подвижности в плече и двух в локте (Masiero et al., 2007);
- Haptic Master, не навязывающий «правильное» движение, а лишь исправляющий отклонения от него (Amirabdollahian et al., 2007);
- T-WREX (Therapy Wilmington Robotic Exoskeleton), имеющий возможность блокировать «ненужные» (для тех или иных лечебных упражнений) степени подвижности (Iwamuro et al., 2008).

Экзоскелеты часто сопрягаются с компьютерной игрой, в которой курсор отражает движение рабочей точки руки (джойстика в руке пациента). В суставах некоторых экзоскелетов применяется пассивный пружинный механизм, обеспечивающий регулируемую разгрузку тренируемой руки. В других экзоскелетах применяется активное управление суставами: их приводы реализуют некоторое «правильное» движение. Некоторые протоколы реабилитации предусматривают формирование «правильного» движения в ходе компьютерной игры с настраиваемыми параметрами. В других протоколах врач выполняет движения пассивной рукой пациента, эти движения регистрируются, а затем воспроизводятся с помощью экзоскелета. Проведение реабилитационных процедур с использованием перечисленных экзоскелетов предполагает либо наличие остаточных движений паретичной руки, либо ее пассивные движения, осуществляемые экзоскелетом. Сопряжение экзоскелета с интерфейсом мозг-компьютер позволяет активно управлять движениями паретичной руки даже при полной потере ее двигательных функций. Интерфейс мозг-компьютер осуществляет управление экзоскелетом непосредственно сигналами мозга, сопровождающими воображение движения. Известно, что воображение движения активирует те же области мозга, что и его исполнение (Decety et al., 1995; Berthoz, 1996; Lotze & Halsband, 2006). Предполагается, что конвергенция центральной

двигательной команды и периферийных сигналов о ее исполнении с помощью экзоскелета создает наилучшие условия для запуска пластических механизмов мозга, направленных на восстановление двигательных функций (Daly J. J. & Wolpaw, 2008). Получены первые данные об эффективности реабилитационной процедуры с использованием системы экзоскелет + ИМК (Котов, 2015).

В обзорах принципов действия экзоскелетов отмечают два аспекта: один, безусловно, положительный, состоит в эффективности использования экзоскелетов в практике постинсультной реабилитации; другой состоит в том, что прогресс в разработке более совершенных экзоскелетов упирается в недостаточное понимание принципов управления движением со стороны центральной нервной системы (ЦНС) (Ferris., 2009). Однако даже известные принципы управления движением в живом организме пока мало используются при разработке системы управления экзоскелетом. В настоящей статье излагаются два таких принципа:

- формирование двигательных синергий — координации суставных углов и моментов сил в суставах при движениях многосуставной конечности;
- управление моментом мышечных сил в суставах по обратной связи от суставных углов с временной задержкой, характерной для живых организмов.

Применение этих принципов иллюстрируется с помощью динамической модели тела человека целиком или отдельных его исполнительных органов, поэтому обсуждению указанных принципов предшествует общее описание используемой динамической модели. Кратко описан также опыт применения этих принципов для управления роботом PostuRob II, движения которого обеспечиваются пневматическими мышцами, имеющими задержки в петле управления по обратной связи, сравнимые с наблюдаемыми у человека (Александров и др., 2013).

Уравнения движения системы связанных твердых тел

Для получения уравнений движения мы использовали подход, разработанный профессором МФТИ *Г.В. Корневым* еще в 70 гг. прошлого века (Корнев, 1979). Примерно в то же время был разработан схожий подход американским исследователем *Кэйном* (Kane & Levinson, 1985), который

используется во многих современных программных продуктах, предназначенных для анализа движений сложных механических систем (например, HbmTBX, разработанный Оттенем (Otten, 1999), или SD/FAST, разработанный фирмой Symbolic Dynamics, Inc). Суть подхода Коренева состоит в получении уравнений Лагранжа с помощью тензорной свертки.

Пусть тело представлено в виде N твердых сегментов, соединенных идеальными шарнирами. Такое приближение справедливо для большинства движений человека (Winter, 1990). В результате преобразований, предложенных Кореневым, можно перейти от описания движений отдельных сегментов в форме уравнений Ньютона-Эйлера к стандартным уравнениям Лагранжа в терминах обобщенных координат и обобщенных сил:

$$I(\Psi)d^2\Psi/dt^2 + C(\Psi) \times_1 d\Psi/dt \times_2 d\Psi/dt = G + Q_m + J_{ext}^T F_{ext}, \quad (1)$$

где Ψ – вектор обобщенных координат, размерность которого равна числу степеней свободы L , I – матрица инерции, $G = -\text{grad}_\Psi P$ – обобщенные гравитационные силы (P – потенциальная энергия тела в гравитационном поле), Q_m – вектор обобщенных сил, производимых мышечными силами или силовыми моментами моторов, F_{ext} – вектор внешних контактных сил, J_{ext} – якобиан, определяющий перемещение точек r_{ext} приложения внешних сил F_{ext} по формуле $dr_{ext}/dt = J_{ext}d\Psi/dt$, C – тензор, определяющий кориолисовы и центробежные силы, где выражение $C \times_1 d\Psi/dt \times_2 d\Psi/dt$ означает, что

$$(C \times_1 d\Psi/dt \times_2 d\Psi/dt)_i = \sum_{jk} C_{ijk} \cdot d\Psi_j/dt \cdot d\Psi_k/dt.$$

Заслуга Коренева состоит в том, что он получил явные выражения для всех членов уравнения Лагранжа, включая кориолисовы силы, в частности, им показано, что тензор C можно выразить через матрицу инерции:

$$C_{ijk} = 1/2 (\partial I_{ij} / \partial \Psi_k + \partial I_{ik} / \partial \Psi_j - \partial I_{jk} / \partial \Psi_i).$$

Явные выражения для всех членов уравнения движения позволяют переписать его в символьном виде и, соответственно, существенно (на порядок) сократить время интегрирования этих уравнений. Эти выражения особенно просты, если в качестве обобщенных координат используются эйлеровы углы. Для расчета масс, тензоров инерции и положений центров масс для каждого из сегментов руки или тела были использованы антропометрические таблицы (Winter, 1990). Вектор обобщенных сил Q_m может

быть выражен через мышечные усилия в случае биомеханической модели тела или через силовые моменты моторов при моделировании робота. В первом случае $Q_m = M_F^T F_m$, где F_m — вектор мышечных сил, а M_F — матрица, задающая плечи всех мышечных сил в соответствии с формулой $dl/dt = M_F d\Psi/dt$, где l — вектор длин мышц. Во втором случае $Q_m = M_T^T T_m$, где T_m — вектор силовых моментов моторов, а M_T — матрица, задающая преобразование обобщенных координат Ψ в углы вращения вокруг осей моторов Γ в соответствии с формулой $d\Gamma/dt = M_T d\Psi/dt$. Естественно, матрицы M_F и M_T зависят от конструкции силовых приводов.

При моделировании движений руки мы ограничились системой из трех сегментов (плечо, предплечье и кисть) с числом степеней свободы $L = 7$ (рис. 1): сгибание–разгибание, приведение–отведение и вращение в плечевом суставе, сгибание–разгибание и пронация–супинация в локтевом суставе, сгибание–разгибание и приведение–отведение в лучезапястном суставе. Плечевой сустав моделировался шаровым шарниром, локтевой и лучезапястный — шарнирами с двумя ортогональными осями.

При моделировании тела человека (кроме рук) мы ограничились системой из 9 сегментов: 1) голова, 2) верхняя часть корпуса, включая грудь, голову и руки, 3) нижняя часть корпуса, включающая таз, 4) два бедра, 5) две голени, 6) две стопы. Верхняя и нижняя части корпуса полагались соединенными идеальным шаровым шарниром, тазобедренные суставы также полагались шаровыми шарнирами, коленные — цилиндрическими, а голеностопные — шарнирами, обеспечивающими поворот во фронтальной и сагиттальной плоскостях. В модели учитывалось движение головы только вокруг центральной оси тела. Таким образом, максимально (в свободном полете, например, в фазе полета прыжка или бега) модель имеет $L = 36$ степени свободы (например, 3 координаты и 3 эйлеровых угла поворота относительно некоторой неподвижной системы координат для тазового сегмента, 3 эйлеровых угла поворота для верхней части корпуса относительно таза, 1 угол поворота головы вокруг центральной оси тела, 7 степеней свободы на каждую руку, 3 эйлеровых угла поворота для каждого бедра относительно таза, по одному углу поворота для каждой голени относительно бедра и по два угла поворота для каждой стопы относительно голени). При стоянии на одной ноге (например, в фазе опоры на одну ногу при ходьбе) 6 степеней свободы замораживаются (координаты и углы поворота стопы опорной ноги) и у модели тела остается 30 степеней свободы. При стоянии на двух ногах еще шесть степеней свободы замораживаются и у модели

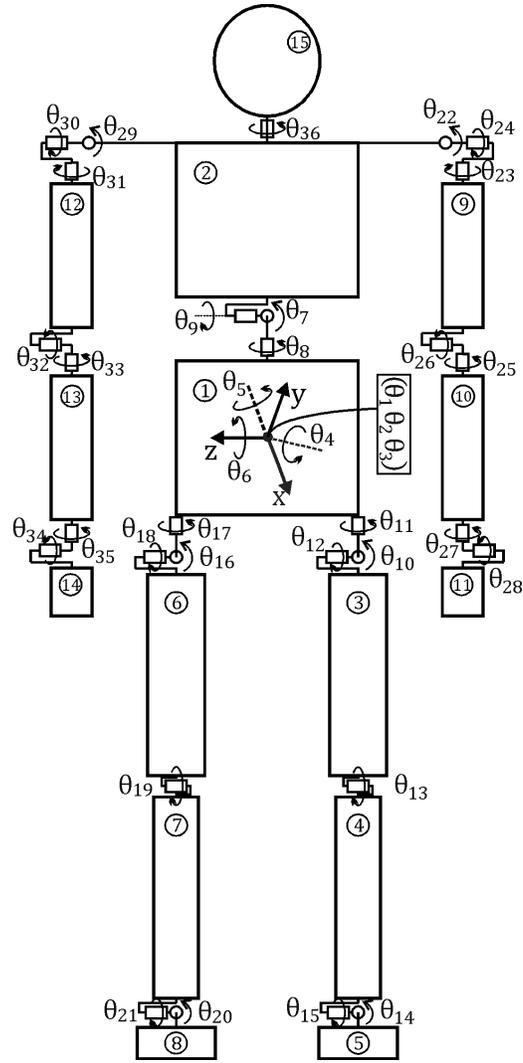


Рис. 1. Конструкция робота, имеющего 36 степеней свободы и управляемого 30 моторами

тела остается 24 степени свободы. Для каждого из этих случаев получены уравнения движения, основанные на замораживании соответствующих степеней свободы введением ограничивающих внешних сил.

Конструкция модели робота с $L = 36$ степенями свободы, управляемого 30 моторами, обеспечивающими заданные силовые моменты вращения вокруг своих осей, показана на рис. 1. Координатные оси каждого звена совмещены с главными осями его тензора инерции, а начало каждой связанной системы координат совмещено с центром масс соответствующего звена. Предполагается, что в исходном состоянии ось неподвижной системы совмещена с системой координат (СК), связанной с тазом, так что ось X направлена вперед, ось Y — вверх, а ось Z образует с ними правую тройку. Предполагается также, что в исходном состоянии все связанные СК имеют оси, направленные вдоль соответствующих осей неподвижной СК.

В качестве обобщенных координат выбраны три координаты центра масс тазового сегмента относительно неподвижной СК, угол поворота головы относительно верхнего сегмента корпуса, по три эйлеровых угла для каждого плечевого сустава, по два эйлеровых угла для каждого локтевого и лучезапястного сустава, три эйлеровых угла поворота таза относительно неподвижной СК, 3 эйлеровых угла поворота верхнего сегмента корпуса относительно таза, по 3 эйлеровых угла поворота каждого бедра относительно таза, углы поворота каждой голени относительно бедра и по 2 эйлеровых угла поворота стопы относительно голени.

Эйлеровы углы поворотов в каждом суставе зависят только от поворотов вокруг осей моторов в том же суставе. Пусть исходно оси моторов направлены вдоль осей неподвижной системы. Тогда в исходном состоянии первые три мотора, вращают верхний сегмент корпуса относительно таза, изменяя углы θ_7 , θ_8 и θ_9 , следующие три мотора вращают левое бедро относительно таза, изменяя углы θ_{10} , θ_{11} и θ_{12} и в целом мотор с номером i изменяет угол θ_{6+i} . Как видно из рис. 1, первые шесть строк матрицы M_T^T , определяющей связь между обобщенными силами и силовыми моментами моторов, равны нулю, $M_{T\,7,1}^T = 1$, $M_{T\,8,2}^T = 1$, $M_{T\,8,3}^T = \sin \theta_7$, $M_{T\,9,3}^T = \cos \theta_7$, $M_{T\,10,4}^T = 1$, $M_{T\,11,5}^T = 1$, $M_{T\,11,6}^T = \sin \theta_{10}$, $M_{T\,12,6}^T = \cos \theta_{10}$, $M_{T\,13,7}^T = 1$, $M_{T\,14,8}^T = 1$, $M_{T\,15,9}^T = 1$, $M_{T\,16,10}^T = 1$, $M_{T\,17,11}^T = 1$, $M_{T\,17,12}^T = \sin \theta_{16}$, $M_{T\,18,12}^T = \cos \theta_{16}$, $M_{T\,19,13}^T = 1$, $M_{T\,20,14}^T = 1$, $M_{T\,21,15}^T = 1$, аналогично для моторов, вращающих сегменты рук и голову. Остальные элементы матрицы равны нулю.

Уравнения движения робота при ограничении числа степеней свободы

В случае стояния робота на одной ноге одна из его стоп фиксирована относительно неподвижной системы координат. Для задания положения и ориентации этой стопы в пространстве фиксируем координаты трех точек на границе подошвы в неподвижной системе координат (рис. 2). Пусть координаты этих точек относительно центра масс стопы составляют $r_1 = (a_1, -a_2, a_3)^T$, $r_2 = (a_1, -a_2, -a_3)^T$, $r_3 = (-a_1, -a_2, 0)^T$, то есть они находятся на a_3 ниже центра масс стопы, две точки находятся на передней границе стопы, а одна — на пятке. Длина стопы при этом составляет $2a_1$, а ширина $2a_2$.

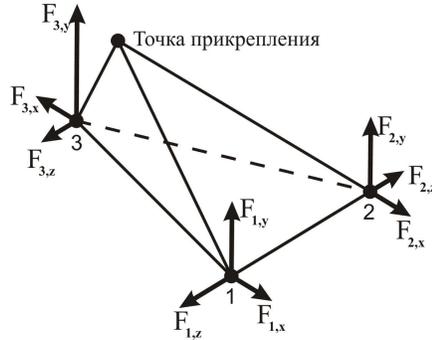


Рис. 2. Схема приложения фиксирующих сил на стопе

Скорость перемещения каждой из этих точек в неподвижной системе координат задается уравнением $v_i = J_i d\Psi/dt$ ($i = 1, \dots, 3$), где J_i — якобиан, связывающий скорость i -й точки на стопе со скоростью изменения обобщенных координат. Скорость всех трех точек можно задать уравнением $v = J d\Psi/dt$, где $v = (v_1; v_2; v_3)$ — вектор, объединяющий скорости трех точек, $J = (J_1; J_2; J_3)$ — их общий якобиан, имеющий размерность $9 \times L$, где для рассматриваемого робота общее число степеней свободы $L = 36$. Поскольку точки должны быть неподвижны, должны выполняться равенства $J d\Psi/dt = 0$ и

$$J d^2 \Psi/dt^2 + H \times_1 d\Psi/dt \times_2 d\Psi/dt = 0, \quad (2)$$

где $H_{ijk} = \partial J_{ij} / \partial \Psi_k$.

Уравнение (1) можно переписать в виде

$$I d^2 \Psi / dt^2 = T + J^T F, \quad (3)$$

где $T = G + Q_m + J_{ext}^T F_{ext} - C(\Psi) \times_1 d\Psi/dt \times_2 d\Psi/dt$ — обобщенные силы, создаваемые гравитационными силами, моторами, заданными внешними силами и кориолисовыми силами, F — вектор фиксирующих силы, приложенных к точкам на стопе. Вектор F имеет размерность 9 (по 3 силы, приложенных к трем точкам на стопе). Комбинируя (2) и (3) можно получить уравнение для определения фиксирующих сил:

$$JI^{-1} J^T F = -JI^{-1} T - H \times_1 d\Psi/dt \times_2 d\Psi/dt. \quad (4)$$

Матрица $JI^{-1} J^T$ в уравнении (4) имеет размерность 9×9 , но эта матрица является вырожденной. Поскольку три точки фиксации приложены к твердому телу, то они не могут перемещаться независимо, поэтому якобиан J имеет ранг 6 по числу степеней свободы движения твердого тела. Поэтому и ранг матрицы $JI^{-1} J^T$ имеет ранг 6. В этом случае фиксирующие силы F находятся из уравнения (4) неоднозначно. Их можно найти псевдообращением матрицы $JI^{-1} J^T$ или наложив на фиксирующие силы некоторые дополнительные ограничения. Таким образом, наличие ограничений на движение стопы робота сводится к введению дополнительных ограничивающих сил в уравнение (1) для свободно движущегося тела.

Для описания движений робота при стоянии на двух ногах дополнительно фиксируем координаты трех точек на подошве другой стопы в неподвижной системе координат. Пусть координаты точек фиксации относительно центра масс этой стопы будут теми же, что и для первой стопы. Тогда скорости шести точек на двух стопах можно задать уравнением $v = J d\Psi/dt$, где $v = (v_1; v_2; v_3; v_4; v_5; v_6)$, где $J = (J_1; J_2; J_3; J_4; J_5; J_6)$ их общий якобиан, имеющий размерность $18 \times L$. Точно так же, как при стоянии на одной ноге, вектор фиксирующих сил F находится из уравнения (4). Однако в данном случае вектор F имеет размерность 18 и матрица $JI^{-1} J^T$ в уравнении (4) имеет размерность 18×18 . Как и при стоянии на одной ноге, эта матрица является вырожденной и имеет ранг 12. Поэтому вектор сил F можно найти псевдообращением матрицы $JI^{-1} J^T$ или наложив на фиксирующие силы некоторые дополнительные ограничения.

Точно таким же образом можно учесть и другие ограничения на движение робота, например, фиксацию его таза при сидении. Дополнительными точками фиксации могут быть точки на кистях рук, например, обеспечивающие удержание робота при лазании и т.д. Таким образом, введение

фиксирующих сил позволяет легко учесть наличие любых фиксирующих ограничений на движение робота без изменения основной модели с максимальным числом степеней свободы.

При стоянии робота мы в качестве фиксирующих сил выбрали три силы на каждой стопе, приложенные к точкам на границе ее подошвы. Именно контур подошвы очерчивает границу устойчивости робота, за которую не должен выходить центр давления. Это соответствует условию, что вертикальные силы, приложенные к выбранным точкам фиксации, не должны быть отрицательными, то есть робот не может цепляться стопой за опорную поверхность. Поскольку для выбора фиксирующих сил по уравнению (4) имеется неоднозначность, условие того, что вертикальные составляющие этих сил не являются отрицательными, может использоваться для разрешения этой неоднозначности.

При скачкообразной смене ограничений на движение робота, например, при касании неподвижной опоры после падения или касании неподвижной поверхности при ударе, можно считать, что происходит скачкообразное изменение скорости сегментов робота при неизменной его конфигурации, то есть при фиксированных значениях обобщенных координат. В этом случае согласно уравнению (1) изменение скоростей обобщенных координат задается уравнением:

$$I\Delta d\Psi/dt = J^T I_F, \quad (5)$$

где I_F — импульс фиксирующих сил, а J — якобиан точек приложения фиксирующих сил. Поскольку эти точки меняют свою скорость от некоторого начального значения, задаваемого вектором v_0 до нуля, то должно выполняться равенство:

$$-v_0 = J\Delta d\Psi/dt. \quad (6)$$

Введем матрицу N , задающую ортогональное дополнение якобиана J до полного пространства размерности числа степеней свободы системы L , то есть $NJ^T = 0$, и матрица N имеет размерность $(L-r) \times L$, где r — ранг якобиана J . Умножая уравнение (5) на N , исключим из этого уравнения фиксирующие силы F . Объединяя полученное уравнение с уравнением (6), получаем систему уравнений для определения скачкообразного изменения обобщенных скоростей $\Delta d\Psi/dt$:

$$\begin{cases} NI\Delta d\Psi/dt = 0, \\ J\Delta d\Psi/dt = -v_0, \end{cases}$$

имеющую однозначное решение. Когда изменения обобщенных скоростей $\Delta d\Psi/dt$ найдены, импульсы фиксирующих сил могут быть найдены из уравнения:

$$JJ^T I_F = JI\Delta d\Psi/dt,$$

полученного из (5) умножением на J . Однако опять надо иметь в виду, что решение этого уравнения неоднозначно в силу вырожденности матрицы JJ^T .

Управление движением робота в сагиттальной плоскости

Идея управления роботом опирается на наши исследования движений человека в сагиттальной плоскости, поэтому общему описанию предлагаемых принципов управления движениями робота предшествует описание принципов, используемых центральной нервной системой для управления движениями тела человека. Известно, что управление позой и движениями человека использует эффективные стратегии, направленные на преодоление сложности многозвенной конструкции тела человека и наличия больших задержек в петле управления по обратной связи. Одна из таких стратегий заключается в координации движений в различных суставах, что упрощает управление кинематически избыточной двигательной системой (Bernstein, 1967). Примером такой координации является наклон тела стоящего человека в сагиттальной плоскости: наклон тела вперед сопровождается отклонением ног назад (Babinski, 1899), что минимизирует смещение центра тяжести, сохраняя позу устойчивой. Известно, что такое согласование движений в голеностопном и тазобедренном суставах не является простым следствием биомеханического взаимодействия сегментов тела, а обусловлено контролем центральной нервной системы (Crenna et al., 1987; Oddsson & Thorstenson 1987; Pedotti et al., 1989).

Проблема координации движений в различных суставах имеет два аспекта: согласованное изменение суставных углов («кинематическая синергия») и согласованное изменение силовых моментов, вызывающих соответствующее движение («динамическая синергия»). В работах (Alexandrov et al., 2001a,b) было показано, что существуют движения, в которых одновременно наблюдается кинематическая и динамическая синергии. Этим свойством обладают движения вдоль собственных векторов динамического уравнения, названные «собственными движениями» или «естественными синергиями». Преимущество собственных движений заключается в

том, что они могут независимо управляться по прямым и обратным связям (Alexandrov & Frolov, 2011). В работе (Alexandrov et al., 2005) показано, что это управление осуществляется с помощью пропорционально-дифференциального (ПД) контроллера с временной задержкой в петле обратной связи. Наличие относительно большой временной задержки до 50–200 мсек (Peterka, 2002; Alexandrov et al., 2005; Maurer et al., 2006) в петле обратной связи накладывает ограничения на параметры ПД-контроллера как снизу, так и сверху, иначе управление окажется неустойчивым.

В работе (Александров и др., 2013) описанные принципы управления движениями человека были использованы для управления антропоморфным роботом PostuRob II, разработанным в лаборатории *Т. Мергнера* (Hettich et al., 2011). Было показано, что такое управление позволяет преодолеть трудности, обусловленные переходом от идеальных модельных конструкций к реальным техническим устройствам, которые имеют шумы в показаниях датчиков углов и сил, сухое и вязкое трение, люфты и зазоры, неточности в измерениях механических параметров звеньев и т. д. Робот PostuRob II имеет всего две степени свободы (подвижность в голеностопном и тазобедренном суставах), обеспечивающие его движения в сагиттальной плоскости.

Собственные векторы уравнения движения

Движения в сагиттальной плоскости человека и антропоморфного робота с двумя степенями свободы описываются моделью двухзвенного перевернутого маятника. Динамическое уравнение, описывающее такое движение, получается из уравнения (1) фиксацией движений во всех суставах, кроме голеностопных и тазобедренных, и фиксацией его стоп на плоской горизонтальной платформе. Стопы фиксируются параллельно на одной линии во фронтальной плоскости, а движения в соответствующих суставах левой и правой ноги полагаются одинаковыми.

Описание движения в терминах собственных векторов предполагает переход к линейному приближению динамического уравнения в окрестности вертикального положения звеньев:

$$I_0 d^2 \Psi / dt^2 - D_0 \Psi = T_m, \quad (7)$$

где Ψ — двумерный вектор суставных углов ($\Psi = 0$ при вертикальном положении сегментов тела), моменты гравитационных сил представлены

в виде $D_0\Psi$, а I_0 и D_0 — инерционная и гравитационная матрицы с постоянными коэффициентами, T_m — вектор, задающий силовые моменты моторов в голеностопных и тазобедренных суставах. Выражения для коэффициентов этих матриц через механические параметры сегментов тела можно найти в (Александров и др., 2013). В линейном приближении любое движение можно представить как суперпозицию движений вдоль собственных векторов, которые по определению удовлетворяют уравнению:

$$D_0 w_i = \lambda_i I_0 w_i, i = 1, 2, \quad (8)$$

где λ_i ($i = 1, 2$) — соответствующие собственные значения. Вектор ξ , задающий временной ход движения вдоль собственных векторов задается обратным преобразованием выражения:

$$\Psi(t) = W \xi(t), \quad (9)$$

где два столбца матрицы W представляют собственные вектора w_i ($i = 1, 2$). Первый компонент каждого собственного вектора w_i задает относительный вклад голеностопных суставов в собственное движение, а второй — тазобедренных. Для «стандартного человека» весом 70 кг и ростом 170 см, с параметрами сегментов, «стандартизованными» в соответствии с антропометрическими таблицами (Winter, 1990), $w_1 = (-0.24, 0.97)^T$, $w_2 = (0.94, 0.34)^T$, где первая компонента собственного вектора задает вклад голеностопных, а вторая — тазобедренных суставов. Видно, что для первого собственного движения больший вклад дают тазобедренные суставы, а для второго — голеностопные. Соответственно, эти собственные движения были названы Н- (Hip, тазобедренный) и А- (Ankle, голеностопный) синергиями.

Согласно уравнениям (8) и (9) динамическое уравнение (7) в терминах собственных движений принимает вид:

$$d^2 \xi / dt^2 - \Lambda \xi = \eta, \quad (10)$$

где

$$\eta = UT_m, U = (I_0 W)^{-1}, \quad (11)$$

Λ — диагональная матрица из собственных значений λ_i , а два столбца u_i ($i = 1, 2$) матрицы U в уравнении (11) — два вектора, дающие вклад в силовые моменты голеностопных и тазобедренных суставов каждого их

собственных движений. В терминах ПД-контроллера эти управляющие силовые моменты могут быть представлены в виде:

$$T_m(t) = -D_0\Psi(t - \tau) + S(\Psi^d(t - \tau) - \Psi(t - \tau)) - Vd\Psi/dt(t - \tau), \quad (12)$$

где первое слагаемое компенсирует гравитационные силы, $\Psi^d(t)$ задает желаемый временной ход изменения суставных углов, S и V — матрицы «жесткости» и «вязкости», коэффициенты которых задают коэффициенты усиления в петле управления по обратной связи. В терминах собственных движений уравнение (12) принимает вид:

$$\eta(t) = -\Lambda\xi(t - \tau) + S_{eig}(\xi^d(t - \tau) - \xi(t - \tau)) - V_{eig}d\xi/dt(t - \tau), \quad (13)$$

где

$$S_{eig} = (I_0W)^{-1}SW, V_{eig} = (I_0W)^{-1}VW \quad (14)$$

— матрицы жесткости и вязкости в терминах собственных движений. Как показано в работах (Alexandrov et al., 2001b, 2005, 2011), собственные движения управляются центральной нервной системой независимо, то есть матрицы S_{eig} и V_{eig} в уравнении (14) являются диагональными. Тогда уравнение движения (7) распадается на два независимых скалярных уравнения:

$$d\xi_i/dt(t) - \lambda_i\xi_i(t) = -\lambda_i\xi_i(t - \tau) + S_{eig_i}(\xi_i^d(t) - \xi_i(t - \tau)) - V_id\xi_i/dt(t - \tau), \quad i = 1, 2, \quad (15)$$

где S_{eig_i} и V_{eig_i} — диагональные элементы матриц S_{eig} и V_{eig} . Каждое из уравнений (15) эквивалентно уравнению движения однозвенного перевернутого маятника с $\lambda = mgh/I$, где I — его момент инерции относительно оси вращения, m — масса, h — высота центра масс и g — ускорение свободного падения.

Обращение уравнений (14) позволяет найти матрицы жесткости и вязкости в уравнении (12) в терминах суставных углов:

$$S = I_0WS_{eig}W^{-1}, V = I_0WV_{eig}W^{-1}. \quad (16)$$

Как показано в работе (Alexandrov et al., 2005), если матрицы S_{eig} и V_{eig} диагональны, то матрицы S и V симметричны, но недиагональны. Поэтому управление с помощью ПД-контроллера в терминах суставных углов предполагает для управления каждым суставом учитывать не только движения в этом, но и во всех остальных суставах. Такое управление

называется «управлением по полному состоянию» (Barin, 1989; Park et al., 2004), а число параметров петли обратной связи равно $L(L + 1)$, где L — число степеней свободы в системе. В противоположность этому при независимом управлении в терминах собственных движений число параметров петли обратной связи уменьшается до числа диагональных элементов в матрицах S_{eig} и V_{eig} , то есть до $2L$.

Поиск значений параметров петли обратной связи, обеспечивающих, устойчивое управление движениями робота при наличии временных задержек, является достаточно сложной задачей, которая, как будет показано далее, даже не всегда имеет решение. У человека имеется три петли управления по обратной связи (Peterka, 2002). Первая петля обеспечивается вязко-эластичными свойствами собственно мышц, сухожилий и связок. Эта петля не имеет временной задержки. Вторая петля задается рефлексом на растяжение. Она включает рецепторы растяжения мышечных интрафузальных волокон, альфа-мотонейроны спинного мозга и экстрафузальные мышечные волокна, обеспечивающие мышечные усилия. Задержка в этой петле складывается из времени активации мышечных усилий после синаптической активации экстрафузальных мышечных волокон, которое составляет примерно 25 мс (Welch & Ting, 2008), и временем проведения нервного импульса от мышечных интрафузальных волокон к альфа-мотонейронам и обратно к экстрафузальным волокнам, которое также составляет 25–35 мс. Так что общая задержка в этой петле составляет 50–60 мс. Наконец, третья петля проходит через головной мозг, и задержки в этой петле составляют до 200 мс (Peterka, 2002).

Эффективная задержка в общей петле управления по обратной связи является результатом осреднения указанных трех задержек. По данным работ (Alexandrov et al., 2005; Alexandrov & Frolov, 2011) для Н-синергии эта задержка у разных людей лежит в диапазоне 50–60 мс, а для А-синергии — в диапазоне 120–150 мс.

Анализ устойчивости управления

Независимое управление по каждому собственному движению позволяет анализировать устойчивость управления движениями робота в целом с помощью независимого анализа устойчивости управления отдельно для каждого собственного движения, которое описывается уравнением (15). Тогда устойчивость управления определяется корнями μ характеристическо-

го уравнения:

$$\mu^2 - \lambda + (S_{eig} + \lambda) e^{-\mu\tau} + \mu V_{eig} e^{-\mu\tau} = 0. \quad (17)$$

Если $\tau > 0$, уравнение (17) имеет бесконечное множество комплексных корней $\mu = \alpha + i\omega$, где α и ω — действительная и мнимая части корня μ , а i — мнимая единица (Alexandrov et al., 2005). Уравнение (15) устойчиво, если действительные части всех корней уравнения (17) отрицательны. Максимальное число α действительных частей всех корней характеристического уравнения называется показателем Ляпунова. Таким образом, решение уравнения (15) является устойчивым, когда для него индекс Ляпунова $\alpha < 0$. Индекс Ляпунова задает характерное время $t_{chr} = 1/|\alpha|$ отклика системы на внешнее возмущение. Область в координатах S_{eig} и V_{eig} , для которой индекс Ляпунова не превосходит заданное значение α , будем называть α -областью. Она определяется пересечением двух ветвей решения уравнения (17). Одна ветвь соответствует действительным корням, для которых $\mu = \alpha$. Если это условие выполняется, то S_{eig} и V_{eig} удовлетворяют уравнению:

$$S_{eig} + \alpha V_{eig} + \lambda + (\alpha^2 - \lambda) e^{\alpha\tau} = 0, \quad (18)$$

которое описывает прямую линию на плоскости $(V_{eig} \times S_{eig})$. Вторая ветвь решения уравнения (17) соответствует корням μ , имеющим ненулевую мнимую часть ω . Тогда при данных значениях α и ω значения S_{eig} и V_{eig} , удовлетворяющие этому уравнению, могут быть найдены как решение системы двух действительных уравнений:

$$\begin{cases} S_{eig} \cos \omega\tau + V_{eig} (\alpha \cos \omega\tau + \omega \sin \omega\tau) = [\lambda + (\omega^2 - \alpha^2)] e^{\alpha\tau} - \lambda \cos \omega\tau, \\ S_{eig} (\sin \omega\tau) / \omega + V_{eig} (\alpha (\sin \omega\tau) / \omega - \cos \omega\tau) = 2\alpha e^{\alpha\tau} - \lambda (\sin \omega\tau) / \omega. \end{cases} \quad (19)$$

На рис. 3 приведены α -области, соответствующие значениям $\alpha = 0$ до $\alpha = -11 \text{ с}^{-1}$ для $\lambda = 10 \text{ с}^{-2}$, $\tau = 50 \text{ мс}$, до $\alpha = -7 \text{ с}^{-1}$ для $\lambda = 10 \text{ с}^{-2}$, $\tau = 100 \text{ мс}$, до $\alpha = -11 \text{ с}^{-1}$ для $\lambda = 50 \text{ с}^{-2}$, $\tau = 50 \text{ мс}$ и до $\alpha = -4 \text{ с}^{-1}$ для $\lambda = 50 \text{ с}^{-2}$, $\tau = 100 \text{ мс}$.

Прямые линии представляют решение уравнения (18), кривые — решение системы (19), эти линии являются границами α -областей. При $\alpha = 0$ эта область становится областью устойчивости. Как показано на рис. 3, устойчивое управление движением механической конструкции ПД-контроллером с временной задержкой возможно только при ограничении его параметров как сверху, так и снизу.

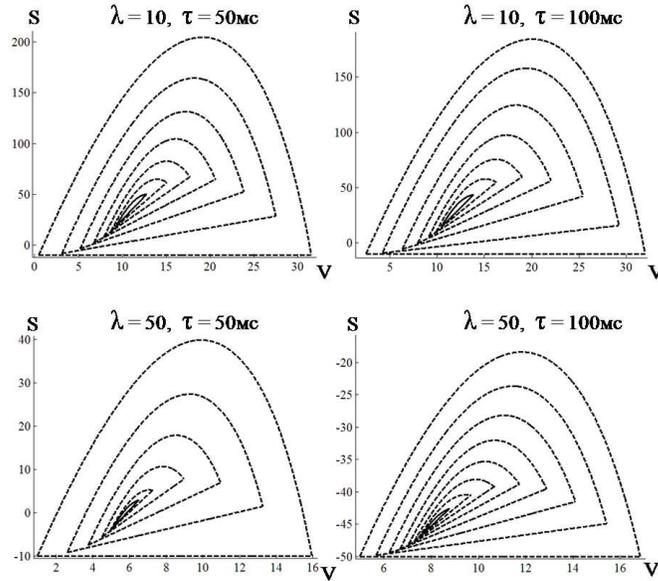


Рис. 3. Ветви решения характеристического уравнения (17) при различных значениях показателя Ляпунова α

Чем больше α по абсолютной величине, то есть чем быстрее восстанавливается равновесие системы после случайного возмущения, тем уже становится α -область. Для заданных значений τ и λ существует предельное значение α , при котором α -область исчезает, и дальнейшее уменьшение α становится невозможным. Значения параметров S_{eig} и V_{eig} , для которых достигается предельное значение показателя Ляпунова можно считать оптимальными для данных значений λ и τ .

На рис. 4 показана зависимость оптимальных значений показателя Ляпунова от λ при некоторых величинах временной задержки τ . Для каждого значения τ при некотором значении λ оптимальное значение α достигает нуля, то есть для этих значений λ и τ область устойчивости исчезает. Это означает, что устойчивое управление механической конструкцией при λ , больших этого критического значения, невозможно. Так как λ определяется только биомеханическими характеристиками тела, то единственной возможностью устойчивого управления такой конструкцией с помо-

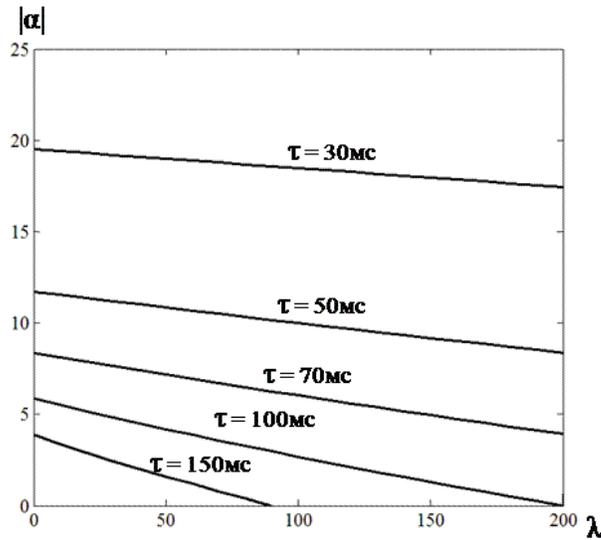


Рис. 4. Зависимость оптимального показателя Ляпунова α от λ и τ

стью ПД-контроллера является уменьшение временной задержки τ . Если по конструктивным соображениям уменьшение временной задержки в ПД-контроллере невозможно, то эту проблему можно решить добавлением в конструкцию робота пассивной пружины. При этом, как указывалось выше, эффективная задержка в петле обратной связи уменьшится и устойчивость управления восстановится. Как показано в работе (Alexandrov et al., 2005), фактически по этому пути пошла природа при управлении собственным движением, наибольший вклад в которое вносит движение в коленях. В (Alexandrov et al., 2005) оно названо К-синергией (Кnee, колено) и рассмотрено наряду с описанными в настоящей работе А- и Н-синергиями. Для К-синергии значение λ оказалось на порядок больше, чем для Н-синергии и эффективное время задержки в петле управления этим собственным движением оказалось равным 12 мс. Такая короткая эффективная задержка возможна только при увеличении вклада пассивных вязко-эластичных свойств мышц, сухожилий и связок с нулевой задержкой.

Опыт управления роботом

Робот Posturob II (Hettich et al., 2011) управляется пневматическими мышцами, изменяющими усилия в зависимости от подаваемого на них давления. Давление регулируется ПД-контроллером, получающим информацию о движении робота от сенсоров, установленных на теле робота. Они позволяют измерять суставные углы и скорости их изменения, угол и скорость поворота верхнего сегмента робота относительно вертикали и силовые моменты, обеспечивающие вращение сегментов тела в голеностопном и тазобедренном суставах. При использовании принципа независимого управления собственными движениями робота ПД-контроллер получает информацию от сенсоров о текущих величинах $\Psi(t)$ и скорости изменения $d\Psi/dt(t)$ суставных углов, а также о желаемом их изменении $\Psi^d(t)$. В контроллере эти величины преобразуются в вектора $\xi(t)$, $d\xi/dt(t)$ и $\xi^d(t)$ с помощью обращения формулы (9). Необходимая для этого матрица собственных векторов W была заранее рассчитана по механическим характеристикам сегментов робота. Вектора $\xi(t)$, $d\xi/dt(t)$ и $\xi^d(t)$ были преобразованы в обобщенные силы по формуле:

$$\eta(t) = -\Lambda\xi(t) + S_{eig}(\xi^d(t) - \xi(t)) - V_{eig}d\xi/dt(t), \quad (20)$$

которая отличается от формулы (13) тем, что в ней используются эти вектора в текущем времени, а не с временной задержкой, которая появляется при преобразовании силовых моментов на выходе контроллера в реальные силовые моменты, подаваемые на суставы. Для голеностопного сустава эта задержка составила 91 мс, а для тазобедренного 53 мс. Эти задержки обусловлены инерционностью регуляторов давления пневматических мышц. Они были уравнены в ПД-контроллере добавлением задержек $\tau_1 = 9$ мс к силовому моменту, поступающему на голеностопный сустав, и $\tau_2 = 47$ мс к силовому моменту, поступающему на тазобедренный сустав. Таким образом, для обоих собственных движений задержка ПД-контроллера составила $\tau = 100$ мс. Силовые моменты, поступающие на суставы рассчитывались обращением формулы (11): $T_m^d(t) = U^{-1}\eta(t)$. Затем, как указано выше, на выходе из контроллера силовые моменты рассчитывались по формулам $T_{m1}^c(t) = T_{m1}^d(t - \tau_1)$ и $T_{m2}^c(t) = T_{m2}^d(t - \tau_2)$. После прохождения через пневморегуляторы на суставные углы подавались силовые моменты, задаваемые вектором $T_m(t) = T_m^d(t - \tau)$.

Матрицы S_{eig} и V_{eig} в уравнении (20) являются диагональными, их коэффициенты рассчитаны так, чтобы показатели Ляпунова были макси-

мальны по абсолютной величине для задержки $\tau = 100$ мс и значений λ_H и λ_A , рассчитанным по механическим характеристикам сегментов робота. Эти показатели для Н- и А-синергий составили, соответственно, -5.62 с^{-1} и -4.12 с^{-1} , то есть время установления равновесия после случайного возмущения робота составляет примерно 240 мс.

По матрицам S_{eig} и V_{eig} обращением уравнений (14) можно получить матрицы S и V в терминах суставных углов. Как показано в работе (Александров и др., 2013), коэффициенты этих матриц лежат в том же диапазоне, что используемые для управления движениями в голеностопном и тазобедренном суставах человека.

В экспериментах с роботом было показано, что несмотря на наличие шумов в показаниях датчиков углов и сил, сухое и вязкое трение, люфты и зазоры, неточности в измерениях механических параметров звеньев и другие характеристики реального технического устройства, управление им по биологически адекватным принципам, используемым центральной нервной системой для управления телом, было устойчивым, а передаточные функции преобразования желаемых изменений суставных углов в наблюдаемые были близки к теоретическим (Александров и др., 2013). Следует заметить, что управление по уравнению (12) предполагает использование для расчета каждого силового момента значений суставных углов и скоростей их изменения во всех суставах. При этом на каждый сустав от ПД-контроллера передается требуемый для выполнения движения силовой момент. Таким образом, от традиционного для роботов и манипуляторов управления по кинематике суставных углов в каждом индивидуальном суставе, для управления роботом PostuRob II используется управление по заданному силовому моменту.

Принцип управления по собственным векторам уравнения движения в общем случае

Как и для случая движений стоящего робота в сагиттальной плоскости, управление по собственным векторам уравнения движения в общем случае основано на линеаризации этого уравнения в окрестности некоторой точки равновесия. Для описанного в предыдущем разделе робота с двумя степенями свободы такой точкой равновесия было спокойное вертикальное стояние с нулевыми углами в голеностопном и тазобедренном суставах. Далее общий принцип управления поясняется на примере робота, стоя-

щего на одной или двух ногах, но с возможными движениями по всем оставшимся степеням свободы. Для описанной в разделе 2 модели робота, имеющего исходно 36 степеней свободы, после фиксации одной из ног, ограничивающей 6 степеней свободы, у робота их остается 30, а после фиксации двух ног их остается 24.

Согласно уравнениям (3) и (4) движение робота, стоящего на одной или двух ногах, описывается системой уравнений:

$$\begin{aligned} Id^2\Psi/dt^2 + C \times_1 d\Psi/dt \times_2 d\Psi/dt &= G + M_T^T T_m + \\ &+ J_{ext}^T F_{ext} + J^T F, \\ JI^{-1} J^T F &= -JI^{-1}(G + M_T^T T_m - J_{ext}^T F_{ext} - \\ &- C \times_1 d\Psi/dt \times_2 d\Psi/dt) - H \times_1 d\Psi/dt \times_2 d\Psi/dt, \end{aligned} \quad (21)$$

где G и $M_T^T T_m$ — обобщенные силовые моменты гравитационных сил и силовых моторов, F_{ext} — заданные внешние силы и F — 9 или 18 опорных сил, действующих на одну или две фиксированные стопы.

По аналогии с управлением движениями человека в сагиттальной плоскости, описанным в предыдущем разделе, предполагается, что робот и в общем случае управляется с помощью ПД-контроллера с временной задержкой. Все дальнейшие преобразования нацелены на получение параметров ПД-контроллера, обеспечивающих устойчивое управление роботом, то есть матриц S и D в выражении:

$$T_m(t) = T_m^{st}(t - \tau) + S(\Psi^d(t - \tau) - \Psi(t - \tau)) - Dd\Psi/dt(t - \tau), \quad (22)$$

где первое слагаемое компенсирует внешние силы, действующие на робота, а два последних члена компенсируют инерционные силы.

В общем случае найти матрицы S и D , обеспечивающие устойчивое управление роботом при наличии временной задержки в петле ПД-контроллера, является трудной задачей даже для двумерного робота, рассмотренного в предыдущем разделе. Как там было показано, область устойчивого управления ограничена значениями параметров как сверху, так и снизу. При отсутствии временной задержки устойчивое управление может быть достигнуто с помощью увеличения коэффициентов матриц S и D , и это может быть достигнуто даже в случае, когда эти матрицы являются диагональными, то есть каждый суставной угол управляется только собственным мотором по отклонениям этого угла от заданного желаемого значения. Именно такое управление используется в стандартных роботах,

манипуляторах и экзоскелетах. Однако экзоскелеты с большими коэффициентами в петле обратной связи воспринимаются человеком как «недружественные», так как жестко навязывают человеку движения и он воспринимает себя как бы «закованным». При уменьшении коэффициентов этих матриц устойчивое управление обеспечивается только в случае, когда они не являются диагональными, но тогда очень усложняется поиск области устойчивости. Далее предлагается обобщить подход, основанный на независимом управлении собственными движениями робота, рассмотренный в предыдущем разделе. В частности, предлагается применить этот подход к линеаризованным уравнениям движения в окрестности некоторой точки равновесия.

Пусть точка равновесия задается вектором обобщенных координат Ψ_0 . Тогда согласно уравнению (21) в точке равновесия:

$$\begin{cases} M_{T_0}^T T_{m_0} + J_0^T F_0 = -G(\Psi_0) - J_{ext_0}^T F_{ext}, \\ J_0 I_0^{-1} M_{T_0}^T T_{m_0} + J_0 I_0^{-1} J_0^T F_0 = -J_0 I_0^{-1} (G(\Psi_0) + J_{ext_0}^T F_{ext}), \end{cases} \quad (23)$$

где $I_0 = I(\Psi_0)$. Число неизвестных в системе уравнений (23) составляет 39 или 48, где 30 неизвестных образуют вектор силовых моментов моторов T_{m_0} и 9 или 18 неизвестных образуют вектор опорных сил F_0 при стоянии на одной или двух ногах. Порядок системы уравнений (23) составляет 45 или 54 в зависимости от того, фиксированы одна или две ноги: порядок первого уравнения составляет 36 по числу степеней свободы тела, порядок второго уравнения составляет 9 или 18 в зависимости от числа фиксирующих сил. Однако, как указывалось в разделе «Уравнения движения системы связанных твердых тел», якобиан J_0 имеет размерность 9×36 или 18×36 , но ранг 6 или 12, так как фиксация каждой стопы ограничивает только 6 степеней свободы тела. Кроме того, в матрице $M_{T_0}^T$ первые 6 строк нулевые. Поэтому для робота, стоящего на одной ноге, все силовые моменты моторов, обеспечивающие равновесие, находятся однозначно, а фиксирующие силы — не однозначно. В этом случае полное решение системы уравнений (23) можно найти псевдообращением матрицы, образующей левую часть системы или накладыванием дополнительных ограничений на фиксирующие силы F . В случае, когда робот стоит на двух ногах, и фиксирующие силы, и силовые моменты моторов находятся неоднозначно и могут быть получены псевдообращением этой матрицы или накладыванием дополнительных ограничений как на фиксирующие силы, так и силовые моменты моторов.

Пусть силовые моменты моторов и фиксирующие силы, обеспечивающие равновесие робота в точке Ψ_0 , найдены. Представим в окрестности точки равновесия $\Psi = \Psi_0 + \Delta\Psi$. Тогда в линейном приближении первое уравнение движения системы (21) имеет вид:

$$\begin{aligned} I_0 d^2 \Delta\Psi / dt^2 &= dG/d\Psi(\Psi_0) \Delta\Psi + dM_T^T/d\Psi(\Psi_0) \Delta\Psi T_{m_0} + \\ &+ M_{T_0}^T \Delta T_m + dJ_{ext}^T/d\Psi(\Psi_0) \Delta\Psi F_{ext} + \\ &+ dJ^T/d\Psi(\Psi_0) \Delta\Psi F + J_0^T \Delta T. \end{aligned}$$

Группируя члены, содержащие $\Delta\Psi$, представим:

$$\begin{aligned} dG/d\Psi(\Psi_0) \Delta\Psi + dM_T^T/d\Psi(\Psi_0) \Delta\Psi T_{m_0} + dJ_{ext}^T/d\Psi(\Psi_0) \Delta\Psi F_{ext} + \\ + dJ^T/d\Psi(\Psi_0) \Delta\Psi F = D_0 \Delta\Psi. \end{aligned}$$

Тогда это уравнение преобразуется к виду:

$$I_0 d^2 \Delta\Psi / dt^2 = D_0 \Delta\Psi + M_{T_0}^T \Delta T_m + J_0^T \Delta F, \quad (24)$$

где, по аналогии с уравнением (7) для случая движений двумерного робота, обобщенную силу $D_0 \Delta\Psi$ можно назвать «гравитационной».

Как указывалось в разделе «Уравнения движения системы связанных твердых тел» при фиксации точек на одной или двух стопах должно выполняться равенство $J_0 \Delta\Psi = 0$, то есть тело сохраняет свободу движения в пространстве, образующем ортогональное дополнение к якобиану J_0 . Введем в этом пространстве ортонормальную матрицу N , тогда перемещение робота при фиксирующих ограничениях можно задать уравнением $\Delta\Psi = Nx$, где x — произвольный вектор, имеющий размерность числа степеней свободы робота, оставшихся после фиксации одной или двух его стоп. Можно рассматривать компоненты вектора x , как новые обобщенные координаты уравнения движения. Умножим уравнение (24) на N^T , тогда уравнение движения в обобщенных координатах x принимает вид:

$$I_x d^2 x / dt^2 = D_x x + T_x, \quad (25)$$

где $I_x = N^T I_0 N$ — матрица инерции, $D_x = N^T D_0 N$ — «гравитационная матрица» в новой системе координат,

$$T_x = N^T M_{T_0}^T \Delta T_m \quad (26)$$

— обобщенные силы, создаваемые моторами, а последний член в уравнении (24) исчез из уравнения (25), потому что N образует ортогональное дополнение к J_0 , то есть $N^T J_0 = 0$.

В уравнении (25) матрица I_x не вырожденная и имеет размерность 30×30 для робота, закрепленного на одной ноге и 24×24 , для робота, закрепленного на двух ногах, поэтому уравнение (25) по аналогии с уравнением (7), рассмотренным в разделе «Управление движением робота в сагиттальной плоскости», можно переписать в терминах собственных движений:

$$d^2 \xi / dt^2 - \Lambda \xi = \eta,$$

где Λ — диагональная матрица собственных векторов уравнения движения, определяемая равенством $D_x W = I_0 W \Lambda$, где W — матрица, столбцы которой образованы собственными векторами уравнения движения, вектор ξ , задающий временной ход движения вдоль собственных векторов, задается обратным преобразованием выражения:

$$x(t) = W \xi(t), \quad (27)$$

обобщенные силы в терминах собственных движений задаются уравнением:

$$\eta = U T x, \quad (28)$$

где $U = (I_x W)^{-1}$.

Если по аналогии со случаем движения робота в сагиттальной плоскости, рассмотренным в разделе «Управление движением робота в сагиттальной плоскости», управлять обобщенными силами с помощью ПД-контроллера, то есть положить:

$$\eta(t) = -\Lambda \xi(t - \tau) + S_{eig} (\xi^d(t - \tau) - \xi(t - \tau)) - V_{eig} d\xi/dt(t - \tau), \quad (29)$$

где матрицы жесткости и вязкости S_{eig} и V_{eig} являются диагональными, то, как и в случае движений робота в сагиттальной плоскости, уравнение движения распадается на независимые уравнения для каждого из собственных движений:

$$d^2 \xi_i / dt^2(t) - \lambda_i \xi_i(t) = -\lambda_i \xi_i(t - \tau) + S_{eig_i} (\xi_i^d(t - \tau) - \xi_i(t - \tau)) - V_{eig_i} d\xi_i / dt(t - \tau), \quad (30)$$

где число уравнений совпадает с числом степеней свободы в системе.

Уравнение (29) можно исследовать на устойчивость точно так же, как это было сделано в разделе 3, и для каждого собственного движения найти оптимальные значения S_{eig_i} и V_{eig_i} , обеспечивающие отрицательные и максимальные по величине показатели Ляпунова. Когда эти значения найдены, можно обратить уравнение (28), а с помощью уравнений (27) перейти к обобщенным координатам x , получив:

$$T_x = -D_x x(t - \tau) + S_x (x^d(t - \tau) - x(t - \tau)) - V_x dx/dt(t - \tau),$$

где $S_x = I_0 W S_{eig} W^{-1}$ и $V_x = I_0 W V_{eig} W^{-1}$. Теперь, подставив в это уравнение выражения $x = N^+ \Delta \Psi$, где N^+ — матрица, псевдообратная к N , и используя уравнение (26), получим уравнение для определения ΔT_m :

$$\begin{aligned} N^{+T} N^T M_{T_0}^T \Delta T_m = & -N^{+T} D_x N^+ \Delta \Psi(t - \tau) + \\ & + N^{+T} S_x N^+ (\Delta \Psi^d(t - \tau) - \Delta \Psi(t - \tau)) - \\ & - N^{+T} V_x N^+ d\Delta \Psi/dt(t - \tau). \end{aligned} \quad (31)$$

Таким образом, матрицы S и V в уравнении (22), обеспечивающие устойчивое управление роботом в окрестности некоторой точки равновесия, задаются выражениями:

$$S = N^{+T} S_x N^+, V = N^{+T} V_x N^+.$$

Член T_m^{st} , компенсирующий внешние силы, приложенные к роботу, может быть найден из уравнений (23).

Временная задержка ПД-контроллера, как и для робота PostuRob II, рассмотренного в разделе «Управление движением робота в сагиттальной плоскости», определяется временем преобразования желаемых силовых моментов в действующие силовые моменты в контроллерах моторов.

Строго говоря, приведенные рассуждения доказывают только квазистатическую устойчивость управления роботом, то есть устойчивость управления только в окрестности точки равновесия. Однако по нашему опыту управление моделью робота с помощью ПД-контроллера, имеющего параметры, вычисленные указанным способом были всегда устойчивым. Единственная проблема, что эти параметры приходится иногда пересчитывать по ходу движения робота, так как собственные векторы и собственные значения линеаризованного уравнения движения зависят от текущей конфигурации робота. При больших изменениях конфигурации робота параметры

ТАБЛИЦА 1. Собственные векторы линеаризованных уравнений динамики модели руки

Плечевой сустав	Вращение, Rots	0.09	0.13	-0.01	-0.68	-0.01	0.27	-0.03
	Отведение-приведение, Ab-Ads	0.02	0.04	-0.01	0.00	0.00	-0.05	-0.90
	Сгибание-разгибание, F-Es	-0.02	-0.03	0.01	-0.08	0.02	-0.27	0.07
Локтевой сустав	Пронация-супинация, P-Se	0.25	-0.14	0.02	-0.13	-0.53	-0.36	0.26
	Сгибание-разгибание, F-Ee	-0.05	0.02	0.04	-0.70	-0.05	0.39	0.10
Лучезапястный сустав	Отведение-приведение, Ab-Adw	0.71	0.31	0.88	-0.11	0.45	0.67	-0.21
	Сгибание-разгибание, F-Ew	0.64	-0.93	-0.47	0.08	0.72	0.35	-0.26
		w_1^{μ}	w_2^{μ}	w_3^{μ}	w_4^{μ}	w_5^{μ}	w_6^{μ}	

ПД-контроллера, рассчитанные при некоторой конфигурации, уже могут не обеспечивать устойчивость управления при новой конфигурации.

При стоянии робота на одной ноге силовые моторы, управляющие движениями робота, рассчитываются по приведенным формулам однозначно. То же можно отметить при управлении движениями руки робота, при фиксации верхнего сегмента корпуса, к которому она прикреплена. Однако при стоянии робота на двух ногах силовые моменты находятся неоднозначно, и они могут быть найдены либо псевдообращением уравнения (31), либо с помощью наложения на силовые моменты моторов некоторых дополнительных ограничений.

Для примера в табл. 1 приведены собственные вектора уравнения движения руки при ее горизонтальном положении с расстоянием кисти от середины груди на 15 см. Механические характеристики сегментов руки взяты по антропометрическим таблицам, приведенным в работе (Winter,

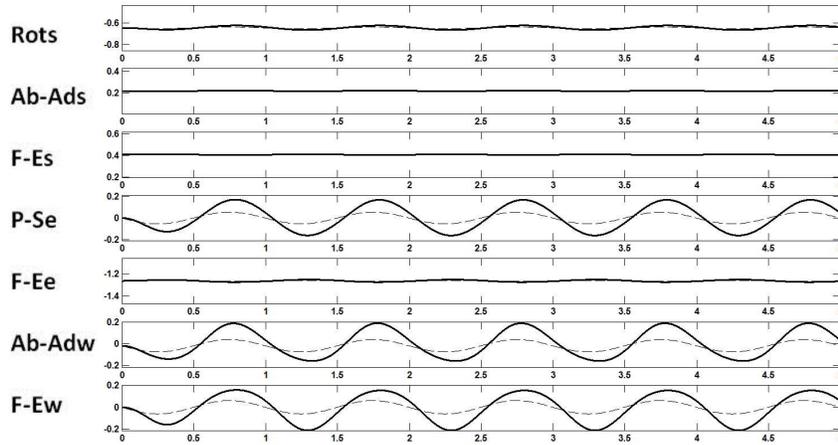


Рис. 5. Собственные движения в степенях подвижности руки, соответствующие собственному вектору w_1^H из табл. 1: желаемое движение показано штриховыми линиями; движение, полученное интегрированием уравнений динамики — сплошными линиями

1990). Собственные вектора определяют вклады степеней свободы руки в собственные движения. Так, в первые три собственных движения основной вклад вносят степени свободы луче-запястного сустава; в пятом собственном движении к ним добавляется пронация предплечья, в шестом — степени свободы локтевого и плечевого (кроме отведения-приведения) суставов; четвертое собственное движение в основном определяется вращением плеча относительно его продольной оси и сгибанием в локтевом суставе, а седьмое — отведением в плечевом суставе.

Для того, чтобы определить собственные движения, соответствующие собственным векторам, приведенным в табл. 1, необходимо решить прямую задачу динамики, то есть проинтегрировать уравнения динамики, правые части которых представляют собой ПД-контроллер, описываемый уравнением (22). Параметры ПД-контроллера выбраны оптимальными при задержке 50 мс. Это соответствует экспериментально наблюдаемому задержкам в петле управления по обратной связи руки человека (Frolov et al., 2000, 2006). Напомним, что критерием оптимальности, как указано в разделе 3, является максимизация по абсолютной величине показателя Ляпунова

для каждого собственного движения. Вычисленные значения находятся в диапазоне значений, приводимых в литературе по вязкоупругим свойствам суставов руки, приведенных, например, в работе (Frolov et al., 2000, 2006).

В качестве желаемого задавались периодическое движение в суставах с амплитудами, пропорциональными элементам собственного вектора:

$$\Psi_k^d = Aw_k^d \sin 2\pi ft,$$

где $k = 1, 2, \dots, 7$ — номер собственного вектора, $A = 0.1$ рад, $f = 1$ Гц.

Собственные движения, полученные в результате интегрирования уравнений динамики, близки к желаемым движениям. Таким образом, ПД-контроллер обеспечивает устойчивое управление моделью руки.

Заключение

В исследованиях в области моторного контроля у человека и животных существует проблема динамической и кинематической избыточности, связанная с тем, что в двигательных актах участвует гораздо большее число мышц и суставов, чем требовалось бы для реализации необходимой комбинации суставных моментов сил и выполнения необходимой двигательной задачи. Соответствующие исследования проводились *Н. А. Бернштейном* (Bernstein, 1967), который показал, что живые организмы сводят двигательное управление к управлению с помощью определенного набора мышечных и межзвенных синергий, включающего в себя относительно небольшое количество их стереотипных комбинаций. В ряде предыдущих работ (Alexandrov et al., 2001a,b, 2005, 2011) при исследовании движений человека в сагиттальной плоскости было показано, что ЦНС в качестве двигательных синергий использует собственные движения динамического уравнения (которые были также названы «естественными синергиями»). Они представляют собой движения вдоль собственных векторов динамического уравнения и являются некоторыми стереотипными комбинациями суставных углов и суставных моментов, которые в этом случае могут рассматриваться как целостные единицы двигательного управления. Преимуществом такого управления является его значительное упрощение, поскольку естественные синергии могут управляться кинематически и динамически независимо друг от друга.

При поддержании равновесия у прямоходящего человека центральная нервная система использует принцип управления по обратной связи, что-

бы скомпенсировать различного рода непредсказуемые возмущения, например, движение опоры, внешние толчки и т. д. Информация, используемая центральной нервной системой о действии возмущений, является результатом комбинированного влияния сенсорных сигналов различной модальности. Сенсомоторная интеграция объединяет проприоцептивную, зрительную, вестибулярную, тактильную и мышечную системы, каждая из которых имеет свои специфические характеристики и временные задержки в петлях обратной связи. Силовой ответ с нулевой задержкой определяется пассивными механическими свойствами мышц и сухожилий. Затем с задержкой около 50–80 мс включаются спинальные механизмы рефлекторного ответа. Наиболее высоколатентные механизмы автоматического ответа, связанные с головным мозгом, включаются еще позже и имеют латентность до 150–200 мс (Peterka, 2002). В рамках гипотезы о независимом управлении естественными синергиями эффективная задержка в петле обратной связи для каждой из синергий является результатом суммарного влияния всех этих механизмов.

Наличие большой задержки в петле обратной связи накладывает ограничение на ее параметры (жесткость и вязкость), необходимые для обеспечения устойчивости управления как сверху, так и снизу. Как показано на рис. 3, области устойчивости при независимом управлении каждым собственным движением сужаются при возрастании временной задержки τ и увеличении собственного значения λ . Для каждой задержки τ существует критическое значение λ , при котором устойчивое управление с помощью ПД-контроллера становится невозможным.

В настоящей работе принципы управления, разработанные при анализе движений стоящего человека в сагиттальной плоскости, были перенесены на общий случай управления движениями антропоморфного робота. Применимость этих принципов проверялась с помощью динамической модели робота, включающей 15 сегментов, движущихся с 36 степенями свободы и приводимыми в движение 30 одноосными моторами. Предложен универсальный способ описания движений робота на основе подхода, предложенного Г. В. Кореневым еще в 70-е годы прошлого века (Корнев, 1979), и с использованием ограничений степеней свободы с помощью фиксирующих сил. Специально приведен вывод уравнений движения при ограничении степеней свободы, когда робот стоит на одной или двух ногах. При стоянии на одной ноге силовые моменты моторов, обеспечивающих заданное движение определяются однозначно. При стоянии на двух ногах возможное число комбинаций силовых моментов избыточно. Они могут быть най-

дены однозначно только при наложении некоторых ограничений. Силовые моменты, обеспечивающие требуемое движение руки робота, фиксированной на верхнем сегменте корпуса, также определяются однозначно.

Принцип независимого управления собственными движениями основан на линеаризации уравнений движения в окрестности точки поддержания равновесия. Таким образом, предлагаемый принцип фактически обеспечивает квазистатическую устойчивость управления. Однако опыт управления моделью робота показал, что управление является также и динамически устойчивым. Однако при движении робота необходимо время от времени пересчитывать параметры управления в петле обратной связи, которые зависят от текущей конфигурации робота.

Принцип независимого управления собственных движений был также подтвержден при управлении роботом PostuRob II, разработанным в лаборатории Т. Мергнера (Hettich et al., 2011). Хотя параметры управления роботом были вычислены по идеальной модели и игнорировались присутствующие всегда в реальной механической системе такие факторы, как трение, нелинейности, шумы, люфты, ошибки измерений и т. д., управление робота было устойчивым. Влияние этих неучтенных факторов отразилось лишь в незначительных отклонениях экспериментально наблюдаемых движений робота, но не повлияло на общий характер этих движений (Александров и др., 2013). Отметим, что главной особенностью робота PostuRob II является имитация не только биомеханических характеристик тела, но и сенсорных систем человека. Поэтому эксперименты с PostuRob II служат для проверки применимости физиологических принципов двигательного управления в робототехнике, а также решают и обратную задачу тестирования физиологических гипотез о принципах сенсомоторной интеграции с помощью технической модели. В этом смысле полученное в работе (Александров и др., 2013) подтверждение о возможности устойчивого управления антропоморфным роботом может являться дополнительным аргументом в пользу выдвинутой нами гипотезы о независимом управлении естественными синергиями у человека.

Литература

- [Александров и др. 2013]. Александров А. В., Мергнер Т., Фролов А. А., Хеттик Г. Муравьев И. П. (2013) Устойчивое управление позой и движениями стоящего гуманоида по принципу естественных синергий у человека // *Российский журнал биомеханики*. – Т. 17, № 1 (59). – С. 94–109.

- [Корнев 1979]. *Корнев Г. В.* (1979) Целенаправленная механика управляемых манипуляторов. – М.: Наука.
- [Котов и др. 2015]. *Котов С. В., Турбина Л. Г., Бобров П. Д., Фролов А. А., Павлова О. Г., Курганская М. Е., Бирюкова Е. В.* (2015) Реабилитация больных, перенесших инсульт, с помощью биоинженерного комплекса «интерфейс мозг-компьютер + экзоскелет» // *Журнал неврологии и психиатрии им. С. С. Корсакова* (в печати).
- [Alexandrov et al. 2001a]. *Alexandrov A. V., Frolov A. A., Massion J.* (2001a) Biomechanical analysis of movement strategies in human forward trunk bending. I. Modeling // *Biol. Cybern.* – Vol. 84. – pp. 425–434.
- [Alexandrov et al. 2001b]. *Alexandrov A. V., Frolov A. A., Massion J.* (2001b) Biomechanical analysis of movement strategies in human forward trunk bending. II. Experimental study // *Biol. Cybern.* – Vol. 84. – pp. 435–443.
- [Alexandrov et al. 2005]. *Alexandrov A. V., Frolov A. A., Horak F. B., Carlson-Kuhta P., Park S.* (2005) Feedback equilibrium control during human standing // *Biol. Cybern.* – Vol. 93. – pp. 309–322.
- [Alexandrov, Frolov 2011]. *Alexandrov A. V., Frolov A. A.* Closed-loop and open-loop control of posture and movement during human upper trunk bending (2011) // *Biol. Cybern.* – Vol. 104. – pp. 425–438.
- [Amirabdollahian et al. 2007]. *Amirabdollahian F., Loureiro R., Gradwell E., Collin C., Johnson G., Harwin W.* (2007) Multivariate analysis of the Fugl-Meyer outcome measures assessing the effectiveness of the GENTLE/S robot mediated stroke therapy // *Journal of Neuroengineering and Rehabilitation.* – Vol. 4. – p. 4.
- [Babinski 2001]. *Babinski J.* (1899) De l'asynergie c?rebelleuse // *Rev. Neurol.* – Vol. 7. – pp. 806–816.
- [Bach-Y-Rita 2001]. *Bach-Y-Rita P.* (2001) Theoretical and practical considerations in the restoration of function after stroke. – *Top Stroke Rehabilitation.* – Vol. 8. – pp. 1–15.
- [Barin 1989]. *Barin K.* (1989) Evaluation of a generalized model of human postural dynamics and control in the sagittal plane // *Biol. Cybern.* – Vol. 61. – pp. 37–50.
- [Bernstein 1967]. *Bernstein N. A.* (1967) The co-ordination and regulation of movements. – London, Pergamon Press.
- [Berthoz 1996]. *Berthoz A.* (1996). The role of inhibition in the hierarchical gating of executed and imagined movements // *Cognitive Brain Research.* – Vol. 3. – pp. 101–113.
- [Crenna et al. 1987]. *Crenna P., Frigo C., Massion J., Pedotti A.* (1987) Forward and backward axial synergies in man // *Exp. Brain Res.* – Vol. 65. – pp. 538–548.

- [Daly, Wolpaw 2008]. *Daly J.J., Wolpaw J.R.* (2008) Brain-computer interfaces in neurological rehabilitation // *The Lancet Neurology*. – Vol. 7(11). – pp. 1032–1043.
- [Decety, Jeannerod 1995]. *Decety J., Jeannerod M.* (1995) Mentally simulated movements in virtual reality: does Fitts's law hold in motor imagery? // *Behavioral and Brain Research*. – Vol. 72. – pp. 127–134.
- [Ferris 2009]. *Ferris D.P.* (2009) The exoskeletons are here // *Journal of NeuroEngineering and Rehabilitation*. – Vol. 6(17).
URL: <http://www.jneuroengrehab.com/content/6/1/17>
- [Frolov et al. 2009]. *Frolov A.A., Dufosse M., Rizek S., Kaladjian A.* (2000) On the possibility of linear modelling the human arm neuromuscular apparatus // *Biol. Cybern.* – Vol. 82. – pp. 499–515.
- [Frolov et al. 2006]. *Frolov A.A., Prokopenko R.A., Dufosse M., Oueddou F.B.* (2006). Adjustment of the human arm viscoelastic properties to the direction of reaching // *Biological Cybernetics*. – Vol. 94 (2). – pp. 97–109.
- [Hettich et al. 2011]. *Hettich G., Fennel L., Mergner T.* (2011) Double inverted pendulum model of reactive human stance control. Multibody dynamics // CD Proceedings, ECCOMAS Thematic Conference, 3-4 July 2011 / eds. *J. C. Samin, P. Fisette*. – Brussels.
- [Hingtgen et al. 2006]. *Hingtgen B., McGuire J.R., Wang M., Harris G.F.* (2006) An upper extremity kinematic model for evaluation of hemiparetic stroke // *Journal of Biomechanics*. – Vol. 39 (4). – pp. 681–688.
- [Iwamuro et al. 2008]. *Iwamuro B. T., Cruz E. G., Connelly L. L., Fischer H. C., Kamper D. G.* (2008) Effect of a gravity-compensating orthosis on reaching after stroke: evaluation of the therapy assistant WREX // *Archives of Physical Medicine and Rehabilitation*. – Vol. 89. – pp. 2121–2128.
- [Kane, Levinson 1985]. *Kane T.R., Levinson D.A.* (1985) Dynamics: Theory and applications. – New York: McGraw-Hill.
- [Kwakkel et al. 1999]. *Kwakkel G., Wagenaar R. C., Twisk J.W., Lankhorst G. J., Koetsier J. C.* (1999) Intensity of leg and arm training after primary middle-cerebral-artery stroke: a randomised trial // *Lancet*. – Vol. 354. – pp. 191–196.
- [Lotze, Halsband 2006]. *Lotze M., Halsband U.* (2006) Motor imagery // *Journal of Physiology*. – Vol. 99. – pp. 386–395.
- [Lum et al. 2002]. *Lum P.S., Burgar C. G., Shor P. C., Maimundar M., Van der Loos M.* (2002) Robot-assisted movement training compared with conventional therapy techniques for the rehabilitation of upper-limb motor function after stroke // *Archives of Physical Medicine and Rehabilitation*. – Vol. 83 (7). – pp. 952–959.

- [Marchal-Crespo, Reinkensmeyer 2009]. *Marchal-Crespo L., Reinkensmeyer D.J.* (2009) Review of control strategies for robotic movement training after neurologic injury // *Journal of NeuroEngineering and Rehabilitation*. – Vol. 6(20).
URL: <http://www.jneuroengrehab.com/content/6/1/20>
- [Masiero et al. 2007]. *Masiero S., Celia A., Rosati G., Armani M.* (2007) Robotic-assisted rehabilitation of the upper limb after acute stroke // *Archives of Physical Medicine and Rehabilitation*. – Vol. 88(2). – pp. 142–149.
- [Maurer et al. 2006]. *Maurer C., Mergner T., Peterka R.J.* (2006) Multisensory control of human upright stance // *Exp. Brain Res.* – **171**: 231–250.
- [Nudo et al. 1996]. *Nudo R.J., Milliken G.W., Jenkins W.M., Merzenich M.M.* (1996) Use-dependent alterations of movement representations in primary motor cortex of adult squirrel monkeys // *Journal of Neuroscience*. – Vol. 16(2). – pp. 785–807.
- [Oddsson, Thorstensson 1986]. *Oddsson L., Thorstensson A.* (1986) Fast voluntary trunk flexion movements in standing: primary movements and associated postural adjustments // *Acta Physiol Scand.* – **128**: 341–349.
- [Otten 1999]. *Otten E.* Balancing on a narrow ridge: biomechanics and control. (1999) // *Phil. Trans. R. Soc. Lond. B.* – **354**. – pp. 869–875.
- [Park et al. 2004]. *Park S., Horak F.B., Kuo A.D.* (2004) Postural feedback responses scale with biomechanical constraints in human standing // *Exp. Brain Res.* – Vol. 154. – pp. 417–427.
- [Pedotti et al. 1989]. *Pedotti A., Crenna P., Deat A., Frigo C., Massion J.* (1989) Postural synergies in axial movements: short and long-term adaptation // *Exp. Brain Res.* – Vol. 74. – pp. 3–10.
- [Peterka 2002]. *Peterka R.J.* (2002) Sensorimotor integration in human postural control // *J. Neurophysiol.* – Vol. 85. – pp. 1097–1118.
- [Peterka 2009]. *Peterka R.J.* (2009) Comparison of human and humanoid robot control of upright stance // *Journal of Physiology*. – Vol. 103. – pp. 149–158.
- [Reinkensmeyer et al. 2000]. *Reinkensmeyer D.J., Kahn L.E., Averbuch M., McKenna-Cole A., Schmit B.D., Rymer W.Z.* (2000) Understanding and treating arm movement impairment after chronic brain injury: progress with the ARM guide // *Journal of Rehabilitation Research and Development*. – Vol. 37(6). – pp. 653–662.
- [Taub et al. 2002]. *Taub E., Uswatte G., Elbert T.* (2002) New treatments in neurorehabilitation founded on basic research // *Nature Reviews. Neuroscience*. – Vol. 3(3). – pp. 228–236.
- [Welch, Ting 2008]. *Welch T.D., Ting L.H.* (2008) A feedback model reproduces muscle activity during human postural responses to support-surface translations // *J. Neurophysiol.* – Vol. 99. – pp. 1032–1038.

[Winter 1990]. *Winter D.A.* (1990) *Biomechanics and motor control in human movement*. – 2nd Ed. – New York: John Wiley and Sons.

Александр Алексеевич ФРОЛОВ, доктор биологических, кандидат физико-математических наук, профессор, заведующий лабораторией «Математическая нейробиология обучения» Института высшей нервной деятельности и нейрофизиологии РАН и заведующий отделением «Нейрокомпьютерные интерфейсы» Российского национального медицинского университета им. Н. И. Пирогова, старший научный сотрудник Технического университета Острова Чешской республики. Область научных интересов — аттракторные нейронные сети, двигательное управление и обучение, биомеханика, интерфейс мозг-компьютер, двигательная реабилитация, управление роботами, манипуляторами и экзоскелетами. Член редколлегии журналов “Neural Network World” и «Нейрокомпьютеры: теория и применение». Автор двух монографий, 6 глав в книгах и более 250 научных публикаций.

Алексей Владимирович Александров, кандидат биологических наук, старший научный сотрудник лаборатории «Математическая нейробиология обучения» Института высшей нервной деятельности и нейрофизиологии РАН. Область научных интересов — двигательное управление и обучение, биомеханика, управление роботами, манипуляторами и экзоскелетами. Автор 2 глав в книгах и более 50 научных публикаций.

Павел Дмитриевич Бобров, кандидат биологических наук, научный сотрудник лаборатории «Математическая нейробиология обучения» Института высшей нервной деятельности и нейрофизиологии РАН. Область научных интересов — двигательное управление и обучение, биомеханика, интерфейс мозг-компьютер, двигательная реабилитация, управление роботами, манипуляторами и экзоскелетами. Автор 10 научных публикаций.

Елена Владимировна БИРЮКОВА, кандидат физико-математических наук, старший научный сотрудник лаборатории «Математическая нейробиология обучения» Института высшей нервной деятельности и нейрофизиологии РАН и старший научный сотрудник отделения «Нейрокомпьютерные интерфейсы» Российского национального медицинского университета им. Н. И. Пирогова. Область научных интересов — двигательное управление и обучение, биомеханика, интерфейс мозг-компьютер, двигательная реабилитация, управление роботами, манипуляторами и экзоскелетами. Автор 40 научных публикаций.

Ю. И. НЕЧАЕВ

Санкт-Петербургский государственный исследовательский университет
информационных технологий, механики и оптики

E-mail: nechaev@mail.ifmo.mail.ru

**КОНТРОЛЬ ЧРЕЗВЫЧАЙНЫХ СИТУАЦИЙ В
ИНТЕГРИРОВАННОЙ СРЕДЕ ВИРТУАЛЬНОГО ПОЛИГОНА НА
ОСНОВЕ СОВРЕМЕННОЙ ТЕОРИИ КАТАСТРОФ**

Аннотация

Обсуждается проблема контроля чрезвычайных ситуаций на основе виртуального полигона (ВП). Структура ВП интегрирует модели знаний с использованием графо-аналитической и нейродинамической систем (GA и ND-системы). Синтез осуществлен в рамках методов теории катастроф. Высокопроизводительная среда ВП обеспечивает моделирование и визуализацию чрезвычайных ситуаций в условиях непрерывного изменения динамики объекта и внешней среды. Концепция ВП реализует обработку информации при интерпретации нелинейных нестационарных систем в режиме реального времени. Формальная модель топологической динамики ND-системы предусматривает использование фрактальной геометрии и энтропийного подхода. Сформулирован общий подход к созданию критериального базиса ND-системы в условиях неопределенности и неполноты исходной информации. Компьютерное моделирование динамики взаимодействия проведено применительно к морским динамическим объектам (ДО) при различном уровне внешних возмущений.

Yu. I. NECHAEV

National Research University of Information Technologies,
Mechanics and Optics, Saint-Petersburg

E-mail: nechaev@mail.ifmo.mail.ru

**CONTROL OF EXTREME SITUATIONS IN THE INTEGRATED
ENVIRONMENT OF VIRTUAL TESTBED ON THE BASIS OF THE
MODERN CATASTROPHE THEORY**

Abstract

The control problem of extreme situations on the basis of virtual testbed (VT) is discussed. Structure of VT integrates models of knowledge with use graph analytical and neuro-dynamic systems (GA and ND-systems). Synthesis is carried out within the limits of methods of the catastrophe theory. High-performance of VT environment provides modeling and visualization of extreme situations in the conditions of continuous change of dynamics of object and an environment. Concept of VT realizes information processing at interpretation of nonlinear non-stationary systems in a regime of real time. The formal model of topology dynamic of ND-system provides use fractal geometry and entropy approach. The general approach to creation criteria basis of ND-system in the conditions of uncertainty and incompleteness of the initial information is formulated. Computer modeling of dynamics of interaction is spent with reference to sea dynamic objects (TO) at various level of external indignations.

Введение

Расширение функциональных возможностей использования интеллектуальных технологий и высокопроизводительных вычислений при контроле чрезвычайных ситуаций связано с совершенствованием методов обработки информации в сложных динамических средах [1–23]. Разработанные концептуальные основы создания ВП мониторинга транспортных и социальных систем реализованы в виде интегрированного многопроцессорного комплекса, функционирующего на основе динамической модели катастроф (рис.1). ВП включает два функциональных блока — *графоаналитическую* (GA-система) и *нейродинамическую* систему (ND-система). GA-система обеспечивает интерпретацию текущих ситуаций на основе методов классической математики, а ND-система — с использованием нейронечеткого

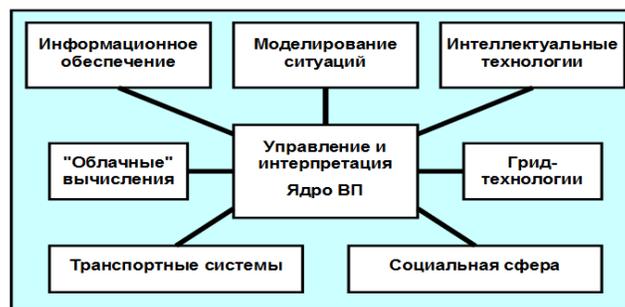


Рис. 1. Структура, реализующая концептуальную модель ВП

(NF) и нейроэволюционного (NE) моделирования [12, 13]. Основной класс задач, реализуемых в процессе функционирования ВП, связан с анализом и прогнозом нелинейных нестационарных систем (NN-систем).

Динамическая модель катастроф при контроле чрезвычайных ситуаций открывает перспективы построения алгоритмов и программного обеспечения прикладных задач в различных областях практических приложений [1, 7, 17]. Применительно к рассматриваемой проблемной области разработанная вычислительная технология реализована на основе ВП мониторинга транспортных и социальных систем в режиме реального времени. Работа представляет собой сокращенное изложение концептуальных решений топологии нестационарных динамических систем, доложенных автором на Международном конгрессе в Кембридже (Англия) в 2014 году.

Концепция виртуального полигона при реализации методов теории катастроф в сложных динамических средах

Интегрированный вычислительный комплекс ВП контроля транспортной и социальной среды реализует сложное преобразование информации с использованием формализованной модели знаний как многоуровневая интеллектуальная система (ИС), состоящая из иерархии имитационных моделей, отражающих проблемные области практических приложений. Функциональная схема ВП включает основные блоки, реализующие концептуальную модель в среде «облачных» вычислений (рис. 1). Такая интегра-

ция определяет взаимосвязь динамической теории катастроф и уровней информационной, функциональной и аппаратной конфигурации сложной инфраструктуры при контроле чрезвычайных ситуаций в транспортных и социальных системах.

Как видно из рис. 1, ВП организуется в рамках CLOUD-системы (система «облачных» вычислений) и GRID-технологий. CLOUD-система представляет собой мультипроцессорный комплекс, обеспечивающий интеграцию вычислительной среды на уровне информационной, функциональной и аппаратной конфигурации [12, 13]. GRID-система [9] функционирует с использованием собственных и внешних ресурсов.

Ядро ВП содержит функциональные компоненты, обеспечивающие интерпретацию чрезвычайных ситуаций на основе динамической модели катастроф. Функционирование ВП осуществляется на основе аппаратно-программного комплекса в соответствии со структурой, представленной на рис. 2. Здесь использованы следующие обозначения: А — блок моделей взаимодействия объектов TS-систем; В — блок управления и интерпретации; С — блок информационного обеспечения; D — блок интеллектуальных технологий реализации баз знаний TS-систем.

Рассмотрим характеристику блоков ВП: M_1 — блок моделей оценки состояния TS-систем, навигационной и оперативной обстановки; MA_i ($i = 1, \dots, n$) — модели анализа поведения TS-систем и внешней среды; M_2 — блок моделей управления; МФ — модели функционирования ВП; MU_j ($j = 1, \dots, m$) — модели взаимодействия элементов управляющего комплекса; MU_k ($k = 1, \dots, K$) — модели взаимодействия элементов TS-систем; M_3 — блок планирования операций; $(MLP) - 1, \dots, MLP - m$ — блок долгосрочного и оперативного планирования элементов ВП; $MOP - 1 \dots MOP - n$ — модели долгосрочного и оперативного планирования; $MC - 1, \dots, MC - k$ — модели управления структурами компонент ВП; DS — диалоговая система управления ВП; LS_p ($p = 1, \dots, P$) — локальные системы управления; SA — блок генерации сценариев и адаптации TS-систем; RB — блок выработки практических рекомендаций; $IS - 1, \dots, IS - m, IS - 1, \dots, IS - n$ — ИС контроля состояния ВП, ДО и внешней среды в TS-системах; VR — система виртуальной реальности; $SC \& MAC$ — технологии мягких вычислений и мультиагентных систем; GRID — технологии реализации виртуального полигона; CLOUD — технология «облачных» вычислений.

В основе комплекса технических средств системы виртуальной реальности (VR-системы) используется широкоэкранный стереовизуализации, включающая в себя:

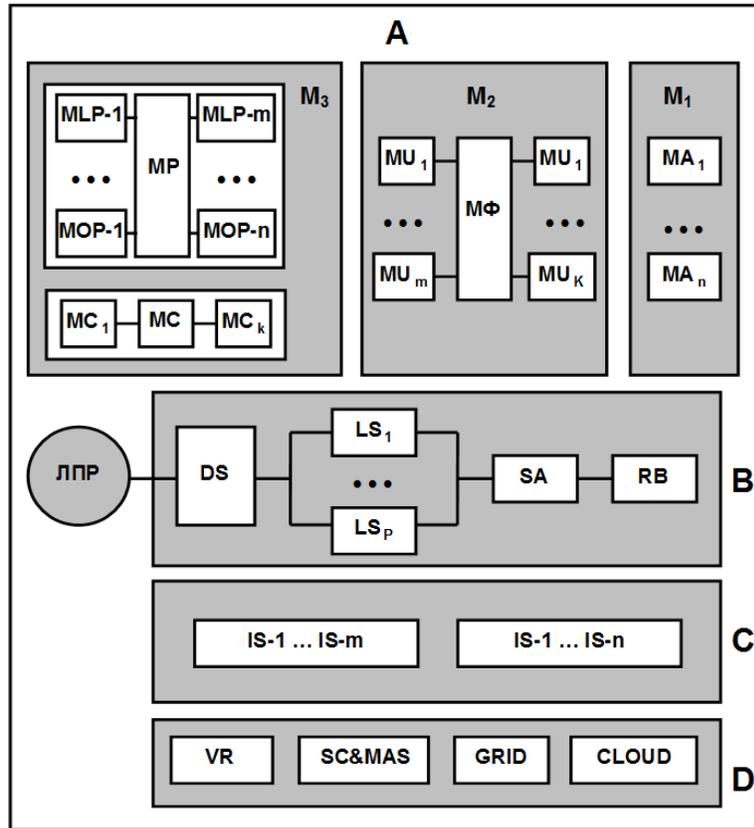


Рис. 2. Структура ВП контроля чрезвычайных ситуаций в ТS-системах

- шесть проекторов Rohar Projectiondesign с фильтрами круговой поляризации;
- две плазменные панели для вывода информации с дополнительных компьютеров в распределенной среде VLUC;
- комплекс оборудования по коммутации и трансформации видеосигналов;
- недеполяризующий экран обратной проекции;

- рабочие станции Hewlett-Packard Z800 и Z400 для управления системой.

Взаимодействие пользователя с ВР-системой обеспечивает комплекс устройств ввода информации, включающий: стандартные мышь и клавиатуру; 3D-манипулятор; камеры с высокой реактивностью на движение, сопряженные с системой motion capture; тактильные манипуляторы («перчатки»). Дополнительно в состав ВР-системы введен интерактивный стол для взаимодействия с системой в процессе поддержки принятия решений. Устройство выполнено на основе плазменной панели 103" Panasonic TH-103PF12ЕК с интерактивной сенсорной насадкой PQ Labs G3 Basic 103" на 32 касания с защитным стеклом и подключено к локальной сети как отдельное устройство ввода.

Топологическое пространство преобразования информации на основе современной теории катастроф

Особенностью топологии функциональных компонент ВП является интеграция вычислительных технологий классической математики (GA-систем) и ND-систем, сочетающих нейронечеткое (NF) и нейроэволюционное (NE) моделирование. Важная роль в реализации структурной и функциональной конфигурации ND-системы на основе методов современной теории катастроф принадлежит фрактальной геометрии и формальному концептуальному анализу. Топология, отображающая графическую интерпретацию физических закономерностей при исследовании взаимодействия сложного ДО с внешней средой формализуется на базе фрактальных структур ND-системы [13]. Рассматриваемые структуры, моделируют процессы развития текущих ситуаций в рамках парадигмы обработки информации в мультипроцессорной вычислительной среде [10]. Возникновение угрожающих, особенно предаварийных и аварийных ситуаций, выработка механизмов управления и поддержки принятия решений по сохранению безопасности ДО описывается с помощью потоков событий Work Flow [2]. Преобразование информации при функционировании ВП на основе динамической модели катастроф представлено на рис. 3.

Концептуальная модель преобразования информации ND-системой в сложной динамической среде, имеет вид:

$$S(U) = \langle F(Com) : \{T(t, \tau) \times X(KB) \times Q(V, W)\} \rightarrow Y(R) \rangle, \quad (1)$$



Рис. 3. Поток информации в интегрированном вычислительном комплексе ИП

где $S(U)$ — множество стратегий управления; $F(Com)$ — множество элементов, реализующих принцип конкуренции; $T(t, \tau)$ — множество моментов времени, определяющих модель развития угрожающих ситуаций $X(KB)$ — множество элементов оперативной базы данных; $Q(V, W)$ — множество значений вектора входных воздействий (состояние внешней среды — ветроволновые возмущения); $\{T(\tau) \times X(KB) \times Q(V, W)\}$ — множество закономерностей в данных; $Y(R)$ — множество правил обобщения информации; τ — интервал времени реализации.

Обратная алгоритмическая связь в концептуальной модели (1) используется для моделирования деятельности оператора ИП по способам формирования управляющих воздействий. Поддержка принятия решений реализуется на основе критериев максимальной эффективности. Принципом обратной алгоритмической связи является разность энтропий системы до и после получения информации, что уменьшает неопределенность в оценке и анализе текущего состояния контролируемого ДО и неоднозначность в выборе способов формирования управляющих воздействий в зависимости

от критичности возникающих ситуаций.

Формирование структуры данных ND-системы при моделировании динамических ситуаций реализуется путем перестройки данных в мультипроцессорной вычислительной среде [10]. Процесс перестройки сопровождается фазовым переходом, в результате которого отмечается качественный скачок в изменении элементов ND-системы, причем последовательность перестройки осуществляется в виде следующей цепочки преобразования информации [14]:

$$F(SA) \rightarrow Fluct \rightarrow Bifurc \rightarrow Reorg \rightarrow F(NSA) \quad (2)$$

где $F(SA)$ — функционирование ND-системы в области притяжения исходной структуры-аттрактора; $Fluct$ — отклонения (флуктуации); $Bifurc$ — бифуркация; $Reorg$ — реорганизация (фазовый переход); $F(NSA)$ — функционирование в области новой структуры-аттрактора.

В рамках представленной концептуальной модели формализуются процессы структурной и функциональной конфигурации ND-системы на основе аппарата знаний логической системы, организованной на базе синергетической теории управления [17] и когнитивной парадигмы [11]. Методы и модели ND-системы построены с использованием принципа сложности и концепции минимальной длины описания MDL [3].

Рассмотрим общую математическую постановку задачи контроля исследуемого динамического объекта (ДО) с помощью ВП. Представим эволюцию ДО на заданном интервале времени $[t_0, t_k]$ в виде вектора фазовых координат $z = (z_1, \dots, z_n)^T$, где T — оператор транспонирования; t_0, t_k — начало и конец временного интервала. В результате решения задачи интерпретации ситуации требуется определить оптимальную стратегию программного управления, переводящего исследуемый ДО из начального состояния в конечное, определяемое требованиями безопасности [14]:

$$U^*(opt) = (u^*(t)) \in [t_0, t_k]. \quad (3)$$

Задачу управления, генерации и принятия решений при функционировании ВП обозначим кортежем

$$\langle M, J_E, S, Q \rangle, \quad (4)$$

где M — модель динамики объекта; J_E — минимизирующий функционал; S — стратегия реализации оптимального управления; Q — характерные ограничения и связи.

Для решения задачи (4) зададим массив исходных данных

$$R = f(W, V, DO, T_L, U_0, U_1, [t_0, t_k]), \quad (5)$$

где W, V — возмущающие воздействия (массивы параметров моделей внешней среды); DO — динамический объект; T_L — массив времени запаздывания по каналам U, W, V ; U_0 и U_1 — нижние и верхние границы интервала изменения управляющих воздействий.

Множество состояний системы представим как декартово произведение

$$H_C = M \times J_E \times S \times Q \times R, \quad (6)$$

где M, J_E, S, Q, R — множества M различных моделей объектов ВП, видов функционала J_E , стратегий управления S , ограничений Q и значений массива R .

Наряду с множеством H_C введем множество H_R для определения задачи оптимального управления как декартово произведение

$$H_R = A \times B \times C \times T_L \times U_0 \times \Phi_E, \quad (7)$$

где $A, B, C, T_L, U_0, Z_k, Z_E$ — множество значений параметров моделей динамики системы (A — модели идентификации, B — модели контроля, C — модели прогноза ситуации), временного интервала T_L , границ управления U_0 и минимизирующего функционала Φ_E .

На основе соотношений (3)–(7) построен алгоритм и программный комплекс функционирования ВП мониторинга транспортных и социальных систем при интеллектуальной поддержке ГА и ND-систем с использованием и интеллектуальных технологий [2, 12, 13]. В качестве объектов оперативного контроля рассматриваются суда и плавучие технические средства освоения океана, в том числе и авианесущие суда, имеющие полетную палубу или вертолетную площадку. Объектами контроля социальной среды являются социодинамические процессы в обществе (разного рода акции, террористические акты, криминальные действия и пр.), а также процессы, обусловленные реакцией общества на внешние воздействия (паника при пожарах или наводнениях, развитие эпидемий и пр.).

Актуальность такого исследования определяется обоснованием теоретических аспектов построения топологической картины взаимодействия на основе динамической модели катастроф при функционировании ВП в условиях непрерывного изменения динамики внешней среды, а *новизна* —

синтезом моделей контроля транспортных и социальных катастроф на основе моделей GA и ND-систем, а также теоретическим базисом построения топологической картины катастроф на основе теорем и аксиом, определяющих основные требования к интерпретации ситуации в процессе эволюции системы в сложной динамической среде. Таким образом, в отличие от традиционного представления в настоящем исследовании реализована модель топологии сложных динамических систем, функционирующих в режиме реального времени.

Интерпретация топологического пространства при функционировании ND-системы

Модель топологии ND-систем — это интерпретирующая теория, в рамках которой можно рассматривать различные формализмы топологии в зависимости от рассматриваемой проблемы. Исходным является понятие множества, позволяющего в рамках концепции пространства и времени определить основные понятия интерпретации ND-системы.

Пространство и время в ND-системах

Взаимодействие ДО с внешней средой в ND-системах реализуется в пространстве и времени, с помощью которых отображается эволюция сложной системы. Под пространством понимается структура, в которой осуществляются преобразования информации и строятся топологические структуры на основе следующей теоремы:

Теорема 1. *Представление топологических структур ND-системы реализуется в виде трехмерного евклидова пространства, представляющего собой приближенный абстрактный образ реального физического пространства.*

Доказательство этой теоремы приведено в работах по топологии динамических систем [4, 5, 20] с использованием следующих определений:

Топологическим пространством ND-системы называется множество T , в котором выделено семейство F подмножеств, подчиненное следующим условиям: T — элемент семейства F , любое объединение множеств из семейства F есть элемент семейства F ; пересечение двух множеств из семейства F есть множество на F . Семейство F называется топологией

множества T , а его элементы — *открытыми множествами* этой топологии. Топология множества T , содержащая в качестве открытых множеств объединения вида $\cup_{\alpha} V_{\alpha} (V_{\alpha} \in B)$, называется топологией, порожденной семейством B . Замкнутым множеством топологического пространства ND-системы называются дополнения открытых множеств.

Топологическая динамика ND-систем формируется на основе алгоритмов преобразования информации пространственно-временных событий в рамках динамической модели катастроф. Используя пространственно-временное представление (x, y, z, t) для описания движения ND-системы, введем в рассмотрение функцию интерпретации $F(t)$. Каждая точка траектории системы имеет определенные пространственные координаты $x(t)$, $y(t)$, $z(t)$, являющимися функциями времени. «Замыкание» пространственной последовательности событий осуществляется на временном интервале $[t_0, t_k]$ эволюции ND-системы. Взаимно-однозначное соответствие между событиями и координатами на этом интервале представляется как

$$S \xleftrightarrow{K} (x, y, z, t), \quad (8)$$

где буква K показывает, в какой системе координат рассматривается событие S . При этом значениям (x, y, z, t) соответствует вполне определенная система координат.

В современной математике интерпретация пространства осуществляется в виде множества объектов, в качестве которых рассматривают геометрические фигуры, фрактальные множества и функции, отображающие состояния физической системы. Преобразование координат при интерпретации ND-систем выполняется на основе динамической модели катастроф. Концептуальные основы этой модели определяют топологический анализ и преобразование информации на интервале реализации $[t_0, t_k]$ для двух предельных случаев взаимодействия — движение к целевому аттрактору и потеря устойчивости (возникновение катастрофы). Рис. 4 иллюстрирует эту закономерность, определяющую топологические преобразования на плоскости и при переходе к эллиптическому отображению [14].

Пространства $R^2(r, \varphi)$ и $R^2(x^1, x^2)$ взаимнооднозначны и регулярны, а импликация отображает переход от плоскости ($r = 0, \infty; \varphi = 0, 2\pi$) к эллиптическому отображению. Отображение $f: C \rightarrow A$ задается формулами $x^1 = r \cos \varphi$, $x^2 = r \sin \varphi$. При этом прямоугольная сетка превращается в полярную.

Решение задач топологического синтеза ND-систем в сложных динамических средах связано с изучением свойств исследуемого простран-

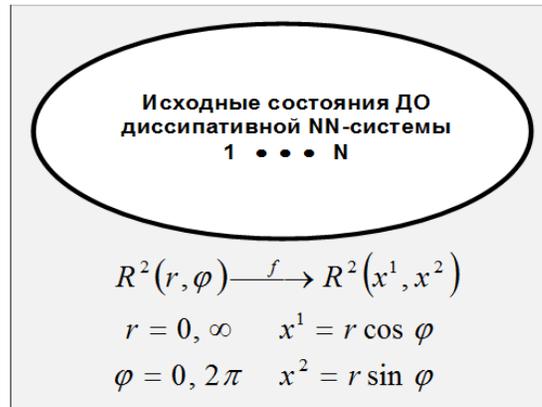


Рис. 4. Преобразование координат в задаче интерпретации нелинейной нестационарной системы (NN-системы) на основе динамической модели катастроф

ства и пространственных отношений. Рассмотрение пространства как общей онтологической категории связано с выбором *базовой концепции пространства*. Построение пространства ND-систем предполагает определение множеств пространственных примитивов (фрактальных множеств) и базовых пространственных отношений, а также задание структуры пространства в виде аксиом теории пространства, исходя из требований исследуемой предметной области.

Многие задачи параметрического синтеза ND-систем решаются с использованием методов современной компьютерной математики и нетрадиционного анализа на основе нейронечеткого и нейроэволюционного моделирования. Этот анализ надо рассматривать не как новую область вычислительной математики, а как единый математический «язык» интерпретации ND-систем в сложной динамической среде.

Топологическое пространство динамической модели катастроф

Важную роль в геометрической интерпретации текущих ситуаций с помощью ND-системы на базе методов современной теории катастроф играет

пространство событий. Каждое событие характеризуется положением — координатами x, y, z и временем t [14]. Фазовое пространство при аналитической интерпретации событий — это совокупность всех возможных состояний динамики ND-системы, которые интерпретируются как точки этого пространства.

Динамическая модель катастрофы [11], отображающая поведение сложного объекта в ND-системе, представлена в виде кортежа:

$$DM(Cat) = \langle H(Cat), A(Cat) \rangle, \quad (9)$$

где $H(Cat)$, $A(Cat)$ — компоненты, интерпретирующие динамическую среду взаимодействия на основе геометрической и аналитической модели катастроф.

Геометрическая и аналитическая интерпретация физической картины взаимодействия в ND-системе на основе компонент $H(Cat)$ и $A(Cat)$ имеет вид:

$$H(Cat) = \langle B(t), W(t), V(t) \rangle, \quad (10)$$

$$A(Cat) = \langle A(CR), A(PH), A(ND) \rangle, \quad (11)$$

где $B(t)$ — бифуркационное множество, представляющее собой образ особого множества в пространстве управляющих параметров; $W(t)$ — множество, отображающее динамическую среду, интегрирующую влияние внешних возмущений и особенностей динамики объекта; $V(t)$ — множество, отображающее структурные изменения в ДО, вызванные непрерывным изменением действующих возмущений; $A(CR)$ — математическая модель, отображающая оценку динамической среды взаимодействия на основе критериальных соотношений, разработанных в рамках стандартных алгоритмов исследуемой проблемной области; $A(PH)$ — математическая модель, отображающая оценку динамической среды с помощью теории стохастических систем, теории детерминированного хаоса и синергетической парадигмы; $A(ND)$ — математическая модель, отображающая оценку динамической среды на основе ND-системы.

Эволюция ND-системы определяется особенностями взаимодействия исследуемого ДО с внешней средой и формализуется на основе следующей теоремы и вытекающих из нее следствий.

Теорема 2. *Поведение ND-системы на интервале реализации $[t_0, t_N]$, интерпретируется в рамках динамической модели катастроф, позволяющей выделять в процессе эволюции системы критические интервалы вре-*

мени возникновения неблагоприятных режимов функционирования и выработать управляющие воздействия $U(t)$ по предотвращению нестандартных (нештатных и экстремальных) ситуаций.

Следствие 2.1. Возникновение и развитие неблагоприятных ситуаций в ND-системе отображается в виде фрактальной структуры $E(CM)$, содержащей фиксированные значения перемещения ДО в заданной точке эволюции системы на временном интервале $[t_0, t_N]$ в исследуемой ситуации.

Следствие 2.2. Динамика ND-системы, заданная в виде фрактальной структуры, характеризуется состояниями системы при движении к целевому аттрактору (стабильное состояние системы) и при потере устойчивости (возникновение катастрофы). Условия перехода между этими состояниями описываются на основе логической системы знаний.

Доказательство этой теоремы применительно к контролю экстремальных ситуаций в процессе функционирования ИС [1, 8, 18] можно найти в монографии [11] при рассмотрении приложения динамической модели катастроф в задачах динамики сложных объектов.

Методы управления в ND-системе ориентированы на обеспечение функционирования ИС в условиях непрерывного изменения динамики объекта и внешней среды. Адаптация системы обеспечивается с помощью механизмов нечеткого управления, определяющих конфигурацию «вход–выход». При этом обратная связь может быть отрицательной при стабилизации системы в бассейне аттрактора, или положительной, ведущей к бифуркации, нестабильности и хаосу.

В рамках представленной концептуальной модели формализуются процессы структурной и функциональной конфигурации ND-системы на основе аппарата знаний логической системы, организованной на базе синергетической теории управления [16] и когнитивной парадигмы [11]. Модели динамической базы знаний ВП построены с использованием принципа сложности и концепции минимальной длины описания [3, 19].

Топологическое пространство фрактальных структур при исследовании динамики ND-систем

Принципиальное отличие предлагаемого топологического подхода к обработке информации при функционировании ND-систем состоит в использовании различных моделей фрактального анализа при интерпретации динамических ситуаций. Формирование фрактальных отображений осуществ-

ляется на основе нейронечеткого и нейроэволюционного моделирования. Реализация разработанных моделей в прикладных системах определяется комплексным характером математического описания нарушений непрерывности исследуемых феноменов. Преимущества предлагаемого подхода заключаются в возможности геометрической, но и аналитической интерпретации экстремальных ситуаций и в представлении информации о динамике ситуации в виде простых геометрических образов фрактального отображения, легко воспринимаемых оператором ВП в условиях ограниченного времени на принятие решений.

Сформулируем задачу исследования фрактальной структуры на основе нейроэволюционного моделирования в интервале реализации $[t_1, t_N]$ в виде эллипса, движущегося по заданной траектории.

Определение 1. Область Ω формирования фрактальной структуры Φ в пространстве состояний определяется как ограниченная конфигурация множества всех состояний динамической системы в процессе ее эволюции в нестационарной среде:

$$\Omega : \Phi_0 \rightarrow \Phi_N \in [t_0, t_N], \quad (12)$$

где Φ_0 — начальное состояние фрактальной структуры Φ ; Φ_N — конечное состояние, определяющее следующие условия:

$$\Phi_N = Stab(Attr), \Phi_N = Cap(Attr), \quad (13)$$

где $Stab(Attr)$, $Cap(Attr)$ — области притяжения аттрактора в случае стабильного состояния системы и потери устойчивости движения (возникновение катастрофы).

Определение 2. Отображение φ , действующее на Φ , определяет операцию сдвига фрактальной структуры в процессе эволюции динамической системы, которая реализуется при выполнении условий:

$$\varphi : \Phi_0 \dots \Phi_N \in [t_0, t_N], F_0 \dots F_N, G_0 \rightarrow G_M, \quad (14)$$

где $\Phi_0 \dots \Phi_N$ — отображение движения фрактальной структуры, а $F_0 \dots F_N$ — модификация фрактальной структуры в процессе эволюции на интервале реализации $[t_0, t_N]$.

Определение 3. Операция сдвига без изменения конфигурации определена, если фрактальные структуры принадлежат одному семейству отображения (рис. 5) интегрированной области изменения параметра $X(t)$ в виде векторного множества $\{R_1, \dots, R_6\}$, определяющего множество $W(t)$ [13].

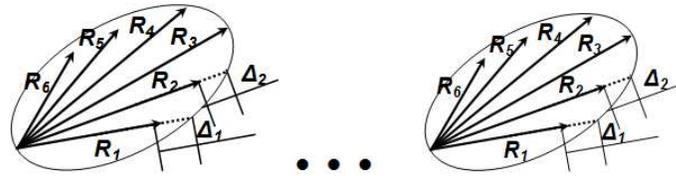


Рис. 5. Когнитивная структура без изменения конфигурации фрактала

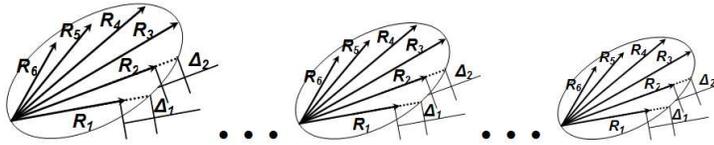


Рис. 6. Когнитивная структура с сохранением конфигурации фрактала в фазах расширения и сжатия

Определение 4. Операция сдвига с изменением конфигурации фрактальной структуры определена, если выполняется условие сохранения множества, отображающего структуру области, интегрирующей компоненты математического описания (рис. 6).

Определение 5. Операция сдвига с изменением фрактальной структуры определена, если выполняются условия сохранения множества, отображающего сложную структуру области, интегрирующей компоненты математического описания (рис. 7).

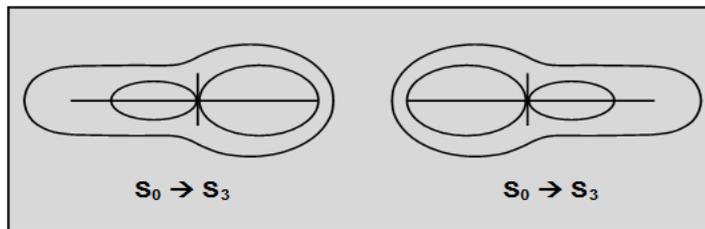


Рис. 7. Геометрическая интерпретация области $W(t)$ для различных значений параметров объектов S_0

При реализации операций (12)–(14) заданная фрактальная структура функционирует в сложной динамической среде с обобщенным множеством достижимости G^f и вектором показателей качества $f \in R^n$. Наряду с эллиптическими фрактальными отображениями при изучении динамики ND-систем могут оказаться полезными структуры в виде L-систем, систем итерированных функций (СИФ) и множества Кантора [4].

Связь хаоса с фракталом устанавливается путем интерпретации СИФ как структуры, состоящей из полного метрического пространства X и сжимающих отображений T_1, \dots, T_N , действующих в X . Если коэффициенты сжатия представить как

$$S_1, \dots, S_N, S = \max\{S_1, \dots, S_N\}, \quad (15)$$

то по теореме Хатчинсона СИФ в виде

$$E_0 = T_1(E_{k-1}) \cup T_2(E_{k-1}) \cup \dots \cup T_m(E_{k-1}), k = 1, 2, \dots \quad (16)$$

сходится к единственному компактному аттрактору E .

Рандомизированный алгоритм СИФ вместо преобразования $T_1(S)$, $T_2(S)$, $T_3(S)$ реализует стратегию случайного поиска на основе датчика случайных чисел.

В отличие от теории СИФ, L-система состоит из алфавита, слова инициализации, называемого аксиомой (инициализатором), и набора порождающих правил, указывающих, как преобразовать слово при переходе от уровня к уровню (от итерации к итерации).

Синтез топологических структур при оценке возникновения резких скачкообразных явлений в процессе эволюции ND-системы выполняется в рамках концепции динамической модели катастроф. На систему действует возмущение, вызывающее резкое снижение сопротивляемости ДО внешним крениющим нагрузкам. Зафиксируем интервал времени $[t_1, t_N]$ на котором динамические характеристики $X(t)$ могут достигать минимального значения. Положение экстремума можно установить, используя план Фибоначчи [16], который интерпретируется с помощью кода Грея [8], обладающего свойством непрерывности бинарной комбинации. Процедура определения момента времени $t^* \in [t_1, t_N]$, $X(t) \rightarrow \max$ с использованием чисел Фибоначчи предусматривает совместное использование экспериментальных данных от датчиков измерительной системы и от аналитической компоненты динамической модели катастроф.

Помимо рассмотренного плана Фибоначчи при анализе ND-системы находит применение фрактальная структура в виде *дерева Фибоначчи*. Кластер Фибоначчи при оценке возникновения «скачка» (катастрофы) на заданном интервале $[t_1, t_N]$ изображается в виде дерева в соответствии с преобразованиями [14]:

$$\Phi(F_R) = \langle G(F_R), C(F_R) \rangle, \quad (17)$$

где $\Phi(F_R)$ — семейство фрактальных структур; $G(F_R)$ — исходная фрактальная структура; $C(F_R)$? операции фрактальной алгебры.

Прогноз развития исследуемой ситуации состоит в выполнении алгоритма, разработанного на основе ND-систем. Фрактальная структура реализована в виде процедуры, отображающей такты построения дерева Фибоначчи в рамках композиции фрактальных структур. Как следует из результатов анализа, прогнозирование исследуемой ситуации состоит в выполнении такта фрактальной структуры при заданном числе вершин. В задачах контроля динамики объектов ND-системы может быть полезно построение *модифицированного* дерева Фибоначчи, структура которого описана в работе [16].

Помимо рассмотренных приложений при контроле текущих ситуаций NN-системы числа Фибоначчи находят применение в оптимизационных задачах на основе процедур нейроэволюционного моделирования. Алгоритмы генетических операторов, построенных на основе различных интерпретаций, позволяют выделить достаточно простые преобразования, основанные на использовании чисел Фибоначчи [14, 16].

На основании топологической интерпретации можно исследовать поведение ДО в зависимости от уровня действующих возмущений и проследить последовательное развитие динамики для различных стадий эволюции, определяющих переход от угрожающей ситуации к развитию аварии — возникновению предаварийной, аварийной ситуаций. В качестве иллюстрации на рис. 8 приведены стадии эволюции ND-системы в рамках динамической модели катастроф.

Здесь эллиптические структуры $\Omega_1, \dots, \Omega_5$ отображают постепенное ухудшение исследуемой динамической характеристики в процессе развития ситуации, связанной с потерей устойчивости и возникновении катастрофы. Время развития ситуации характеризует интервал $[t_0, t_N]$, а в качестве показателя устойчивости использовано изменение максимального значения векторной диаграммы (м). Топологическое пространство этой эволюции могут дополнять физические картины динамики взаимодействия,

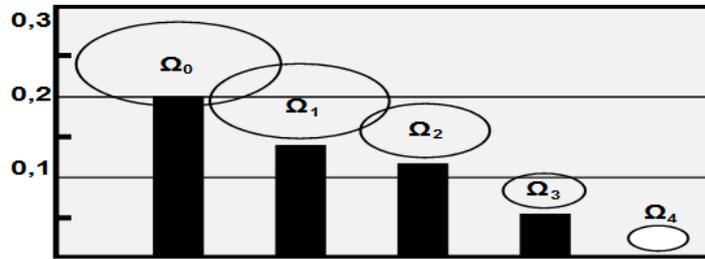


Рис. 8. Эволюция ND-системы при различном уровне действующих возмущений на интервале $[t_0, t_k]$: $\Omega_0 \rightarrow \Omega_1$? возникновение угрожающей ситуации; $\Omega_2, \dots, \Omega_4$? развитие ситуации при переходе к предаварийной и аварийной ситуациям и полной потере устойчивости

наблюдаемые на самоходных радиоуправляемых моделях в условиях естественного волнения [1, 17].

Аксиоматический базис топологического пространства ND-систем

Сформулируем описание теории ВП в виде интерпретации сложных динамических систем. Построение теоретического базиса ВП определяется исходными аксиомами рассматриваемой проблемной области. В основе аксиоматического синтеза лежит *метод интерпретаций*. Каждому понятию и отношению аксиоматической теории соответствует некоторое формализованное описание. Выделение объектов транспортной или социальной среды из совокупности реально взаимодействующих элементов глобальной системы предполагает эвристическое пренебрежение отдельными связями или их малой зависимостью от управленческих решений. Совокупность таких объектов называется *полем интерпретации* транспортной и социальной среды:

$$P(Int) = \langle Q_1(CSE), \dots, Q_m(CSE) \rangle, \quad (18)$$

где $\langle Q_1(CSE), \dots, Q_m(CSE) \rangle$ — математические описания моделей идентификации, контроля и прогноза ситуации, определяющие общую структуру функциональных моделей ВП.

Всякому утверждению теории ВП ставится в соответствие некоторое высказывание об элементах поля интерпретации, свойства которого являются предметом рассмотрения базовой теории — динамической модели катастроф, которая также может быть представлена как аксиоматическая теория. Этот метод позволяет доказывать непротиворечивость теории ВП в зависимости от аксиоматической теории катастроф.

Уточнением понятия аксиоматической теории ВП является понятие *формальной системы* FS. Это позволяет представить различные теории элементов транспортной и социальной среды как математические объекты и строить общую теорию ВП как метатеорию таких теорий.

$$FS = \langle Meta\{(Th)_1, \dots (Th)_n\} \rangle, \quad (19)$$

где $\{(Th)_1, \dots (Th)_n\}$ — совокупность теоретических принципов, определяющих функционирование составляющих общей теории на основе концепции ВП.

Формальная система ВП строится как класс отображений, в котором выделяется подкласс *теорем* данной формальной системы. Выводом формальной системы является конечная последовательность структур, в которой каждая формула является либо аксиомой системы, либо непосредственно следует из каких-либо предшествующих этой последовательности формул по одному из правил вывода системы.

Основные операции, выполняемые в ND-системе в рамках парадигмы [13], осуществляется на основе аксиоматического базиса, позволяющего описать топологию ND-системы на уровне структурной и функциональной конфигурации (рис. 9).

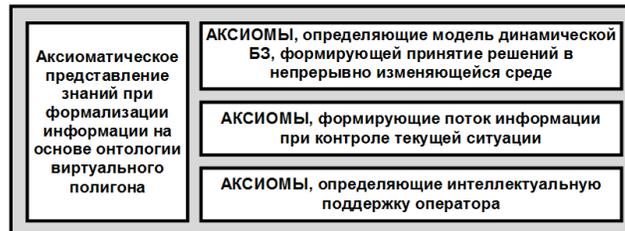


Рис. 9. Аксиоматический базис в ND-системе

Принципиальным достоинством такой технологии является представление эволюции ДО на интервале реализации $[t_0, t_N]$ в виде фрактальных

структур, а интерпретации динамики взаимодействия — с помощью энтропийного анализа [6]. В результате достигается простота и наглядность отображения текущей ситуации в сложной динамической среде [11].

Аксиоматическое представление знаний

Общие понятия аксиоматики исследуемой проблемной области специфичны в каждой прикладной онтологии. Применительно к рассматриваемой проблеме аксиоматическое представление знаний в ND-системе определяется формализацией потока информации на основе комплексной онтологии. В рамках этого представления выделены следующие основные аксиомы [13].

Аксиомы идентификации. Назначением аксиом идентификации является описание всех типов переменных и отношений, определяющих область топологической структуры:

$$Axiom(Ident) = \langle Var, Rel \rangle \in \Omega(Str), \quad (20)$$

где Var, Rel — переменные задачи и отношения между ними; $\Omega(Str)$ — топологическая структура. Если объект управления описывается множеством параметров $X = X_1, \dots, X_N$, то требуется находить или уточнять значения части параметров. При этом каждый параметр характеризуется определенным интервалом значений, с помощью которого задаются известные параметры и ограничения в задачах оптимизации.

Аксиомы планирования. Для осуществления итеративной процедуры вводятся аксиомы планирования, задающие правила (порядок и условия корректности) вычислений. В основе вычислений топологических объектов в области эволюции фазового пространства лежит свойство интервальной арифметики, позволяющее осуществить сходимость итеративной процедуры вычислений значений параметров к некоторым локализирующим интервалам, содержащим требуемые решения.

$$Axiom(Plan) = \langle Evol(PH), Int(Cal) \rangle, \quad (21)$$

где $Evol(Ph)$ — область эволюции фазового пространства, $Int(Cal)$ — процедуры интервальной арифметики.

Аксиомы вычислений. С помощью аксиом вычислений задаются правила вычисления отношений в области эволюции фазового пространства.

Аксиомы вычислений преобразования фазового пространства включают также аксиомы оптимизации.

$$Axiom(Calcul) = \langle Rule(Cal), Axiom(Opt) \rangle, \quad (22)$$

где $Rule(Cal)$ — правила вычислений; $Axiom(Opt)$ — аксиомы оптимизации. В отличие от аксиом идентификации, вычисления и планирования, эти аксиомы позволяют осуществлять поиск оптимальных решений. Таким образом, аксиоматическое представление знаний в ND-системе позволяет осуществлять поддержку процедур нейронечеткого и нейроэволюционного моделирования при интерпретации поведения ДО в процессе эволюции в сложной динамической среде.

Аксиоматический базис фрактальной геометрии

Развитие теоретических принципов интерпретации закономерностей динамики взаимодействия в ND-системе реализуется на базе фрактальных структур [20]. Рассматриваемая конфигурация обеспечивает моделирование процессов развития сложных ситуаций и механизмов управления изменениями конфигурации программных модулей ВП в рамках общей концепции современной теории катастроф [11]. Организация ND-системы на основе фрактального отображения описывается граф-структурой

$$G = (V(E), A(E))$$

в виде событий и условий. *События* характеризуют управляющие действия в системе, а *условия* — логическое описание ее состояния.

Рассматриваемые в ND-системе текущие фракталы отображают эволюцию системы в виде структур

$$g(v(E), a(E)) \in G(V(E), A(E)), \quad (23)$$

определяющих последовательность конфигураций $g_1(F_R), \dots, g_N(F_R)$ движения ДО при стабилизации системы (движение к целевому аттрактору) и при потере устойчивости (возникновение катастрофы). На текущей конфигурации семейства фракталов фиксируются начальное $g_0(F_R)$ и конечное $g_N(F_R)$ состояния ДО в зависимости от особенностей интерпретации. Система развивается на временном интервале $[t_0, t_N]$, которому сопоставляется последовательность дискретных состояний, формализуемых в рамках гипотезы квазистационарности [1].

Пространство состояний фрактальной системы определяется упорядоченным множеством фрактальных отображений. Эти отображения представляют собой самоподобные структуры, развивающиеся в процессе эволюции системы. В общем виде фрактальный ансамбль изображается в виде компактного множества, представленного на основе следующих определенных интерпретации динамики ND-системы.

Теоретический базис преобразования информации в сложных динамических средах при интерпретации объектов транспортной и социальной среды реализован в рамках фундаментальной теоремы динамической модели катастроф [10], сформулированной применительно к рассматриваемой среде на основе исследований [1, 8, 18]:

Теорема 3. *Для сложных динамических систем, описываемых транспортной и социальной среду в рамках принципа конкуренции с помощью целевого функционала, реализующего функцию интерпретации с ограниченным числом параметров и переменных, существует только ограниченное число локальных геометрических структур фрактальной геометрии для множеств динамической модели катастроф в зависимости от особенностей ситуации и уровня действующих возмущений.*

Реализация этой теоремы при геометрической и аналитической интерпретации поведения объектов транспортной и социальной систем в сложной динамической среде связана с использованием следующих важных следствий.

Следствие 3.1. Динамическая модель катастрофы определяет функцию интерпретации в виде бифуркационного множества в пространстве управляющих переменных; множества, определяющего динамическую среду управления, интегрирующую потоки событий; множества, характеризующего внешнюю среду и структурные изменения в транспортной и социальной системе. При изменении управляющих параметров система может эволюционировать к состоянию устойчивого равновесия, соответствующего области стабилизации при движении системы к целевому аттрактору.

Следствие 3.2. В процессе эволюции транспортной и социальной системы в сложной динамической среде при реализации управляющих воздействий существуют различные состояния равновесия, определяемые множествами динамической модели катастроф, в результате чего в процессе управления возникает возможность выбора между этими состояниями.

Следствие 3.3. При недостаточной эффективности управляющих воздействий система, описывающая эволюцию транспортной и социальной

среды, может достигать состояния потери устойчивости настолько быстро, что можно рассматривать этот процесс протекающим практически мгновенно (возникновение катастрофы).

Интерпретация динамики транспортной и социальной систем в режиме реального времени потребовала разработки алгоритмов анализа текущих ситуаций в условиях ограниченности временных интервалов и исходной информации. Алгоритмы решения задач реализуются на основе теории сложности [19] и концепции минимальной длины описания А. Н. Колмогорова [3].

Эволюция системы отображается на основе синергетической парадигмы [17]. В рамках такой интерпретации используется подход, реализуемый с использованием *обобщенного принципа диссипации*, сформулированного Н. Н. Моисеевым [7]. Применительно к исследованию транспортной и социальной среды этот принцип имеет следующую интерпретацию: *если допустимо не единственное состояние транспортной или социальной среды, а целая совокупность состояний, согласованных с действующими законами и связями, наложенными на систему, то реализуется то состояние, которому отвечает минимальный рост энтропии. Этот принцип носит универсальный характер и может быть использован при изучении поведения сложных динамических систем.*

Процесс эволюции состоит в переходе транспортной или социальной системы из одного состояния в другое за счет изменения управляющих воздействий. В результате система сама начинает движение в сторону нового состояния, которое она занимает в течение некоторого интервала времени. В синергетике такой переход основан на принципе *бифуркационного управления* рисками. Развитие динамики системы в этом случае осуществляется на основе следующих аксиом, сформулированных в рамках обобщенного принципа диссипации [7]:

Аксиома 1. Бифуркационная диаграмма, отображающая движение транспортной или социальной системы к целевому аттрактору представляет собой *каскад бифуркаций*. При этом движение по регулярным участкам эволюции чередуется с точками бифуркации, характеризующими ситуации выбора «параметра порядка» в самоорганизующейся системе на основе синергетической парадигмы [17].

Аксиома 2. Движение по каскаду бифуркаций в случае потери устойчивости ДО транспортной или социальной среды характеризуется траекторией движения системы, отображающей возрастание опасности наступления

критической ситуации (катастрофы).

Аксиома 3. Принцип вложения аттракторов динамической системы определяет базовые понятия синергетической парадигмы, которые можно интерпретировать как декомпозицию пространства состояний в процессе самоорганизации, приводящую к выделению параметров порядка, к которым подстраиваются остальные параметры системы.

Реализация аксиом 1–3 позволяет выявлять «скрытые» эффекты и явления, возникающие в транспортной и социальной среде. Вследствие декомпозиции пространства состояний формируется определенная направленность процессов самоорганизации и образуются *целевые аттракторы*, имеющие свои области притяжения в зависимости от особенностей множеств явлений, определяющих структуру динамической модели катастроф [11]. Это свойство нелинейных диссипативных систем объясняется эффектом самоорганизации и открывает новые возможности *анализа рисков* принятия решений в транспортной и социальной среде при интерпретации чрезвычайных ситуаций [2].

Управление и принятие решений при функционировании ND-системы в виртуальной среде

Целью управления и принятия решений при функционировании ВП является достижение желаемого (целевого) аттрактора, т. е. асимптотически устойчивого конечного состояния транспортной или социальной среды. Размерность целевого аттрактора существенно меньше размерности исходного пространства. Это позволяет сформулировать утверждения, определяющие общий подход к моделированию поведения ДО транспортной и социальной среды в рамках синергетической парадигмы [17].

Процессы обработки информации в интегрированном вычислительном комплексе ВП включают две фазы — фазу расширения и фазу сжатия пространства состояний. Эти фазы реализуются путем совокупности управляющих воздействий. В фазе расширения формируется подмножество различных альтернатив поведения ДО транспортной или социальной среды. В фазе сжатия преобразуется область притяжения множества аттракторов в один из желаемых (целевых) аттракторов. Стратегия направленной самоорганизации при функционировании ВП состоит в формировании и поддержании системных инвариантов, определяющих структуру соответствующих аттракторов — целей управления и принятия решений.

На основе этих утверждений сформулируем общую постановку задачи синтеза ВП мониторинга транспортной и социальной среды при управлении и принятии решений на основе синергетического подхода. Формальная модель, определяющая динамику взаимодействия объектов в транспортной и социальной среде, может быть описана с помощью соотношения [14]:

$$S(t) = F(X, U, W(t), J(t)), \quad (24)$$

где $x(t)$ — параметры, определяющие состояния среды взаимодействия; $u \in U$ — вырабатываемые управляющие воздействия; $W(t), J(t)$ — внешние и параметрические воздействия.

Создание фрактальной структуры рассматриваемого приложения базируется на развитии моделей [4, 15]. Фрактальные компоненты моделей взаимодействия находят применение при выполнении распределенных вычислений на основе парадигмы обработки информации в высокопроизводительной вычислительной среде [10].

Концептуальная модель вычислительного комплекса ВП, реализующего динамическую модель катастроф [11], определяет решение следующих задач анализа и прогноза развития текущих ситуаций в транспортной и социальной среде:

$$T(GS) = \langle G(Idea), G(Appr), G(For) \rangle, \quad (25)$$

$$G(Idea) = \langle G(Env), G(DO) \rangle, \quad (26)$$

$$G(For) = \langle G(Beh), \{G(Env), G(DO)\} \rangle, \quad (27)$$

где кортеж $\langle \bullet \rangle$ характеризует граф-структуру задач контроля поведения динамики среды: идентификация $G(Idea)$, аппроксимация $G(Appr)$ и прогноз ($G(For)$) текущей ситуации; $G(Beh)$, $G(Env)$, $G(DO)$ — структуры, определяющие движение объектов транспортной и социальной среды в процессе эволюции (Beh), параметры внешней среды $G(Env)$, динамики транспортной системы и социальных явлений $G(DO)$.

В соответствии с концепцией динамической модели катастроф [11] граф-структура $G(Beh)$ реализует принцип формирования эволюции транспортной и социальной среды:

$$G(Beh) = \langle G(Attr) \rangle, \quad (28)$$

$$G(Attr) = \langle G(Stab), G(Cap) \rangle, \quad (29)$$

где $G(\text{Attr})$ — аттракторные множества; $G(\text{Stab})$ — множество, формирующее движение системы к целевому аттрактору; $G(\text{Cap})$ — множество при потере устойчивости движения (возникновение катастрофы).

В процессе эволюции транспортной и социальной среды ВП вырабатывает управленческие решения. Интеллектуальная поддержка оператора ВП реализуется в рамках когнитивной парадигмы. Информационные границы когнитивной структуры по способам формирования управляющих решений формируются с использованием кругов Эйлера [18]. Расширение области кругов Эйлера обеспечивается повышением уровня формализации управления при анализе и прогнозе динамики объектов среды взаимодействия.

Реализация принципов функционирования ND-системы в высокопроизводительной среде виртуального полигона

Формирование концептуальной модели функционирования динамической базы знаний ВП предусматривает генерацию альтернативных концепций, анализ вариантов и выбор предпочтительной технологии. Разработка нейросетевых моделей, интерпретирующих динамику ND-систем, проводится на основе работ [8, 11, 18]. Для упрощения процедур синтеза ИНС используется гипотеза квазистационарности [1].

Формирование нейросетевой модели ND-системы на участке *квазистационарности* заключается в синтезе алгоритма рекуррентной модификации параметров и определении структуры настраиваемой модели на основе обучающей выборки, полученной по результатам данных динамических измерений и математического моделирования. Структурный синтез нейросетевой модели осуществляется путем решения задачи оптимизации. Поиск структуры модели осуществляется на основе определения максимального значения целевой функции при равной вероятности различных структур настраиваемой модели. В качестве целевой функции при решении задачи структурной оптимизации используется модель, наиболее полно отражающая особенности динамики объекта на рассматриваемом участке квазистационарности. Параметрический синтез ИНС осуществляется на основе рекуррентной процедуры оценки параметров нейронной сети для заданных векторов входа и выхода на рассматриваемом участке квазистационарности. Элементами обучающих выборок, подаваемых на вход и выход настраиваемой нейросетевой модели, являются векторы измерений. На

выходе ИНС формируется последовательность данных, которая рассматривается как вектор-функция заданных параметров.

Функционирование ИНС в рамках парадигмы высокопроизводительных вычислений [9] обеспечивает возможности нелинейного преобразования информации и массовый параллелизм. При этом достигается высокий уровень параллельной обработки информации за счет выбора архитектуры сети (структурный синтез) и использования быстродействующих алгоритмов при «настройке» синоптических связей (параметрический синтез) и организации общей системы параллельных вычислений [2, 7, 16].

Типичными моделями ИНС являются:

- модель преобразования информации при реализации динамической базы знаний на основе принципа адаптивного резонанса [8, 18];
- модель идентификации текущей ситуации с целью формирования аналитического представления модели катастроф [11];
- модель непрерывного контроля текущей ситуации в условиях неопределенности и неполноты исходной информации [1];
- модель, аппроксимирующая поведение объекта в сложной динамической среде в рамках синергетической парадигмы [17];
- модель управления, основанная на реализации нейросетевого контроллера [8, 11, 18].

Описание этих моделей при функционировании ND-системы приведено в работе [14].

Интеллектуальные технологии ND-системы при моделировании морских динамических объектов

Когнитивная парадигма при обработке информации ND-систем

Когнитивная парадигма при интерпретации текущих ситуаций методами теории катастроф открывает возможности человеко-компьютерного взаимодействия в режиме реального времени. Главное преимущество такой вычислительной технологии — решение проблемы обеспечения быстрой реакции оператора на возникающие события при контроле сложных, особенно нестандартных (нештатных и экстремальных) ситуаций. На основе достижений в области интеллектуального управления когнитивный подход определяет концепцию представления знаний в трудно формализуемых средах [1, 8, 18].

Общая структура исходной информации при интерпретации текущей ситуации в рамках когнитивной парадигмы формируется на основе семантической сети, с помощью которой дается описание рассматриваемых задач ND-систем и методов их решения:

$$X = X_A \cup X_K \cup X_S, \quad (30)$$

где X_A — данные о текущей ситуации, X_K — результаты, получаемые на основе анализа имеющейся информации о динамике ND-системы, X_S — данные, специфичные для каждой задачи интерпретации динамики взаимодействия, и результатов ее анализа.

Обработанные и структурированные данные поступают на вход динамической базы знаний, осуществляющей процедуру логического вывода в сложной динамической среде на основе принципа адаптивного резонанса [1, 8, 18].

Обработка информации на основе когнитивной парадигмы и моделей топологии динамической теории катастроф может быть реализована в рамках концепции самоорганизующихся систем [11–14]. Модель знаний когнитивной структуры представляет собой совокупность эмпирических аксиом и операций, реализующих многообразие математических методов обработки информации. Формально модель знаний исследуемого топологического пространства может быть представлена в виде когнитивной структуры:

$$M(Cogn - Know) = \{F/m\} : J(Imp) \rightarrow J(Out), \quad (31)$$

где $\{F/m\}$ — когнитивная структура, реализующая модель катастрофы; $J(Imp)$, $J(Out)$ — вход и выход модели.

Оператор оценки истинности (адекватности) когнитивной структуры модели катастроф имеет вид

$$J\{Cat(a/A)\} \rightarrow J\{Cat(b/B)\}, \quad (32)$$

где $J\{Cat(a/A)\}$, $J\{Cat(b/B)\}$ — оператор, преобразующий элементы знания когнитивной структуры на входе и выходе системы знаний.

Многообразие результатов работы когнитивной структуры топологического пространства ND-системы определяется как

$$\langle WF(a/A), F(b/B), F(c/C) \rangle. \quad (33)$$

Здесь $F(a/A)$, $F(b/B)$, $F(c/C)$ — функции интерпретации, описывающие элементы знания на входе, выходе и при описании результатов работы когнитивной структуры.

Эволюция когнитивной структуры топологического пространства (поле импульсов) в процессе развития текущей ситуации определяется в виде потока информации

$$Imp : J(e/E) : \{J(a/A)\} \rightarrow \{J(b/B)\}, \quad (34)$$

где $J(e/E)$ — энергия импульсов, задающих поток информации как топологии в модельно-параметрическом пространстве развития текущей ситуации.

Траектория, реализуемая преобразованием (34) представляет собой последовательность состояний ND-системы, смена которых осуществляется в зависимости от уровня действующих возмущений и особенностей динамики объекта. Управление сложным ДО в процессе развития эволюции топологического пространства формируется на основе рекомендаций, вырабатываемых ВП на основе данных динамических измерений, интегрированной системы знаний и моделирования на основе стандартных, нечетких и нейросетевых моделей.

Соотношения (31)–(34) позволяют представить текущую ситуацию и управление в топологическом пространстве как преобразование:

$$Str(\tau/t) : J\{Imp(a/A, b/B, c/C)\} \rightarrow J\{Out(a/A, b/B, c/C)\}, \quad (35)$$

$$U : Imp(\tau/T) \rightarrow Out(\tau_0/T),$$

где τ_0/T — целевой аттрактор ND-системы, движение к которому в условиях неопределенности формируется с помощью гипотез и упрощающих предположений в рамках синергетической парадигмы.

Интерпретация поведения сложных ДО на базе когнитивной парадигмы в топологическом пространстве осуществляется на основе следующих аксиом и утверждений:

Аксиома 4. Информационные границы для формирования управляющих решений при интеллектуальной поддержке оператора ВП зависят от особенностей возникающих ситуаций и характеризуются на основе предварительного анализа и прогноза развития ситуации при функционировании динамической базы знаний и модели теории катастроф.

Аксиома 5. Модель интеллектуальной поддержки оператора ВП предусматривает реализацию когнитивной парадигмы в рамках алгоритмического контура программного и адаптивного управления, а также алгоритмического контура самообучения системы.

Управляющие воздействия в алгоритмическом контуре *программного управления* ND-системой формируются автоматически на основе данных динамических измерений и формализованной системы знаний об особенностях динамики взаимодействия объекта с внешней средой в исследуемой ситуации. Управляющие воздействия в алгоритмическом контуре *адаптивного управления* ND-системой вырабатываются в автоматизированном режиме на основе модели, реализующей теорию адаптивного резонанса (автоматическое поле параметрической настройки системы) с использованием формализованных знаний и обобщенного опыта управления. Управляющие воздействия в алгоритмическом контуре *самообучения* системы в процессе интеллектуальной поддержки оператора формируются с помощью компоненты самообучения, функционирующей на основе текущей и накопленной информации о взаимодействии объекта с внешней средой в нестандартных (нештатных и экстремальных) ситуациях.

Расширение областей, сформулированных в приведенных выше аксиомах и утверждениях, достигается за счет повышения уровня формализации управления при анализе и прогнозе динамики объекта в сложных ситуациях, особенно в нестационарной среде.

Когнитивная парадигма, реализуемая на основе топологических структур динамической модели катастроф, способствует эффективному диалогу «Оператор - ВП». Моделирование динамики ND-систем в рамках когнитивной парадигмы обеспечивает [11]:

- выбор рациональных моделей и алгоритмов функционирования ND-системы в заданном топологическом пространстве;
- формирование сервиса когнитивных образов и управляющих воздействий в процессе эволюции ND-системы;
- обучение ND-систем на тестовых примерах из библиотеки когнитивных образов и команд управления.

Таким образом, использование когнитивной парадигмы позволяет повысить качество управления и принятия решений за счет феномена когнитивного образа, обладающего высокой динамичностью и информативностью при топологическом синтезе NN-системы.

Пути реализации процедур построения когнитивных структур NN-систем основное внимание обращается на интерпретацию сложных ситуаций при функционировании ВП — обеспечение безопасности мореплавания и посадки ЛА морского базирования [1, 18]. При этом выделены три направления использования когнитивных структур:

- представление информации для принятия оперативных решений в нестандартных ситуациях;
- сжатие информации при построении и обучении ND-систем;
- визуализация многомерной информации при анализе данных динамических измерений.

Областью приложения результатов проведенных исследований являются ND-системы, использующие параллельные алгоритмы обработки измерительной информации на основе суперкомпьютерных технологий. Когнитивные структуры в ВП используются для повышения эффективности управления и принятия решений за счет феномена когнитивного образа, обладающего высокой динамичностью и информативностью. Идеи *когнитивной парадигмы* в ВП открывают возможности реализации программного комплекса ND-систем на основе методов теории катастроф в режиме реального времени при решении проблемы формирования управляющих воздействий. На основе современных достижений в области интеллектуального управления когнитивный подход определяет концепцию представления знаний в трудноформализуемых средах.

Контроль поведения ND-системы в процессе эволюции в сложной динамической среде

Моделирование процессов развития сложных ситуаций и механизмов управления изменениями функционирования ВП производится в рамках общей концепции современной теории катастроф [11]. Концептуальный базис интеллектуальной среды моделирования эволюции ДО разрабатывается на основе результатов исследований, изложенных в работе [2, 18]. Приведенный анализ этих результатов позволяет сформулировать следующие основные требования к математической модели взаимодействия в транспортных и социальных системах:

- *содержательная интерпретируемость* с использованием концепции конкуренции на основе геометрической и аналитической компонент динамической модели катастроф;
- *эффективная вычислимость* на основе алгоритмов параллельной обработки информации в мультипроцессорной вычислительной среде.

Указанные требования определяют построение модели взаимодействия при разработке алгоритмов контроля текущей ситуации и тестирования базы знаний, определяющих динамику исследуемой среды в различных внешних условиях. Модель «облачных» вычислений реализуется концептуальным блоком на основе многоуровневого интерфейса оператора ВП, интегрированной ИС управления вычислениями с использованием описания задачи, формализации описания и предметной области, *мета потока* данных MWF и блока обработки данных, осуществляющего декомпозицию задачи и ее отображение на набор доступных матасервисов с использованием дополнительных требований к процедуре решения. Полученная информация передается на блок *абстрактного потока данных* AWF, технически настроенного потока данных WF, актуализация состояние которого осуществляется от блока управления. Формирование и обработка *конкретного потока данных* CWF ведется с использованием статуса задачи, а результаты работы передаются в блок анализа и блок полученных результатов решения [2].

ND-системы при интерпретации поведения морских ДО в процессе эволюции в нестационарной среде

Оценка и анализ текущего состояния динамики объекта во времени позволяет исследовать развитие процессов взаимодействия в автоматизированном режиме функционирования ВП. На множестве информационных объектов и скрытых закономерностей текущей ситуации обеспечивается формирование адекватной упреждающей реакции по предупреждению и устранению неблагоприятных ситуаций на основе технологий интеллектуальной поддержки оператора.

Процедуры принятия решений формализуются на основе анализа особенностей возникающих ситуаций [11, 18] с использованием следующих утверждений.

Надежность прогноза угрожающих ситуаций при оценке динамики ND-системы определяется в зависимости от критериев развития угрожающих ситуаций. Адаптивный прогноз строится на основе анализа результатов математического моделирования динамики взаимодействия объекта с внешней средой, а также с использованием априорной информации о процессах-прецедентах, накопленной по данным аварийной статистики. Закономерности, используемые при построении базы знаний ND-системы, устанавли-

ваются на основе фундаментальных представлений о развитии угрожающих ситуаций в процессе движения ДО к целевому аттрактору. Описание этих закономерностей ведется в рамках динамической модели катастроф для процессов взаимодействия, изученных теоретическими и экспериментальными методами. Нечеткие модели прогноза угрожающих ситуаций в ND-системе строятся с использованием существенных факторов и закономерностей, сформулированных для различных по критериям выбора процессов. Результаты функционирования нечеткой системы знаний позволяют сформулировать процедуры идентификации угрожающей ситуации и выработки практических рекомендаций по обеспечению безопасности ДО.

Формирование управляющих воздействий реализуется в зависимости от критичности возникающих ситуаций с использованием энтропийного подхода [6] к интерпретации поведения ND-системы при движении к целевому аттрактору [11]. В качестве начального условия принимается допустимая энтропия системы Эдоп-1, а ограничение выражается в следующем виде

$$R(S) = (1 - E_E/E_d) \leq R(P), \quad (36)$$

где $R(S)$ — степень отклонения системы от состояния равновесия; E_E и E_d — текущая и допустимая энтропия системы; $R(P)$ — заданная степень отклонения системы от состояния равновесия, которая устанавливается параметрической настройкой.

Используя преобразование [14], получаем общее решение для количества необходимой информации в следующем виде

$$F_n(T_{CR}) = (T_{CR})^n \exp(-T_{CR}), \quad (37)$$

где T_{CR} — время обновления информации.

Имитация взаимодействия ДО с внешней средой отрабатывается в процессе тестирования ВП при различном уровне действующих возмущений.

Система виртуального моделирования при функционирования ВП на основе методов теории катастроф

Система виртуального моделирования при функционировании ВП формируется как некоторое множество компонент (рис. 10), количество которых

соответствует используемым ДО. Каждой математической модели, описывающей состояние ДО в соответствии с рассматриваемым физическим эффектом, ставится в соответствие определенный объем аппаратных ресурсов. В этих условиях моделируемые системы функционируют параллельно, а их взаимодействие обеспечивается за счет обмена данных в мультипроцессорной вычислительной среде. Это позволяет повысить скорость моделирования и упростить программирование задач за счет снижения сложности системы.

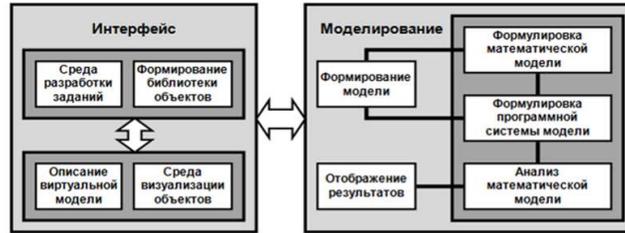


Рис. 10. Схема виртуального моделирования

Визуализация модели внешней среды и динамики взаимодействия

Для моделирования пространственно-временного поля морского волнения используется модель авторегрессии — скользящего среднего. Эта модель основана на представлении процесса волнения в форме линейной динамической системы с распределенными параметрами и случайным входным сигналом [1, 18]. Алгоритм высокопроизводительных вычислений воспроизводит реальную картину трехмерного волнового поля на основе данных о климатических спектрах морского волнения [1]. Теоретические принципы виртуального моделирования обеспечивают генерацию динамические картины поведения исследуемых объектов. Программа Extreme Events Simulator [18] обеспечивает визуализацию динамической сцены в режиме отображения динамики взаимодействия с использованием данных о реальных параметрах внешней среды.

Динамическая модель ситуации может быть реконструирована путем изменения управляющих воздействий — курсового угла волны φ и скорости морского ДО V_S . В зависимости от интенсивности ветра U и волнения

W для различных V_S и φ происходит непрерывное изменение показателей мореходности [18]. Одно из направлений использования виртуального моделирования связано с созданием *расширенной реальности*, подобно системе EADS, обслуживающей самолеты, вертолеты и спутники.

Визуализация результатов функционирования динамической базы знаний ВП

Разработка интерфейса оператора выполняется с учетом наиболее полного представления информации о функционировании ВП на основе алгоритмов классического и нейронечеткого управления в рамках принципа конкуренции. В качестве иллюстрации тестирования динамической базы знаний ВП [18] рассмотрим контроль глиссады на различных этапах посадки ЛА в рамках концепции мягких вычислений [23]. В процессе тестирования рассмотрены следующие сценарии: контроль глиссады на значительном удалении от ДО; контроль глиссады на завершающем этапе посадки; запрет посадки при прогнозе «окна безопасной посадки».

Для указанных сценариев на рис. 11–13 представлены картины визуализации динамических сцен с характеристикой параметров движения ДО, которые сопровождаются записями кривых продольной качки, а также параметров движения ЛА с указанием меры соответствия текущей и «идеальной» траектории, параметров прогноза «окна безопасной посадки» и вывода о возможности продолжения посадки или необходимости захода на второй круг.

Мера соответствия текущей траектории «идеальной» глиссады представляется как в числовом виде, так и в лингвистической форме в виде принадлежности параметров отклонений к заданным нечетким значениям. Как видно из рис. 11, отклонения от глиссады и линии курса незначительны, о чем информируется оператор ВП. В данном сценарии прогноз «окна безопасной посадки» не производится, поскольку до посадки остается значительное время (около 40 с). Рис. 12 демонстрирует динамику процесса посадки ЛА на небольшом расстоянии от расчетной точки посадки, когда до момента касания остается небольшое время.

В этом случае модель контролируемой глиссады строится на основе краткосрочного прогноза качки ДО, что позволяет более точно скорректировать траекторию полета ЛА. Параллельно осуществляется прогноз «окна безопасной посадки» — продолжение посадки возможно только при доста-

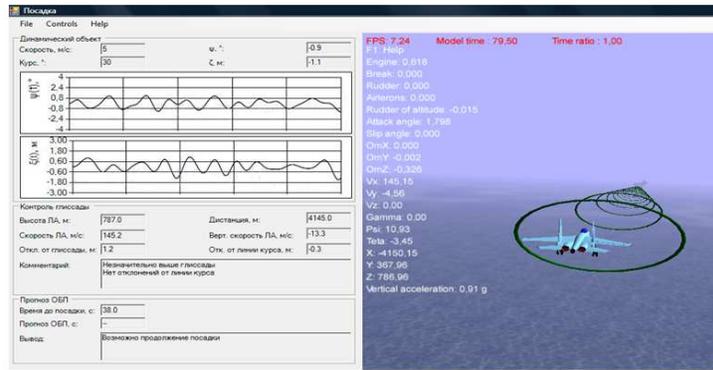


Рис. 11. Контроль глиссады на значительном удалении от ДО

точной продолжительности прогнозируемого «окна», в противном случае выводится информация о необходимости захода на второй круг.

Сценарий «Запрет посадки при прогнозе динамики воздействия» (рис. 13) представляет ситуацию, когда в процессе снижения ЛА при движении по глиссаде и одновременного прогноза «окна безопасной посадки» устанавливается недостаточная продолжительность «окна» для безопасного завершения операции посадки.

В этом случае на экран оператора выводится информация о необходимости захода на второй круг. Продолжение посадки за пределами «окна безопасной посадки» в штормовых условиях является значительным риском. Оценка риска принятия решений при возникновении неблагоприятных ситуаций при тестировании динамической базы знаний проводилась с использованием матрицы риска [11]. Из-за сложности проведения детальных количественных расчетов возникновения опасности P и уровня ее последствий A оценка риска выполнялась при сопоставлении с экстремальной ситуацией, характеризующей режим основного резонанса килевой качки, которая подробно изучена теоретическими и экспериментальными методами. Расчеты показали, что опасность риска возрастает по мере уменьшения соотношения $WSL/(WSL)_{min}$ при прохождении пакетов с малым числом волн в составе нерегулярного волнения.

Реализация когнитивной парадигмы [8, 11, 18] при формировании экрана взаимодействия оператора с ВП осуществляется совместно с геометри-

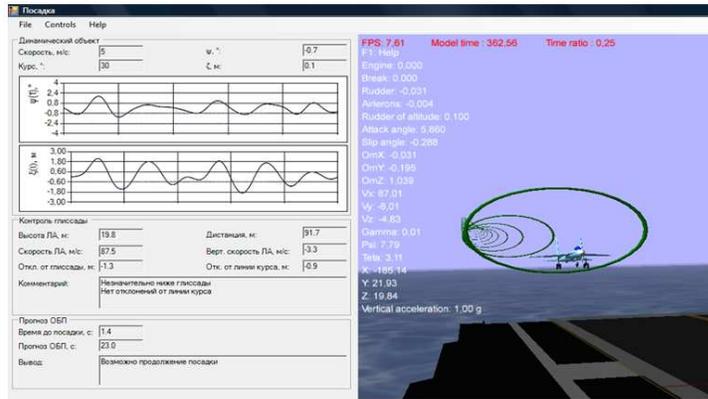


Рис. 12. Контроль глиссады на завершающем этапе посадки

ческой и аналитической интерпретацией исследуемой ситуации (рис. 14). При этом выполняются следующие требования. Все возникающие ситуации подразделяются в соответствии с общепринятыми стандартными наименованиями: угрожающая, предаварийная, аварийная. Причем аварийная ситуация предусматривает критическую и катастрофическую.

Когнитивные образы, отображающие результаты функционирования аналитической компоненты в соответствии с сформулированными выше аксиомами и определениями управляющих воздействий, формируются с помощью цветовой гаммы: угрожающая ситуация — желтый цвет, предаварийная — оранжевый цвет, аварийная — красный цвет с информацией об особенностях катастрофы. Зеленый цвет означает условия нормальной эксплуатации. Критическая и катастрофическая ситуации характеризуются красным цветом с конкретными практическими рекомендациями. Реализация когнитивных образов осуществляется в режиме реального времени в соответствии с динамикой развития текущей ситуации (данные прогноза и результаты измерений).

Главной особенностью ВП является реализация базовых принципов и процедур, делающих естественным процесс общения оператора с ИС. Безопасная поддержка оператора определяется в соответствии с качеством управления на основе вырабатываемой информации. Критерии безопасности определяются по степени критичности ситуации в соответствии с

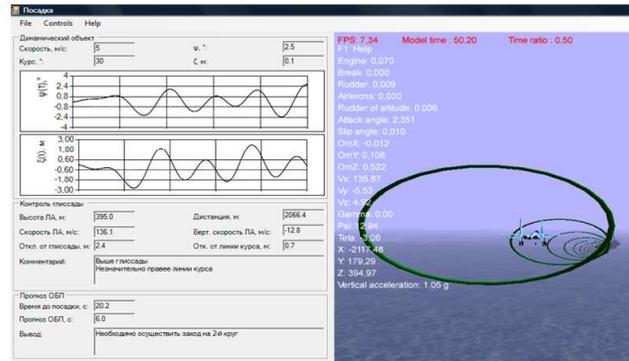


Рис. 13. Запрет посадки при прогнозе «окна безопасной посадки»

нормативными показателями и документами, принятыми в отечественной и международной практике.

Интерпретация режимов движения ДО на основе моделей ND-систем

Сложность проблемы контроля нештатных и экстремальных ситуаций, неполнота и неопределенность исходной информации о поведении системы «ДО–внешняя среда» приводят к необходимости разработки вычислительной технологии, обеспечивающей обработку данных в режиме реального времени с помощью высокопроизводительных вычислительных средств. Основная роль в этой технологии принадлежит данным динамических измерений [1].

Функционирование ВП в режиме реального времени основано на использовании измерительной информации, поступающей с датчиков параметров, определяющих динамику взаимодействия объекта с внешней средой. Качество этой информации и алгоритмы ее преобразования в значительной степени определяют надежность вырабатываемых рекомендаций и эффективность ИС.

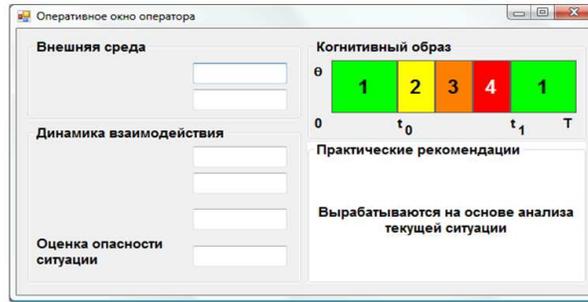


Рис. 14. Графическое окно «Оперативный контроль» и прогнозирование данных о динамике объекта на основе когнитивной парадигмы: $[0, T]$ — исследуемая область; $[t_0, t_1]$ — область возникновения экстремальной ситуации; 1 — условия нормальной эксплуатации; 2, 3, 4 — угрожающая, предаварийная и аварийная ситуации

Контроль режима функционирования ВП при оценке поведения ДО

Идентификация математических моделей, характеризующих нестандартные (нештатные и экстремальные) ситуации, осуществляется на основе статистического анализа данных измерений, полученных в условиях эксплуатации ВП, а также в процессе имитационного моделирования взаимодействия аварийного судна с внешней средой. Временные кривые исследуемых процессов представляются в следующем виде [1, 14, 18]:

$$\mathfrak{R}(t_i) = F(t_i) + \mathfrak{S}(t_i) + S(t_i). \quad (38)$$

Здесь под $\mathfrak{R}(t_i)$ понимаются исследуемые процессы $\zeta(t_i), \theta(t_i), \Psi(t_i)$; $F(t_i)$ — медленно меняющаяся функция времени (тренд); $\mathfrak{S}(t_i)$ — периодическая (циклическая) составляющая; $S(t_i)$ — стохастическая составляющая:

$$S(t_i) = \xi(t_i) + \varepsilon(t_i), \quad (39)$$

где $\xi(t_i)$ — независимая случайная последовательность (шум) с математическим ожиданием $M[\xi(t_i)] = 0$ и дисперсией $\sigma_\xi^2(t_i)$; $\varepsilon(t_i)$ — последовательность случайных событий («выбросов»), которые представляют собой аномальные наблюдения в случайные моменты времени τ_i :

$$\varepsilon(t_i) = \begin{cases} A_i & \text{if } t_i = \tau, \\ 0 & \text{if } t_i \neq \tau. \end{cases} \quad (40)$$

Здесь A_i — амплитуда аномального наблюдения, значительно превышающая размах исходного ряда наблюдений. Последовательность аномальных наблюдений при контроле режима функционирования ВП образует пуассоновский поток событий с параметром λ .

Построение модели (40) при обработке экспериментальных данных сводится к идентификации аналитического представления каждого слагаемого. В качестве методов оценивания допустимых отклонений удобно использовать нечеткие методы, заложенные в основу представления базы знаний интегрированных ИС в составе ВП. При формализации неопределенностей степень соответствия режиму нормальной эксплуатации задается в виде нечетких множеств и ФП [1, 8, 18].

Обнаружение изменений в процессе эволюции системы

Обнаружение изменений в поведении динамических системы, описывающей движение ДО к целевому аттрактору, относится к классу сложных задач, в которых управление реализуется в условиях неопределенности состояния внешней среды [11, 14]. Внутреннее состояние и структура системы влияют на взаимодействие ДО с окружающей средой. При этом внутрисистемная информация влияет на входную и выходную, а дальнейшее функционирование системы основывается на контроле этих изменений. Текущее состояние системы взаимодействия оценивается через выходные переменные системы и характеристики окружающей среды. Таким образом, при контроле движения к целевому аттрактору на основе текущей информации определяется изменение свойств окружающей среды и динамики объекта.

На начальном этапе решения данной задачи устанавливаются причинно-следственная модель взаимодействия на основе данных «вход–выход» характеристик ДО в режиме нормального функционирования. При этом используется представление «вход–выход» системы в виде совокупности временных рядов. Анализ причинно-следственных закономерностей ND-системы позволяет разрабатывать эффективные алгоритмы управления и функционирования.

Моделирование объектов социальной среды при функционировании ВП

В качестве практического приложения моделирования объектов социальной среды при функционировании ВП рассмотрим контроль чрезвычайной ситуации, связанной с наводнением и возможным затоплением прибрежных областей (рис. 15 и 16).

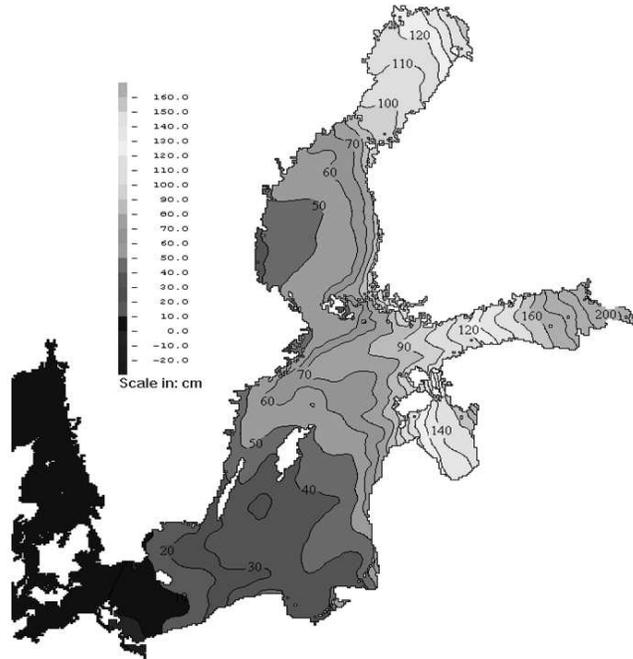


Рис. 15. Уровень моря по результатам гидродинамического моделирования

Для учета этих эффектов расчетная область моделирования содержит области, которые считаются «сухими» в начале расчета и могут затопляться в процессе штормового нагона. Таким образом, в этом случае задается в виде цифрового массива не только батиметрии акватории, соответствующей невозмущенному положению уровня моря, но и топографии прибрежных участков суши — районов возможного затопления.



Рис. 16. Визуализация результатов расчета затоплений нагонной волной территорий Васильевского острова

Программа позволяет на основе заданных полей приводного ветра моделировать спектральные характеристики морского волнения в диапазоне синоптической изменчивости, а по ним с помощью интегрирования определять характерные высоты, периоды и направления волн. Особенностью использования модели SWAN является ориентация на специфические эффекты мелководных акваторий, что важно, учитывая мелководность акватории восточной части Финского залива. На рис. 16 приведен пример работы программы ВП по моделированию наводнения Санкт-Петербурга (по ретроспективным данным). Для решения задачи прогнозирования наводнений применялась модель SWAN [22].

В рамках разработанной технологии используется модель эволюции во времени при движении системы к целевому аттрактору. Входными данными модели являются значения объемов воды, попадающих на исследуемые области через разрушенные защитные сооружения. Рассчитывается распределение воды по исследуемой области в соответствии с ее топографическими данными. Первичными выходными данными является зависимость количества воды от координат затапливаемой территории. На каждом шаге по времени алгоритм включает: обработку граничных условий; сортировку зон воздействия по уровню воды для каждой зоны; расчет объемов воды, перемещаемых к соседним зонам; лимитирование объема перемещаемой воды; использование потоков воды из соседних зон; перемещение объемов; расчет скоростей; обработка только что затопленных зон; обновление уровня воды для всех зон воздействия. Входные данные для модели зада-

ются в форме гидрографа (зависимости расхода воды в конкретной области от времени). В качестве примера на рис. 17 представлены результаты моделирования затопления Васильевского острова Санкт-Петербурга для трех различных моментов времени. Визуализация результатов моделирования производилась с использованием спутниковой карты.

Критериальный базис оценки адекватности ND-систем в условиях неопределенности и неполноты исходной информации

При рассмотрении проблемы адекватности ND-системы используется интерпретация топологического пространства взаимодействия в рамках общих представлений последовательности преобразований текущей информации при функционировании ВП на основе динамической модели катастроф. Процедуры оценки адекватности ND-системы построены с учетом структурных изменений в процессе ее эволюции при реализации динамической модели катастроф. Эти процедуры нашли отражение при формулировке степени неопределенности ND-системы, формировании концептуального ядра и оценки адекватности с использованием экспериментальных данных. На рис. 17 представлена последовательность операций обработки информации в задачах нейроидентификации, нейроаппроксимации и нейропрогноза определяющая критериальный базис оценки адекватности ND-системы. Здесь выделены основные этапы реализации вычислительной технологии определения параметров внешней среды, динамики взаимодействия, а также стадии эволюции при прогнозе поведения ДО.



Рис. 17. Критериальной базис ND-систем

Рассмотрим особенности функционирования программного комплекса бортовой ИС, интегрирующего модели и топологические структуры ND-систем. Концептуальная модель оценки адекватности функционирования ND-систем формализует процессы построения комплекса задач и критериальных функций для интерпретации процессов взаимодействия ДО с внешней средой. Процедуры интерпретации осуществляются с помощью вычислительного комплекса ND-системы, интегрирующего в рамках принципа конкуренции системы, обеспечивающие вычислительные операции компонент динамической модели катастроф на основе графоаналитической (GA) и нейродинамической (ND) систем,

Формализация неопределенности в ND-системах

При формализации неопределенности среды функционирования динамической модели катастроф можно выделить три среды моделирования и визуализации текущей ситуации, которые используются при оценке адекватности математических моделей NN-систем (рис. 18):

1. *Слабая неопределенность*, состоящая в сложности формализации динамики взаимодействия с учетом всех действующих факторов, принятых при формировании критериального базиса ND-систем.
2. *Значительная неопределенность* в сложных условиях взаимодействия объекта с внешней средой, состоит в сложности формализации модели взаимодействия с учетом реальной картины поведения ДО как ND-системы при различном уровне внешних возмущений.
3. *Полная неопределенность*, обусловленная отсутствием модели взаимодействия NN-системы и представляющая собой уникальный случай исследования текущей ситуации на основе гипотез и упрощающих предположений.

Задача исследования NN-систем в условиях неопределенности связана с рассмотрением отображения [11, 14]:

$$F : (R^n) \times (R^r) \rightarrow R, \quad (41)$$

где (R^n) и (R^r) — пространство поведения и пространство управления, с помощью которого необходимо выполнить анализ ND-системы на основе достижений классической математики и интеллектуальных технологий, интегрированных в динамической модели катастроф.



Рис. 18. Формализация неопределенности при оценке адекватности ND-систем

Четкое разделение указанных сред связано с решением проблемы выбора границы области неопределенности «где начинается и кончается недопустимость». Решение этой задачи возможно только в каждом конкретном случае в зависимости от особенностей ND-системы и взаимодействия ДО с внешней средой. При этом следует обратить внимание на использование математических моделей в условиях больших отклонений ДО от положения равновесия при оценке потери устойчивости и возникновении катастрофы. В частности, удовлетворительные результаты могут быть получены на основе метода функционала действия с использованием модифицированного уравнения Матье.

Особенности преобразования информации в NN-системах

Формальная модель преобразования информации в вычислительном комплексе бортовой ИС, интегрирующим программные модули ND-системы представляет собой логическую структуру развивающихся во времени взаимосвязанных компонент ND-систем [14].

В качестве конкурирующей вычислительной технологии рассматриваются методы и модели, построенные на основе достижений классической математики. Исходными компонентами при формировании концептуальной модели вычислительного комплекса обработки информации являются:

- развивающееся множество задач интерпретации поведения ДО и топология структуры исполнительных модулей;

- отображения, описывающие распределение задач в зависимости от особенностей взаимодействия ДО с внешней средой;
- область функциональной надежности алгоритмов на множестве состояний, описывающих динамику взаимодействия;
- множество маршрутов, по которым перемещаются исходные данные и результаты выполнения вычислительных модулей.

Поток информации при функционировании программных средств NN-системы представлен на рис. 19. Здесь дается содержательная интерпретации компонент системы в зависимости от выполняемых операций, реализуемых управляющим модулем.

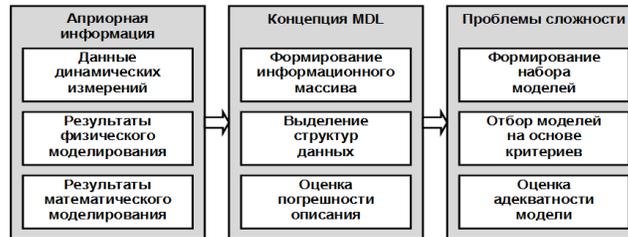


Рис. 19. Поток информации, определяющий стратегию оценки адекватности модели взаимодействия ДО с внешней средой

Этот модуль взаимосвязан с программной средой, функции которой поддерживаются базами знаний и данных. Главной задачей этих взаимосвязанных компонент интегрированной системы является обеспечение управления распределенными вычислениями в режиме реального времени. Таким образом, проблему интерпретации вычислительной среды можно определить как поиск решений задач минимизации, обеспечивающей на прогнозируемом интервале времени предоставление оперативной информации с необходимым качеством и уровнем безопасности.

Алгоритм преобразования информации при функционировании NN-систем

Стратегия оценки адекватности моделей вычислительного комплекса на рис. 20 определяет формализацию процедуры на основе учета факторов,

характеризующих априорную информацию, концепцию минимальной длины описания и проблему сложности. Здесь указана последовательность этапов формирования адекватной модели в рамках концепции MDL [3] и теории сложности [19]. Как следует из этого рисунка, проблема адекватности при функционировании бортовой ИС решается путем интеграции априорной информации, концепции MDL и проблемы сложности, определяющей выбор решения при контроле текущих ситуаций в соответствии с концептуальной моделью динамической теории катастроф [11], адаптируемой применительно к рассматриваемой проблеме.

В рамках такого представления можно сформулировать общий алгоритм вычислительного комплекса, обеспечивающий преобразование информации в сложной динамической среде, определяющий поведение ND-системы в сложной динамической среде [14]:

$$\{W(t) \times V(t)\} \rightarrow \Omega(\theta, \psi, \dots, \zeta, [t_1, t_k]), \quad (42)$$

где $\{W(t) \times V(t)\}$ — нестационарные возмущения внешней среды; $\Omega(\bullet)$ — область поведения ДО под воздействием внешних возмущений; $(\theta, \psi, \dots, \zeta)$ — параметры, определяющие динамику объекта в текущей ситуации; $[t_1, t_k]$ — интервал реализации. Математическую модель взаимодействия ДО с внешней средой а ND-системе формируют два основных фактора:

- внешнее возмущение в текущей ситуации, представляемое в виде различных аппроксимаций ветровых потоков и «климатического спектра» морского волнения [1, 9, 18], широко используемого в международной практике при моделировании динамики внешней среды;
- реальная модель ND-системы, отображающая сложное взаимодействие ДО и внешней среды в текущей ситуации, включающая нелинейную пространственную функцию восстанавливающего момента [11], непрерывно изменяющегося в процессе эволюции системы.

Формализованное ядро теории нормирования ND-систем

Исследование динамики ND-системы предполагает построение и рассмотрение моделей прямых и обратных задач. Решением прямой задачи является переход от известной структуры и особенностей динамики системы к характеристикам и критериальным соотношениям. Обратная задача (синтез) представляет собой переход от желаемых характеристик и критериальных соотношений к структуре системы и свойствам ее компонентов. Эти

модели характеризуют *формализованное ядро* теории нормирования. При интерпретации формализованного ядра на в условиях неопределенности и неполноты исходной информации рассматривается критерий адекватности математических моделей с учетом описываемых видов движения и представляющей собой либо функцию от параметров модели, либо функционалы кривых соответствующих дифференциальных уравнений. Коэффициенты модели, удовлетворяющие заданным параметрическим, функциональным и критериальным ограничениям, образуют допустимую область в пространстве критериев. Задавая точность аппроксимации параметров, и точность критериев, можно представить критерий близости (адекватности) данных математического моделирования физическому эксперименту [1, 11, 18].

В качестве критериев адекватности моделей ND-системы могут быть использованы допустимые расхождения теоретических и экспериментальных данных, а также ограничения, накладываемые на расхождение временных и фазовых траекторий при оценке поведения динамической системы при различном уровне действующих возмущений, условия проверки принадлежности выборочных данных эмпирическим законам распределений (законы Гаусса, Рэля, Вейбулла и др.). Оценка адекватности усложняется для моделей ND-системы большой размерности. В этом случае содержательность задачи восстановления параметров определяется не только структурой модели, но и критериями близости теоретических и экспериментальных данных, а также степенью полноты вектора критериев.

Понятие адекватности связано с другой очень важной особенностью нелинейных динамических систем — грубостью их математических моделей. Использование этого понятия вызвано тем, что любая адекватная модель отражает исследуемое явление лишь с некоторой приближенностью, практически никогда не описывая ее абсолютно точно. Поэтому при анализе моделей ND-системы необходимо получать данные, которые не испытывали бы заметной зависимости от неточности моделирования, то есть были бы достаточно инвариантными по отношению к этим неточностям. Таким образом, результаты исследования модели и характер ее динамики должны испытывать достаточно малые изменения при сравнительно небольших вариациях структуры модели.

Оценка адекватности конкурирующей вычислительной технологии

В качестве конкурирующей вычислительной технологии используем стандартные процедуры оценки адекватности, основанные на вероятностной интерпретации [14]. Эти процедуры позволяют выделить наиболее часто встречающихся варианты проверки адекватности полученного уравнения регрессии.

Вариант 1: анализ основан на серии параллельных экспериментов. В этом случае для каждого значения параметра имеем серию параллельных опытов.

Вариант 2: основная серия опытов проведена без параллельных экспериментов, а дисперсия воспроизводимости определена в отдельной серии опытов.

Вариант 3: основная серия опытов выполнена без параллельных экспериментов, и нет данных для расчета дисперсии воспроизводимости.

Расчетные формулы для каждого варианта основаны на стандартных статистических процедурах, а в качестве критерия адекватности используется критерий Фишера.

Реализация принципа конкуренции на основе модифицированной схемы оценки адекватности

Задача оценки адекватности, особенно математических моделей, описывающих сложную эволюцию ДО, представляет собой многоэтапный итерационный процесс получения доказательства правильности и корректности выводов относительно поведения исследуемой динамической системы. Одним из известных методов валидации моделей при моделировании взаимодействия NN-систем в сложных динамических средах является схема О. Балчи [21].

Схема О. Балчи модифицирована автором [14] для конкретного приложения при разработке ND-системы с целью учета данных физического, нейронечеткого и нейроэволюционного моделирования. При этом основная идея схемы Балчи сохранена, а выполненные усовершенствования состояли в рассмотрении моделей ND-системы как составной части базирующегося на ней практического приложения — задачи моделирования сложных динамических ситуаций при функционировании бортовой ИС.

Модифицированная схема Балчи имеет трехцикличную структуру на основе следующих представлений (рис. 20).

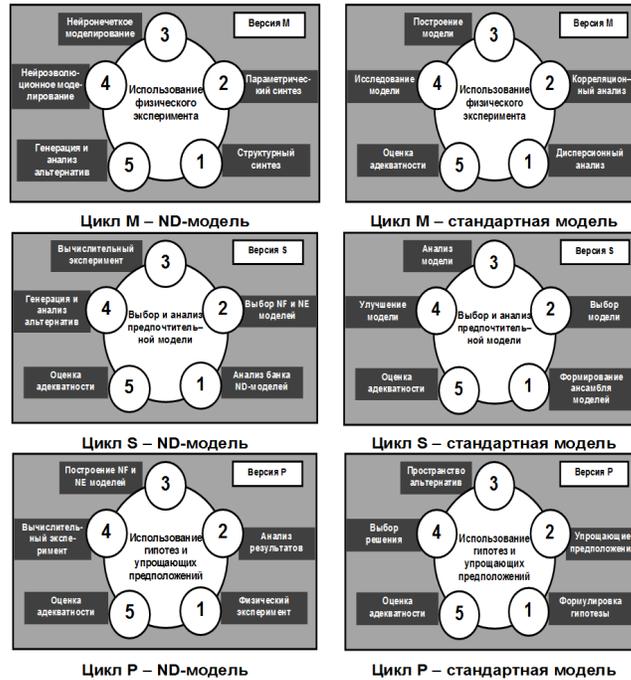


Рис. 20. Модифицированная схема Балчи: M,S,P – циклы преобразования информации

Первый цикл связан с разработкой конкурирующих моделей (modeling – M), реализуемых на основе ND-системы и методов классической математики. В процессе выполнения этого цикла выполняется структурный и параметрический синтез нейронной сети в задачах нейрончатого NF и нейроэволюционного NE моделирования, а для конкурирующей модели – оценка общей структуры и компонент в рамках процедур последовательного статистического анализа.

Второй цикл относится к реализации соответствующих математических (имитационных) экспериментов, выполняемых с конкурирующими моделями (simulation – S) для заданных начальных условий и элементов

входного вектора. Здесь формируются NF и NE модели анализа банка данных, на основе которых реализуется вычислительный эксперимент, генерация и анализ альтернатив и оценка адекватности. Построение и анализ конкурирующей модели ведется в соответствии с формализацией задачи в условиях значительной неопределенности в соответствии с алгоритмом [14].

Третий цикл — наиболее важный. Он состоит в проведении физических (physical — P) экспериментов, на базе которых формируются модели, обеспечивающие оценку адекватности в условиях полной неопределенности. На этом цикле в ND-системе формируются компоненты NF и NE моделей с использованием данных физического моделирования, реализуется вычислительный эксперимент и оценка адекватности.

Интеллектуальная поддержка процедур M, S, P обеспечивается системой управления вычислениями и визуализацией результатов моделирования [11, 14].

Заключение

Таким образом, рассмотренный подход к построению ВП открывает новые возможности анализа и прогноза взаимодействия ДО в транспортной и социальной системах. Онтологический синтез аксиоматики вычислений позволил формализовать процесс обработки информации и структурировать систему знаний среды взаимодействия в рамках нечеткого логического базиса. Цикл эволюции системы в текущей ситуации (движение системы к целевому аттрактору и потеря устойчивости) рассматривается на основе динамической модели катастроф. В процессе эволюции определяются критические ситуации и интервалы времени возникновения неблагоприятных режимов функционирования ДО исследуемой системы. Анализ этих режимов открывает возможности генерации управляющих воздействий по предотвращению чрезвычайных ситуаций. Формирование фрактального аттрактора и генерация соответствующего правила с помощью логической системы знаний обеспечивают оперативный контроль и прогноз развития ситуации в заданных условиях функционирования.

Разработанные концептуальные основы создания ВП контроля чрезвычайных ситуаций являются определяющими в приложениях современной теории катастроф к задачам транспортного и социального мониторинга. При этом для каждого конкретного приложения требуется уточнять фор-

мальный аппарат знаний, методы интерпретации и прогноза ДО исследуемой среды взаимодействия.

Литература

1. Бортовые интеллектуальные системы. Часть 1. Авиационные системы. Часть 2. Корабельные системы. – М.: Радиотехника, 2006. Часть 3. Системы корабельной посадки летательных аппаратов. – М.: Радиотехника, 2008.
2. Бухановский А. В., Иванов С. В., Нечаев Ю. И. Моделирование нелинейных систем в сложных динамических средах. – Санкт-Петербург: Монография. – Изд. центр НИУ ИТМО, 2013.
3. Колмогоров А. Н. О представлении непрерывных функций нескольких переменных в виде суперпозиции непрерывных функций одного переменного и сложения // Доклады АН СССР. – 1957. – т. 114, Вып. 5. – с. 953–956.
4. Кроннвер Р. М. Фракталы и хаос в динамических системах. – Москва. Техносфера, 2000.
5. Куратовский К. Топология. – М.: Мир, 1966 (том 1), 1969 (том 2).
6. Лазарев В. Л. Эволюция систем контроля и управления с позиций информационно-энтропийной теории // Сборник докладов Международной конференции по мягким вычислениям и измерениям SCM-2005. т.1. Изд-во СПбГЭТУ «ЛЭТИ». – с. 33–41.
7. Моисеев Н. Н. Избранные труды. – М. Тайрекс Ко., 2003.
8. Нейрокомпьютеры в интеллектуальных технологиях XXI века. – М.: Радиотехника, 2012.
9. Нечаев Ю. И., Бухановский В. В., Васильев В. Н. Концепция и принципы создания интеллектуальных гид-систем // Труды XVI Всероссийской научно-методической конференции «Телематика-2009». Санкт-Петербург. Т.2, с. 444–446.
10. Нечаев Ю. И. Математическое моделирование в бортовых интеллектуальных системах реального времени // Тр.5-й Всероссийской конференции «Нейроинформатика-2003». – М.: МИФИ, 2003. Лекции по нейроинформатике. Часть 2, с. 119–179.
11. Нечаев Ю. И. Теория катастроф: современный подход при принятии решений. – Санкт-Петербург: Арт-Экспресс, 2011.
12. Нечаев Ю. И. Нейросетевые модели при интерпретации эволюции нелинейной нестационарной системы на основе методов теории катастроф // XV Всероссийская научно-техническая конференция «Нейроинформатика-2013». Лекции по нейроинформатике. – М.: МИФИ, 2013, с. 270–318.

13. Нечаев Ю. И. Принципы нейродинамики в задачах адаптивной идентификации и прогноза на основе методов теории катастроф в среде «облачной» модели // XVI Всероссийская научно-техническая конференция «Нейроинформатика-2014». Лекции по нейроинформатике. – М.: МИФИ, 2014, с. 199–246.
14. Нечаев Ю. И. Топология нелинейных нестационарных систем. Санкт-Петербург: Арт-Экспресс, 2015.
15. Пайтген Х.-О., Рихтер П.Х. Красота фракталов. – М.: Мир, 1993.
16. Помехоустойчивые коды: Компьютер Фибоначчи / Отв. Ред. В. П. Стахов. – М.: Знание. Радиоэлектроника и связь. Вып. 6, 1989.
17. Синергетическая парадигма. Многообразие поисков и подходов. – М.: Прогресс-Традиция, 2000.
18. Системы искусственного интеллекта в интеллектуальных технологиях XXI века. ? Санкт-Петербург: Арт-Экспресс, 2011.
19. Солодовников В. В., Тумаркин В. И. Теория сложности и проектирование систем управления. – М.: Наука, 1990.
20. Черноушко Ф. Л. Оценивание фазового состояния динамических систем. – М.: Наука, 1988.
21. Balci O. Verification, validation and accreditation // Proceedings of the 1998 Winter Simulation Conference. – 1998, pp. 41?48.
22. SWAN. User manual. Delft University of Technology. 2004 [Электронный ресурс]: URL: <http://fluidmechanics.tudelft.nl/swan/index.htm>
23. Zadeh L. A. Fuzzy logic, neural networks and soft computing // *Communication of the ACM*. – 1994. – Vol. 37, № 3. – pp. 77–84.

Юрий Иванович НЕЧАЕВ, Заслуженный деятель науки РФ, академик РАЕН, доктор технических наук, профессор, международный эксперт в области высокопроизводительных вычислений и интеллектуальных систем.

НЕЙРОИНФОРМАТИКА–2015

**XVII ВСЕРОССИЙСКАЯ
НАУЧНО-ТЕХНИЧЕСКАЯ
КОНФЕРЕНЦИЯ
С МЕЖДУНАРОДНЫМ УЧАСТИЕМ**

ЛЕКЦИИ ПО НЕЙРОИНФОРМАТИКЕ

Оригинал-макет подготовлен *Ю. В. Тюменцевым*
с использованием издательского пакета $\text{\LaTeX 2}_{\epsilon}$
и набора PostScript–шрифтов *PSCy*

Подписано в печать 20.11.2014. Формат 60 × 84 1/16
Печ. л. 17,25. Тираж 170 экз. Заказ № 185

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

XVII ВСЕРОССИЙСКАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ
С МЕЖДУНАРОДНЫМ УЧАСТИЕМ

НЕЙРОИНФОРМАТИКА–2015

ПЛЕНАРНЫЕ ДОКЛАДЫ

1. А. Н. ГОРБАНЬ¹, Е. М. МИРКЕС¹, А. Ю. ЗИНОВЬЕВ²

¹*University of Leicester, Great Britain;* ²*Curie Institute, Paris, France*

Робастные топологические грамматики для нейронных сетей, обучающихся без учителя

2. R. STOOP

Institute of Neuroinformatics and of Physics, UZH and ETHZ of Zurich, Switzerland

The cochlea – a prototypical ancient neural network with a critical architecture

3. M. TSODYKS

Weizmann Institute of Science Rehovot, Израиль

Understanding the capacity of information retrieval from long-term memory

4. Yu. TIMOFEEVA¹, D. MICHIELETTO¹, Y. LU¹, S. COOMBES²

¹*University of Warwick, Great Britain;* ²*University of Nottingham, Great Britain*

Dendrites, neurons and resonances

5. К. В. АНОХИН

Национальный исследовательский центр «Курчатовский институт» Москва

Когнитом: гиперсетевая организация высших функций мозга

6. А. В. САМСОНОВИЧ
George Mason University, USA

Функциональные возможности биологически инспирированных когнитивных архитектур

7. Г. С. ОСИПОВ
Институт системного анализа РАН, Москва

Нейрофизиологические и психологические основания знаковой картины мира

8. О. П. КУЗНЕЦОВ, Л. Ю. ЖИЛЯКОВА
Институт проблем управления им. В. А. Трапезникова РАН, Москва

Сложные сети и когнитивные науки