

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

НАУЧНАЯ СЕССИЯ НИЯУ МИФИ–2010

НЕЙРОИНФОРМАТИКА–2010

**ХII ВСЕРОССИЙСКАЯ
НАУЧНО-ТЕХНИЧЕСКАЯ
КОНФЕРЕНЦИЯ**

**ЛЕКЦИИ
ПО НЕЙРОИНФОРМАТИКЕ**

По материалам Школы-семинара
«Современные проблемы нейроинформатики»

Москва 2010

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

НАУЧНАЯ СЕССИЯ НИЯУ МИФИ–2010. XII ВСЕРОССИЙСКАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ «НЕЙРОИНФОРМАТИКА–2010»: ЛЕКЦИИ ПО НЕЙРОИНФОРМАТИКЕ. – М.: МИФИ, 2010. – 328 с.

В книге публикуются тексты лекций, прочитанных на Школе-семинаре «Современные проблемы нейроинформатики», проходившей 26–29 января 2010 года в МИФИ в рамках XII Всероссийской конференции «Нейроинформатика–2010».

Материалы 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

ISBN 978–5–7262–1225–8 © *Национальный исследовательский ядерный университет «МИФИ», 2010*

Содержание

Предисловие	8
<i>В. Л. унин-Б р овс ий. Теория мозжечка</i>	14
Введение	15
Краткая сводка данных о нейронной организации мозжечка	16
Мозжечок и перцептрон	18
Каковы функции мозжечка	21
Функция лианнных клеток	22
В погоне за Близнецами	23
Поиск потенциалов, отражающих активность разных ветвей аксона лианной клетки	25
Наблюдения, связанные с СИ зарегистрированных клеток-близнецов	28
Наблюдения, связанные с СИ и ПИ клеток Пуркинье-близнецов	28
Восстановление вне-мозжечкового входа лианной клетки на выходе клетки Пуркинье	29
Уравнения Маука	31
Преобразование информации малыми клетками ядер мозжечка	33
Имитационное моделирование мозжечкового модуля	36
Пределы запоминающей способности мозжечкового модуля	39
Мозжечок и когнитивные функции	42
Обсуждение	42
Литература	45
<i>Р. А. Ти иджи-Х мбурьян. Детальное моделирование нейронов и нейронных сетей: Как и зачем</i>	49
Введение	50
Краткое введение в теорию нейронных сетей	52
Химические и электрические синапсы	54

Гомогенность, гетерогенность, размерность и связность сети. Случайные, диффузные и фокальные проекции нейронов	56
Краткая теория электрогенеза	58
Потенциал Нернста	58
Баланс токов и проводимостей	60
Уравнение Гольдмана-Ходжкина-Каца	62
Точечные модели	64
Уравнения Ходжкина-Хаксли	64
Различные ионные каналы	68
Многосегментные модели	76
Моделирование отростков нейрона. Кабельное уравнение	76
Дендритные деревья и активная мембрана	78
Геометрия дендритного дерева нейрона и типы активности	81
Феноменологические модели нейронов, используемые при построении нейронных сетей	84
Модель интегрирующего нейрона	85
Модификации модели интегрирующего нейрона	86
Модель ФицХью и Нагумо	88
Модель Ижикевича	90
Общая сравнительная характеристика феноменологических моделей	91
Модели синаптической передачи	92
Модель электрического синапса	92
Феноменологические модели химической синаптической передачи	94
Детальные модели химической синаптической передачи	95
Примеры моделей биологически обоснованных нейронных сетей	96
Модель с автоторможением	97
Модель зрительной коры кошки	98
Заключение	103
Литература	104
Л. А. Ст и еви . Искусственные когнитивные системы	106
Введение	107
Когнитивный подход и развитие когнитивной науки	108
Искусственный интеллект и когнитивная наука	110
Когнитивистский и эмерджентный подходы и системы	111

Когнитивистские системы	113
Эмерджентные когнитивные системы	115
Гибридные модели и системы	120
Когнитивные архитектуры	120
Разработка гибридных когнитивных систем	130
Когнитивные концепции	131
Когнитивный агент гибридной архитектуры	136
Средства реализации когнитивных систем	137
Применение нейробиологических модулей и обучения с подкреплени- ем в агентах-игроках для футбола роботов	138
Когнитивная система управления роботом на иммунологических сетях	142
Система безопасности робота	144
Когнитивные агенты на поведенческих сетях	146
Когнитивный агент-игрок на поведенческих сетях	148
Когнитивные агенты на адаптивных триангуляционных модулях	152
Адаптивный триангуляционный модуль	153
Когнитивный агент на адаптивных триангуляционных модулях	155
Заключение	157
Литература	157

А. А. Жд нов. Адаптивные машины — неизбежное направление раз- вития техники. Задачи и проблемы	162
Введение	162
Что такое адаптивность	165
Что такое управление	166
Несколько критических замечаний в отношении общепринятого понимания процесса управления	188
Искусственные нейронные сети	196
Синтез систем автономного адаптивного управления	199
Примеры машин с системами автономного адаптивного управления	205
Математические, технологические и психологические проблемы перехода к адаптивным технологиям	208
Заключение	209
Литература	210

И. . ерси и ев. Адаптивное построение иерархических нейросетевых систем для классификации и для сегментации временных рядов	212
Введение	213
Основополагающие идеи метода	213
Алгоритм формирования групп классов	214
Алгоритм построения ИНК	215
Свойства алгоритма построения ИНК	216
Результаты численных экспериментов	217
Одномерное распределение Кантора	218
Распознавание текстур	221
Распознавание гласных	222
Дикторонезависимое распознавание изолированных слов	224
Нейросетевая сегментация временных рядов	227
Описание алгоритма анализа временных рядов с переключающейся динамикой	228
Описание алгоритма анализа временных рядов с дрейфовой динамикой	230
Эксперименты с псевдо-хаотическими временными рядами	232
Эксперименты с биомедицинскими данными	236
Работа с данными космофизического эксперимента	238
Заключение	239
Литература	240
В. . Кошур. Нейроинтеллектуальные материалы, системы и конструкции	243
Введение	244
Примеры адаптивных материалов, систем и конструкций	245
Слоистые композиционные материалы	245
Активные композиционные панели и подавление вибраций	254
Адаптивные конструкции космических телескопов и космических антенн	254
Управление акустическими полями и подавление шума	256
Нейрокомпьютерная диагностика и неразрушающий контроль	259
Классификационная таблица интеллектуальных материалов, систем и конструкций	264
Заключение	267
Литература	268

Ю. И. е е в. Проблемы моделирования динамики сложных систем при реализации нейросетевых технологий	271
Введение	272
Концепция моделирования динамики внешней среды в бортовых ИС	274
Моделирование динамики объекта как нелинейной диссипативной системы	281
Нейроаппроксимация и нейропрогноз при контроле экстремальных ситуаций в сложных динамических средах	286
Нейроаппроксимация в задачах контроля динамики сложного объекта	286
Нейропрогноз поведения сложного объекта в бортовых ИС	295
Нелинейные эффекты и сценарии развития хаоса в диссипативных динамических средах	301
Динамический хаос в нелинейных диссипативных системах	302
Уравнение Дуффинга	305
Обобщенное уравнение Матье	306
Сценарии перехода к хаосу и управление в хаотических системах	308
Управление в самоорганизующихся системах	311
Управление в нестандартных ситуациях	314
Нейросетевые модели управления	315
Парадоксы, возникающие при моделировании динамики сложных объектов	317
Заключение	320
Литература	322

ПРЕДИСЛОВИЕ

1. В этой книге содержатся тексты ряда лекций, прочитанных на Десятой Школе-семинаре «Современные проблемы нейроинформатики», проходившей 26–29 января 2010 года в НИЯУ МИФИ в рамках XII Всероссийской научно-технической конференции «Нейроинформатика–2010», а также текст лекции *В. Л. Дунина-Барковского* «Теория мозжечка», представленной ранее, но не вошедшей в состав сборника Школы–2009 [14].

При отборе и подготовке материалов для лекций авторы и редактор следовали принципам и подходам, сложившимся при проведении девяти предыдущих Школ (см. [1–14]). 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, приглашаемых из числа 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 Десятой Школы-семинара «Современные проблемы нейроинформатики» на конференции «Нейроинформатика–2010» вошли следующие 11 лекций:

1. *В. Л. Дунин-Барковский, В. Ф. Кичигина.* Нейронные операции в септуме и гиппокампе.
2. *А. А. Ежов.* Эффект Эфроса (распознавание образов и когнитивная слепота).
3. *А. А. Жданов.* Адаптивные механизмы — актуальное и неизбежное направление развития техники. Задачи и проблемы.
4. *В. Д. Кошур.* Нейро-интеллектуальные материалы, системы и конструкции.
5. *Н. Г. Макаренко.* Выделение независимых компонент из смеси сигналов.
6. *Ю. И. Нечаев.* Проблемы моделирования динамики сложных систем при реализации нейросетевых технологий.
7. *И. Г. Персианцев.* Адаптивное построение иерархических нейросетевых систем для классификации и для сегментации временных рядов.
8. *А. И. Самарин.* Модели активного зрительного восприятия.
9. *Л. А. Станкевич.* Искусственные когнитивные системы.

10. Р. А. Тикиджи-Хамбурьян. Детальное моделирование нейронов и нейронных сетей — как и зачем.
11. А. А. Фролов. Аттракторные нейронные сети: теория и эксперимент.

Шесть из перечисленных выше лекций публикуются в данном сборнике, остальные в силу технических причин будут опубликованы в сборнике лекций следующей Школы-семинара.

3. В лекции **Р. А. Тикиджи-Хамбурьяна** «Детальное моделирование нейронов и нейронных сетей: как и зачем» рассматривается одна из основных частей сравнительно молодого раздела науки, называемого «вычислительные нейронауки» (Computational Neuroscience). Данная лекция призвана дать читателю базовые знания в подходах и методах вычислительной нейронауки, показать тесную связь между ее методами и проблемами нейробиологии.

4. В лекции **Л. А. Станкевича** «Искусственные когнитивные системы» обсуждаются пути развития искусственных когнитивных систем. Один из таких путей, связанных с разработкой когнитивных гибридных систем, которые способны обучаться восприятию сложной информации и формированию рационального поведения в динамически изменяющихся средах в реальном времени, рассматривается детально. Показано, что такие системы могут быть эффективны, например, для современных интеллектуальных роботов, поскольку они могут быть базой для разработки искусственной нервной системы таких роботов. Приводятся примеры разработки и применения обучаемых компонентов когнитивных систем.

5. В лекции **А. А. Жданова** «Адаптивные механизмы — актуальное и неизбежное направление развития техники. Задачи и проблемы» рассматривается актуальность перехода к технологиям создания адаптивных машин, программ и систем, подобных естественным системам управления. Представлена схема, состав и структура системы автономного адаптивного управления (ААС), выведенная из понимания возможностей решения задачи адаптивного управления в условиях, в которых работают естественные управляющие системы. Проведен сравнительный анализ разработанной схемы ААС с функциональной схемой *П. К. Анохина*. Представлена разработанная модель нейрона как элементарной самообучаемой системы распознавания, проведено ее сравнение с формальным нейроном искусственных нейронных сетей. Описаны разработанные действующие модели прикладных ААС. Указаны математические, технологические и психологические проблемы перехода к адаптивным технологиям.

6. В лекции **И. Г. Персианцева** «Адаптивное построение иерархических нейросетевых систем для классификации и для сегментации временных рядов» предложен алгоритм построения самоорганизующегося классификатора на основе многослойного персептрона. В результате работы алгоритма создается классификатор, имеющий древовидную структуру, каждый узел которой представляет собой персептрон. Структура дерева и параметры каждого персептрона формируются автоматически. При работе с данными, содержащими большое количество классов, предложенный алгоритм позволяет существенно снизить вычислительную стоимость решения задачи. Алгоритм был проверен на ряде тестовых и практических задач. Предложена модификация алгоритма, допускающая его использование для анализа временных рядов с дрейфовым типом изменения динамики. Приводятся результаты численных экспериментов по анализу модельных псевдохаотических рядов и анализу реальных данных биомедицинских и космофизических исследований.

7. В лекции **В. Д. Кошура** «Нейро-интеллектуальные материалы, системы и конструкции» представлены основные концептуальные идеи, которые лежат в основе разработки новых интеллектуальных материалов, систем и конструкций. Рассмотрены примеры адаптивных материалов и нейрорегулируемых систем, которые используются для трансформации упругих и акустических полей, подавления вибраций и шума, адаптивных конструкций космических антенн большого диаметра. Представлена модель нейрокомпьютерной диагностики для неразрушающего контроля ответственных элементов технических систем при их эксплуатации. Приведена классификационная таблица интеллектуальных материалов и систем, в основе которой лежит реализация энергетического и информационного обмена, осуществляемого на материальных носителях различного пространственного масштаба от метрового до нанометрового диапазона. Отмечены новые перспективные направления разработок.

8. В лекции **Ю. И. Нечаева** «Проблемы моделирования динамики сложных систем при реализации нейросетевых технологий» обсуждаются вопросы повышения эффективности моделирования поведения нелинейного динамического объекта при функционировании бортовой интеллектуальной системы в сложных динамических средах. Основное внимание уделяется использованию нейронных сетей при решении задач анализа и интерпретации информации. Сформулирована постановка задачи и концепция обеспечения эффективности моделирования динамики объекта как суще-

ственно нелинейной системы. Разработана модель представления волнения в виде климатического спектра сложной пространственной структуры и сформулированы сценарии развития шторма. Проведено компьютерное моделирование динамики взаимодействия нелинейного объекта при различном уровне внешних возмущений.

* * *

Для того, чтобы продолжить изучение вопросов, затронутых в лекциях, можно порекомендовать такой уникальный источник научных и научно-технических публикаций, как цифровая библиотека ResearchIndex (ее называют также CiteSeer, см. позицию [15] в списке литературы в конце предисловия).

Каждый из хранимых источников (статьи, препринты, отчеты, диссертации и т.п.) доступен в полном объеме в нескольких форматах (PDF, PostScript, DjVu и др.) и сопровождается очень подробным библиографическим описанием, включающим, помимо данных традиционного характера (авторы, заглавие, место публикации и/или хранения и др.), также и большое число ссылок-ассоциаций, позволяющих перейти из текущего библиографического описания к другим публикациям, «похожим» по теме на текущую просматриваемую работу. Это обстоятельство, в сочетании с весьма эффективным полнотекстовым поиском в базе документов по сформулированному пользователем поисковому запросу, делает библиотеку ResearchIndex незаменимым средством подбора материалов по требуемой теме.

Помимо библиотеки ResearchIndex, можно рекомендовать также богатый электронный архив публикаций [16], а также портал научных вычислений [17].

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 [1–14].

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 концепции мягких вычислений, проблем использования методов и средств нейроинформатики для решения различных классов прикладных задач. Не будут забыты и взаимодействия нейроинформатики с такими важнейши-

ми 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.

Литература

1. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // III Всероссийская научно-техническая конференция «Нейроинформатика-2001», 23–26 января 2001 г. / Отв. ред. Ю. В. Тюменцев. – М.: Изд-во МИФИ, 2001. – 212 с.
2. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // IV Всероссийская научно-техническая конференция «Нейроинформатика-2002», 23–25 января 2002 г. / Отв. ред. Ю. В. Тюменцев. Часть 1. – М.: Изд-во МИФИ, 2002. – 164 с.
3. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // IV Всероссийская научно-техническая конференция «Нейроинформатика-2002», 23–25 января 2002 г. / Отв. ред. Ю. В. Тюменцев. Часть 2. – М.: Изд-во МИФИ, 2002. – 172 с.
4. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // V Всероссийская научно-техническая конференция «Нейроинформатика-2003», 29–31 января 2003 г. / Отв. ред. Ю. В. Тюменцев. Часть 1. – М.: Изд-во МИФИ, 2003. – 188 с.
5. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // V Всероссийская научно-техническая конференция «Нейроинформатика-2003», 29–31 января 2003 г. / Отв. ред. Ю. В. Тюменцев. Часть 2. – М.: Изд-во МИФИ, 2003. – 180 с.
6. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // VI Всероссийская научно-техническая конференция «Нейроинформатика-2004», 28–30 января 2004 г. / Отв. ред. Ю. В. Тюменцев. Часть 1. – М.: Изд-во МИФИ, 2004. – 200 с.
7. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // VI Всероссийская научно-техническая конференция «Нейроинформатика-2004», 28–30 января 2004 г. / Отв. ред. Ю. В. Тюменцев. Часть 2. – М.: Изд-во МИФИ, 2004. – 200 с.

8. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // VII Всероссийская научно-техническая конференция «Нейроинформатика-2005», 26–28 января 2005 г. / Отв. ред. *Ю. В. Тюменцев*. – М.: Изд-во МИФИ, 2005. – 216 с.
9. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // VIII Всероссийская научно-техническая конференция «Нейроинформатика-2006», 24–27 января 2006 г. / Отв. ред. *Ю. В. Тюменцев*. – М.: Изд-во МИФИ, 2006. – 244 с.
10. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // IX Всероссийская научно-техническая конференция «Нейроинформатика-2007», 24–26 января 2007 г. / Отв. ред. *Ю. В. Тюменцев*. Часть 1. – М.: Изд-во МИФИ, 2007. – 180 с.
11. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // IX Всероссийская научно-техническая конференция «Нейроинформатика-2007», 24–26 января 2007 г. / Отв. ред. *Ю. В. Тюменцев*. Часть 2. – М.: Изд-во МИФИ, 2007. – 148 с.
12. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // X Всероссийская научно-техническая конференция «Нейроинформатика-2008», 22–25 января 2008 г. / Отв. ред. *Ю. В. Тюменцев*. Часть 1. – М.: Изд-во МИФИ, 2008. – 152 с.
13. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // X Всероссийская научно-техническая конференция «Нейроинформатика-2008», 22–25 января 2008 г. / Отв. ред. *Ю. В. Тюменцев*. Часть 2. – М.: Изд-во МИФИ, 2008. – 164 с.
14. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // XI Всероссийская научно-техническая конференция «Нейроинформатика-2009», 27–30 января 2009 г. / Отв. ред. *Ю. В. Тюменцев*. – М.: Изд-во МИФИ, 2009. – 280 с.
15. CiteSeer^x: Scientific Literature Digital Library and Search Engine.
URL: <http://citeseerx.ist.psu.edu/>
16. The Archive arXiv.org e-Print archive – Physics, Mathematics, Nonlinear Sciences, Computer Science.
URL: <http://arxiv.org/>
17. Портал научных вычислений (Matlab, Fortran, C++ и т. п.)
URL: <http://www.mathtools.net/>

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

В. Л. ДУНИН-БАРКОВСКИЙ

Отдел нейроинформатики, Центр оптико-нейронных технологий,
НИИ системных исследований РАН, Москва

E-mail: wldb@niisi.ras.ru

ТЕОРИЯ МОЗЖЕЧКА

Аннотация

Приведен аналитический обзор данных о нейронных операциях в мозжечке. Эти операции основаны на роли клеток нижних олив (лианнных клеток), дающих лианнные волокна на клетках Пуркинье мозжечка, в работе мозжечка. Совокупность морфологических, физиологических и модельных данных, полученных после появления гипотезы обучения в мозжечке (Marr, 1969), свидетельствует о том, что эта гипотеза в целом верна, но детали работы нейронов мозжечка сильно отличаются от первоначальных идей. Как наличие, так и отсутствие импульсации лианнной клетки являются сигналами для модификации синапсов параллельных волокон на клетках Пуркинье, которая зависит также от активности пресинаптических волокон. Хранение информации реализуется как адаптивная аппроксимация значений запоминаемой функции комбинациями величин активности зернистых клеток. Запоминающая емкость системы определяется количеством участвующих в ее работе модифицируемых синапсов. Запоминающие способности клеток Пуркинье, управляемых одной лианнной клеткой, суммируются. Заключается, что сейчас уже сложился комплекс основных представлений о том, как и что делает мозжечок, и актуальны исследования по детализации этих представлений. Настоящий обзор дополняет новыми данными статью (Дунин-Барковский, Подладчикова, 2002).

W. L. DUNIN-BARKOWSKI

Department of Neuroinformatics, Center for Optical Neural Technologies,
Scientific Research Institute for System Analysis,
Russian Academy of Sciences, Moscow
E-mail: wldb@niisi.ras.ru

THEORY OF CEREBELLUM

Abstract

A survey of the data on neural operations in the cerebellum is given. These operations are based on a role of climbing fiber cells (neurons of inferior olives), in functions of the cerebellum. It is shown that the whole set of morphological, physiological, and model data obtained after publicizing of the cerebellar learning theory (Marr, 1969) proves that the theory is correct in its basic principles, although many details of the work of cerebellar neurons much differ from initial ideas. Impulses of a climbing fiber cell as well as absence of impulses serve as signals for modification of synapses of parallel fibers on Purkinje cells. The synaptic changes also depend on activity of presynaptic fibers. Information storage in the cerebellum is implemented as adaptive approximation of (real-valued non-negative) stored functions with combinations of activity of granule cells. The storage capacity of the system is determined by a number of modifiable synapses in the system. Storage capacities of different Purkinje cells controlled with a single climbing fiber cell are additive. A formulation of a problem for physiological experiments of analysis of work of pairs of Purkinje cells controlled with a single climbing fiber cell, and first results of such experiments are described. It is concluded that the skeleton of principles of how the cerebellum works and what it does is established now and studying the details of these mechanisms are on agenda. The present survey is an updated version of (Дунин-Барковский, Подладчикова, 2002).

Введение

Общеизвестна удивительная однородность и регулярность мозжечка – структуры мозга, ответственной за координацию движений и двигательное обучение, что привлекало к его исследованиям пристальное внимание ученых разных специальностей. Благодаря этому детали нейронной организации мозжечка изучены на структурном, функциональном и вычислительном уровнях, по-видимому, лучше, чем характеристики других отделов мозга. И, хотя до сих пор нет общепринятой доминирующей концепции того, как работает мозжечок, ее контуры постепенно проясняются.

Краткая сводка данных о нейронной организации мозжечка

Мозжечок — это 10% массы мозга и от 50% до 90% общего числа нервных клеток (когда не оговорено противное, речь идет о мозжечке человека). Центральной в мозжечке бесспорно является клетка Пуркинье (КП), — очевидно самая красивая клетка в нервной системе позвоночных (рис. 1). Ни одна книга о нервных клетках не обходится без ее «портрета». Дендриты КП (общая длина — около 10 мм, среднее расстояние до тела клетки около 400 мкм) равномерно упакованы в параллелепипед («листок») с размерами (500 мкм) × (500 мкм) × (10 мкм). КП расположены в коре мозжечка в один слой и их дендритные «листки» параллельны друг другу. На каждую КП действует чрезвычайно много (до 500 тыс.) синапсов от зернистых клеток, получающих входы от мшистых волокон (Ito, 1984, 2001, 2006, 2008).




Рис. 1. Клетка Пуркинье мозжечка крысы в опыте по исследованию ее электрических реакций и динамики внутриклеточного кальция. Темная полоса, подходящая слева к телу клетки — это электрод, обеспечивающий режим фиксации потенциала всей клетки (фото из работы (Artinian, Finch, 2003))

Аксоны зернистых клеток называются параллельными волокнами (ПВ). Они практически параллельны друг другу и перпендикулярны плоскости дендритов КП. Длина ПВ — до 6 мм; каждое из них пронизывает до 1000 «листочков» КП. Помимо входов от большого числа зернистых клеток на каждую КП через сложный синапс оказывает мощное воздействие одиночное входное нервное волокно — лианное волокно (ЛВ). Клетки — источники этих волокон (лианные клетки, ЛК) расположены вне мозжечка (в ядрах нижних олив), но их естественно считать элементами его устройства. Каждая ЛК действует на несколько разных КП (у крысы, в среднем, 7, с диапазоном от 2 до 17 (Sugihara et al., 2001, Sugihara, 2006)).

Активность КП чрезвычайно разнообразна — от длительных пауз до высокочастотных пачек импульсов. В частности, ЛК активируют КП со средней частотой 1 раз в секунду, при этом как слишком длинные, так и короткие межимпульсные интервалы редки. В силу конструкции синапса ЛВ и его расположения на ближних к телу клетки ветвях дендритов КП даже одиночный импульс ЛК вызывает мощное кратковременное (1–4 импульса с мгновенной частотой до 500 имп/с) возбуждение КП, которое называется сложным импульсом (СИ) в отличие от простых, обычных, импульсов, которыми клетка работает в остальное время с частотой до 150 имп/с. Генерация простых импульсов (ПИ) обусловлена входами ПВ.

КП являются выходными клетками коры мозжечка. Их аксоны обеспечивают управление активностью ядер мозжечка. Разные отделы коры мозжечка связаны с разными ядрами. КП через интернейроны ядер оказывают воздействие на ЛК. Это воздействие осуществляется через особый тип клеток в ядрах мозжечка — малые тормозные клетки (МТК). Каждая из этих клеток имеет тормозящие синапсы на всех ЛК, формирующих вход к тем же КП, которые дают выход на данную МТК. В конечном счете возбуждение КП оказывает возбуждающее воздействие на ее ЛК, формируя как бы сигналы положительной обратной связи.

Размерами и тонкостью устройства мозжечка человек отличается от обезьяны практически так же сильно, как и корой больших полушарий мозга. То есть, не исключено, что часть исключительно человеческих функций (функций, отличающих человека от обезьяны) выполняется с существенным (или исключительным) участием мозжечка.

Мозжечок и персептрон

Структура основных связей основных клеток коры мозжечка (рис. 2) как бы «срисована» со схемы первого автоматического устройства классификации образов — трехслойного персептрона (Rosenblatt, 1962). Идея же того, что мозжечок представляет собой огромный мультиперсептрон пришла сравнительно поздно, более, чем через 10 лет после рождения этого первого успешного нейробионического проекта (Marr, 1969). С тех пор эта идея получила солидную экспериментальную и теоретическую поддержку в сотнях работ и сейчас практически не вызывает сомнений (Ito, 2001, 2006, 2008; Voicu, 2008; и многие другие).

Сейчас понятно, что мозжечок как «биологическая реализация идеи персептрона» во многих отношениях отличается от своего технического аналога.

Во-вторых, уже лет пятнадцать как стало известно, что выходные сигналы из коры мозжечка (от клеток Пуркинье) поступают на вход «обучающих» лианнных клеток. Таким образом мозжечковый мультиперсептрон охвачен сильной обратной связью. Интересно, что связь эта является одновременно и положительной и отрицательной.

Эта связь положительна, поскольку лианное волокно возбуждает клетку Пуркинье, клетка Пуркинье тормозит клетки ядер мозжечка, которые, в свою очередь, тормозят лианнные клетки, т. е., в конечном счете, возбуждение лианнной клетки приводит к положительному сигналу на входе этой клетки. Прямых экспериментов по тестированию данного механизма положительной обратной связи не проводилось. В принципе, не исключено, что ее и нет, если лианнная клетка помимо лианнных синапсов на клетках Пуркинье имеет синапсы на тех клетках ядер мозжечка, которые замыкают обратную связь на лианнные клетки. Такие связи могли бы блокировать эффект непосредственного возбуждения клетки Пуркинье лианнным волокном.

Отрицательная обратная связь с лианнных клеток на себя через клетки Пуркинье подтверждена в многочисленных экспериментах и замыкается следующим образом. Связи с зернистых клеток (т. е., с их аксонов — параллельных волокон) на клетках Пуркинье все время меняют свою силу. Причем, сила связей может как расти, так и уменьшаться. Скорость изменения весов связей контролируется, в основном, двумя факторами. Первый из них — фактор лианнной клетки. Его величина и знак переменны во времени и зависят только от времени, прошедшего с момента начала последнего импульса лианнной клетки. Точная форма этой зависимости не изучена, но в первом приближении — это ступенчатая функция, отрицательная на интервале от нуля до 20 мс и положительная при остальных значениях аргумента. Интеграл от этой функции по ее аргументу от нуля до текущего положительного значения обращается в нуль при значении аргумента около одной секунды. Это значение, называется равновесным интервалом (активности) лианнной клетки. Второй фактор, влияющий на скорость изменения связей параллельных волокон, фактор параллельного волокна, зависит от того, какова была активность пресинаптической зернистой клетки на интервале времени, предшествующем текущему моменту. То есть, фактор представляет собой свертку активности пресинаптического нейрона с некоторым ядром, точные характеристики которого неизвестны. В том случае, когда фактор параллельного волокна постоянен, а лианнная клетка разряжается с равновесным интервалом, сила связи параллельного волокна с клеткой

Пуркинье, слегка колеблясь, остается постоянной в течении длительного времени.

В реальном мозжечке, во всех случаях, когда активность лианного волокна прекращалась (например, при повреждении или временном охлаждении лианной клетки), в течение 10 минут после прекращения возбуждения лианной клетки частота работы клеток Пуркинье становилась очень большой и оставалась такой до конца периода наблюдения, или до тех пор, пока не начинает возбуждаться лианная клетка (Colin et al., 1980).

Отведение активности от клеток Пуркинье в большинстве экспериментальных условий показывает, что импульсы лианной клетки генерируются обычно как бы случайно, со слабой или отсутствующей корреляцией с динамикой действий, в которую мозжечок вовлечен. Корреляция между соседними межимпульсными интервалами незначительна. Средний межимпульсный интервал — около одной секунды.

Теоретический анализ работы упрощенной модели мозжечкового модуля в случае постоянных входных сигналов (как по скалярному входу, так и по векторному входу состояний внешней системы) показывает, что при любых начальных условиях система приходит в стационарное состояние за экспоненциальное время.

Имитационные эксперименты показывают, что в стационарном состоянии лианная клетка работает в режиме динамического хаоса со средним межимпульсным интервалом, равным равновесному интервалу лианной клетки. Переход из одного равновесного состояния системы в другое при замене входных констант на новые случайные значения занимает около тысячи таких интервалов. К стационарному режиму работы лианной клетки система приходит и в том случае, когда сигналы на входе системы непрерывно изменяются, оставаясь функциями одного скалярного параметра. Если же сигналы на входе системы — периодические функции такого параметра, статистические свойства активности лианной клетки в стационарном режиме не отличаются от характеристик этой активности при постоянных сигналах на входе системы. В последнем случае выход системы опережает входной сигнал по фазе, на величину, зависящую от постоянной времени клеток ядер. В этом смысле модуль осуществляет как бы предсказание входного сигнала. Что, безусловно может быть полезно для всех функций, в которых мозжечок может принимать участие.

Каковы функции мозжечка

На этот вопрос примерно с равным основанием можно ответить двояко, например: «Мозжечок делает все». Или: «Мозжечок ничего не делает». Разрешение парадокса в том, что мозжечок вырабатывает, хранит и отвечает за выполнение основной массы тонких деталей любых движений, выполняемых мозгом, как физических или мысленных, так и движений души. Последнее становится понятным только в самое последнее время (Ito, 2008; Ackermann, 2008). В частности, есть гипотеза, что мозжечок ответственен за интуицию, т. е. решение стоящих перед человеком задач без осознания процесса решения.

Практически всякое движение может быть исполнено как грубо, тяп-ляп, так и может быть насыщено массой деталей. Наличие многих деталей может казаться не необходимым для конечной функции, но они могут существенно влиять на качество выполняемых действий. Хорошая аналогия здесь — принятие пищи. Происходить оно может как в роскошных ресторанах с роскошными блюдами, так и просто в любом месте, любым способом и продуктами лишь покрывающими необходимые энергетические и ассортиментные (водные, солевые, витаминные и т. д.) потребности организма. И то и другое — питание, но цены их могут различаться на многие порядки величины.

А представление о «ненужности» мозжечка (в особо яркой форме высказался на эту тему *Джефф Хокинс* в своей знаменитой книге «Об интеллекте» (Hawkins, Blakeslee, 2004)) возникло вот почему. При грубом обследовании движений животных и человека можно сказать, что все они возможны и в отсутствие мозжечка (т. е. — «мозжечок ни для чего не нужен»). Хотя, оказывается, что не все движения — полет птиц и летучих мышей без мозжечка невозможен. Очевидно, суть дела здесь в том, что полеты вообще невозможны без огромной массы тонких деталей. Кстати, мозжечок летающих позвоночных, больше по размерам и совершеннее по структуре, чем у их нелетающих ближайших родственников. Но человек без парашюта или самолета не летает, поэтому *Хокинс* считает, что мозжечок к интеллекту не имеет отношения. Поправляя этого автора, отважного рыцаря, первого из успешных создателей современных вычислительных средств, решившегося на «лобовую атаку» на создание искусственного разума, можно сказать, что мозжечок нужен для полета. И, в частности, — для полета мысли.

Функция лианнных клеток

Как отмечалось выше, для внешнего наблюдателя кора мозжечка с входными мшистыми волокнами, переключающимися на зернистых клетках и далее действующими на КП, на каждую из которых действует еще и сильный «хозяин» — ЛВ, один в один похожа на трехслойный перцептрон Розенблатта (Rosenblatt, 1962). Даже несколько странно, что интерпретация структуры коры мозжечка как множества перцептронов появилась только в 1969–1971 гг. (Marg, 1969, Albus, 1971). После появления этой теории начались интенсивные поиски процессов обучения в мозжечке (Дунин-Барковский, Ларионова, 1976; Gilbert, Thach, 1977, Ito, 1977; Дунин-Барковский и др., 1987; и многие другие). Результаты этих поисков будут рассмотрены ниже. Как в контексте парадигмы обучения, так и вне нее, надо было пытаться понять, что и как делает лиана, образующая на КП, пожалуй, самый сильный синаптический контакт между клетками нервной системы позвоночных.

Трудности с лианнными клетками — большие. С одной стороны, эти клетки формируют одно из самых сильных синаптических соединений в нервной системы. С другой стороны, ЛК работает импульсами с частотой 1 имп/с. Моменты появления импульсов у ЛК в большинстве случаев слабо коррелированы с какими-нибудь внешними событиями. Несмотря на низкую среднюю частоту импульсации, которая сохраняется на одном и том же уровне в течение интервалов времени порядка десятка минут, ЛК так или иначе функционирует постоянно. ЛК вызывает мощное возбуждение КП, но это гипервозбуждение порождает на выходе КП лишь 2–3 импульса, за которыми часто следует пауза. Уже из этого краткого описания более или менее понятно, что ЛК функционирует как-то не так, как «нормальные» нейроны. Мы с двух разных сторон попытались подойти к анализу функции ЛК в работе КП. Первый подход — экспериментальный. Задача этого подхода состояла в том, чтобы исследовать одновременно активность разных КП, управляемых ЛВ одной и той же ЛК. Если активность ЛВ влияет на формирование связей ПВ с КП, то у КП, получающих ЛВ от одной ЛК («лианнных близнецов») корреляция активности их ПИ должна быть значительно выше, чем у КП, контролируемых разными ЛК (см. следующий раздел).

Второй подход — теоретический. Он основывался на гипотезе, впервые высказанной в работе М. Маука с соавторами о том, что пластичность синапсов ПВ на КП позволяет поддерживать постоянной среднюю частоту активности ЛК при изменении синаптического притока на эти клетки из

вне-мозжечковых источников (Mauk, Donegan, 1997; Medina et al., 2000). Мы предложили аналитическую формулировку этой гипотезы в виде уравнений Маука и исследовали ее следствия (Dunin-Barkowski et al., 1998; Dunin-Barkowski, Wunsch, 1999, 2000; Dunin-Barkowski, 2002). Имитационное моделирование и теоретические расчеты показали, что мозжечковый модуль, основанный на гипотезе Маука, объясняет экспериментальные данные, которые не закладывались исходно в модель, и является удобным и мощным вычислительным инструментом, работой которого можно объяснить большинство известных функций мозжечка. Эти подходы позволили нам с помощью методов Computational Neuroscience сделать существенный шаг к пониманию «нейронной механики» мозжечка — т. е. нейронных механизмов, реализованных в этой структуре мозга. Изложение результатов ниже состоит из нескольких фрагментов, каждый из которых затрагивает разные аспекты работы этой структуры.

В погоне за Близнецами

- Почему же его никто не может поймать?
- Да он никому не нужен.

Из анекдота о Неуловимом Джо

В 1976 г. автору данного обзора пришла идея о том, что ключ к пониманию «механики» мозжечка может дать регистрация пар КП, контролируемых одной и той же ЛК. Позднее, в НИИ нейрокибернетики им. А. Б. Когана мы стали называть такие КП лианными «близнецами». Исходно идея «ловить пары близнецов» появилась как идеальное средство «проверки» гипотезы о том, что ЛВ определяет связи КП с ПВ (Дунин-Барковский, 1976). Главное преимущество этой экспериментальной модели виделось в том, что она может дать возможность посмотреть на результаты «обучения», имевшего место когда-то в прошлом в истории данных клеток. Иными словами, обучение (если оно имело место) проходило в абсолютно естественных условиях. Такой подход контрастировал с разнообразными схемами опытов по «обучению» КП, реализованными в известных экспериментальных работах, использовавших преимущественно сочетанную стимуляцию входов ПВ и ЛВ (Ito et al., 1982, Дунин-Барковский и др., 1987; Linden, 1996; Artinian, Finch, 2003; и многие другие). В качестве одного из критериев то-

го, что КП контролируются одной и той же ЛК, предполагалось сравнивать времена возникновения СИ у пар КП — близнецов. На основании известных данных (о скорости распространения импульсов по ЛВ, характере их ветвления, стабильности ЛП ответов КП на стимуляцию ЛВ и пр.) следовало ожидать (Дунин-Барковский, 1978), что СИ у лианных близнецов должны быть или синхронны или иметь постоянный временной сдвиг порядка 1–2 мс с высокой стабильностью (флуктуация менее 10% от исходной величины).

Однако регистрация активности КП-близнецов была нерешенной экспериментальной задачей. Несмотря на множество косвенных указаний на наличие таких КП (Ito, 1984), регистраций КП с синхронными СИ и несинхронными ПИ, что соответствует критериям активности КП с общим ЛВ, в литературе до начала наших исследований не было описано. Единственная запись синхронных СИ двух КП без анализа особенностей их активности представлена в работе (Bell, Kawasaki, 1972). Но, похоже, что в той работе «близнецы» не регистрировались. Сложность проблемы поиска и регистрации активности КП с общим ЛВ отмечалась в ряде работ (например, Sasaki et al., 1989) и в личных дискуссиях в 1976–2001 гг. (П. Г. Костюк, М. Ито, Ю. И. Аршавский, И. А. Кедр-Степанова, Дж. Симпсон и другие). Начиная с 1990 г. над указанной проблемой началась совместная работа автора обзора и Л. Н. Подладчиковой с сотрудниками. Первая наша публикация на эту тему появилась в 1993 г. (Dunin-Barkowski et al., 1993) и это было по существу анонсирование намерений. В последующие годы была разработана стратегия поиска «близнецов» и получены первые результаты в этом направлении — регистрация активности удаленных друг от друга лианных окончаний аксона ЛК (Дунин-Барковский и др., 1997). В 1999 г. мы опубликовали также данные по двум парам близнецов (Dunin-Barkowski et al., 1999; Дунин-Барковский и др., 1999). Только у одной из этих пар одновременно наблюдались и сложные и простые импульсы КП. Разработанные методы проведения эксперимента и анализа данных позволили фактически в каждом опыте ($n = 18$) наблюдать в коре мозжечка морских свинок и крыс активность (в том или ином виде) от одной до трех пар КП с общим ЛВ. Ниже мы подробнее опишем результаты наших поисковых исследований, проведенных на коре мозжечка морской свинки.




Рис. 3. Два примера (а, б) пар КП-«близнецов». Расстояние между электродами в референтном (верхние кривые, отмечены \blacktriangledown) и тестовом (нижние кривые) отведениях 400 мкм (а) и 600 мкм (б). Приведены усредненные сложные импульсы, в каждой паре кривых (а) и (б) верхние и нижние кривые получены одновременно в одном опыте и их изображение синхронизировано по времени; n — количество усредненных потенциалов. В случае (а) индивидуальные СИ и ПИ идентифицировались как в референтном, так и тестовом отведениях. В (а) СИ в референтном отведении опережает СИ в тестовом отведении, в (б) наблюдаются обратные временные отношения между двумя СИ. Форма СИ во всех четырех случаях различна

второй электрод на значительных расстояниях (от нескольких сотен микрон до нескольких миллиметров) в одной парасагиттальной плоскости (± 200 мкм) с первым электродом и искать зоны, в которых видны потенциалы, синхронные с СИ, регистрируемыми первым электродом. После нахождения точки с ощутимыми следами СИ предполагалось подробно исследовать окрестности такой точки с учетом полученных на первом этапе данных о расстоянии, на котором может быть зарегистрирован потенциал, связанный с возбуждением данной КП.

3. В другой серии опытов мы применяли «гребенки», состоящие из нескольких (до 6) электродов, расположенных на одной линии, в надежде обнаружить (как бы случайно) пару КП, контролируемых общей ЛК.

На первом этапе поисковых экспериментов удачной оказалась вторая серия опытов. Получено 14 парных регистраций потенциалов СИ (из 255), которые соответствуют приведенным выше критериям обусловленности активностью разных ветвей аксона одной ЛК. Эти регистрации представлены одной парой КП с идентифицируемыми СИ и ПИ у обеих клеток (рис. 3а), одной парой КП с СИ без ПИ (рис. 4а) и 12-ю парами — с наличием СИ и ПИ в одном из отведений (референтном) и низкоамплитудных полевых потенциалов (НАПП) в другом (тестовом) отведении (рис. 3б), выявляемых при синхронной суммации потенциалов в обоих отведениях. НАПП имели сходство формы и длительности с СИ. В частности, длительность НАПП коррелировала ($r = +0.89$) с длительностью референтных СИ (10.46 ± 4.31 мс и 10.49 ± 4.15 мс). Кроме того, НАПП проявляли стабильность параметров в разных выборках суммации и жесткую привязку по времени к СИ референтной КП. Они начинались раньше или позже референтного СИ (см. рис. 3), в среднем, на 0.82 ± 0.58 мс, при этом различие в парах независимых выборок суммации референтных СИ одной КП составило 0.09 ± 0.03 мс. Обнаруженные свойства НАПП указывают на то, что наиболее вероятный источник этих потенциалов — постсинаптическое действие на не идентифицированную КП одной из ветвей ЛВ, контролирующего референтную КП.

Что мы увидели в первых регистрациях (14 пар) активности КП-близнецов?

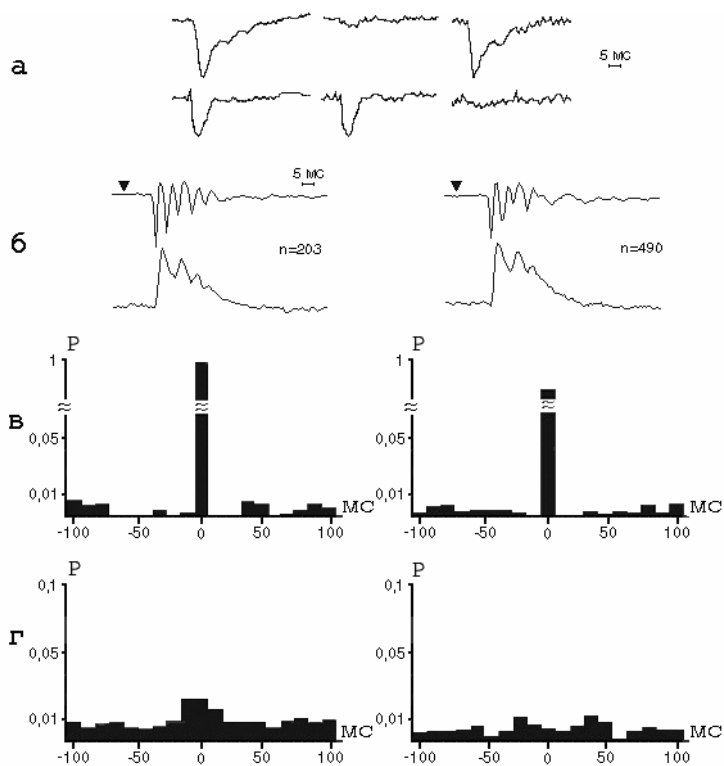


Рис. 4. Динамика синхронизации СИ у пар КП с общим (а-в) и разными ЛВ (г). (а) пример СИ одной из пар КП-близнецов при синхронных (слева) и асинхронных (в центре и справа) разрядах; (б) пример длительных (слева) и коротких (справа) СИ другой пары КП-близнецов; (в, г) функции кросскорреляции СИ одних и тех же КП при изменении длительности СИ

Наблюдения, связанные с СИ зарегистрированных клеток-близнецов

1. Во-первых, мы увидели то, что ожидали увидеть: в мозжечке встречаются практически синхронные СИ клеток, расположенных достаточно далеко друг от друга — на расстояниях от 200 мкм до 900 мкм.

2. Во-вторых, неожиданно оказалось, что часто наблюдается отсутствие СИ в одном из каналов (Рис. 4а) при его присутствии в другом канале (в среднем, вероятности таких событий — 0.05 и 0.18 для двух пар, представленных на рис. 3а и 4а, соответственно). Обнаружено, что вероятность совместного разряда СИ у пар КП с общим ЛВ зависит от ряда параметров активности. В частности, при раздельной суммации потенциалов в режимах синхронной и асинхронной генерации СИ оказалось, что асинхронные СИ у каждой КП были короче по длительности (на 2–6 мс) и имели меньше компонент, чем синхронные (рис. 4а, см. также (Дунин-Барковский и др., 1999)), при этом степень синхронизация длительных СИ была много выше, чем у СИ короткой длительности (рис. 4в). У пар КП, иннервируемых разными ЛВ и расположенных на расстоянии 100–200 мкм друг от друга, в редких случаях также проявлялась более выраженная грубая синхронизация длительных СИ по сравнению с СИ короткой длительности (рис. 4г).

3. Форма СИ у «близнецов» может достаточно сильно отличаться (см. рис. 3). В том случае, когда форма СИ имела отчетливый колебательный характер, период этих колебаний был разным (0.9 мс для одной клетки и 1.5 мс для другой клетки на рис. 3а). Подобные различия формы СИ обнаружены в 10 из 14 случаев регистрации пар КП с общим ЛВ.

Наблюдения, связанные с СИ и ПИ клеток Пуркинье-близнецов

1. Характер зависимости ПИ от СИ для двух клеток близнецов — разный. У одной КП наблюдается только кратковременное торможение активности, в то время как у другой клетки — реакция многофазная: торможение-возбуждение-торможение (рис. 5.2а). Одной из возможных причин столь различного поведения КП с общим ЛВ могло являться различие формы их СИ (см. выше). Это предположение было протестировано на всей выборке зарегистрированных КП ($n = 41$). Оказалось, что не только взаимодействия между СИ и ПИ (рис. 5.2б), но и все проявления активности данной КП,

включая свойства ПИ (Подладчикова и др., 2002), коррелируют с типом СИ («быстрый» или «медленный»).

2. Характер функции автокорреляции у обеих клеток был сходный, но не идентичный (рис. 5.1а).

3. Вопреки нашим ожиданиям, мы не обнаружили выраженной кросс-корреляции простых импульсов КП-близнецов на временах порядка времени их автокорреляции (Дунин-Барковский и др., 1999).

4. При анализе тех случаев, когда собственный СИ КП был блокирован, обнаружено торможение в активности ПИ после сложного импульса КП-двойника, в то время как у пар КП, иннервируемых разными ЛВ, торможение ПИ после «чужого» СИ никогда не наблюдалось (Подладчикова и

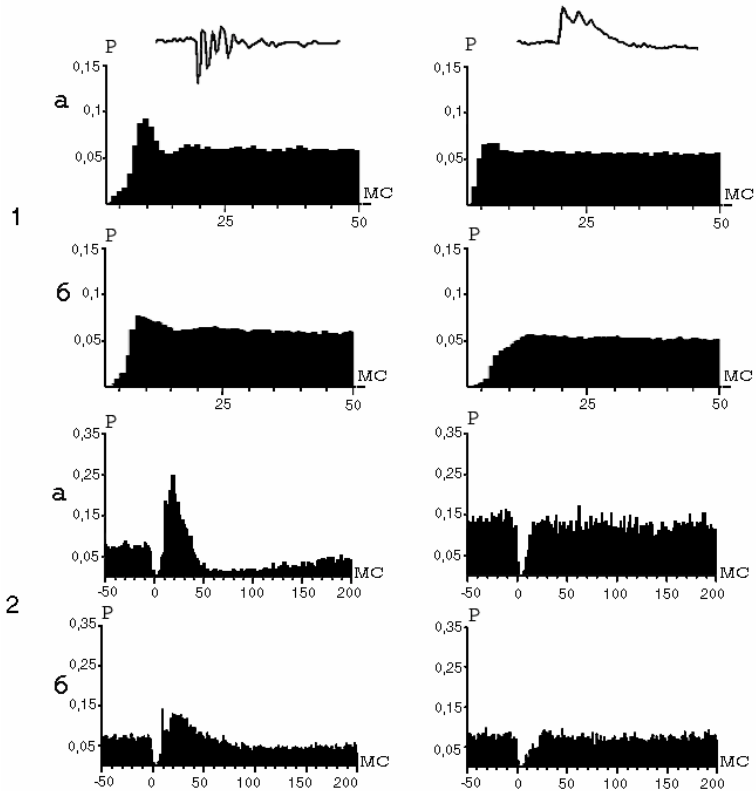


Рис. 5. Функции автокорреляции ПИ (1) и кросскорреляции между СИ и ПИ (2) у КП с СИ «быстрого» (слева) и «медленного» (справа) типов. На (1) и (2) верхний ряд — гистограммы активности одной из КП-близнецов, нижний ряд — усредненные гистограммы для всей выборки КП данного типа. Гистограммы нормированы к 50 отсчетным импульсам; на (1а) и (1б) значение функций в нулевом кванте, равное 1, не представлено. Вверху показаны примеры СИ «быстрого» и «медленного» типов

зернистых клеток, которые активируются непосредственно вслед за возбуждением ЛВ — уменьшают свою эффективность (так называемая долговременная депрессия в мозжечке (Ito, 1984, 2001), а синапсы зернистых клеток, которые возбуждаются в отсутствие возбуждения ЛВ, увеличивают свою эффективность. Отсюда следует, что пластичность связей зернистых клеток с КП организована таким образом, что поддерживает более или менее постоянным суммарный синаптический приток к ЛК. В самом деле, если возрастает синаптический приток к ЛК извне мозжечка, они начнут чаще возбуждаться. В силу этого, синаптические связи зернистых клеток на той КП, на которую действует данная ЛК начнут ослабляться, что вызовет увеличение тормозящего входного сигнала на ЛК (КП ослабят торможение клеток ядер, а те — увеличат торможение ЛК). Данное грубое описание не дает представления о том, что может происходить в динамике, когда на мозжечок поступают быстро изменяющиеся сигналы и входная информация на ЛК коррелирована с активностью зернистых клеток. Мы провели необходимый анализ и моделирование работы лианной ячейки мозжечка (Dunin-Barkowski, 2002; Вышинский и др., 2003), чтобы оценить роль указанных факторов в работе системы. Основные результаты описаны ниже.

Уравнения Маука

Рассмотрим конструкцию на рис. 6а. Мы будем использовать следующие обозначения и предположения:

$\Pi(t)$ — частота простых импульсов КП (неотрицательная непрерывная переменная);

$g(t) = (g_1(t), \dots, g_N(t))$ — активность зернистых клеток; g_i равно либо 1 либо 0;

$\sigma_1, \dots, \sigma_N$ — веса возбуждающих синапсов зернистых клеток на КП, неотрицательная непрерывная переменная;

$\alpha(t)$ — внешний (не от КП) синаптический вход на ЛК;

N — количество зернистых клеток, действующих на одну КП.

Связи от КП к ЛК осуществляются малыми ядерными клетками (не показаны на рис. 6а). Детали работы этого звена обсуждаются ниже. На рис. 6а выход КП имеет двойное обозначение: $\Pi(t)$ и $\underline{a}(t)$, чтобы подчеркнуть тот факт, что $\Pi(t)$ часто может быть копией (но инверсированной!) $a(t)$. Это обстоятельство является важнейшим свойством мозжечкового модуля и детально описано ниже.




Рис. 6. Основные элементы мозжечкового модуля: **(а)** базовая структура, здесь Π — КП, C — ЛК, g_1, \dots, g_N — аксоны зернистых клеток, $\sigma_1, \dots, \sigma_N$ — синаптические веса, $\alpha(t)$ — внешний вход на C , $\Pi(t)$ и $\tilde{a}(t)$ — выход Π ; **(б)** зависимость синаптической пластичности от времени, прошедшего с момента последнего возбуждения ЛК; T_{equ} — равновесный интервал; **(в)** характеристики активности зернистых клеток, g_1, \dots, g_N — активность зернистых клеток. Овальная линия представляет возможные значения векторов активности зернистых клеток; стрелки показывают направление изменения активности во времени; **(г)** временной ход внешнего входа на ЛК, s — параметр входного множества

Поведение системы мы описываем следующими уравнениями Маука:

$$\Pi(t) = \int_{-\infty}^t \sum_{i=1}^N \sigma_i(\theta) g_i(\theta) \exp\left(-\frac{t-\theta}{T_{\Pi}}\right) \frac{d\theta}{T_{\Pi}}, \quad (1)$$

$$\frac{d\sigma_i(t)}{dt} = \varepsilon \xi(t - t_j) e_i(t), \quad i = 1, \dots, N, \quad (2)$$

$$e_i(t) = \Phi(g_i(\theta)), \quad (3)$$

$$e_i(t) = I \exp(-(t - v_i)/T_e), \quad (3')$$

$$\int_{t_j}^{t_{j+1}} (\alpha(\theta) + \beta \Pi(\theta)) \exp\left(-\frac{t_{j+1}-\theta}{T_c}\right) d\theta = H, \quad j = 0, 1, 2, \dots \quad (4)$$

Большая часть обозначений описана выше. Остальные обозначения и комментарии — следуют. Уравнение (1) описывает работу КП. Его выходной (непрерывный) параметр — частота ПИ. Мы используем простейший

оператор для описания КП, поскольку вычисления показывают, что точная форма вход-выходной зависимости КП мало влияет на работу системы (Dunin-Barkowski, 2002). Уравнения (2) — основа системы. Их столько же, сколько синапсов ПВ на КП. Согласно этим уравнениям веса этих синапсов постоянно изменяются. Скорость изменения пропорциональна «лианной» функции пластичности $\chi(\tau)$, представленной на рис. 6б. Эта функция обобщает экспериментальные данные о двунаправленной синаптической пластичности (Mauk, Donegan, 1997, Ito, 2006). Величина T_{equ} на рис. 6б обозначает равновесный интервал работы ЛК, в течение которого сумма положительных и отрицательных площадей под кривой $\chi(\tau)$ достигает нуля. Второй зависящий от времени множитель в (2) представляет собой готовность синапса к изменениям, $e(t)$. Этот фактор зависит от активности пресинаптического ПВ, $g(t)$, но не совпадает с ней, как показывают уравнения (3) и (3'). Очевидно, (3) и (3') отображают накопление и распад *метаботропного фактора* в синапсах ПВ на КП. Последний следует отличать от *ионотропного* действия этих синапсов (фактически описываемого уравнением (1)). Разумеется, присутствие метаботропного фактора в уравнениях синаптической пластичности совершенно естественно с точки зрения клеточной физиологии. Важно, однако, что система, в которой синаптическая пластичность зависит от ионотропного фактора - неустойчива (см. ниже). Уравнения типа (3) и (3') использовали также (Spoelstra et al., 2000), но с мотивацией, отличающейся от нашей. Точная форма уравнения (4) для последовательности моментов возбуждения ЛК не очень существенна. Здесь, однако, обязательно должно фигурировать взаимодействие на входе ЛК двух типов синаптических входов (извне мозжечка и от КП (доставляемого с помощью клеток ядер)). В (4) $\alpha(t)$ — это внешний вход на ЛК, а β — константа.

Рис. 6а и 6б и уравнения (1)–(4) составляют упрощенное ядро модели мозжечка. В частности, на рис. 6а отсутствуют клетки ядер мозжечка. В следующем разделе мы рассмотрим правомерность этого упрощения.

Преобразование информации малыми клетками ядер мозжечка

Одна ЛК посылает ЛВ к нескольким КП (10 — у человека, 7 — у крысы). Недавно были описаны 34 ЛК крысы с полным прослеживанием всех окончаний их аксонов (Sugihara et al., 2001; Sugihara, 2006). Количество лианнных окончаний у этих клеток составляет 6.6 ± 3.7 (среднее стандартное \pm отклонение). Эти данные показывают, что существуют какие-то неслучай-

ные факторы, определяющие число коллатералей ЛК в каждом конкретном случае.

КП действуют на ЛК через малые клетки ядер. Для оценки эффектов, вызываемых этим преобразованием, рассмотрим простейшие линейные уравнения, описывающие ядерные клетки:

$$z_i(t) = k_i \sum_{j \in C_i} G(y_j(t)) + \sum_{j \notin C_i} G(y_j(t)) . \quad (5)$$

Здесь $z_i(t)$ — компонента синаптического потенциала ЛК с номером i , которая обусловлена входом от малых клеток ядер; $y_j(t)$ выходной сигнал КП с номером j ; $G(\cdot)$ — преобразование сигналов в синапсах; C_i — множество КП, связанных с i -й ЛК, k_i — масштабный множитель. Свойства (5) зависят от корреляции между внешними входами различных ЛК. В качестве первого приближения будем считать их некоррелированными. Мы примем также, что когда связи КП настроены, $y_j(t)$ на 100% коррелированы для КП, управляемой одной и той же ЛК и имеют нулевую корреляцию для КП, управляемых разными ЛК (см. рис. 2). Это предположение — очень сильное. Его справедливость зависит от того, насколько коррелированы входы зернистых клеток на клетки Пуркинье. Аналитические расчеты систем, близких к реальности затруднительны, поэтому для исследования корреляции активности клеток Пуркинье, управляемых одним лианным волокном необходимы соответствующие имитационные экстаерименты. На данной стадии анализа ограничимся гипотезой о справедливости указанных выше упрощающих предположений.

Положим $k_i = 1/(L_i \cdot p_i)$ и $y_j(t) = x_i(t)$ для всех КП, $j(i)$, управляемых i -й ЛК. Пусть L_i — количество малых клеток ядер, с которыми связывается каждая из КП, контролируемых данной i -й ЛК и p_i — количество КП, контролируемых ею. Легко заметить, что количество (равных) компонент в первой сумме в правой части (5) составляет $L_i p_i$. Количество (не равных) компонент во второй сумме уравнения (5) может быть оценено как

$$\sum_{r=1}^{N_c} (L_i p_i \cdot L_r p_r) / N_N,$$

где N_c and N_N — количество ЛК и малых клеток ядер соответственно. Теперь (5) можно переписать так:

$$z_i(t) - G(x_i(t)) = k_i \sum_{j \notin C_i} G(y_j(t))$$

или

$$z_i(t) = G(x_i(t)) + \xi_i(t), \quad (6)$$

где $G(x_i(t))$ — преобразование (одного и того же) сигнала всех КП, управляемых i -й ЛК, а $\xi_i(t)$ — шум, обусловленный сигналами от других ЛК за счет взаимодействия на «общих» малых клетках ядер.

Дисперсия $\xi_i(t)$ может быть оценена следующим образом:

$$D[\xi_i(t)] = D\left[\sum_{j \notin C_i} G(y_j(t)) = \frac{1}{L_i p_i} \cdot L_i p_i \cdot \frac{\sum_{r=1}^{N_c} L_r p_r}{N_n} \cdot \bar{D}[G(x(t))], \right.$$

где $\bar{D}[G(x(t))]$ представляет среднее значение $D[G(x_j(t))]$ для всех ЛК. Далее мы имеем:

$$D[\xi_i(t)] = \frac{1}{L_i p_i} \cdot \frac{\sum_{r=1}^{N_c} L_r p_r}{N_N} \cdot \bar{D}[G(x(t))]$$

и

$$D[\xi_i(t)] = \frac{\bar{L} \bar{p}}{L_i p_i} \cdot \frac{N_c}{N_N} \cdot \bar{D}[G(x(t))],$$

где \bar{L} и \bar{p} — средние значения L_i и p_i . Уравнение (6) описывает «шум», в канале i , обусловленный взаимодействием различных лианых модулей мозжечка за счет общих малых клеток ядер. Из (6) следует, что в среднем вклад всех посторонних компонент в $z_i(t)$ имеет амплитуду около N_c/N_N . Для реального мозжечка эта величина (и соответствующее отношение шум/сигнал) имеет порядок 1.0 (Fredette, Mugnaini, 1991). Эта величина кажется значительной, но вычислительный эксперимент показывает, что отношение шум/сигнал вплоть до 3.0 оказывает незначительное действие на способность КП запоминать внешний сигнал на ЛК (Dunin-Barkowski, 2002; также, см. ниже). Из уравнения (6) также следует, что произведение $L_i \cdot p_i$ в мозжечке должно быть постоянным для разных ЛК клеток. В противном случае отношение шум/сигнал для ЛК, имеющих малое количество лианых окончаний, будет слишком большим.

В случае коррелированных $x_i(t)$ поведение системы зависит от типа корреляции. Общий случай должен быть исследован в вычислительных экспериментах. Частный случай массовой положительной корреляции $x_i(t)$ допускает простое качественное рассмотрение. В самом деле, в этом случае для восстановления общих компонент сигналов многих ЛК могут быть использованы ресурсы (т. е. синапсы ПВ на КП) всех коррелированных

ЛК. Это обстоятельство расширяет возможности представления сигналов одновременно многими модулями ЛК по сравнению с отдельным представлением таких же сигналов.

Следует остановиться еще на одной возможной роли преобразования информации малыми клетками ядер. Ниже будет продемонстрировано, что связи зернистых клеток с КП настраиваются в конечном счете так, что сигнал от клеток ядер полностью компенсирует все колебания во времени внешнего сигнала на ЛК, обеспечивая постоянство суммарного синаптического притока к этим клеткам. Если же выходной сигнал клеток ядер представляет собой задержанный сигнал от КП (например, вследствие большой постоянной времени клеток ядер), то выходной сигнал КП представляет предсказание внешнего сигнала ЛК (впервые это явление и его возможное применение продемонстрировано в (Spoelstra et al., 2000)).

В следующем разделе будут представлены результаты имитационных экспериментов, иллюстрирующие работу описанного механизма.

Имитационное моделирование мозжечкового модуля

Мы ограничимся анализом частного случая входных и выходных сигналов мозжечка (рис. 6в и 6г), позволяющим продемонстрировать свойства этой конструкции. Пучок стрелок на рис. 6в обозначает координаты в пространстве активности зернистых клеток. Мы предполагаем, что вектор активности зернистых клеток принадлежит множеству, обозначенному овалом в верхней части рис. 6в. Вектор активности равномерно перемещается со временем по этому множеству, в направлении, указанном стрелками вдоль овала. Внешний сигнал на ЛК имеет вид:

$$\alpha(t) = \alpha(g(t)) = F(s(t)), \quad (7)$$

где s — параметр (например, порядковый номер) множества входных векторов, а $F(\cdot)$ — фиксированная функция. Рис. 6г иллюстрирует временной ход $\alpha(t)$ и $s(t)$. Необходимым условием возможности выравнивания входного потока на ЛК является: $M \leq N$, где M — количество векторов в «опорном» множестве. Ряд свойств численного моделирования уравнений (1)–(4) качественно устойчив и может быть описан в достаточно общих терминах.

Основной результат моделирования (рис. 7а и 7б) демонстрирует способность КП синтезировать выходной сигнал, точно соответствующий внешнему синаптическому притоку на ЛК, так что суммарный синаптический

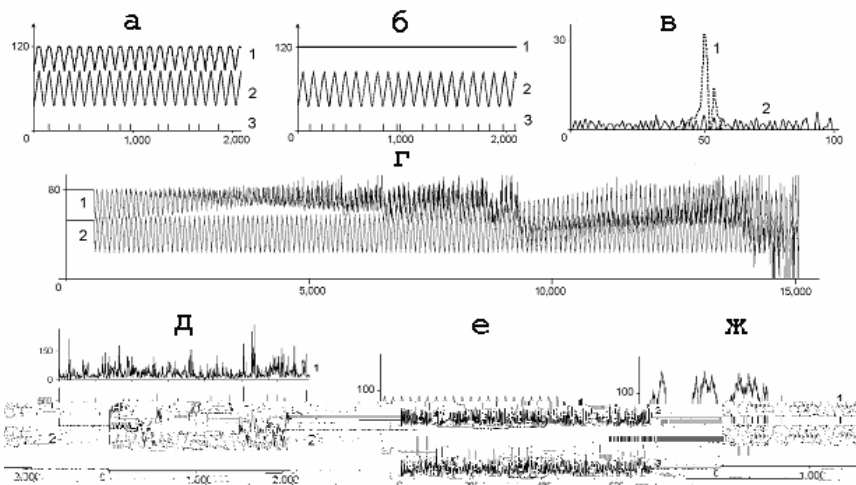


Рис. 7. Результаты моделирования. Время — в тактах моделирования. Здесь **(а)** и **(б)**: (1) — суммарный синаптический приток; (2) — внешний вход; (3) — последовательность импульсов ЛК после 200 и 5000 циклов внешнего входа; **(в)** распределение импульсов по фазам внешнего сигнала в (а, (1)) и (б, (2)); **(г)** срыв выравнивания, когда пластичность зависит от ионотропных компонентов, (1) и (2) такие же, как в (а); **(д)** 700 последовательных интервалов между импульсами: 1 — нейрон двигательной коры кролика (в мс) 2 — модельная ЛК (в тактах моделирования), 3 — ЛК мозжечка морской свинки (в секундах); **(е)**, **(ж)** — влияние шума на усвоение внешнего входа после 10000 циклов внешнего сигнала. Отношение шум/сигнал: 0 для (е) и 3.0 для (ж) 1 — внешний вход + шум; 2 — выход клетки Пуркинье

приток на ЛК становится практически постоянным. Можно видеть, что после $150 T_{equ}$, процесс выравнивания этого притока продолжается (рис. 7а). Он заведомо завершен после $3700 T_{equ}$: линия 1 на рис. 7б (суммарный синаптический приток на ЛК) — горизонтальная прямая. Характер активности ЛК (нижние лучи на рис. 7а и 7б) в переходном и стационарном режиме примерно одинаков. Однако, в переходном периоде возбуждение ЛК привязано к фазе внешнего сигнала (рис. 7в, пунктирная линия), в то время, как в стационарном режиме корреляции возбуждений ЛК с внешним сигналом не наблюдается (рис. 7в, сплошная линия). Вычисления также показывают, что настройка связей, показанная на рис. 6а и 6б, может наблюдаться для нелинейной модели интеграции информации на КП и не чувствительна к значительным вариациям свойств многих компонент системы (на рисунке не показано).




Рис. 8. Диаграмма Пуанкаре для последовательных интервалов между импульсами модельной ЛК. Черные точки имеют координаты (T_i, T_{i+1}) , где i — порядковый номер межимпульсного интервала ЛК, $i = 1, \dots, 32000$

Выравнивание неустойчиво, когда пластичность зависит не от метаботропного, а от ионотропного фактора синаптического действия. Рис. 7г демонстрирует поведение системы с пластичностью, зависящей от ионотропного фактора. Исходно система была приведена в равновесие на фоне постоянного внешнего входа на ЛК. После того, как на вход был подан

модуль. Ответ в достаточной степени очевиден. Для того, чтобы аппроксимировать функцию в N точках, нужно иметь как минимум N парамет-

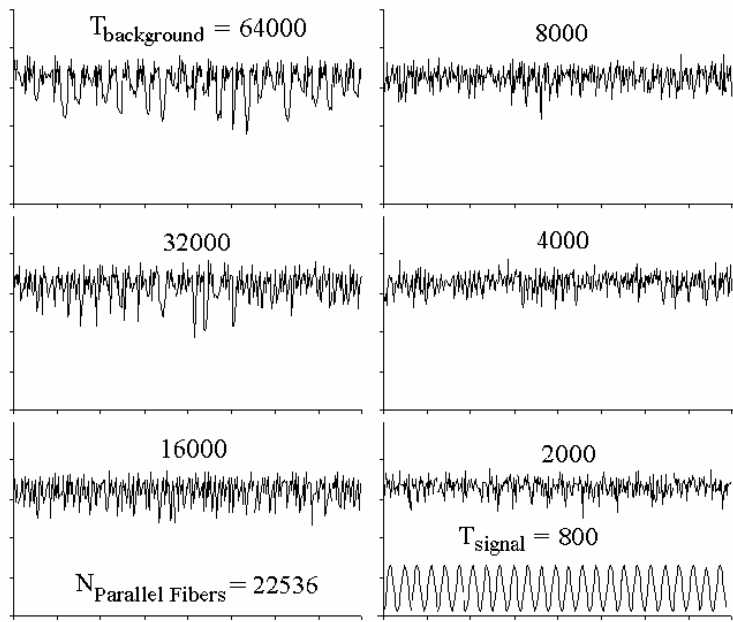


Рис. 9. Суммарный синаптический приток к ЛК, внешний синаптический приток к которой — периодический сигнал с периодом 800 (справа, внизу). Длительность цикла активности на зернистых клетках, $T_{\text{background}}$ указана на рисунке. Количество зернистых клеток — 22536. Видно, что существенное ухудшение выравнивания наблюдается тогда, когда период фонового сигнала на зернистых клетках превосходит количество этих клеток: при периодах 32000 и 64000 отдельные циклы внешнего сигнала остаются целиком не сбалансированы. Для всех значений периодов фонового цикла выравнивание проводилось в течение 100 циклов фонового сигнала

Мозжечок и когнитивные функции

Появляется все больше данных о том, что мозжечок играет очень существенную роль в когнитивных процессах (Ito, 2006, 2008; Ackermann, 2008). Прогресс в понимании когнитивных функций мозжечка, в частности, связан с успехами молекулярной генетики. Обнаружен ген, обозначаемый как FOXP2, мутации в котором приводят к нарушениям речи. Кроме того, показано, что мутации этого гена, в первую очередь, влияют на структуру мозжечка. Мутации вызывают также другие типичные «мозжечковые» нарушения движений (Ackermann, 2008).

Обнаружено три типа нарушений связанных с речью при повреждениях гена FOXP2.

Эти симптомы частично были известны и раньше у пациентов с поражениями мозжечка. Во-первых, это — так называемая скандированная речь. Она состоит из монотонно произносимых слогов. Подвижность темпа речи и ее эмоциональная окраска пропадают. Кроме того, темп речи у пациентов не может превышать 3 слога в секунду, в то время как в норме он может быть и в десять раз выше. Во вторых, нарушается так называемая внутренняя речь — произнесение текстов «про себя». В-третьих, нарушается восприятие слов, в которых существенную роль играют временные соотношения между слогами. Эти факты указывают на то, что мозжечок, хотя и не является необходимой частью нервной системы для проявлений интеллекта, тем не менее, в норме включен в выполнение интеллектуальных действий.

Обсуждение

Из изложенного следует, что основные загадки мозжечка можно считать в значительной степени разгаданными. В 1960-х годах было высказано предположение, что ЛВ настраивает связи ПВ на КП (Marr, 1969). Многие годы электрофизиологических экспериментов, детального анализа морфологии нейронов и связей и математического моделирования системы показали, что эта гипотеза в целом верна. Вместе с тем, прояснились детали того, как реализована настройка связей и какие функции она может выполнять. Основные характеристики механизмов работы мозжечка, ставших понятными благодаря 40 годам (отсчет от момента публикации статьи Дэвида Марра) комплексных исследований, проведенных во многих странах, ре-

зюмированы ниже.

1. Основным функциональным блоком мозжечка (ячейкой) является ЛК с управляемыми ею КП (от 2 до 17). Ячейка включает в себя петлю обратной связи от КП на ЛК. Ячейки мозжечка выполняют свои функции за счет пластичности синапсов ПВ на КП. Эта пластичность определяется соотношением времен возбуждения ЛВ и ПВ. В результате синаптической пластичности синаптический приток на ЛК выравнивается. Таким образом вход на ЛК из мозжечка («внутренний» вход) воспроизводит (с коэффициентом усиления минус единица) внешний вход на ЛК. Для воспроизведения (восстановления) сигнала используется очень широкий спектр информации, доставляемой в кору мозжечка мшистыми волокнами. Только подобным выравниванием можно объяснить свойства функциональной привязки активности клеток Пуркинье в работе (Noda, Suzuki, 1979). Универсальность (одинаковость) структуры мозжечка во всех его отделах показывает универсальную необходимость реализуемой им операции для разных задач организма.

2. Отдельные мозжечковые модули работают не независимо. Во-первых, у них в значительной степени общий поток входной информации от мшистых волокон. Во-вторых, клетки ядер мозжечка, участвующие в передаче сигнала от КП к ЛК, участвуют в работе многих модулей. В случае, когда внешние сигналы модулей, имеющих общие клетки ядер коррелированы, КП экономят значительные ресурсы по сравнению с независимой работой тех же модулей.

3. Выравнивание синаптического притока к ЛК может быть использовано по-разному, в зависимости от свойств внешнего сигнала ЛК и параметров петли обратной связи мозжечковой ячейки. В частности, если малые клетки ядер задерживают (например, в силу большой постоянной времени) поступление сигналов от КП на ЛК, то выход КП в настроенном состоянии предсказывает внешний сигнал на ЛК. Такое предсказание очень важно в задачах управления движениями, как это продемонстрировано в (Spoelstra et al., 2000). Опережение «выученной» реакции КП по сравнению с внешним сигналом ЛК важно в участии мозжечка в мигательном условном рефлексе. В моделировании этого явления М. Маук (Medina et al., 2000) предположил, что сигнал на мигательное движение поступает на внешний вход ЛК, КП которых обычно тормозят мигательное движение. После многих сочетаний безусловного стимула с условным, КП с некоторым опережением по отношению к стандартному времени подачи безусловного сигнала

замолкает, вызывая тем самым необходимое мигательное движение. Сигналом на выключение КП является появление на входе КП той афферентной обстановки, на фоне которой во время проведения сочетаний появлялся безусловный стимул. Непосредственно контролируемым экспериментатором параметром этой афферентной обстановки является время, прошедшее с начала подачи условного стимула. Экспериментаторы отмечают, что только сохранность мозжечка позволяет правильно воспроизводить интервал между началом условного стимула и условно-рефлекторным ответом. Интересно, что с этой точки зрения «неспособность» животного дифференцировать длительные интервалы между началом условного стимула и предъявлением безусловного стимула может быть обусловлена тем, что на больших интервалах от начала условного стимула афферентный сигнал может не нести признаков, однозначно связанных с интервалом между текущим моментом и началом условного стимула. На малых временах такая информация имеется в силу нестационарности реакции нейронов на включение любого воздействия. На больших временах постоянных временных маркеров, связанных с включением условного стимула, может не быть.

Важной проблемой мозжечковой физиологии является идентификация константы ε и функции $\chi(\tau)$ в уравнении (2). Вариации во времени могли бы приводить к тому, что мозжечковая память становится постоянной, или, наоборот, быстрее стирается. Важно понять, имеются ли естественные эндогенные факторы в мозжечке, влияющие на эту константу. Вопрос о постоянстве параметров $\chi(\tau)$ можно было бы решить путем долговременного непрерывного наблюдения за активностью ЛК. Один из первых вопросов здесь — насколько стабильна и насколько различна у разных клеток величина T_{equ} . Анализ статистических характеристик активности ЛК и их сравнение с характеристиками модельных ЛК (как, например, на рис. 7д) позволили бы лучше охарактеризовать наличие и/или характеристики стохастической динамики как фактора, определяющего параметры этой активности.

И, наконец, огромное значение для углубленного понимания механизмов мозжечка имеет регистрация пар КП, управляемых одной ЛК (см. раздел «В погоне за Близнецами»). Сравнение активности таких клеток в разных функциональных состояниях и при разных воздействиях позволит получить количественную информацию о работе «лианного» модуля в условиях естественного, выработанного до вмешательства экспериментатора, поведения. Видимо, сопоставление экспериментов данного типа с экспериментами в физике высоких энергий (элементарных частиц) может

быть оправдано. В обоих случаях ищутся события, обладающие определенными очень редко встречающимися свойствами. Анализ характеристик таких событий позволяет подтвердить или опровергнуть теоретические постулаты о свойствах системы.

Уже анализ активности небольшого числа зарегистрированных пар КП-«близнецов» дал информацию, существенную для развития теоретических представлений о работе элементов коры мозжечка. В частности, сдвиг по времени между СИ КП-близнецов дает масштаб времени, существенный для настройки параметров мозжечковых модулей. Наши данные показывают, что разница времен генерации СИ разными ветвями ЛВ может достигать 1.5 мс. В то же время величина временного сдвига стабильна: флуктуации составляют около 10%. Весьма существенно выявленное при анализе активности пар КП блокирование проведения импульса от клетки нижних олив в дистальные ветви ЛВ. Вероятность блокирования сильно зависит от интервала между СИ и других параметров текущей активности данной КП. Интересен вопрос о соотношении формы СИ КП-«близнецов». Периоды быстрых колебаний внутри СИ (см. рис. 3а) у КП с общим ЛВ — разные, что говорит в пользу независимых механизмов генерации вторичных максимумов СИ у «близнецов». Таким образом можно констатировать, что механизмы работы мозжечка практически перестали быть *terra incognita*. Вместе с тем, путь от первичного понимания грубой схемы процессов в системе до детального описания ее функционирования может быть достаточно долгим. Мы находимся, фактически, в начале этого пути.

Литература

- [Дунин-Барковский, Подладчикова, 2002]. *Дунин-Барковский В. Л., Подладчикова Л. Н.* Исследование роли лианых клеток в работе мозжечковых модулей // *Нейрокомпьютеры*, 2002, № 7–8, с. 47–64.
- [Дунин-Барковский, Ларионова, 1976]. *Дунин-Барковский В. Л., Ларионова Н. П.* Об активности нейронов мозжечка лягушки *in vitro* // *Материалы VI Всесоюзной конференции по электрофизиологии ЦНС.* – Каунас, 1976, с. 149.
- [Вышинский и др., 2003]. *Вышинский Л. Л., Гринев И. Л., Дунин-Барковский В. Л., Флеров Ю. А., Широков Н. И.* Мониторинг, анализ и прогнозирование поведения многоагентных систем на базе нейрокомпьютерной модели мозжечка. – Вычислительный центр им. А. А. Дородницына РАН, Москва, 2003, 60 с.
- [Дунин-Барковский и др., 1987]. *Дунин-Барковский В. Л., Жуковская Н. М., Ларионова Н. П., Чайлахян Л. М., Чудаков Л. И.* Увеличение эффективности синапсов

- параллельных волокон на клетках Пуркинье лягушки после одновременной активации лианнных и параллельных волокон // *Нейрофизиология*, 1987, т. 19, № 2. – с. 156–164.
- [Дунин-Барковский и др., 1997]. *Дунин-Барковский В. Л., Маркин С. Н., Подладчикова Л. Н.* Оценка вклада простых и сложных импульсов клеток Пуркинье в локальные потенциалы коры мозжечка // *Биофизика*, 1997, т. 42, с. 516–520.
- [Дунин-Барковский и др., 1999]. *Дунин-Барковский В. Л., Маркин С. Н., Подладчикова Л. Н., Вунч Д. М.* Свойства активности ветвей лязящего волокна иннервирующего различные клетки Пуркинье, *Биофизика*, 1999, т. 44, с. 1056–1063.
- [Дунин-Барковский, 1978]. *Дунин-Барковский В. Л.* Информационные процессы в нейронных структурах. – М.: Наука, 1978.
- [Подладчикова и др., 2002]. *Подладчикова Л. Н., Бондарь Г. Г., Дунин-Барковский В. Л.* Особенности активности «быстрых» и «медленных» клеток Пуркинье мозжечка. *Биофизика*, 2002, т. 47, № 2, с. 338–344.
- [Ackermann, 2008]. *Ackermann H.* Cerebellar contributions to speech production and speech perception: psycholinguistic and neurobiological perspectives. – *Trends in Neurosciences*, 2008.
- [Albus, 1971]. *Albus J. S.* A theory of cerebellar function // *Math. Biosci.*, 1971, **10**, pp. 25–61.
- [Artinian and Finch, 2003]. *Artinian L. R., Finch E. A.* Dual role of ryanodine receptor during parallel fiber – Purkinje cell synaptic transmission // Soc. Neuroscience Ann. Meeting, New Orleans, 2003, Poster Presentation No. 426.21.
- [Baker and Golub, 1991]. *Baker G. L., Golub J. P.* Chaotic dynamics. An Introduction. – Cambridge University Press, New York, 1991.
- [Bell and Kawasaki, 1972]. *Bell C. C., Kawasaki T.* Relations among climbing fiber responses of nearby Purkinje cells // *J. Neurophysiol.*, 1972, **35**, pp. 155–169.
- [Colin et al., 1980]. *Colin F., Manil J., Desclin J. C.* The olivocerebellar system. Delayed and slow inhibitory effects: An overlooked salient feature of the cerebellar climbing fibers // *Br. Research*, 1980, **187**, pp. 3–27.
- [Dunin-Barkowski et al., 1993]. *Dunin-Barkowski W. L., Khandozhko I. I., Podladchikova L. N., Markin S. N.* In search of cerebellar climbing fiber Purkinje cell twins // Proceedings of the IJCNN'93 Nagoya, 1993, Vol. 1, pp. 121–122.
- [Dunin-Barkowski et al., 1995]. *Dunin-Barkowski W., Markin S., Podladchikova L.* HEP type experiments in cerebellar research // Neural Networks for Physicists No. 5, 1995, Minneapolis: UMN, pp. 112–120.
- [Dunin-Barkowski, Markin et al., 1999]. *Dunin-Barkowski W. L., Markin S. N., Podladchikova L. N., Wunsch D. C.* Climbing fiber purkinje cell twins are found // Proceedings of IJCNN'99, Washington, DC, 1999, Vol. 1, pp. 180–183.

- [Dunin-Barkowski, Shishkin et al., 1998]. *Dunin-Barkowski W.L., Shishkin S.L., Wunsch D.C., Sukharev A.A.* Computational intelligence and cerebellar enigmas // Proceedings of IJCNN'98, Anchorage, Vol. I, 1998, pp. 640–645.
- [Dunin-Barkowski, Shishkin et al., 1999]. *Dunin-Barkowski W.L., Shishkin S.L., Wunsch D.C.* Stability Properties of Cerebellar Neural Networks: The Purkinje Cell – Climbing Fiber Dynamic Module // *Neural Processing Letters*, 1999, Vol. 9, No. 2, pp. 97–106.
- [Dunin-Barkowski and Wunsch, 1999]. *Dunin-Barkowski W.L., Wunsch D.C.* Phase-based storage of information in the cerebellum // *Neurocomputing*, 1999, Vol. 26–27, No. 1–3, pp. 677–685.
- [Dunin-Barkowski and Wunsch, 2000]. *Dunin-Barkowski W.L., Wunsch D.C.* Phase-based cerebellar learning of dynamic signals // *Neurocomputing*, 2000, Vol. 32–33, pp. 709–725.
- [Dunin-Barkowski, 2002]. *Dunin-Barkowski W.L.* Analysis of output of all Purkinje cells controlled by one climbing fiber cell // *Neurocomputing*, 2002, Vol. 44–46, pp. 391–400.
- [Ekerot and Jorntell, 2001]. *Ekerot C.F., Jorntell H.* Parallel fibre receptive fields of Purkinje cells and interneurons are climbing fibre-specific // *Eur. J. Neurosci.*, 2001, **13**, pp. 1303–1310.
- [Fredette and Mugnaini, 1991]. *Fredette B.J., Mugnaini E.* The GABAergic cerebello-olivary projection in the rat // *Anat. Embriol.*, 1991, **184**, pp. 225–243.
- [Gilbert and Thach, 1977]. *Gilbert P.F.C., Thach W.T.* Purkinje cell activity during motor learning // *Brain Research*, 1977, **128**, pp. 309–328.
- [Hawkins and Blakeslee, 2004]. *Hawkins J., Blakeslee S.* On intelligence. – Time Books, NY, 2004, 565 pp.
- [Ito, 1984]. *Ito M.* The cerebellum and neural control. – Raven Press, New York, 1984.
- [Ito, 2001]. *Ito M.* Cerebellar long-term depression: Characterization, signal transformation, and functional roles // *Physiol. Reviews*, 2001, **81**, pp. 1143–1195.
- [Ito, 2006]. *Ito M.* Cerebellar circuitry as a neuronal machine // *Prog. Neurobiol.*, 2006, Vol. 78, pp. 272–303.
- [Ito, 2008]. *Ito M.* Control of mental activities by internal models in the cerebellum // *Nature Reviews Neuroscience*, 2008, Vol. 9, pp. 304–313.
- [Ito et al., 1982]. *Ito M., Sakurai M., Tongroach P.* Climbing fiber induced depression of both mossy fiber responsiveness and glutamate sensitivity of cerebellar Purkinje cells // *J. Physiol.*, 1982, **324**, pp. 113–134.
- [Linden, 1996]. *Linden D.J.* Cerebellar long-term depression as investigated in a cell culture preparation // *Behav. and Br. Sci.*, 1996, **19**, pp. 339–346.

- [Marr, 1969]. *Marr D.* A theory of cerebellar cortex // *J. Physiol.*, 1969, **202**, pp. 437–470.
- [Mauk and Donegan, 1997]. *Mauk M., Donegan N.* A Model of pavlovian eyelid conditioning based on the synaptic organization of the cerebellum // *Learning and Memory*, 1997, **3**, pp. 130–158.
- [Medina et al., 2000]. *Medina J. F., Garcia K. S., Nores W. L., Taylor N. M., Mauk M. D.* Timing mechanism in the cerebellum: Testing predictions of a large-scale computer simulation // *J. Neurosci.*, 2000, **20**, pp. 5516–5525.
- [Noda and Suzuki, 1979]. *Noda H., Suzuki D.* The role of flocculus of the monkey in fixation and smooth pursuit eye movements // *J. Physiol.*, 1979, **294**, pp. 335–348.
- [Rosenblatt, 1962]. *Rosenblatt F.* Principles of neurodynamics: Perception and the theory of brain mechanisms. – Washington, DC, Spartan, 1962.
- [Sasaki et al., 1989]. *Sasaki K., Bower J., Llinas R.* Multiple Purkinje cells recording in rodent cerebellar cortex // *Eur. J. Neurosci.*, 1989, **1**, pp. 575–586.
- [Spoelstra et al., 2000]. *Spoelstra J., Schweighofer N., Arbib M. A.* Cerebellar learning of accurate predictive control for fast-reaching movements. *Biol. Cybern.*, 2000, **82**, 321–333.
- [Sugihara, 2006]. *Sugihara I.* Organization and remodeling of the olivocerebellar climbing fiber projection // *Cerebellum*, 2006, Vol. 5, pp. 15–22.
- [Sugihara et al., 2001]. *Sugihara I., Wu H.-S., Shinoda Y.* The entire trajectories of single olivocerebellar axons in the cerebellar cortex and their contribution to cerebellar compartmentalization // *J. Neurosci.*, 2001, **21**, pp. 7715–7723.
- [Voicu, 2008]. *Voicu H.* The cerebellum: An incomplete multilayer perceptron? // *Neurocomputing*, 2008, Vol. 72, pp. 592–599.

Виталий Львович ДУНИН-БАРКОВСКИЙ, доктор физико-математических наук, профессор, заведующий Отделом нейроинформатики Центра оптико-нейронных технологий НИИСИ РАН, директор НИИ нейрокибернетики им. А. Б. Когана (в 1990–1995 годах), Президент-основатель Российской Ассоциации нейроинформатики (1991 год), адъюнкт-профессор Техасского технологического университета (с 2006 года), автор одного из первых в мире проектов нейро-СБИС (1974 год), нескольких монографий и многих статей (с 1965 года) по нейроинформатике и теоретической и экспериментальной биофизике различных отделов нервной системы (в частности, мозжечка и ствола мозга).

Р. А. ТИКИДЖИ-ХАМБУРЬЯН
НИИ Нейрокибернетики им. А. Б. Когана,
Южный Федеральный Университет,
Ростов-на-Дону, Россия
E-mail: rth@nisms.krinc.ru

ДЕТАЛЬНОЕ МОДЕЛИРОВАНИЕ НЕЙРОНОВ И НЕЙРОННЫХ СЕТЕЙ: КАК И ЗАЧЕМ

Аннотация

Когда мы исследуем мозг, то впервые в истории человечества встречаемся с ситуацией, когда сложность объекта исследования равна сложности самого исследователя. Мы пытаемся исследовать мозг мозгом. Поэтому мы можем анализировать нервную ткань, но мы не можем синтезировать все эти данные в новые знания. Таким образом, есть только один путь: синтезировать эти данные вне мозга. Этот подход в исследовании нервной ткани, называемый «вычислительными нейронауками» — новейшее направление в нейроисследованиях.

R. A. TIKIDJI-HAMBURYAN
A. B. Kogan Research Institute for Neurocybernetics,
Southern Federal University, Rostov-on-Don, Russia
E-mail: rth@nisms.krinc.ru

DETAILED MODELING OF NEURONS AND NEURON NETWORKS: HOW TO AND WHY

Abstract

When we study the brain, for the first time in science history we have a unique situation, where the complexity of studied object equals to the complexity of researcher. We try to study brain by means of our brains. Therefore we might analyze the nerve tissue, but we can not synthesize all these data to a new knowledge, thus there is only one way: to synthesize these data out of our brain. This approach to nerve tissue research named “Computational Neuroscience” represents the newest field of Neuroscience research.

Введение

В данной лекции мы рассмотрим одну из основных частей сравнительно молодого раздела науки, называемого Computational Neuroscience (вычислительные нейронауки). Сама идея применить моделирование для обобщения экспериментальных данных и предиктивных исследований не нова. Математические и численные эксперименты находят широкое применение уже давно, однако, в области нейробиологии этот метод исследования стал широко применяться лишь с середины 80-х годов прошлого века. Наиболее ярко основную идею этого направления выразил *Берт Сакман*: «Я знаю все данные: типы клеток, свойства их активности, связность клеток, возбудимость дендритов, синаптическую динамику . . . но я не могу понять это (как целое — Р. А. Т-Х), я вынужден это моделировать». Из этой цитаты вытекает основная задача вычислительных нейронаук — аккумулировать в моделях разнородные экспериментальные данные и исследовать после этого обобщенную модель так, как если бы это был реальный биологический объект.

Первые попытки таких исследований предпринимались еще в 40-х годах прошлого века. Революционные работы *МакКаллока* и *Питтса* заложили основы нового направления: моделирования нейронных сетей. Максимальная формализация и примитивизация функции единичного нейрона сделали в конечном итоге это направление частью математики, называемой формальными нейронными сетями. К сожалению, практически все результаты, получаемые в этой области, не имеют никакого отношения к работе реальных нейронов и реального мозга.

Вторую попытку привлечь математическое моделирование для обобщения экспериментальных данных предпринял *Ролл* в середине 60-х годов. Необходимо заметить, что, несмотря на то, что именно им были заложены основы детального биологически обоснованного моделирования как единичных нейронов, так и малых и средних нейронных сетей, некоторые выводы, сделанные на основе его моделей, затормозили развитие нейробиологии практически на десятилетие, а его совместные с *Экклсом* работы сильно исказили представление о принципах работы дендритного дерева нейрона и синаптических связях в сети.

Бурное развитие моделирования, как средства аккумуляции экспериментальных данных и метода получения новых знаний о функционировании как единичных клеток, так и сети в целом, было обусловлено появлением в середине 80-х принципиально новых компьютеров с непрерывно

растущими вычислительными мощностями и появлением новых нейро-биологических методик, позволяющих проводить измерения не только на клетке в целом, но и на отдельных ее участках, частях мембраны и даже отдельных белковых молекулах, принимающих участие в электрогенезе клетки (ионных каналах). За анализом обширного экспериментального материала не следовало синтеза; другими словами, было практически невозможно понять, как изменятся характеристики активности клетки при наличии или отсутствии у нее того или иного ионного канала. Как влияют друг на друга разные ионные каналы? Как изменится динамика всей сети, если в ней появятся элементы с теми или иными ионными каналами, а значит с измененными динамическими свойствами? На эти вопросы, как и на многие другие, было призвано ответить новое направление — вычислительные нейронауки.

Моделирование нейронных сетей с учетом реальных биологических свойств отдельных элементов также является частью направления Computational Neuroscience. В отличие от формальных нейронных сетей, где единственным элементом, как правило, является мгновенный сумматор с выходной сжимающей функцией, важнейшим показателем нейронной активности является ее динамика. Поскольку динамические свойства нейронов крайне разнообразны, а сети сугубо гетерогенны, остаются открытыми вопросы: «Как динамические свойства единичного элемента влияют на активность сети в целом? Как активность сети в целом и пришедшие к нейрону сигналы, в частности, модулируют его активность?» и т. д.

Сложность моделирования динамических свойств и большая ресурсоемкость многосегментных и точечных моделей на основе уравнений Ходжкина и Хаксли (ХХ) сделали необходимым поиск феноменологических моделей нейрона, которые позволяли бы воспроизводить динамику реальной клетки как феномен, без детализации процессов, лежащих в ее основе. К настоящему моменту феноменологические модели постепенно уступают место крупным нейронным сетям с моделями единичных элементов на основе ХХ. Это связано с постоянным ростом вычислительных ресурсов и, как следствие, появившейся возможностью моделировать все тело нейрона с множественными связями и динамику различных химических компонент даже в больших моделях. Однако феноменологические модели до сих пор не потеряли своей актуальности и все еще достаточно широко применяются. С их помощью исследуются, в частности, такие вопросы, как свойства динамики сети при различной организации связей между элементами; наборы возможных состояний активности сети при включении в

нее различных элементов и т. д.

Данная лекция призвана дать читателю базовые знания в подходах и методах Computational Neuroscience, показать тесную связь между проблемами нейробиологии и методами Computational Neuroscience. Она опирается

ная, сильно разросшаяся клетка (так называемый синцитий). После того как Гольджи открыл и опубликовал в 1885 году способ фиксации и окраски нервной ткани, с помощью которого окрашивалось лишь 5–7% всех клеток, стало ясно, что мозг, как и прочие органы, состоит из отдельных клеток, которые были названы нейронами. Победа нейронной доктрины произошла в основном благодаря работам *Рамон-и-Кахаль*, который гистологически исследовал различные части мозга, окрашенные по методу Гольджи (за эти работы *Рамон-и-Кахаль* и *Гольджи* получили Нобелевскую премию). На рис. 1 приведен один из многочисленных рисунков *Рамон-и-Кахаль*. Исходя из своих наблюдений, он пришел к следующим выводам:

- нервная ткань — это большая сеть нерегулярно связанных друг с другом нервных клеток (нейронов);
- у нервной клетки есть отдельно выделенное волокно, исходящее из тела самого нейрона, которое, не ветвясь, направляется к другим клеткам (он назвал это волокно аксоном) и там заканчивается либо на теле другой клетки, либо на других, более толстых ее отростках;
- выделенное тонкое волокно всегда начинается на некотором выпячивании на теле самой клетки (*Рамон-и-Кахаль* назвал этот участок аксонным холмиком);
- другие, более толстые отростки, иногда напоминающие крону дерева, всегда находятся более близко к телу клетки (они получили название «дендриты»);
- между аксоном одной клетки и дендритом другой могут существовать контакты, названные «синапсами».

Рамон-и-Кахаль предположил, что дендриты и сома являются входами клетки, аксонный холмик — ее возбудимой зоной, а сам аксон представляет собой выход нейрона. Конечно, впоследствии было обнаружено достаточно большое количество аксо-аксональных и дендро-дендритных синапсов. Было показано, что не только аксонный холмик является возбудимым участком нейрона, но и само тело и дендриты обладают возбудимостью. Однако именно первоначальные представления *Рамон-и-Кахаль* легли в основу теории формальных нейронных сетей.

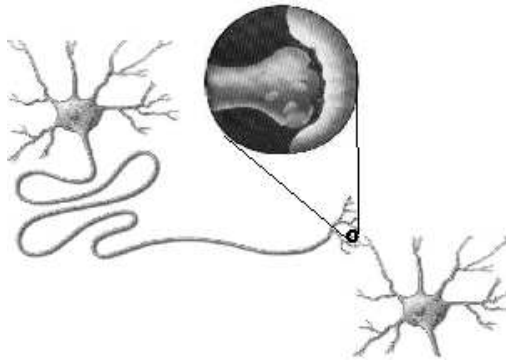


Рис. 2. Схематичное изображение двух нейронов — показан длинный аксон и короткие разветвленные дендриты. Во вставке показан химический синапс — контакт между нейронами

Химические и электрические синапсы

На рис. 2 схематично изображены два нейрона, показан длинный аксон и короткие разветвленные дендриты. Синапс, изображенный также в увеличенном виде, представляет из себя тонкую щель между двумя клетками. Отросток аксона, образующий синапс, называют предсинапсом, а участок мембраны дендрита или сомы клетки — постсинапсом. Под воздействием электрического импульса, потенциала действия (ПД) генерируемого пресинаптическим нейроном, из синапса выделяется специальное химическое вещество, называемое медиатором. Оно запасается в пресинаптической терминали аксона в виде крошечных пузырьков (везикул), которые подходят к мембране, сливаются с ней и выбрасывают свое содержимое (медиатор) в щель между клетками. Медиатор, как правило, является достаточно нейтральным веществом и напрямую не может воздействовать на постсинаптический нейрон. Для передачи воздействия на постсинапсе должны находиться специальные рецепторы со сродством именно к данному типу медиатора. Эти рецепторы свяжут выделившиеся молекулы медиатора и изменят свою конформацию (так как рецептор представляет собой белковую молекулу), перейдя в другое состояние. При этом часть из них начинает пропускать через себя те или иные ионы (т. е. рецептор либо одновременно является ионным каналом, либо имеет непосредственную связь с каналом,

приводя к очень быстрому открытию последнего); другая часть рецепторов может включиться в метаболический цикл клетки и через длинную цепочку химических реакций косвенно изменить ионную проводимость мембраны. В любом случае взаимодействие медиатора с постсинаптическим рецептором должно привести к появлению тока через постсинаптическую мембрану нейрона и, как следствие, к локальному изменению мембранного потенциала.

Это изменение можно зафиксировать экспериментально и оно является критерием отнесения данного вещества к медиаторам. Если под воздействием медиатора мембранный потенциал повышается, то медиатор называют возбуждающим, равно как и постсинаптический потенциал (возбуждающий постсинаптический потенциал, ВПСП). Если же потенциал понижается, то его называют тормозным (ТПСП). Те синапсы, в которых воздействие передается посредством медиаторного обмена, называют химическими. Рецепторы также делятся на две группы: первая сразу начинает проводить электрический ток — ионотропные рецепторы, а вторая изменяет сначала метаболизм нейрона — метаботропные рецепторы.




Рис. 3. Электрический синапс

Химическими синапсами возможности передачи сигнала в нейронной сети не исчерпываются. На рис.3 показан принципиально другой тип соединения — электрический синапс. Этот тип межклеточных контактов был впервые открыт в нервной ткани беспозвоночных и длительное время счи-

слева) показаны мембраны двух клеток, на поверхности которых образована пора из белковых молекул, называемых коннексинами. Поскольку внеклеточная часть коннексина имеет сродство к самой себе, то она связывается с внеклеточными частями коннексинов на мембране другого нейрона, образуя межклеточное соединение. Другой важной особенностью коннексина является неравномерность доменной структуры, из-за чего коннексины образуют шестигранную пору, называемую коннексоном, через которую могут проходить практически все типы ионов и даже небольшие белковые молекулы (к настоящему времени есть большое разногласие в экспериментальных данных, по одной версии коннексоны практически полностью «прозрачны» для ионов, по другой через них могут проникать лишь определенные молекулы, например IP_3 и не могут проходить крупные ионы типа Ca^{2+}). Очевидно, что в электрическом синапсе происходит, в отличие от химического синапса, двунаправленный обмен и там нельзя выделить пресинапс и постсинапс. Клетки, связанные электрическим соединением, будут взаимно влиять на потенциал друг друга (что является одним из основных различий химических и электрических контактов).

Существуют также данные о несинаптическом химическом воздействии клеток друг на друга (так называемой гуморальной передаче). Однако из-за того, что этот тип передачи крайне редко моделируется, мы его рассматривать не будем.

Гомогенность, гетерогенность, размерность и связность сети. Случайные, диффузные и фокальные проекции нейронов

Некоторые понятия, характеризующие биологически обоснованные нейронные сети, были заимствованы из теории формальных нейронных сетей. В силу важности этих характеристик мы дадим краткое их определение:

- Сеть называется **гомогенной**, когда все ее элементы одинаковы и образуют однотипные нейронные связи. Классической гомогенной сетью является однослойный перцептрон [4]. В случае, если в сети имеются элементы с различными свойствами, или если сеть нерегулярна, то она считается **гетерогенной**. К гетерогенным сетям относят сети со встречным распространением [4].
- Операции, производимые формальной нейронной сетью, можно записать в векторном виде, где размерностью вектора будет количество элементов в слое или во всей сети. И к биологически обоснованным

моделям нейронных сетей также применяют понятие **размерности**, определяющее количество единичных элементов сети. При этом, если элементы содержат отдельные сегменты, то последние не учитываются.

- Сеть называется **полносвязной**, если каждый элемент сети образует непосредственные связи со всеми другими элементами сети¹. В формальных нейронных сетях не допускаются связи элемента с самим собой и наличие более чем одной связи между элементами, поэтому количество связей в полносвязной сети составляет $P = N(N - 1)$, где P — число связей, а N — число элементов сети. Для биологически обоснованных нейронных сетей связностью называется общее количество связей между элементами, при этом множество связей между двумя единичными клетками возможно, но не учитывается. Таким образом, полносвязная сеть имеет связность $P = NN$. Связность сети не может быть больше, чем связность полносвязной сети с этим же количеством элементов. Мозг является слабосвязной сетью. По приближенным оценкам, его связность p не превышает и 3% от максимально возможной P .

Другие термины, используемые для описания моделей нейронных сетей, были заимствованы из нейробиологии. Мы также дадим краткие их определения:

- **Проекцией** нейрона называется все множество клеток, с которыми он образует синаптическое соединение в качестве предсинапса.
- **Случайная проекция** — это такая проекция, при которой нет выделенной нейроанатомической области и нет выделенного типа клеток, которым данный нейрон отдает входное воздействие.
- **Диффузная проекция** — вид случайной проекции, но пространственно ограниченной.
- **Фокальная проекция** — вид проекции, при которой обнаруживается некоторая область (фокус) с наиболее высокой концентрацией синаптических контактов от данного нейрона и небольшая периферическая область, в которой плотность контактов быстро падает.

¹В однопроходных нейронных сетях понятие полносвязности трактуется иначе. В таких сетях полносвязными сетями называются такие сети, в которых каждый элемент последующего слоя получает синапсы от всех элементов предыдущего.

- Выделяют также **специфические проекции**, к которым относят проекции, связи в которых происходят только с нейронами определенного типа.

Краткая теория электрогенеза

Хорошо известно, что в покое нейрон имеет постоянный заряд, который создает электрическое поле напряженностью порядка от $-(56 \div 72)$ мВ на мембране. Если внешним источником тока попытаться уменьшить этот заряд, то при определенных условиях потенциал нейрона самопроизвольно увеличится до $+(25 \div 45)$ мВ, а затем быстро упадет до уровня $-(62 \div 75)$ мВ. Этот автогенерационный процесс называется потенциалом действия или, в зарубежной литературе, spike. Его общая длительность 1–3 мс. Нейрон далеко не уникален в этом своем свойстве. По данным [5], значительно больший потенциал покоя и ПД наблюдается у растительных клеток. Так, споры гриба вешенки способны генерировать ПД амплитудой до 1.5 В. Однако только в нейроне ПД несет в себе информационную функцию. Рассмотрим теперь, как формируется потенциал покоя и какова его природа.

Потенциал Нернста

Билипидный слой, отделяющий цитоплазму клетки от внешней среды, является очень хорошим изолятором с напряжением пробоя порядка 30 кВ/см, поэтому за все электрические процессы на мембране нейрона (за исключением накопления заряда) отвечают большие белковые молекулы, пронизывающие мембрану клетки насквозь (т.н. ионные каналы или поры). В большинстве случаев ионные каналы избирательны к виду пропускаемого ими иона и не способны пропускать другие вещества. К тому же концентрации основных ионов в растворах, омывающих мембрану с разных сторон, существенно различаются, что и порождает появление электрического потенциала на базиллярной мембране клетки.

Рассмотрим сосуд, изображенный на рис.4 который разделен на две части непроницаемой перегородкой 'а'. Заполним две части сосуда 'b' и 'с' растворами *NaCl* с концентрациями 1.0 М/л и 0.1 М/л соответственно. Пусть имеется ион-селективная пора 'd' в мембране 'а', которая пропускает только ионы натрия 'е'. Предположим, что во время заполнения сосудов




Рис. 4. Схема появления электрического потенциала на ионоселективной поре

пора 'd' была закрыта и не пропускала через себя ионы. Другими словами, до начала рассмотрения обмена между растворами не было. Рассмотрим поведение ионов натрия в момент открытия поры 'd'. Близлежащие ионы 'e' под действием разности концентраций начнут диффундировать через пору из части 'b' в часть 'c', что показано на рис. 4 стрелками. Изменение химического потенциала, вызывающего диффузию, будет зависеть от температуры и разности концентраций:

$$\Delta\mu_{ch} = RT \ln \frac{C_b}{C_c}, \quad (1)$$

где R — универсальная газовая постоянная, T — температура, C_b и C_c — соответствующие концентрации. Однако, поскольку пора непроницаема для ионов хлора, поток положительно заряженных ионов натрия приведет к появлению разности электрического потенциала, стремящегося вернуть ионы натрия назад:

$$\Delta\mu_e = zFE, \quad (2)$$

где z — валентность иона, F — постоянная Фарадея, E — электрический

потенциал раствора. Очевидно, что, когда $\Delta\mu_e$ станет равным $\Delta\mu_{ch}$, обмены ионами натрия через пору 'd' уравниваются. Будем предполагать, что объемы обеих частей сосуда достаточно велики, а пора 'd' достаточно мала, чтобы приростом концентрации ионов натрия в части 'с' за счет обмена можно было бы пренебречь. Таким образом, возникает разность потенциала между растворами, которую можно измерить вольтметром 'f'. Значение разности потенциалов также может быть получено теоретически, приравниванием (2) к (1):

$$E = \frac{RT}{zF} \ln \frac{C_b}{C_c} . \quad (3)$$

Полученное в соотношении (3) для E называется потенциалом Нернста или реверсным потенциалом. Эта формула имеет достаточно большие ограничения. Так, если представить себе, что концентрация ионов натрия в части 'с' равна нулю, то $E \rightarrow -\infty$, и наоборот, при $C_b = 0 : E \rightarrow +\infty$. Для случая, когда нельзя пренебречь количеством ионов, проходящих через пору, необходимо использовать уравнение Гольдмана-Ходжкина-Каца, которое будет описано ниже.

Баланс токов и проводимостей

Как минимум три иона играют существенную роль в формировании потенциала покоя: натрий, калий и хлор. В табл. 1 приведены концентрации этих ионов во внешней среде и во внутриклеточных растворах.

ТАБЛИЦА 1. Значения реверсных потенциалов, внутренних и внешних концентраций

	Внутренняя кон-ция (мМоль/л)	Внешняя кон-ция (мМоль/л)	Потенциал (мВ)
Na^+	50	437	+56
K^+	397	20	-77
Cl^-	40	556	-68




Рис. 5. Токи ионов через мембрану и эквивалентная электрическая схема для их описания

Как видно из приведенных данных, условия для трех основных ионов различные. Существенные различия в концентрациях во вне- и внутриклеточных средах приводят к тому, что любая пора или любой канал, проводящий Na^+ , K^+ или Cl^- , может быть рассмотрен как источник ЭДС с соответствующим потенциалом и внутренним сопротивлением. Токи этих ионов через мембрану схематично показаны на рис. 5 (верхняя часть). Очевидно, что общий потенциал на мембране будет определяться балансом внутренних сопротивлений источников. Для простоты перейдем к проводимостям и, учитывая ток электростатического заряда билипидной мембраны, получим эквивалентную схему, показанную на рис. 5 (нижняя часть) и уравнение баланса токов:

$$c \frac{du}{dt} = -g_{Na}(u - E_{Na}) - g_K(u - E_K) - g_{Cl}(u - E_{Cl}), \quad (4)$$

где c — емкость мембраны, u — общий потенциал на ней, g — внутренние проводимости и E — ЭДС соответствующих источников, т. е. реверсные

потенциалы, полученные по соотношению (3).

Для состояния покоя очевидно, что $du/dt = 0$. Следовательно, из (4) можно получить выражение для потенциала покоя:

$$u_{rest} = \frac{g_{Na}E_{Na} + g_K E_{NK} + g_{Cl}E_{Cl}}{g_{Na} + g_K + g_{Cl} + g_L}, \quad (5)$$

где g_L — ток утечки через неселективные каналы.

Поскольку в покое потенциал нейрона составляет от -56 мВ до -72 мВ, можно предположить, что $g_L + g_{Na} < g_{Cl} + g_K$. Однако при генерации ПД мембранный потенциал может доходить в пике до $+(25 \div 45)$ мВ. Очевидно, что если никаких дополнительных источников тока нет, то $g_{Na} > g_L + g_{Cl} + g_K$. Следовательно, проводимости не постоянны, а являются динамическими переменными. Описание динамики проводимостей будет рассмотрено в разделе «Точечные модели».

Уравнение Гольдмана-Ходжкина-Каца




Рис. 6. Общая схема для вывода уравнения Гольдмана (обозначения даны в тексте)

Рассмотрим случай, когда нельзя пренебречь количеством ионов, проникающих через мембрану. Для этого рассмотрим поток ионов J через мембрану толщиной h . С внутренней и внешней стороны мембрану омывают растворы с концентрацией C_i и C_o соответственно. Пренебрегая дискретно-

стью проникновения ионов через мембрану, будем считать, что концентрация ионов внутри мембраны рядом с внутренними и внешними сторонами будет $C'_i = \gamma C_i$ и $C'_o = \gamma C_o$, где γ — коэффициент растворимости данного типа иона в мембране (рис. 6). Пусть также на мембране присутствует разность потенциалов $\varphi = \varphi_i - \varphi_o$. Тогда уравнение электродиффузии примет вид:

$$J = -C\nu \frac{d\mu}{dx}, \quad (6)$$

где C — концентрация, ν — подвижность иона, μ — электрохимический потенциал. Поскольку $\mu = \mu_{ch} + \mu_e$ и учитывая, что $\mu_{ch} = RT \ln(C)$ и $\mu_e = zF\varphi$, перепишем (6) в следующем виде:

$$J = -\nu RT \frac{dC}{dx} - C\nu zF \frac{d\varphi}{dx}. \quad (7)$$

Исходя из приближения постоянного поля $d\varphi/dx = u/h$, получим:

$$\frac{dC}{dx} + \frac{zFu}{RT} C = -\frac{J}{\nu RT}. \quad (8)$$

Разрешая уравнение (8) по C и учитывая, что $C(0) = C'_o = \gamma C_o$ и $C(h) = C'_i = \gamma C_i$, получим формулу Гольдмана:

$$J = \frac{zFPu}{RT} \frac{C_i - C_o e^{-\frac{zFu}{RT}}}{1 - e^{-\frac{zFu}{RT}}}, \quad (9)$$

где $P = \gamma\nu RT/h$ — ионная проницаемость мембраны. Учитывая, что электрический ток ионов можно выразить через их поток как $I = zFJ$, получим окончательное уравнение для тока через мембрану:

$$I = \frac{z^2 F^2 Pu}{RT} \frac{C_i - C_o e^{-\frac{zFu}{RT}}}{1 - e^{-\frac{zFu}{RT}}} = \frac{z^2 F^2 Pu}{RT} \frac{C_0 - C_i e^{\frac{zFu}{RT}}}{1 - e^{\frac{zFu}{RT}}}. \quad (10)$$

Выражение (10) называется уравнением Гольдмана-Ходжкина-Каца (ГХК). Забегая вперед, нужно отметить, что для каналов с динамической проводимостью (10) адаптируют, исходя из того, что $I = m^p h^q zFJ$, где m и h — воротные переменные (см. подраздел «Уравнения Ходжкина-Хаксли»).

Точечные модели

В данном разделе рассматриваются модели нейрона как целого. В отличие от моделей, представленных в следующем разделе, точечные модели не разделяют нейрон на сегменты, не выделяют части дендрита и сомы, не рассматривают гетерогенность плотности каналов вдоль тела клетки. Это не очень хорошо с точки зрения адекватности моделирования, однако позволяет сконцентрироваться исключительно на динамике ионных проводимостей. Основой для такого рассмотрения послужили работы *Алана Ходжкина* и *Эндрю Хаксли*, которые исследовали электрогенез на препарате гигантского аксона кальмара. Особенность данного препарата заключается в том, что это один из самых толстых нервных отростков, диаметр которого может составлять 1.2–2.0 мм. Отравляя аксон тетродотоксином, блокирующим натриевые каналы, и тетраэтиламмонием, блокирующим калиевые каналы, им удалось наблюдать отдельно токи натрия и калия. На рис. 7 показано, как ведет себя ток через мембрану (вторая кривая сверху) при скачке потенциала из состояния покоя в некоторое фиксированное значение (первая кривая сверху). Суммарный ток через мембрану показан на второй сверху кривой рис. 7, а токи натрия и калия даны, соответственно, на третьем и четвертом графике рис. 7. Рассмотрим, как можно описать поведение токов с математической точки зрения.

Уравнения Ходжкина-Хаксли

Вернемся еще раз к эквивалентной электрической схеме на рис. 5. Поскольку для ионов натрия и калия допустимо пользоваться уравнением Нернста (3), не прибегая к соотношению ГХК (10), положим ЭДС источников постоянными и равными реверсным потенциалам из табл. 1. При этом проводимости каналов должны зависеть, как минимум, от потенциала. Поскольку ток натрия, как это следует из рис. 7, при увеличении потенциала сначала увеличивается, а затем уменьшается, то логично предположить, что на проводимость натрия влияют два процесса, по-разному зависящие от потенциала. Один из них быстрый, он увеличивает проводимость при увеличении потенциала, а другой медленный и уменьшает ее с увеличением потенциала. Если предположить, что есть некоторая максимальная проводимость натриевого канала, равная $\overline{g_{Na}}$, то текущую проводимость можно выразить как:

$$g_{Na} = \overline{g_{Na}} m^3 h,$$




Рис. 7. Характер протекания тока через мембрану при скачке потенциала из состояния покоя в некоторое фиксированное значение. По оси абсцисс отложено время. Между двумя вертикальными пунктирными метками 5 мс

$$\frac{dm}{dt} = \alpha_m(u)(1 - m) - \beta_m(u)m, \quad (11)$$

$$\frac{dh}{dt} = \alpha_h(u)(1 - h) - \beta_h(u)h,$$

где m и h – активационная и инактивационная воротные переменные, $\alpha(u)$ и $\beta(u)$ – функции открытия и закрытия воротной переменной. В своей работе Ходжкин и Хаксли предположили, что третья степень у активационной переменной объясняется тем, что для прохождения через канал в направлении понижения концентрации необходимо три иона натрия, которые связываются с активными центрами поры, вызывают ее конформацию и тем самым переходят во внутриклеточный раствор. При движении в

обратном направлении достаточно всего одного иона и поэтому h имеет первую степень.

По аналогии для калиевого канала можно ввести $\overline{g_K}$. Однако поскольку калиевый канал лишь медленно открывается с повышением потенциала, у него будет присутствовать лишь активационная переменная:

$$g_K = \overline{g_K} n^4, \quad \frac{dn}{dt} = \alpha_n(u)(1 - n) - \beta_n(u)n. \quad (12)$$

Для анализа удобно преобразовать дифференциальные уравнения (11) и (12) в следующий вид:

$$\frac{dx}{dt} = -\frac{x - x_\infty(u)}{\tau_x(u)}, \quad (13)$$

где x — одна из воротных переменных m , h или n , $\tau_x(u)$ — постоянная времени переменной x при потенциале u , $x_\infty(u)$ — точка устойчивости или, в зарубежной литературе, steady state. Из свойств уравнения (13) вытекает, что переменная x , при постоянном потенциале, будет асимптотически стремиться к x_∞ со скоростью τ_x . Очевидно, что:

$$\tau_x(u) = \frac{1}{\alpha_x(u) + \beta_x(u)}, \quad x_\infty(u) = \frac{\alpha_x(u)}{\alpha_x(u) + \beta_x(u)}. \quad (14)$$

Таким образом, общая система уравнений Ходжкина-Хаксли включает в себя уравнения для ионных проводимостей и уравнение для мембранного потенциала:

$$c \frac{du}{dt} = -g_{Na}(u - E_{Na}) - g_K(u - E_K) - g_L(u - E_L), \quad (15)$$

где c — емкость мембраны.

Первые функции для $\alpha(u)$ и $\beta(u)$ каналов были подобраны Ходжкиным и Хаксли, исходя из экспериментальных данных. Они приведены в табл. 2.

После преобразования (14) получим функции устойчивого состояния и постоянной времени от потенциала. Их поведение отражено на рис. 8. Построенные таким образом функции очень удобны для визуального анализа. Начнем с натриевых воротных переменных. Из рис. 8 видно, что постоянная времени для активационной переменной меньше любой другой постоянной времени. Поскольку m и h входят в уравнение (11) как произведение, то диапазон напряжений, когда проводимость натрия не будет стремиться к

ТАБЛИЦА 2. Функции для $\alpha(u)$ и $\beta(u)$ калиевого и натриевого каналов (Цит. по [9])

	$\alpha(u)$	$\beta(u)$
n	$\frac{0.01(u + 55)}{1 - \exp(-0.1(u + 55.0))}$	$0.125 \exp(-0.0125 * (u + 65))$
m	$\frac{0.1(u + 40)}{1 - \exp(-0.1(u + 40))}$	$4 \exp(-0.0556(u + 65))$
n	$0.07 \exp(-0.05(u + 65.0))$	$\frac{1}{\exp(3 - 0.1u) + 1}$




Рис. 8. Функции устойчивого состояния и постоянной времени от потенциала для воротных переменных n , m и h (цит. по [9])

нулю, можно определить по площади под объединением двух этих кривых. Данный диапазон называется в зарубежной литературе window current и составляет для натрия от -70 до -38 мВ. Однако это вовсе не означает что, за пределами этого диапазона ток **всегда** будет равен нулю! Поскольку к -40 мВ уже существенно падает скорость активационной переменной, то для достижения устойчивого ее состояния требуется большее время, чем при потенциале, равном -70 мВ. С другой стороны, инактивационная переменная становится на этом участке значительно быстрее и стремится закрыть ток натрия со скоростью, превышающей медленно открывающийся ток калия.

Поведение базовой системы уравнений Ходжкина-Хаксли достаточно

примитивно. Бифуркационная диаграмма ее активности показана на рис. 9.

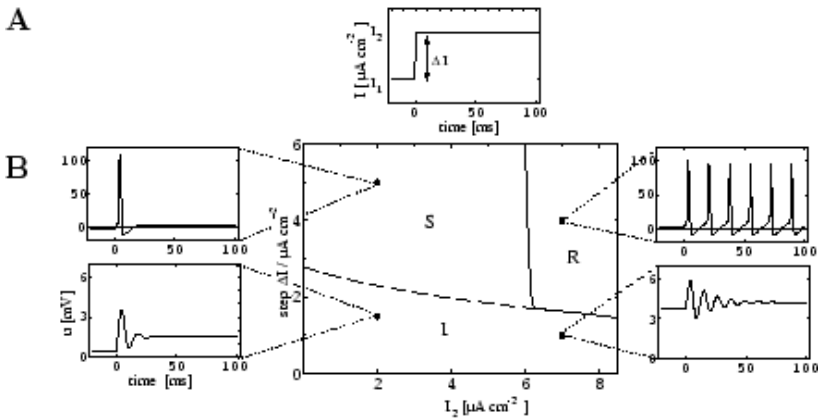


Рис. 9. Бифуркационная диаграмма активности для базовой системы уравнений Ходжкина-Хаксли (цит. по [13])

Видно, что существуют всего три вида активности — периодическая, единичная и безимпульсная. Данная модель не может объяснить и имитировать многие феномены реальной активности нейронов, такие как адаптация (как к повышению потенциала, так и к его понижению), катодическая депрессия, постанодальная экзальтация и другие. Эти эффекты объясняются существованием большого количества различных ионных каналов, рассмотрение которых будет сделано в следующем разделе.

Различные ионные каналы

Нервная система беспозвоночных, к которым относится кальмар, является ранним образованием в эволюции живого. За время эволюции от беспозвоночных к млекопитающим функционирование нервной системы в общем и нейронов в частности сильно изменилось. Одним из приобретений в ходе эволюции по мнению [15] было значительное увеличение видов и типов ионных каналов на поверхности мембраны. К настоящему моменту их насчитывается несколько десятков тысяч. Однако источником столь большого разнообразия являются изменения однотипных каналов от вида к виду. По сути, для нервной ткани разнообразие типов невелико. Ниже

мы рассматриваем ионные каналы, классифицируя их по иону, к которому данный канал имеет родство. Существует и другой тип разделения, по характерным свойствам данных каналов. В табл. 3 дано такое деление. Читатель может без труда по представленному ниже материалу распределить каналы по соответствующей таксонометрии.

ТАБЛИЦА 3. Разделение ионных каналов по их характерным свойствам

	<i>Na</i>	<i>NaP</i>	<i>CaP</i>	<i>CaT</i>	<i>K</i>	<i>KA</i>	<i>KCa</i>	<i>H</i>
Быстрые	X	X				X		
Медленные				X	X			X
Не инактивируемые		X			X			
Низкопороговые		X		X				
Высокопороговые	X		X					
Активир. гиперполяризацией								X
Ион-зависимые							X	

Натриевые каналы. Кроме уже рассмотренного выше быстрого натриевого канала, обозначенного в табл. 3 как *Na*, рассмотрим неинактивируемый натриевый канал. Поскольку у данного канала отсутствует инактивация, он называется в зарубежной литературе *persistent* и обозначается как *NaP*. Рассмотрим одну из его модификаций, данную по [10].

$$g_{NaP} = m^3 g_{NaP}, \quad \frac{dm}{dt} = \alpha_m(u)(1 - m) - \beta_m(u)m,$$

$$\alpha_m(u) = \frac{200}{1 + \exp\left(-\frac{u - 18}{16}\right)} \quad (16)$$

$$\beta_m(u) = \frac{25}{1 + \exp\left(\frac{u + 58}{8}\right)}$$




Рис. 10. Функции устойчивого состояния и постоянной времени для NaP канала (пунктирная линия) от мембранного потенциала (цит. по [10])

Поведение функции устойчивого состояния и постоянной времени от мембранного потенциала приведено на рис. 10 пунктирной линией. Как видно из графика, порог открывания для неинактивируемого натриевого канала лежит ниже, чем для классического натриевого канала, изображенного на этом же рисунке сплошной линией. Это означает, что наличие этого канала делает клетку более возбудимой и позволяет запускать ПД при потенциале около -65 мВ, причем небольшой проводимости NaP вполне достаточно, чтобы вывести потенциал мембраны на уровень -52 мВ, когда начавшуюся волну поддержит быстрый натриевый канал.

Кальциевые каналы. Уравнение ГХК (10), как правило, применяют для случая кальциевой динамики. Это связано с тем, что внутриклеточная концентрация кальция крайне мала и нельзя пренебречь количеством ионов, переносимых через канал, как это делается при выводе уравнения Нернста. Однако в работе [10] уравнение ГХК заменили на два независимых процесса: расчет тока кальция через мембрану и расчет внутренней концентрации кальция с коррекцией потенциала Нернста.

Выделяют три вида кальциевых каналов: CaP , CaL , CaT . Первые два канала высокопороговые и различаются лишь скоростью инактивации. CaL — это медленно инактивируемый канал. Его иногда моделируют неинактивируемым каналом. CaT — низкопороговый медленный кальциевый канал. В данной лекции мы проанализируем два кальциевых канала (CaP и CaT), описанных в [10].

$$g_{CaP} = mn\overline{g_{CaP}},$$


$$\alpha_m(u) = \frac{8.5}{1 + \exp\left(-\frac{u-8}{12.5}\right)}, \quad \beta_m(u) = \frac{35.0}{1 + \exp\left(\frac{u+74}{14.5}\right)}, \quad (17)$$

$$\alpha_n(u) = \frac{0.0015}{1 + \exp\left(\frac{u-28}{8}\right)}, \quad \beta_n(u) = \frac{0.0055}{1 + \exp\left(-\frac{u+23}{8}\right)},$$

$$g_{CaT} = m\bar{n}\overline{g_{CaT}},$$

$$\alpha_m(u) = \frac{2.60}{1 + \exp\left(-\frac{u+21}{8}\right)}, \quad \beta_m(u) = \frac{0.18}{1 + \exp\left(\frac{u+40}{4}\right)}, \quad (18)$$

$$\alpha_n(u) = \frac{0.0025}{1 + \exp\left(\frac{u+40}{80}\right)}, \quad \beta_n(u) = \frac{0.19}{1 + \exp\left(-\frac{u+50}{10}\right)}.$$



С P Ca²⁺ current




Рис. 11. Графики устойчивого состояния и постоянной времени для активационной m и инактивационной h воротных переменных каналов CaT — верхний и CaP — нижний график, соответственно (цит. по [10])

На рис. 11 приведены графики устойчивого состояния и постоянной времени для активационной и инактивационной воротных переменных CaT — верхний график и CaP — нижний график. Из них можно видеть, что CaT имеет значительно более низкий порог, чем CaP . Однако при этом CaT значительно медленнее активируется, что требует длительного удержания мембранного потенциала вблизи -60 мВ. Если сопоставлять CaT и NaP , то, несмотря на то, что пороги у этих каналов близки, их поведение будет принципиально отличаться. Так, CaT может приводить к образованию низкоамплитудных ПД, поскольку обладает инактивацией и самопроизвольно закрывается, в то время как нарастание NaP проводимости ограничивается лишь внешними источниками (такими как быстрыми калиевыми каналами) и не может приводить к появлению низкоамплитудных ПД. С другой стороны, CaT канал не может вызывать длительные плато потенциала или пачечную активность, в то время как экспериментально показано, что при блокаде NaP плато потенциала в активности нейрона не наблюдаются.

Калиевые каналы. Кроме рассмотренного выше медленного калиевого канала, в данном подразделе мы рассмотрим также А-тип калиевого канала и один из вариантов кальций-зависимого калиевого канала.

А-тип калиевого канала приводится по описанию [10]. Это хороший пример, показывающий принципы анализа поведения канала, поскольку в его названии нет определения его специфики.

$$g_{KA} = m^4 h \bar{g}_{KA},$$

$$\alpha_m(u) = \frac{1.4}{1 + \exp\left(-\frac{u+27}{12}\right)}, \quad \beta_m(u) = \frac{0.49}{1 + \exp\left(\frac{u+30}{4}\right)}, \quad (19)$$

$$\alpha_h(u) = \frac{0.0175}{1 + \exp\left(\frac{u+50}{8}\right)}, \quad \beta_h(u) = \frac{1.3}{1 + \exp\left(-\frac{u+13}{10}\right)}.$$

Если сопоставить рис. 12, на котором изображены зависимости m_∞ , h_∞ , τ_m и τ_h , с рис. 8, то становятся хорошо видны различия между А-типом и медленным К каналом. С одной стороны, А-тип имеет значительно более быструю активацию, чем К канал, и окно тока у А-типа лежит в начальном участке активации К канала. С другой стороны, постоянная времени активации у А-типа значительно меньше, а инактивации в окне тока значительно больше постоянной времени К канала. Из этого следует,




Рис. 12. Зависимости величин m_∞ , h_∞ , τ_m и τ_h калиевого канала А-типа (K_A) от потенциала (цит. по [10])

что А-тип откроется и будет поддерживать ток калия значительно раньше, чем откроется медленный K канал. При достижении мембранным потенциалом порога генерации он быстро закроется. Его основное влияние будет на подпороговые процессы и начальные/конечные стадии ПД.

Другим важным видом калиевых каналов является кальций-зависимый калиевый канал. Это один из ярких примеров хемо-чувствительных каналов. Рассмотрим один из самых простых случаев, приведенных в [8]:

$$g_{KCa} = \frac{g_{KA}}{Ca_i^{2+} + K_D} Ca_i^{2+}, \quad (20)$$

где Ca_i^{2+} — внутриклеточная концентрация кальция, K_D — постоянная, определяющая насыщение канала. Выражение (20) является классическим уравнением Михаэлиса-Ментона вида $f(x) = x/(x + b)$. Его поведение при условии $b = 1$ показано на рис. 13. Понятно, что b , как и K_D , определяет точку полувысоты, помеченную на графике как 'o'. Надо отметить, что такое представление работы кальций-зависимого калиевого канала сильно упрощено, поскольку эти каналы, как правило, еще и потенциал-зависимые. В [10] показан хороший пример для $KK2$ и KBK каналов, где хемочувствительность вводится как дополнительная воротная переменная. Из-за громоздкости выражений и сложности анализа мы не будем рассматривать этот случай.

Рассмотрим, какие свойства приобретает динамика нейрона при появлении в рассмотрении кальций-зависимого калиевого канала. Очевидно, что если у нейрона не было бы кальциевого обмена, то кальций-зависимый калиевый канал никак бы не повлиял на активность нейрона. Следовательно,




Рис. 13. Характер поведения классической функции Михаэлиса-Ментона вида $f(x) = x/(x + b)$

при агрегации его в модель необходимо, чтобы в модели обязательно присутствовали кальциевые каналы и также моделировалась динамика внутриклеточного кальция. Поскольку внутриклеточная концентрация кальция крайне мала, проводимость кальций-зависимого калиевого канала не будет оказывать существенного влияния на активность нейрона до тех пор, пока кальциевые каналы не поднимут до высокого уровня внутриклеточную концентрацию кальция. Последнее может произойти либо при длительной импульсной активности, либо во время появления у нейрона высокочастотной пачечной активности, либо при длительном пребывании мембранного потенциала нейрона в окне тока CaT канала. Открывшийся таким образом KCa канал будет шунтировать открытые кальциевые и/или натриевые каналы, понижая потенциал клетки и стабилизируя активность. Таким образом, агрегация KCa в модель нейрона позволяет моделировать процессы адаптации, повышение порога срабатывания при длительной подпороговой деполяризации и ограничивать автогенераторные процессы, связанные с высокочастотной импульсной активностью.

Неспецифические ионные каналы. Существует достаточно большой класс ионных каналов, которые могут пропускать несколько типов ионов.

К нему относится так называемый гиперполяризационный или H -канал, который способен пропускать не только K^+ , но и Na^+ . Поскольку проницаемость данного канала для ионов K^+ выше, чем для ионов Na^+ , в некоторых работах (например, [10]), его отнесли к калиевым каналам с аномальным реверсным потенциалом, равным -30 мВ. По данным [15], реверсный потенциал H -канала может лежать в диапазоне от -65 мВ до -20 мВ, в зависимости от проницаемости канала для различных ионов. Рассмотрим H -канал так, как он впервые был описан в [20], с коррекцией из [21]:

$$g_h = m\bar{g}_h \quad \frac{dm}{dt} = -\frac{1}{\tau}(m - m_\infty),$$

$$m_\infty(u) = \frac{1}{1 + \exp\left(\frac{u+75}{5.5}\right)}, \quad (21)$$

$$\tau(u) = \frac{1}{\exp(-14.5 - 0.0086u) + \exp(-1.87 + 0.0701u)}.$$




Рис. 14. Зависимости величин m_∞ и τ для неспецифического H -канала от мембранного потенциала (цит. по [21])

Кривые для m_∞ и τ даны на рис. 14. Как видно из этих графиков, порог закрытия H -канала лежит в области ниже -70 мВ, и прямо на генерацию ПД он влияния не оказывает. Однако, другая важная особенность данного канала — это его феноменальная постоянная времени, которая может существенно влиять на пролонгированную импульсную активность и на длительную гипервозбудимость нейрона. Это один из самых медленных каналов. Рассмотрим, какие свойства приобретет модель, если в нее агрегировать H -канал.

Очевидно, что на быстрые процессы деполяризации и генерации непосредственно ПД он оказывать влияния не будет. Однако если несколько гиперполяризовать нейрон и удерживать потенциал на уровне -80 мВ в течении достаточного для активации H -канала времени (порядка $100-200$ мс !!!), то у клетки появится устойчивый деполяризующий ток, способный, после снятия внешней гиперполяризации, даже вызвать пачечную активность. Таким образом, агрегация в модель H -канала создает эффект понижения порога ПД после длительной гиперполяризации, называемый постанодальной экзальтацией.

Многосегментные модели

Пространственная геометрия нервных клеток сложна и многообразна. Поэтому моделирование нейронов с помощью точечных моделей является достаточно большим упрощением. Поскольку аксиальное сопротивление по цитоплазме нейрона достаточно велико и сопоставимо с общим трансмембранным сопротивлением, нельзя объединять всю мембрану всего нейрона в единое целое. Совершенно очевидно, что мембранный потенциал в разных частях нейрона может различаться. Кроме того, разные части нейрона могут содержать (и чаще всего содержат) различные наборы ионных каналов. Моделирование сложного дендритного дерева требует принципиально иного подхода, который и будет рассмотрен в этом разделе.

Моделирование отростков нейрона. Кабельное уравнение

Рассмотрим отросток нейрона, схематично изображенного на рис. 15 в верхней части рисунка. Легко заметить, что его можно сегментировать на участки с приблизительно одинаковым диаметром и аксиальным сопротивлением. После сегментации такой отросток можно заменить на эквивалентные цилиндры, как это показано в нижней части рисунка. Если цилиндр имеет слишком большую длину, то на его протяжении мембранный потенциал может изменяться. Таким образом, каждый из цилиндров следовало бы также разбить на сегменты, изменением потенциала вдоль которых можно было бы пренебречь. Например, в пакете *Neuron* разбиение идет не на цилиндры, а на согласующиеся по диаметрам усеченные конусы. Рассмотрим несколько близко расположенных цилиндров, обладающих пока только пассивной мембраной (т.е. не имеющих активных ионных каналов и огра-

нических лишь сопротивлением и емкостью), изображенных на рис.16. Пусть при этом каждый из сегментов имеет одинаковую длину dx , емкость C , аксиальное сопротивление R_L и трансмембранное сопротивление R_T . Пусть также имеется распределенный по пространству и времени входной ток $I_{ext}(t, x)$.

Рассмотрим ток через аксиальное сопротивление R_L . Согласно закону Ома:

$$R_L i(x + dx) = u(t, x + dx) - u(t, x) \quad (22)$$




Рис. 15. Схематическое изображение отрезка нейрона (сверху) и пример его сегментации на цилиндры (снизу)

Согласно первому закону Киргофа:

$$i(x + dx) - i(x) = C \frac{\partial}{\partial t} u(t, x) + \frac{1}{R_T} u(t, x) - I_{ext}(t, x). \quad (23)$$

Совершим предельный переход к погонным емкостям, аксиальным и трансмембранным сопротивлениям: $C = cdx$, $R_L = r_L dx$, $R_T^{-1} = r_T^{-1} dx$. Будем считать распределенным и входной ток $I_{ext}(t, x) = i_{ext}(t, x) dx$. Получим из (22) и (23):

$$\frac{\partial}{\partial x} u(t, x) = r_L i(t, x), \quad (24)$$

$$\frac{\partial}{\partial x} i(t, x) = c \frac{\partial}{\partial t} u(t, x) + \frac{1}{r_T} u(t, x) - i_{ext}(t, x). \quad (25)$$

Подставляя $i(t, x)$ из (24) в (25), получим:

$$\frac{\partial^2}{\partial x^2} u(t, x) = cr_L \frac{\partial}{\partial t} u(t, x) + \frac{r_L}{r_T} u(t, x) - r_L i_{ext}(t, x). \quad (26)$$




Рис. 16. Электрическая схема близко расположенных сегментов, обладающих только пассивной мембраной (цит. по [13])

Заменяя $r_L/r_T = \lambda^2$ и $cr_L = \tau$ и переходя к безразмерным переменным в долях λ и τ , мы получим кабельное уравнение:

$$\frac{\partial}{\partial t} u(t, x) = \frac{\partial^2}{\partial x^2} x^2 u(t, x) - u(t, x) + i_{ext}(t, x). \quad (27)$$

Для получения более интуитивно понятных результатов рассмотрим стационарный случай, при котором $\partial u(t, x)/\partial t = 0$, и положим $i_{ext}(t, 0) = 1$ и $i_{ext}(t, x \neq 0) = 0$. Тогда решением уравнения (27) будет:

$$u(x) = \frac{1}{2} e^{-|x|}. \quad (28)$$

Из приведенного на рис. 17 графика функции (28) видно, что потенциал на расстоянии λ от источника тока убывает в e раз. Аналогичное значение имеет и τ (только в отношении оси времени).

Дендритные деревья и активная мембрана

Из вышесказанного очевидно, что действие любого синапса на дендритном дереве нейрона, находящегося дальше 2λ от сомы, совершенно безразлично для нейрона. Это приводит к парадоксу, который был впервые поставлен в работе Ролла и Экклса в 1963 году: зачем нужны нейрону дендриты, если в среднем 2λ составляет расстояние в 1.5–2 диаметра сомы и не превышает 20–30 мкм? Поскольку прямого ответа на этот вопрос в течение




Рис. 17. Зависимость потенциала от расстоянии λ до источника тока (цит. по [13])

практически целого десятилетия получить не удавалось, в нейробиологии бытовало мнение, что дендритные деревья не выполняют информационной функции, а являются инструментом тонкой настройки нейрона. Эти заблуждения были сняты после изобретения Неером и Сакманом метода патч-кламп, позволяющего регистрировать токи в разных частях клетки с точностью вплоть до отдельных каналов. Как и следовало ожидать, мембрана дендритного дерева также является активной и содержит различные активные ионные каналы. Причем распределение этих каналов не гомогенно, и различные участки дендритного дерева содержат те или иные ионные каналы с различной плотностью. Очевидно, что при наличии ионных каналов уравнение (27) примет вид:

$$i(x + dx) - i(x) = C \frac{\partial}{\partial t} u(t, x) + \underset{i}{[g_i(t, x, u)(u(t, x) - E_i)]} - I_{ext}(t, x), \quad (29)$$

где $g_i(t, x, u)$ и E_i — проводимость и реверсный потенциал i -го агрегированного в модель ионного канала. По аналогии с переходом от (23) к (26) получим:

$$\frac{\partial^2}{\partial x^2} u(t, x) = cr_L \frac{\partial}{\partial t} u(t, x) + r_L \underset{i}{[g_i(t, u)(u(t, x) - E_i)]} - r_L i_{ext}(t, x), \quad (30)$$

где $g_i(t, u)$ — погонная плотность проводимости i -го ионного канала.

Очевидно, что уравнение (30) достаточно сложно, чтобы искать его

аналитическое решение. К тому же при изменении количества каналов или их типов уравнение (30) будет меняться. Поэтому данную систему, как правило, решают численно (так как в $g_i(t, u)$ описываются отдельными дифференциальными уравнениями). Для этого необходимо дискретизировать модель как по пространству, так и по времени. Следовательно, сегментирование дендритного дерева есть ничто иное, как дискретизация пространственной координаты модели, а пассивная электрическая схема, изображенная на рис. 16, преобразуется в рис. 18. Исходя из соображений точности, становится очевидным и условие пространственного сегментирования нейрона:

$$\Delta x \ll \lambda. \tag{31}$$




Рис. 18. Пространственная сегментация дендритного дерева нейрона и ее преобразование в эквивалентную электрическую схему (цит. по [9])

По поводу численного решения уравнения (30) необходимо сделать ряд замечаний:

1. При решении уравнения для точечного описания можно пользоваться явными методами решения дифференциальных уравнений, такими

как методы Рунге-Кутты или метод Эйлера с экспоненциальной аппроксимацией (описан в [9]). В случае многосегментных моделей использовать явные методы не рекомендуется, поскольку это сильно влияет на точность и устойчивость решения. Единственным исключением является случай двухсегментной модели, в котором уравнение (30) допустимо решать при помощи так называемого метода прямых.

2. Выбор Δx и Δt необходимо делать не только исходя из условия (31). Следует учитывать также устойчивость метода и накопление ошибки. Надо заметить, что во всех руководствах по численному решению уравнения (30) настоятельно рекомендуется использовать две временные сетки для решения $u(t, x)$ и для решения $g_i(t, u)$. Сетки имеют одинаковый шаг, но сдвинуты друг относительно друга на $\Delta t/2$.
3. По мнению автора, при многосегментном моделировании нельзя выделять отдельные зоны на дендритном дереве с разными плотностями и/или разными наборами каналов. Переходы должны быть максимально плавными. В противном случае в сегментах на границе зон могут наблюдаться крайне неустойчивые решения.

Геометрия дендритного дерева нейрона и типы активности

В этом подразделе мы будем детально рассматривать влияние геометрии нейрона на его активность и сделаем короткое введение в типы активностей нейронов. В качестве базовой будут использованы модели клеток с различной геометрией, опубликованные *Майеном* и *Сейновски* в 1996 году в журнале *Nature* [19]. Все модели из этой работы содержали пять каналов, приведенных в табл. 4. Плотности максимальных проводимостей для дендритных сегментов, сомы и аксона одинаковы для всех моделей и даны в табл. 5.

Рассмотрим приведенные в [19] четыре типа нейронов (см. рис. 19). Это звездчатая безшиповая клетка третьего слоя коры (а), звездчатая шипиковая клетка четвертого слоя (b), малая пирамидная клетка третьего слоя (с) и большая пирамидная клетка пятого слоя (d).

Из рис. 19 видно, что, несмотря на одинаковую плотность каналов, активность моделей принципиально различна. Так, звездчатая, лишенная шипиков, клетка (а) способна выдавать высокочастотную активность без признаков адаптации или уменьшения частоты. Такие клетки по терми-

ТАБЛИЦА 4. Описание пяти ионных каналов и динамики кальция, используемых в модели (цит. по [19])

		$E_L = -70, E_{Na} = +50, E_K = -90, E_{Ca} = +140 \text{ mV}$
Na^+ :	m^3h	$\alpha_m = 0.182(u + 30)/[1 - \exp(-(u + 30)/9)]$ $\beta_m = -0.124(u + 30)/[1 - \exp((u + 30)/9)]$ $h_\infty = 1/[1 + \exp(v + 60)/6.2]$ $\alpha_h = 0.024(u + 45)/[1 - \exp(-(u + 45)/5)]$ $\beta_h = -0.0091(u + 70)/[1 - \exp((u + 70)/5)]$
Ca^{2+} :	m^2h	$\alpha_m = 0.055(u + 27)/[1 - \exp(-(u + 27)/3.8)]$ $\beta_m = 0.94 \exp(-(u + 75)/17)$ $\alpha_h = 0.000457 \exp(-(u + 13)/50)$ $\beta_h = 0.0065/[1 + \exp(-(u + 15)/28)]$
K_V^+ :	m	$\alpha_m = 0.02(u - 25)/[1 - \exp(-(u - 25)/9)]$ $\beta_m = -0.002(u - 25)/[1 - \exp((u - 25)/9)]$
K_M^+ :	m	$\alpha_m = 0.001(u + 30)/[1 - \exp(-(u + 30)/9)]$ $\beta_m = 0.001(u + 30)/[1 - \exp((u + 30)/9)]$
K_{Ca}^+ :	m	$\alpha_m = 0.01[Ca^{2+}]_i, \tau_m = 0.02, [Ca^{2+}]_i \text{ (mM)}$
$[Ca^{2+}]_i$:		$d[Ca^{2+}]_i/dt = -\alpha I_{Ca} - ([Ca^{2+}]_i - [Ca^{2+}]_\infty)/\tau$ $\alpha = 10^5/2F, [Ca^{2+}]_\infty = 0.1 \mu M, \tau = 200 \text{ ms}$
R_{axial} :		$150 \Omega/cm(6.66 \text{ mS/cm})$

нологии [6] и [22] называют fast spiking cell и обозначают FS. Другой тип активности проявляет модель звездчатой шипиковой клетки (b). После короткой фазы адаптации она генерирует регулярные ПД с постоянной частотой. Этот тип активности называют regular spiking (RS). У моделей пирамидных клеток (по данным [6], некоторые пирамидные клетки с пограничной морфологией относятся к RS типу) наблюдается принципиально иной тип активности. У модели малой пирамидной клетки (c) это регулярные, короткие высокочастотные пачки. В реальности адаптация у таких нейронов принимает вид уменьшения количества ПД в пачке с течением времени. Надо заметить, что иногда адаптация может приводить к тому,

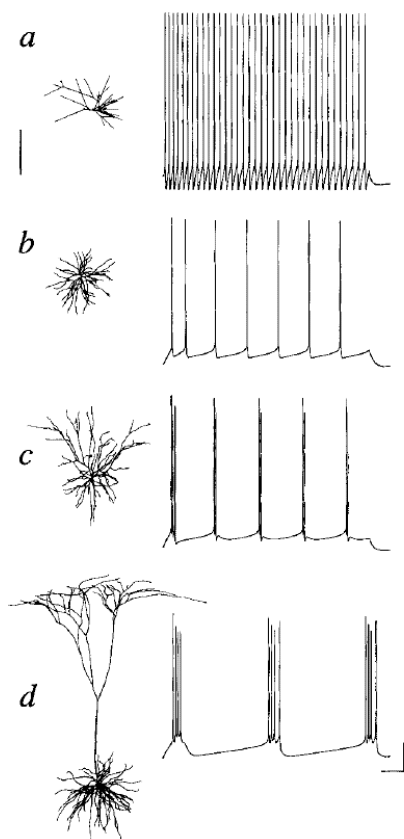


Рис. 19. Четыре типа нейронов: **(а)** звездчатая безшиповая клетка третьего слоя коры; **(б)** звездчатая шипиковая клетка четвертого слоя; **(с)** малая пирамидная клетка третьего слоя; **(д)** большая пирамидная клетка пятого слоя (цит. по [19])

что пачечный режим будет наблюдаться только у первой группы ПД и редуцироваться во всех последующих группах до единичного импульса. Такой тип клеток в зарубежной литературе называют burst cell (BC). Еще недавно к группе BC относили и активность больших пирамидных клеток. Имитация этой активности моделью показана на вкладке (d). Однако сей-

Таблица 5. Плотности максимальных проводимостей для дендритных сегментов, сомы и аксона (цит. по [19])

Аxon	\bar{g}_i	Soma	\bar{g}_i	Dendrite	\bar{g}_i
Na^+	$30000(pS/\mu m^2)$	Na^+	$20(pS/\mu m^2)$	Na^+	$20(pS/\mu m^2)$
		Ca^{2+}	$0.3(pS/\mu m^2)$	Ca^{2+}	$0.3(pS/\mu m^2)$
		K_{Ca}^+	$3(pS/\mu m^2)$	K_{Ca}^+	$3(pS/\mu m^2)$
		K_M^+	$0.1(pS/\mu m^2)$	K_M^+	$0.1(pS/\mu m^2)$
K_V^+	$2000(pS/\mu m^2)$	K_V^+	$200(pS/\mu m^2)$	L	$0.03(mS/cm2)$
		L	$0.03(mS/cm2)$		

час данную активность выделяют в отдельный класс. Он характеризуется слабой адаптацией и наличием регулярно идущих пачек с большим, чем у ВС, количеством ПД в пачке. Второй существенной особенностью этого типа является наличие значительно большей, чем у ВС, следовой гиперполяризации. Клетки с таким типом активности называют chattering cell (ChC). В русскоязычной литературе для описания активности ВС и ChC клеток применяют общий термин «пачечная активность».

Феноменологические модели нейронов, используемые при построении нейронных сетей

С середины 80-х годов прошлого века и по середину первого десятилетия этого у исследователей, моделирующих большеразмерные сети, существовала проблема: необходимо было выбрать оптимальное приближение, масштаб для моделирования. Исследователи искали разумный компромисс между большей детализацией единичного элемента и описания его динамики и размерностью сети. Ограниченность вычислительного ресурса породила множество упрощенных моделей, позволяющих с одной стороны удовлетворительно моделировать динамику единичных элементов, а с другой эффективно использовать вычислительный ресурс. Поскольку эти модели воспроизводили динамику мембранного потенциала как феномен, без детализации механизмов, приводящих к этой динамике, их стали называть феноменологическими.

Модель интегрирующего нейрона

Эта модель нейрона появилась задолго до работ Ходжкина и Хаксли, в те времена, когда предполагалось, что в максимуме ПД потенциал мембраны равен нулю. Это породило предположение, что ПД есть ничто иное, как электрический пробой мембраны, который наступает при достижении потенциалом определенного значения. Впоследствии Роллом была предложена эта же модель в качестве предельного упрощения модели Ходжкина-Хаксли (ХХ). В зарубежной литературе она получила название “integrate-and-fire”, в отечественной ее называют интегрирующим или импульсным нейроном (ИН). Поведение этой модели описывается простой системой уравнений:

$$\begin{cases} u = 0, t' = t & \text{если } u \geq \vartheta \\ c \frac{du}{dt} = I_{syn} - \frac{u}{r} & \text{в других случаях} \end{cases} \quad (32)$$

где u — мембранный потенциал, c — емкость мембраны, r — сопротивление утечки мембраны, I_{syn} — входной синаптический ток, ϑ — порог срабатывания. ПД в ИН не моделируется, а лишь фиксируется как факт. Считается, что ПД произошел, когда выполнилось верхнее условие системы (32). Данная модель действительно крайне примитивна, однако она хорошо воспроизводит свойство RS и FS клеток, демонстрирующих логарифмическое нарастание частоты импульсов при увеличении постоянного тока I_{syn} , инжектируемого в модель. На рис. 20 показан график поведения мембранного потенциала ИН от времени при $I_{syn} = \text{const}$ (левый рисунок) и диаграмма «ток-частота» (так называемая диаграмма $I-f$; правый рисунок, сплошная линия).

Поскольку $I-f$ кривая у данной модели нарастает неограниченно, а у реального нейрона она насыщается, то в данную модель вводят так называемый абсолютный рефрактерный период. По аналогии с реальной клеткой, ИН не способен «генерировать» ПД в течение определенного периода времени после предыдущего ПД. Для этого система (32) переписывается следующим образом:

$$\begin{cases} u = 0, t' = t & \text{если } u \geq \vartheta \\ u = 0 & t < (t' + t_{ref}) \\ c \frac{du}{dt} = I_{syn} - \frac{u}{r} & \text{в других случаях} \end{cases} \quad (33)$$




Рис. 20. График поведения мембранного потенциала ИН от времени при $I_{syn} = \text{const}$ (слева) и диаграмма «ток-частота» (справа) (цит. по [13])

где t_{ref} — период абсолютной рефрактерности, t' — время последнего срабатывания ИН. I - f кривая для варианта (33) дана на рис. 20 пунктиром. Несмотря на свою простоту, данная модель имеет собственные динамические и частотные свойства, однако их, как правило, не рассматривают. С другой стороны, ИН крайне удобен для аналитического рассмотрения в силу своей простоты и, кроме того, позволяет сильно экономить вычислительный ресурс. По мнению автора, основным недостатком ИН модели является «прерывистость истории» ИН. Это становится понятным, если задать простой вопрос: что осталось от предыдущих срабатываний и генераций ПД в текущей динамике ИН? Любой сброс одной из переменных по условию в определенное значение приводит к потере информации об активности модели в предыдущий период.

Модификации модели интегрирующего нейрона

Поскольку модель ИН не требует большого вычислительного ресурса для своей реализации, было предпринято множество попыток его модификации для придания модели ИН более биологически обоснованной динамики. Здесь будет описан модифицированный интегрирующий нейрон (МИН), предложенный автором [3]. Данная модель (в отличие от классической модели ИН) позволяет имитировать такие эффекты, как: следовая (постимпульсная) поляризация и ее накопление при пачечной активности; адап-

тация к деполяризации; катодическая депрессия и постанодалная экзальтация. Кроме того, у МИН отсутствует прерывистость истории, о которой говорилось выше. В отличие от ИН, МИН имеет два сегмента: основной и дополнительный. Динамика их потенциала описывается обыкновенными дифференциальными уравнениями:

$$\tau \frac{du}{dt} = rI_{syn} + \frac{r}{r_{ap}} (u_{ap} - u) - u, \quad \tau_{ap} \frac{du_{ap}}{dt} = u - u_{ap}, \quad (34)$$

где индекс ap обозначает переменные для дополнительного сегмента, $\tau = rc$ — постоянная времени сегмента, r — сопротивление сегмента.

Для моделирования адаптации как к длительной деполяризации, так и длительной гиперполяризации в модель введено интегральное смещение порога:

$$\frac{du_i}{dt} = \begin{cases} u \frac{a}{\tau_r} - u_i & \text{если } u > u_i \\ u \frac{a}{\tau_f} - u_i & \text{если } u \leq u_i \end{cases} \quad \vartheta = u_i + c_{th}, \quad (35)$$

где u_i — интегральный потенциал, τ_f и τ_r — постоянные времени спада и нарастания интегрального потенциала, a — коэффициент, увеличивающий скорость изменения интегрального потенциала во время ПД, а все остальное время принимающий значение, равное единице, c_{th} — постоянное смещение порогового потенциала относительно интегрального. МИН эмулирует поведение реального нейрона не только в промежутках между ПД, но и во время самого ПД. Для этого левое уравнение в (34) заменяется системой:

$$\begin{cases} \tau \frac{du}{dt} = rI_{syn} + \frac{r}{r_{ap}} (u_{ap} - u) - u + 2 \frac{r}{\tau_s} \theta_s, & \text{если } t - t' < \frac{\tau_s}{2} \\ \tau \frac{du}{dt} = rI_{syn} + \frac{r}{r_{ap}} (u_{ap} - u) - u - 2 \frac{r}{\tau_s} \theta_s, & \text{если } \frac{\tau_s}{2} < t - t' < \tau_s \\ \tau \frac{du}{dt} = rI_{syn} + \frac{r}{r_{ap}} (u_{ap} - u) - u & \text{в других случаях,} \end{cases} \quad (36)$$

где τ_s и θ_s — длительность и амплитуда ПД, соответственно.

Свойства МИН во многом повторяют характерные свойства ИН. Несмотря на то, что у МИН нет сброса по условию, сохраняется логарифмическая

передаточная характеристика $I-f$, которая показана на рис. 21 для различных значений τ .




Рис. 21. Логарифмическая передаточная характеристика $I-f$ для различных значений τ (цит. по [2])

В дополнение к уже сказанному, МИН позволяет моделировать скорость адаптации в зависимости от постоянной времени основного интегратора. Данное свойство не закладывалось первоначально в модель и вытекает из того, что генератор ПД влияет по-разному на нейроны с разными постоянными времени. Поскольку значение порога зависит от интегрального потенциала, то для клеток с большой постоянной времени интегральный потенциал будет больше, а для меньшей постоянной времени и интегральный потенциал уменьшится.

Модель ФицХью и Нагумо

МИН, как и ИН, базируется на обыкновенном линейном дифференциальном уравнении. Однако, существуют и другие типы моделей. Рассмотрим классическую модель с нелинейной правой частью, предложенную

полинома имеются три точки равновесия, одна из которых неустойчива. В зависимости от значения параметров устойчивые точки равновесия могут быть помещены вблизи потенциала покоя и максимальной амплитуды ПД. В зависимости от коэффициентов ε и e в (37) наклон линейной части второго уравнения можно менять. Поэтому данная модель имеет способность к автогенерации. В своем классическом варианте, с устойчивым вторым уравнением, модель демонстрирует такие феномены, как адаптация, постанодальная экзальтация и уменьшение амплитуды ПД при пачечном режиме.

Модель Ижикевича

Несмотря на то, что модель ФХН является достаточно простой и универсальной, Евгением Ижикевичем в 2001 году была предложена модель нейрона, несколько упрощающая модель ФХН. Она основывается на квадратном полиноме в правой части уравнения для мембранного потенциала, также является двусегментной и содержит дополнительное условие для сброса:

$$\begin{aligned} \frac{du}{dt} &= 0.04u^2 + 5u + 140 - v, \\ \frac{dv}{dt} &= a(bu - v), \end{aligned} \quad (38)$$

если $u \geq 30 : u \leftarrow c, v \leftarrow v + d,$

Поведение основного и дополнительного потенциалов во время ПД показано в левой части рис. 23 (необходимо учитывать, что в оригинальной работе, откуда взята иллюстрация, $v(t)$ обозначает мембранный потенциал, а $u(t)$ — дополнительную переменную). В работе [17] показано, что данная модель способна воспроизводить все двадцать типов активности реальных биологических нейронов (по классификации Ижикевича) в зависимости от значений четырех параметров модели.

Справа на рис. 23 приведены значения параметров данной модели для семи различных типов активности, а на рис. 24 показаны сами паттерны активности.

По субъективному мнению автора, единственным недостатком данной модели является частичная разрывность ее истории вследствие сброса мембранного потенциала при достижении им порога (т. е. уровня 30 мВ).




Рис. 23. Изменение основного и дополнительного потенциалов во время потенциала действия (слева) и параметры для различных режимов работы (справа). Следует учитывать, что в оригинальной работе, откуда взята иллюстрация, $v(t)$ обозначает мембранный потенциал, а $u(t)$ — дополнительную переменную (цит. по [16])

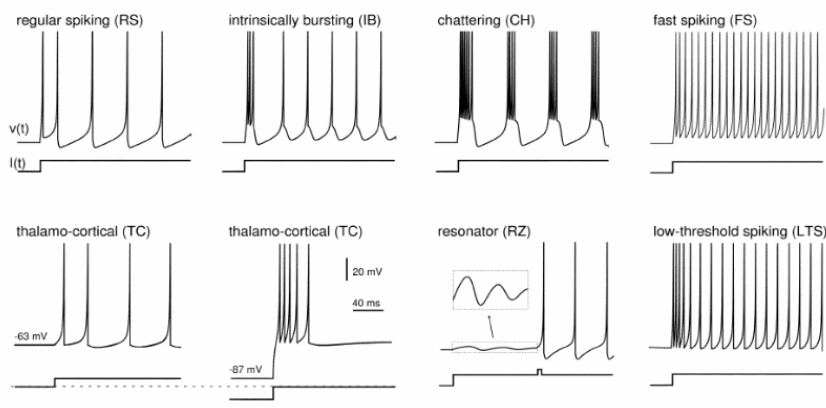


Рис. 24. Имитация паттернов активности характерных для различных видов реальных биологических нейронов (цит. по [16])

Общая сравнительная характеристика феноменологических моделей

На рис. 25 приводится сравнительная таблица и диаграмма «биологическая адекватность–необходимый вычислительный ресурс», в которой приведены данные для наиболее популярных феноменологических моделей. Стоит заметить, что, несмотря на полноту приведенной картины, некоторые ас-

пекты представленных данных являются субъективным мнением ее автора.

Модели синаптической передачи

Как упоминалось ранее, моделей синаптической передачи (как химической, так и электрической) значительно меньше, чем моделей нейронов. Но их также можно разделить на феноменологические и детальные. Рассмотрим вначале простую универсальную модель электрического синапса.

Модель электрического синапса

Как было описано выше, электрический синапс можно рассматривать как свободный ток ионов через крупные поры между клетками. Движение разнородных ионов в растворе есть электрический ток, и переносом вещества при моделировании электрических синапсов, как правило, пренебрегают. Совершенно очевидно, что:

$$I_{syn_e12} = -I_{syn_e21} = g_{syn_e}(u_2 - u_1), \quad (39)$$

где g_{syn_e} — проводимость электрического синапса, u_1 и u_2 — потенциалы связываемых клеток, I_{syn_e12} и I_{syn_e21} — синаптические токи электрического синапса для первой и второй клетки соответственно.

Применение для химического синапса омической модели делается с рядом неочевидных допущений:

- 1) безразлична природа переносчиков электрического тока;
- 2) ионы движутся только по направлению электрического поля и не перемещаются химическим градиентом;
- 3) ток ионов никак не изменяет концентрации веществ во внутриклеточных средах двух клеток.

Однако поскольку в глиальных клетках экспериментально показано существование кальциевых волн за счет обмена кальцием через электрические синапсы, то обменом Ca^{2+} нельзя пренебрегать при моделировании этого вида синапса. По мнению автора, следует рассчитывать омический ток (39), далее вычислять ток кальция по выражению Гольдмана и корректировать внутриклеточные концентрации кальция в обоих нейронах.

Феноменологические модели химической синаптической передачи

Поскольку, как правило, химические синапсы предполагают однонаправленное воздействие от пресинапса к постсинапсу, при их моделировании также выделяют пресинаптическую и постсинаптическую части. Обычно феноменологические модели синапсов применяют в сетях с феноменологическими же моделями нейронов. Как мы видели в разделе 3, далеко не все модели нейронов эмулируют ПД, некоторые из них, например ИН, лишь фиксируют момент времени его возникновения t' . Поэтому в феноменологических моделях также фиксируют лишь время ПД. Рассмотрим несколько простейших моделей:

$$I_{syn} = \begin{cases} 0 & \text{если } t < t_p \\ \omega \exp\left(\frac{t'_p - t}{\Omega}\right) & \text{в других случаях} \end{cases} \quad (40)$$

$$I_{syn} = \begin{cases} 0 & \text{если } t < t'_p \\ \omega \frac{t'_p - t}{\Omega} \exp\left(1 - \frac{t'_p - t}{\Omega}\right) & \text{в других случаях} \end{cases} \quad (41)$$

$$I_{syn} = \begin{cases} 0 & \text{если } t < t'_p \\ \omega \frac{\exp\left(\frac{t'_p - t}{\Omega_1}\right) - \exp\left(\frac{t'_p - t}{\Omega_2}\right)}{\Omega_1 - \Omega_2} & \text{в других случаях} \end{cases} \quad (42)$$

где t'_p — момент времени последнего пресинаптического ПД, ω — максимальный ток синапса, называемый также весом синапса, Ω — постоянная времени синапса. Модель (41) также называют альфа-синапсом, а модель (42) двухэкспоненциальной. Однако, все эти очень простые модели не учитывают ни выброса медиатора, ни его возможное накопление в синаптической щели и, как следствие, не способны воспроизвести ряд феноменов, наблюдающихся в реальных синапсах.

Приведем еще одну феноменологическую модель, предложенную автором:

$$\frac{dm_i}{dt} = \begin{cases} \frac{m_s}{\Omega_r} - \frac{m_i}{\Omega_f} & \text{если } t - t'_p \Omega_r \\ -\left(\frac{m_i}{\Omega_f}\right) & \text{в других случаях} \end{cases} ; \quad I_{syn} = \omega m_i, \quad (43)$$

где Ω_r — постоянная времени нарастания постсинаптического тока, Ω_f — постоянная времени его спада, m_s — величина выброса медиатора, вызванного единичным ПД. Поскольку введена дополнительная динамическая переменная m_i , описывающая количество медиатора в синаптической щели, данная модель способна воспроизводить такой феномен, как накопление медиатора в щели. Однако, у модели (43) есть существенное ограничение. Поскольку в модели нет ограничения амплитуды m_i то синаптический ток при накоплении медиатора может принимать значения, не обоснованные с биологической точки зрения.

Детальные модели химической синаптической передачи

При детальном моделировании необходимо учитывать, что синаптический ток имеет ту же природу, что и все трансмембранные токи, и, следовательно, его необходимо моделировать в терминах реверсных потенциалов и максимальных проводимостей:

$$I_{syn} = \overline{g_{syn}} \Theta(u - E_{syn}), \quad (44)$$

где $\overline{g_{syn}}$ — максимальная синаптическая проводимость, E_{syn} — реверсный потенциал синапса, Θ — воротная функция синапса.

Приведем несколько примеров воротной функции синапса. В работе [8] используют две Θ — с быстрой и медленной динамикой для ионотропных и метаболотропных синапсов соответственно:

$$\frac{d\Theta}{dt} = \alpha \left(1 - \exp \left(\frac{u_p - \vartheta}{s} \right)^{-1} - \frac{\Theta}{\Omega} \right) \quad (45)$$

$$\frac{d\Theta}{dt} = \alpha_{\Theta x} (1 - \Theta) - \frac{\Theta}{\Omega_{\Theta}}; \quad \frac{dx}{dt} = \alpha_x \left(1 - \exp \left(\frac{u_p - \vartheta}{s} \right)^{-1} - \frac{x}{\Omega_x} \right) \quad (46)$$

где α — коэффициент нарастания, τ — постоянные времени, u_p — потенциал предсинаптического нейрона, ϑ — потенциал полуактивации синапса, s — крутизна нарастания активации предсинапсом посинаптического тока. Как видно из выражений (45) и (46), в данной реализации воротная переменная зависит от значения предсинаптического потенциала u_p . В связи с тем, что ПД является весьма коротким по времени событием, выброс медиатора, моделируемый сигмоидной функцией (в выражениях (45) и (46) терм в минус первой степени), а, следовательно, и активация воротной переменной

достаточно быстры. В силу динамических свойств модели (45) ее применение оправданно, только если максимум ПСП приходится на окончание ПД предсинаптического нейрона. Для более пролонгированной динамики вполне уместно использовать двухстадийную модель (46), в которой ПД активирует промежуточную переменную x , медленное затухание которой после ПД продолжает активировать основную воротную переменную.

В некоторых работах учитывается тот факт, что выброс медиатора является случайным процессом, модулируемым предсинаптическим потенциалом. При моделировании для этого используется распределение Пуассона:

$$\Theta(u_p, t) = P(u_p, \Xi(t)), \quad (47)$$

где P — распределение Пуассона, $\Xi(t)$ — некоторый случайный процесс.

В работе [7] также учитывается потенциальная чувствительность магний содежащей компоненты, которая содержится в некоторых типов рецепторов. Кроме того, в [14] учитывается эффект истощения медиатора в предсинаптическом терминале (так как запасы медиатора в предсинапсе ограничены, и для их восстановления требуется время). Однако, в большинстве случаев для большеразмерной сети вполне подходят модели (45) и (46), которые можно отнести к детальным феноменологическим.

В заключении этого раздела хотелось бы отметить, что моделирование синаптической передачи становится значительно более сложным в случае многосегментных моделей, имитирующих динамику концентраций ионов во внутриклеточной среде. Для этих целей не подходит ни одна из вышеописанных моделей, и требуются специальные подходы к описанию процессов, происходящих при генерации ПСП.

Примеры моделей биологически обоснованных нейронных сетей

В данном разделе приведены несколько примеров построения моделей нейронных сетей. Для иллюстрации использовались наиболее интересные, нетипичные модели, демонстрирующие зачастую неожиданные и парадоксальные результаты. К таким моделям, по мнению автора, можно отнести модель с автоторможением, предложенную Додла и Ринзелем в 2005 году [11].

Модель с автоторможением

Гистологи и нейробиологи давно обратили внимание на то, что у некоторых тормозных клеток после длительного ветвления аксон образует синаптическую терминаль с клеткой, из которой он вышел (т.е. возвращается). Поскольку длительность распространения импульса по волокну достаточно велика, данную связь нельзя считать классической обратно-отрицательной связью. Поэтому такое автоторможение до недавнего времени не рассматривалось вообще.

Из общих соображений можно предположить, что наличие ветви автоторможения должно ограничивать активность клетки, не давая ей генерировать длительные пачки ПД, уменьшая общее количество импульсов в последовательности и среднюю частоту.

Рассмотрим классическую модель ХХ (15), (11) и (12), активируемую некоторым случайным процессом. Пусть эта модель имеет единственный синапс сама с собой, моделируемый уравнением (45). Будем задерживать значение предсинаптического потенциала клетки, модулирующего синапс, на 1 мс, что соответствует задержке по относительно длинному тонкому волокну.

На вкладке в верхнем правом углу рис. 26 изображена схема нейронной сети, а на треках — активность нейрона без автоторможения (верхний график) и с автоторможением (нижний график). Как ни парадоксально это выглядит на первый взгляд, при автоторможении среднее количество импульсов увеличивается и частота генерации ПД возрастает.

На рис. 27 приведен график зависимости выходной частоты модели от частоты входа при различных максимальных проводимостях тормозного синапса. На графике хорошо видно, что при некоторых условиях выходная частота модели с максимальной проводимостью тормозного синапса 20mS/cm^2 в полтора раза превышает выходную частоту без автоторможения.

Анализ модели показывает, что причиной этого результата является факт, что ТПСП автоторможения возникает как раз в тот момент времени, когда начинает открываться калиевый канал (это хорошо видно на нижнем графике рис. 26, где показана также динамика проводимости тормозного синапса). Шунтируя проводимость калиевого канала, тормозный синапс увеличивает срез ПД, не давая калиевой воротной переменной полностью открыться. Это, в свою очередь, приводит к быстрой инактивации калиевого канала и более быстрому восстановлению клетки после предыдущего

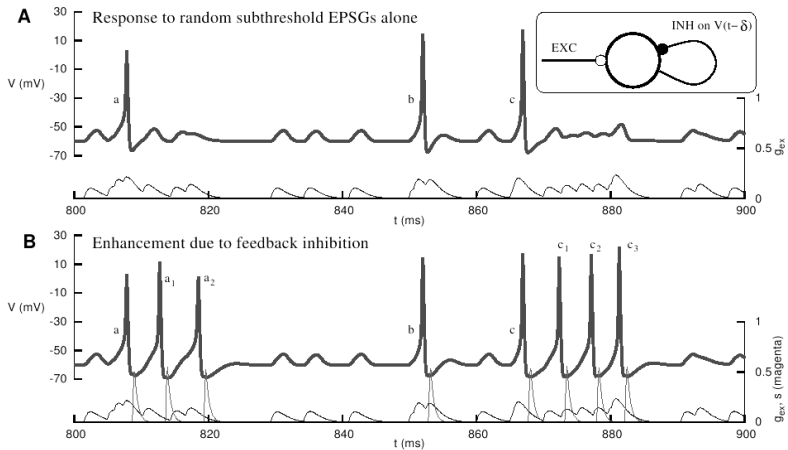


Рис. 26. Схема нейронной сети (вкладка в верхнем правом углу), активность нейрона без автоторможения (верхний график) и с автоторможением (нижний график) (цит. по [11])

ПД.

Эта модель является хорошей иллюстрацией того, как моделирование может помочь объяснить, какую роль играют те или иные особенности реальной нейронной сети.

Модель зрительной коры кошки

Другая, не менее примечательная модель была опубликована Хиллом и Таниони также в 2005 году [14]. В этой модели содержалось более 65 тысяч точечных моделей нейронов. Каждый элемент сети моделировался одной системой уравнений, представляющим собой некоторый компромисс между ИН и точечной моделью ХХ. Модель структурно повторяла первичные и вторичные зрительные поля коры и специфические и неспецифические ядра таламуса в масштабе 1 : 9, т.е. на один моделируемый нейрон в реальном мозге животного в среднем приходится девять нервных клеток.

На рис. 28 приведена общая структура сети, состоящей из двух отделов — первичного V_p и вторичного V_s , включающих в себя: участки коры,




Рис. 27. Зависимость выходной частоты модели от частоты входа при различных максимальных проводимостях тормозного синапса (цит. по [11])

каждый из которых состоял из трех слоев, имитирующих реальные сети слоев $L1 - L3$, $L4$ и $L5 - L6$ соответственно; два участка таламуса: релейного ядра Tr и неспецифического ядра Ts ; два отдела при таламической ретикулярной формации — Rp и Rs соответственно. Структура возбуждающих и тормозных связей строилась таким образом, чтобы в вертикальном направлении в сети образовывались группы с колончатой структурой. Каждая из таких колонок была настроена на распознавание определенной ориентации и была способна различать ее во входном сигнале. Основной особенностью данной модели являлось то, что она демонстрировала не только активность, характерную для нейронов во время бодрствования, но и была способна моделировать активность во время медленноволнового сна. Причем переход от одной активности к другой сопровождался целым каскадом характерных паттернов, соответствующим слабой, средней и глубокой дремоте.

На рис. 29 показан переход модели от паттерна, соответствующего бодрствованию, к паттерну медленноволнового сна. Для такого перехода у всех




Рис. 28. Общая структура сети, состоящей из двух отделов — первичного Vp и вторичного Vs (цит. по [14])

клеток модели увеличивалась проводимость пассивного K_L^+ канала. Как видно из рисунка, модель переходит от единичных ПД к паттерну активности «пачка–пауза–пачка», характерному для медленноволнового сна. Хорошо известно, что синхронизация нейронов повышается во время так называемого верхнего состояния (upstate), а в паузах между ними (downstate) резко падает. На пространственной диаграмме модели (в нижней части рис. 29) видно, что данная модель хорошо повторяет эти особенности поведения реальных нейронов во время медленноволнового сна. При помощи этой модели можно ответить на вопрос: какие ионные каналы или/и какие связи влияют на медленноволновую активность? На рис. 30 показаны две иллюстрации из этой работы, которые наглядно демонстрируют, как меняется поведение модели при удалении тех или иных ее компонент, увеличении или уменьшении влияния различных ионных каналов на общую динамику активности.

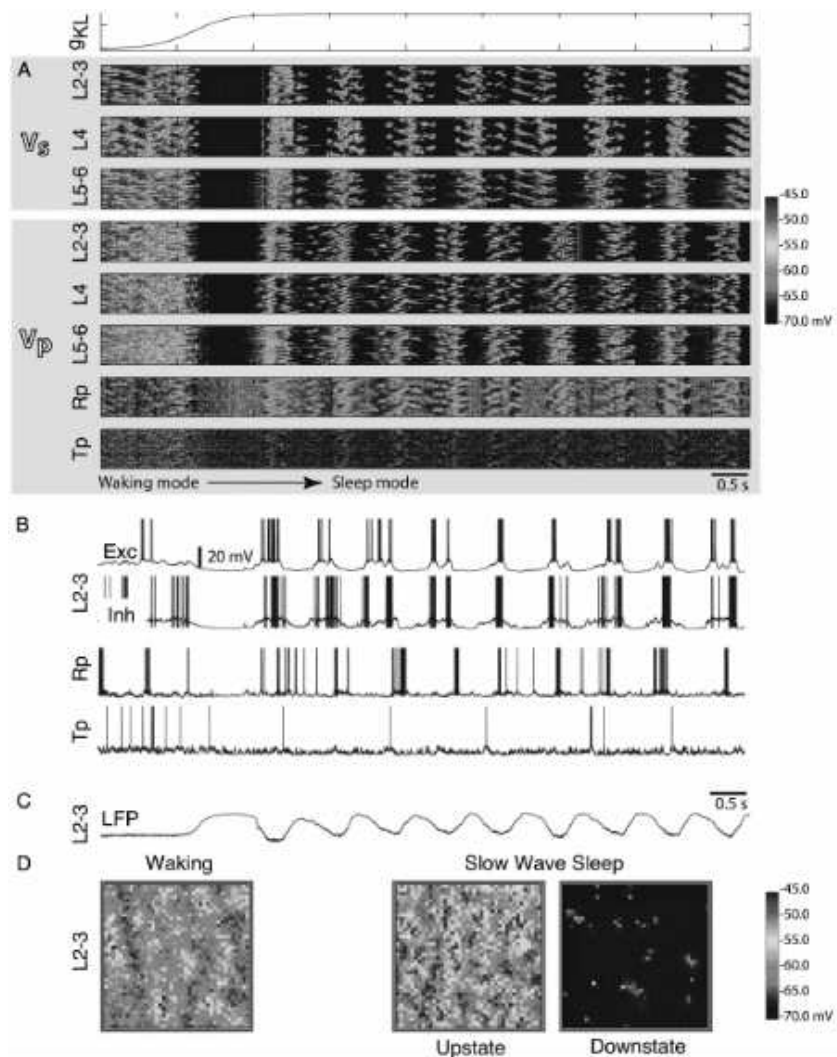


Рис. 29. Переход модели от паттерна, соответствующего бодрствования-

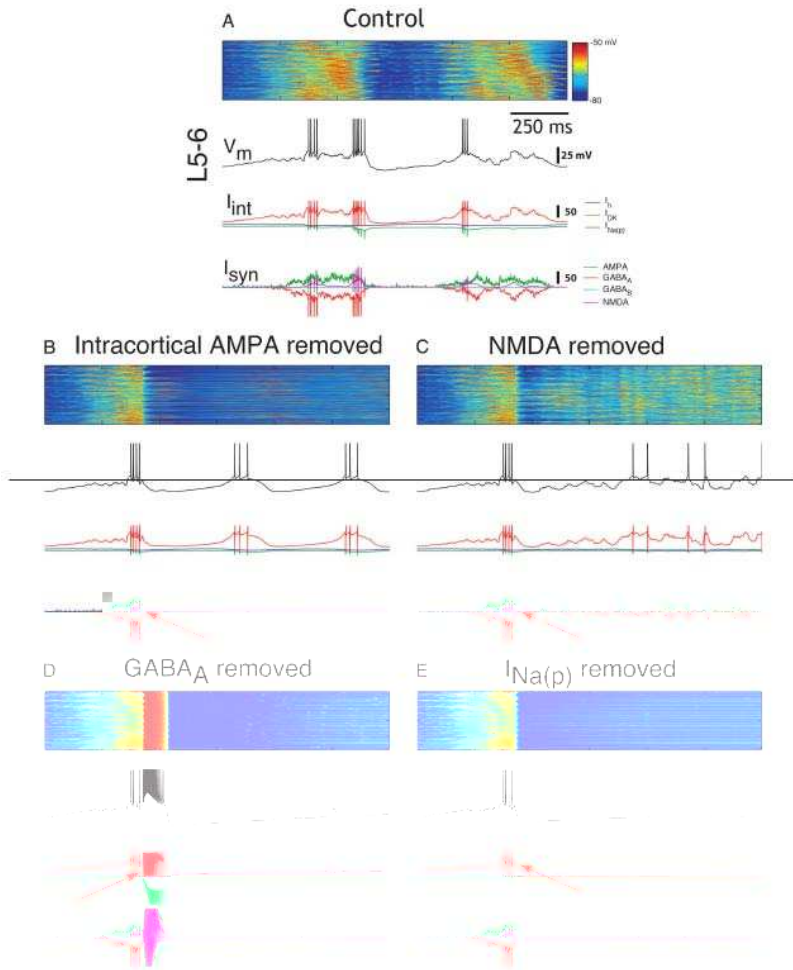


Рис. 30. Изменение поведения модели при удалении различных ее компонент, увеличении или уменьшении влияния различных ионных каналов на общую динамику активности (цит. по [14])

Заключение

Рассмотренные в данной лекции модели не исчерпывают все возможные виды моделирования. К сожалению, из-за ограниченного объема не удалось включить раздел, посвященный моделированию внутриклеточной динамики кальция и натрия, моделям активных и пассивных транспортов, моделям буферизации и выброса различных ионов.

Как мы видели из приведенных примеров, моделирование нейронов и нейронных сетей зачастую позволяет не только объяснить, как происходят те или иные процессы, но и обнаружить явления, ранее неизвестные и не являющиеся очевидными. С методологической точки зрения моделирование заменяет синтез в процессе познания природы. Не будучи способными понять все множество экспериментальных фактов и взаимодействий выявленных процессов, мы вынуждены моделировать их.

Эта особенность моделирования привела к тому, что во многих зарубежных журналах по нейрофизиологии редакция рекомендует обязательно включать моделирование если не в само исследование, то хотя бы в дискуссию.

Безусловно, по-прежнему остаются элементы «искусства» при правильном подборе модели, поиске оптимального соотношении размерности сети и точности модели, при выборе уровня рассмотрения проблемы, на решение которой направлено моделирование. Однако, в большинстве случаев такие вопросы уже не столь критичны для исследователя. Возросшая мощность вычислительной техники и специализированные программные продукты с высокой эффективностью позволяют решать многие задачи моделирования без ограничений точности модели.

Как следует из общего содержания, специалист в области биологически обоснованного нейромоделирования обязательно должен владеть прочными знаниями математических методов, численных методов, иметь навыки программирования и, главное, хорошо разбираться в проблемах и вопросах нейробиологии. Подготовка такого специалиста, объединяющего знания из трех разнородных областей, непростая задача. Проблема усугубляется тем, что на русском языке практически отсутствует литература по данным вопросам. Автор настоятельно рекомендует заинтересовавшимся этой увлекательной наукой обратиться к доступным учебникам на английском или французском языке.

Литература

1. *Николлс Д., Мартин Р., Валлас Б., Фукс П.* От нейрона к мозгу // Пер. с англ. П. М. Балабана, А. В. Галкина, Р. А. Гиниатуллина, Р. Н. Хазипова, Л. С. Хируга. – М.: Едиториал УРСС, 2003.
2. *Тикиджи-Хамбурьян Р. А.* Анализ влияния генератора спайков на динамические свойства модифицированного импульсного нейрона. // Тез. док. 5-ой Всероссийской научно-технической конференции «Нейроинформатика 2003», М.: МИФИ, 2003, с. 134–141.
3. *Тикиджи-Хамбурьян Р. А.* Модифицированный импульсный нейрон как базовая модель для реалистичных нейронных сетей // *Нейрокомпьютеры: разработка и применение*, №7-8, 2002.
4. *Уоссерман Ф.* Нейрокомпьютерная техника: Теория и практика. Пер. с англ. – М.: Мир, 1992. – 240 с.
5. *Шенард Г.* Нейробиология. В 2-х т. Т.1. Пер. с англ. – М.: Мир, 1987. – 454 с.
6. *Bannister A. P.* Inter- and intra-laminar connections of pyramidal cells in the neocortex // *Neuroscience Research*. v. 53: 95–103, 2005.
7. *Brunel N., Wang X.-J.* Effects of Neuromodulation in a Cortical Network Model of ObjectWorking Memory Dominated by Recurrent Inhibition // *J. Comput. Neurosci.* – v. 11: 63–85, 2001.
8. *Compte A., Sanchez-Vives M. V., McCormick D. A., Wang X.-J.* Cellular and network mechanisms of slow oscillatory activity (1 Hz) and wave propagations in a cortical network model // *J. Neurophysiol.*, v.89: 2707–2725, 2003.
9. *Dayan P., Abbott L. F.* Theoretical neuroscience (computational and mathematical modeling of neural Systems. – MIT Press, Cambridge MA, 2001.
10. *DeSchutter E., Bower J. M.* An active membrane model of the cerebellar Purkinje cell (I. Simulation of current clamps in slice) // *J. Neurophysiol.*, vol. 71: 375–400, 1994.
11. *Dodla R, Svirskis G, Rinzel J.* Well-timed, brief inhibition can promote spiking: Postinhibitory facilitation // *J. Neurophys.* 95: 2664–2677, 2006.
12. *FitzHugh R.* Impulses and physiological states in models of nerve membrane? // *J. Biophys.*, v.1: 445–466, 1961.
13. *Gerstner W., Kistler W. M.* Spiking neuron models: Single neuron, populations, plasticity. – Cambridge University Press, 2002.
14. *Hill S., Tononi G.* Modeling sleep and wakefulness in the thalamocortical system // *J. Neurophysiol.*, v.93: 1671–1698, 2005.

15. *Hille B.* Ion channels of excitable membranes. Third Edition. – Sinauer Associates Inc., Sunderland, Massachusetts USA, 2001.
16. *Izhikevich E. M.* Simple model of spiking neurons // *IEEE Transactions on Neural Networks*, v. 14: 1569–1572, 2003.
17. *Izhikevich E. M.* Which model to use for cortical spiking neurons? // *IEEE Transactions on Neural Networks*. – v.15: 1063–1070, 2004.
18. *Izhikevich E. M., FitzHugh R.* FitzHugh-Nagumo model // *Scholarpedia*, 3193, 2006
19. *Mainen Z. F., Sejnowski T. J.* Influence of dendritic structure on firing pattern in model neocortical neurons // *Nature*. – v. 382: 363–366, 1996.
20. *McCormick D. A., Pape H.-C.* Properties of a hyperpolarization-activated cation current and its role in rhythmic oscillation in thalamic relay neurons // *J. Physiology*. – v. 431: 291–318, 1990.
21. *McCormick D. A., Huguenard J.* A model of the electrophysiological properties of thalamocortical relay neurons // *Journal of Neurophysiology*. – v. 68: 1384–1400, 1992.
22. *Nowak L. G., Azouz R., Sanchez-Vives M. V., Gray C. M., McCormick D. A.* Electrophysiological classes of cat primary visual cortical neurons in vivo as revealed by quantitative analyses // *J. Neurophysiol.* – v. 89: 1541–1566, 2003.

Рубен Акимович ТИКИДЖИ-ХАМБУРЬЯН, старший научный сотрудник НИИ Нейрокибернетики им. А. Б. Когана, Южного Федерального Университета. Область научных интересов: детальное моделирование нейронов и локальных нейронных структур мозга; нейронные ансамбли — возникновение и стабилизация; обучение с учетом локальной кальциевой динамики, обратного распространения потенциала действия по дендритному дереву нейрона и локальной биохимической кинетики. Является автором более 30 научных работ.

Л. А. СТАНКЕВИЧ

Санкт-Петербургский государственный политехнический университет

E-mail: stankevich_lev@inbox.ru

ИСКУССТВЕННЫЕ КОГНИТИВНЫЕ СИСТЕМЫ

Аннотация

В данной лекции обсуждаются пути развития искусственных когнитивных систем. Один из таких путей, связанных с разработкой когнитивных гибридных систем, которые способны обучаться восприятию сложной информации и формированию рационального поведения в динамически изменяющихся средах в реальном времени, рассматривается детально. Показано, что такие системы могут быть эффективны, например, для современных интеллектуальных роботов, поскольку они могут быть базой для разработки искусственной нервной системы таких роботов. Приводятся примеры разработки и применения обучаемых компонентов когнитивных систем.

L. A. STANKEVICH

Saint-Petersburg State Polytechnic University, Russia

E-mail: stankevich_lev@inbox.ru

ARTIFICIAL COGNITIVE SYSTEMS

Abstract

In the given lection, ways for development of artificial cognitive systems are discussed. One of the ways related to cognitive hybrid systems, which are able to be learned and to form complex information perception and rational behavior forming in real time, are considered in details. It is shown that such systems can be effective, for example, for the modern intellectual robots because they can be a base for artificial nervous system of robots. Examples of development and application of the cognitive system learnable components are considered.

Введение

Развитие искусственного интеллекта привело к формированию нового подхода, который предполагает создание интеллектуальных обучаемых систем на основе раскрытых в последнее время нейрофизиологических принципов построения нервной системы и методов познавательной и мыслительной (когнитивной) деятельности человека. Такой подход может быть назван когнитивным подходом, а системы — искусственными когнитивными системами. Предполагается, что научное направление, связанное с построением искусственных когнитивных систем, будет определять развитие информатики и искусственного интеллекта в ближайшем будущем. Разработка когнитивных систем стала главным вызовом нового столетия, о чем свидетельствуют крупные проекты в этом направлении, объявленные DARPA, FP7-IST и др.

Проблема, связанная с разработкой искусственных когнитивных систем, возникла на стыке когнитивной науки и искусственного интеллекта. Ожидается, что такие системы будут способны к накоплению знаний в реальном времени и самоорганизации в процессе решения сложных и трудно формализуемых задач. Развитие искусственных когнитивных систем имеет целью достижение уровня интеллектуальности систем, близкого к человеческому, что позволит автоматизировать процесс решения многих задач, которые не могут быть эффективно решены традиционными интеллектуальными системами. Разработка искусственных когнитивных систем сопровождается теоретическими исследованиями, направленными на создание подходящих концепций и архитектур таких систем, а также методов реализации таких систем, их структур и элементов.

В данной лекции обсуждаются пути развития когнитивного подхода в психологии, а также связь искусственного интеллекта и когнитивной науки. Рассматриваются когнитивистская и эмерджентная парадигмы искусственных когнитивных систем. Кратко описываются некоторые из известных архитектур когнитивистских, эмерджентных и гибридных систем. Подробно описывается развиваемая автором и его коллегами методология разработки гибридных когнитивных систем. Рассмотрены специально разработанные когнитивные концепции, архитектуры и когнитивные средства построения таких систем. Показано применение разработанных средств для создания когнитивных агентов, способных эффективно функционировать в составе систем группового управления реального времени в динамически меняющихся средах, а также в составе искусственной нервной системы гуманоидного робота.

Когнитивный подход и развитие когнитивной науки

Истоки когнитивного подхода в науках о человеке прослеживаются, начиная с работ древнегреческих мыслителей. К ним можно отнести учение об универсалиях Платона, его теорию памяти, аристотелевские законы ассоциации и принципы рассуждения, составляющие основу логического мышления и др. Однако реальное осознание этих понятий произошло в более поздний период, связанный с возникновением научной психологии. Начало научной психологии исходит от *Гельмгольца* (Hermann von Helmholtz, 1821–1894) и *Вандта* (Wilhelm Wundt, 1832–1920). *Гельмгольц* первый применил научный подход к изучению зрения человека. *Вандт* в 1879 году открыл первую лабораторию экспериментальной психологии в университете Лейпцига. Здесь он начал эксперименты по решению людьми задач восприятия и ассоциативных задач, интроспективному (основанному на субъективном объяснении) исследованию мыслительных процессов человека. Однако позднее возникшее движение бихевиоризма (John Watson, 1878–1958) и (Edward Lee Thordike, 1874–1949) восстало против субъективизма, отрицая любую теорию, включающую ментальные процессы, на том основании, что интроспекция не может обеспечить надежных свидетельств. Бихевиористы замыкались на изучении только объективных измерений восприятия (или стимулов, задаваемых животным) и их результатами (или ответами). Ментальные конструкции, такие как Знания, Убеждения, Цели и Шаги рассуждений были признаны ненаучными, связанными с «народной» психологией. Бихевиоризм раскрыл множество знаний о поведении крыс и голубей, но имел меньше успехов в понимании людей. Несмотря на это, он имел сильное влияние на психологию (особенно в США) в 1920–1960 годы.

Термин «когнитивный» происходит от лат. *cognitio* — познание, а собственно когнитивный подход базируется на идеях *когнитивной психологии* — одного из динамично развивающихся направлений. Когнитивная психология, давшая взгляд на процессы мозга, как процессы обработки информации, связана с работами *Джеймса* (William James, 1842–1910). Заметим, что и *Гельмгольц* также настаивал, что восприятие включает форму бессознательного логического вывода. Когнитивная точка зрения была сильно затемнена бихевиоризмом, пока в 1943 году *К. Кларк* не опубликовал работу “The Nature of Explanation”, где вернул значение ментального шага между стимулом и ответом и показал, что Убеждения, Цели и Шаги рассуждений могут быть полезными компонентами теории поведения человека. Он яс-

но описал три ключевых шага процесса преобразования стимула в ответ: (1) стимул транслируется во внутреннее представление; (2) это представление преобразуется когнитивными процессами, чтобы произвести новое внутреннее представление; (3) последнее представление, в свою очередь, ретранслируется в ответное действие.

Формирование когнитивной психологии как особой дисциплины обычно связывают с именем *Найссера*, опубликовавшего книгу с изложением когнитивного подхода в психологии [1], которая стала в определенном смысле программной. Он отнес к числу важнейших принципов когнитивного подхода трактовку человека как действующего, активно воспринимающего и продуцирующего информацию, руководствующегося определенными планами, правилами, стратегиями. Для этого подхода характерна специфическая направленность исследований, выражающаяся в движении от понимания сложного феномена к пониманию простого. Заметим, что бихевеиоризм и необихевеиоризм имеют противоположную исследовательскую стратегию, основанную на понимании сложного процесса путем предварительного изучения простых процессов. Для когнитивного подхода важным моментом является рассмотрение активности человека как иерархически организованной.

Первоначально основной задачей когнитивного подхода было изучение процессов преобразования информации с момента поступления сигнала в органы чувств до получения ответа. Сторонники когнитивного подхода исходно используют «компьютерную метафору», уподобляя процессы переработки информации человеком тем, которые протекают в вычислительном устройстве [2]. Использование динамических моделей и математических формализмов для описания мыслительных процессов также играет значительную позитивную роль в развитии этого подхода. Еще одной сферой, оказавшей большое влияние на развитие когнитивного подхода, явились исследования в области математической лингвистики, в частности, так называемые трансформационные грамматики, разработаны *Н. Хомским* [3].

С точки зрения психологии и нейробиологии нервная система человека включает когнитивную и аффективную системы [4]. Когнитивная система отвечает за восприятие информации о среде, получаемой с помощью сенсоров, структурирование и хранение ее в виде знаний в кратковременной и долговременной памяти, а также организует ментальные (разумные) процессы преобразования информации при решении интеллектуальных задач. Аффективная система организует выполнение действий, которые ведут к реализации выработанных когнитивной системой планов, т. е. коорди-

нирует и управляет моторикой всех эффекторов человеческого организма (мышцами, органами пищеварения, кровоснабжения и др.). Эти системы находятся в постоянном взаимодействии друг с другом, обеспечивая целесообразное функционирование организма в условиях изменяющейся среды.

Современные исследования в области когнитивной науки позволили сделать интересные обобщения, на базе которых создаются новые когнитивные модели, и обосновать новые гипотезы о когнитивных процессах мозга [5]. Следует заметить, что в настоящее время когнитивный подход в психологии испытывает определенные трудности, связанные с обилием моделей, предлагаемых для интерпретации различных аспектов мыслительного процесса, и отсутствием достаточных оснований для аргументированного выбора среди них.

Искусственный интеллект и когнитивная наука

В настоящее время термин «когнитивный» используется не только в психологии, но и в технике. Разработка ряда когнитивных моделей, т. е. формализованных моделей мыслительных процессов, отражающих современные гипотезы об их протекании в мозге человека, положило начало применению когнитивного подхода при создании технических систем. Применительно к техническим системам также стал использоваться термин «когнитивные системы», как отражение факта использования когнитивных моделей в интеллектуальных системах [6, 7].

Переход психологических понятий в техническую область свидетельствует о попытке приблизить интеллектуальные способности технических систем к человеческим. Понятие когнитивности в психологии связывает концепции познания и знаний. Когнитивная наука детально изучает информационные процессы мозга человека и пытается строить формализованные модели этих процессов. Технически важно то, что мозг воспринимает информацию, т. е. обрабатывает ее сенсорными системами и формирует структурированную систему знаний. Результаты исследования процессов обработки информации, связанных с познанием и мышлением в рамках когнитивной науки позволили построить *когнитивную теорию мозга*, описывающую работу мозга на основе информационного подхода и концепции знаний. Эта теория оказалась полезной с точки зрения совершенствования технических интеллектуальных систем.

Специалисты по интеллектуальным системам, использующие когнитив-

Л. А. СТАНКЕВИЧ

ную теорию мозга, стали трактовать познание с технической точки зрения,

системам [11] выделены два класса подходов. *Когнитивистский подход* основан на символьном представлении знаний об окружающем мире и символической обработке этой информации при решении интеллектуальных задач. *Эмерджентный подход* основан на принципах самоорганизации, которая обеспечивает приспособление системы к изменениям, происходящим в окружающем мире.

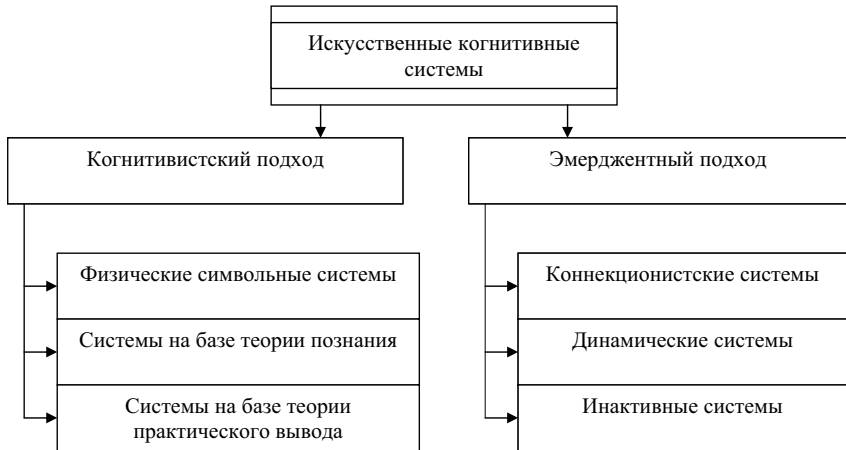


Рис. 1. Классификация когнитивных подходов и систем

Когнитивистский подход соответствует классическому для искусственного интеллекта символистскому представлению когнитивности как способности решать задачи с использованием символических представлений о проблемной области. Такой подход привел к разработке концепции физических символических систем и систем на базе теории познания и практического вывода.

Эмерджентный подход противостоит взгляду на обработку информации в символическом виде и отдает предпочтение позиции, где когнитивность рассматривается как эмерджентная, т. е. неожиданно появляющаяся или развивающаяся в процессе самоорганизации способность рационально решать задачи в структурном или алгоритмическом виде. В эмерджентных когнитивных системах при самоорганизации в зависимости от реализации автоматически создаются коннективистские, динамические или инактив-

ные структуры, активизация которых приводит в итоге к формированию системой рационального поведения.

Различия этих подходов фундаментальны не только в плане манипуляции символами. Основные различия кратко охарактеризованы в табл. 1.

Таблица 1. Сравнение когнитивистского и эмерджентного подходов

Характеристики	Когнитивистские системы	Эмерджентные системы
Вычислительные действия	Синтаксическая манипуляция символами	Конкурентная самоорганизация сети
Структура представлений	Паттерны символьных последовательностей	Глобальные состояния системы
Семантическое основание	Ассоциации типа «восприятие-символ»	Навыки конструирования
Временные ограничения	Не учитываются	Синхронизированная загрузка в реальном времени
Воплощение	Не подразумевается	Подразумевается
Восприятие	Абстрактные символьные представления	Ответ на пертурбации
Действие	Причинное следствие символьных манипуляций	Пертурбация среды системой
Предвидение	Процедурный или вероятностный вывод, использующий априорные модели	Самоэффективное пересечение пространства состояний «восприятие-действие»
Адаптация	Обучение новым знаниям	Развитие новой динамики

Когнитивистские системы

Когнитивизм имеет свое происхождение в кибернетике 1945–56 годов. Именно в этот период намерением кибернетиков было создание науки о мозге, основанной на логике. Основной идеей когнитивизма является утверждение, что познание включает вычисления, определенные через внутренние представления в виде знаний, которые дают абстрактную информацию о мире. Это представление формируется через восприятие, которое определяет подходящую символьную структуру данных, а затем эта структура используется для планирования и действий в мире. Такой подход обозначается как манипуляция символами.

В когнитивистских системах когнитивность обеспечивается манипуляциями с явными символьными представлениями состояния и поведения

во внешнем мире, чтобы обеспечить подходящие адаптивные, основанные на предвидении эффективные взаимодействия, а также накопление знаний, собранных из опыта. Восприятие касается абстракции пространственных и временных представлений внешнего мира из сенсорных данных. Рассуждения производятся через манипулирование символическими представлениями о внешнем мире, которое позволяет изменять конфигурацию мира, возникающую из причинных действий. В большинстве когнитивистских систем символические представления являются продуктом конструктора-человека. Это значит, что такие представления хорошо понимаемы и интерпретируемы людьми. Однако это является и ограничительным фактором когнитивистских систем, поскольку такие создаваемые человеком представления обедняют систему, являясь идеализированными.

Физическая символическая система определена Ньюэллом и Саймоном в их ранней работе по искусственному интеллекту [12]. Понятие физической символической системы эквивалентно автоматической формальной системе. Такая система производит эволюционирующий во времени набор символических структур. *Символ* представляется как физический паттерн, который является компонентом символической структуры.

Ньюэлл и Саймон считали, что в физической символической системе имеют место два сильно связанных рекурсивных процесса (рис. 2): (1) процессы могут производить процессы и (2) паттерны могут назначать паттерны (которые могут быть также и процессами). Согласно этой схеме, система не только может быть построена на абстрактных представлениях и выводах на них, но она может быть модифицирована как функция обоих процессов через текущее состояние (структуру) и ее представление.

Считается, что физические символические системы могут рассматриваться как абстрактные модели когнитивистских систем.

Системы на базе теории познания используют обучение и приобре-

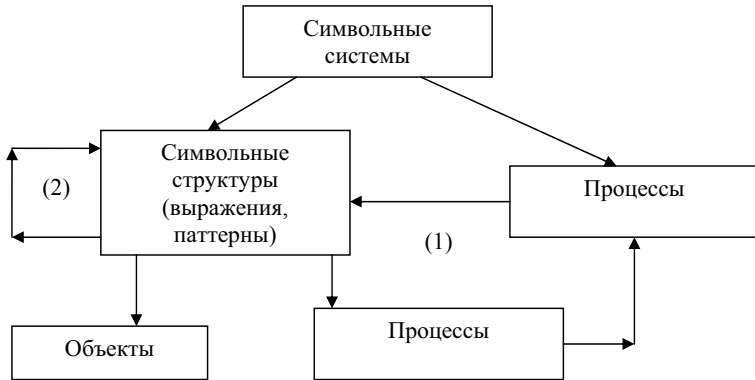


Рис. 2. Физические символичные системы

нимо с поведением людей, которые знают, как хорошо это делать с учетом сделанных ошибок.

Системы на базе теории практического вывода основаны на высокоуровневых психологических концепциях Убеждений, Желаний, Намерений [14]. В таких системах процесс принятия решения о том, что делать, имеет сходство с *практическим выводом*, который применим в нашей повседневной жизни. Основными компонентами этих систем являются структуры данных представляющие убеждения, желания и намерения системы, и функции, которые представляют размышление (решение какие намерения принять, т. е. решения, что делать) и обоснования выбора целей и средств (решения, как это делать).

Эмерджентные когнитивные системы

Эмерджентность имеет другой взгляд на когнитивность, как процесс, при котором система становится жизненной и эффективной в своей среде. Это осуществляется через процесс самоорганизации, который обеспечивает непрерывную перестройку структуры и параметров системы в реальном времени путем взаимодействий системы и среды, в результате которых происходит их взаимное определение (рис. 3). Взаимное определение означает, что когнитивная система определяется в рамках среды и в то же время, что когнитивный процесс восприятия определяет, что является реальным и зна-

чимым для системы. При этом система сама конструирует свою реальность (свой мир) как результат ее действий в этом мире.

Некоторые авторы утверждают, что когнитивность является дополнением восприятия [15]. Восприятие имеет дело с небольшими, а когнитивность — с более долгими временными периодами. Следовательно, когнитивность отражает механизм, через который система компенсирует промежуточную природу восприятия и может, поэтому, адаптироваться к среде и предсказывать ее действия, которые происходят в много больших масштабах времени.

В противовес когнитивистскому подходу, эмерджентный подход предполагает, что первичная модель для когнитивного обучения должна быть основана больше на формировании навыков предсказания, чем на извлечении знаний, и, что процессы, которые управляют действиями и улучшают способность управления действиями, являются корневыми для всех интеллектуальных систем. Хотя когнитивизм влечет за собой абстрактные модели, которые не воплощены в принципе, физическая реализуемость систем не важна в модели когнитивности. В контрасте с этим эмерджентный подход является внутренне воплощенным, т. е. физически реализуемым.

Коннекционистские системы реализуют *параллельную обработку* распределенных паттернов активации, используя статистические свойства, а не логические правила. Термин «коннективизм» еще до эры компьютеров использовался психологом *Торндайком* в 1932 году [16], чтобы охарактеризовать расширенную форму ассоцианизма, основанного на коннекционистских принципах, ясно видимых в модели ассоциативной памяти. Он также предугадал несупервизорный алгоритм обучения, который позднее был предложен физиологом *Хеббом*, который был первым, кто использовал термин «коннективизм» применительно к нейронным сетям [17]. Коннективизм поддерживали *МакКаллок* и *Питс*, поскольку ими было показано, что любое утверждение пропозициональной логики может быть представлено сетью простых обрабатывающих элементов, и эта сеть имеет мощность машины Тьюринга [18].

Системы на нейронных сетях являются примером реализации коннекционистского подхода. Разработка и исследование таких систем связано с известными работами *Розенблатта*, *Хопфилда* и др. Развитие моделей нейронных сетей в PDP-архитектуре *Руммельхарта*, *Вербоса* и др. [19] также внесло значительный вклад в когнитивную науку. Так, эта архитектура увела исследователей от последовательных вычислительных моделей мозга к

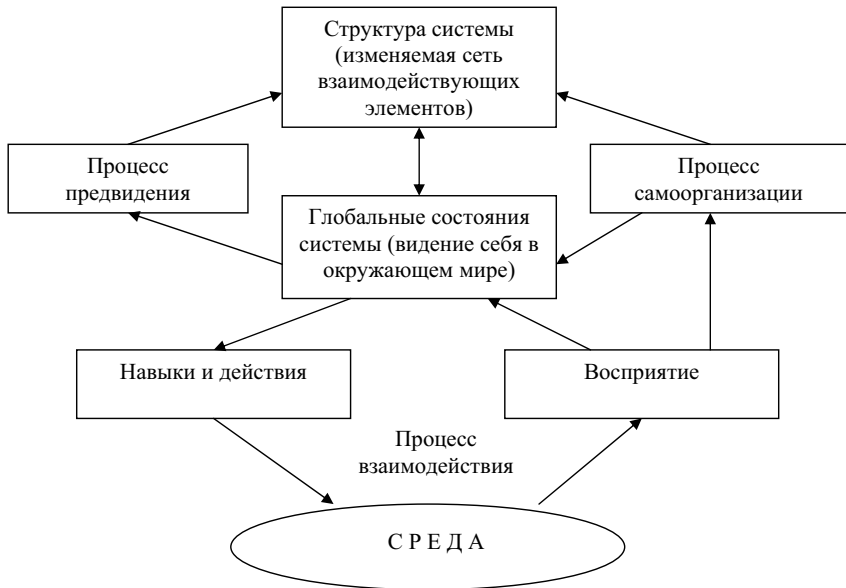


Рис. 3. Эмерджентные системы

параллельно действующим сетям кооперирующихся компонентов.

Динамические системы основаны на результатах *теории динамических систем*, дополняющих классические подходы в искусственном интеллекте [20]. Рассмотрение когнитивности с позиций динамических систем правомерно, поскольку моторные системы и системы восприятия человека являются динамическими.

В общем случае динамическая система является открытой, диссипативной, нелинейной, неустойчивой системой. *Открытость* может рассматриваться как наличие большого числа взаимодействующих компонент, которые можно добавлять или убирать для изменения системы. *Диссипация* означает наличие свойства диффундировать энергию, что уменьшает ее фазовое пространство со временем. *Неустойчивость* в смысле невозможности поддержания структуры или функций без внешних источников энергии и информации является общим свойством. *Нелинейность* позволяет обеспечить сложное поведение при диссипации. При этом только малое

число степеней свободы системы (параметры порядка) вкладывается в ее поведение. Способность характеризовать поведение высоко-размерных систем низко-размерной моделью является одним из отличительных свойств динамических систем от коннективистских.

Нужно отметить тот факт, что динамические системы обеспечивают непосредственно многие характеристики, присущие естественным когнитивным системам, такие как: мультистабильность, адаптивность, формирование образов, распознавание, устремленность, обучение. Эти характеристики достигаются чисто как функции законов динамики и самоорганизации и не требуют символьных представлений.

Динамические системы позволяют непосредственно реализовать *когнитивные функции высокого порядка*, такие как устремленность и обучение [21]. Например, устремленность или целенаправленное поведение достигается суперпозицией функций потенциальных намерений и состояний системы. Обучение видится как модификация паттернов в поведения путем изменения фазового пространства динамической системы.

Можно утверждать, что динамические системы могут обеспечить когнитивные свойства без символьных представлений и вся ментальная активность является эмерджентной, ситуативной и воплощенной. Когнитивность возникает социально, т. е. при динамическом взаимодействии между компонентами. Поэтому когнитивные динамические системы являются воплощенными. Это свойство возникает прямо от процессов самоорганизации, когда система различает сама себя как заметную сущность через ее динамическую конфигурацию и интерактивную деятельность в среде.

Инактивные системы развивают эмерджентную парадигму еще дальше. В противовес когнитивизму в инактивных системах когнитивность рассматривается как процесс, посредством которого могут разрешаться вопросы, важные для непрерывного существования системы, т.е. определение системы происходит при ее взаимодействии со средой, в которой она воплощена. При этом ничего нет заданного заранее и нет нужды в символьном представлении. Вместо этого есть инактивная интерпретация, связанная с выбором подходящих действий, основанных на контексте, в реальном времени. Для инактивных систем цель когнитивности — раскрыть неспецифическую регулярность и порядок, который будет сконструирован как значимый для системы, в процессе непрерывного функционирования и развития когнитивной системы.

Для инактивной системы требуется выполнение только одного фунда-

ментального условия — эффективности действий. Оно обеспечивает непрерывное развитие системы. Это условие связано с тем, что имеется базис порядка в среде когнитивной системы. С этой точки зрения, когнитивность является процессом, путем которого этот порядок или некоторые его аспекты раскрываются или конструируются системой.

Инактивные системы исследуются с 1970-х годов в работах биологов *Матурана* и *Варела* и их последователей [22]. Цель этих исследований — выяснить природу эмерджентности автономных систем. Была найдена концепция, названная *автопоэзисом* или *самопродукцией*, где система проявляется как когерентная системная сущность, выделенная из среды в результате процесса последовательной самоорганизации. В настоящее время различают инактивные системы с различной степенью автопоэзиса.

Системы с *автопоэзисом первого порядка* являются клеточными. Они образуются через структурное связывание со средой. При этом возмущения среды инициируют структурные изменения системы, обеспечивающие продолжение ее функционирования.

Автопоэзис второго порядка соответствует метаклеточным системам, которые образуются путем структурного связывания со средой через нервную систему, способную к ассоциации многих внутренних состояний с различными взаимодействиями, в которые вовлечен организм. В добавление к процессам самопродукции эти системы имеют также процессы саморазвития.

Системы с *автопоэзисом третьего порядка* демонстрируют связывание между системами второго порядка, которые являются автономными когнитивными системами (когнитивными агентами). Характерно, что такие системы обладают способностью пертурбации их собственных организационных процессов и соответствующих структур. Они способны к трем типам поведения: (1) инстинктивному, которое производит организационные принципы, возникающие из филогенетической эволюции системы; (2) онтогенетическому, которое обеспечивает развитие системы в течение жизни; (3) коммуникационному, которое является результатом связывания когнитивных сущностей.

В дополнение к этому *Бигхард* [23] ввел два типа самоорганизующихся систем: (1) самоподдерживающиеся системы, которые делают активные вклады, поддерживающие собственное упорство в достижении целей, но не вкладываются в поддержание условий упорства; (2) рекурсивные самоподдерживающиеся системы, которые делают активные вклады также и в условия упорства.

Гибридные модели и системы

Такие системы комбинируют аспекты когнитивистских и эмерджентных систем [24]. Разработчики гибридных систем опираются на аргументы против использования явных запрограммированных знаний при создании искусственных когнитивных систем и развивают активные системы восприятия, в которых главным стало поведение типа «восприятие-действие», а не абстрагированное восприятие и представление мира. Такие системы могут использовать представления, но эти представления должны быть созданы самой системой в процессе взаимодействия с миром. Как следствие этого подхода можно отметить, что нельзя иметь прямой доступ к внутреннему семантическому представлению мира, и когнитивные системы должны быть воплощенными хотя бы в течение фазы обучения.

Например, результаты недавних исследований привели к разработке когнитивных систем зрения на гибридных принципах [25]. Архитектурно эти системы комбинируют основанные на нейронных сетях компоненты, позволяющие реализовать поведение «восприятие-действие», и символичные компоненты. Другая биологически мотивированная система [26], моделирующая функции мозга и кортикальных путей, продемонстрировала развитие сегментации объектов, распознавания и способности локализации без любых априорных знаний только за счет визуальной информации при эксплуатации и простых манипуляциях. Такие гибридные системы строятся, как правило, как расширения коннекционистских систем и демонстрируют способность учиться на простых объектах и использовать действия человека при обучении через наблюдение.

Когнитивные архитектуры

Наиболее сложно решаемым вопросом является реализация систем, поддерживающих рассмотренные когнитивные парадигмы. Описанные в литературе архитектуры когнитивных систем и агентов типа АСТ [13], SOAR [27], BDI [14] поддерживают когнитивистскую парадигму и носят в основном концептуальный характер. Однако эти архитектуры продолжают развиваться и их рассмотрение полезно не только с теоретических, но и практических позиций.

Архитектуры АСТ. Эти архитектуры [13] основаны на теории АСТ (Adaptive Control of Thought), которая развивает центральную проблему

науки о мышлении — *обучение и приобретение знаний*. Она основана на системе продукций, а также на обобщенной модели мышления человека. Обучение рассматривается как процесс, включающий декларативный и процедурный этапы.

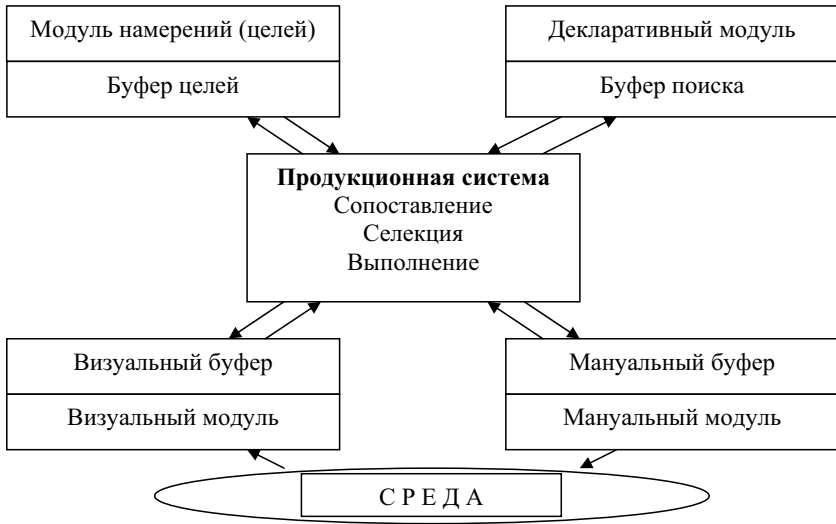


Рис. 4. Архитектура АСТ-R

На декларативном этапе в памяти системы формируются начальные знания в форме высказываний, но их нельзя непосредственно использовать при решении задачи. Высказывания формируются в кратковременной рабочей памяти и предварительно обрабатываются интерпретатором. Когда задача поставлена, то информация о ней, содержащаяся в рабочей памяти, заменяется знаниями из долговременной памяти. Интерпретатором является система универсальных продукций, которая используется для преобразования информации при решении задачи. Такие преобразования выполняются с помощью механизмов процедурализации и композиции. *Процедурализация* состоит в замене переменных в начальных универсальных продукциях на некоторые конкретные значения. *Композиция* обеспечивает слияние независимых продукций и формирование обобщенной продукции, позволяющей за один шаг сделать требуемое действие. Далее обучение

переходит на процедурный этап, соответствующий *координации знаний*. Механизмов координации знаний несколько. *Специализация* обеспечивает создание новой продукции на основе разделения успешно и не успешно применяемых продукций. *Обобщение* объединяет продукций, порождающие один результат. *Усиление* позволяет повысить приоритет часто используемых продукций, чтобы при сопоставлении они использовались еще чаще. Это приводит к стабилизации процесса решения задачи.

Для реализации АСТ теории разработаны и исследуются несколько архитектур, которые постоянно модернизируются. Один из последних и наиболее интересный вариант архитектуры, названный АСТ-R (Rational), представлен на рис. 4. Эта архитектура содержит 5 модулей. Модуль цели следит за внутренним состоянием системы, формирует набор целей, которые определяют поведение системы при достижении этих целей. Решение задач определяется текущими целями, в соответствии с которыми генерируются действия. Декларативный модуль ищет информацию в долговременной памяти, которая содержит декларативные знания. Визуальный модуль обрабатывает сенсорную информацию о среде. Мануальный модуль формирует моторные действия, которые изменяют окружающую среду. Производственная система включает процедурную память и координирует действия всех перечисленных модулей, разрешая конфликты, возникающие, если поиск решений требует реализации (поджигания) сразу нескольких продукций. Это делается через 4 буфера: целей, поиска, визуальный и мануальный. АСТ-R действует в циклической манере: паттерны, находящиеся в буферах (определяемые внешним миром и состоянием системы), распознаются, одиночные продукций запускаются и буферы модернизируются.

Архитектура SOAR. Эта обобщенная архитектура [27] когнитивных агентов, решающих задачи с использованием производственных правил, поддерживается языком и программным интерпретатором. Исходно она использует методы компиляции знаний, подобные предложенным в теории АСТ, и позволяет строить целенаправленных агентов, которые могут быть охарактеризованы в терминах их целей, пространства задачи, состояний, операторов и ассоциативных предпочтений. Предпочтения могут быть использованы, чтобы организовать разделяемые нормы для выбора существующих, приемлемых или ранжированных целей, состояний пространства задачи и операторов. Цели агентов могут быть автоматически генерированы или сознательно выбраны агентом, как разумной сущностью. Долговременная база знаний агента содержит набор правил. Кратковременная память

фиксирует набор текущей информации.

SOAR может рассматриваться как программная реализация *унифицированной теории познания*. Эмпирические исследования выявили, что во многих примерах поведение SOAR сравнимо с поведением людей, которые знают, как хорошо это делать и знают об ошибках, которые сделаны. Структура системы изменяется в ответ на изменения среды, поскольку она встроена в базу знаний и связана с процедурой реструктуризации индивидуальных и коллективных действий при различных условиях.

Более поздние разработки Plural SOAR и TAC Air SOAR основаны на более полных моделях человеческого познания и используются для построения когнитивных агентов для коллективной работы. *Многоагентные варианты* SOAR обеспечивают моделирование команд как коллектива SOAR-агентов. Многоагентный SOAR строится с использованием трех ключевых идей: внутренних моделей других агентов команды, когнитивных структур общения (социального поведения) и коммуникации. Каждый член команды является агентом с ментальной моделью поведения, о которой другие агенты или знают, или будут знать в определенных обстоятельствах. Эти знания могут включать представления о целях и предпочтениях других агентов, что позволяет агенту предполагать, что будут делать другие агенты. Каждый агент команды имеет разделяемые знания о когнитивной социальной структуре. Эта структура определяет восприятие агента, которое дает информацию о том, с кем взаимодействовать, как и о чем договариваться. В итоге, агент команды имеет знания о том, как реализовать коммуникации и что, когда и кому передавать и как составлять сообщения. Коммуникация в этих моделях управляется путем передачи соглашений со специальным, связанным с задачей содержанием.

Архитектура BDI. Агенты, которые оперируют ментальными понятиями убеждений, желаний и намерений, названы BDI (Belief-Desire-Intention) агентами [14, 28]. Процесс практического вывода в BDI-агенте использует семь основных компонент:

- набор текущих убеждений, представляющий собой информацию агента о текущем окружении;
- функцию пересмотра убеждений, ($br\ f$) которая воспринимает вход очувствления и текущие убеждения агента и на основе этого определяет новый набор убеждений; варианты доступные для агента (его желания) на основе текущих убеждений об его окружении и его текущих намерений;

- набор текущих вариантов, представляющий собой возможные направления действий доступные для агента;
- функцию фильтра (filter) которая представляет собой процесс размышления агента, и который определяет намерения агента на основе его текущих убеждений, желаний и намерений;
- набор текущих намерений, представляющий собой текущий фокус агента — состояния тех мероприятий, которые были намечены для выполнения;
- функцию выбора действия (execute) которая определяет, какое действие должно быть выполнено исходя из текущих намерений.

Можно формально определить эти компоненты. Первое, пусть Bel будет набором всех возможных убеждений, Des — набором всех возможных желаний, и Int — набором всех возможных намерений. Для целей этого раздела неважно, что содержат эти наборы. Однако чаще всего убеждения, желания и намерения представлены формулами логики, возможно первого порядка. Из чего бы не состояли эти наборы, неважно, кроме того, что они имеют некоторую совместимость, определенную в них такую, что можно ответить на вопрос, например, согласуется ли намерение достигнуть x с некоторыми убеждением y .

Представление убеждений, желаний и намерений логическими формулами требует выяснения вопроса, являются ли эти логические формулы непротиворечивыми (это — хорошо известная и хорошо понятная проблема).

Состояние BDI-агента в каждый данный момент является тройкой

$$(B, D, I), \text{ где } B \subseteq Bel, D \subseteq Des, I \subseteq I.$$

Функция пересмотра убеждений отображает:

$$brf : \wp(Bel) \times \wp(Int) \rightarrow \wp(Des),$$

которая, основываясь на текущем восприятии и текущих убеждениях, определяет новый набор убеждений. Пересмотр убеждений выходит за рамки этого раздела и больше здесь обсуждаться не будет.

Делиберативный процесс в BDI-агенте (формирующий решение, что делать) представлен двумя функциями. Первая — функция выработки вариантов, отображает набор убеждений и набор намерений на набор желаний:

$$options : \wp(Bel) \times \wp(Int) \rightarrow \wp(Des).$$

Эта функция выполняет несколько ролей. Так, она отвечает за обоснование выбора целей и средств — процесс принятия решения о том, как достичь желаний. Таким образом, как только агент сформировал свои намерения x , он также должен одновременно рассмотреть варианты достижения x . Эти варианты будут более конкретными (менее абстрактными), чем x . Так как некоторые из этих вариантов сами станут намерениями, они также будут участвовать в генерации вариантов и, таким образом, еще более конкретизируют варианты, которые будут генерироваться. В таком же плане можно рассматривать процесс генерации вариантов в BDI-агенте, как некоторую рекурсивно вырабатываемую структуру иерархического вида, которая реализует переходы ко все более специфическим намерениям, пока в конце концов не будут достигнуты намерения, которые соответствуют немедленно выполнимым действиям.

В то время как основной целью функции *options* является обоснование выбора целей и средств, она, кроме того, должна удовлетворять некоторым другим ограничениям. Во-первых, она должна быть непротиворечивой: любые выработанные варианты должны не противоречить ни текущим убеждениям, ни текущим намерениям. Во-вторых, она должна быть своевременной, т.е. она должна распознавать ситуацию, когда обстоятельства окружающей среды изменяются в выгодную сторону, чтобы предложить агенту новые пути достижения намерений или возможность достижения намерений, которые были бы не достижимы в противном случае.

Вторая функция делиберативного процесса — функция *filter*

$$filter : \wp(Bel) \times \wp(Del) \times \wp(Int) \rightarrow \wp(Int),$$

которая обновляет намерения агента, исходя из ранее принятых намерений и текущих убеждений и желаний. Эта функция

ограничению:

$$\forall B \subset \wp(Bel), \forall D \subset \wp(Des), \forall I \subset \wp(Int), filter(B, D, I) \subseteq I \cup D.$$

Другими словами, текущими намерениями являются намерения, принятые ранее, или новые принятые варианты.

Функция *execute* предполагается как просто возвращающая любые выполнимые намерения, т. е. те намерения, которые соответствуют непосредственно выполняемым действиям:

$$execute : \wp(Int) \rightarrow A.$$

Функция принятия решения *action* BDI-агента формирует действия по восприятию:

$$action : P \rightarrow A$$

и реализуется путем выполнения всех описанных ранее функций.

Завершающий вывод (means-ends reasoning) является процессом, решающим, как достичь конца всего практического вывода (т.е. намерения, которое агент имеет), используя пригодные средства, т. е. действия, которые агент может выполнять. Такой вывод более известен в искусственном интеллекте, как планирование. В нашем варианте планировщик реализует алгоритм планирования, имея входную информацию в виде: (1) цели, намерения или задачи; (2) текущего состояния среды, т. е. убеждения агента; (3) действия, которые может выполнять агент. На выходе алгоритм планирования генерирует *план* в виде набора действий, который должен привести к достижению цели. Заметим, что первым реальным планировщиком можно считать систему STRIPS, разработанную в 1960-е годы. В ней планирующий алгоритм был основан на принципе нахождения разности между текущим состоянием мира и целевым состоянием и уменьшении этого различия путем применения подходящих действий. Для описания состояний использовалась логика предикатов первого порядка.

Рассмотренный алгоритм реализуется в структуре, представленной на рис. 5.

Формально способность агента выполнить завершающий вывод может быть представлена функцией планирования в виде:

$$plan : \rho(Bel) \times \rho(Int) \times \rho(Ac) \rightarrow Plan,$$

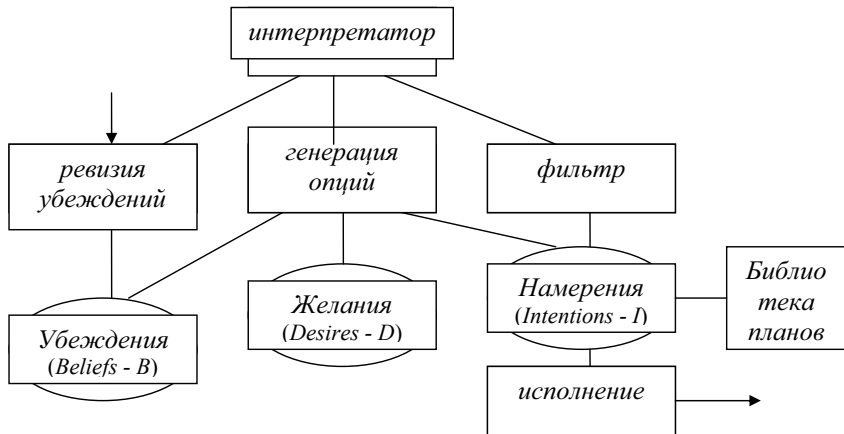


Рис. 5. Структура BDI-агента

которая на основе текущих убеждений и намерений определяет план для достижения этих намерений. Однако во многих реализациях агентов с практическим выводом функция планирования реализуется упрощенно путем придания агенту библиотеки планов, которая является подготовленным заранее набором планов. Нахождение плана для достижения текущего намерения в этом случае выполняется одним проходом по библиотеке планов, в результате которого выбирается план, позволяющий достичь намерения как постуловия при предусловиях, определяемых текущими убеждениями.

BDI-модель привлекательна по нескольким причинам. Во-первых, эта модель интуитивна: мы все понимаем процесс принятия решения, что делать, и потом, как делать, и мы все имеем естественное понимание идей убеждения, желания, и намерения. Во-вторых, эта модель дает явное функциональное разбиение, которое указывает, какого типа подсистемы могут потребоваться при построении агента. Но основной трудностью при построении этой модели является знание того, как эффективно реализовать функции, определяющие функционирование модели.

Архитектура Darwin. Эта нейроподобная архитектура поддерживает эмерджентную парадигму. Под таким названием разработана серия платформ для экспериментирования в области управления роботами [29]. Эти платформы имеют также общее название “Brain-Based Devices — BBD”, что

дословно означает «Приборы, основанные на мозге». На самом деле BBD можно рассматривать как модель нервной системы, которая может развивать пространственную и эпизодическую память, а также способности распознавания путем автономного обучения через экспериментирование. В этом плане BBD наиболее близка к коннекционистским и инактивным моделям. В отличие от большинства коннекционистских моделей, эта архитектура более сильно моделирует структуру и организацию мозга, чем искусственные нейронные сети. В настоящее время такой подход называют также нейроморфным, что предполагает уход от известных моделей формальных нейронных сетей и попытки реализации моделей функциональных частей мозга и нервной системы в виде программ для универсальных ЭВМ или даже специализированных аналоговых и цифровых микросхем. Средствами BBD возможно, как грубое моделирование нервной системы в целом, так и более тонкое моделирование ее частей и их взаимодействий, что позволяет проводить эксперименты по реализации нейросетевых механизмов для разных видов памяти, распознавания и управления.

Главные нейронные механизмы BBD-подхода — синаптическая пластичность, поощрения или оценивание системы, входящие связи, динамическая синхронизация нейрональной активности, нейроподобные элементы с пространственно-временными свойствами. Адаптивное поведение достигается через взаимодействие этих нейронных механизмов с сенсомоторными компонентами, которые обучаются автономно путем активного очувствления и самодвижения.

Проект Darwin в своем развитии прошел ряд этапов. Наиболее интересные результаты получены на последних этапах проекта. Так, Darwin VIII был способен к различению простых визуальных целей (цветных геометрических форм) путем ассоциации их с врожденно предпочитаемыми аудио репликами. Для моделирования этих способностей использовалась модель нервной системы с 28-ю нейрональными областями, содержащими около 54 тысячи нейронных элементов с 1.7 млн. синаптических связей. Эта система моделирует основные регионы зрения коры головного мозга, тренинга, оценки и аудио обработки. Регионы зрения имеют сложные связи и обрабатывают сигналы рецептивных полей (изображений) после предварительной фильтрации гауссовскими фильтрами с вертикальной, горизонтальной и диагональной разверткой, а также красно-зелеными цветными фильтрами. Область тренинга определяет направление видения камеры (пристальный взгляд), которое формируется на основе возбуждающих проекций аудио региона. Это позволяет системе ориентироваться на на-

правление источника звука. Взаимодействие регионов зрения и тренинга обеспечивает перемещение системы к центру пристального взгляда на визуальный объект. Регион оценивания имеет адаптивные связи с регионом тренинга, чем достигается обучение выбору цели. Адаптация осуществляется с использованием специального правила, которое подобно известному правилу Хебба. Поведенческой особенностью Darwin VIII является предпочтение одной цели над другими за счет врожденного механизма ассоциации выбираемой цели звуковым репликам. Такое предпочтение демонстрируется путем ориентации по направлению к цели.

Darwin IX может выполнять навигацию и категоризировать структуры, используя искусственные усы, моделируемые на основе нейроанатомических структурах соматосенсорной системы крысы, которая включает 17 регионов с 1101 нейронных элементов и около 8400 синаптических связей.

Darwin X способен развивать свою пространственную и эпизодическую память, построенную на модели гиппокампа и окружающих его регионов. Его модель нервной системы содержит 50 нейрональных областей, включающих 90000 нейронных единиц с 1.4 млн. синаптических связей. Эта платформа включает визуальную систему, систему направления головы, формацию гиппокампа, базальный отдел мозга, систему оценки-ощущения и систему выбора действий. Визуальная система позволяет распознавать объекты, а затем вычислять их позицию, тогда как средства одометрии (визуальных измерений) используются, чтобы чувствовать направление головы.

Архитектура Cog. Эта архитектура развита Бруксом и Сказелатти в рамках проекта Cog для проведения когнитивных исследований с использование роботов [30]. Она поддерживает парадигму гибридных когнитивных систем.

В рамках проекта Cog проводились работы в области теории мозга, которые фокусировались на социальных взаимодействиях, как ключевом аспекте когнитивной функции в тех социальных навыках, которые требуют атрибутов Убеждений, Целей и Желаний по отношению к другим людям. Робот, поддерживающий теорию мозга, должен быть способен к обучению из наблюдений, используя нормальные социальные сигналы, и способен к выражению его внутреннего состояния (эмоций, желаний, целей) через социальные (несимвольные) взаимодействия. Он должен быть способен распознавать цели и желания других и, как следствие, предвидеть реакции наблюдателя и модификации своего собственного поведения

в соответствии с этим.

Архитектура Cog создавалась с целью проводить исследования в области теории мозга, предложенной Сказелатти [31]. Эта теория комбинирует модели Лесли [32] и Барон-Кохена [33], которые декомпозируют проблему в наборы навыков предшественников и моделей развития. Теория Лесли объединяет независимые специфицированные по областям модули для различения: (1) механического агентства; (2) агентства действий и (3) агентства позы. Грубо говоря, моделируется поведение неанимированных и анимированных объектов, а также убеждение и намерение анимированных объектов. Теория Барон-Кохена включает три модуля: (1) интерпретации воспринимаемых стимулов (визуальных, аудио и тактильных); (2) интерпретации визуальных стимулов, ассоциированных с глазо-подобными формами; (3) внимания, которое использует информацию от первых двух модулей. Третий модуль, в свою очередь, передает вырабатываемую информацию на Модуль теории мозга, который представляет знания о намерениях или «эпистемические ментальные состояния» других агентов.

Исследования проводились на платформе (роботе), представляющей собой верхнее-торсовую часть гуманоидного робота с двумя руками по 6 степеней подвижности (СП), торсом с тремя СП, головой и шеей с 7-ю СП; всего 22 степени подвижности. Платформа оснащена двумя бинокулярными визуальными системами: широкоугольной и узконаправленной; аудио-системой с двумя микрофонами, трех степенной вестибулярно-окулярной системой и набором тактильных сенсоров.

Теория мозга Сказелатти, позволила воспроизвести в системе Cog, которая управляла роботом, навыки восприятия и моторные навыки предшественника, на которых могли быть построены более сложные способности, предусмотренные в теории: различение между неанимированными и анимированными движениями и идентификация направления взгляда. Они используют несколько построенных на видеообработке способностей, таких как: (1) выбор направления по цвету объектов; (2) детектирование движений; (3) детектирование цвета кожи; (4) оценка неравенства объектов; (5) визуальный поиск и внимание; (6) видео моторные управления; (7) рефлекс сглаживания-слежения; (8) движение головы и шеи.

Разработка гибридных когнитивных систем

Обзорные материалы предыдущих разделов позволяют сделать вывод о малой значимости когнитивистского подхода для практического создания

искусственных когнитивных систем. С практической точки зрения лучшие результаты может дать гибридный подход, в котором преобладают идеи, положенные в основу эмерджентных систем. Работы автора и его коллег в этом направлении, проводимые с 1998 года, позволили выработать определенную методологию разработки искусственных когнитивных систем гибридного типа.

В данном и в последующих разделах обсуждаются когнитивные концепции, гибридные архитектуры, построенные на их основе, специальные когнитивные средства и способы реализации на них когнитивных систем с предлагаемыми архитектурами.

Когнитивные концепции

Реализация искусственных когнитивных систем требует, прежде всего, разработки соответствующих когнитивных концепций. Понятие «когнитивные концепции», с недавних пор применяемое в машинном интеллекте, относится к некоторым полезным с технической точки зрения концепциям, инспирированным из психологии. В данной работе это понятие расширяется за счет концепций, построенных на основе последних достижений когнитивной науки и нейрофизиологии [34].

Исследования, проведенные на основе последних результатов когнитивной науки в области когнитивных функций и процессов познания и мышления, позволили сформировать «концепцию когнитивной функциональности», которая предполагает, что когнитивные процессы строятся на основе композиции когнитивных отношений, которые, в свою очередь, состояются из когнитивных функций. Эта концепция оказывается полезной для формального описания когнитивных систем в функциональном плане. Оказалось полезным ввести также *концепцию когнитивного конструктивизма*, основанную на исследованиях в области нейрофизиологии. Эта концепция определяет возможность реализации когнитивных процессов путем конструирования специальных когнитивных структур из вложенных когнитивных элементов, которые способны реализовать когнитивные отношения и функции.

Концепция когнитивной функциональности основана на обобщении исследований в области когнитивной науки, в результате которого оказалось возможным выделить и связать ряд функциональных когнитивных и эффекторных компонент нервной системы человека в схему, представленную на рис. 6. Эта схема включает три функциональных компонента: *Процессы преобразования, Сенсорные процессы и Эффекторные процессы*. Процессы преобразования образуются объединением когнитивных отношений преобразования, которые, в свою очередь, составлены из когнитивных функций преобразования. Сенсорные процессы составлены из когнитивных отношений и функций восприятия, а эффекторные процессы — из эффекторных отношений и функций действий. Дополнительные функции связности процессов обеспечивают взаимодействие этих разнородных процессов.



Рис. 6. Схема функциональных компонент разных уровней

Иерархия функциональных компонент дает возможность выделить три уровня композиции. На самом нижнем уровне имеют место *когнитивные функции*, т. е. отображения нескольких входных аргументов в одно возвращаемое значение функции (параметр выхода). Следующий уровень включает *когнитивные отношения*, т. е. отображения нескольких входных аргументов в несколько выходных значений отношения. Заметим, что отношения составляются из функций и, в отличие от функций, могут быть обратимыми. На третьем уровне формируются *когнитивные процессы*, составленные из цепочек функций и отношений. Процессы могут связываться на уровне *композиций процессов* с использованием когнитивных функций *связности* процессов.

Концепция когнитивного конструктивизма построена на основании сведений о структурной организации нервной системы человека [4] и технических возможностей конструирования сложных систем. Обобщение этих сведений дало возможность предложить для построения когнитивных систем конструктивные принципы: модульности, иерархичности, вложенности, полной связности в пределах уровня, пирамидального управления элементами компонентов нижних уровней сигналами от верхних уровней.

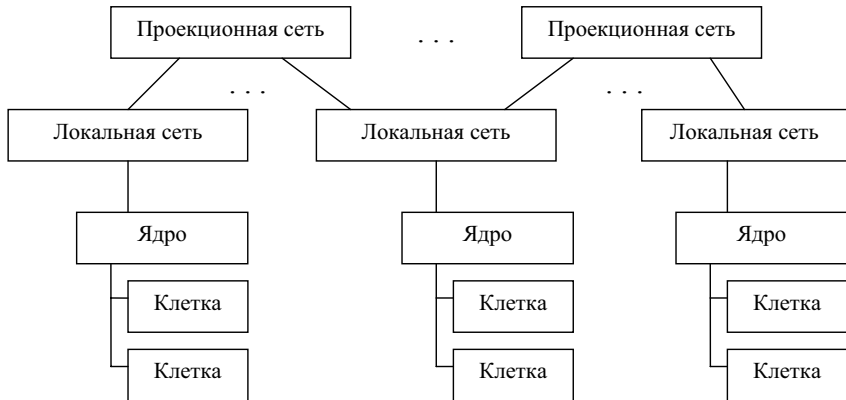


Рис. 7. Конструктивная схема системы

Построенная по этим принципам конструктивная схема системы представлена на рис. 7. Структура включает 4 уровня иерархии и вложенности:

уровень 1: Проекционные сети, рассматриваемые как подсистемы, объ-

единение которых образует систему в целом; они состоят из связанных наборов Когнитивных компонентов типа Клеток, Ядер и Локальных сетей.

уровень 2: Локальные сети, состоящие из наборов Когнитивных элементов типа Клеток и Ядер и вкладывающиеся в Проекционные сети.

уровень 3: Ядра, состоящие из наборов Когнитивных компонентов типа Клеток и вкладывающиеся в Локальные и Проекционные сети.

уровень 4: Клетки, являющиеся неделимыми Когнитивными компонентами, вкладывающимися в Ядра, Локальные и Проекционные сети.

Каждый когнитивный компонент этой схемы реализует определенный функциональный компонент. Так, Клетка реализует простую *когнитивную функцию*, Ядро — *простое когнитивное отношение*, связанное с представлением и распознаванием образов, а Локальная сеть — *сложное когнитивное отношение*, связанное с преобразованием образов. Подсистема внутри этой схемы является функционально самостоятельной и отвечает за *когнитивный процесс*, поддерживающий определенное поведение. Допустимы связи между Подсистемами и, значит, когнитивными процессами.

Концепции когнитивной многоагентности поддерживают гипотезу о существовании некоторых автономных когнитивных сущностей в нервной системе человека [35]. Эта гипотеза соответствует последним результатам исследований в области когнитивной теории мозга и нейрофизиологии и позволяет связать знания о строении и функционировании нервной системы. Так, нейрофизиологи частично прояснили локализацию некоторых когнитивных процессов в нейронных структурах мозга. Показано также превалирующее значение замкнутых подсистем внутри нервной системы человека, которые реализуют поведенческие процессы. Эти подсистемы представляют собой цепочки нейронных модулей (локальных сетей), распределенные по ряду областей нервной системы. Такие цепочки взаимодействуют между собой в перекрывающихся областях мозга. Функциональные объединения таких цепочек, отвечающие за определенные наборы поведений, можно считать *агентами нервной системы*. Такие агенты могут конкурировать между собой или кооперироваться для организации сложного поведения. В соответствии с этой гипотезой было введено понятие *когнитивного агента*, а также разработана методология создания *многоагентных когнитивных систем управления* [36].

Концепции когнитивной многоагентности определяют поведение когнитивных агентов. Предполагается, что такие концепции, инспирированные изучением психологии человека, могут сыграть ключевую роль в развитии искусственного интеллекта [37]. Они включают три высокоуровневые концепции: *Убеждение*, *Желание*, *Намерение*, обозначаемые в литературе аббревиатурой BDI (Belief-Desire-Intention), и, дополнительно, *Умение* (Know-How) и *Обязательство* (Commitment). Считается, что во многих случаях метафора агента наиболее полезна, когда используются именно такие *высокоуровневые когнитивные спецификации*. Они дают возможность определить: (1) текущее состояние агента; (2) действие, которое агент мог сделать и (3) как агент мог бы вести себя в различных ситуациях без рассмотрения того, как он реализован.

Когнитивный агент является интеллектуальным и в нем может быть использован строгий логический вывод (*теоретический вывод*), но в большинстве случаев менее строгие процессы принятия решений могут быть более эффективными. Хорошие результаты может дать модель принятия решений, названная *практическим выводом*.

Намерение определяет состояние, выбранное агентом как конечное и обязательное для достижения. Намерение может касаться текущих действий или направлено на будущее. В большинстве случаев оно является утверждением позиции (отношения) и имеет тенденцию вести к действию.

Убеждение связывается со знаниями агента в определенные моменты времени. Знание обычно определяется как истинное убеждение. В модальной логике убеждение описывается модальным оператором необходимости.

Желание ассоциирует с каждым моментом времени множество моментов, представляющих желания агента. Агент имеет желание в данный момент времени, если оно истинно во всех доступных мирах агента в этот момент. Желания являются входами в процесс рассуждений агента, которые позволяют ему выбрать цели.

Умение является ключевым моментом успешной реализации намерения. Оно включает набор действий для удовлетворения намерения. Предполагается, что агент знает, как достичь намерения, если он способен соотнести намерение и свои действия, т. е. обеспечить выполнение намерения.

Обязательство означает свойство агента обязательно иметь намерение. Обязательство агента управляет тем, как он будет упорствовать при достижении намерения и как это будет долго. Обязательство может рассматриваться также как ограничение для агента.

Когнитивный агент гибридной архитектуры

Анализ возможностей разных когнитивных архитектур показал, что на практике в основном используются *агенты реактивной архитектуры с когнитивными компонентами*, которые обеспечивают им свойство адаптивности. Однако при проектировании когнитивных агентов со сложным поведением может дать хорошие результаты только их комбинирование разных архитектур. Как пример такого комбинирования рассмотрим *гибридную архитектуру когнитивного агента*, построенную на основе описанных здесь когнитивных концепций.

Гибридная архитектура агента (рис. 8) включает два верхних уровня с архитектурой BDI [14] для организации индивидуальной и коллективной работы агента и нижний исполнительный уровень с архитектурой Subsumption [38].



Рис. 8. Когнитивный агент гибридной архитектуры

Нижний уровень когнитивного агента полностью реактивный. Он непосредственно получает информацию от сенсоров объекта и посылает управ-

ляющие инструкции к его исполнительным устройствам (эффекторам). Уровень имеет несколько слоев, каждый из которых формирует свое реактивное поведение. На этом уровне предусмотрен специальный механизм выбора действия, основанный на иерархии слоев и приоритетах. Чем выше по иерархии находится слой, тем больше его приоритет. Если в текущей ситуации формируют реакции одновременно несколько слоев, для исполнения выбирается тот слой, текущий приоритет которого выше.

Средний уровень агента использует информацию об индивидуальных желаниях и убеждениях. Убеждения формируются путем обработки сенсорной информации в процессе мониторинга окружающей среды. При этом распознаются и регистрируются значащие события. На основе информации о событиях, текущих желаниях и убеждениях агента формируется маска приемлемых в текущей ситуации действий. На основе этой маски формируются текущие намерения агента. По текущим намерениям агента выбирается подходящий план его действий, в соответствии с которым настраиваются приоритеты слоев нижнего уровня агента.

Верхний уровень агента отвечает за координацию убеждений взаимодействующих агентов и разрешение конфликтов между агентами, которые могут иметь разные намерения. При этом детектируются конфликты между намерениями одного агента и убеждениями другого. Результатом работы этого уровня является формирование общих намерений взаимодействующих агентов. Общие намерения достигаются путем переговоров агентов и взаимной коррекции их убеждений, которые изначально могут существенно различаться.

Когнитивные агенты гибридной архитектуры могут обеспечить сложное человекоподобное коллективное поведение интеллектуальных роботов в условиях непредсказуемой динамически изменяемой среды [39].

Средства реализации когнитивных систем

Используя формализованные методы обучения и решения задач, можно создавать когнитивные модули и структуры, способные отображать когнитивные функции и моделировать когнитивные процессы [9].

Когнитивные модули строятся на сетях элементов с разными вычислительными базисами и регулируемыми связями между ними. Настройка на отображение конкретных когнитивных функций осуществляется путем обучения по примерам точечного отображения этих функций, которые формируются учителем или автоматически отбираются из генерируемого набора

ра примеров. *Когнитивные структуры* строятся как сети когнитивных модулей, соединенных прямыми и обратными связями. Каждая когнитивная структура должна воспринимать цели, ограничения и вырабатывать сигналы селекции поведения в зависимости от текущей ситуации (состояния агента и внешнего мира). На выходах когнитивной структуры формируются последовательные сигналы активизации действий, соответствующих ее уровню. Связи между модулями отображают передачи выработанных ими сигналов другим модулям или обратных сигналов от них. Эти связи настраиваются путем обучения во времени для когнитивных процессов.

Когнитивные модули и структуры сетевого типа могут быть реализованы на формальных нейронных сетях. Однако на базе традиционных нейронных сетей оказалось трудно, а иногда и невозможно, реализовать, например, сложное человекоподобное поведение интеллектуальных роботов. Поэтому был разработан целый набор разных средств, более пригодных для реализации когнитивных систем. В этот набор входят: нейрологические, иммунологические и поведенческие сети, триангуляционные модули.

Применение нейрологических модулей и обучения с подкреплением в агентах-игроках для футбола роботов

Специальные *нейрологические модули* (клетки и ядра) позволяют более эффективно, чем нейронные сети, реализовать многие когнитивные функции и отношения в процессах восприятия информации и принятия решений. Разработаны и исследованы несколько вариантов нейрологических модулей: с нейронно-логическим базисом на основе мозжечковой модели, а также с нечетко-логическом базисом на основе сеточной и кластерной моделей. Они настраиваются путем обучения с подкреплением.

Обучение с подкреплением основано на взаимодействии обучаемого объекта с окружающей средой с целью достижения некоторой цели [40]. Такой тип обучения в сочетании нейрологическими модулями оказался эффективным при управлении командной работой агентов-игроков в плохо определенных многоагентных игровых средах [41]. Оно дает возможность автоматически сформировать нужные правила поведения агента при отработке сценарных эпизодов.

Агент и окружающая среда взаимодействуют друг с другом в дискретные моменты времени t_k , $k = 0, 1, 2, 3, \dots$. В каждый момент времени t , агент получает некую информацию об окружающей среде $s_t \in S$, где

S — множество всевозможных состояний, и на этом основании выбирает действие $a_t \in A(s_t)$, где $A(s_t)$ — множество возможных действий в состоянии s_t . В следующий момент времени t_{k+1} агент получает подкрепление $r_{t+1} \in R$ и оказывается в новом состоянии s_{t+1} . В каждый момент времени агент осуществляет отображение текущего состояния в вектор, содержащий числовые значения, характеризующие каждое из возможных действий. Такое отображение называется политикой агента, и обозначается, как π_t . Методы обучения с подкреплением позволяют определить, как агент должен изменять свою политику в соответствии с опытом. При этом агент максимизирует суммарное значение подкреплений (наград), которое он может получить.

Один из известных методов обучения с подкреплением называется *Sarsa*(λ). Базовый алгоритм *Sarsa*(λ) дает возможность вычислять функцию $Q(s, a)$, определяющую значимость действий агента в текущих ситуациях. Обучение проводится по эпизодам и шагам внутри них. При этом формируется $e(s, a)$ — вектор траекторий значений $Q(s, a)$, аппроксимация которого запоминается как результат обучения (политика). Этот метод был применен для обучения правильному поведению виртуального агента-игрока в среде виртуального футбола роботов.

На рис. 9 представлен модифицированный алгоритм *Sarsa*(λ), приспособленный к обучению агента-игрока в среде футбола роботов. В этом алгоритме введены три базовых функции, раскрыт метод выбора действий во время обучения, способ обновления траекторий значений $Q(s, a)$ и отображение входного вектора в активные рецепторные поля. Базовые функции имеют следующее назначение. Функция *BeginEpisode*() — агент вызывает эту функцию в начале каждого эпизода. Функция *DoEpisodeStep*() — агент вызывает эту функцию, когда происходит очередной шаг эпизода. Очевидно, что эти функции будут вызываться, какой бы задаче не обучался модуль. Функция *EndEpisode*(*boolsuccess*) имеет смысл и будет вызвана только для задач, в которых есть понятие и имеет смысл специально обрабатывать терминальное состояние. *Success* — параметр, определяющий, закончился ли эпизод успешно — *true*, или неуспешно — *false*. В строке 3 алгоритма происходит отображение входного вектора в активные рецепторные поля *нейрологического модуля на основе мозжечковой модели*. В строке 4 происходит определение q -значений каждого действия для текущего состояния. В строке 5 определяется действие, которое будет выбрано. Обычно выбирается действие с максимальным значением. Параметр ε обычно выбирают из диапазона $(0, 0.05]$. В строках 11–16 происходит обновление траекторий

```

BeginEpisode ()
1    $currentStep \leftarrow 1$ 
2    $\bar{e} = 0$ 
3    $T \leftarrow$  множество активных полей для нового (текущего) состояния  $s$ 
4    $\bar{Q}_a \leftarrow \{\sum_{i \in T} \theta(i)\}_j, j = \overline{1, n}, n -$  количество возможных действий
5    $lastOption \leftarrow \begin{cases} \arg \max_a \bar{Q}_a & \text{с вероятностью } 1 - \varepsilon \\ random(\arg \bar{Q}_a) & \text{с вероятностью } \varepsilon \end{cases}$ 
7    $Q_{lastOption} \leftarrow \bar{Q}_{lastOption}$ 
DoEpisodeStep ()
8    $currentStep \leftarrow currentStep + 1$ 
9   if (stepLimit && currentStep > MAX_STEPS) return false
10   $T \leftarrow$  множество активных полей для предыдущего состояния  $s$ 
11  для всех вариантов действий  $a$ 
12    для всех  $i \in T$ 
13      если  $a = lastOption$ 
14         $e(i) = 1$ 
15      в противном случае
16         $e(i) = 0$ 
17   $T \leftarrow$  множество активных полей для нового (текущего) состояния  $s'$ 
18   $\bar{Q}_a \leftarrow \{\sum_{i \in T} \theta(i)\}_j, j = \overline{1, n}, n -$  количество возможных действий
19   $newOption \leftarrow \begin{cases} \arg \max_a \bar{Q}_a & \text{с вероятностью } 1 - \varepsilon \\ random(\arg \bar{Q}_a) & \text{с вероятностью } \varepsilon \end{cases}$ 
20   $Q_{newOption} \leftarrow \bar{Q}_{newOption}$ 
21   $\delta \leftarrow rewardForStep + \gamma Q_{newOption} - Q_{oldOption}$ 
22   $\bar{\theta} \leftarrow \bar{\theta} + \alpha \delta \bar{e}$ 
23   $Q_{lastOption} = Q_{newOption}$ 
24   $\bar{e} \leftarrow \lambda \bar{e}$ 
EndEpisode (bool success)
25   $numberOfPlayedEpisodes \leftarrow numberOfPlayedEpisodes + 1$ 
26   $T \leftarrow$  множество активных полей для предыдущего состояния  $s$ 
27  для всех вариантов действий  $a$ 
28    для всех  $i \in T$ 
29      если  $a = lastOption$ 
30         $e(i) = 1$ 
31      в противном случае
32         $e(i) = 0$ 
33  если  $success = true$ 
34     $reward \leftarrow rewardForSuccess$ 
35  в противном случае
36     $reward \leftarrow rewardForFailure$ 
37   $\delta \leftarrow reward - Q_{oldOption}$ 
38   $\bar{\theta} \leftarrow \bar{\theta} + \alpha \delta \bar{e}$ 
39  SaveEpisode() - сохраняем определённые параметры для отладки

```

Рис. 9. Модифицированный алгоритм *Sarsa*(λ)

значений $Q(s, a)$. Такой метод обновлений называется замещением. Конкретные значения наград r (подкреплений) могут задаваться статически (в начале обучения) и больше не меняться или динамически, когда подкрепление определяется «извне» и конкретное значение предъявляется системе на каждом шаге обучения.

Был произведен эксперимент по обучению двух агентов-игроков команды правильному выполнению *простого сценария атаки*. По сценарию задача двух игроков — забить мяч в ворота противника, защищаемые вратарем. Первый игрок ведет мяч. Он должен научиться выбирать одно из следующих действий: пас партнеру, пас партнеру на ход, дриблинг к воротам противника. Удар по воротам не входил в это множество, и проверялся отдельно. Второй игрок, получив мяч, должен выбрать направление удара, и попытаться забить мяч. Задача сводится к минимизации времени взятия ворот противника. Обозначим оптимальное поведение как π^* (оптимальная политика агента), множество всех допустимых политик как Π , длительность произвольного эпизода при политике π как $T(\pi)$. Тогда формально задача сводится к определению политики, такой, что

$$\pi^* = \underset{\forall \pi \in \Pi}{\operatorname{argmin}} T(\pi).$$

При настройке процесса обучения были выбраны следующие значения подкреплений. За каждый шаг эпизода

$$r_{forEpisodeStep} = -0.001,$$

за успешное окончание эпизода (ворота взяты)

$$r_{forSuccessEnd} = 1,$$

если вратарь завладевал мячом (провал)

$$r_{forFailureEnd} = -1.$$

После того, как был отдан пас, игрок запоминал это состояние, и потом, в случае успешного завершения, подкрепление определялось как

$$r = 1 - 0.001 \cdot t,$$

где t — время до завершения эпизода, в случае неуспеха оно оставалось таким же (т. е. $r = -1$). Иные случаи рассматривались как ошибки (например, промах по воротам, превышение допустимой длительности времени

эпизода), и не обрабатывались, а происходил переход к инициализации следующего эпизода. Обучение контролировалось специальной программой — тренером, который и определял, когда инициализировать новый эпизод.

При моделировании состояние s определялось набором параметров: d_1 — расстояние от игрока с мячом до игрока противника; d_2 — расстояние от игрока с мячом до партнера; d_3 — расстояние от игрока мячом игрока до центра ворот; β — угол между векторами, на которых вычислялись расстояния d_1 и d_2 . Действия агентов-игроков a выбирались из множества допустимых действий $A = \{dribble, pass\}$, включающих дриблинг и пасы.

Суммарное время обучения составило примерно 10 часов. Обучение останавливалось, исходя из визуальной оценки игры агентов. Преимущества таким образом обучаемых агентов-игроков были показаны в соревнованиях. Так, команда STEP (Soccer Team of ElectroPult) таких агентов стала Чемпионом Мира в Симуляционной 2D Футбольной Лиге Кубка Роботов RoboCup-2004 (Португалия, Лиссабон, 2004).

Когнитивная система управления роботом на иммунологических сетях

Технические системы, основанные на современных представлениях об иммунной системе человека, демонстрируют новые свойства в сравнении с нейронными и нейрологическими системами [42]. Интересные с технической точки зрения модели иммунных систем базируются на биологическом понятии *иммунитета*, т. е. способности иммунной системы к отторжению чужеродных тел. Приобретенный человеком иммунитет является совершенным механизмом защиты организма от чужеродных молекул (*антигенов*) и связан с активностью лимфоцитов. Лимфоциты синтезируют *антитела*, особые белки, которые связываются с *антигенами* и подготавливают их к последующему разрушению. Для успешной работы иммунная система должна порождать огромное разнообразие антител, способных связаться с любой молекулой.

Существует несколько теорий построения и функционирования иммунных систем.

Клонально-селекционная теория является классической. Она утверждает, что, когда антиген попадает в организм, существовавшие до этого клоны антител, которые случайно распознают его, получают стимул к размножению и выработке соответствующих антител. Однако эта теория

оказалась малопригодной для построения технических иммунных систем.

Теория идиотопических сетей более интересна как парадигма, пригодная для использования в технических системах [43]. Согласно ней, антитела могут в свою очередь выступать как антигены друг для друга. Тем самым возникает сильно связанная сеть, в которой все антитела имеют, как детерминанты антигенов — *идиотопы*, так и центры распознавания антител — *паратопы*. Таким образом, иммунная система представляется как огромная сеть паратопов, которые распознают идиотопы и идиотопов, которые распознают паратопы. Идиотопы стимулируют активность лимфоцитов с комплементарными паратопами, обнаруженными на вырабатываемых ими антителах. Наоборот, паратопы подавляют активность соответствующих лимфоцитов. Так формируется иммунный ответ, обеспечивающий повышение концентрации антител данной специфичности. Таких ответов может быть несколько, причем следующий ответ подавляет предыдущий. Но каждый последующий иммунный ответ значительно слабее, нежели ингибируемый им предыдущий, и постепенно угасает. Как показано на моделях, подобные процессы в иммунных сетях приводят в результате к подавлению (удалению) клонов, обладающих сходством с антигеном. На базе этой теории развита парадигма *иммунологических сетей*, применяемая в технических приложениях.

Динамика иммунологической сети связана с изменениями концентрации антител. Концентрация i -го антитела может быть вычислена в соответствии с уравнением

$$\frac{dA_i(t)}{dt} = \left\{ \alpha \sum_{j=1}^N m_{ji} a_j(t) - \alpha \sum_{k=1}^N m_{ik} a_k(t) + \beta m_i - k_i \right\} a_i(t), \quad (1)$$

$$a_i(t+1) = \frac{1}{1 + \exp(0.5 - A_i(t))}. \quad (2)$$

В этих уравнениях N — число антител, m_{ji} и m_i означают сходство между антителами j и i (например, степень отклонения) и между антителом и детектированным антигеном соответственно. Первый и второй термы правой части уравнения (2) означают стимуляцию и подавление от других антител соответственно. Третий терм представляет стимуляцию от антигена, а четвертый терм является фактором диссипации (например, естественной смерти). Уравнение (3) является функцией, обеспечивающей стабильность концентрации. Выбор антител определяется значениями концентраций антител.

Пространственная модель Тараканова [44] дает математический аппарат для формального описания иммунологических систем. В этой модели введены понятия клетки и пространственной формальной иммунной сети (SFIN — Spatial Formal Immune Network). Клетка определена как пара «число-точка в q -мерном Евклидовом пространстве». SFIN состоит из набора клеток, для которых определены парные Евклидовы дистанции и некоторый порог. Одна клетка распознает другую, если они имеют одинаковые числа, и дистанция между ними меньше порога. Для модификации сети введены правила: Апостозиса (удаления распознанной клетки) и Иммунизации (добавления нераспознанной клетки). Определенная таким образом SFIN дополнена процедурой обучения и может эффективно решать задачи распознавания образов.

Система безопасности робота

Рассмотрим подход к построению иммунологической сети [43] в системе безопасности робота при работе с человеком.

В простом варианте иммунологическая сеть может быть настроена на выбор поведений, защищающих от внезапной остановки робота при потере энергии или опасных ситуаций, связанных с возможностью нанести вред человеку. Пусть, при движении робота среди людей параметры текущей ситуации, детектируемые установленными на борту сенсорами, рассматриваются как множественные антигены, а подготовленные заранее модули действий — как антитела. Такая система может регулироваться через стиляцию и подавление между антителами.

В качестве примера рассмотрим фрагмент иммунологической сети для *обеспечения безопасности робота при перемещении объектов среди людей*. Среда робота (помещение) ограничена и имеет много объектов, которые он должен перемещать. Задача робота — переносить объекты в нужное место, следя за запасом энергии (уровня заряда батареи) и избегая столкновений с человеком. Введем следующие допущения: (1) робот потребляет энергию E_m на каждом шаге; (2) робот теряет добавочно энергию E'_m , когда он переносит объект; (3) если робот сталкивается с человеком, он теряет некоторую энергию E_c дополнительно. Тогда текущий уровень энергии будет

$$E(t) = E(t-1) - E_m - k_1 E'_m - k_2 E_c, \quad (3)$$

где $k_1 = 1$, если объект перемещается роботом, или $k_1 = 0$ в противном

случае; $k_2 = 1$, если есть столкновение с человеком, или $k_2 = 0$ в противном случае. Уровень энергии используется как главный параметр при выборе поведения робота.

В нашем примере полагается, что каждый *антиген* дает информацию об элементах среды (объект, человек, база) и уровне энергии робота. Каждое *антитело* определяется его структурой: для паратопа используется пара: предусловие и поведение, а для идиотопа используется номер, стимулирующего антитела, и степень стимула. Похожая структура предусловия используется и для антигена. Для выбора антитела используется переменная «концентрация антитела».

Ограничимся *фрагментом* иммунологической сети, в которой взаимодействуют 4 антитела с предусловиями: «направление на базу», «направление на человека», «уровень энергии низкий», «уровень энергии высокий», которые формируют необходимые управления, а возмущения возникают от антигенов: «база справа», «человек спереди», «энергия высокая», «энергия низкая». Эти антигены вторгаются в мир робота, а антитела, взаимодействующие между собой при выборе поведения, должны компенсировать антигены (т. е. после отработки поведений эти антигены должны исчезнуть).

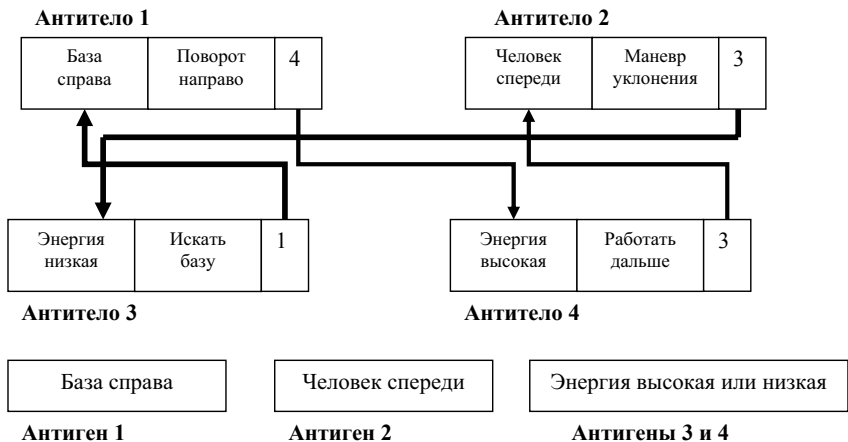


Рис. 10. Пример сети взаимодействующих антител

Фрагмент сети показан на рис. 10. Например, антитело 1 активизирует

ся, если робот детектирует базу в направлении справа, и затем должно вызвать поведение «поворот вправо». Однако, если текущий уровень энергии высокий, это антитело должно дать возможность другим антителам, представленным его идиотопами (в нашем случае, антителу 4), помешать перезаряду батареи. Теперь предположим, что робот имеет достаточно энергии. В этом случае антитела 1, 2 и 4 одновременно стимулируются антигенами. В результате концентрация этих антител увеличится. Однако, благодаря взаимодействиям антител через их паратопы и идиотопы при обучении сети, концентрация каждого антитела изменяется. В итоге антитело 2 должно иметь наивысшую концентрацию и будет в дальнейшем выбрано. Это означает, что робот будет делать маневр уклонения от контакта с человеком. В случае, если робот не имеет достаточно энергии, имеется тенденция к выбору антитела 1 подобным же образом. Это означает, что робот не будет делать специальный маневр уклонения от человека и попытается сделать поворот направо, чтобы идти к базе и перезарядить батарею.

Когнитивные агенты на поведенческих сетях

Интересные с технической точки зрения модели систем управления взаимодействующими объектами в сложных плохо предсказуемых средах базируются на психологическом понятии *поведения*, т. е. способности системы к формированию рациональных действий управляемых ею объектов в соответствии с заданными целями и условиями среды. По характеру действий и механизмам их выбора можно различать простое *реактивное* поведение, а также сложное *делиберативное* (разумное) поведение. Поведенческие системы, работающие в динамически изменяющихся условиях среды, должны быть *адаптивными*, т. е. способными изменять заложенные при проектировании поведения в новых условиях. Такие системы должны иметь средства коррекции знаний о поведении в процессе функционирования. Это соответствует процессам познания и сознания, которые изучаются специалистами по когнитивной науке.

Когнитивная теория сознания Бара является физиологической теорией сознания, которая описывает функциональное построение и высокоуровневую архитектуру системы сознания [45]. Она постулирует *глобальное рабочее пространство*, где события сознания возникают и обрабатываются в распределенной системе процессоров, для которых особую важность имеет контекст. *Процессоры* могут рассматриваться как малые автономные бес-

сознательные системы, каждая из которых управляет отдельной функцией. Обычно процессоры имеют прямые или не прямые коммуникации между собой. Коалиция бессознательных процессоров использует глобальное пространство как разделяемую область памяти процессоров. Процессоры сами организуются, чтобы формировать сознание для понимания ситуации. Состоящие из бессознательных процессоров контексты (контексты целей, контексты целей-доминант, контексты восприятия) огранич

Выбор поведения производится в цикле путем вычисления активации каждого модуля в соответствии с выражением (1) и выбора соответствующего модуля компетенции. После чего выполняется его поведение и делается переход к следующему шагу выбора, при необходимости уменьшая порог срабатывания на малое значение.

Расширенные поведенческие сети Франклина [47], построенные в рамках рассмотренной идеологии когнитивной теории сознания, используют модифицированный способ управления переменными в механизме выбора действий, в результате чего стало возможным обрабатывать потоки поведений. Поток поведений является набором поведений, которые служат удовлетворению одиночной цели агента. Сеть в целом сравнивает множество потоков поведений и выбирает потоки, которые удовлетворяют ее.

Когнитивный агент-игрок на поведенческих сетях

Рассмотрим вариант построения с использованием адаптивных поведенческих сетей когнитивного агента-игрока для командной работы в среде баскетбола роботов RoboFIBA [48].

Агент-игрок, традиционно используемый для среды RoboFIBA, имеет *реактивную архитектуру с тремя управляющими уровнями*: верхним тактическим, средним поведения и нижним навыков (рис. 11). Верхний тактический уровень выбирает текущее коллективное поведение, основываясь на информации об игроках, положениях маркеров поля и мяча по отношению к игроку, а также параметрах, определяющих стратегию команды (роли игроков, формации, планы игры), которые инициализируются перед игрой. Средний уровень включает процедуры, определяющие поведение агента при игре: ведение мяча с препятствиями, перехват мяча, пässe, прессинг и т. д. Различное поведение выбирается в соответствии с текущими состояниями среды и игрока. При реализации разного поведения используются средства уровня навыков игрока. Уровень навыков игрока включает бег с разгонами и поворотами, обход препятствий, бросок по кольцу или пас партнеру и т. д. Результатом работы этого уровня является последовательный набор команд, исполняемых сервером. На всех уровнях этого агента используются специально разработанные правила формирования поведения в различных игровых ситуациях. Настройка на игру производится вручную путем изменения структуры и параметров правил во время тренировочных игр.

Модель
мира

Представление
игровой
площадки

Стратегия
(Сценарии,
Роли,
Задачи)

Состояние
игрока


Модуль
синхронизации

Тактические
решения

Поведения

Восприятие

Навыки



В отличие от традиционного варианта агента-игрока на правилах когнитивный агент-игрок на адаптивных поведенческих сетях способен обучаться правильному поведению под управлением тренера. Для этого в агенте была использована *трехуровневая адаптивная поведенческая система*, модули компетенции которой были реализованы на нейрологических модулях. Каждый модуль компетенции поведенческой сети своего уровня обучался отдельному поведению, т. е. отображению своей поведенческой функции, а сеть уровня в целом реализует настраиваемый путем обучения механизм селекции поведений на этом уровне. Локальные сети всех трех уровней соединялись связями, по которым передается информация о выбранном на данном уровне поведении по принципу «каждый-каждому». Информация от верхних уровней к нижним воспринималась последними как указание на соответствующее изменение своего поведения. Обратная информация от нижних уровней к верхним подтверждала согласованное исполнение поведений нижними уровнями.

При *разработке агента* сначала вручную были определены предусловия целей и поведения для модулей компетенции, а затем определялась их связность. Эта операция выполнялась автоматически с использованием *механизма параметризации*, т. е. изменения параметров связей сети. При этом определяется номер активируемого модуля компетенции (в нашем случае, заранее обученного определенной поведенческой функции нейрологического модуля) и степень его активации $a_{i,j}^t$. Для этого используется *обучение с подкреплением*, которое стартует от ситуации, когда параметры связей модулей не определены, но могут быть получены, используя сигналы подкрепления.

Допустим, что ситуации С1 и С2 возникают в среде агента, причем каждая ситуация может одновременно активизировать модули М1 и М2. Как следствие, степень активизации каждого модуля может увеличиться. Однако, поскольку приоритеты М1 и М2 неизвестны (потому, что номера модулей изначально не определены и нет цепочки «активизация-торможение»), любой из них может быть выбран случайно.

Теперь предположим, что случайно выбран модуль М1, и затем получен позитивный сигнал подкрепления. Чтобы сделать тенденцию выбора М1 при таких же или похожих ситуациях, можно записать номер М1 (т.е. 1) в память связей модуля М2 и увеличить степень активизации a_{21}^t . Модификация степени активизации производится в соответствии с выражениями:

$$a_{12} = \mu_{D_s}^{Act} = \max(\mu_{r_1}^p, \mu_{r_2}^r), \quad (5)$$

$$a_{21} = \mu_{Ds}^{Inh} = \max(\mu_{r2}^p, \mu_{r1}^r). \quad (6)$$

Здесь μ_{Ds}^{Act} и μ_{Ds}^{Inh} представляют степени функции принадлежности к термам *Активизации* (Act — Activation) и *Торможения* (Inh — Inhibition), соответствующие нечеткой переменной поддержки выбора модуля компетенции (Ds — Degree of support). Величины μ_{r1}^p , μ_{r2}^p , μ_{r1}^r и μ_{r2}^r являются степенями функции принадлежности к нечетким термам *Пенальти* (p — penalty) и *Поощрения* (r — reward), которые рассматриваются как термы сигнала *Подкрепления* R (для модуля M1 или M2). Последние 4 степени функций принадлежности могут быть вычислены, используя заданные функции принадлежности для термов p и r переменной R и подсчитывая число раз получения пенальти или поощрения, когда выбираются модули M1 или M2.

Процедура модификации работает, например, чтобы поднять относительный приоритет M1 по отношению к M2. В случае, когда агент получает сигнал пенальти, номер M2 (т. е. 2) записывается в память связей M1 и степень активации модифицируется аналогичным предыдущему образом. Это увеличивает относительный приоритет M1 по отношению к M2.

В случае агента-игрока, в зависимости от командной тактики (оборона, атака или подбор мяча) были заданы поощрения и пенальти, которые приведены в табл. 2.

ТАБЛИЦА 2. Поощрения и пенальти для обучения сети

Вид подкрепления	Оборона	Подбор мяча	Атака
Поощрения	Противник потерял мяч	Игрок подобрал мяч	Мяч попал в кольцо
Пенальти	Мяч пропущен	Противник подобрал мяч	Мяч потерял

Также использовался следующий набор из 8-ти ситуаций и 10-ти поведений.

Ситу ии: С1-2-3 (Мяч у меня-партнера-свободен-рядом); С4-5 (Партнер ближе к моему кольцу-кольцу противника); С6 (Рядом противник с мячом); С7-8 (Я с мячом в прыжке-противник на пути к кольцу).

оведения: М1-2-3-4 (Стоп-бросок по кольцу-блокшот-прыжок); М5-6 (Движение к кольцу-противнику); М7-8 (Пас ближайшему партнеру-партнеру вперед); М9 (Шаг в сторону); М10 (Ловить мяч).

ТАБЛИЦА 3. Результаты тестовой игры

Показатели	Команда А	Команда В
Счет	10	5
2-х очковые броски (точные / всего)	2 / 8	1 / 2
3-х очковые броски (точные / всего)	2 / 7	1 / 1
Пасы (точные / всего)	33 / 64	20 / 65
Точность паса (%)	52	31
Владение мячом	52	48

Созданная по этим данным и обученная поведенческая сеть использована в агенте-игроке команды А, которая тестировалась в соревновании с командой В, поведение агентов которой определялось жестких системой правил, составленных разработчиком.

Анализ игры (табл. 3) показал более высокие показатели в точности паса и владении мячом у команды А. Более качественная игра в пас обеспечила команде А преимущество в счете. Команда В лишь 3 раза довела свою атаку до броска по корзине, в то время как команда А совершила 15 бросков.

Эксперимент показал, что при использовании описанного механизма параметризации качество поведения агентов зависит от времени обучения. Оно может быть дополнительно улучшено, если использовать дополнительно механизм структуризации поведенческой сети, построенный на генетическом алгоритме.

Когнитивные агенты на адаптивных триангуляционных модулях

Обучаемые сетевые средства не всегда дают преимущества при построении когнитивных агентов со сложным поведением. Большой эффект дают когнитивные модули, построенные на методах адаптивной функциональной аппроксимации, например, на основе многомерной триангуляции. Такие модули, в частности, значительно лучше работают в режиме обучения подкреплением.

Адаптивный триангуляционный модуль

Специальный модуль для аппроксимации сложных когнитивных функций был разработан на основе метода барицентрической аппроксимации [49]. В нем используется класс линейных функций, известных как барицен-

Предложен простой алгоритм, имеющий сложность $O(N)$, где N — средняя глубина дискретизации. Алгоритм позволяет определить симплекс, которому принадлежит произвольная точка x , и, осуществив преобразование координат этой точки в пространство базового симплекса, найти барицентрические координаты $\lambda_{x^{(i)}}$, $1 \leq i \leq n + 1$.

Модуль, построенный на основе такого барицентрического аппроксиматора, может быть настроен на отображение когнитивной функции или отношения путем супервизорного обучения или обучения с подкреплением.

При супервизорном обучении для обновления значений функции в вершинах $f(x^{(i)})$ и степеней доверия этим значениям $p_{x^{(i)}}$ на базе примеров, задающих $f(x)$, используется следующая итерационная схема:

$$f_{n+1}(x^{(i)}) = f_n(x^{(i)}) + \{f(x) - f_n\{x^{(i)}\}\} \frac{\lambda_{x^{(i)}}(x)}{p_{n+1}\{x^{(i)}(x)\}}, \quad (9)$$

$$p_{n+1x^{(i)}} = p_{nx^{(i)}} + \lambda_{x^{(i)}}(x). \quad (10)$$

Алгоритм обучения с подкреплением строится на основе методов динамического программирования. Решается задача максимизации значения функционала подкрепления (10), путем выбора оптимального управления u^* , т. е.

$$J(x, u(t)) = \int_0^{\tau} \gamma^t r(x(t), u(t)) dt + \gamma^\tau R(x(\tau)), \quad (11)$$

где $r(x, u)$ — текущее подкрепление, $r_b(x)$ — граничное подкрепление, γ — коэффициент $0 \leq \gamma < 1$.

В процессе решения этой задачи вводится целевая функция:

$$V(x) = \sup_{u(t)} J(x, u(t)). \quad (12)$$

Путем аппроксимации уравнения Гамильтона-Якоби-Беллмана с помощью конечно-разностной схемы получаем следующее выражение для целевой функции:

$$V^\Sigma(x) = \sup_{u \in U} \left[\gamma^{\tau(x,u)} \sum_{j=0}^n \lambda_{x^{(j)}} \{ \eta(x, u) \} V^\Sigma(x^{(j)}) + \tau(x, u) r(x, u) \right], \quad (13)$$

где $\eta(x, u)$ — проекция x в направлении, параллельном $f(x, u)$ на противоположную грань симплекса, а $\tau(x, u)$ такого, что:

$$\eta(x, u) = x + \tau(x, u)f(x, u). \quad (14)$$

Вводятся Q -значения:

$$\begin{aligned} Q^\Sigma(x, u) &= \gamma^{\tau(x, u)} V^\Sigma\{\eta(x, u)\} + \tau(x, u)r(x, u), \\ Q^\Sigma(x, u) &= R(x), \text{ при } x \in X. \end{aligned} \quad (15)$$

Для итеративного решения (15) необходимо знание $\eta(x, u)$ и $\tau(x, u)$. Они могут быть определены путем взаимодействия с объектом на основе построенных траекторий изменения его состояния, в зависимости от приложенного управления. Разработан безмодельный подход решения с использованием теоремы Талеса для аппроксимации $\tau(x, u)f(x, u)$ на основе точки входа траектории в симплекс x_1 и точки выхода из симплекса x_2 :

$$\tau(x, u)f(x, u) = \frac{x_2 - x_1}{\lambda_x(x_1)}. \quad (16)$$

На основе выражений (15) и (16) строится итерационная схема вычисления $Q^\Sigma(x, u)$:

$$Q_{n+1}^\Sigma(x, u) = \gamma^{\frac{\tau_x}{\lambda_x(x_1)}} \frac{V^\Sigma(x_2) - V^\Sigma(x_1)}{\lambda_x(x_1)} + V^\Sigma(x) + \frac{\tau_x}{\lambda_x(x_1)} r(x, u). \quad (17)$$

Здесь τ_x время движения по траектории x_1 до точки x_2 .

Для обеспечения сходимости такая динамика обучения комбинируется со структурной динамикой, заключающейся в уточнении симплексов с нерегулярной целевой функцией.

Когнитивный агент на адаптивных триангуляционных модулях

Главная идея, лежащая в основе разработки когнитивного агента, способного управлять динамическими объектами со сложным индивидуальным и групповым поведением, заключается в использовании гибридной архитектуры, компоненты которой настраиваются на отображение сложных когнитивных функций путем обучения с подкреплением. *Трехуровневая гибридная архитектура* комбинирует BDI-архитектуру, а также реактивную слоистую архитектуру, что должно позволить когнитивному агенту совместить

реактивность обработки реакций на внешние воздействия с долгосрочным планированием и командной кооперацией.

Для реализации предложенной архитектуры необходимы обучаемые модули, которые способны: (1) обучаться произвольному вектор-векторному отображению; (2) эффективно функционировать и обучаться в случае высокой размерности пространства входов; (3) обучаться как на основе супервизорного обучения, так и путем обучения с подкреплением. Таким требованиям в наибольшей степени соответствуют описанные здесь *адаптивные триангуляционные модули* (ATM).

Когнитивный агент гибридной архитектуры был разработан в соответствии с ранее рассмотренной общей схемой (рис. 8). BDI-модель, использованная на верхних уровнях агента, была подробно описана в разделе 4, поэтому здесь рассмотрим кратко только уровень исполнения и уровень взаимодействия агента.

На входы каждого из *исполнительных модулей*, построенных как ATM, одновременно поступает информация с сенсоров. Она преобразуется в управляющие сигналы, которые затем поступают на исполнительные устройства. Каждый модуль отвечает за определенные аспекты рефлекторного поведения системы. Для настройки модулей используется обучение с подкреплением. В процессе работы верхний уровень перенастраивает управляющие слои путем изменения приоритетов модулей.

Уровень взаимодействия BDI формирует индивидуальные убеждения и намерения агента в соответствии с его желаниями (текущими целями), а также корректирует их после согласования с убеждениями и намерениями взаимодействующих с ним агентов. Процесс взаимодействия агентов *на уровне взаимодействий* реализуется сетью ATM-модулей, обеспечивающих согласование убеждений и намерений, а также генерацию общих намерений.

Когнитивные агенты гибридной архитектуры на ATM-модулях были реализованы и настроены на управление беспилотными аппаратами, выполняющими координированные групповые операции по уничтожению наземных целей [49]. Агенты такой архитектуры были использованы также в цифровой нервной системе гуманоидного робота для формирования поведения при взаимодействии с другими роботами и человеком [50].

Заключение

В настоящее время когнитивный подход широко используется не только в психологии, но и в технике. Разрабатывается и исследуется большая гамма искусственных когнитивных систем, использующих когнитивные модели и нейроподобные средства реализации. Предполагается, что именно такие системы позволят достичь уровня поведения, соответствующего поведению человека.

Наиболее полезными с точки зрения практического применения можно считать искусственные когнитивные системы с гибридными архитектурами. Разработка, исследования и применение таких систем проводятся автором этой работы и его коллегами с 1998 года. Эти работы развиваются на основе предложенных концепций, таких как когнитивная функциональность, конструктивизм и многоагентность.

Разработанные варианты когнитивных модулей сетевого типа: нейрологических, иммунологических, поведенческих, а также на основе адаптивной триангуляционной аппроксимации, дали возможность реализовать ряд когнитивных систем и агентов для роботизированных игровых сред.

Литература

1. *Neiser U.* Cognitive psychology. – NY, 1967.
2. *Солто Р.* Когнитивная психология. – М.: Мир, 1996.
3. *Хомский Н.* Три модели описания языка. Кибернетический сборник. Вып. 2 – М.: Изд-во ИЛ, 1961.
4. *Шеперд Г.* Нейробиология. Том 1, 2. – М.: Мир, 1987.
5. *Величковский Б. М.* Когнитивная наука. Основы психологии познания. В 2-х тт. – М.: Академия, 2006.
6. *Станкевич Л. А.* Когнитивные нейрологические системы управления // Проблемы нейрокибернетики (Материалы 12-й Международной конференции по нейрокибернетике, Ростов-на-Дону, Россия, октябрь, 1999). – Ростов-на-Дону: Изд-во Северо-Кавказского НЦ высшей школы, 1999.
7. *Гергей Т.* Когнитивные системы – потребность информационного общества и вызов компьютерным наукам // IX Национальная конференция по искусственному интеллекту КИИ-2004 (18 сентября – 2 октября 2004 г., Тверь). Труды конференции в 3-х томах, Том 1, М.: Физматгиз, 2004, с. 3–10.
8. *Станкевич Л. А.* Искусственная нервная система гуманоидного робота // Труды Юбилейной международной конференции по нейрокибернетике (Ростов-на-Дону, 25–28 сентября 2002), Ростов-на-Дону, 2002.

9. *Станкевич Л. А.* Нейрологические средства систем управления интеллектуальных роботов // Научная сессия МИФИ-2004. VI Всероссийская НТК «Нейроинформатика-2004»: Лекции по нейроинформатике, ч.2. – М.: МИФИ, 2004, с. 57–110.
10. *Станкевич Л. А.* Когнитивный подход к управлению гуманоидными роботами // В книге «От моделей поведения к искусственному интеллекту». Серия «Науки об искусственном», Ред. *Редько В. Г.* – Изд-во УРСС, 2006, Гл. 14, с. 386–443.
11. *Vernon D., Metta G., Sandini G.* A survey of artificial cognitive systems: implications for autonomous development of mental capabilities in computational agents // *IEEE Transactions on Evolutionary Computation*, Vol. 11, No. 2, April 2007, pp. 151–180.
12. *Newell A., Simon H. A.* Computer science as empirical inquiry: Symbol and search // *Communications of the Association for Computing Machinery*. – vol. 19, pp. 113–126, 1976, Tenth Turing Award Lecture, ACM.
13. *Anderson J.* The architecture of cognition. – Harvard University Press, MA, 1983.
14. *Bratman M.* Intention, plan, and practical reasoning. – Harvard University Press, Cambridge, MA, 1987.
15. *Sandini G., Metta G., Vernon D.* Robocup: An open framework for research in embodied cognition // In: Proc. IEEE-RAS/RSI Int. Conf. on Humanoid Robots (Humanoids 2004), 2004, pp. 13–32.
16. *Thronckle E. L.* The fundamental of learning. – New York: Columbia Univ., Teacher College, 1932.
17. *Hebb D. O.* The organization of Behavior. – New York: Wiley, 1949.
18. *McCulloch W. S., Pitts W.* A logical calculus of ideas immanent in nervous activity // *Bull. Math. Biophys.*, vol. 5, pp. 115–133, 1943.
19. *Rumelhart D. E., McClelland J. L.* (Eds.) Parallel distributed processing: Explorations in the microstructure of cognition. – Cambridge, VA: MIT Press, 1986.
20. *Reiter R.* Knowledge in action: Logical foundation for specifying and implementing dynamical systems. – Cambridge, MA: MIT Press, 2001.
21. *Thelen E., Smith L. B.* A dynamic systems approach to the development of cognition and action. In “Bradford Books Series in Cognitive Psychology” – Cambridge, MA: MIT Press, 1944.
22. *Maturana H., Varela F.* The tree of knowledge – the biological roots of human understanding. – London, U.K.: New Science Library, 1987.
23. *Bickhard M. H.* Autonomy, function, and representation // *Artificial Intelligence*. Spec. Issue on Communication and Cognition. – vol. 17, no. 3–4, 2000, pp. 111–131.
24. *Granlund G. H.* The complexity of vision // *Signal Processing*, vol. 74, 1999, pp. 101–126.

25. *Granlund G. H.* A cognitive vision architecture integrating neural networks with symbol processing // *KI-Zeitschrift Kunstliche Intelligenz*. Special Issue on Cognitive Computer Vision. – April, 2005.
26. *Metta G., Fitzpatrick P.* Early integration of vision and manipulation // *Adaptive Behavior*, vol. 11, no. 2, 2003, pp. 109–128.
27. *Laird J. et al.* Soar: An architecture for general intelligence // *Artificial Intelligence*, 33(1), 1987, pp. 1–64.
28. *Wooldridge M.* An introduction to multiagent systems. John Wiley & Sons, Ltd. 2002.
29. *Krichmar J. L., Edelman G. M.* Brain-based devices for the study of nervous system and the development of intelligent machines // *Artificial Life*, vol. 11, 2005, pp. 63–67.
30. *Brooks R. A. et al.* The cog project: Building a humanoid robot // In: *Computation for Metaphors, Analogy, and Agends*, C. L. Nehaniv, Ed. Berlin, Germany: Springer-Verlag, 1999, vol. 1562, Springer Lecture Notes in Artificial Intelligence.
31. *Scassellati B.* Theory of mind for a humanoid robot // *Autonomous Robots*, vol. 12, 2002, pp. 13–24.
32. *Leslie A. M.* Tomm, toby, and Agency: Core architecture and domain specificity // In: *Mapping the Mind: Specificity in Cognition and Culture*, L. A. Hirschfield and S. A. Gelman, Eds. – Cambridge, U.K.: Cambridge Univ. Press, 1994, pp. 119–148.
33. *Baron-Cohen S.* Mindblindness. – Cambridge, MA: MIT Press, 1995.
34. *Станкевич Л. А.* Когнитивные концепции и их применение в технических интеллектуальных системах // Первая Всероссийская конференция «Когнитивная наука-2004», Казань, 9–12 октября, 2004.
35. *Minsky M.* Society of mind. – New York: Simon and Schuster, 1986.
36. *Станкевич Л. А.* Многоагентные когнитивные нейрологические системы управления // IV Всероссийская конференция «Нейрокомпьютеры и их применение», НКП2000, Москва, 16–18 февраля 2000, М., 2000.
37. *Weiss G.* (Ed.) Multi-agent systems. A modern approach to distributed artificial intelligence. – MIT Press, Cambridge, MA., 1999.
38. *Brooks R. A.* Intelligence without representation // *Artificial Intelligence*, 47, pp. 139–159, 1987.
39. *Станкевич Л. А.* Когнитивные структуры управления гуманоидным роботом // *Новости искусственного интеллекта*, № 1, 2004.
40. *Sutton R. S., Barto A. G.* Reinforcement learning: An introduction. – MIT Press, Cambridge, MA, 1998.

41. *Котенко И. В., Станкевич Л. А.* Командная работа агентов в реальном времени // *Новости искусственного интеллекта*, № 3(57), 2003, с. 25–31.
42. *Станкевич Л. А.* Иммунологические системы: модели и применение // Научная сессия МИФИ-2007. IX Всесоюзная научно-техническая конференция «Нейроинформатика-2007» (23–26 января 2007, Москва), Сб. научных трудов. В 3-х частях, часть 3. М.: МИФИ, 2007, с. 98–105.
43. *Jerne N.K.* Towards a network theory of the immune system // *Annales d'Immunologie* (Institut Pasteur), 1974, 125C, pp. 373–389.
44. *Tarakanov A. O., Kvachev S. V., Sukhorukov A. V.* A formal immune network and its implementation for on-line intrusion detection // LNCS 3685: MMM-ACNS 2005 / *Gorodetsky V., Kotenko I., and Skormin V.* (Eds.), Springer-Verlag, Berlin Heidelberg, 2005, pp. 394–405.
45. *Baars B.* A cognitive theory of consciousness. – Cambridge University Press, New York, 1988.
46. *Dorer K.* Extension behavior networks for behavior selection in dynamic and continuous domain // Proceeding of Conference ECAI-2004.
47. *Franklin S.* Autonomous agents as embodied AI // *Cybernetics and Systems*. 1997, 28, pp. 499–520.
48. *Станкевич Л. А., Троцкий Д. А.* Баскетбол роботов — много-агентная игровая среда RoboFIBA // *Материалы XVI Научно-технической конференции «Экстремальная робототехника»*, 11–13 апреля 2005, ЦНИИ РТК, СПб., 2005.
49. *Тымакин Д. Л.* Многоагентные когнитивные системы управления динамическими объектами со сложным поведением. Диссертация на соискание ученой степени к. т. н., СПбГТУ, 2002.
50. *Станкевич Л. А.* Когнитивные структуры и агенты в системах управления интеллектуальных роботов // *Новости искусственного интеллекта*, № 1, 2004, с. 41–55.

Лев Александрович СТАНКЕВИЧ, кандидат технических наук, профессор Санкт-Петербургского политехнического университета. Научные интересы: интеллектуальное управление, искусственные когнитивные системы, нейробиологические средства, многоагентные системы управления, футбол роботов, гуманоидные роботы. Автор более 130 печатных работ, 8 учебных пособий и 2 монографий. Организатор команд по футболу роботов и участник чемпионатов мира по футболу роботов (RoboCup) в симуляционной лиге. Является одним из организаторов и участников создания первого в России гуманоидного робота APHE.

A. A. ZHDANOV

S. A. Lebedev Institute of Precision Mechanics and Computer Engineering,
Moscow, Russia

E-mail: aazhdanov@ipmce.ru

**ADAPTIVE MACHINES AS AN UNAVOIDABLE WAY OF
TECHNOLOGICAL EVOLUTION. PROBLEMS AND TASKS**

Abstract

The paper considers the topicality of new way of technologies evolution that consists in development of adaptive machines, programs and systems similar to natural control systems. We present the scheme, structure and composition of the biologically-inspired “Autonomous Adaptive Control” (AAC) system that logically follow from the conditions in which the natural control systems work. The comparison of the AAC system with P.K. Anokhin “Functional System” helps to find a difference and common lineaments of these models of natural control systems. The AAC system can be created on base of presented superposition of some methods of self-learning pattern recognition, decision-making methods, knowledge base and some others methods. One of approach to AAC system creation is based on special self-learning neuron models, which were elaborated by us for the AAC system. We presented a few prototypes of application adaptive machines on base of the AAC method. Some mathematical, technological and physiological problems of transfer to new adaptive technologies are considered in the paper.

А. А. ЖДАНОВ

ОАО Институт точной механики и вычислительной техники

им. С. А. Лебедева, Москва,

E-mail: aazhdanov@ipmce.ru

АДАПТИВНЫЕ МАШИНЫ – НЕИЗБЕЖНОЕ НАПРАВЛЕНИЕ РАЗВИТИЯ ТЕХНИКИ. ЗАДАЧИ И ПРОБЛЕМЫ

Аннотация

Рассматривается актуальность перехода к технологиям создания адаптивных машин, программ и систем, подобных естественным системам управления. Представлена схема, состав и структура системы «Автономного адаптивного управления», выведенная из понимания возможностей решения задачи адаптивного управления в условиях, в которых работают естественные управляющие системы. Проведен сравнительный анализ разработанной схемы системы «Автономного адаптивного управления» с «Функциональной схемой» П. К. Анохина. Представлена разработанная модель нейрона, как элементарной самообучаемой системы распознавания, и проведено ее сравнение с формальным нейроном ИНС. Описаны разработанные действующие модели прикладных систем «Автономного адаптивного управления». Указаны математические, технологические и психологические проблемы перехода к адаптивным технологиям.

Введение

Среда, в которой мы живем, состоит из двух компонент — естественной и техногенной. Появлению этого нового для нашей планеты явления — техногенной среды, мы обязаны, видимо, возникновению у человеческого вида интеллекта. До появления человеческого интеллекта и люди и другие организмы жили, наверное, в органическом единстве с естественной средой, но и в полной зависимости от нее. С возникновением интеллекта у людей возникла способная строить сложные адекватные модели явлений, строить сложные целенаправленные программы поведения, прогнозировать и преобразовывать окружающий мир в свою пользу. Создавая новую, техногенную, среду, человек опирается на свои модели, и, по мере их развития, оказывается способным ко все более сложному поведению, ко все более сложным преобразованиям действительности. Очевидно, что не все результаты техногенной деятельности человечества позитивны. Но мы надеемся, что, постепенно заменяя окружающую нас естественную среду на

техногенную, мы тем самым не роим себе яму, а развитие интеллекта породит и такие модели, которые будут учитывать опасности, и дадут нам в руки способы избежать их. Однако, вступив на путь развития интеллекта, человечество уже не может остановиться, «точка принятия решения» уже давно пройдена, нам надо продолжать это движение, заботясь о его безопасности. Обсудим некоторые возможности, которые помогут осознать закономерности развития технологий, применяемых людьми в своей преобразовательной деятельности.

В развитии своих технологий мы очень часто идем по пути, по которому прошла Природа, и делаем те же изобретения, которые уже были сделаны Природой. Это заставляет нас считать, что бионический путь является весьма целесообразным. Он намечает правильное направление, по которому следует направлять поиск в нашем технологическом развитии. Если Природа нашла некоторое решение, и оно закрепилось в ней, то следует относиться к этому с большим доверием и вниманием. Можно приводить большое число примеров, подтверждающих эту мысль.

Я бы хотел остановиться здесь на системах управления, как на наиболее «интеллектуальных» системах, способных к принятию решений на основе переработки информации. Для того, чтобы увидеть тенденцию развития систем управления, совершим краткий экскурс в прошлое. Посмотрим, каковы были важнейшие вклады науки в технологии и в создание техногенной среды нашего обитания.

Первый вклад был «количество». Первые научные сведения помогали нашим предкам увеличивать количество средств — пищи, жилищ, оружия, сырья, топлива и т. д., в том числе увеличивать количество видов вещей, их разнообразие.

Второй вклад был «качество». Наука привела к улучшению качества средств. Появились образцы качественной еды, качественных жилищ-дворцов, качественного дорогого оружия, дорогих предметов искусства и роскоши, качественного сырья, сложных и утонченных технологических процессов и т. п.

Следующий вклад был «оптимальность». Когда стало понятно, что высококачественных вещей на всех не изготовишь, пришло осознание необходимости уметь создавать оптимальные вещи и процессы. Явилась эпоха оптимизации. Наука дала возможность создавать оптимальные жилища, оптимальную одежду, оптимальную еду. Все достижения техники XX века — это результат достижений в науке оптимизации. Любая современная машина — это результат оптимизации. Оптимизация, как известно, состоит в том,

что при исходных заданных условиях — некотором объекте с фиксированными свойствами, признаковом пространстве, и критериях оптимальности, находятся такие значения параметров, при которых объект демонстрирует выходные параметры, наилучшие в смысле заданных качественных критериев (фитнес-функции). Операция оптимизации системы — одноразовая. Найдя оптимальный вариант машины (системы, процесса), люди фиксируют его в технической документации изделия и затем тиражируют изделие с данными неизменными параметрами. В процессе эксплуатации однажды найденные и зафиксированные значения параметров уж не меняются, изделие просто изнашивается и затем списывается. Следствием такого рода технологий, характерных для XIX-го и XX-го веков, был выпуск больших серий одинаковых машин — продуктов одноразовой оптимизации.

Если мы теперь попробуем сравнить это достижение техносферы с достижениями биосферы, то увидим, что в Природе дело обстоит не совсем так. С одной стороны, очень похоже, что «изделия» в Природе тоже оптимизированы, и некоторые параллели провести можно. Например, можно сравнивать виды животных с сериями машин. Однако налицо и явные различия. В каждом виде — «серии» животных или растений, есть много общего, но нет двух одинаковых организмов. Этот разброс вариантов природных «изделий»-индивидов внутри одного вида явно указывает на то, что Природа продолжает искать оптимальные варианты методом проб и ошибок. Она не останавливается на некотором однажды найденном варианте. Во-вторых, можно видеть, что каждый индивид существеннейшим образом меняется в процессе своей жизни. Младенчество, детство, взрослая фаза жизни, передача наследуемых признаков, их мутация и естественный отбор — это технология постоянного поиска, приспособления, адаптации вида организмов к условиям его существования. И поиск этот никогда не останавливается. Его и нельзя останавливать, так как, в отличие от одноразовой оптимизации, условия, в которых приходится жить организмам, постоянно меняются. Одноразовая оптимизация в Природе просто недопустима. Это же касается и свойств одного отдельно взятого индивида. Условия его жизни мало предсказуемы и постоянно изменяются, поэтому природные организмы представляют собой адаптивные, самоприспосабливающиеся системы.

Вернемся к вопросу о вкладах науки в техносферу и спросим себя, в чем будет состоять следующий этап? Если следовать логике развития, то следующим вкладом науки в техносферу должно быть появление технологий создания адаптивных машин, т. е. машин и систем, способных к

самоприспособлению, самообучению, саморазвитию. Ведь именно к этой технологии пришла Природа в своем развитии. Образцы этого «изобретения» Природы мы во множестве видим вокруг себя. И мы видим также, что наши технологии практически абсолютно не демонстрируют нам такого рода изделий. Следовательно, мы стоим на пороге появления новых технологий — технологий создания адаптивных машин, программ и систем, и, следовательно, нам неизбежно придется этим заниматься.

Что такое адаптивность

Договоримся о терминах. Слово «адаптивность» не имеет сегодня однозначного смысла. Например, у биологов «адаптивность» может означать свойство привыкания рецепторных клеток к постоянному воздействию, вызывающее снижение их восприимчивости. У социологов «адаптивность» может означать готовность к пересмотру привычных представлений и решений, способность гибко реагировать на меняющиеся обстоятельства. У системщиков «адаптивность» может означать стремление к состоянию устойчивого равновесия, которое предполагает адаптацию параметров системы к изменяющимся параметрам внешней среды.

В обиходном техническом смысле под «адаптивностью» понимается способность системы адекватно реагировать на изменившиеся обстоятельства, что-то вроде робастности и способности принимать правильные решения в необычных условиях. Иногда под адаптивностью понимают заранее предусмотренные в машине опции, которые можно включать в тех или иных соответствующих обстоятельствах. Но все это не соответствует тому пониманию свойства «адаптивность», о котором мы будем говорить здесь. Дадим определение понятию «адаптивность».

ОПРЕДЕЛЕНИЕ 1. *Адаптивностью* будем называть способность системы управления некоторого автономного управляемого объекта добывать знания о свойствах системы «среда–объект управления–система управления», накапливать эти знания в своей памяти и использовать эти знания для управления с целью дальнейшего их пополнения и сохранения накопленных знаний путем обеспечения физического выживания объекта, как носителя памяти и средств работы с нею (при неимении других способов к сохранению и использованию знаний).

Поясним это определение. Прежде всего, речь идет об объектах, обладающих системой управления — специализированной подсистемой, ра-

ботающей с информацией. Отсеиваем «адаптивные» машины без систем управления, но с ручкой переключения опций, обеспечивающих заранее известное изменение свойств в предусмотренных ситуациях. Во-вторых, отсеиваем неавтономные системы управления, в которых все знания заложены изначально, кем-то извне машины, или когда при управлении имеется возможность доступа к знаниям вне объекта управления; мы говорим только о машинах, способных добывать знания для управления на своем опыте. В-третьих, мы отсеиваем машины, работающие с произвольно заданными целевыми функциями; например, ракета, которая должна долететь куда следует и там взорваться — это не наш объект, потому что в природе таких объектов, изначально нацеленных на самоуничтожение или вообще — на выполнение кем-то поставленных целей, нет (опустим такие тонкости, как апоптоз, альтруизм, рабство), системы управления такими объектами могут быть устроены любым способом — *ad hoc*. Напротив, всем живым организмам присуще стремление к выживанию за счет использования при управлении накопленных ими же знаний. Наконец, поясним слова о том, чем же именно должна управлять система управления. Нервная система живого организма, а именно ее мы и имеем в виду, управляет не просто телом организма, но телом, погруженным в окружающую среду, т. е. всем тем миром, что находится за пределами ее самое, и даже более того — миром, в который включена и сама эта нервная система, потому что при управлении она предусматривает и свои собственные будущие реакции. В технических системах речь почти всегда идет об управлении только заданным объектом, а влияние всего остального — например, среды, учитывается лишь как помеха.

Что такое управление

Рассмотрим, как понимается управление в современной технологии. Типовая схема системы управления показана на рис. 1.

Объект управления (ОУ) — некая машина или система, например, ракета. Неким заказчиком задается целевая функция, например — долететь по заданной траектории в заданную точку. На объект управления действуют случайные возмущающие воздействия со стороны среды, они уведут объект управления с желаемой заказчиком траектории. Система распознавания на основании вектора показаний датчиков X распознает текущее состояние Ω объекта управления, которое сравнивается с желаемым, и на-

среда

возмущающие
воздействия

X

заказчик



отличия состоят в следующем.

1. Заказчик системы управления и объект управления в Природе — это одно и то же. «Заказчик» сидит внутри ОУ и представляет собой собственно систему управления. Отсюда сразу следует, что главной целевой функцией (во всяком случае — одной из главных) может быть только выживание объекта управления (но отнюдь не «долететь в некую точку и там взорваться» или что-либо подобное).
2. Система управления живого организма не знает изначально оптимального закона управления, позволяющего достигнуть целевой функции (а именно, выживания). Система начинает свою жизнь в заранее малоизвестной среде и должна закон управления найти. Это означает, что другой важной целевой функцией является поиск закона управления — поиск знаний. Следовательно, во многих отношениях, схема системы управления должна обеспечивать поиск, быть поисковой системой. Свойства и среды и самого ОУ постоянно изменяются, поэтому поиск закона управления и его обновление должны происходить постоянно, т.е. система управления в самом общем случае должна быть системой поисковой оптимизации. Целевые функции выживания и накопления знаний назовем *естественными целевыми функциями*, что весьма родственно понятию «естественное право», предусматривающему право на жизнь.
3. Окружающая среда в естественных системах управления рассматривается отнюдь не как источник возмущений, но как сложноорганизованная субстанция, закономерности которой следует стремиться понять, чтобы в ней выжить.
4. Постоянному изменению на основе результатов поисковой оптимизации должны подвергаться не только информация — знания, но и само устройство объекта управления, датчиков, исполнителей и, в том числе, — устройство самой системы управления.

Из сказанного следует, что схема биологически-инспирированной системы управления, должна быть такой, как показано на рис. 3.


Уточним также, что собой представляет «закон управления» в том общем виде, в котором его следует понимать при построении адаптивных систем управления.

Вернемся к рис. 2 и зададимся следующим вопросом: а откуда возникли все элементы изображенного на нем «закона управления»? А именно:



В общем случае, если мы хотим построить действительно адаптивную систему управления, и именно так, как она работает в природных системах управления, то мы должны понимать, что все ответы на эти вопросы, т. е. все указанные параметры система управления должна искать сама. Отсюда следует, что для организации адаптивного управления в полном объеме система управления должна решать следующий ряд определенных задач. Образно покажем эти задачи на рис. 4, который соответствует рис. 2, но в общем виде.

Задача 1. Определение множества информативных признаков, которыми можно пользоваться для управления (ось $\Omega(t)$ на рис. 4). Это соответствует двум задачам из теории систем распознавания — задаче определения рабочего словаря признаков $X = (x_1, x_2, \dots, x_k, \dots, x_K)$ и задаче определения алфавита классов $\Omega = (\Omega_1, \Omega_2, \dots, \Omega_i, \dots, \Omega_N)$.



признаков с их вариациями посредством мутаций. Это очень мощный метод поисковой оптимизации, хотя и требующий долгого времени. В технике этот метод можно воспроизводить генетическими алгоритмами.

Что касается задачи определения алфавита классов

$$\Omega = (\Omega_1, \Omega_2, \dots, \Omega_i, \dots, \Omega_N),$$

то эта задача разбивается на несколько сложных подзадач. Возникает следующая их постановка. Задан словарь признаков X и набор T соответствующих измерителей. Требуется на основе методов самообучения сформировать алфавит классов, существенных для управления заданным объектом управления в заданной среде. Как известно из теории систем распознавания, для построения самообучаемой системы распознавания, способной без «учителя» сформировать алфавит классов, нужно обязательно задать правила формирования образов, иначе система работать не сможет. Это требование отражает тот факт, что множество исходных объектов, в данном случае — входных сигналов, можно разбить на классы (классифицировать) самыми разнообразными способами. Например, одну и ту же кучу предметов можно расклассифицировать по виду, или по весу, или по цвету, или по форме, или по наличию вредных примесей и т. д. и т. п. То есть, обязательно нужно задать принцип классификации — правило, говорящее, что именно заказчик системы распознавания хочет считать классом.

Нам представляется, что принципы классификации — правила для формирования классов-образов, формируются тоже на этапе формирования биологического вида поисковым методом. И эти правила заложены уже в общую для всех представителей вида морфологию нервных сетей и органов чувств. Однако формирование конкретных образов осуществляется самим индивидом, но на основе полученных им от предков правил. Насколько известно автору, примерами таковых правил являются присущие именно человеку: способности распознавать в зрительной информации прямые линии, из которых строятся более сложные зрительные образы; способности формировать образы человеческих лиц своих соплеменников; по-видимому, наличие большого числа «шаблонов» для формирования конкретных поведенческих паттернов, и, даже, как утверждают, наличие культурологических шаблонов, присущих конкретной этнографической группе [1].

По поводу существа этих правил формирования классов-образов можно предположить, что в них входит принцип кластеризации — т. е. близости в многомерном признаковом пространстве точек, описывающих схожие

объекты. Этот принцип реализуется, в частности, в механизме пластичности нейронных синапсов, которые при прохождении по ним возбуждения взаимно стимулируют рост друг друга, если они расположены в пределах некоторой ограниченной окрестности. Однако среди признаков особо выделяется ось времени, поскольку, во-первых, нервная система живых организмов предназначена, во многом, для управления движением, что требует строгой временной синхронизации движущихся частей организма, а во-вторых, — относительное положение событий во времени отражает причинно-следственные связи явлений в нашем мире, что должно учитываться в формируемых образах, используемых для управления.

На базе таких заданных «шаблонов»-правил, конкретным индивидом формируется множество уже конкретных классов-образов, которые и составляют алфавит классов $\Omega = (\Omega_1, \Omega_2, \dots, \Omega_i, \dots, \Omega_N)$ данного индивида. Эта задача решается применением подходящего метода классификации. Сформированный алфавит классов должен быть запомнен в памяти системы управления индивида (в «памяти образов»). Очевидно также, что алфавит классов — «память образов» конкретного индивида может пополняться на протяжении всей его жизни, т. е. ось Ω на рис. 4 постоянно расширяется. Помимо сказанного, необходимо учитывать, что подсистема формирования образов должна быть способна формировать «образы над образами», т. е. обнаруживать закономерности, включающие в себя более мелкие закономерности. Это тоже приводит к постепенному расширению оси образов Ω (рис. 4), и, более того, — к постепенному переносу области определения «закона управления» в сторону таких более сложных образов.

ЗАДАЧА 2. Следующая задача тоже связана с осью Ω в законе управления на рис. 4. Это задача распознавания образов. Управляющей системе нужно понять, какие из уже сформированных ранее образов действуют (распознаются) в текущий момент. Решение задачи состоит в том, что текущие показания датчиков $X(t)$ сравниваются с содержимым памяти образов — алфавитом классов $\Omega = (\Omega_1, \Omega_2, \dots, \Omega_i, \dots, \Omega_N)$, описанных на языке признаков, и с помощью так называемых «решающих правил», выносится решение — к каким из классов относится текущая ситуация, или — какие образы распознаются в текущий момент. Задача решается применением подходящего метода распознавания. Например, можно использовать какую-либо искусственную нейронную сеть (ИНС).

ЗАДАЧА 3. Определение эффективных «управляющих» воздействий на объект управления и среду (на рис. 4 соответствует определению диапазона и значений оси M). С одной стороны эта задача ограничена возможностями

исполнительных устройств, которыми располагает ОУ. Природа отбирает и конструирует исполнительные устройства тоже применительно ко всему биологическому виду и тоже поисковым способом естественного отбора. Однако в силу большого числа степеней свободы исполнительных органов возникает огромное поле для перебора и выбора нужных воздействий и их комбинаций, как на этапе обучения, так и на этапе принятия решений. Здесь возникает задача целесообразного структурирования данных, описывающих возможные управляющие воздействия, и их представления в памяти. Такое структурирование тоже должно быть основано на некоторой классификации, например, по степени влияния воздействий на результат, для чего можно использовать теоретико-множественные подходы и их логические операции. Очевидно, что структуризация данных об управляющих воздействиях, а также увеличение количества таких данных, могут происходить в течение всей жизни объекта управления, т. е. ось M на рис. 4 может сильно изменяться со временем в процессе адаптации системы управления. Тем самым, можно утверждать, что для адаптивных систем управления и область определения и область значений закона управления могут изменяться в процессе адаптации в результате работы поисковых механизмов.

ЗАДАЧА 4. Поиск статистически достоверного закона управления. Теперь остановимся на самом законе управления (кривая на рис. 4). Откуда она появляется? В технических системах управления на всем протяжении XX века такая кривая определялась в результате решения обратной задачи, описывающей реакцию математической модели заданного ОУ на управляющие воздействия с одновременным учетом целевого положения объекта управления. Вначале составлялась математическая модель ОУ, описывающая изменение состояния ОУ в ответ на то или иное управляющее воздействие. Затем указывалось желаемое для заказчика целевое состояние, и решалась обратная задача. Результат — подобный показанному на рис. 4, «закон управления», указывающий, какое управляющее воздействие нужно применить при заданном отклонении текущего состояния ОУ от желаемого заказчиком, чтобы минимизировать это отклонение.

Очевидно, что точность найденного таким способом закона управления определялась точностью математической модели ОУ. Известно, что возможности современной математики далеко не безграничны, и для многих и многих реальных объектов построить их математические модели и вывести из них эффективные законы управления оказывается делом весьма затруднительным или вовсе невозможным. Каков же выход из такого положения? Выход состоит в построении систем, способных находить оптимальный

закон управления предъявленным объектом минуя этап построения математической модели ОУ, т. е. в построении адаптивных систем управления. В данном контексте легко объяснить способ работы адаптивной системы управления, сделаем это, опираясь на рис. 4.

Прежде всего, ось Ω будем понимать именно как алфавит классов — множество образов, которые уже сформированы системой управления. Потому что при понимании $\Delta\Omega(t)$ именно как рассогласования текущего и желаемого состояний уже учитывается качественный критерий, оценивающий отклонение текущего состояния от цели. В общем случае это должно быть просто множество различных образов. Например, это множество образов различных управляющей системой состояний, в которых может находиться ОУ. Можно упорядочить множество образов в каком-либо отношении, используя правило монотонности — близкие образы описывают близкие состояния ОУ.

Пространство (M, Ω) является поисковым пространством, на котором расположен заранее неизвестный управляющей системе закон управления, который следует найти. При этом в естественных условиях не выделяется особого времени на то, чтобы сначала найти этот закон, а потом уже им пользоваться для управления. В общем случае искать закон управления живым организмам приходится в то же самое время, когда нужно им пользоваться — принимать решения и управлять (иногда выделяется период детства, обучающих игр, обучения родителями и т. п.).

Итак, в процессе жизни ОУ, в текущий момент, система распознавания образов, которая уже сформировала некоторый алфавит классов, распознает конкретный образ текущего состояния $\Omega(t)$ или несколько таких образов (если ни одного образа к этому моменту еще не было сформировано, то это тоже вполне «штатный» случай, просто неопределенность еще больше возрастает). Для простоты, пусть это будет один образ $\Omega_i(t)$. Тем самым в признаковом пространстве (M, Ω) выделяется столбец, соответствующий образу $\Omega_i(t)$. Пусть закон управления еще не определен для этого столбца, т. е. система управления еще «не знает», какое управляющее воздействие $M_k(t+1)$ ей следует выбрать для исполнения в следующий момент $(t+1)$. Для поиска наилучшего решения системе управления следует в самом общем случае использовать метод «проб и ошибок», выбирая воздействие $M_k(t+1)$ случайным способом и запоминая, что получится в результате. В качестве результата нужно фиксировать номер образа того состояния, в которое перейдет ОУ после совершения действия $M_k(t+1)$. Конечно, результат может состоять в том, что будет вызвано распознавание нескольких

новых образов и/или прекратится распознавание нескольких ранее распознанных образов. Это все надо фиксировать в определенной структуре. Для простоты будем считать, что результат состоит в распознавании одного образа $\Omega_r(t+2)$. Можно ли считать, что переход из состояния $\Omega_i(t)$ при совершении воздействия $M_k(t+1)$ в состояние $\Omega_r(t+2)$, т. е. тройка

$$\langle \Omega_i(t), M_k(t+1), \Omega_r(t+2) \rangle, \quad (1)$$

которая, на самом деле, получена по ретроспективным данным о предыстории

$$\langle \Omega_i(t-2), M_k(t-1), \Omega_r(t) \rangle, \quad (2)$$

является закономерным результатом? По одному прецеденту считать так, в общем случае, нельзя. Следовательно, надо накопить убедительную статистику. Значит, система управления должна каждый раз, когда она попадает в состояние $\Omega_i(t)$, пробовать совершать разные действия $M_k(t+1)$, но для каждого из них запоминать результат $\Omega_r(t+2)$, и подсчитывать число повторяющихся совпадений. Если некоторая тройка вида (2) повторится в предыстории не менее, чем M раз, что достаточно для заключения о неслучайном характере совпадения, то такую тройку системе управления следует сохранить как элементарное «знание» о свойствах ОУ (а точнее — системы «среда–объект управления–система управления»). Назовем памятью, где сохраняются знания, *Базой Знаний* (БЗ). При определенных условиях в БЗ следует сохранять и знания об отдельных прецедентах, но это уже более сложные подробности, которые сейчас опустим.

Подчеркнем в сказанном одну важную деталь: основным способом получения эмпирических знаний, которые можно использовать при управлении, является **поиск многократно повторяемых комбинаций событий** вида (1). «Если у меня в руке зажат камень, и я разожму руку, то камень упадет. А если не разожму — то не упадет. Я это знаю, потому что это было уже много раз».

Итак, в Базе Знаний накапливается в виде совокупности троек (2) статистически достоверная информация о том, в какие известные состояния Ω_r объект управления закономерно переходит при совершении воздействий M_k , если перед этим ОУ находился в состоянии Ω_i . Поскольку ретроспективные данные вида (2) имеют статистическое подтверждение (каждая тройка повторялась не менее, чем M раз), то это дает уверенность в том, они будут повторяться и в будущем и их можно использовать для прогнозирования. Поэтому при принятии решений система управления с опре-

деленным, но вынужденным риском, экстраполирует известные ей ретроспективные закономерности (2) окружающего мира, сдвигая их по времени в будущее и превращая в прогноз вида (1). Тем самым, система управления, распознав, что она находится в текущий момент в состоянии $\Omega_i(t)$, имеет основания предполагать, что если она совершит действие $M_k(t+1)$, то к моменту $(t+2)$ ОУ должен перейти в состояние $\Omega_r(t+2)$. Это и есть тот прогноз, на который может опираться система управления при принятии решений.

Однако одного знания о том, какими способами можно целенаправленно перейти в этом мире из одного состояния в другие, т. е., того, что записано в Базе Знаний, не достаточно для управления. Потому, что в этих знаниях не указано качественное различие между разными состояниями, тем самым — отсутствуют указания на целевые состояния, перейти в которые и следует стремиться. Такого рода знания эквивалентны карте метрополитена в руках без указания целевой точки в городе, в которую нам следует сейчас добраться, и без меры, позволяющей оценить степень близости различных станций к искомой целевой точке в городе.

Не останавливаясь здесь подробно на этом вопросе, скажем только, что управляющей системе абсолютно необходимо наличие некоторой качественной шкалы оценок, которыми можно характеризовать образы состояний. В технических системах такие оценки введены в виде мер, оценивающих состояния ОУ в признаковом пространстве относительно целевой точки, заданной заказчиком системы (например, отклонение траектории полета от заданной). Но в природных системах управления, как было сказано выше, есть только две главные целевые функции — (а) выживание и (б) накопление знаний. Поэтому качественные оценки всех образов так или иначе характеризуют образы именно в соответствии с этими целевыми функциями. Каждый сформированный системой управления образ снабжается своей качественной оценкой. И эта оценка характеризует важность этого образа для выживания ОУ или его полезность для накопления знаний. Разные образы с одинаковыми оценками равноценны для природной системы управления. Это дает нам возможность выбирать между разнородными целевыми состояниями, например, «вкусное пирожное ли мне съесть или лучше интересную книжку почитать?». Источниками качественных оценок для образов являются: априорные знания, переданные в генофонде от предков, — для базовых образов, обеспечивающих основной гомеостаз, собственный опыт — для вновь сформированных образов конкретных объектов, процессов и состояний, а также «аналитически» выведенные оценки

для некоторых труднодостижимых образов (на аналитическом выводе таких оценок, как и на аналитическом выводе новых знаний, останавливаться здесь не будем). Автор глубоко убежден, что подсистемой, обеспечивающей нервную систему любого живого организма информацией о качественных оценках образов, является эмоциональный аппарат, присутствующий в любом живом организме [2–4]. Другой важной функцией эмоционального аппарата в природных системах управления является «овеществление» указанных целевых функций — выживания и накопления знаний в виде одной универсальной цели — стремления к максимизации обобщенной текущей эмоциональной оценки, характеризующей состояние ОУ. Это один из «обманов» Природы, которым она заставляет все организмы быть активными в окружающей среде, постоянно воздействовать на среду, что приносит нервной системе новые знания, которые и повышают вероятность выживания ОУ.

Можно утверждать, что в каждой природной системе управления в некотором виде присутствует таблица (см. пример на рис. 5), в которой каждому сформированному образу поставлена в соответствие его качественная, или как будем говорить — «эмоциональная» оценка.

Номер образа Ω_i	Эмоциональная оценка образа S_i
Ω_1	так себе
Ω_2	хорошо
Ω_N	очень плохо

Рис. 5. Пример таблицы эмоциональных оценок S_i сформированных образов Ω_i . Оценки заданы априорно, либо найдены в процессе жизни объекта управления

Итак, вернемся к рис. 4. Первоначально отсутствующая кривая «закона управления» на нем появляется в результате следующих операций. Каждый раз, когда ОУ попадает в текущее состояние Ω_i , система управления пробует совершать различные действия M , как это было описано выше, получая в результате распознавание образов результатов. Если эти образы Ω_r результирующих состояний статистически повторяются, то они записываются в долговременную память — в Базу Знаний. На этом множестве образов Ω_r результирующих состояний строится еще одно измерение S_i — значения эмпирически найденных эмоциональных оценок этих состояний

с помощью таблицы (рис. 5).

Подчеркнем два важных момента. Формирование образа результата совершения того или иного действия — достаточно сложная задача, требующая наличия у системы управления определенных ресурсов. Здесь также требуется применение самообучаемой системы распознавания. В общем случае, множество образов результатов действий не обязательно совпадает с множеством образов исходных состояний. Образы исходных состояний могут быть очень конкретными, а образы результирующих состояний могут быть более общими, размытыми. Например, образ целой чашки в руке перед тем, как ее роняют на пол — это одно, а образ разбившихся чашек — это более общий образ, это то общее, что есть у всех разбившихся об пол чашек. У каждого ли животного имеется такая по мощности система распознавания, которая может формировать точный образ результата? Поэтому сравнивать реально случившийся результат с тем результатом, который планировался — это по силам далеко не всякому организму, потому что далеко не всякий организм в состоянии в подробностях представить себе результат своего выбранного действия. Нам представляется, что простые организмы могут формировать образы результатов только в очень простой форме. Самая простая форма образа результата — это просто его эмоциональная оценка. Т. е., организм запоминает, что если он сделает это, то будет «хорошо» или «плохо», но не может себе представить образ результата более содержательно. И такого представления образа результата может быть вполне достаточно для эффективного принятия решений хотя бы на один шаг вперед. Нервная система как бы говорит себе: «Я сделаю так потому, что знаю, что в результате будет хорошо». Примерно так работают известные системы с подкрепляющим обучением, Reinforcement Learning Systems. Более продвинутая нервная система в этом случае может сказать: «Я сделаю так потому, что в результате перейду в такое-то конкретное состояние, а оно “хорошее”». Во втором случае система управления может планировать свои решения на несколько шагов вперед, например, сначала сознательно перейдя в состояние с плохой оценкой, чтобы потом иметь возможность перейти в состояние с уже более хорошей оценкой, т. е. проходить через локальные минимумы.

Отсюда очевиден алгоритм принятия решений системой управления. Он состоит в следующем. Система распознавания распознает образ (или множество образов) текущего состояния Ω_i . По этому номеру образа (или номерам образов) БЗ отделяет ту свою часть, которая адекватна текущей ситуации, на рис. 4 это столбец образов результатов. По таблице (рис. 5)

находятся эмоциональные оценки образов результатов. Далее решается оптимизационная задача — нужно найти действие, соответствующее образу (или образам) результатов с максимальной оценкой (оценками). На рис. 4 это действие $M(t+1)$. Задача поиска максимума зависит от полноты имеющихся данных. Если система управления успела ранее исследовать все возможные действия, что уже отражено в БЗ, то в текущий момент остается только выбрать действие, соответствующее максимуму (т. е. «из всех возможных в текущий момент действий, я выбираю то, которое даст мне результат с наибольшей из возможных в этой ситуации эмоциональных оценок»). Отсюда совсем не следует, что новое состояние будет лучше предыдущего). Это удовлетворяет целевой функции «выживания».

Если же в отделенных БЗ данных имеются пропуски (см. рис. 4), т. е. система управления еще не знает о результатах всех возможных действий, а известные действия обещают только плохие результаты, то она может принять решение о совершении пробных действий в попытке заполнить пробелы в БЗ и найти действие, которое в подобных условиях даст хороший результат. Это удовлетворяет целевой функции «накопления знаний». Принятие решения здесь предполагает применение некоторой стратегии поиска — случайного перебора, градиентного спуска, действия по аналогии, по прецедентам и т. п. Для организации направленного поиска здесь возможно применение различных способов прогнозирования знаний, их формального вывода [5–9]. Более того, без применения некоторой стратегии направленного поиска с использованием всей доступной априорной информации (переданной генетически в виде неких шаблонов от предков, а в технических системах — идущих от научных знаний) мы сразу же сталкиваемся с «проклятием размерности» в попытках организовать поиск методом простого перебора в достаточно сложных признаковых пространствах. Результаты таких пробных действий, более или менее обоснованных и со случайной компонентой, приносят новые знания, которые могут попасть в БЗ, где хранится уже статистически обоснованная информация.

Из найденных экстремальных по эмоциональным оценкам результатов действий для каждого из известных образов исходных состояний и складывается, в конечном счете, тот закон управления, который показан как кривая на рис. 4 и 2. Но в отличие от традиционного неадаптивного варианта (рис. 2), закон управления, найденный адаптивной системой управления (рис. 4), отражает не аналитически выведенный приближительный закон управления, а реальный, соответствующий текущим свойствам предъявленного объекта управления. При этом закон управления, представленный

в БЗ адаптивной системы управления, будет изменяться со временем, если свойства объекта, окружающей среды, или других компонент системы изменяются.



той своей части, которая является автономной, если даже другая ее часть работает по указанию из неизвестных нам источников. Поэтому мы смело можем утверждать, что рассмотренная схема адаптивного управления в полной мере относится и к живым организмам (рис. 6).

В более подробном виде, с указанием необходимых разделов памяти, а также некоторых, не описанных выше, но важных блоков, именно — подсистемы управления Базой Знаний (выполняющей, в частности, и задачу формального вывода новых знаний), а также подсистемы определения временного темпа принятия решений, схема системы автономного адаптивного управления представлена на рис. 7.

Рис. 7 представляет схему автономной адаптивной системы управления и, одновременно, ее прообраза — нервной системы, так, как они должны выглядеть в общем случае с кибернетической точки зрения. В данной схеме выделяются функциональные блоки и блоки памяти. Все функциональные блоки в этой системе должны быть адаптивными, самообучаемыми. Все блоки работают в двух параллельных режимах.

Первый режим есть обучение на основе ретроспективных данных, отражающих историю процесса управления, записанных в доступных им разделах памяти. Каждый раздел памяти обладает своей глубиной — характерным временем обновления. Поэтому обучение может происходить в «фоновой» манере, в своем темпе и независимо от процесса управления, однако оно должно успевать за обновлением данных в памяти. Результаты обучения также записываются в соответствующие разделы памяти, что и составляет собственно процесс адаптации. А именно, в процессе развития индивида самообучаются: подсистема формирования и распознавания образов (результат записывается в память образов), подсистема эмоций, База Знаний, подсистема определения времени принятия решений. В процессе развития вида на другой временной шкале адаптируются: датчики и исполнители, а также «шаблоны» — правила для самообучаемых систем, передаваемые всем индивидам.

Второй из параллельно идущих режимов, есть режим управления. Он основан на взаимосогласованной работе всех указанных подсистем, и пользуется теми данными, которые к текущему моменту уже записаны в соответствующих разделах памяти. Например, результат распознавания образов зависит от того, какие образы были сформированы ранее, а результат принятия решений зависит и от распознанных образов, и от текущего содержания Базы Знаний, и от сложившихся к текущему моменту эмоциональных оценок образов. Любое изменение содержимого любого из этих разделов

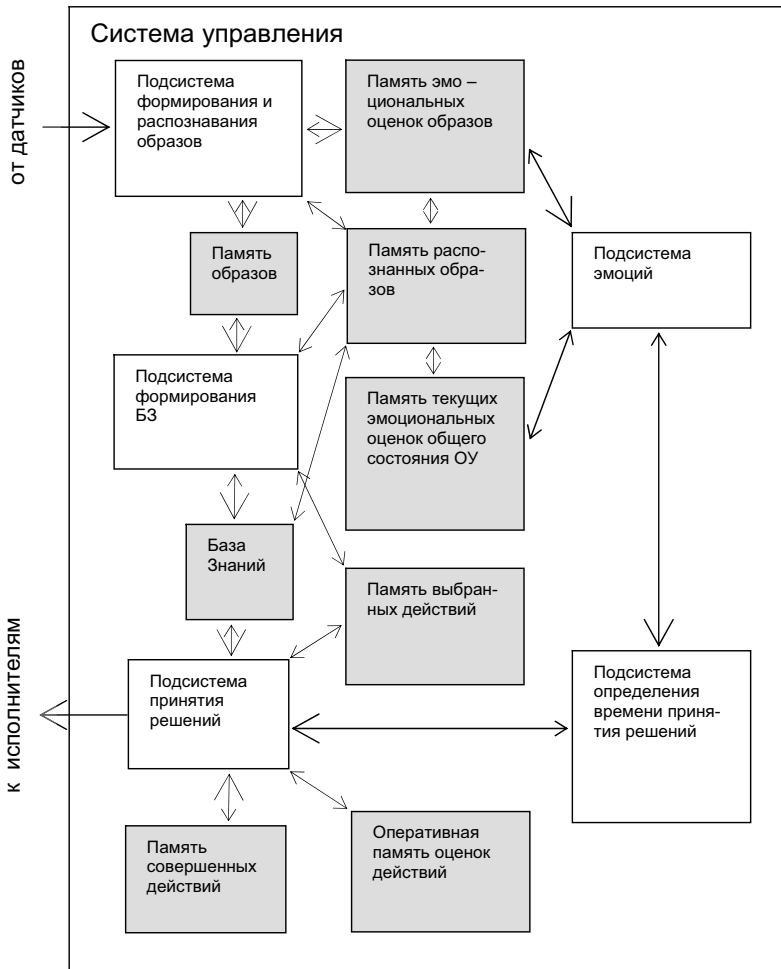


Рис. 7. Схема системы «Автономного адаптивного управления», как концептуальной модели нервной системы. Функциональные блоки и блоки памяти

памяти может привести к существенно иному результату принятия решений.

Еще раз в общих чертах опишем алгоритм работы адаптивной системы управления (аналога нервной системы).

1. Подсистема формирования и распознавания образов распознает в текущей входной информации те образы, которые она может распознать в текущий момент на основе показаний датчиков, содержимого памяти образов и имеющихся алгоритмов распознавания. Множество распознанных в текущий момент образов появляется на выходе распознающей системы. Одновременно в фоновом режиме эта же подсистема формирует новые образы на основе показаний датчиков и содержимого памяти образов — находит те комбинации входных сигналов и распознаваемых образов, которые появляются уже много раз либо сопровождаются сильной эмоцией. Результат — новые сформированные образы, записывается в память образов.

2. Подсистема (аппарат) эмоций, располагая ассоциированными с распознанными образами их эмоциональными оценками, суммирует эти оценки, получая интегральную эмоциональную оценку текущего состояния. Эта интегральная эмоциональная оценка текущего состояния поступает в подсистему определения времени принятия решений. Вычисляется время, отведенное на принятие решения, которое тем меньше, чем текущая ситуация хуже или чем быстрее она ухудшается. Одновременно подсистема эмоций находит или уточняет эмоциональные оценки для новых, недавно сформированных образов, путем поиска корреляции между фактами их наблюдения и вариациями интегральной эмоциональной оценки текущего состояния. Помимо этого, аппарат эмоций задает универсальную «мотивацию» управляющей системе — она всегда заставляет систему управления стремиться к увеличению интегральной эмоциональной оценки текущего состояния. Эта универсальная «мотивация» «защита» в устройстве подсистемы принятия решений. «Доминирующая мотивация» — это распознанные в текущий момент образы с наибольшими отрицательными оценками или возможность, согласно БЗ, в текущий момент вызвать распознавание образов с большими оценками.

3. База Знаний в режиме принятия решений получает на вход множество распознанных в текущий момент образов и отделяет ту свою часть, которая адекватна текущей ситуации — это та часть, в которой есть записи, указывающие, какие действия, согласно предыдущему опыту или априор-

ной информации, можно совершать в текущей ситуации. (Например, если распознаны образы, говорящие о том, что вы вошли в магазин, то БЗ активизирует те записи, в которых перечислены все возможные действия, которые вы умеете совершать, входя в магазин. Если распознанные образы говорят о том, что вы оказались под водой, то в БЗ отделяется та ее часть, где записаны все доступные вам действия, которые вы умеете совершать под водой). Эта отделенная часть БЗ открывается для доступа со стороны системы принятия решений. Параллельно с этим в фоновом режиме обучения подсистема формирования БЗ пытается формировать новые знания. Для этого она просматривает доступные ей «архивы» — память распознанных образов и память совершенных действий, пытаясь обнаружить в ней закономерные тройки вида (2). Если таковые находятся, то они вносятся в БЗ, расширяя знания. Кроме этого, подсистема формирования БЗ пытается формальными способами (например, методом аналогий) вывести новые знания на основе анализа содержимого БЗ. Если таковые новые знания обнаруживаются, то они записываются в БЗ, но с пометкой «Прогноз. Проверить!». Такие прогнозируемые знания могут служить направляющей нитью при целенаправленном поиске новых полезных, с точки зрения целевых функций, знаний.

4. Подсистема принятия решений работает следующим способом. От подсистемы определения времени принятия решений, она получает указание на отведенное ей время для совершения своей работы в данный акт управления. Как было сказано выше, отведенное время T тем короче, чем текущая ситуация хуже (по текущей интегральной эмоциональной оценке) или чем быстрее она ухудшается (1-я производная). Если ситуация настолько плоха, или так быстро ухудшается, что на принятие решения отводится ноль времени, $\Delta T = 0$, то система управления отключается — «падает в обморок». Если $\Delta T > 0$, то эта величина переводится в некое число k , характеризующее глубину просмотра БЗ, которую можно себе позволить в текущей ситуации. Обычно это небольшая величина. Смысл принятия решения состоит в следующем. Согласно открывшемуся ей фрагменту БЗ, система управления знает, какими действиями в данной ситуации она может пользоваться, и что произойдет в результате совершения каждого из альтернативных действий. А именно, какие образы можно вызвать, а какие образы можно вытеснить (прекратить их распознавание). Естественно, что вместе с образами появляются или исчезают и их эмоциональные оценки. Подсистеме принятия решений остается только оценить суммарный выиг-

рыш по каждому из альтернативных действий и выбрать действие, которое обещает дать максимальный выигрыш по суммарной эмоциональной оценке. При этом в БЗ просматривается только влияние на k образов результатов с максимальными по модулю их эмоциональными оценками. Именно поэтому мы постоянно выбираем между выигрышами и проигрышами, например, запросто выбираем между такими разнородными образами, как ущерб своему здоровью и получение приятных нам впечатлений. Подчеркиваем, что при принятии решений играет роль только эмоциональная оценка образов и ассоциативно распознаваемых одновременно с ними ансамблей, а отнюдь не их содержание. Поэтому, например, трудно бороться с пороками — если вызываемые ими положительные эмоции нечем перекрыть, то эти состояния будут вызываться вновь и вновь. В большинстве случаев системе управления приходится бороться с распознанными образами, имеющими отрицательные оценки. Мы часто распознаем образы с отрицательными оценками — пустота в желудке, холод либо жара в помещении, сигналы от всяческих желез и внутренних органов, неприятности в окружающей среде и тому подобные образы заставляют нас выбирать действия, обещающие прекратить эти мучения. Редко ничто нас не беспокоит, и тогда мы можем подумать о том, как бы нам вызвать распознавание приятного образа. Либо появляется шанс поймать сравнительно большой выигрыш, пренебрегая неудобствами, и тогда мы решаемся на такой шаг. Если в результате выбора находится несколько действий, абсолютно равноценных по эмоциональной оценке результата, то выбор производится случайным способом.

5. Номер выбранного действия сообщается исполнительным устройствам, которые его реализуют.

6. Каждый цикл принятия решений сопровождается сохранением некоторой информации в соответствующих разделах памяти. Эти разделы памяти могут быть кратковременными (некоторое время помним, что видели или что сделали), а некоторые — долговременными, например, память образов или БЗ, куда записываются извлеченные из опыта знания.

7. Подчеркнем, что система управления работает крайне формально — все сигналы с датчиков и с нейронов, распознающих образы — одинаковые нервные импульсы, для нее равноценны. Отличие проявляется только в эмоциональных оценках разных образов. И принятие решений строится только на основании сравнения этих эмоциональных оценок. Другое дело, что с ростом интеллекта возрастает сложность образов, их специализация или абстрактность, а также степень ассоциативности. Память образов, База

S — память эмоциональных оценок образов,

$S(t)$ — интегральная эмоциональная оценка текущего состояния,

$\langle \Omega_i(t), M_k(t+1), \Omega_r(t+2) \rangle$ — База Знаний,

$\Delta T(t)$ — интервал времени на принятие решения,

$M_k(t+1)$ — принятое решение — управляющее воздействие,

K_a — набор априорных правил формирования знаний,

Rnd — генератор случайных воздействий, необходимый для обеспечения поиска,

L — исполнительные устройства, операции:

- 1 — измерения и перевод физических воздействий в цифровой вид,
- 2 — распознавание образов,
- 3 — формирование новых образов — алфавита классов,
- 4 — формирование Базы Знаний,
- 5 — извлечение из памяти эмоциональных оценок распознанных образов,
- 6 — вычисление интегральной эмоциональной оценки текущего состояния объекта управления,
- 7 — обмен информацией с памятью эмоциональных оценок образов,
- 8 — вычисление времени, отведенного на принятие решения,
- 9 — принятие решения,
- 10 — использование генератора случайных воздействий при необходимости выбора из равнозначных вариантов,
- 11 — формальный вывод новых знаний по БЗ и на основе набора априорных правил формирования знаний,
- 12 — передача принятого решения исполнительным устройствам,
- 13 — обратная связь от исполнительных устройств к датчикам через тело объекта управления и окружающую среду.

Несколько критических замечаний в отношении общепринятого понимания процесса управления

Почему мы уделяем этим вопросам понимания процесса управления такое большое внимание? По двум причинам. Во-первых, понимание принципов адаптивного управления, реализуемого в природных управляющих системах — нервных системах, дает нам возможность самим строить системы управления с адаптивными свойствами, а необходимость в таких системах уже назрела, о чем было сказано в первой части статьи. Во-вторых, анализируя соответствующую литературу, можно сделать вывод о том, что сегодня не существует общепринятого понимания того принципа управления, который реализован в биологических системах. Проблемами понимания принципа действия мозга сегодня озабочены: нейрофизиологи, кибернетики, инженеры и философы. Оказалось, что в силу сложности объекта исследования на пути каждого из этих специалистов стоят специфические проблемы.

Нейрофизиологи стараются найти ответы с помощью изошренных инструментов и методик наблюдения нервной активности, освоение и использование которых требует больших усилий. Однако объект изучения — мозг, морфологически очень сложен. Понять принцип работы мозга с помощью исследования его материальных реализаций практически невозможно, как невозможно понять принцип работы неизвестного микропроцессора только с помощью микроскопа, но без понимания принципов построения вычислительной машины. Нейрофизиологи под тяжестью открывшегося им вида сложнейшей машины нередко «сваливаются» в изучение деталей, не существенных для понимания принципа управления. С другой стороны, нейрофизиологи не обязаны знать ни принципов построения систем распознавания образов, ни принципов принятия решений, и тому подобных дисциплин, которые выходят за рамки биологии. Однако мозг, работающий с информацией, вынужден работать как кибернетическая машина, он не может пренебрегать принципами работы с информацией. И без понимания этих принципов понять принцип работы мозга - кибернетической машины - нельзя. Поэтому можно наблюдать парадоксальные ситуации. Например, в последние несколько лет нейрофизиологами дискутируется вопрос о том, имеется ли в нервной системе подсистема принятия решений (decision-making)? Хотя кажется очевидным, что если животное выбирает, куда повернуть — направо или налево, то это означает, что у него есть некий центр принятия решений. Определяется ли принятие решений уровнем некото-

рого гормона в межклеточной среде? Решение определяется результатами обучения, а тот или иной гормон — это лишь одна из деталей механизма хранения, передачи и использования информации в процессе принятия решений. Другая «ловушка» для нейрофизиологов — это отвлечение на исследование экстремальных или побочных эффектов, демонстрируемых нервной системой в необычных для нее условиях.

Кибернетики и математики, в свою очередь, тоже пока не в состоянии разобраться с работой мозга, потому что они полагают, что без досконального знания предмета изучения — мозга, понять его работу нельзя, а начинать погружаться в океан биологической информации сложившемуся специалисту из другой области решиться трудно. Поэтому у кибернетиков и математиков бытует такое представление: мы не знаем, как работает мозг, и заниматься его изучением не будем, дайте нам постановку задачи, и мы придумаем программу, которая будет делать то же самое. И они с успехом создают такого рода программы — шахматные компьютеры, автоматические переводчики с языка на язык, шагающих и танцующих роботов и т. п. Однако эти программы практически ничего общего не имеют с устройством мозга и ничего не объясняют в его устройстве.

Все это вместе приводит к довольно странным представлениям о работе мозга, которые можно увидеть в современной научной литературе. Одно из бытующих представлений состоит в том, что поведение мозга определяется записанной где-то в его памяти таблицей вида «состояние» → «адекватная реакция».

В рассмотренной выше общей модели адаптивного управления (4), это соответствует таблице

$$\langle \Omega_i(t) \rightarrow M_k(t+1) \rangle, \quad (3)$$

т. е. мозг живет по правилу: «Если распознан образ $\Omega_i(t)$, то совершай действие $M_k(t+1)$ ».

Однако такой способ управления приписать живому организму совершенно невозможно. Прежде всего, в таком «табличном» понимании способа управления не описывается механизм обучения, и отсутствует свобода выбора, присущая живым организмам. В схеме на рис. 7 и в формализации (4) это соответствует только некоторой части подсистемы распознавания, сильно обедненной Базе Знаний и примитивной процедуре принятия решений. С точки зрения рассмотренной выше схемы автономного адаптивного управления остается неясным:

- кто и каким способом нашел, что именно образы Ω_i являются инфор-

если давление превышает заданный уровень — клапан открывается и давление падает до уровня, при котором клапан закрывается. Можно оставить только датчики и систему распознавания, и принимать решения, однозначно соответствующие распознанным образам. Так работает львиная доля технических систем управления. Другой вариант — можно выкинуть из цикла управления все, оставив только базу знаний, с закачанными в нее знаниями от человека-эксперта — так работают экспертные системы, и это считается одной из вершин в теории искусственного интеллекта. И т. д. Нам представляется, что настало время переходить к построению действительно интеллектуальных систем управления в их полном виде.

В нейрофизиологической литературе ответ на вопрос о принципе действия нервной системы обычно завуалирован общими фразами, смысл которых сводится к очевидным утверждениям, что в нервной сети есть маршруты от входа к выходу — рефлекторные дуги, и что работа нервной системы зависит от топологии этой сети и других причин, влияющих на ее функционирование. Вопросы обучения, составления базы знаний, логики принятия решений и другие вопросы о принципах адаптивного управления, как правило, не рассматриваются совсем. И это положение дел понятно. Ответственные биологи должны основывать свои выводы на достоверных наблюдениях. Мозг же, являясь сильно распределенной системой, с мощными средствами, обеспечивающими его помехозащищенность и отказоустойчивость, насквозь адаптивный — постоянно приспосабливающийся и постоянно изменяющий свои проявления и реакции на раздражения, будучи активной, а не реактивной системой, является крайне трудным, постоянно меняющимся объектом изучения для выделения в нем устойчивых реакций и свойств. Поэтому, не понимая логики работы мозга, в нем очень трудно выделить что-то детерминированное, это ставит исследователей в весьма затруднительное положение.

Наиболее продвинутой моделью нервной системы долгие годы была модель, предложенная в 30-х годах прошлого века академиком П. К. Анохиным и названная «Функциональной системой» (рис. 8). В те годы эта модель, действительно, явилась выдающимся шагом вперед. В ней впервые обращалось внимание на необходимость различения в биологических системах, как управляемых объектах, контуров обратной связи, необходимой для целенаправленного управления, акцентировалась необходимость системного подхода в их понимании.

Теория функциональных систем (ФС) долгие годы являлась путеводной нитью в исследованиях принципов функционирования живых объектов,

она объединяла идеологию исследований многих и многих специалистов, и в этом ее большое достоинство. Развившиеся за прошедшие годы представления, в том числе — полученные, исходя из иных отправных точек, дают нам сегодня возможность яснее увидеть как правильные стороны в предложенном описании ФС, которые нашли экспериментальное подтверждение, так и те стороны, которые сегодня могут быть уточнены или изменены. Рассмотрим некоторые такие детали ФС.




Рис. 8. Схема функциональной системы по П. К. Анохину

ФС рассматривалась как определенный «шаблон», который можно применять к решению разных задач управления, и который возникает в нервной системе в том месте, в котором организуется управление. Однако нам известно о трудностях, которые возникали при попытках построить систему управления по схеме ФС. Нам представляется, что причиной этому являются некоторые неопределенности, скрывающиеся за указанными в ФС понятиями, а иногда чрезмерно сложные для реализации задачи. Укажем некоторые из них. Так, понятие «афферентного синтеза» вполне раскрывается понятиями из теории систем распознавания образов, описывающими способ построения самообучаемых систем распознавания. Это понятия: множество измерителей, признаковое пространство, рабочий словарь признаков, правила формирования образов, алфавит классов, описание классов на языке признаков, решающие правила, а также программа управления

процессом распознавания. Эти известные решения полностью описывают функции подсистемы афферентного синтеза и результат его работы: а)

Представляется не вполне обоснованным введение в ФС такой подсистемы, как «Акцептор результата действия». По замыслу, видимо, это подсистема, которая воспринимает воздействие со стороны среды, являющееся откликом среды на Действие объекта управления. Прежде всего, неясно, как отличать воздействия среды, являющиеся результатом Действия, от воздействий среды, не являющихся таким результатом. Поиск таких результатов человечество занимается усиленно уже много лет. Пример: является ли глобальное потепление результатом нашего воздействия на Природу, или не является. Или более простой пример: является ли боль в печени следствием того, что я съел именно этот салат? Не всякому специальному исследованию удастся найти такую связь, а примитивному животному отделить сходу результат Действия от просто «Обстановочной афференциации» не представляется возможным. Мы приходим к выводу, что нет смысла выделять такую подсистему, как «Акцептор результата действия». Потому что результат Действий воспринимается теми же самыми датчиками и той же самой системой распознавания, которые воспринимают все воздействия со стороны внешней и внутренней среды.

Кроме того, надо также представить себе сложность сравнения прогнозируемого результата действия с реальным результатом. Если улитка принимает решение переползти на соседнее место, то вряд ли она может себе вообразить, как будет выглядеть это соседнее место, с тем, чтобы иметь возможность сравнить результат и свой прогноз. Боюсь, что в голове улитки просто нечем вообразить себе этот планируемый результат. Для яркого и подробного воображения себе ожидаемого результата действия, допускающего последующее его сравнение с реальностью, надо иметь довольно развитые мозги, Базу Знаний, и, возможно, даже язык, с помощью которого из этой Базы Знаний можно было бы по своему желанию извлекать подробности ожидаемого результата. Нам представляется, что, во-первых, результат ожидается в большинстве случаев либо в виде самых простых образов — сытости, тепла, полового удовольствия и т. п., а у более простых организмов и просто в виде эмоциональных оценок результата: например, улитка помнит, что если переползти на соседнее место в случае, когда все под собой уже съела, то будет хорошо. Вообразить себе это новое место она, возможно, не в состоянии. Во-вторых, а надо ли сравнивать результат с прогнозом? Во всех наших реализациях систем автономного адаптивного управления, которые реально демонстрировали способность к адаптивному управлению, осуществлять такое сравнение в общем случае было не нужно. Закономерные результаты совершения действий в определенных

исходных условиях, накапливались в Базе Знаний, и если они там были, то использовались при принятии решений. Система управления автоматически полагается на надежность той информации, которую она записала ранее в БЗ. Если же в результате выбора и совершения действия, результат расходился с тем, что было записано в БЗ, то ничего страшного для системы управления не происходило. В новой ситуации она снова обращалась к БЗ и двигалась дальше. Впадать в разочарование или предпринимать работу над ошибками при выявлении такого расхождения в общем случае ни к чему, для этого нет ни времени, ни необходимости — надо двигаться дальше в новых условиях. Если же БЗ содержала ошибочную информацию, либо если свойства среды или ОУ изменились, то БЗ постепенно переучится в свойственной ей манере. Нам представляется, что такого рода операцию — сравнение планируемого результата с реальным, осуществляют только в редких специальных случаях высокоорганизованные животные. Например, тогда, когда они выводят новые знания некоторым формальным способом из старых, и потом хотят проверить справедливость своего прогноза. Так поступают, например, ученые, кропотливо проверяющие свои гипотезы. У небольшого организма может не оказаться ни средств для воображения ожидаемого результата, ни памяти для того, чтобы этот воображаемый результат сохранить до нужного момента, ни средств, с помощью которых можно было бы как-то сравнить наступившую реальность с тем, что отложено в память, ни возможностей, чтобы как-то использовать результаты такого сравнения. Это в общем случае ненужная операция.

Следует обратить внимание на то, что в схеме ФС отсутствует такая важнейшая подсистема как База Знаний — память, в которой накапливается добытая системой управления статистически достоверная информация о причинно-следственных связях в системе «объект-среда». Такая эмпирически найденная информация принципиально необходима для обоснованного принятия решений. Она является своего рода «моделью мира», которую система управления строит и использует для выбора альтернативных вариантов своего поведения. При отсутствии такой информации совершенно неясно, на что может опираться система управления при принятии решений, и где сохраняются результаты ее адаптации. «Программы действий» живого организма не могут быть жестко заданными. Прежде всего, это должны быть программы выбора из альтернативных вариантов на основе накопленных в памяти знаний. Нам представляется, что появление в ФС таких объектов и операций, как Акцептор результата действия, обратная афферентация, сравнение результата действия с прогнозом, вызваны

попыткой заменить ими центральное отсутствующее звено — память эмпирически найденных в окружающем мире причинно-следственных связей — Базу Знаний. Без памяти для хранения знаний нельзя построить адаптивное управление. Если под памятью понимать хранилище Программ действий в виде четких однозначных предписаний, то это тоже не верно. Память в рассматриваемых системах должна содержать не столько однозначные программы, сколько наборы возможностей, из которых управляющая система имеет право выбирать более или менее обоснованно, но с элементом случайности, без которой невозможно развитие.

Представленные нами теоретические принципы и схема автономного адаптивного управления (ААУ) были выведены нами из понимания общих принципов управления, которые применимы и к техническим и к биологическим объектам, работающим в одинаковых исходных условиях, поскольку являются логически вынужденными. Сопоставление системы ААУ с ФС П. К. Анохина, ориентированной на биологические системы, может оказаться весьма полезным, так как может обогатить обе теории.

Искусственные нейронные сети

Коротко проанализируем существующее состояние дел с таким важным и полезным разделом науки, имеющим отношение к проблеме построения адаптивных систем управления, как искусственные нейронные сети (ИНС). ИНС часто рассматриваются как модели нервной системы, способные воспроизводить принципы ее функционирования. Мы разделяем мнение тех специалистов, которые считают, что такие параллели очень мало оправданы и здесь покажем, почему.

Основные свойства ИНС стоят в следующем. ИНС по своему устройству представляет собой обучаемую с учителем, либо (что реже) самообучаемую геометрическую (детерминированную) систему распознавания образов, либо обучаемый (самообучаемый) аппроксиматор функций (рис. 9).

Когда ИНС обучена и используется в рабочем режиме (рис. 9), то в общей схеме автономной адаптивной системы управления (4) она может быть использована либо для реализации отображения показаний датчиков в вектор входной информации $1 : \mathbf{T} \rightarrow \mathbf{X}$, либо в качестве системы распознавания образов, осуществляющей преобразование от показаний датчиков к распознанным образам $2 : \mathbf{X} \rightarrow \{\Omega_i(t)\}$. При желании, ИНС можно использовать для реализации некоторых других отдельных отображений в




Рис. 9. В рабочем режиме ИНС выполняет функции системы распознавания образов, либо аппроксимирует заданную функцию

схеме (4), например, отображения $6 : \{S_i(t)\} \rightarrow S(t)$ или $8 : S(t) \rightarrow \Delta T(t)$. Но реализовать работу всей автономной адаптивной системы управления, т. е., осуществлять отображение от входных сигналов к выходным реакциям системы управления $X(t) \rightarrow L(t+1)$ ИНС никак не в состоянии. Дело даже не в структуре ИНС, препятствия начинаются уже с самого способа обучения ИНС (рис. 10).

Обучение ИНС требует наличия «учителя», имеющего возможности: а) знать желаемый выход ИНС для каждого из входных векторов, б) наблюдать множество всех выходных сигналов ИНС, в) сравнивать реальный выход с желаемым, вычисляя невязку, г) иметь доступ к весам (синапсам) всех нейронов ИНС и возможность корректировать их, д) управлять подачей объектов из обучающей выборки, обеспечивая полноту обучения. Каждое из этих требований совершенно фантастическое с точки зрения реальной нервной системы. Выполнить эти требования можно только в больших по размеру ИНС.

Помимо сказанного, ИНС обладает свойством «катастрофического забывания», состоящего в том, что однажды обученная ИНС, не может быть дообучена впоследствии без тотального перечувания по всей обучающей выборке.

Нами неоднократно предпринимались попытки реализовать рассмотренную схему системы автономного адаптивного управления непосредственно на базе ИНС, и это привело лишь к частичному решению с помощью ИНС адаптивного резонанса. Все же весьма оригинальное решение было найдено, о нем будет сказано ниже. Еще одно нарекание вызывает модель нейрона, используемая в ИНС, так называемый «формальный нейрон».




Рис. 10. Предварительное обучение ИНС с помощью «учителя», управляющего подачей объектов из обучающей выборки, наблюдающего рассогласование реального и желаемого выхода ИНС, и имеющего доступ к весам (синапсам) всех нейронов




Рис. 11. «Формальный нейрон», используемый в ИНС

Предназначенный для разбиения многомерного признакового пространства на подобласти при помощи гиперплоскостей в случае пороговой активационной функции, либо для аппроксимации функций, формальный нейрон сам по себе не обладает никакими средствами ни для выделения закономерностей в наблюдаемых явлениях, ни для самообучения. Выше мы пришли к выводу, что основным способом получения эмпирических знаний, которые можно использовать при управлении, является **поиск многократно повторяющихся комбинаций событий**. У «формального нейрона» к этому нет никаких автономных средств.

Из сказанного в этом разделе следует, что ИНС к моделированию нервной системы имеет очень отдаленное отношение. Да, ИНС родились более чем полвека назад из первых попыток моделирования нейронов, но пред-

ставляют собой очень упрощенную модель нейрона и очень упрощенную модель фрагмента нервной ткани. ИНС можно использовать в технике для построения весьма полезных систем распознавания, обучающихся с учителем. Но добиваться от ИНС работы в роли системы автономного адаптивного управления не следует категорически. Собственные проблемы ИНС и соответствующие задачи известны — это борьба за скорость обучения ИНС по обучающим выборкам, различные алгоритмы обучения, увеличение емкости памяти ИНС. Однако модели нервных систем целесообразно строить на иных моделях нейронов и сетей.

Синтез систем автономного адаптивного управления

Принципиальную возможность построения систем автономного адаптивного управления (ААУ) мы рассмотрели выше, перечислив все основные задачи и указав возможные способы их решения. Список подзадач и их взаимосвязь указаны в общей схеме системы «Автономного адаптивного управления», представленной на рис. 7, все основные отношения указаны в схеме морфизмов (4). Вся система управления в основных своих чертах имеет дискретный характер, соответствующий дискретному характеру логики вообще и дискретному характеру нервной системы, — логической машины, отражающей логику внешнего мира, работающей с дискретной информацией и логическим способом принимающей решения. Потому основной принцип работы и нервной системы и ее моделей может описываться теоретико-множественным языком, имеющим дело с отображениями между дискретными множествами входных и выходных сигналов и качественных оценок, а также языком логики. Основной принцип обучения состоит в отыскании тех конкретных отображений, которые в данной прикладной системе происходят статистически неслучайно. Способами поиска статистически неслучайных комбинаций дискретных событий могут быть, например, подходящие методы взаимного корреляционного анализа. Поскольку и самообучаемые системы распознавания и корреляционный анализ требуют априорного указания правил формирования образов, и различных ограничений, которые должны преодолеть проблему «проклятия размерности», то такие правила и ограничения находятся на «видовом» уровне, в процессе эволюционного развития вида. Последние достаточно приемлемо воспроизводятся генетическими алгоритмами.

Возможные способы построения систем автономного адаптивного управ-

ления мы подробно описали в монографии [5]. Построить систему ААУ можно, применяя подходящих методы построения самообучаемых систем распознавания, способы представления знаний, методы принятия решений. Нами построен ряд программных и физических моделей адаптивных машин, на основе рассмотренного метода ААУ, которые описаны в публикациях группы и представлены в Интернете [13].

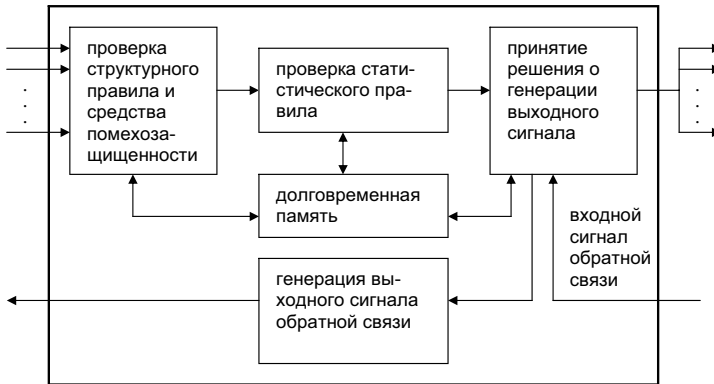


Рис. 12. Общая схема нейрона для систем ААУ

Одним из наиболее интересных для специалистов, занимающихся проблемами ИНС, способов реализации систем ААУ, является способ построения систем ААУ на основе сетей из разработанных нами моделей нейронов, которые мы для их отличия от формальных нейронов и от ИНС, называем нейроноподобными элементами или нейронами ААУ. В нейроне ААУ реализуется описанный выше принцип **поиска и запоминания многократно повторяемых пространственно-временных комбинаций событий**. Поскольку здесь фигурируют две характеристики — структурная (определенные комбинации) и статистическая (определенная повторяемость), то нейрон должен иметь средства к анализу этих двух критериев — структурного и статистического. Подчеркнем, что оба этих критерия, применительно к наблюдаемым им событиям-сигналам, проверяются нейроном автономно, без привлечения внешнего «учителя», непосредственно управляющего во время его обучения и работы. Проверка структурного правила осуществляется сама по себе некоторой встроенной в нейрон не слишком сложной системой распознавания с заранее заданным правилом. Проверка статисти-

стического критерия повторяемости отобранных структур входных данных тоже может быть простой (например, число повторений сравнивается со статистическим порогом) или более сложной (например, по частоте наблюдения отобранной комбинации). Сказанному удовлетворяет следующая схема нейрона ААУ (рис. 12). Обучение нейрона состоит в поиске им заранее неизвестной комбинации, удовлетворяющей обоим критериям, и ее запоминании в своей долговременной памяти. В целом, отдельный нейрон должен представлять собой элементарную самообучаемую систему распознавания образа — образа неслучайной пространственно-временной комбинации входных сигналов.

Нами разработано несколько вариантов моделей нейрона, соответствующих данной схеме, и отличающихся сложностью примененных структурного и статистического правил [14, 15]. Наиболее простой вариант показан на рис. 13.

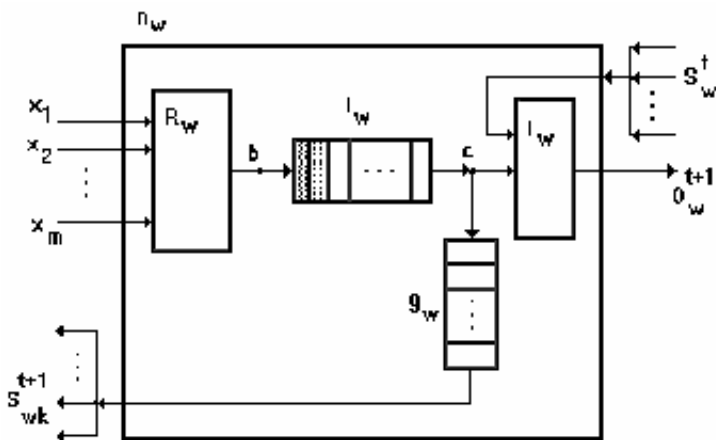


Рис. 13. Одна из реализаций нейрона ААУ

Формальное описание работы нейрона дано, например, в работах [5, 16]. В элементе R_w нейрона n_w проверяется, удовлетворяет ли входной вектор заданному структурному правилу, например, самому простому — все ли m входных сигналов равны “1”? Если это правило выполняется, то блоком l_w проверяется статистическое правило, например, наблюдался ли этот входной вектор уже больше, чем M раз? Пока оба этих правила не будут выпол-




Рис. 14. Пример формирования (слева) и распознавания (справа) образа пространственно-временной последовательности сигналов (обведены рамками сверху), которой соответствует образ O_{11}

нены, нейрон считается необученным, закономерность не найдена, образ не сформирован, и на выходе такого нейрона всегда будет сигнал $S_w = 0$. Если же однажды оба правила выполняются, то нейрон перейдет в состояние «обучен». С этого момента он будет реагировать выходным сигналом $S_w = 1$ всякий раз, когда на его входе будет наблюдаться подобный входной вектор и делать это со строгой временной задержкой, необходимой для корректного управления событиями при управлении. Для нейронов, получающих его выходной сигнал, это будет означать, что такт назад произошло некоторое вполне определенное (каждый раз одно и то же) событие. На сообщение о таком событии другие нейроны и подсистемы могут опираться в своем поиске других закономерностей или для распознавания ранее уже найденных. Сигналы нейронов ААУ в сети имеют вполне определенную семантику — они «говорят» о том, что в системе произошли вполне определенные события и произошли они во вполне определенные моменты времени. Использование обратных связей между нейронами, которые способны «отключать» сработавшие нейроны, а также временных задержек в срабатывании нейронов, позволяет строить сети, способные формировать и распознавать образы строгих пространственно-временных закономерностей.

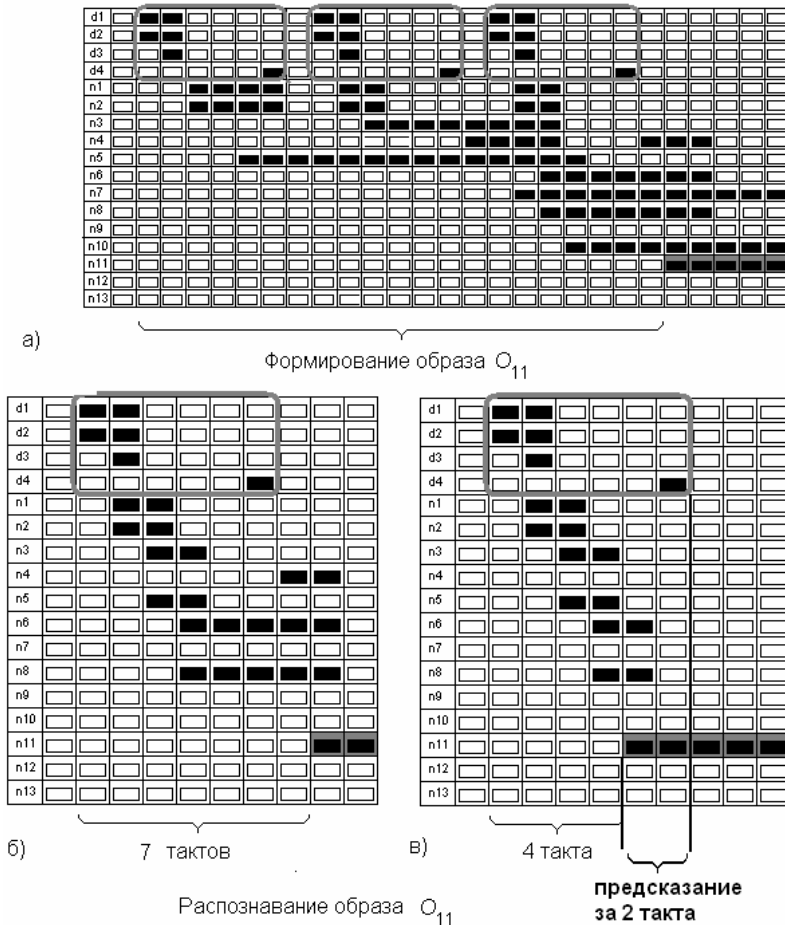


Рис. 15. Пример опережающего распознавания. Нейрон n_{11} научился распознавать образ пространственно-временного явления (рамка вверху) раньше, чем закончится его восприятие, т.е. нейрон способен к предсказанию будущих событий

стей, причинно-следственных событий, комбинаторных явлений или событий (рис. 14), строить типовые программы реализации принятых решений. Наличие в нейроне средств помехозащищенности обеспечивает возможность опережающего распознавания образов (рис. 15), что, собственно, и обеспечивает возможность прогнозирования и принятия решений, а также — далеко идущую возможность ассоциативного распознавания и языковых явлений [10–12].

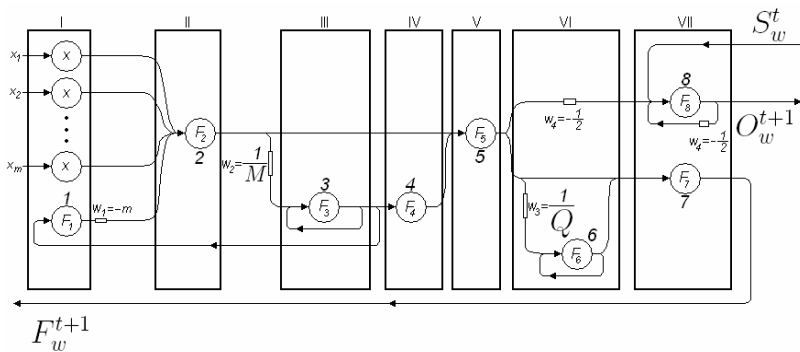


Рис. 16. Схема из «формальных нейронов» ИНС, эквивалентная по свойствам одному нейрону ААУ, показанному на рис. 13

В работе [5] показано, что разные способы использования нейронов ААУ могут составить полный логический базис И, ИЛИ, НЕ, и с их помощью можно реализовать все подсистемы, составляющие систему ААУ.

К сожалению, специалисты по ИНС видят мало знакомых им черт «формального нейрона» в нейроне ААУ, пока не «чувствуют» его и им трудно применить свой опыт для работы с таким нейроном. Чтобы перекинуть «мостики» между нейроноподобной версией систем ААУ и ИНС, мы предпринимали попытки построить системы ААУ на «формальных» нейронах ИНС, которые не увенчались явным успехом в силу присущего ИНС свойства «катастрофического забывания», противоречащего свойству систем ААУ обучаться, дообучаться и переобучаться непосредственно в процессе управления. Оригинальное решение проблемы было получено в 2007 году студентами МФТИ А. Чернодубом и Д. Пономаревым, предложившими из «формальных нейронов» строить не всю систему ААУ, но один нейрон ААУ. Ими разработана такая эквивалентная нейрону ААУ схема из не менее

чем 9-и «формальных нейронов» ИНС и доказана полная функциональная идентичность этих двух объектов. Разработанная ими схема показана на рис. 16 и описана в работе [17].

Используя схему из «формальных нейронов», показанную на рис. 16, в качестве одного нейрона ААУ, можно построить всю систему ААУ средствами ИНС. Призываем специалистов ИНС обратить внимание на эту возможность, открывающую собой в теории ИНС переход от «парадигмы

ОУ становилось все более целенаправленным — ОУ все чаще добивался тех состояний, которые имели высокие «эмоциональные» оценки, а доля случайных составляющих в поведении ОУ постепенно уменьшалась. В состоянии, когда БЗ накапливала достаточно знаний, поведение ОУ становилось вполне целесообразным, и качество управления достигало своего максимума.




Рис. 17. Типичные кривые роста во времени качества управления, обеспечиваемого системой ААУ (черная линия). Для сравнения показано качество управления, обеспечиваемое детерминированной системой управления, построенной на лучших решающих правилах, найденных априорно (серая линия)

Для количественного оценивания качества управления разрабатывались соответствующие критерии. Характерной для систем ААУ чертой является постепенный рост оценки качества управления с постепенным приближением к некоторой асимптоте (см. пример на рис. 17), определяемой такими ограничениями, как количество нейронов в БЗ, точность датчиков, возможности приводов и т. п., которые можно, при желании, расширять. Как правило, система ААУ со временем начинает демонстрировать более высокое качество управления, чем то, которое демонстрирует априорно рассчитанная детерминированная система управления (если ее можно построить), за счет автоматического приспособления к каким-то нюансам, которые трудно предусмотреть заранее. При этом адаптивная система управления может автоматически переучиваться при изменении свойств ОУ или среды, чего не может делать детерминированная система управления. Например, это




Рис. 18. Примеры реализованных адаптивных систем: **(а)** мобильный робот «Гном № 9» с адаптивной системой управления учится ездить без столкновений и собирать мусор; **(б)** модель спутника с адаптивной системой угловой стабилизации

важно при поломках сенсорных или исполнительных устройств ОУ.

Были разработаны, например, следующие системы. Мобильный робот Гном № 9 (рис. 18), который самостоятельно обучался ездить без столкновений в лабиринте и собирать мусор (бумажки) заданного цвета. Если вначале робот движется хаотично, натываясь на препятствия и игнорируя мусор, то постепенно количество наездов на препятствия уменьшалось практически до нуля, и робот начинал целенаправленно собирать мусор. При этом он демонстрировал такие непредусмотренные ситуации, как решение забрать мусор у стенки, «сознательно» получая при этом уже ожидаемое им неприятное соударение со стенкой и некоторые другие нетривиальные свойства.

Физическая модель наноспутника с адаптивной системой угловой стабилизации демонстрирует способность постепенно находить способ управления спутником и стабильно удерживать его в заданном состоянии.

Адаптивная система управления активной подвеской транспортного средства автоматически обучается управлять подвеской так, чтобы повысить комфортность, устойчивость и управляемость автомобиля. Существуют также и другие примеры.

Математические, технологические и психологические проблемы перехода к адаптивным технологиям

При переходе к технологиям построения адаптивных машин, программ и систем возникает ряд разнохарактерных проблем. Если мы правы в оценке актуальности перехода к адаптивным машинам, опираясь на факт их наличия в живых системах, их свойства, которые не воспроизводимы в современных технических системах на основе одноразовой оптимизации, и неизбежность появления спроса на подобные машины при расширении сферы объектов, требующих автономного и, следовательно, адаптивного управления, то человечеству придется заниматься построением адаптивных машин. При этом придется преодолевать следующие существующие проблемы.

Психологические проблемы перехода к адаптивным машинам. В общественном сознании еще отсутствует массовое представление о том, что машины могут быть адаптивными. Вся предшествующая технология приучила нас смотреть на машины, как на объекты, приспособленные к усредненным ожидаемым условиям эксплуатации и к усредненным пользователям, а во-вторых, как на машины с фиксированными свойствами, не меняющимися со временем. Мы охотно готовы заменять устаревшие машины на новые, более «продвинутые», но не готовы допустить, что машина

нет появляться, то окажется, что привычные технологии следует подвергнуть существенным изменениям. Переход от производства однотипных штампованных машин, которые изменяются только изнашиваясь, к машинам, которые сходят с конвейера одними, а потом накапливают опыт и изменяются в индивидуальном порядке, «умнеют» по мере «взросления», требует существенных изменений в подготовке специалистов, традициях, менталитете и т. д. Заметим, что технологии и сегодня являются в определенном смысле адаптивными, хотя и неявно. Накопление, мутирование, отбор и закрепление новых признаков идет в . . . «генах» технологической и научной документации. Когда этот процесс будет полностью автоматизирован и совмещен с полностью автоматизированной реализацией конструкций, описанных в документации, это будет одним из шагов в указанном направлении.

Математические и другие теоретические проблемы. Всякая технология основывается на теоретических возможностях. Выше мы показали, что возможность построения автономных адаптивных систем управления на основе определенной совокупности уже известных сегодня методов, существует. Более того, мы разработали и показали действующие прототипы таких машин. Основная теоретическая задача состоит в правильном системном понимании и описании алгоритмов всех взаимосвязанных подсистем адаптивной управляющей системы, которые должны логически вынужденно следовать из тех начальных условий, в которых работают нервные системы или адаптивные машины.

Заключение

В настоящей работе мы описали актуальность и, по-видимому, неизбежность перехода технологий от построения систем на основе одноразовой оптимизации к построению систем, способных к перманентной оптимизации в реальном времени функционирования. Были указаны основные подходы к построению такого рода систем и методы, которые можно использовать для этого. Была в общих чертах описана разработанная нами система «Автономного адаптивного управления» (ААУ), претендующая на аналогию с нервными системами по принципу действия. Представлены варианты работающих прикладных адаптивных систем, построенных на ее основе. Некоторое внимание мы уделили здесь представлению одного из важных способов реализации систем ААУ — нейросетевого (нейроподобного) способа, основанного на специально разработанных нами новых моделях нейрона (нейрона ААУ), которые исходят из понимания нейрона

как элементарной самообучаемой системы распознавания. Было показано, как можно построить нейрон ААУ из «формальных нейронов» ИНС, что открывает возможность построения систем ААУ в том числе и с использованием средств ИНС. Возможно, что нейрофизиологам будет интересна затронутая здесь тема сравнения схемы системы «Автономного адаптивного управления» с «Функциональной схемой» П. К. Анохина, поскольку обе модели имели одну и ту же цель, но были построены, отталкиваясь от различных исходных условий.

В целом мы надеемся, что разработанными принципами построения систем «Автономного адаптивного управления» мы внесли определенный вклад в технологии создания адаптивных машин, программ и систем, которые будут работать в недалеком будущем.

Литература

1. *Луговской В. М.* Супермозг человечества. – М.: Народный Пушкинский фонд, 2009.
2. *Жданов А. А.* О роли аппарата эмоций как системообразующего фактора в адаптивных системах управления // Труды Института системного программирования РАН. М., 2004. с. 215–225. (Англ. том.: *Zhdanov A. A.* Emotional system as a system-forming factor in adaptive control systems. Proc. of the Institute for System Programming. RAS, Vol. 5. *V. P. Ivannikov* (ed.), ISP RAS, 2004. pp.191–200).
3. *Zhdanov A. A., Vinokurov A. N.* Emotions simulation in methodology of autonomous adaptive control // 14th IEEE Int. Symp. on Intellig. Control /Intellig. Systems and Semiotics ISIC/ISAS'99. Spec. session "Emotions and Intelligent Systems". Sept. 15–17, 1999, Cambridge, Massachusetts, USA. Paper 99-002I-6.
4. *Жданов А. А.* Аппарат эмоций как системообразующий фактор // Сб. научн. тр. Всерос. н.-техн. конф. «Нейроинформатика-2004», М.: МИФИ. – с. 85–93.
5. *Жданов А. А.* Автономный искусственный интеллект. 2-е изд. (монография). – М.: БИНОМ. Лаборатория знаний, 2009. – 359 с.
6. *Zhdanov A. A., Zemskikh L. V.* The evolutionary growth of neural networks for the autonomous adaptive control system // The 5th World Multiconference on Systemics, Cybernetics and Informatics (SCI 2001) and the 7th International Conference on Information Systems Analysis and Synthesis (ISAS 2001), Orlando, USA, July 22–25, 2001. – pp.404–409.
7. *Жданов А. А., Земских Л. В., Беляев Б. Б.* Применение генетических алгоритмов для оптимизации нейросетевой базы знаний адаптивной системы стабилизации углового движения космического аппарата // Сб. тезисов докладов XXV академических чтений по космонавтике, Москва, 24–26 января 2001 г. – М.: Война и мир. – с. 128–129.

8. *Жданов А. А., Земских Л. В., Беляев Б. Б.* Система стабилизации углового движения космического аппарата на основе нейроноподобной системы автономного адаптивного управления // *Космич. исследования.* – 2004, т. 42, № 3. – с. 1–15.
9. *Земских Л. В., Самаров Е. К., Жданов А. А., Бабкова В. В.* Применение генетических алгоритмов для оптимизации адаптивной системы управления мобильного робота на параллельном вычислительном комплексе // *Труды Института системного программирования: Том 7, Новые подходы в нейроноподобных и основанных на знаниях системах* /Под ред. *А. А. Жданова.* – М.: ИСП РАН, 2004. – с. 79–104.
10. *Zhdanov A. A., Naumkina T. S.* Modeling of formation of extralinguistic factors influencing the attitude of the recipient towards language messages // *Proc. of the 12th International Conference SPECOM-2007.* – pp. 833–838.
11. *Zhdanov A., Kondukov A., Naumkina T., Dmitrienko O.* Automatic origin of a language in AAC neuron-like systems // *Proc. of the 11th International Conference “Speech and Computer SPECOM-2006”*, pp. 550–554.
12. *Жданов А. А., Наумкина Т. С.* Моделирование языковых явлений в нейроноподобных системах управления // *Сб. научн. тр. Всероссийской научно-технической конференции «Нейроинформатика-2007»*, ч. 3, с. 76–84.
13. URL: www.aac-lab.com
14. *Zhdanov A. A., Ryadovikov A. V.* Neuron models in the autonomous adaptive control method // *Optical Memory and Neural Network*, Allerton Press, Inc., Vol. 9, No. 2, 2000, pp. 115–132.
15. *Рядовиков А. В., Жданов А. А.* О некоторых формальных моделях нейронов // *Сб. научн. тр. Всероссийской научн.-техн. конференции «Нейроинформатика-99»*, ч. 1. – М.: МИФИ, 1999. – с. 202–211.
16. *Жданов А. А.* Метод автономного адаптивного управления // *Известия Академии Наук. Теория и системы управления.* – 1999, № 5, с. 127–134.
17. *Пономарев Д. Ю., Жданов А. А., Чернодуб А. Н.* Нейросетевая реализация формальной модели нейрона, используемого в методе «Автономного адаптивного управления» // *Нейрокомпьютеры: разработка, применение.* – 2007, № 1. – с. 64–75.

Александр Аркадьевич ЖДАНОВ, доктор физико-математических наук, заведующий отделом Института системного программирования РАН, Москва. Область научных интересов: адаптивное управление, нейронные сети, распознавание образов. Имеет более 60 научных публикаций.

И. Г. ПЕРСИАНЦЕВ
НИИ Ядерной Физики МГУ, Москва,
E-mail: ipers@srd.sinp.msu.ru

**АДАПТИВНОЕ ПОСТРОЕНИЕ ИЕРАРХИЧЕСКИХ
НЕЙРОСЕТЕВЫХ СИСТЕМ ДЛЯ КЛАССИФИКАЦИИ И ДЛЯ
СЕГМЕНТАЦИИ ВРЕМЕННЫХ РЯДОВ**

Аннотация

Предложен алгоритм построения самоорганизующегося классификатора на основе многослойного персептрона. В результате работы алгоритма создается классификатор, имеющий древовидную структуру, каждый узел которой представляет собой персептрон. Структура дерева и параметры каждого персептрона формируются автоматически. При работе с данными, содержащими большое количество классов, предложенный алгоритм позволяет существенно снизить вычислительную стоимость решения задачи. Алгоритм был протестирован на ряде модельных, тестовых и практических задач. Предложена модификация алгоритма, допускающая его использование

Введение

Классификация данных и распознавание образов является одной из важнейших задач обработки результатов физических измерений в различных областях науки и техники. Нейронные сети (НС) являются одним из классов алгоритмов, часто применяемых для решения подобных задач. Отличительными чертами НС являются их способность обучаться на примерах и обобщать полученную информацию, невосприимчивость к шуму и присутствующая им параллельность архитектуры. При решении практических задач классификации и распознавания образов с помощью традиционных нейросетевых подходов существует ряд принципиально важных недостатков и ограничений, наиболее значимыми среди которых являются: сложность решения задач классификации в случае плохо разделимых классов, субъективность выбора алгоритма решения конкретной задачи и его параметров, возможность попадания в локальный минимум, заметное снижение качественных характеристик НС классификатора при большом количестве классов, неоправданно высокая вычислительная стоимость построения НС классификатора при большом количестве классов, проблема интерпретации признаков, по которым НС принимает решение.

Целью исследований являлось преодоление указанных выше недостатков путем разработки конструктивного нейросетевого алгоритма классификации, обладающего следующими свойствами: наращивание архитектуры НС по мере необходимости в процессе тренировки; сокращение вычислительной стоимости решения задачи классификации; обеспечение оптимального выбора признаков, используемых нейросетью для классификации данных, а также универсальность алгоритма, т. е. применимость его к возможно более широкому кругу задач.

Основополагающие идеи метода

Метод адаптивного построения **иерархических нейросетевых классификаторов (ИНК)** основан на следующих соображениях [1–6].

Процесс тренировки многослойного персептрона (МСП) можно рассматривать как одновременное выделение признаков в скрытом слое и их декодирование в выходном слое. Для простейшей архитектуры МСП количество выделяемых признаков можно считать пропорциональным количеству нейронов в скрытом слое. При этом задание числа нейронов в скрытом

слое меньше некоторого порога приведет к ситуации, когда НС будет не способна выделить количество признаков, достаточное для классификации предложенных образов в требуемое количество классов. НС начнет путать образы из классов, похожих в терминах того небольшого количества признаков, которые выделяются в скрытом слое.

Можно предположить, что при некоторых условиях нейросеть будет в этой ситуации выделять наиболее существенные признаки во входных данных и, следовательно, эти признаки можно использовать для принятия решения о том, какие классы следует объединить в группы.

Алгоритм формирования групп классов

Основанный на вышеизложенной идее алгоритм формирования групп классов (АФГК) работает следующим образом.

Шаг 1. Вначале МСП обучается решать задачу классификации с использованием стандартного метода обратного распространения ошибки [7].

Шаг 2. По прошествии нескольких эпох тренировки, алгоритм производит анализ статистики ответов МСП на тренировочном наборе. В процессе анализа проводится «голосование» образов: для каждого образа (примера) определяется номер нейрона выходного слоя, имеющего максимальную амплитуду отклика и превышающего некий порог голосования. Этот номер трактуется как номер класса, за принадлежность к которому «проголосовал» данный образ. Если количество образов из класса k , проголосовавших за принадлежность к классу j , больше половины количества образов в классе k , то считается, что все представители класса k отныне принадлежат классу j . Другими словами, если ответом сети на образы из разных классов является стабильная активация одного и того же нейрона, то такая ситуация рассматривается как свидетельство в пользу того, что эти классы следует объединить.

Шаг 3. После окончания анализа всех классов, производится соответствующая модификация желаемых выходов. После этого тренировка продолжается с использованием измененной информации о классе, к которому принадлежит каждый образ.

Приведем формальное описание алгоритма АФГК.

Шаг 1. Обучение по методу обратного распространения ошибки

$$\forall p \in C_k \quad O_i(p) = \delta_{ik}$$

Шаг 2. Анализ статистики ответов

Возможный вариант — «голосование по порогу»:

$$\forall p \in C_k$$

IF $\operatorname{argmax}(Y(p)) = j$ AND $Y_j(p) > \Theta$ THEN

$$V_j = V_j + 1$$

Шаг 3. Модификация желаемого ответа

IF $V_j > N(C_k)/2$ THEN

$$\forall p \in C_k \quad O_i(p) = \delta_{ik}$$

Указанные выше стадии «тренировка–анализ–модификация желаемых ответов» повторяются, пока классы продолжают объединяться. В результате описанной процедуры исходный набор классов разбивается на некоторое количество групп и одновременно с этим создается классификатор, поддерживающий именно это разбиение.

Алгоритм построения ИНК

Опишем **алгоритм построения ИНК** как процесс построения дерева решений, узлы в котором реализованы в виде МСП с заданным размером скрытого слоя. Построение ИНК начинается с вызова АФГК, в результате работы которого происходит объединение исходных классов в небольшое количество групп. Таким образом, формируется базовый узел ИНК (первый уровень иерархии), в котором осуществляется наиболее «грубая» классификация. Очевидно, что полученные группы классов можно рассматривать как ветви дерева решений.

После создания базового узла, для каждой из полученных групп классов (ветвей) вновь вызывается АФГК. Важно, что при этом алгоритм анализирует лишь те исходные классы, которые попали в данную ветвь дерева. В результате формируется узел следующего уровня иерархии, а из анализируемых классов образуются новые группы (ветви). После формирования всех узлов данного уровня иерархии, АФГК вызывается для каждой из

вновь полученных ветвей. Ясно, что узлы более высоких уровней иерархии осуществляют все более и более детальную классификацию.

Алгоритм построения ИНК для данной ветви останавливается, если в ней содержится один исходный класс, или если дальнейшая детализация классов в этой ветви невозможна (например, если процент ошибочных классификаций в узле превысил некоторый порог).

Свойства алгоритма построения ИНК

Можно трактовать процесс построения ИНК как процесс подбора адекватной сложности задачи на каждом уровне иерархии. Пусть задана архитектура МСП, используемая при построении ИНК (для простоты единственным параметром архитектуры будем считать размер скрытого слоя). В процессе формирования очередного узла возможны три результата работы АФГК:

- 1) Заданная архитектура МСП способна разделить классы, входящие в данную ветвь, т. е. сложность поставленной в данном узле задачи классификации соответствует возможностям используемой НС.
- 2) Заданная архитектура МСП не может разделить классы, входящие в данную ветвь, но возможно образование групп классов, т. е. задача классификации, слишком сложная для решения в данном узле, разбивается на задачу разбиения классов по группам (причем сложность этой задачи адекватна возможностям используемой НС) и на набор задач для узлов следующего уровня иерархии. Заметим, что при использовании такой стратегии задача тренировки узла ИНК может быть решена достаточно быстро, поскольку предложенный метод модификации желаемых ответов сильно ускоряет сходимость обучения. С другой стороны, количество классов, подлежащих распознаванию, постепенно уменьшается с каждым следующим уровнем иерархии, что упрощает задачу классификации.
- 3) На некотором этапе построения ИНК может сформироваться ветвь, внутри которой границы между классами настолько сложны, что заданная архитектура МСП не в состоянии ни разделить классы, ни сформировать из них группы, что говорит о невозможности решить задачу классификации средствами заданной архитектуры.

Как видно из этого рассмотрения, первоначальная глобальная задача распознавания множества исходных классов (возможно, очень сложная)

разбивается на последовательность локальных задач со сложностью, адекватной возможностям нейросетевой архитектуры, используемой в узлах ИНК. Преимущества иерархического способа решения задачи перед использованием одиночного МСП с большим скрытым слоем достаточно очевидны. Хотя одиночный МСП и может решить задачу (по теореме об МСП как универсальном аппроксиматоре [8]), однако требуемый размер скрытого слоя заранее неизвестен, и его приходится находить методом подбора. В то же время, в предлагаемом иерархическом подходе архитектура МСП может быть практически произвольной, поскольку алгоритм наращивает структуру ИНК по мере необходимости, используя заданную архитектуру как конструкционные блоки.

Докажем теорему, позволяющую оценить количество скрытых нейронов МСП, достаточное для построения ИНК со 100% распознаванием.

Теорема. Пусть требуется классифицировать P примеров $X \in R^N$ в M классов. Тогда для построения ИНК, дающего гарантированное 100% распознавание, достаточно использовать МСП с размером скрытого слоя, равным $\min(2 \cdot N, P - 1)$.

Доказательство. Действительно, пусть в узле ИНК требуется классифицировать P примеров $X \in R^N$ в два класса \mathbf{K}_1 и \mathbf{K}_2 (если количество классов больше 2, то объединим эти классы на два новых класса произвольным образом). Рассмотрим пример $X \in \mathbf{K}_1$. В наихудшем случае, его требуется отделить от $(P - 1)$ примеров из \mathbf{K}_2 . Для этого достаточно:

- либо построить набор из $(P - 1)$ гиперплоскостей, отделяющих X от каждого из примеров из \mathbf{K}_2 , на что требуется $(P - 1)$ скрытых нейронов;
- либо для каждого из признаков X_j ($j = 1, N$) построить по 2 гиперплоскости, отделяющих данный пример от примеров с меньшими и с большими значениями этого признака, для чего требуется $(2 \cdot N)$ скрытых нейронов.

Таким образом, теорема доказана.

Результаты численных экспериментов

Для проверки алгоритма был выбран ряд модельных задач, а также известные задачи реального мира, чьи базы данных доступны по сети Интернет. Ниже приводятся основные результаты проверки алгоритма на некоторых из них.

Параметры алгоритма (размер скрытого слоя N , скорость обучения σ и период анализа статистики ответов T), как правило, являлись общими для всех узлов дерева. Момент при обучении МСП был равен 0.9. Изменяя параметры N , σ и T , можно изменять количество классов в каждом узле, т. е. топологию получающегося иерархического дерева. На всех рисунках, представляющих полученные для разных задач иерархические деревья, для каждого узла указаны список классов, поступающих для распознавания на вход данного узла, и проценты правильного распознавания на тренировочном и тестовом наборах.

Одномерное распределение Кантора

Интервал $[0 \dots 1.8]$ был разделен на 180 сегментов длиной по 0.01. Подлежащие классификации образы представляли собой кривые Гаусса с полушириной 0.1 и единичной амплитудой. Входными признаками для этих образов были их амплитуды в серединах всех 180 сегментов. (Таким образом, нейронные сети всех уровней имели каждая по 180 нейронов во входном слое.) Функция плотности распределения максимумов образов описывалась хорошо известным одномерным распределением Кантора.




Рис. 1. Задача с одномерным распределением Кантора. Функция плотности распределения максимумов образов (сплошная линия); пример классифицируемого образа (пунктир)

Расстояние между соседними пиками функции плотности распределения равнялось ширине каждого пика; то же справедливо для групп соседних пиков. На рис. 1 сплошной линией показана функция плотности рас-

пределения для одномерного распределения Кантора, пунктирной – пример классифицируемого образа.

Признаком, определяющим принадлежность образа к тому или иному классу, являлась координата его максимума. Каждый из 8 пиков на рис. 1 был разделен на два равных сегмента, что в сумме давало 16 исходных классов для базовой сети. Тренировочный и тестовый наборы содержали по 320 образов, по 20 образов для каждого из 16 классов. Количество нейронов в скрытом слое намеренно выбиралось минимальным (2–3) для получения возможно более сложной иерархической структуры с меньшим количеством выходных классов для каждого узла и с потенциально более высоким качеством распознавания.

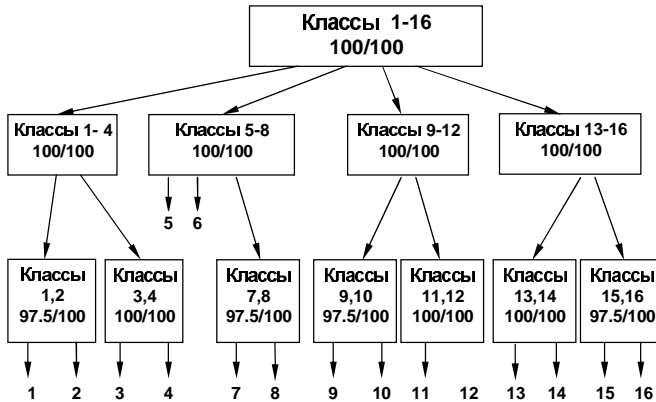


Рис. 2. ИНК для одномерного распределения Кантора: $N = 2$, $\sigma = 0.01$, $T = 5$ для базового узла, $T = 20$ для всех остальных узлов. Процент правильного распознавания на тренировочном наборе 98.75%, на тестовом наборе 100%

На нижеприведенных рисунках (рис. 2, рис. 3) представлены примеры ИНК для данной задачи, полученных для различных наборов параметров алгоритма (размер скрытого слоя N , скорость обучения σ и период анализа статистики ответов T).

Заметим, что все запуски дали сходные результаты: базовая сеть всегда группировала исходные классы по 4 (1–4, 5–8, 9–12 и 13–16); сети второго уровня иерархии имели по две или три выходных категории; сети третьего

уровня использовались для того, чтобы различить нераспознанные к этому моменту соседние классы.

Увеличение N (и в меньшей мере — увеличение T) приводит к увеличению количества классов, распознаваемых в каждом узле, и, как следствие, к уменьшению глубины дерева. Вся система оказывается достаточно чувствительной к начальной инициализации весов МСП, т. е. два последовательных запуска алгоритма с одними и теми же параметрами приводят, как правило, к построению различных по топологии деревьев.

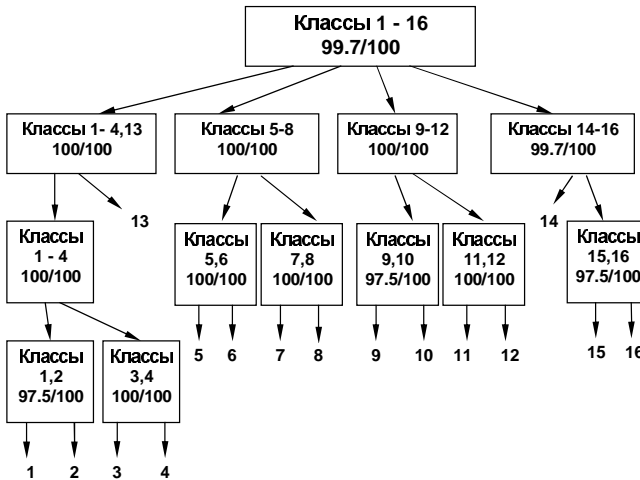


Рис. 3. Базовый и терминальный узлы $N = 2$, остальные $N = 3$, $\sigma=0.1$, $T = 5$. Процент распознавания на тренировочном наборе 98.75%, на тестовом наборе 100%

Увеличение σ дополнительно усиливает влияние начальной инициализации весов и приводит к построению менее сбалансированных деревьев. Впрочем, процент распознавания системы в целом весьма слабо зависит от конкретной топологии дерева (даже при его сильной асимметрии) и для данной задачи всегда оказывается весьма высоким (не менее 98.75%).

На рис. 4 показан пример эволюции принадлежности различных исходных классов с течением времени для базового узла ИНК.




Рис. 4. Пример эволюции принадлежности различных исходных классов с течением времени для базового узла ИНК

Распознавание текстур

Эта хорошо известная база данных, доступная по сети Интернет [9], позволила провести первое адекватное сравнение результатов работы алгоритма с результатами работы альтернативных алгоритмов. База данных `texture_CR.dat` содержит 11 классов, помеченных номерами 2, 3, 4, 6, 7, 8, 9, 10, 12, 13, 14. Тренировочный и тестовый наборы содержат по 250 образов в каждом классе. Данные нормировались к нулевому среднему и единичному стандартному отклонению. Каждый образ описывается 40 признаками.

Для этой задачи оказались справедливыми все наблюдения о влиянии параметров на получаемые деревья, сделанные выше для задачи с распределением Кантора. Отметим, что при любой разумной комбинации параметров процент распознавания получавшегося иерархического дерева оказывался не ниже 98.5%, что превышает наилучшие результаты, приводимые в [9] для того же способа предобработки данных (98%). Заметим, что для разных полученных деревьев существуют устойчивые группы классов, объединяемые алгоритмом на первой стадии. Такие группы, как правило, состоят из классов, имеющих, согласно [9], минимальную взаимную дисперсию.

Для дополнительной проверки возможностей алгоритма задача была модифицирована следующим образом. Каждый из 11 классов был случайным образом разбит на 4 подкласса равного размера. В результате работы алгоритма на втором уровне иерархического дерева 44 исходных класса были автоматически сгруппированы по 4 класса, образовав 11 реально различающихся групп. При этом уровень правильного распознавания этих 11 классов составил 99.4%. Стоит также заметить, что и в этом эксперименте на первом уровне дерева алгоритмом были объединены классы с минимальной взаимной дисперсией.

Распознавание гласных

Задача дикторонезависимого распознавания 11 гласных звуков английского языка [10] отличается сложными для распознавания классами. Это хорошо видно из приведенной ниже таблицы, в которой показаны наилучшие результаты, достигнутые для этой задачи [10]. Образы описываются 10 признаками. Данные нормированы к нулевому среднему и единичному стандартному отклонению. Тренировочный набор содержит по 48 примеров для каждого класса, тестовый — по 42. На рис. 5 показан пример ИНК для данной задачи, полученный при $N = 1$, $\sigma=0.01$ и $T = 1$.

ТАБЛИЦА 1. Сравнительные результаты для задачи распознавания гласных

Алгоритм классификации	Нейронов в скрытом слое	% на тестовом наборе
Однослойный перцептрон	—	33
МСП	88	51
Модель Канервы	528	50
Радиальные базисные функции	528	53
Сеть с гауссовскими узлами	528	55
Сеть с квадратичными узлами	88	55
Метод ближайших соседей	—	56
ИНК	(1)	58

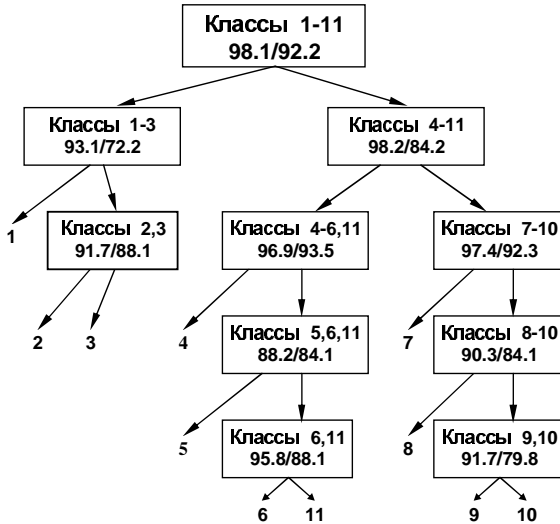


Рис. 5. ИНК для распознавания гласных: $N = 1$, $\sigma = 0.01$, $T = 1$. Процент правильного распознавания на тренировочном наборе 84.90%, на тестовом наборе 58.23%

Заметим, что хотя общие закономерности влияния параметров на результаты построения иерархических деревьев сохранились, процент правильного распознавания на тестовом наборе для этой задачи зависел от значений параметров тренировки гораздо сильнее, и мог изменяться от 50% до рекордного значения 58.23%.

Сравнение ИНК и стандартного МСП. Число нейронов ИНК в скрытом слое в табл. 1 записано с некоторой долей условности — понятно, что хотя каждый узел у дерева имеет 1 нейрон, в целом дерево эквивалентно более сложной структуре. Поэтому на этой же задаче, очень показательной именно в силу крайне низких процентов правильного распознавания, было проведено прямое сравнение полученных деревьев и стандартного МСП.

Были натренированы МСП с размерами скрытого слоя от 1 до 10 с шагом 1, и далее до 100 с шагом 20 (20, 40, 60, 80 и 100). На рис. 6 приведена зависимость процента распознавания на тестовом наборе для МСП

(сплошная линия) и для ИНК (отдельные точки) в зависимости от полного числа связей в полученной архитектуре. Анализ этой зависимости показывает, что ИНК не только существенно выигрывают по процентам распознавания, но также и весьма эффективны по вычислительной сложности. Наилучший ИНК, полученный для этой задачи, имеет такое же количество весов, как и МСП с 7 нейронами в скрытом слое.




Рис. 6. Процент распознавания гласных на тестовом наборе для МСП (сплошная линия, MLP) и для некоторых ИНК (отдельные точки, V1, V4, V5, V6) в зависимости от полного числа связей в полученной архитектуре. Параметры алгоритма построения ИНК указаны в легенде. Скорость обучения во всех случаях $\sigma = 0.01$

Качество распознавания для тех же ИНК и МСП также сравнивалось на тестовом наборе, искаженном 10% и 20% белым шумом. На рис. 6 приведены результаты сравнения МСП и ИНК по устойчивости к шуму, накладываемому на тестовые данные. Даже в наихудшем случае 20% белого шума, ИНК имеют более высокий процент распознавания на тестовом наборе, что связано с меньшим количеством весов и большей устойчивостью решения.

Дикторонезависимое распознавание изолированных слов

Алгоритм построения ИНК был также успешно опробован при разработке нейросетевой системы дикторонезависимого распознавания изолированных слов.




Рис. 7. Распознавание гласных. Сравнение МСП (40h, 60h, 80h обозначает число нейронов в скрытом слое) и ИНК (V1, V4, V5, V6) по устойчивости к шуму, накладываемому на тестовые данные. Зависимость процента распознавания на тестовом наборе от относительной амплитуды белого шума. Параметры алгоритма построения ИНК указаны в легенде. Скорость обучения во всех случаях $\sigma = 0.01$

С помощью этой системы была реализована возможность голосового управления работой стандартного калькулятора Windows, наглядно иллюстрируя эффективность ИНК.

Подготовка данных. Речевой сигнал оцифровывался с частотой 10 кГц 12-битовым аналого-цифровым преобразователем и разбивался на непрерывающиеся сегменты шириной 6.4 мс. После домножения сигнала в каждом сегменте на сглаживающее окно Хэмминга, производился расчет быстрого преобразования Фурье сигнальным процессором ADSP-1205 фирмы Analog Devices. Затем осуществлялся поиск начала/конца слова по алгоритму, основанному на алгоритме Рабинера-Шафера [11]. В результате определения начала и конца слова формировался массив векторов, образующий спектральный образ произнесенного слова. Частотный диапазон полученного массива преобразовывался в т. н. шкалу барков [12], для чего он разбивался на 20 интервалов и для каждого интервала вычислялась суммарная интенсивность попавших в него спектральных отсчетов. Границы интервалов вычислялись по формуле:

$$z = \frac{26.81f}{1960 + f} - 0.53, \quad (1)$$

где z — частота в барках, f — частота в герцах.

В результате для каждого слова получалась последовательность спектральных векторов (спектрограмма), длина которой зависела от длины произнесенного слова. Чтобы избавиться от временной зависимости, каждая такая последовательность приводилась к одинаковой длине путем линейной деформации по времени. Эта длина составляла 50 сегментов (640 мс) и соответствовала средней длине слова.

Амплитуды полученной спектрограммы переводились в шкалу децибел, и максимальное значение сигнала принималось за 0 дБ (при этом экспериментально определенный уровень шума соответствовал -17 дБ). После этого спектрограмма перенормировалась из диапазона $[-17$ дБ, 0 дБ] в диапазон $[0, 1]$. На вход системы распознавания подавались двумерные спектрограммы слов, состоящие из 1000 точек (50 точек по времени, 20 точек по частотной шкале), нормированные в диапазон $[0, 1]$.

База данных содержала 36 слов для управления калькулятором в русскоязычной версии оболочки Microsoft Windows, произнесенными 19 дикторами (14 мужских голосов, 5 женских голосов). Тренировочный набор включал 12 мужских и 3 женских голоса, тестовый набор — 2 мужских и 2 женских голоса.

Для искусственного расширения используемого при тренировке набора данных каждый предъявляемый образ мог искажаться одним из следующих способов. В одном случае к образцу добавлялся случайный белый шум, не превышающий заданной амплитуды A_{noise} , в другом случае образец подвергался нелинейным временным искажениям амплитуды $A_{distort}$ (чем имитировалось изменение темпа произнесения слова). Благодаря применению указанной методики эффективное количество образов, используемых при тренировке, было практически не ограничено и тем самым предотвращалась возможность эффекта «переучивания» нейросети.

Стратегия постепенного усложнения тренировки. Стратегия постепенного усложнения тренировки применительно к данной задаче заключалась в следующем. В начале обучения НС предъявлялись лишь неискаженные образы ($A_{noise} = 0$, $A_{distort} = 0$), и обучение продолжалось до достижения НС заранее заданного уровня правильного распознавания на тестовом наборе (90%). Затем амплитуда искажений A_{noise} и $A_{distort}$ устанавливалась равной некоторой малой величине, и, тем самым, тренировочный набор расширялся за счет предъявления слегка искаженных

образов, а задача классификации усложнялась. По достижении заданного уровня правильного распознавания амплитуды искажений еще увеличивались. Амплитуда искажений постепенно возрастала по мере обучения НС до тех пор, пока нейросеть была в состоянии поддерживать качество распознавания на заданном уровне.

Описание системы распознавания. Был построен ИНК, состоящий из двух уровней иерархии. Базовая НС имела 24 нейрона в скрытом слое. 36 исходных классов (36 слов) были объединены алгоритмом АФГК в 6 групп (1 группа из 4 классов, 3 группы по 6 классов и 2 группы по 7 классов). Для каждой из групп были построены вспомогательные НС, содержащие от 12 до 24 нейронов в скрытом слое. Для уменьшения вероятности ложного распознавания незнакомых слов в тренировочный набор каждой из НС второго уровня иерархии были включены не только представители классов, попавших в данную ветвь ИНК, но и все примеры из остальных классов. Для этих примеров из «посторонних» классов желаемым ответом НС была нулевая активность всех нейронов выходного слоя, что при распознавании трактовалось как ответ «не знаю». Общий процент правильного распознавания 36 слов для незнакомого диктора составил около 95%, что соответствовало типичным значениям, получаемым в нейросетевых системах распознавания [13].

Нейросетевая сегментация временных рядов

Алгоритм построения ИНК может быть использован для анализа объектов, представимых в пространстве признаков в виде непрерывных или квазинепрерывных траекторий, в частности, для анализа временных рядов с переключающейся динамикой.

Пусть временной ряд y_t ($t = 1, 2, \dots$) генерируется источником $S(z_t)$, где z_t является переменным во времени параметром, принимающим значения из фиксированного множества параметров $\Theta = \{\theta_1, \theta_2, \dots, \theta_K\}$. В момент времени t значение y_t зависит от предыстории y_{t-1}, y_{t-2}, \dots и от текущего значения z_t . Значение z_t может скачком изменяться (переключаться) в произвольные моменты времени (т. е. значение изменяется за время, пренебрежимо малое по сравнению с интервалами между этими изменениями). Конкретные значения параметров из множества и их число K заранее неизвестны.

Задача анализа структуры временного ряда в рамках этой модели заключается в разбиении временного ряда на участки, внутри которых значение z_t не изменяется. На практике условие мгновенности изменения значения z_t (т. е. «переключение») выполняется далеко не всегда. Одним из наиболее очевидных предположений является наличие достаточно широкого участка «дрейфа». В этом случае анализ структуры временного ряда предполагает, помимо выделения участков с постоянным значением z_t , также определение участков дрейфа, на которых одновременно существует несколько значений z_t .

Можно предполагать, что в качестве объектов с описанными видами изменения типа динамики могут выступать временные ряды самой различной природы, от физических процессов (например, в задачах исследования динамики межпланетной плазмы, классификации типов электрических процессов в головном мозге, сегментации непрерывной речи) до финансовых зависимостей (например, при анализе состояния фондового рынка).

В работах [14–16] описывается нейросетевой подход к исследованию объектов с переключающейся динамикой, однако в этих работах производится подстройка и отбор нейросетей при заранее заданном их количестве, т. е. архитектура всего комплекса нейросетей в целом фиксирована и имеет параллельный, а не иерархический принцип организации. В нашем подходе используется принцип постепенного иерархического наращивания сложности структуры ИНК, что позволяет получать многоуровневые нейросетевые комплексы с очень сложными поверхностями разделения классов.

В работе [17] предлагается метод анализа временных рядов с дрейфовым характером изменения типа динамики, в котором для анализа участков дрейфа предлагается использование скрытых марковских моделей. В предложенном нами подходе при сегментации таких временных рядов используется чисто нейросетевой анализ участков дрейфа.

Описанные методики были применены для сегментации временных рядов с переключающейся и дрейфовой динамикой.

Описание алгоритма анализа временных рядов с переключающейся динамикой

Алгоритм формирования групп классов (АФГК) для анализа и сегментации временных рядов с переключающейся динамикой работает следующим образом [18, 19]. Введем величину «минимального размера сегмента» (МРС), задавая ее значение, исходя из априорной оценки минимального времени

жизни одного типа динамики. Анализируемый временной ряд разбивается на одинаковые участки с размером, равным МРС, причем в пределах каждого из участков динамика объекта предполагается неизменной. В допущении, что переключение между различными типами динамики происходит достаточно редко, каждый из этих участков считается принадлежащим к отдельному классу со своей собственной динамикой. Таким образом, количество выходных нейронов в НС равно начальному количеству получившихся участков.

Методика тренировки МСП аналогична методике, использовавшейся для анализа статических объектов. Вначале обучение ведется стандартным методом обратного распространения ошибки. По прошествии нескольких эпох тренировки, алгоритм производит анализ статистики ответов МСП на тренировочном наборе. Так как данный алгоритм работает с временными рядами, то имеет смысл учитывать очевидное априорное соображение, что классы соседних образцов (в том числе и относящихся к разным участкам начального разбиения), скорее всего, совпадают. Таким образом, при рассмотрении голосования отдельного образца следует учитывать результаты голосования его соседей слева и справа, попадающих в т. н. «окно анализа». Размер окна анализа примем равным половине МРС. Будем считать, что рассматриваемый образец отнесен к классу j , если больше половины образцов в окне анализа проголосовало за принадлежность к классу j (в противном случае информация о принадлежности к классу не изменяется).

После окончания анализа голосования временной ряд разбивается на новые сегменты в соответствии с измененной принадлежностью к классам. Если количество образцов в каком-либо сегменте меньше, чем МРС, то такой сегмент присоединяется к сегменту, расположенному левее.

В результате, границы сегментов, изначально расположенные равномерно, могут быть передвинуты. После формирования нового разбиения на сегменты тренировка продолжается. Последовательность операций «тренировка–голосование–модификация сегментов» повторяется, пока разбиение временного ряда не перестанет изменяться. Итоговое количество классов, на которые был разбит временной ряд, определяется лишь по окончании тренировки МСП.

В результате работы АФГК участки временного ряда с одинаковой или близкой динамикой оказываются отнесенными к одному и тому же классу, а весь временной ряд разбивается на сегменты с указанием типа динамики.

Алгоритм построения ИНК при анализе временных рядов с переключающейся динамикой также аналогичен случаю анализа статических объ-

ектов. Сеть следующего уровня не строится, если после окончания тренировки все образцы объединены в один класс. В этом случае будем считать, что в рассматриваемом временном ряду выделение дополнительных типов динамики не представляется возможным. Сеть следующего уровня не строится и для классов, состоящих из сегментов, каждый из которых не превышает двойного размера MPC. Такие классы разделять на более мелкие сегменты нецелесообразно, так как их размер сравним со временем жизни динамики одного типа.

Для всех остальных классов строятся сети следующего уровня иерархии. Все образцы, принадлежащие одному такому классу, снова разбиваются на сегменты размера MPC. Количество выходных нейронов в сети следующего уровня равно количеству получившихся сегментов. Процедура обучения получившейся сети аналогична обучению базовой сети. Особенностью процедуры является то, что теперь мы рассматриваем временной ряд не как непрерывный, а как состоящий из выделенных на предыдущем уровне иерархии участков временного ряда, которые могут не являться смежными. Поэтому алгоритм сегментации применяется к каждому такому участку временного ряда по отдельности.

Описание алгоритма анализа временных рядов с дрейфовой динамикой

Одним из главных предположений, которое было положено в основу описанного выше алгоритма анализа временных рядов с переключающейся динамикой, являлось предположение о мгновенном переключении между различными типами динамики. Однако на практике данное условие выполняется далеко не всегда. Одним из наиболее очевидных предположений является наличие достаточно широкого участка «дрейфа». В рамках этой модели, на участке дрейфа предполагается одновременное существование нескольких типов динамики, причем типы динамики плавно трансформируются один в другой (дрейфуют) в течение некоторого достаточно значительного интервала времени. Например, в модельных задачах рассматривался дрейф вида:

$$f(t) = a(t) * f_L(t) + (1 - a(t)) * f_R(t), \quad (2)$$

где f_L и f_R — функции, описывающие динамику в сегментах, расположенных слева и справа от переходного участка, соответственно, а $a(t)$ — функция, линейно нарастающая от 0 до 1 на участке дрейфа.

Очевидно, что заложенные в существовавший алгоритм ограничения позволяли относить такие участки только к какому-либо одному классу, что приводило к тому, что при сегментации появлялись хаотические перескоки от класса к классу на коротком временном интервале

Обобщение алгоритма АФГК на случай дрейфового характера изменения типа динамики заключается в следующем.

Будем рассматривать ответ нейронной сети (множество активностей нейронов выходного слоя $O_j(S_i)$, $j = 1, \dots, K$) на предъявление примера S_i ($i = 1, \dots, N$) как оценку вероятности принадлежности данного примера к каждому из K классов. Учтем предположение о плавном характере изменения типа динамики во временном ряде с характерным масштабом, равным минимальному времени жизни одного типа динамики. С другой стороны, ответы НС на предъявление разных примеров являются статистически независимыми, поскольку используемая архитектура (МСП) не имеет внутренней памяти. Исходя из этого, можно оценить функцию распределения вероятностей принадлежности примера S к каждому из K классов путем усреднения ответов НС по окну анализа шириной W :

$$P_j = \sum_{i=1}^W O_j(S_i) / W, \quad i = 1, \dots, W, j = 1, \dots, K,$$

где суммирование ведется по всем примерам S_i , попадающим в окно анализа.

Будем считать незначимыми классы m , для которых выполняется условие

$$P_m < P_{win}/5, \quad \text{где } P_{win} = \operatorname{argmax}(P_j), \quad j = 1, \dots, K,$$

и для таких классов примем $P_m = 0$. Наконец, перенормируем сумму вероятностей для оставшихся классов на 1. Полученный вектор P_m используется как желаемый ответ для примера S .

Таким образом, предлагаемый алгоритм может отнести данный пример не к одному классу (за принадлежность к которому проголосовало большинство представителей), а одновременно ко всему набору «классов-кандидатов». Благодаря тому, что в желаемом ответе допускается наличие нескольких классов, во время тренировки для каждого примера будет найдена наиболее предпочтительная группа классов.

Если тип динамики какого-то участка анализируемого временного ряда состоит из примеров, каждый из которых классифицируется однозначно, то весь этот участок будет отнесен к единственному классу. Если же этот участок принадлежит области предполагаемого дрейфа, то на отдельных его

фрагментах будут доминировать различные типы динамики. Заметим, что анализ процесса изменения амплитуд ответов нейросети на участке дрейфа позволяет получать количественную информацию о характере дрейфа одного типа динамики в другой.

Эксперименты с псевдо-хаотическими временными рядами

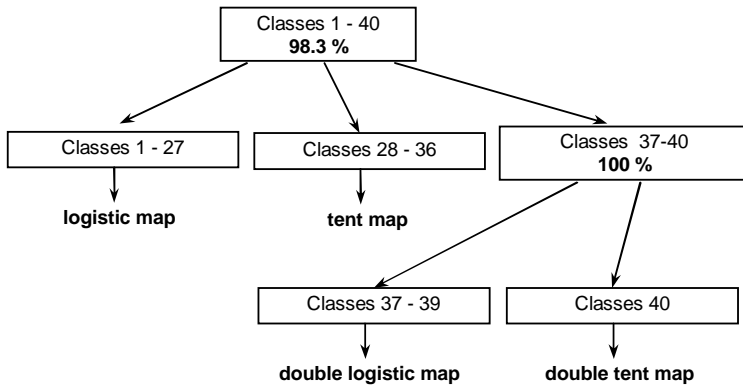
В модельных экспериментах использовалась задача определения границ псевдохаотических последовательностей $x(t+1) = f_i(x(t))$, $i = 1, 2, 3, 4$, где:

1. $f_1(x) = 4x(1-x)$, $x \in [0, 1]$; **logistic map**
2. $f_2(x) = 2x$, $x \in [0, 0.5]$, $2(1-x)$, $x \in [0.5, 1]$; **tent map**
3. $f_3(x) = f_1(f_1(x))$; **double logistic map**
4. $f_4(x) = f_2(f_2(x))$; **double tent map**


Эти последовательности чередовались, генерируя (в разных экспериментах) по 25–125 точек каждая, а общая длина тренировочного набора данных составляла 1000–2400 точек. Затем временной ряд линейно нормировался к нулевому среднему и единичному стандартному отклонению. Пример для тренировки нейросети формировался из пяти последовательных значений полученного временного ряда. Принадлежность примера к классу определялась по тому, к какому классу принадлежит последняя (самая правая) точка отрезка.

На начальной стадии исследовались временные ряды с переключающейся динамикой. Границы между сегментами в процессе работы алгоритма считались фиксированными.

В первом эксперименте каждая из псевдохаотических последовательностей поочередно генерировала по 50 точек, и этот процесс был повторен 5 раз. Таким образом, общая длина временного ряда составила 1000 точек. Этот ряд был поделен на 40 сегментов по 25 точек, поэтому первоначально в задаче было 40 классов. Общий процент распознавания этого ИНК составил 96.1%. Заметим, что классификация того же временного ряда в 4 класса, соответствующие 4 последовательностям, с помощью обыкновенного МСП дает лишь около 95%.



(a)



(b)

Рис. 8. Вверху – ИНК, построенный в эксперименте с сильным дисбалансом представительности классов (пропорция 27 : 9 : 3 : 1). Общий процент распознавания ИНК 98.3%. Внизу – сегментация временного ряда, полученная с помощью построенного ИНК (номер псевдохаотической последовательности, к которой была отнесена каждая точка временного ряда, в зависимости от номера точки; нуль соответствует нераспознанным образам)

Был также проделан набор экспериментов с несбалансированными классами, когда некоторые псевдохаотические последовательности давали значительно больше точек, чем другие. Наиболее сильный дисбаланс использовался в эксперименте, результаты которого представлены на рис. 8.

Было взято 1350 точек logistic map, 450 точек tent map, 150 точек double logistic map и только 50 точек double tent map. Таким образом, пропорция

между последовательностями была $27 : 9 : 3 : 1$. Размер тренировочного набора составил 2000 примеров. Этот набор был разделен на 40 сегментов по 50 точек в каждом. Общий процент распознавания ИНК, представленного на рис. 8, составил 98.3%. Проценты распознавания для каждой из последовательностей были следующими: logistic — 99.33%, tent — 98.2%, double logistic — 91.4%, double tent — 92%.

В следующей серии экспериментов в процессе работы алгоритму разрешилось подстраивать положение границ сегментов. Опишем один из таких экспериментов. Все четыре последовательности поочередно генерировали по 100 точек. Процесс был повторен 5 раз, в результате общая длина временного ряда составила 2000 точек. Весь набор был разбит на 47 сегмента по 43 примера в каждом (кроме последнего сегмента, принадлежащего f_4 , в котором было 22 примера), причем 13 из 47 сегментов содержали примеры, принадлежащие различным последовательностям. Таким образом, во многих сегментах присутствовало изменение типа динамики, и ожидалось, что алгоритм передвинет границы сегментов соответственно. Значение MPC было выбрано равным 10, скорость обучения 0.01.




Рис. 9. Результат сегментации модельного временного ряда после подстройки положения границ сегментов. Вертикальные линии — границы сегментов при начальном разбиении

Общий процент распознавания ИНК составил 98% при точно определенных границах каждого типа динамики. Границы сегментов были передвинуты алгоритмом таким образом, что к каждому сегменту принадлежат примеры практически только одного типа динамики (рис. 9).

В последней серии экспериментов исследовались временные ряды с дрейфовым характером изменения типа динамики.

Последовательности f_1-f_4 поочередно генерировали по 100 точек, с переходными участками шириной 50 точек. Процесс был повторен 4 раза, и в результате общая длина временного ряда составила 2400 точек. Весь набор был разбит на 48 сегментов по 50 примеров в каждом.

Для анализа полученного временного ряда использовалась нейросеть с 5 входными нейронами, 20 нейронами в скрытом слое и 48 нейронами в выходном слое. Сеть тренировалась со скоростью 0.01. С шагом в 200 эпох для каждого примера из временного ряда вычислялась оценка вероятности его принадлежности к каждому из классов, путем усреднения ответов НС в окне анализа шириной 50 точек.




Рис. 10. Результат сегментации модельного временного ряда, в котором переключение типа динамики носит дрейфовый характер. Видно, что на участках дрейфа одновременно существуют два типа динамики

На рис. 10 приведен результат сегментации описанной псевдохаотической последовательности с помощью разработанного алгоритма. На графике показаны существующие в каждый момент времени типы динамики, определенные в результате работы алгоритма. Видно, что на участках дрейфа одновременно существуют два типа динамики.

Эксперименты с биомедицинскими данными

Описанный алгоритм построения ИНК был применен для анализа записей физиологического изменения параметров дыхания (респираторные данные), снятых у здоровых людей во время дневного сна. Задача заключалась в разбиении временного ряда (10–15 тысяч точек, рис. 11, верхний график) на сегменты с различными типами динамики, соответствующими определенным стадиям сна. Сегментация, полученная с помощью ИНК (рис. 11, нижний график), сравнивалась с ручной разметкой временного ряда медицинским экспертом (рис. 11, средний график). Экспертная разметка включала 5 классов (W1/W2 — две фазы бодрствования, S1/S2 — две фазы сна, и артефакт) [20]. Данные для этого эксперимента доступны в Интернете [21].




Рис. 11. Анализ биомедицинских данных. Сверху вниз: анализируемый временной ряд (респираторные данные); ручное разбиение экспертом-медиком; результат сегментации данных разработанным алгоритмом

Данные нормировались к нулевому среднему и единичному стандартному отклонению. На вход нейросети подавались 16 точек временного

ряда, взятых с шагом в 6 точек. Временной ряд разбивался на сегменты по 360 точек в каждом. Значение MPC было выбрано равным 180, что соответствовало характерному времени существования одного типа динамики (фазы сна) по заключениям экспертов.

В табл. 2 приведены средние проценты соответствия разбиения, полученного с помощью ИНК, с экспертным разбиением. Соответствие ручной разметки с машинной сегментацией измеряется на различных уровнях точности. Грубое разбиение включает в себя два класса: $W = W1 \cup W2$ и $S = S1 \cup S2$. В более тонком разбиении используются три класса — $W1$, $W2$ и $S = S1 \cup S2$. В качестве «тестового набора» использовались две другие записи респираторных данных, полученные для того же пациента. Для сравнения приведены также результаты из статьи.

ТАБЛИЦА 2. Средние проценты соответствия разбиения, полученного с помощью ИНК, с экспертным разбиением

	Результат ИНК	Результат ИНК	Результаты [6]	Результаты [6]
Набор данных	W1-W2-S	W-S	W1-W2-S	W-S
Тренировочный	81.30%	86.93%	79.08%	86.33%
Тестовый	59.10%	71.35%	63.92 %	75.24%

Сильное различие между процентами, полученными для тренировочного и тестового наборов при сегментации W1-W2-S, могут свидетельствовать о некоторой «переученности» ИНК. Этот эффект связан, по-видимому, как с недостаточной представительностью данных, так и с тем, что одним из основных положений алгоритма является отсутствие ограничений сверху на выявляемое количество различных типов динамик.

Полученные проценты, тем не менее, демонстрируют перспективность алгоритма. Важно заметить, что эксперт давал оценку не только по респираторным данным, но и на основе других физиологических сигналов, регистрировавшихся одновременно с респираторными данными (ЭЭГ, ЭКГ, электроокулограмма, артериальное давление, частота сердечных сокращений), в то время как ИНК строился лишь на основе респираторных данных.

Работа с данными космофизического эксперимента

В качестве объекта анализа использовался временной ряд, состоящий из среднечасовых значений скорости солнечного ветра за 1974 г. (8760 точек). Поскольку в данных имелись значительные (около 20%) пропуски, для их заполнения использовалась следующая процедура: пропуски сначала заполнялись линейно с добавлением небольшого шума и вычислялся десятичный логарифм полученной зависимости. Затем рассчитывались коэффициенты вейвлет-преобразования Добеши 4-го порядка по 512 точкам (т.е. 512 часов, что составляет около 3 недель), и проводилось обратное преобразование с отбрасыванием коэффициентов с амплитудой ниже 30% от максимальной. Отфильтрованная кривая сглаживалась путем усреднения по 6 часам. Анализируемый временной ряд представлен на верхнем графике рис. 12. Расстояние между вертикальными линиями соответствует одному обороту Солнца.

Для компактного представления динамики полученного временного ряда в качестве входов для нейронной сети использовались 4 первые коэффициента вейвлет-преобразования Добеши 4-го порядка по 128 точкам (128 часов, что составляет около 5 суток) и 13 задержанных значений каждого из этих коэффициентов (с шагом в 48 часов). Максимальная задержка составляла 624 часа, а размер временного окна — около 27 суток.

Для определения участков различных типов динамики временной ряд разбивался на 27 сегментов по 324 точки в каждом (рис. 12, верхний график). Окно анализа составляло 162 точки. Нейронная сеть имела 56 входных, 27 выходных нейронов и 5 нейронов в скрытом слое. Скорость обучения сети составляла 0.5.

В результате работы алгоритма была получена сегментация анализируемого временного ряда, представленная на рис. 12.

На среднем графике показаны амплитуды ответов наиболее активных нейронов выходного слоя нейросети в зависимости от номера предъявленного примера. На нижнем графике показано разбиение временного ряда, полученное в результате работы алгоритма (нумерация классов произвольная). Из рисунка видно, что был выделен один основной тип динамики (класс № 3), один тип динамики с периодом проявления 4-5 оборотов Солнца (класс № 2), и два короткоживущих типа динамики с временем существования около половины оборота Солнца (классы № 1 и № 5). Длительности переходных периодов между различными типами динамики составили от 1/5 до половины оборота Солнца.




Рис. 12. Анализ космофизических данных. Сверху вниз: анализируемый временной ряд (скорость солнечного ветра в логарифмическом масштабе); усредненные амплитуды ответов нейронной сети; полученная сегментация временного ряда. Вертикальные линии — начальные границы нечетных сегментов

Заключение

Проведенные исследования показали, что предложенный метод решения задач классификации путем построения ИНК обеспечивает высокую эффективность как при решении задачи с хорошо разделяемыми классами, так и при решении сложной задачи с сильно перекрывающимися классами. Перечислим **отличительные особенности** разработанного подхода:

- Каждый узел ИНК представляет собой обычный МСП, традиционно обучаемый с учителем. Предложенная модификация алгоритма тре-

нировки фактически переводит обучение МСП в режим обучения без учителя.

- Образование групп классов в узлах ИНК происходит одновременно с тренировкой соответствующего классификатора, обеспечивая оптимальный выбор признаков.
- Алгоритм формирования групп классов наследует все хорошо известные преимущества МСП, в частности, возможность тренировки на примерах, что позволяет учесть естественным образом априорную информацию о сходстве группируемых образов.
- Структура ИНК не задается заранее. Рекурсивное применение алгоритма обеспечивает адаптивное наращивание иерархических структур.
- Параметры алгоритма позволяют управлять топологией получаемых ИНК.
- Применение этого подхода позволяет получить структуры с высоким процентом распознавания, достаточно устойчивые к наличию шума в тестовых данных.
- Модификация алгоритма позволяет его использовать для сегментации временных рядов как с переключающейся динамикой, так и с дрейфовым характером изменения динамики.

Литература

1. *Dolenko S. A., Orlov Yu. V., Persiantsev I. G., Shugai J. S., Eremin E. K.* Adaptive method of construction of a perceptron-based hierarchical structure of classifiers // The 4th Open Russian-German Workshop on Pattern Recognition and Image Analysis, Valдай, Russia, March 4-8, 1996, pp. 45-49.
2. *Dolenko S. A., Orlov Yu. V., Persiantsev I. G., Shugai J. S., Eremin E. K.* The perceptron-based hierarchical structure of classifiers constructed by the adaptive method // *Pattern Recognition and Image Analysis*, 1997, Vol.7, No.1, pp.24-28.
3. *Dolenko S. A., Orlov Yu. V., Persiantsev I. G., Shugai J. S., Eremin E. K.* Self-organising construction of hierarchical structure of multi-layer perceptrons // Proc. 5th Int. Conf. on Artificial Neural Networks, Churchill College, University of Cambridge, UK, July 7-9, 1997, p. 285-290.
4. *Доленко С. А., Орлов Ю. В., Персианцев И. Г., Шугай Ю. С.* Использование принципов самоорганизации для построения иерархических нейросетевых классификаторов // 3-я конференция «Распознавание образов и анализ изображений:

- Новые информационные технологии», 1–7 декабря 1997 г., Н. Новгород. Тезисы докладов в 2 ч., ч. 1. с. 31–35.
5. *Dolenko S. A., Orlov Yu. V., Persiantsev I. G., Shugai J. S.* Use of self-organization principles in construction of hierarchical neural network classifiers // *Pattern Recognition and Image Analysis*, 1998, Vol. 8, No. 2, pp. 122–124.
 6. *Dolenko S. A., Orlov Yu. V., Persiantsev I. G., Shugai J. S.* Construction of hierarchical neural classifiers by self-organizing error back-propagation // Proc. Int.ICSC/IFAC Symposium on Neural Computation, Sept 23–25 1998, Vienna, Austria. Ed. *M.Heiss*, ICSC Academic Press International Computer Science Conventions Canada/Switzerland, 1998, pp. 113–116.
 7. *Rumelhart D. E., Hinton G. E., Williams R. J.* Learning internal representations by error propagation // In: *Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, Vol. 1: Foundations, MIT Press, 1986, pp. 318–362.
 8. *Hornik K., Stinchcombe M., White H.* Multilayer feedforward networks are universal approximators // *Neural Networks*, 1989, Vol. 2, No. 5, pp. 359–366.
 9. ELENA – Enhanced Learning for Evolutive Neural Architecture, ESPRIT Basic Research Project Number 6891, June 1995,
URL: <ftp://ftp.dice.ucl.ac.be/pub/neural-nets/ELENA/databases>
 10. Carnegie-Mellon University Repository of Neural Network Benchmarks.
URL: <http://www.boltz.cs.cmu.edu>
 11. *Рабинер Л., Шафнер Р.* Цифровая обработка речевых сигналов. – М: Радио и связь, 1981.
 12. *Traunmuller H.* Analytical expressions for the tonotopic sensory scale // *J. Acoust. Soc. Am.* 1990, Vol. 88, pp. 97–100.
 13. *Lee G. E., Tattersall G. D., Smyth S. G.* Isolated word speech recognition using a neural network based source model // *BT Technol. J.*, 1992, Vol. 10, No. 3, pp. 38–47.
 14. *Pawelzik K., Kohlmorgen J., Muller K.-R.* Annealed competition of experts for a segmentation and classification of switching dynamics // *Neural Computation*, 1996, Vol. 8, No. 2, pp. 340–356.
 15. *Kehagias A., Petridis V.* Time-series segmentation using predictive modular neural networks // *Neural Computation*, 1997, Vol. 9, No. 8, pp. 1691–1709.
 16. *Watanabe E., Nakasako N., Mitani Y.* A prediction method of non-stationary time series data by using a modular structured neural network // *IEICE Trans. Fundamentals*, 1997, Vol. E80-A, No. 6, pp. 971–976.
 17. *Kohlmorgen J., Muller K.-R., Rittweger J., Pawelzik K.* Identification of nonstationary dynamics in physiological recordings // *Biological Cybernetics*, 2000, Vol. 83, pp. 73–84.

18. *Dolenko S. A., Orlov Yu. V., Persiantsev I. G., Shugai Yu. S.* Time series analysis using hierarchical neural network classifiers // Proc. 5th International Conference on Computational Intelligence And Neuroscience, Atlantic City, NJ USA, Ed. *P. P. Wang*, Association for Intelligent Machinery, Inc., 2000, Vol. 1, pp. 908–911.
19. *Dolenko S. A., Orlov Yu. V., Persiantsev I. G., Shugai Yu. S.* Solar wind data analysis using self-organizing hierarchical neural network classifiers // *Lecture Notes in Computer Science*, Eds. *J. Kittler* and *F. Roli*. Springer-Verlag Berlin Heidelberg, 2001, Vol. 2096, pp. 289–298.
20. *Hornik K., Stinchcombe M., White H.* Multilayer feedforward networks are universal approximation // *Neural Networks*, 1990, Vol. 2, No. 5, pp. 359–366.
21. URL: <http://www.first.gmd.de/persons/kohlmorgen.jens/physiodata.tar.gz>

Игорь Георгиевич ПЕРСИАНЦЕВ, ведущий научный сотрудник Научно-исследовательского института ядерной физики имени Д. В. Скобельцына МГУ имени М. В. Ломоносова, доктор физико-математических наук, профессор. Область научных интересов: физика плазмы, спектроскопия, газовые лазеры, адаптивные методы обработки данных физического эксперимента, искусственные нейронные сети, генетические алгоритмы. Имеет более 120 научных публикаций.

В. Д. КОШУР

Институт космических и информационных технологий,
Сибирский федеральный университет, г. Красноярск

E-mail: VKoshur@sfu-kras.ru

НЕЙРОИНТЕЛЛЕКТУАЛЬНЫЕ МАТЕРИАЛЫ, СИСТЕМЫ И КОНСТРУКЦИИ

Аннотация

Представлены основные концептуальные идеи, которые лежат в основе разработки новых интеллектуальных материалов, систем и конструкций. Рассмотрены примеры адаптивных материалов и нейрорегулируемых систем, которые используются для трансформации упругих и акустических полей, подавления вибраций и шума, адаптивных конструкций космических антенн большого диаметра. Представлена модель нейрокомпьютерной диагностики для неразрушающего контроля ответственных элементов технических систем при их эксплуатации. Приведена классификационная таблица интеллектуальных материалов и систем, в основе которой лежит реализация энергетического и информационного обмена, осуществляемого на материальных носителях различного пространственного масштаба от метрового до нанометрового диапазона. Отмечены новые перспективные направления разработок.

V. D. KOSHUR

Institute of Space and Information Technology,
Siberian Federal University, Krasnoyarsk, Russia

E-mail: VKoshur@sfu-kras.ru

NEUROINTELLIGENT MATERIALS, SYSTEMS AND STRUCTURES

Abstract

Some basic concepts are presented underlying development of new intelligent materials, systems and constructions. Examples of adaptive materials and neural control systems are considered which are used for transformation of elastic and acoustic fields, suppression of vibrations and noise, adaptive design of large diameter space reflectors. A model of neural computer diagnostics is suggested to inspect nondestructively major elements of technical systems during their operations. The classification table for intelligent materials and systems is given basing on power and information exchange realizations which is carried out with material carriers of various spatial scales from meter to nanometer range. Some new prospective development directions are outlined.

Введение

История развития человеческого общества в сфере создания искусственных объектов и технических систем свидетельствует о стремлении людей создавать искусственные объекты, которые обеспечивали человеку более комфортные условия жизни. В первую очередь это было связано с необходимостью облегчения физического труда и увеличения его производительности. Созидательные способности человека были направлены на создание новых искусственных систем, которые могли бы частично или полностью заменить человека при выполнении его функциональных обязанностей, усиливали его интеллектуальные возможности, создавая искусственную окружающую среду, которая могла бы сделать жизнь человека более безопасной и комфортной в плане сохранения здоровья, развлечений и получения необходимой информации.

Переход от колеса, рычага и паруса к паровозам, пароходам и самолетам был тесно связан с созданием таких технических подсистем, которые обладают свойством саморегуляции подобно инерционному механизму Уатта. Развитие электроники, теории автоматического регулирования, кибернетический подход и стремление копировать некоторые свойства живых организмов, привели к понятиям адаптивного поведения искусственных объектов и в дальнейшем к созданию систем с элементами искусственного интеллекта.

Реализация в технических системах некоторых уровней искусственного интеллекта может быть проведена на основе мехатроники [1]. Этот термин объединяет понятия «механизм» и «электроника», так что с помощью чувствительных элементов (сенсоров), источников энергии, исполнительных элементов (актуаторов), искусственных нейронных сетей и микрокомпьютеров можно обеспечить требуемую активную реакцию технической системы на изменяющиеся внешние воздействия, то есть оснастить машину «интеллектом». Реализация возможностей нейронных сетей и ЭВМ для целей управления позволяют создавать оригинальные алгоритмы адаптации, слежения, распознавания, обучения [2, 3]. Мехатронные и нейроинтеллектуальные системы представляют собой нераздельное единство механических, электронных и нейросетевых узлов, в которых осуществляется обмен энергии и информации. Для моделирования таких систем используются дифференциальные уравнения, основанные на законах сохранения массы, импульса, энергии, соответствующие численные методы, а также мягкие вычисления, которые включают генетические алгоритмы, искусственные

нейронные сети и нечеткую логику [4].

Если говорить о перспективах развития интеллектуальных материалов, систем и процессов, то яркими примерами, но фантастическими, могут служить проект Эрика Дрекслера самовоспроизводящихся нано-роботов и мыслящий океан, описанный Станиславом Лемом в романе «Солярис».

Примеры адаптивных материалов, систем и конструкций

Слоистые композиционные материалы

Применение композиционных материалов, таких как стекло-, угле-, боропластиков и т. п. при создании аэрокосмической техники привело к пониманию того, что для более эффективного использования таких материалов их структура должна быть оптимально спроектирована, исходя из заданных режимов эксплуатации конкретных композиционных элементов, то есть композиционный материал должен проектироваться и создаваться под конструкцию, учитывая особенности ее эксплуатации [5–8]. Следующий естественный шаг состоит в том, чтобы композиционный материал сделать управляемым активным элементом системы или конструкции. Активный композиционный материал такого типа представлен на рис. 1.

Пьезокерамические вставки, слои или другие структурные элементы могут выполнять роль сенсоров и/или актуаторов, их использование основано на прямом и обратном пьезоэлектрическом эффекте. Возникающие при деформировании электрические напряжения на обкладках пьезоэлектрического слоя дают возможность наблюдать изменения процесса деформирования, а управляемые воздействия электрическим полем на пьезоэлектрические вставки позволяет активно воздействовать и изменять характер процесса деформирования. Блоки управления могут быть спроектированы на основе традиционных схем автоматического регулирования, например в виде ПИД-контроллеров, а также с использованием нейронных сетей различной архитектуры, что является более перспективным при реализации сложных процессов управления [9–17].

На рис. 2 и рис. 3 показаны две схемы нейросетевого управления процессом динамического деформирования слоистой металлокерамической пластины, содержащей 13 чередующихся слоев из алюминия и пьезокерамики, под действием изменяющего внешнего давления $F(t) = F_0 \sin(\omega t)$ на лицевой поверхности пластины.





Рис. 1. Структура активного композиционного материала с пьезо-
керамической вставкой PZT, изолирующими слоями Iso и углепла-
стиковыми слоями CFK



Рис




Рис. 3. Схема включения нейросетевого блока управления по типу автоматического регулирования с выходными сигналами в виде электрических напряжений для шести активных слоев пьезокерамики

щений по толщине композитной пластины, v_s — скорость перемещений тыльной поверхности пластины, u_s — перемещение тыльной поверхности пластины, $u_s^{opt} = f(t, \omega^{opt})$ — заданная функция перемещения тыльной поверхности пластины с требуемой частотой ω^{opt} .

Минимизация функционала J_1 по параметрам \mathbf{W} нейронной сети соответствует максимальному уменьшению колебаний тыльной поверхности пластины. Минимизация функционала J_2 обеспечивает последовательную трансформацию упругих колебаний (приходящих с лицевой на тыльную поверхность пластины) к заданной форме и частоте, а настраиваемая нейронная сеть реализует управление для достижения поставленной цели.

Значения функционалов J_1 , J_2 определяются в результате численного интегрирования в интервале $t \in [0, T]$ системы обыкновенных дифференциальных уравнений движения узловых масс дискретных элементов композитной пластины [10–11] с дополнительными внутренними связями, выраженными в дифференциальной и алгебраической форме. Минимизация функционалов (1) и (2) по параметрам \mathbf{W} трехслойной нейронной сети проводилась различными алгоритмами первого и нулевого порядка. Наиболее эффективными для данных задач оказались алгоритм Хука-Дживса и алгоритм случайного спуска с комбинированным обучением. Для найден-




Рис. 4. Изменение перемещений $u_s(t)$ (кривая 1) при динамическом деформировании композитной пластины в пассивном режиме и $u_s^*(t)$ (кривая 2) для найденного нейросетевого управления (горизонтальная ось — время t в микросекундах)




Рис. 5. Изменение скоростей $v_s(t)$ (кривая 1) при динамическом деформировании композитной пластины в пассивном режиме и $v_s^*(t)$ (кривая 2) для найденного нейросетевого управления (горизонтальная ось — время t в микросекундах)




Рис. 6. Графики заданного перемещения $u_s^{opt} = f(t, \omega^{opt})$ (кривая 1) для $\omega^{opt} = \omega/3$ и перемещения $u_s^{**}(t)$ (кривая 2) для найденного нейросетевого управления при $J_2 \rightarrow \min$ (горизонтальная ось — время t в микросекундах)

ных оптимальных параметров \mathbf{W}^* и рассмотренных вариантов нейросетевого управления удалось осуществить уменьшение амплитуд колебаний тыльной поверхности на один десятичный порядок.

На рис. 4 приведены графики перемещений $u_s(t)$ — при деформировании пластины без включения управления (кривая 1), когда все пьезокерамические слои пластины пассивные и $u_s^*(t)$ — для найденного нейросетевого управления (кривая 2) при $\min J_1 = J_1(\mathbf{W}^*)$.

На рис. 5 представлены графики изменения скорости перемещения $v_s(t)$ (кривая 1) для пассивного режима деформирования и скорости $v_s^*(t)$ (кривая 2) с существенным уменьшением амплитуд колебаний тыльной поверхности композитной пластины для найденного нейросетевого управления при $\min J_1 = J_1(\mathbf{W}^*)$.

На рис. 6 показаны совмещенные графики для заданных перемещений $u_s^{opt} = f(t, \omega^{opt})$ в функционале качества J_2 и перемещения $u_s^{**}(t)$, полученного для найденного нейросетевого управления при $\min J_2 = J_2(\mathbf{W}^{**})$. За счет настройки 30 параметров трехслойной нейронной сети значение функционала $J_2(\mathbf{W})$ удалось уменьшить только в три раза, при этом значение $J_2(\mathbf{W}^{**})$ осталось еще недостаточно близким к нулю. Поэтому расхождение между кривыми на рис. 6 достаточно существенное, но при этом





Рис. 7. Изменение напряженности электрического поля в трех слоях керамики при найденном нейросетевом управлении $J_1 \rightarrow \min$






Рис. 9. Распределение скоростей перемещений $v(z, t)$ композитной пластины для найденного нейросетевого управления при $J_1 \rightarrow \min$

средняя частотная характеристика $u_s^{**}(t)$ близка к заданному значению ω^{opt} .

Чтобы представить физический процесс управления электрическими напряжениями для схемы рис. 1 при минимизации J_1 , т.е. уменьшении амплитуд колебаний на тыльной поверхности металлокерамической пластины, на рис. 7 в виде поверхности $EE_{sve} = E(z, t)$ показано изменение напряженности электрического поля в трех слоях керамики для найденного нейросетевого управления.

Общая волновая картина деформирования металлокерамической пластины приведена на рис. 8 и 9.

На рис. 8 в виде поверхности $VV_{pas} = v(z, t)$ показано изменение распределения скоростей по толщине пластины вдоль координаты z (130 дискретных элементов, по 10 в каждом слое) и времени t в пассивном режиме деформирования.

На рис. 9 в виде поверхности $VV_{sve} = v(z, t)$ показано изменение распределения скоростей по толщине пластины и времени t для найденного нейросетевого управления электрическими напряжениями в трех четных пьезоэлектрических слоях. Ближайшая граница поверхностей соответствует тыльной стороне пластины, где амплитуды скоростей перемещений, благодаря найденному управлению, снижены на порядок.

Анализ результатов проведенных вычислительных экспериментов с най-

денным нейросетевым управлением для подавления различных частот внешнего воздействия из некоторого диапазона показал, что достаточной универсальностью или широкой адаптивностью рассмотренные виды управления, к сожалению, не обладают. В частности, синоптические карты весов нейронных сетей, полученных для подавления амплитуд колебаний на тыльной поверхности пластины, могут сильно отличаться для различных частот внешних воздействий. По этой причине были проведены вычислительные эксперименты по поиску и настройке в определенном смысле универсального нейросетевого управления для заданного интервала частот $\Omega = [0.5\omega, 2.0\omega]$, где $\omega = 5\pi \cdot 10^{-6}$ 1/с. При этом рассматривалась минимизация функционала вида:

$$J_1^\omega(\mathbf{W}) = \frac{1}{1.5\omega T} \left\{ \int_{\Omega \times [0, T]} (v_s)^2 dt d\omega \right\}^{1/2}. \quad (3)$$

Для решения задачи $J_1^\omega \rightarrow \min$ требуются большие вычислительные затраты по сравнению с рассмотренной задачей $J_1 \rightarrow \min$ при фиксированной круговой частотой ω . При минимизации $J_1^\omega(\mathbf{W})$ для универсального нейросетевого управления было достигнуто снижение амплитуды колебаний на тыльной поверхности в 2–3 раза, но не на порядок, как это возможно для каждой частоты в отдельности.

В дальнейшем планируется найти эффективное адаптивное управление за счет введения двухступенчатого управления, содержащего блок распознавания частоты с последующим переключением на настроенный блок управления одной из базовых частот, конечный набор которых с требуемой эффективностью по качеству управления перекрывает определенный интервал частот внешних воздействий. Данный способ управления основан на покрытии интервала Ω конечным набором малых окрестностей $(\omega_i - \varepsilon, \omega_i + \varepsilon)$, где ω_i для $i = 1, 2, \dots, n$ — найденный набор базовых частот, ε — допустимая погрешность в определении частоты, согласованная с локально адаптивными свойствами найденных нейросетевых управлений для базовых частот ω_i .

Найденные с помощью компьютерного моделирования варианты активных материалов в виде композитных пластин с нейросетевым управлением указывают на возможность создания достаточно тонких слоистых преград для гашения упругих волн не за счет демпфирования и пассивного отражения на границах слоев с резко изменяющимися свойствами, а за счет последовательной трансформации упругих волн с помощью управляемого

воздействия электрическими полями на активные структурные включения из пьезоэлектрических материалов.

Ввиду способности управляющих и вычислительных блоков, с использованием нейрочипов, осуществлять высокое быстродействие при преобразовании информации, использование нейросетевых распознающих и управляющих блоков как составляющих элементов комплексной системы, объединяющей механическую, электронную и нейросетевую подсистемы и называемых Матричными Электронными Материалами (МЭМ) [9] является перспективным для управления деформационными процессами в режиме реального времени.

Активные композиционные панели и подавление вибраций [16,17]

На рис. 10 схематично представлен переход от пассивных материалов, систем и конструкций к активным управляемым системам. Третий интеллектуальный уровень характеризуется тем, что сенсорные, актуаторные, а в дальнейшем и электронные блоки управления являются нераздельной частью таких новых конструкций. Если говорить образно, то искусственный интеллект и исполняющие элементы погружаются в создаваемые системы, пронизывая и переплетаясь с другими элементами, так что в совокупности они создают новый искусственный объект, в котором, следуя цели создателя, осуществляется направленный энергоинформационный обмен при целесообразном функционировании.

На рис. 11 показано применение активных композиционных материалов для подавления вибраций в космических аппаратах.

На рис. 12 показано статическое деформирование алюминиевой панели при воздействии распределенными пьезоэлектрическими элементами с разницей потенциалов в 100 В. Этот эффект может быть использован для управления прогибом панелей и активного подавления вибраций.

Адаптивные конструкции космических телескопов и космических антенн [18,19]

На рис. 13 и 14 показан общий вид адаптивной конструкции космического интерферометра и фрагмент несущей стержневой фермы с актуаторными пьезоэлектрическими элементами в стержневых элементах конструкции. Такое инженерное решение позволяет точно позиционировать конструкцию

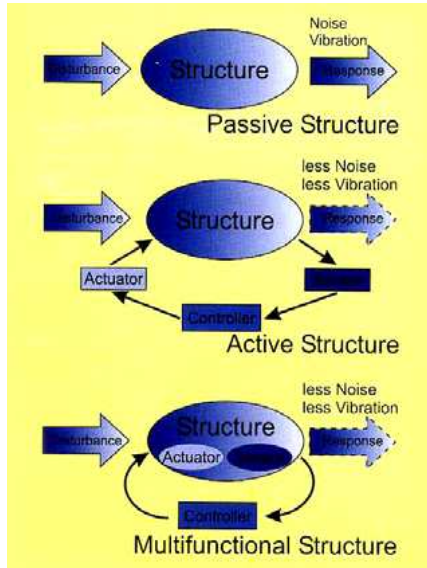


Рис. 10. Схема перехода от пассивных к активным и интеллектуальным конструкциям




Рис. 11. Подавление вибраций в космических аппаратах




Рис. 12. Деформирование панели с пьезоэлектрическими элементами

и управлять уровнем вибрации.

На рис. 15–17 показаны конструктивные особенности адаптивных космических антенн и технология их изготовления. Управление активными элементами антенн позволяет подстраивать форму поверхности рефлектора антенны при нежелательных искажениях, которые могут образоваться из-за неравномерного температурного деформирования антенн большого диаметра при солнечном облучении и переходе антенны в тень планеты.

Управление акустическими полями и подавление шума

В качестве примеров управления поведением среды, на рис. 18–21 показаны варианты активного подавления шума за счёт введения дополнительных

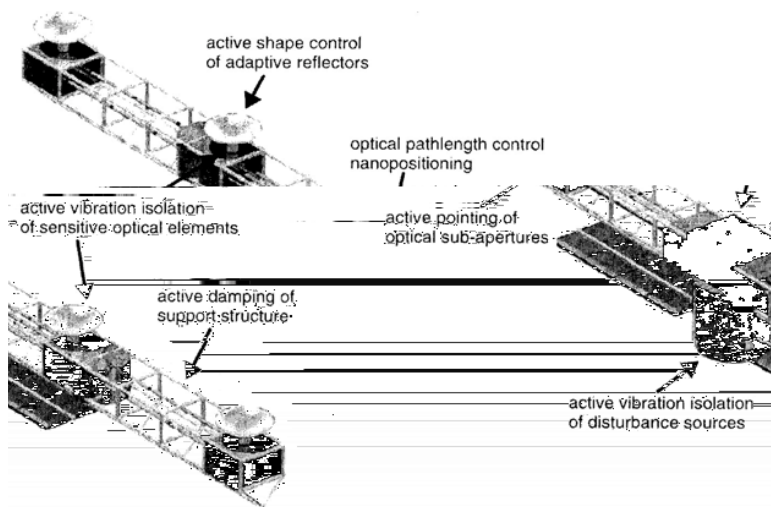


Рис. 13. Адаптивная конструкция космического телескопа




Рис. 14. Фрагмент несущей стержневой фермы телескопа с активными элементами




Рис. 15. Рефлектор космической антенны с активными элементами




Рис. 16. Слои активной космической антенны




Рис. 17. Технология изготовления рефлекторов космических антенн

акустических источников в салоне автомобиля и понижения акустического давления в заданной области ограниченного двумерного пространства [20, 21]. На рис. 20 и 21 показаны последовательные этапы изменения акустического давления в расчетной области при действии пассивного источника и при действии управляемых нейронной сетью активных акустических источников. В контролируемой области S это позволяет уменьшить среднее акустическое давление в несколько раз.

Блоки адаптивного управления, на основе нейронных сетей при реализации в виде электронных схем обладают высоким быстродействием. Это позволяет вести управление в режиме реального времени, включая микро- и миллисекундный диапазон.

Нейрокомпьютерная диагностика и неразрушающий контроль

Разработка методов неразрушающего контроля и диагностики рабочего состояния ответственных элементов технических устройств является актуальной задачей для энергетики, машиностроения, транспорта, авиационной и космической техники. Снабжение ответственных элементов конструкций различными датчиками, которые в процессе эксплуатации выдают информацию но, как правило, косвенную о рабочем состоянии тестируемого элемента, а так же диагностические стенды в полной мере не решают





Рис. 18. Подавление шума в салоне автомобиля

Рис. 19. Двумерная область D и зона контроля акустического давления S ; E — пассивный акустический источник, F — активный акустический источник




Рис. 20. Распределение давления при действии пассивного акустического источника: (а) $t = T/4$, (б) $t = T/2$, (в) $t = T$

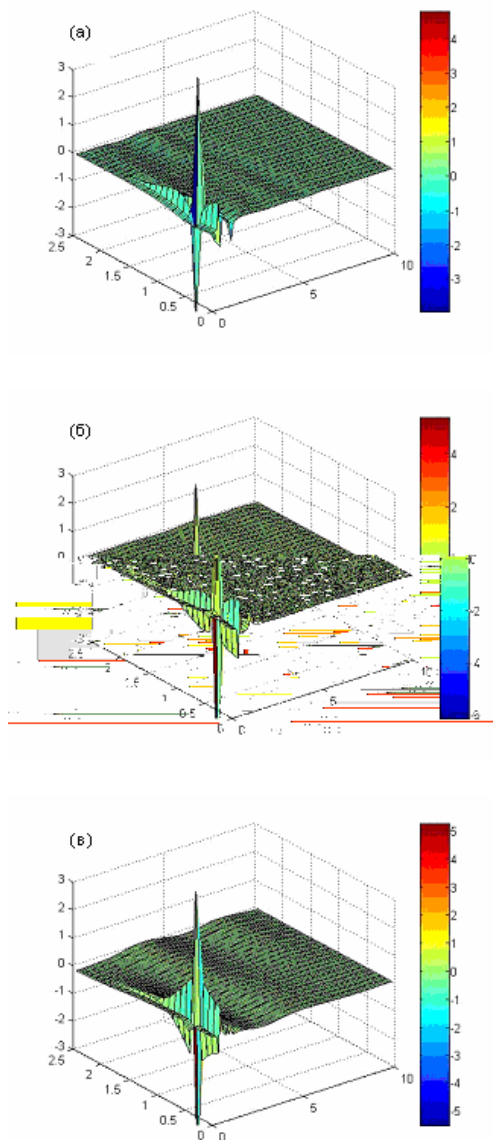


Рис. 21. Распределение давления при действии пассивного и двух активных источников: (а) $t = T/4$, (б) $t = T/2$, (в) $t = T$

проблему контроля технической системы в режиме on-line. Одним из примеров движения в сторону более полного и адекватного представления о текущем рабочем состоянии и надежности является система Smart Disk по диагностике работоспособности жесткого диска при записи информации на компьютере.

В рамках рассматриваемой концепции нейроинтеллектуальных материалов, систем и конструкций можно предложить следующую новую схему нейрокомпьютерной диагностики. В ответственный элемент конструкции, например, лопатку турбины, корпус цилиндра двигателя или поршня при изготовлении внедряется система распределенных сенсорных микро элементов, так чтобы прочностные свойства детали не сильно пострадали. Затем строится детальная компьютерная модель конструкционного элемента с учетом изменения его структуры, т. е. специальным образом распределенных сенсорных включений, например в виде пьезо- или ферромагнитных микродатчиков. На базе компьютерной модели проводится серия многопараметрических расчетов по определению изменения напряженно-деформируемого состояния рассматриваемого конструкционного элемента с записью показаний сенсорных элементов. Это дает возможность подготовить базу данных для обучения специализированной нейронной сети, которая должна эмулировать работу конструкционного элемента. При этом изменяющиеся параметры сенсорных элементов и информация об изменяющейся нагрузке являются входными параметрами нейронной сети, а выходными могут служить соответствующие данные об изменении напряженно-деформируемого состояния моделируемого конструкционного элемента, например, в виде концентрации напряжений в опасных зонах возможного разрушения. После тестирования, обученная нейронная сеть служит информационным образом конструкционного элемента. После ее электронной реализации она присоединяется к конструкционному элементу, так что на ее вход подаются реальные показания встроенных сенсорных элементов и параметры изменяющейся внешней нагрузки, а выходные параметры нейронной сети о текущем напряженно-деформируемом состоянии и концентрации напряжений в режиме on-line могут передаваться супервизорной системе наблюдения и/или контролироваться человеком. Главный смысл нейрокомпьютерной диагностики заключается в том, что за счет свертки информации, полученной после детального и длительного компьютерного моделирования, эмулирующие нейронные сети способны практически мгновенно давать информацию о внутреннем состоянии контролируемых элементов и технической системы в целом.

**Классификационная таблица интеллектуальных
материалов, систем и конструкций**

УРОВНИ ⇒ ↓	СИСТЕМНЫЙ ИНТЕЛЛЕКТ								
	МАСШТАБ	0	1	2	3	4	5	6	7
E-0	L(0,0)								L(0,7)
E-1									
E-2									
E-3									
E-4									
E-5									
E-6									
E-7									
E-8									
E-9	L(9,0)								L(9,7)
(Å)									

Рис. 23. Классификационная таблица интеллектуальных материалов, систем и конструкций

Масштаб материальных элементов в таблице обозначен: $E-k = 1 \cdot 10^{-k} \text{ м}$, $k = 1, 2, \dots, 9$ и девятый уровень соответствует нанотехнологиям [22–25]. Уровни системного интеллекта условно представлены цифрами от 0, 1, 2, \dots , 7 по аналогии со сменой поколений ЭВМ при развитии вычислительной техники.

Рассмотрим некоторые характерные примеры заполнения клеток $L(i, j)$ классификационной таблицы:

L(0-2,0): механизмы с простейшей само регулировкой: механизм Уатта, паровоз Ползунова, поплавковая камера, карбюратор и т. п.

L(0-3,1): жестко программируемые механизмы и приборы на исполнение определенных действий: механические игрушки, часы, шарманка, арифмометр, механическое пианино, радио, проигрыватель, магнитофон, манипуляторы и различные роботы первого поколения.

L(0-4, 2): роботизированные системы второго поколения с элементами подстройки и саморегулирования: следящие системы, автопилот, простейшие системы анализа ситуаций и принятия решений в виде заранее предписанных действий.

L(3-4, 0-3): области таблицы, соответствующие структурным композитным материалам с адаптивными свойствами, мехатронные системы с различным уровнем интеллектуальной реакцией на внешние воздействия.

L(4-6,2-4): ультрадисперсные порошковые материалы и пленки с адаптивными свойствами.

L(3-6,4-6): адаптивные структурные материалы и дисперсные системы с распределенным и супервизорным управлением и разветвленной саморегуляцией – новые прототипы Smart Materials.

L(4-7,5-6): среды и вещества с распределенным энергетическим и информационным обменом, обладающие свойствами самоорганизации – Intelligent Materials.

L(8-9,1-6): наносистемы будущего поколения, с распределенным искусственным интеллектом, который обеспечивается за счет управления физическими полями взаимодействий.

L(9,7): наносистемы, нанороботы фантастического проекта Эрика Дрекслера.

Другим ячейкам таблицы также может быть дана некоторая интерпретация новых проектных решений. При этом следует отметить объективно сложившуюся тенденцию имеющихся и разрабатываемых перспективных проектов — группироваться вдоль главной диагонали двумерной классификационной таблицы, что соответствует «сращиванию» уменьшающихся по пространственным размерам частицам различных веществ и носителей энергии с информационными микроэлементами, представляя возможность в дальнейшем осуществить управляемый и самоорганизующийся энергоинформационный обмен.

Роль нейросетевых связей распределенных по пространству структурного материала или многокомпонентной среды с микросенсорами и актуаторами при нейросетевом адаптивном управлении существенно повышается при реализации искусственного системного интеллекта для уровней 3, 4 и 5. Какие новые идеи потребуются при проектировании и реализации перехода к интеллектуальным материалам и системам 6-го и 7-го уровня — пока не представляется вполне ясным.

Следует отметить, что сложные комплексные адаптивные системы, которые содержат подсистемы с разными масштабами материальных носителей и различного уровня интеллекта, могут быть построены путем объединения ячеек таблицы через «тоннель связей» и выходом из плоскости двумерной таблицы в третье измерение по энергетическим параметрам.

Заключение

В этой лекции мне хотелось показать очень перспективную, наукоемкую область научных исследований и новейших инженерных разработок интеллектуальных материалов, систем и конструкций, расчёт эффективных параметров которых базируется на компьютерном моделировании и многоцелевой оптимизации, в основе которых лежат:

- теория искусственных нейронных сетей;
- теория адаптивного управления;
- механика и физика сплошных сред и композиционных материалов;
- специализированные численные методы решения систем дифференциальных уравнений и методов оптимизации.

В силу того, что лекция, главным образом, носит ознакомительный и обзорный характер, сложных математических формул и описание громоздких систем дифференциальных уравнений и специальных методов их решения в тексте удалось избежать, акцентируя главное внимание концептуальному и качественному описанию результатов. Необходимые детали и математические подробности могут быть восстановлены по цитируемым работам.

Литература

1. *Исии Т., Симояма И., Иноуэ Х., Хироце М., Накадзима Н.* Мехатроника: Пер. с япон. – М.: Мир, 1988. – 318 с.
2. *Linkens D. A., Nyongesa H. O.* Learning system in intelligent control: an appraisal of fuzzy, neural and genetic algorithm control applications // *IEE Proc. Control Theory and Applications*. 1996, Vol. 143, No. 4, pp. 367–386. [Рус. перевод: Обучающиеся системы в интеллектуальном управлении: сопоставление подходов, основанных на размытой логике, искусственных нейронных сетях и генетических алгоритмах. М.: ВИНТИ. Экспресс-информация: Астронавтика и ракетодинамика, 1997, Вып. 8, реф. 15, с. 2–36; 1997, Вып. 9, реф. 16, с. 2–24]
3. *Noor A. K., Jorgensen C. C.* A hard look of soft computing // *Aerospace America*. 1996, Vol. 34, No. 9, pp. 34–39. [Рус. перевод: Мягкие вычисления и некоторые их применения в аэрокосмических системах. – М.: ВИНТИ. Экспресс-информация: Астронавтика и ракетодинамика, 1997, Вып. 15, реф. 27, с. 2–14]
4. *Кошур В. Д.* Вычислительные технологии на основе мягких вычислений // *Вычислительные технологии*, Том 10, Специальный выпуск, 2005. с. 78–83.
5. *Кошур В. Д., Немировский Ю. В.* Континуальные и дискретные модели динамического деформирования элементов конструкций. – Новосибирск: Наука. Сибирское отделение, 1990. – 198 с.
6. *Болотин В. В., Новичков Ю. Н.* Механика многослойных конструкций. – М.: Машиностроение, 1980. – 375 с.
7. *Алфутов Н. А., Зиновьев П. А., Попов В. Г.* Расчет многослойных пластин и оболочек из композиционных материалов. – М.: Машиностроение, 1984. – 264 с.
8. *Кравчук А. С., Майборода В. П., Уржумцев Ю. С.* Механика полимерных и композиционных материалов: Экспериментальные и численные методы. – М.: Наука, 1985. – 304 с.
9. *Кошур В. Д.* Моделирование процессов управления трансформацией упругих волн в слоистых металлокерамических композитах, концепция матричных электронных материалов. // *Доклады Академии наук*, РАН, 1998, том 363, № 2, с. 181–183. Представлена акад. *Ю. И. Шокиным*.

10. *Koshur V.D.* Active and passive neural network control of shock waves transformations in laminated metal-ceramic composites: Concept of the Matrix Electronic Materials (MEM) // *Modelling and Control of Adaptive Structures / Ed. by U. Gabbert, Fortsch.-Ber. VDI Reihe 11, Nr. 268, Dusseldorf, VDI Verlag 1998, pp. 361–366.*
11. *Кошур В.Д.* Применение нейронных сетей для управления трансформацией деформационных волн в слоистых пьезоэлектрических композитах // *Труды Всероссийской научно-технической конференции «Нейроинформатика-99», Часть 2, Москва, МИФИ, 1999, с. 236–244.*
12. *Кошур В.Д.* Проектирование и компьютерное моделирование интеллектуальных матричных материалов на основе двухуровневого нейросетевого управления // *Труды Всероссийской научно-технической конференции «Нейроинформатика-2000», Часть 1, Москва, МИФИ, 2000, с. 249–254.*
13. *Koshur V.D.* Simulation of smart composite materials of the type of MEM by using neural network control. Proceeding of the IUTA // *Proceedings of the IUTAM Symposium Smart Structures and Structronic Systems, Magdeburg, Germany, 26–29 September 2000 / Ed. by U. Gabbert and H. S. Tzou, Kluwer Academic Publishers, Boston-London, 2001. – pp. 231–238.*
14. *Кошур В.Д.* Компьютерное моделирование интеллектуальных композитных материалов // *Вычислительные технологии*, 2001, Том 6, Часть 2, с. 218–225. Спец. выпуск – Труды международной конференции “Recent Developments in Applied Mathematics and Mechanics: Theory, Experiment and Practice” (RDAMM-2001), посвященной 80-летию акад. Н. Н. Яненко, Академгородок, Новосибирск, Россия, 24–29 июня 2001.
15. *Koshur V.D.* Modelling of laminated metal-ceramic composites with neural network control of elastic waves transformations // *Neural Network World, International Journal on Non-Standard Computing and Artificial Intelligence, Vol. 12, No. 4, 2002, pp. 349–360.*
16. *Hanselka H.* Realization of smart structure by using fiber composite materials // *Proceeding of the Second Scientific Conference Smart Mechanical Systems – Adaptronics, University of Magdeburg, 18–19 March 1997, Published by University of Magdeburg, 1997, pp. 1–10.*
17. *Gabber U.* Modeling and Automatic Design of Piezoelectric Controlled Smart Structures. // *IUTAM Symposium on Smart Structures and Structronic Systems. Tutorial Program. 25 September, 2000. University of Magdeburg, Germany, 2000. – 55 pp.*
18. *Dongi F.* Adaptive structures in high precision satellites // *Modelling and Control of Adaptive Mechanical Structures. Nr. 268, Dusseldorf: VDI Verlag 1998, pp. 429–438.*

19. *Melz T., Flovel M., Krajenski V., Antonia de la Torre M., Hanselka H., Moria Pintado J.* Smart antenna reflector manufactured in filament winding technology // *Modelling and Control of Adaptive Mechanical Structures*. Nr. 268, Dusseldorf: VDI Verlag 1998, pp. 449–458.
20. *Кошур В.Д., Фадеева М.С.* Нейроуправление параметрами активного источника для подавления акустических волн в заданной области // *Краевые задачи и математическое моделирование*, 2008. Том 1. с. 52–59.
21. *Кошур В.Д., Фадеева М.С.* Минимизация звукового давления по параметрам активных источников на основе гибридного генетического алгоритма // *Акустический журнал*, 2007. Том 53. № 6. – с. 839–842.
22. Нанотехнология.
URL: <http://www.nanometer.ru>
23. *Хартман У.* Очарование нанотехнологий. – М: Бином, 2008.
24. *Головин Ю.И.* Введение в нанотехнику. – М: Машиностроение, 2007.
25. *Пул Ч., Оуэнс Ф.* Нанотехнологии. – М: Техносфера, 2008.

Владимир Дмитриевич КОШУР, доктор физико-математических наук, профессор, руководитель научно-учебной лаборатории Вычислительного эксперимента кафедры Вычислительной техники в Институте космических и информационных технологий СФУ (г. Красноярск). Область научных интересов: компьютерное моделирование задач механики сплошных сред и композиционных материалов; адаптивное управление и оптимизация систем и процессов; численные методы; параллельные и мягкие вычисления; искусственные нейронные сети, искусственный интеллект. Автор более 150 публикаций и двух монографий.

Ю. И. НЕЧАЕВ

Государственный морской технический университет,
Институт высокопроизводительных вычислений
и информационных систем, г. Санкт-Петербург

E-mail: int@csa.ru

ПРОБЛЕМЫ МОДЕЛИРОВАНИЯ ДИНАМИКИ СЛОЖНЫХ СИСТЕМ ПРИ РЕАЛИЗАЦИИ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

Аннотация

Обсуждаются вопросы повышения эффективности моделирования поведения нелинейного динамического объекта при функционировании бортовой интеллектуальной системы (ИС) в сложных динамических средах. Основное внимание уделяется использованию нейронных сетей как конкурирующих вычислительных технологий при анализе и интерпретации информации. Сформулирована постановка задачи и концепция обеспечения эффективности моделирования динамики объекта как существенно нелинейной системы. Разработана модель представления волнения в виде климатического спектра сложной пространственной структуры и сформулированы сценарии развития шторма. Проведено компьютерное моделирование динамики взаимодействия нелинейного объекта при различном уровне внешних возмущений.

Yu. NECHAEV

Saint-Petersburg State Marine Technical University,
Institute for High-Performance Computing and Information Systems,
Saint-Petersburg

E-mail: int@csa.ru

PROBLEMS OF MODELING OF COMPLEX DYNAMICS SYSTEMS FOR REALIZATION NEURAL NETWORKS TECHNOLOGY

Abstract

An efficiency increasing is discussed to simulate a behavior of nonlinear dynamic object while functioning onboard intelligent system (IS) in complex dynamic environments. Major attention is focused on using of neural networks represent one of competing computational technologies meant for information analysis and interpretation. An appropriate problem statement is formulated as well as an efficiency support concept to simulate object dynamics as essentially nonlinear system. A model of sea roughness is develop which represents it as a climatic spectrum of complex spatial structure. Some scenarios of storm progress with time are also generated. An appropriate computer simulation are carried out to demonstrate dynamics of interaction as applies to various level of external disturbances.

Введение

Развитие науки и технологий в настоящее время сопровождается созданием технических средств интеллектуальной поддержки, отличающаяся чрезвычайной сложностью, расширением круга решаемых задач и диапазоном эксплуатационного использования. В этих приложениях все чаще находят применение компьютерные технологии, основанные на использовании методов искусственного интеллекта (ИИ). Такие технологии ориентированы на цепочку «моделирование–прогнозирование–принятие решений» и связаны с разработкой сложных интегрированных интеллектуальных систем (ИС) (рис. 1). В основу задач интеллектуальной поддержки положен информационный подход, логический базис которого заключается в выявлении и анализе информационных аспектов, имеющих принципиальное значение для понимания глубинной сущности, тенденций и закономерностей исследуемой ситуации [1–50]. Анализ «информационного среза» изучаемых ситуаций позволяет сформулировать основные принципы, определяющие «скрытые» информационные процессы. В настоящее время активно развиваются качественно новые составляющие интеллектуальных технологий, включающие формальный аппарат математики, базирующийся на неалгоритмическом процессе управления, обладающем естественной параллельностью и недетерминизмом [9, 28, 29].



Рис. 1. Архитектура интегрированной бортовой ИС

Появление ИС с динамической базой знаний потребовало пересмотра общих принципов организации и формализации знаний, а также программно-аппаратного обеспечения функционирования таких систем. Требования самообучения и самоорганизации в непрерывно изменяющейся нечеткой среде приводят к переосмысливанию содержания и алгоритмического наполнения адаптивной компоненты базы знаний и повышения роли математического моделирования при оценке и прогнозе поведения судна как сложного динамического объекта (ДО). Основной объем текущей информации здесь формируется не за счет формализации знаний экспертов, а от датчиков измерительной системы. Возникли проблемы интеграции знаний и анализа альтернатив, особенно в сложных бортовых интеллектуальных комплексах, включающих ИС различного назначения и функционирующих в мультипроцессорной вычислительной среде с использованием нейронечетких систем управления и принятия решений [28, 29]. Встраивание в аппарат знаний процесса автоматического решения не только вычислительных, но и логико-комбинаторных задач позволяет продвинуться в решении одной из наиболее сложных проблем «инженерии знаний» — создания средств представления и обработки знаний [23–26].

Целью настоящей работы является рассмотрение некоторых аспектов моделирования процессов взаимодействия ДО с внешней средой на примерах использования нелинейных моделей, обладающих способностями к самоорганизации и допускающих режимы детерминированного хаотического поведения фазовых траекторий. Используемые нелинейные модели описывают сложную динамику, включая равновесные режимы (предельные циклы), а также широкий спектр режимов детерминированного хаоса. При практическом использовании таких моделей при функционировании бортовых ИС обеспечения безопасности мореплавания и посадки летательных аппаратов морского базирования важное значение имеет надежная оценка ситуации и прогнозирование ее развития в условиях непрерывного изменения динамики объекта и внешней среды. Особый практический интерес представляет построение нелинейных математических моделей, способных изменять свою структуру при изменении поведения ДО на волнении. При синтезе таких алгоритмов используют различные подходы — детерминистский, стохастический и подход на основе принципов самоорганизации [9, 27–29]. Первые два подхода предполагают наличие в исходных данных полного информационного базиса, т. е. всех определяющих параметров и факторов, которые необходимо учитывать при анализе ситуации.

Концепция моделирования динамики внешней среды в бортовых ИС

Моделирование динамики внешней среды — одна из сложных задач, решаемых при разработке встроенных процедур и алгоритмов взаимодействия судна с внешней средой при построении базы знаний бортовой ИС. Современный подход к решению этой задачи требует использования новых представлений о динамике ветроволновых полей на основе концепции климатического спектра морского волнения, официально принятой на 18 Ассамблее Межправительственной Морской Организации (Intergovernment Marine Organization — ИМО) в 1993 году вместе с понятием «волновой климат» [33]. С помощью этих понятий открываются возможности более детального, по сравнению с существующей практикой, описания особенностей волновой погоды в конкретных районах океана. Под климатическими понимаются спектры волнения, полученные в результате осреднения ординат измеренных спектров волнения для различных интервалов высот.

Морское волнение относится к геофизическим процессам мелкомасштабного диапазона изменчивости с характерными временными и пространственными масштабами. Волнение рассматривается как вероятностный процесс, зависящий от набора факторов (условий волнообразования). Изменения связаны с прохождением барических образований (синоптическая изменчивость), годовой ритмикой (сезонная изменчивость) и долгопериодными вариациями циркуляционных процессов (межгодовая изменчивость).

Получение информации об экстремальных гидрометеорологических явлениях в рамках понятия о климатическом спектре основано на совместном моделировании ветра, волнения и течений на основе следующих допущений [33]:

- Основным источником данных об океанографических процессах является результаты расчетов по гидродинамическим моделям динамики океана. Такой подход позволяет, используя данные реанализа метеорологических полей как входные данные, получать информационные массивы океанографических характеристик непрерывной продолжительностью в несколько десятков лет.
- Для статистического оценивания экстремальных характеристик, возможных 1 раз в T лет, используется система стохастических моделей, описывающих совместную многомасштабную (синоптическую, сезонную, межгодовую) изменчивость пространственно-временных по-

лей океанографических характеристик. Это позволяет методом Монте-Карло воспроизвести ансамбль их реализаций, экстраполируя значения экстремумов на заданный временной интервал.

- Экстремальность гидрометеорологического явления по отношению к конкретному объекту определяется интегральной совокупностью всех факторов путем рассмотрения функций риска, специфичных для определенных классов морских объектов и сооружений.

В настоящее время доступность глобальных (NCEP/NCAR, ERA-40) и региональных (SMHI, JRA25, NMI и др.) массивов реанализа метеорологических полей, эволюция гидродинамических моделей и развитие высокопроизводительных вычислительных технологий сделали возможной практическую реализацию данного подхода в полном объеме.

Концепция моделирования предусматривает последовательное решение трех задач, объединенных в вычислительную цепочку. Каждая задача дополнительно распадается на систему взаимосвязанных модулей (см. рис. 2).

1. Подготовка массива метеорологической информации. В качестве входных данных для расчета океанографических характеристик (ветрового волнения, течений и уровня моря) могут быть использованы поля атмосферного давления и скорости приводного ветра на основе данных реанализа. Процедура усвоения может проводиться как для каждой метеорологической величины независимо, так и путем пересчета одних величин через другие.

2. Формирование массива полей океанографических характеристик на основе гидродинамических моделей. Использование массива метеорологической информации как входных данных позволяет выполнить совместное гидродинамическое моделирование волнения, течений и уровня моря, что обусловлено необходимостью учета фактической глубины акватории по разгону волн. В том случае, когда штормовые колебания уровня моря обычно сопровождаются развитым ветровым волнением, этот эффект может привести к появлению существенно больших волн, чем предельно возможные при среднем многолетнем положении уровня моря.

Гидродинамическая модель волнения в спектральной форме представляется как уравнение баланса волновой энергии:

$$\frac{\partial N}{\partial t} + \frac{\partial N}{\partial \varphi} \dot{\varphi} + \frac{\partial N}{\partial \theta} \dot{\theta} + \frac{\partial N}{\partial k} \dot{k} + \frac{\partial N}{\partial \beta} \dot{\beta} + \frac{\partial N}{\partial \omega} \dot{\omega} = G. \quad (1)$$

Здесь N — спектральная плотность волнового действия; она является функцией от широты φ , долготы θ , волнового числа k и угла β между

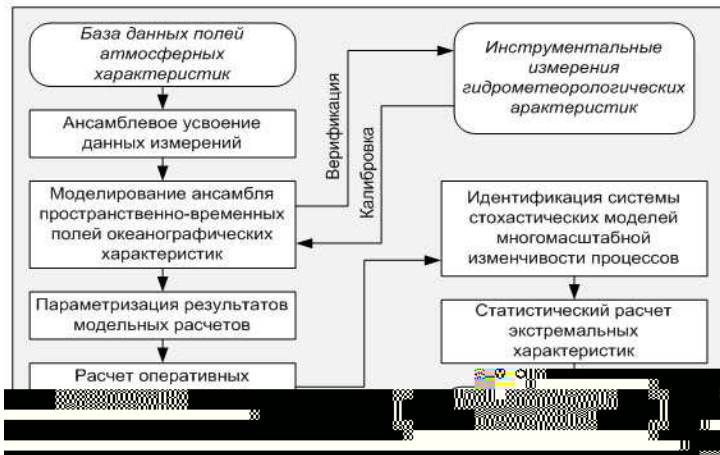


Рис. 2. Комплексная технология моделирования ветра, волнения, течений и уровня моря

направлением волнового вектора и параллелью, а также от частоты ω и времени t .

Это уравнение связывает между собой явления притока энергии от ветра, диссипации и ее перераспределения и нелинейного взаимодействия между частотными составляющими процесса волнения. Чаще всего функция источника G записывается в виде суммы трех компонент $G = G_{in} + G_{nl} + G_{ds}$ (поступления энергии от ветра к волнам, слабонелинейного взаимодействия в спектре ветрового волнения и диссипации волновой энергии, соответственно).

Для расчетов уровня моря и течений в общем случае используется трехмерная гидродинамическая бароклинная модель со свободной поверхностью. Исходная система уравнений в декартовой системе координат в приближении гидростатики и плоскости записывается в виде:

$$\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} + \frac{\partial w}{\partial z} = 0, \quad (2)$$

$$\frac{\partial u}{\partial t} + \frac{\partial}{\partial x}(uu) + \frac{\partial}{\partial y}(vu) + \frac{\partial}{\partial z}(wu) - fv = \quad (3)$$

$$= -\frac{1}{\rho} \frac{\partial p}{\partial x} \left(+ N_h \frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} \right) + \frac{\partial}{\partial z} N_z \frac{\partial u}{\partial z} ,$$

$$\frac{\partial v}{\partial t} + \frac{\partial}{\partial x}(uv) + \frac{\partial}{\partial y}(vv) + \frac{\partial}{\partial z}(wv) + fu = \quad (4)$$

$$= -\frac{1}{\rho} \frac{\partial p}{\partial y} \left(+ N_h \frac{\partial^2 v}{\partial x^2} + \frac{\partial^2 v}{\partial y^2} \right) + \frac{\partial}{\partial z} N_z \frac{\partial v}{\partial z} ,$$

$$\frac{\partial p}{\partial z} = \rho g, \quad (5)$$

$$\frac{\partial T}{\partial t} + \frac{\partial}{\partial x}(uT) + \frac{\partial}{\partial y}(vT) + \frac{\partial}{\partial z}(wT) \left(= \frac{\partial}{\partial z} K_z \frac{\partial T}{\partial z} \right) , \quad (6)$$

$$\frac{\partial S}{\partial t} + \frac{\partial}{\partial x}(uS) + \frac{\partial}{\partial y}(vS) + \frac{\partial}{\partial z}(wS) \left(= \frac{\partial}{\partial z} K_z \frac{\partial S}{\partial z} \right) , \quad (7)$$

$$\rho = \Psi(T, S, p). \quad (8)$$

Здесь f – параметр Кориолиса; p – давление; ρ – плотность; T – температура, S – соленость, u, v, w – составляющие поля скорости течений по осям (x, y, z) , N_z, N_h – коэффициенты вертикальной и горизонтальной вязкости; K_z – коэффициент вертикальной диффузии. Для приливных морей в правой части (3)–(4), (6)–(7) дополнительно учитывается приливная составляющая. Уравнения (1)–(8) интегрируются совместно.

Расчет статистических характеристик, идентификация системы стохастических моделей и оценивание экстремальных характеристик. Статистическая обработка информационной базы гидрометеорологических характеристик выполняется средствами многомерного статистического анализа (МСА) пространственно-временных полей. Технологии МСА позволяют идентифицировать систему стохастических моделей гидрометеорологических полей. Она предназначена для того, чтобы методом Монте-Карло воспроизвести ансамбль реализаций заданного объема, 05(о)18.1998(м)-5.38437(e01)

разных классов. Для воспроизведения океанографических полей в мелко-масштабном (секунды-часы) диапазоне изменчивости применена модель в форме динамической системы с учетом управляющих факторов $\eta(\vec{v})$:

$$\zeta_{\vec{v}} = \sum_{\vec{j}=\vec{0}}^{\vec{N}} \Phi_{\vec{j}} \zeta_{\vec{v}-\vec{j}} + \sum_{\vec{k}=\vec{0}}^{\vec{p}} \Theta_{\vec{k}} \varepsilon_{\vec{v}-\vec{k}} + \sum_{\vec{i}=1}^{\vec{M}} \Xi_{\vec{i}} \eta_{\vec{v}-\vec{i}}. \quad (9)$$

Здесь $\Phi_{\vec{j}}$, $\Theta_{\vec{j}}$ — матричные коэффициенты авторегрессии и скользящего среднего. Зависимость между η и ζ задается значениями весовой функции (функции отклика) $\Xi_{\vec{i}}$.

Для воспроизведения синоптической изменчивости (перемежаемости штормов и окон погоды) использовано импульсное представление пространственно-временного поля в форме:

$$\zeta(\vec{r}, t) = \sum_j a_j W_j(t, \vec{r}) = \sum_j a_j W_j^{(k)}(\vec{r}, \Xi_j), \quad \Xi_j = \Xi_j(t), \quad (10)$$

где $W_j^{(k)}(\bullet)$ — пространственно-временные (временные) импульсы (выбросы выше и ниже уровня Z), движущиеся вдоль определенной траектории $\vec{r} = \vec{r}(t)$, возникающие и исчезающие случайным образом. Коэффициенты a_k суть интенсивности импульсов. Форма импульса, управляемая параметром k , определяется задачей исследования; для описания экстремальных явлений допустимо аппроксимировать $W_j(\bullet)$ по t треугольным импульсом.

Описание сезонной и межгодовой изменчивости требует применения другого класса моделей на основе ортогональных разложений по каноническому базису (естественные ортогональные функции):

$$\zeta(\vec{r}, t) = m(\vec{r}, t) + \sum_{k=1}^s a_k(t) \phi_k(\vec{r}, t) + \varepsilon(\vec{r}, t). \quad (11)$$

Скалярные коэффициенты разложения $a_k = a_k(t)$ суть общие факторы, управляющие изменчивостью основных конфигураций поля, а ε — специфический фактор, характеризующий случайные вариации значений поля в каждой точке \vec{r} в момент времени t . Модель (11) обобщается для описания регрессионной взаимосвязи исходного поля $\zeta(\vec{r}, t)$ с несколькими управляющими факторами — в форме линейной динамической системы (9) относительно коэффициентов их разложения по каноническим базисам. Применение комплекса стохастических моделей (9)–(11) лежит в основе

метода оценивания экстремальных явлений BOLIVAR, позволяющего получить оценки сочетаний гидрометеорологических характеристик, возможных 1 раз в T лет.

В работе [33] приведены примеры типизации частотных и частотно-направленных спектров волнения на основе предложенной процедуры классификации, основанной на методах многомерного статистического анализа. На рис. 3 приведен пример классификации частотно-направленных спектров для Баренцева моря.




Рис. 3. Типовые нормированные спектры морского волнения

Здесь выделено 6 классов морского волнения: А — зыбь; В — ветровое волнение; С — смешанное волнение с разделением систем и преобладанием зыби; D — смешанное волнение с разделением систем и преобладанием ветрового волнения; E — смешанное волнение без разделения систем с преобладанием зыби; F — смешанное волнение без разделения систем с преобладанием ветрового волнения. Градуировка на графиках спектральной плотности $S(\omega)/S_{max}$ по вертикальной оси; ω, c^{-1} по горизонтальной

оси.

Пространственная картина некоторых конфигураций климатических спектров приведена на рис. 4 в виде сложной динамической структуры.

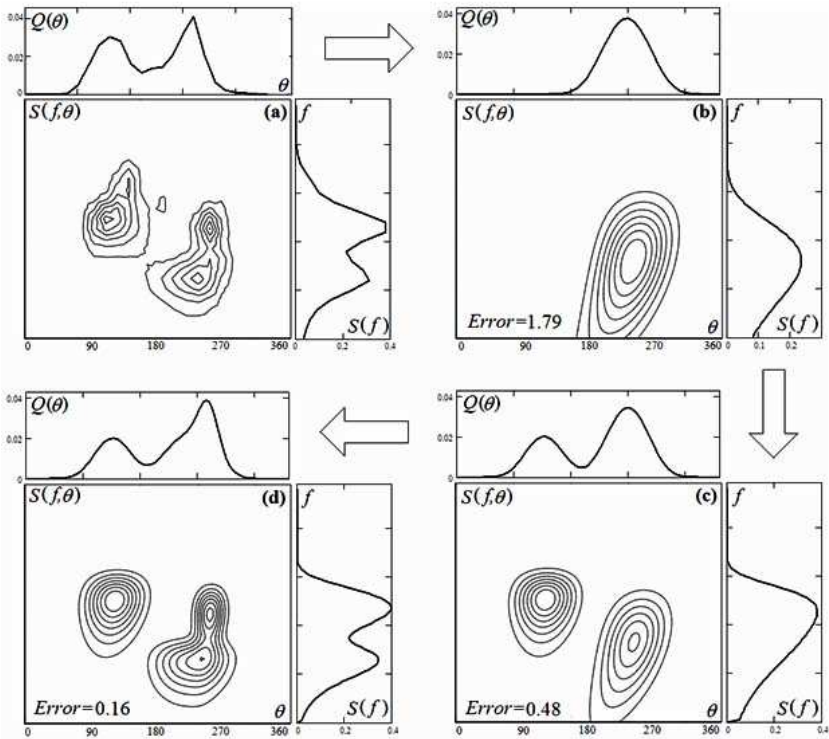


Рис. 4. Пример многопикового направленного волнового спектра: начальный пример и последовательные шаги метода

Следует отметить, что стандартные расчеты, выполняемые при оценке динамики сложных объектов на реальном морском волнении без учета понятия о климатическом спектре могут приводить к существенному отличию результатов и нередким ошибкам в опасную сторону по сравнению с данными, полученными при использовании различных модификаций однопикового спектра, принятого в практике проектирования морских сооружений. Поэтому при разработке бортовых ИС, предназначенных для кон-

троля поведения ДО под воздействием реальных динамических нагрузок в экстремальных ситуациях, игнорирование представления о климатическом спектре недопустимо, поскольку ошибки в опасную сторону могут привести к катастрофическим последствиям. Анализ климатических спектров морского волнения с использованием нейросетевых технологий открывает большие возможности реализации алгоритмов обработки информации о динамике внешней среды при функционировании бортовых ИС в режиме реального времени [26].

Исходные данные о текущей ситуации при функционировании ИС получают путем обработки информации, получаемой от датчиков измерительного комплекса (рис. 1). Обработка этой информации реализуется в режиме реального времени и позволяет «настроить» ИС на решение задач интерпретации текущей ситуации. Алгоритмы анализа и прогноза ситуации базируются на изобретениях автора, позволяющих восстанавливать текущие характеристики волнения и параметры ДО (метацентрическую высоту и аппликату центра тяжести), а также построить фактические значения функций принадлежности, определяющие логику функционирования динамической базы знаний (оценку опасности ситуации и прогноз ее развития) на основе фактических данных о состоянии внешней среды и ДО. В этих приложениях находит широкое применение принцип конкуренции, определяющий парадигму обработки информации в мультипроцессорной вычислительной среде с использованием методов классической математики и нейросетевых технологий.

Моделирование динамики объекта как нелинейной диссипативной системы

Динамика нелинейных систем — одна из быстро развивающихся областей практических приложений методов и моделей в задачах управления и принятия решений. Математические модели, характеризующие нелинейную динамику, обладают специфическими свойствами — единой структурой и общим признаком нелинейности. Слабая нелинейность — уже давно завоеванный наукой рубеж. Здесь существуют общие методы решения и разработаны эффективные алгоритмы для практических приложений. Методы решения задач с более сильными проявлениями нелинейности основаны на сложных математических построениях и использовании современных вычислительных средств [9]. Анализ нелинейностей позволяет вскрыть осо-

бенности задачи, где заложены возможности нетривиальных решений, и построить общую теорию, описывающую поведение нелинейных систем. Наличие колебательных режимов большой амплитуды включает в действие новую физическую связь, «дремавшую» в случае слабых возмущений. Не случайно эта проблема занимает сейчас умы многих исследователей в различных сферах научной деятельности, в том числе и при решении проблем динамики корабля и посадки летательных аппаратов морского базирования [9, 29].

Нелинейные модели динамики объекта на волнении характеризуются рядом особенностей. Учет этих особенностей приводит к необходимости поиска эффективных алгоритмов реализации модели взаимодействия [3, 8]:

- наличие неопределенности в описании внешних сил (ветро-волновые возмущения), из-за которой возникают трудности с формированием начальных условий задачи;
- необходимость учета сложной пространственной нелинейной функции, описывающей восстанавливающий момент на волнении, корректность определения которой связана с учетом интерференционной компоненты, методов расчета которой (вследствие чрезвычайной сложности нелинейной задачи гидродинамики) до настоящего времени не предложено;
- трудности математического описания некоторых задач остойчивости, формализация которых может быть достигнута только на основе гипотез и обобщающих предположений.

Указанные особенности определили новую парадигму, определяющую различные подходы к решению задач динамики объекта на волнении:

- детерминистический подход, при реализации которого динамика системы полностью определяется формулировкой начальных условий исследуемой математической модели;
- стохастический подход, при котором начальные условия задачи не определены, трудно формализуемы и не могут быть корректно сформулированы вследствие стохастичности исследуемого процесса взаимодействия.

При решении задач первого направления формулировка модели взаимодействия основывается на достаточно простых расчетных схемах ветро-волновых возмущений. В частности, воздействие ветра представляется в виде отработанных расчетных схем, которые нашли применение в практике

нормирования, а волнение аппроксимируется гармоническими функциями, либо в виде трохойды [8, 22]. При исследовании стохастических систем наиболее эффективный путь состоит в формулировке начальных условий «на другом конце» задачи и интегрировании системы дифференциальных уравнений в обратном времени с использованием метода функционала действия [9, 13].

Рассмотрим морской ДО как динамическую систему с шестью степенями свободы. Поведение ДО можно описать системой нелинейных дифференциальных уравнений [13, 22]:

$$F_i[\ddot{x}_i, \dot{x}_i, x_i, t, X_{i1}, \dots, X_{im}, Y_{i1}, \dots, Y_{in}] = 0, \quad (12)$$

где $F_i(\bullet)$ — нелинейные функции; x_i — линейные и угловые перемещения; X_{i1}, \dots, X_{im} — параметры, характеризующие судно как динамическую систему (инерционные, демпфирующие и восстанавливающие компоненты); Y_{i1}, \dots, Y_{in} — возмущающие силы и моменты; $i = 1, 2, \dots, 6$.

Реализация системы (12) на современных быстродействующих компьютерах не представляет принципиальных затруднений. Однако в практических задачах динамики принято рассматривать вполне определенные положения ДО на волнении (носом на волну, лагом к волне, на попутном волнении). Учитывая симметрию корпуса относительно диаметральной плоскости, а также незначительную асимметрию относительно миделя, можно упростить исходную систему (12), иногда использовать и отдельные уравнения, пригодные в каждом конкретном случае ориентации ДО относительно генерального направления бега волн.

Наиболее сложной функцией в системе (12) является восстанавливающая компонента, входящая в дифференциальное уравнение бортовой качки. Восстанавливающая компонента отличается существенной нелинейностью, сложностью и многозначностью. Непрерывно изменяясь во времени и пространстве, эта функция в значительной степени определяет результат интегрирования системы (12) при изучении физических картин взаимодействия ДО с внешней средой. Математическое описание нелинейной пространственной функции восстанавливающего момента на волнении основано на обработки систематических испытаний моделей различных типов судов и представляется формулой [22].

$$M_W = M(\theta, \varphi, t) = D[l(\theta, \varphi) + \Delta l(\theta, \varphi) \cos(\sigma_k t - \varepsilon)]; \quad (13)$$

$$l(\theta, \varphi) = 0,5[l(\theta, \varphi)_{\max} + l(\theta, \varphi)_{\min}],$$

$$\Delta l(\theta, \varphi) = 0,5[\Delta l(\theta, \varphi)_{\max} + \Delta l(\theta, \varphi)_{\min}];$$

$$M_W = \varphi(\theta, \varphi_k, t) = Dl(\theta, \varphi, t),$$

где $\Delta l(\theta, \varphi)_{\max}$ и $\Delta l(\theta, \varphi)_{\min}$ — экстремальные значения приращений плеч остойчивости, соответствующие положению судна на подошве и вершине волны при различных курсовых углах φ ; $l(\theta, \varphi, t)$ — плечо восстанавливающего момента, определяемого для различных моментов времени, ε — фаза: $\varepsilon = 0$ и 2π — ДО на подошве волны; $\varepsilon = \pi/2$ — на переднем склоне; $\varepsilon = \pi$ — на вершине волны; $\varepsilon = 3/2\pi$ — на заднем склоне.

Типичными математическими моделями, используемыми при разработке динамической модели знаний в бортовых ИС реального времени, являются [8, 13, 30]:

- Математическая модель, описывающая поведение ДО в экстремальных ситуациях с помощью системы дифференциальных уравнений бортовой, вертикальной и килевой качки:

$$\begin{aligned} (J_x + \mu_{\theta\theta})\theta'' + M_R(\theta') + M(\theta, \varphi_k, t) &= M_x(t); \\ (D/g + \mu_{33})\zeta_G'' + v_\zeta \zeta_G' + \varrho g S \zeta_G + \mu_{33} x_1 \psi'' + (v_{\zeta\psi} - v_0 \mu_{33})\psi' + \\ + (\varrho g S l - v_0 v_\zeta)\psi &= -r_0(\varrho g a_0 - \sigma^2 a_0'' - \sigma b_0') \cos \sigma t - \\ - r_0(\varrho g b_0 - \sigma^2 b_0'' + \sigma a_0') \sin \sigma t; \\ (J_y + \mu_{55})\psi'' + [v_\zeta + (v_0^2/\sigma^2)v_\zeta]\psi'' + (DH\psi - v_0^2 \mu_{33})\psi + \\ + \mu_{33} x_1 \zeta_G'' + (v_{\zeta\psi} + v_0 \mu_{33})\zeta_G' + (\varrho g S l + v_0 v_\zeta)\zeta_G &= \\ = -r_0(\varrho g a_1 - \sigma^2 a_1'' - \sigma b_1') \cos \sigma t - \\ - r_0(\varrho g b_1 - \sigma^2 b_1'' + \sigma a_1') \sin \sigma t, \end{aligned} \tag{14}$$

где $(J_x + \mu_{\theta\theta})\theta''$, $M_R(\theta')$, $M(\theta, \varphi_k, t)$, $M_x(t)$ — инерционная, демпфирующая, восстанавливающая и возмущающая компоненты; остальные обозначения соответствуют принятым в работах [8, 13, 30].

- Математическая модель, описывающая поведение ДО в условиях потери управляемости и внезапного разворота на попутном волнении (режим «бронинг») с помощью системы дифференциальных уравнений продольно-горизонтальной, поперечно-горизонтальной, борто-

вой качки и рыскания судна на волнении [22, 43]:

$$\begin{aligned}
 & [(D/g) + \mu_{\xi\xi}] (\dot{v} \cos \beta^* - \beta^* v \sin \beta^*) + \\
 & + [(D/g) + \mu_{\eta\eta}] v \dot{\chi} \sin \beta^* = \\
 & = F_x = X(t) + P_e - R \\
 & [(D/g) + \mu_{\eta\eta}] (\dot{v} \sin \beta^* - \beta^* v \cos \beta^*) + \\
 & + [(D/g) + \mu_{\xi\xi}] v \dot{\chi} \cos \beta^* = \\
 & = F_y = Y(t) + R_{yB} + R_{y\#}(t) + v_{44644647(+)} 544117004(\cdot) \Omega 11169738
 \end{aligned}$$

Нейроаппроксимация и нейропрогноз при контроле экстремальных ситуаций в сложных динамических средах

Исследования и разработки в области ИИ позволяют рассматривать бортовую ИС как сложную, целостную открытую систему, представляющую собой совокупность динамических структур, согласованно выполняющих функции, обеспечивающие целенаправленное поведение системы в различных условиях эксплуатации. Одной из центральных задач анализа и обобщения результатов исследований является построение интегрированных ИС, использующих методы и модели нечеткого и нейросетевого логического базиса. Это позволяет более гибко и адекватно описывать феномен поведения судна как сложного ДО в условиях неопределенности и неполноты исходной информации.

Нейроаппроксимация в задачах контроля динамики сложного объекта

Рассмотрим задачу структурного и параметрического синтеза нейронных сетей для конкретных приложений в бортовых ИС. Процедуры конструирования связаны с решением задач, позволяющих определить топологию сети (общее число нейронов в сети и число нейронов по слоям) и функции активации, способы задания коэффициентов синоптических связей и оценки работоспособности сформированных нейросетевых моделей. Исходной информацией при конструировании нейронной сети являются векторы входного и выходного сигналов, формулировка задачи и точности ее решения.

Основным этапом нейросетевого моделирования является постановка и решение задачи аппроксимации на основе нейросетевого логического базиса [12, 32] в рамках которого осуществляются:

- описание исходных данных и желаемого выходного сигнала, определение вектора сигнала ошибки, формирование функционала оптимизации через сигналы в системе и выбор метода поиска экстремума этого функционала;
- аналитическое определение преобразования информации в нейронной сети и выбор конкретной ее структуры, нахождение аналитического выражения для градиента функционала оптимизации поставленной задачи и выбор начальных условий при настройке сети;

- выбор типовых входных сигналов для тестирования процесса решения задачи и разработка плана эксперимента.

Обобщенная схема, характеризующая этапы разработки ИНС представлена на рис. 5.

При проектировании ИНС возникает задача выбора оптимальной структуры сети. Под оптимальной структурой понимается такая топология сети (числа скрытых слоев и нейронов в слоях), при которой обеспечивается максимум ее обобщающих способностей, т. е. минимум ошибки обобщения (generalization error). Это особенно важно в случае недостаточной исходной информации, особенно отсутствия независимой тестовой выборки экспериментальных данных.

При решении задачи структурного и параметрического синтеза широко используется парадигма «кривых обучения» (learning curves), представляющих собой зависимости ошибок обучения и обобщения от размеров ИНС и обучающей выборки. Оптимуму размера сети соответствуют локальные минимумы или моменты выхода графиков на асимптоты.

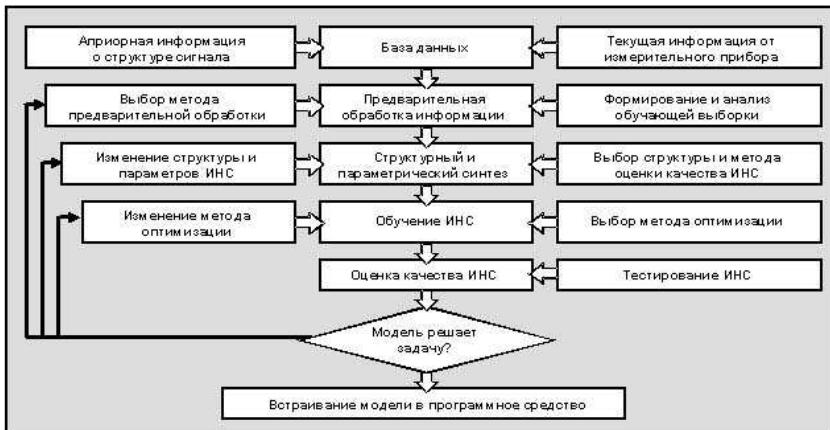


Рис. 5. Поток информации при формировании и обучении нейронной сети

Другим классом кривых обучения являются зависимости «внутренних» свойств нейросети от ее размера, сопоставляемые затем с динамикой ошибки обобщения. Вариантами этого класса являются:

- анализ внутреннего представления (internal representation) задачи,
- теоретическая связь ошибки обучения и максимума суммы модулей весов синапсов, приходящих на нейрон сети,
- критерий, позволяющий оценить разницу между ошибками обучения и обобщения.

Указанные критерии во многих случаях позволяют обходиться без независимой тестовой выборки.

Таким образом, алгоритм обучения нейронной сети представляется последовательностью взаимозависимых этапов. Каждый этап состоит из совокупности выполняемых параллельно независимых операций.

Вычисление выходов нейронов на основе обучающего примера имеет вид [12, 32]:

- для скрытого слоя

$$y_j^{(1)}(t) = \varphi \left(\sum_{l=1}^i w_{lj}^{(1)}(t)x_l(t) + b_j^{(1)} \right); \quad (17)$$

- для выходного слоя

$$y_j^{(2)}(t) = \varphi \left(\sum_{l=1}^i w_{lj}^{(2)}(t)y_l^{(1)}(t) + b_k^{(1)} \right), \quad (18)$$

где $w_{ij}^{(1)}$ — синаптический вес связи i -го входа с j -м нейроном; $X = [x_1, \dots, x_i]$ — вектор входных сигналов; $b_j^{(1)}$ — порог j -го нейрона скрытого слоя; $w_{jk}^{(2)}$ — синаптический вес связи j -го выхода нейрона скрытого слоя с k -м нейроном выходного слоя; $b_k^{(2)}$ — порог k -го нейрона выходного слоя; $\varphi(\bullet)$ — функция активации нейрона.

При реализации параллельных вычислений на многопроцессорном бортовом вычислительном комплексе эти соотношения можно представить в матричном виде как умножение матрицы весовых коэффициентов $W^{(1)}$ скрытого слоя на вектор входа X матрицы весовых коэффициентов $W^{(2)}$ выходного слоя на вектор $Y^{(1)}$ (выход скрытого слоя) [2]:

$$Y^{(1)} = \varphi(W^{(1)T}X + B^{(1)}) =$$

$$= \varphi \left(\begin{bmatrix} w_{11}^{(1)} & w_{21}^{(1)} & \dots & w_{i1}^{(1)} \\ w_{12}^{(1)} & w_{22}^{(1)} & \dots & w_{i2}^{(1)} \\ \dots & \dots & \dots & \dots \\ w_{1j}^{(1)} & w_{2j}^{(1)} & \dots & w_{ij}^{(1)} \end{bmatrix} \times \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_i \end{bmatrix} + \begin{bmatrix} b_1^{(1)} \\ b_2^{(1)} \\ \dots \\ b_j^{(1)} \end{bmatrix} \right) \quad (19)$$

$$Y^{(2)} = \varphi(W^{(2)T}Y^{(1)} + B^{(2)}) = \varphi \left(\begin{bmatrix} w_{11}^{(2)} & w_{21}^{(2)} & \dots & w_{i1}^{(2)} \\ w_{12}^{(2)} & w_{22}^{(2)} & \dots & w_{i2}^{(2)} \\ \dots & \dots & \dots & \dots \\ w_{1k}^{(2)} & w_{2k}^{(2)} & \dots & w_{ik}^{(2)} \end{bmatrix} \times \begin{bmatrix} y_1^{(1)} \\ y_2^{(1)} \\ \dots \\ y_j^{(1)} \end{bmatrix} + \begin{bmatrix} b_1^{(2)} \\ b_2^{(2)} \\ \dots \\ b_k^{(2)} \end{bmatrix} \right) \quad (20)$$

Ошибка реакции сети вычисляется по формулам:

- для выходного слоя

$$\delta_k^{(2)}(t) = e_k(t); \quad (21)$$

- для скрытого слоя

$$\delta_j^{(1)}(t) = \sum_{l=1}^k \delta_l^{(2)} w_{lj}^{(2)}(t) y_j^{(1)}(t). \quad (22)$$

Для всех слоев сети настройка весовых коэффициентов осуществляется в соответствии с формулой:

$$w_{ij}^{(L)}(t+1) = \alpha w_{ij}^{(L)}(t) + \eta \delta_j^{(L)}(t) y_j^{(L)}(t), \quad (23)$$

где α — постоянная момента; η — параметр скорости обучения; $\delta_j^{(L)}$ — локальный градиент j -го нейрона; L — количество слоев.

Этот общий алгоритм параллельной обработки информации может быть использован при обучении многослойного персептрона в составе интегрированной нейронной сети анализа и интерпретации экстремальных ситуаций, а также для универсального алгоритма обучения, реализуемого с использованием методов регуляризации.

Структура нейросетевого ансамбля для построения классификатора эталонных моделей климатических спектров морского волнения представлена на рис. 6. Ансамбль состоит из группы RBF сетей, воспринимающих информацию от измерительной системы. Каждая сеть имеет m входов, на

которые подается вектор измерений X_1, \dots, X_m (вектор состояния) и два параметра на выходе (1 — нормальное состояние, 0 — отказ). Если на выходе сети обнаружен отказ, то это свидетельствует о том, что поданный на нейросетевой ансамбль сигнал не соответствует ни одному из принятых эталонов. В этом случае необходимо перейти к более сложной структуре нейросетевого ансамбля, представляющего собой интегрированный нейросетевой комплекс.




Рис. 6. Нейросетевой ансамбль, реализующий модели климатических спектров морского волнения

Обработка задачи идентификации при построении ансамбля нейронных сетей осуществлялась в процессе решения задачи нейросетевого моделирования. При этом учитывались особенности типичных задач обработки информации при построении климатических спектров морского волнения, которые нашли применение в традиционных алгоритмах спектрального преобразования в приспособленном базисе. Исследование проводилось с использованием данных практических наблюдений, приведенных в работе [33]. Для решения задачи были применены нейронные сети прямого распространения, обучаемые с помощью алгоритма обратного распространения ошибки. На вход нейронной сети подавались 64 значения частотного

спектра (в кв.м·с), соответствующие частотам, начиная с 1/128 Гц до 1/2 Гц (т. е. с шагом 1/128 Гц).

Одна из типичных архитектур исследуемых нейронных сетей представлена на рис. 7.




Рис. 7. Многослойная нейронная сеть, используемая при обработке задачи классификации

Нейронная сеть содержала по 6 выходных нейронов, каждый из которых соответствовал определенному классу климатического спектра. Номер выходного нейрона с максимальным значением выхода показывает номер климатического спектра. Количество нейронов в скрытом слое изменялось в диапазоне от 10 до 100 нейронов.

Обучение производилось до достижения ошибки в 0.0001 на обучающем множестве, но не более 5000 эпох. Всего было обучено 2000 сетей, из которых были отобраны 15 сетей, дающих минимальную ошибку на проверяющей выборке. Графики процесса обучения показаны на рис. 8.

Так как значения выходов нейронных сетей используются в качестве вероятности принадлежности данного спектра к одному из шести классов, было проведено дополнительное испытание нейронных сетей, для выявления качества идентификации класса спектра. Для этого каждой из отобранных нейронных сетей были предъявлены все спектры волнения. Полученные данные использованы при построении процедуры идентификации параметров волнения в задаче анализа и прогноза поведения ДО при




Рис. 8. Кривые процесса обучения нейронных сетей

различном уровне внешних возмущений (рис. 9).

Результаты идентификации позволяют разрабатывать сценарии волновой погоды при оценке безопасности эксплуатации ДО в заданном районе мирового океана. При построении сценариев используются различные формы представления информации о климатических спектрах морского волнения. Одна из наиболее распространенных форм представления — изолинии, характеризующие модуль погоды, сформированный в бортовой ИС анализа и прогноза динамики ветроволновых возмущений [33].

Структура интегрированного нейросетевого комплекса обрабатывалась в процессе моделирования задач идентификации экстремальных ситуаций. На рис. 10 представлена модель такой сети, базирующаяся на нейронном ансамбле: «радиально-базисная сеть–персептрон–сеть Кохонена» [26]. Разработанная архитектура особенно перспективна в задачах обработки сложных сигналов большой размерности и обеспечивает разложение исследуемых параметров на отдельные составляющие с общей параметрической «привязкой». Эффективное решение общей задачи преобразования информации достигается за счет разделения функций нейросетевого ансамбля. Причем, первый входной слой представлен набором RBF-сетей, обеспечивающих фильтрацию данных, второй промежуточный слой — персептрон, выполняющий функцию концентратора, и наконец, выходной слой — самоорганизующаяся сеть Кохонена, реализующий задачу классификации

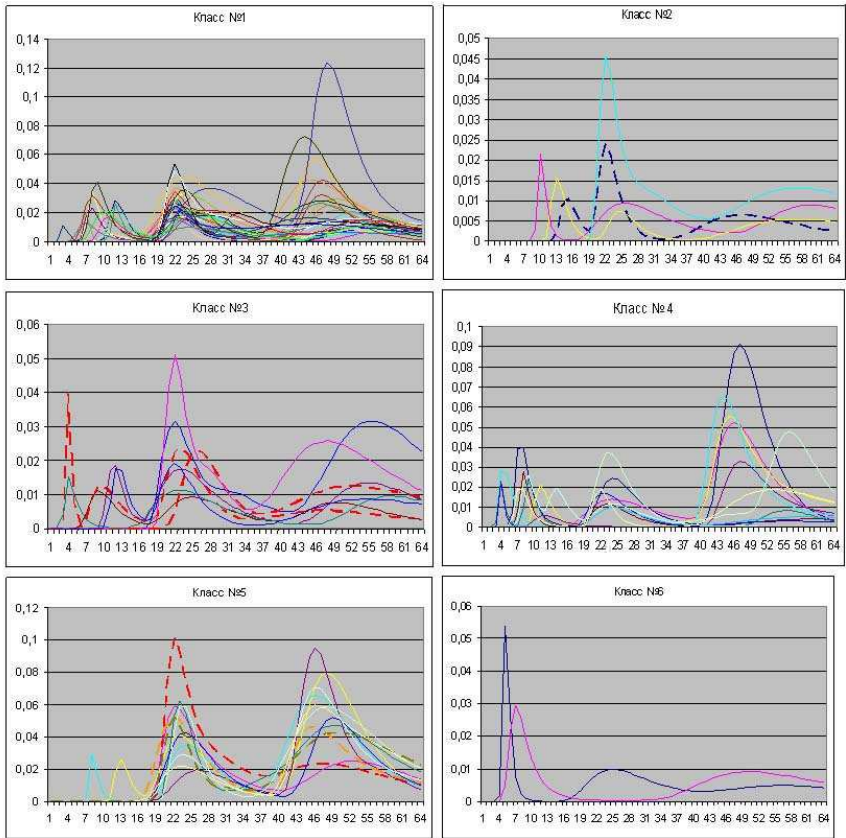


Рис. 9. Результаты идентификации

данных [11].

Архитектура RBF-сети в рамках интегрированного комплекса сохраняется такой же, как и в нейросетевом ансамбле. Персептрон в представленном на рис. 10 нейросетевом комплексе объединяет входы сети с двумя последующими выходами в каждой из RBF-сетей. Поле контрастирования содержит архитектуру, состоящую из ряда входов персептрона, первого входного слоя из m нейронов, второго скрытого слоя из n нейронов, третьего скрытого слоя из r нейронов, четвертого скрытого слоя из 4 нейронов




Рис. 10. Структура интегрированного нейросетевого комплекса, реализующего оператор преобразования сложных сигналов при контроле экстремальных ситуаций

и пятого выходного слоя, состоящего из 2 нейронов. Перцептрон усиливает качество распознавания, «уточняя» весовые коэффициенты [26, 32].

Приведем уравнения, обеспечивающие работу перцептрона для различных слоев сети:

- для входного слоя ($k = 1$) $U^1 = X$ (входной вектор);
- для первого скрытого слоя ($k = 1$)

$$U_j^2 = f \left(\begin{matrix} n_2 \\ w_{ij}^1 U_i^1 \end{matrix} \right), \quad i, j = 1, \dots, n_2; \quad (24)$$

- для пятого выходного слоя ($k = 5$)

$$Y_i = U_i^q = f \left(\begin{matrix} n_q \\ w_{ij}^q U_j^q \end{matrix} \right), \quad i, j = 1, \dots, n_q. \quad (25)$$

Результаты нейросетевого моделирования показали, что перцептрон обеспечивает высокую степень распознавания предъявленных информационных образов в виде результатов измерений для сложных сигналов, харак-

терных при анализе и интерпретации экстремальных ситуаций в бортовых ИС.

Нейропрогноз поведения сложного объекта в бортовых ИС

В процессе анализа динамики взаимодействия судна с внешней средой возникают ситуации, требующие предварительного анализа сигнала, порождаемого системой и представленного заданной временной последовательностью. Эта последовательность несет в себе достаточно представительную информацию о рассматриваемой динамической системе. В соответствии с *теоремой Такенса* [48] можно по эволюции переменной составить общее представление о динамике системы путем реконструкции *аттрактора*. Восстановление аттрактора динамической системы на основе зависимости $x = x(t)$ осуществляется за счет использования метода временной задержки координат. Для этого временной ряд отображается на плоскость в виде множества точек таким образом, чтобы каждому исходному значению $x(t_i)$ соответствовала точка на плоскости, одна из координат которой будет равна $x(t_i)$, а другая — $x(t_i + \tau)$, где τ — величина, называемая *лагом*. Временной ряд можно отобразить в трехмерном пространстве. В этом случае координаты точки по одной оси будут равны $x(t_i)$, по другой — $x(t_i + \tau)$, а по третьей — $x(t_i + 2\tau)$. Таким образом, при отображении исходной последовательности в *пространство размерности* каждая точка $x(t_i)$ будет отображаться в точку этого пространства с координатами:

$$\{x(t_i), x(t_i + \tau), \dots, x(t_i + (n - 1)\tau)\} \quad (26)$$

Согласно теореме Такенса [48], можно подобрать такие параметры реконструкции n и τ , в результате чего множество точек по своим метрическим свойствам будет воспроизводить аттрактор исследуемой системы. Пространство, задаваемое для восстановления исходного аттрактора, называется *пространством вложения* (пространством лага), а множество точек, моделирующее исходной аттрактор — *восстановленным аттрактором*. Такое построение позволяет связать с анализируемым рядом определенной наглядный образ (ситуацию) в пространстве размерности m . Рассматривая реконструированный аттрактор при определенном значении m ($m = 2, m = 3$) можно интерпретировать этот образ как проекцию *фазового пространства* системы в *реконструированное пространство* размерности m . В большинстве случаев, связанных с поведением ДО в сложных

условиях генерируемый динамической системой сигнал имеет невысокую размерность фазового пространства, и наблюдаемая картина имеет характерно выраженную структуру.

Для построения отображений на аттракторе исследуемой системы наряду с методами классической математики используются нейросетевые технологии. Проверка эффективности реконструированных моделей осуществляется с помощью временных рядов, генерируемых датчиками измерительной информации по данным натуральных испытаний. Проблемы, возникающие при практическом применении реконструкции аттрактора связаны с ограниченностью временного ряда, хранением и скоростью обработки информации, а также со стационарностью исследуемого объекта [7, 16, 20].

Развитие учения о нелинейной динамике позволяет рассматривать процессы по наблюдаемым измерениям в виде свойств и траекторий восстановленного аттрактора системы (как функцию ее состояния), породившей данный процесс [7, 16]. В рамках этого подхода задача прогнозирования интерпретируется как поиск отображения окрестности текущей точки восстановленного аттрактора на координаты точки в рассматриваемый момент времени. Последовательность обработки информации при прогнозировании сложных ситуаций в бортовых ИС состоит в решении двух важных задач. Первая из них связана с выявлением «скрытых» знаний и анализом структуры измерений с помощью теоремы Такенса. Вторая представляет собой анализ альтернативных решений, построенных на основе стандартных алгоритмов и ИНС. Построение алгоритма выбора предпочтительного решения в рамках принципа конкуренции ведется на основе информации, поступающей от датчиков измерительной системы. Эта информация предварительно обрабатывается и представляет собой реконструированный на основе теоремы Такенса временной ряд с учетом исследования показателя Ляпунова при анализе структуры измерений.

Согласно теореме Такенса фазовый портрет, восстановленный в виде:

$$Z(t) = \Lambda(y(t)) = (y(t), y(t - \tau), \dots, y(t - (m - 1)\tau)) = (z_1(t), \dots, z_m(t)) \quad (27)$$

топологически эквивалентен аттрактору исходной динамической системы.

Параметр задержки τ определяется временем пересечения траекториями системы сечения Пуанкаре. Таким образом, для реконструкции аттрактора неизвестной динамической системы по заданному временному ряду необходимо определить параметры реконструкции m и τ . Методы оценки этих параметров описаны в работах [3, 14].

На основе данных о параметрах $x_{1t}, \dots, x_{t_n t}$ проводится анализ ситуации и строятся алгоритмы обработки измерительной информации, наилучшим образом отображающие тенденции в изменении компонент информационного вектора. В процессе обработки информации выделяются нестандартные (нештатные и экстремальные) ситуации, осуществляется оценка и прогноз из развития на основе конкурирующих вычислительных технологий [24] в рамках концепции мягких вычислений [50]. Для улучшения качества используемой информации при интерпретации последовательностей сигналов использованы методы их обработки на основе теоремы Такенса [48].

Алгоритм восстановления аттрактора и нелинейного прогноза может быть представлен в виде следующих этапов [20]:

Этап 1. Реконструкция топологической модели динамической системы, продуцирующей временной ряд. Такая модель представляет собой вложение ряда в R_m , натянутое на m -мерные векторы, составленные из отсчетов временного ряда, взятых с постоянным дискретным шагом (лагом). Условие $m \geq 2d + 1$ гарантирует, что полученная реконструкция будет копией истинного d -мерного аттрактора системы. Реконструкция приводит к однородной схеме нелинейного авторегрессионного прогноза

$$x_{i+1} = F(x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}). \quad (28)$$

Этап 2. Аппроксимация функции F , реализуемой с помощью нейронной сети. Решающую роль в таком подходе играет правильный выбор параметров вложения ряда — размерности и лага.

Стандартная процедура Ф. Такенса [48] (равномерное вложение) достаточно хорошо восстанавливает топологию аттрактора систем, имеющих один характерный масштаб времени. Однако исследуемая система характеризуется «быстрой» и «медленной» динамикой. В таком случае рассматривают два масштаба времени, поскольку лаг, выбранный по первому нулю автокорреляционной функции быстрой моды, не сможет контролировать независимость отсчетов в задачах многоциклической динамики. В работе [20] предложен вариант неоднородного вложения, адаптированный к таким задачам.

Выбор параметров реконструкции. Качество реконструкции зависит от выбора параметров m и τ . Для простейших случаев предложены способы выбора оптимальной размерности вложения и величины временной задержки τ [16]. Основная идея реконструкции состоит в том, что удовле-

творительная реконструкция не должна содержать самопересечений. Поэтому производят поиск так называемых «близких соседей», представляющих собой пары векторов, которые оказались близкими в реконструкции, но их прообразы находились далеко. При этом учитывается, что истинные ближайшие соседи остаются близкими при увеличении размерности реконструкции, а ложные — с ростом параметра отдаляются друг от друга. С увеличением m для достижения нужной размерности при правильной реконструкции количество ложных соседей уменьшается.

Для определения оптимального значения временного лага используют два подхода. Первый подход основан на идее о том, что если образующие вектор компоненты независимы друг от друга, то «реконструированные» вектора будут нести в себе «наибольшее количество информации» о системе. Простейший способ добиться такой «линейной» независимости — это выбор τ близкого к первому нулю автокорреляционной функции для исследуемого ряда. Во втором подходе, основанном на теории информации, используется первый минимум взаимной информации для $x(t)$ и $x(t + \tau)$. По временному ряду строятся гистограммы, аппроксимирующие распределения x_i и x_{i+1} , а также совместное распределение x_i и x_{i+1} . На основе гистограмм рассчитываются энтропии и взаимная информация:

$$S = - \sum_{i,j} P_{ij}(\tau) \log_2 P_{ij}(\tau) / P_i P_j, \quad (29)$$

где P_i — вероятность нахождения точки в i -м интервале, а $P_{ij}(\tau)$ — совместная вероятность попадания x_i в i -й интервал и x_{i+1} в j -й интервал.

В связи со сложностью задачи многорежимного управления [10, 34] при прогнозе динамики ДО рассматривают одношаговый и многошаговый нейропрогноз. *Одношаговый прогноз* осуществляется только на один шаг вперед и используется для краткосрочных прогнозов. Результатом прогноза является не только конкретное значение, но и класс, к которому принадлежит переменная (рис. 11). Формирование классов проводится в зависимости от целей прогнозирования. Общий подход состоит в том, что область прогнозируемой переменной разбивается на классы в соответствии с заданной точностью прогноза.

Многошаговый прогноз используется для реализации долгосрочного прогноза возникновения экстремальных ситуаций. Процесс построения прогнозирующей модели предусматривает предварительное определение количества используемых элементов временного ряда y и ошибок прогно-




Рис. 11. Нейронная сеть, реализующая одношаговый прогноз

зирования e . Эти операции завешаются схемой построения ИНС, включающей решение задач структурного и параметрического синтеза.

После выполнения процедур реконструкции временного ряда начинает работать программа нейросетевого моделирования. Применительно к задачам нейропрогноза эта программа позволяет проводить обучение трехслойной нейронной сети обратного распространения с любым количеством нейронов, в том числе нейронов выходного слоя. При инициализации ИНС в качестве параметров указывается число входных нейронов, число выходных нейронов и число нейронов скрытого слоя. При моделировании из общего набора исходных данных формируется обучающая выборка, размер которой зависит от количества нейронов входного слоя и количества нейронов выходного слоя. Эта обучающая выборка передается в функцию обучения нейронной сети TrainNetwork, в параметры которой также входят длина обучающей выборки и максимальная погрешность обучения.

В процессе обучения на первом шаге производится просмотр всей обучающей выборки на предмет нахождения входных данных, приводящих к наибольшей ошибке обучения. Затем обучение производится на основе этих входных данных: вычисляются чувствительность выходного и скры-

того слоев, обновляются веса и смещение выходного и скрытого слоев в соответствии с алгоритмом обратного распространения ошибки.

На рис. 12 представлен пример прогноза смешанной динамики. Обучающая выборка насчитывает 230 точек и выделена темным цветом. Результат прогноза насчитывает 45 точек и выделен светлым цветом. Количество входных нейронов равно 80, количество выходных — 15, скрытый слой содержит 150 нейронов. Нижний график иллюстрирует изменение ошибки обучения.




Рис. 12. Результаты нейропрогноза на 12-м (А) и 50-м (В) цикле обучения

Для улучшения визуального контроля над процессом обучения результаты прогноза выводятся пользователю после каждом цикле обучения, что позволяет быстро подобрать структуру нейронной сети: количество входных нейронов, количество выходных нейронов и количество нейронов скрытого слоя, а также определить размер обучающей выборки. Таймер, вызывающий процедуру обучения нейронной сети, осуществляет вывод

прогноза ИНС с текущими параметрами на экран. Для этого производится создание новой нейронной сети как копии обученной и вызов процедуры CalcOutput, в качестве параметров которой подаются значения нейронов входного слоя и переменная для хранения значений выходного слоя. Результат прогноза выводится на экран, а копия нейронной сети удаляется.

При контроле поведения сложных ситуаций в бортовых ИС используются нейронечеткие сети. Пример структуры такой сети, реализующей контроль динамики полетной палубы при посадке летательного аппарата (ЛА), приведен в работе [29]. Такая структура построена на основе широко распространенной архитектуры нейронечеткой системы ANFIS (рис. 13).

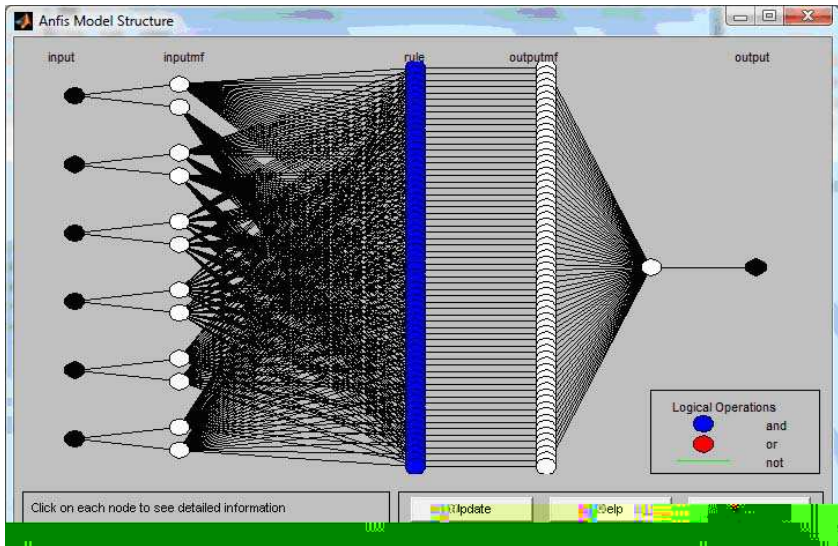


Рис. 13. Нейронечеткая модель, обеспечивающая прогнозирование поведение ДО на волнении при контроле посадки ЛА

Нелинейные эффекты и сценарии развития хаоса в диссипативных динамических средах

При разработке моделей нейроаппроксимации и нейропрогноза в бортовых ИС важное значение приобретает исследование физических закономер-

ностей процессов и явлений, отображающих результат взаимодействия ДО с внешней средой в различных условиях эксплуатации. Ниже продемонстрированы основные особенности поведения нелинейных диссипативных систем, установленные в процессе анализа и интерпретации информации, получаемой в результате функционирования встроенной процедуры, обеспечивающей моделирование экстремальных ситуаций на основе информации, получаемой с датчиков измерительной системы.

Динамический хаос в нелинейных диссипативных системах

Задачи анализа и интерпретации информации при функционировании ИС во многих случаях решаются на основе математических моделей, описываемых нелинейными дифференциальными уравнениями. В ранних работах по нелинейной динамике было принято рассматривать детерминированные (регулярные) и вероятностные (стохастические) процессы, описываемые соответствующими нелинейными дифференциальными уравнениями. Такая классификация основывалась на традиционном подходе классической механики. Однако в последующие годы было обнаружено, что в нелинейной детерминированной системе могут возникать хаотические движения, характеризующиеся тем, что первоначально близкие траектории в ограниченной области фазового пространства могут быстро расходиться. Это свойство нелинейных систем получило название детерминированного хаоса [47]. Нелинейная система может порождать различные виды колебаний: периодические и квазипериодические, субгармонические и хаотические.

В процессе развития динамики нелинейной системы формируются простые (обычные) и странные (стохастические) аттракторы. С простыми аттракторами мы часто встречаемся при анализе нелинейных диссипативных систем. Геометрическая интерпретация простого аттрактора диссипативной системы на фазовой плоскости представляет собой либо неподвижную точку (фокус), к которой устремляются фазовые траектории, либо предельный цикл, обладающий таким свойством, что все близкие фазовые траектории представляют собой спирали, неограниченно приближающиеся к замкнутой кривой в фазовом пространстве (рис. 14).

Типичный сценарий возникновения и развития режима интенсивной качки большой амплитуды можно наблюдать при исследовании параметрических колебаний. Закономерности этого режима качки связаны с особенностями пакета волн зыби, при воздействии которого формируется предельный цикл, характеризующийся стабилизацией амплитуды колебаний

вследствие влияния нелинейности (рис. 14А).




Рис. 14. Формирование предельного цикла при воздействии группы волн

Этот цикл возникает на участке, где последовательность резонансных волн в пакете превышает определенное значение $(h_w)_{CR}$, обеспечивающее колебательный режим с практически постоянной амплитудой θ_{max} . Однако в связи с последующим постепенным уменьшением высот волн в пакете нарушаются условия устойчивости и цикл исчезает (рис. 14В).

Более сложный сценарий — столкновение с неустойчивым циклом (см. рис. 15). Такая ситуация на практике встречается значительно реже и характеризуется последовательным прохождением пакетов волн, содержащих волны различной интенсивности. Например, первый пакет с небольшой высотой резонансных волн приводит к формированию предельного цикла малой, а второго — большой амплитуды. Возникновение и потеря устойчивости колебательного режима («рождение и смерть цикла» по терминологии А. А. Андропова [4]) происходят вследствие ограниченности зоны резонансной качки на сравнительно небольшом временном интервале интенсивных колебаний при прохождении волновых пакетов.

Интересно отметить, что развитие параметрических колебаний при формировании предельного цикла в большей степени проявляется для волновых систем, содержащих группы почти регулярных волн. В этом случае за счет большей глубины модуляции параметра, стоящего в качестве множителя при периодической функции уравнения Матье [31] и обусловленного резким изменением метacentрической высоты, формируются начальные условия, обеспечивающие преодоление «порога возбуждения» параметрического резонанса. В результате возникновение и развитие параметриче-




Рис. 15. Возникновение (A) и потеря устойчивости цикла (B), (C)

ских колебаний отмечается даже на волнах относительно меньшей крутизны.

Странные аттракторы отличает более сложная структура. Кроме неустойчивых (разбегающихся) траекторий, они содержат и устойчивые (притягивающие) траектории. По существу это седловые траектории, устойчивые по одним направлениям и неустойчивые по другим, и образующие множество не касающихся друг друга сложным образом соединяющихся слоев.

Концепция возникновения динамического хаоса и странных аттракторов в нелинейных системах, характерных для описания динамики взаимодействия судна с внешней средой с помощью обыкновенных дифференциальных уравнений, позволяет сформулировать следующие основные положения [19, 41, 42]:

- определения аттракторов диссипативных систем: странный, хаотический, стохастический и др.
- трудности объяснения природы нерегулярных аттракторов в рамках траекторного подхода, т. е. в терминах решений систем дифференциальных уравнений;
- геометрический подход к анализу аттракторов диссипативных систем — сведение задачи к отображению Пуанкаре меньшей размерности.

Исследования по динамике сложных систем при анализе экстремальных ситуаций [41, 42] связаны принятием следующих гипотез:

- гипотеза об экспоненциальном разбегании траекторий на аттракторе диссипативной системы;
- гипотеза о фрактальной структуре аттрактора диссипативной системы;

- гипотеза о переходе к пространственно-временному хаосу по сценарию Рюэля-Тakens.

Уравнение Дуффинга

При изучении поведения хаотических систем важным является исследование странного аттрактора и показателя Ляпунова. Такой результат получен для модели бортовой качки, одной из интерпретаций которого является уравнение Дуффинга [27]. Если в этом уравнении для внешней периодической силы ввести третью координату (для независимой переменной), то получается система третьего порядка с векторным полем

$$f(x) = \begin{pmatrix} f_1(x) \\ f_2(x) \\ f_3(x) \end{pmatrix} = \begin{pmatrix} x_2 \\ -x_1^3 - kx_2 + B \cos x_3 \\ 1 \end{pmatrix} \quad (30)$$

Эта система определяется двумя положительными параметрами: коэффициентом вязкого трения k и амплитудой возмущения B . Дивергенция отрицательная и определяется величиной трения (диссипации)

$$\frac{\partial f_1}{\partial x_1} + \frac{\partial f_2}{\partial x_2} + \frac{\partial f_3}{\partial x_3} = -k < 0. \quad (31)$$

Для системы (30) линеаризованное уравнение имеет следующую матрицу

$$A = \begin{pmatrix} 0 & 1 & 0 \\ -3x_1^2 & -k & -B \sin x_3 \\ 0 & 0 & 0 \end{pmatrix} \quad (32)$$

Результаты расчетов для $B = 10$, $k = 0,1$ приведены на рис. 16. При указанных значениях параметров в системе (30) возникает хаотическое движение [19, 27, 42], что подтверждается приведенными осциллограммами и особенностями изменения показателя Ляпунова.

При исследовании динамического хаоса с помощью уравнения Дуффинга используют различные модификации восстанавливающей компоненты [41, 42]. Так, например, в уравнении нелинейной килевой качки сохраняется представление μx^3 , а в уравнении нелинейной бортовой качки часто принимают зависимость $\mu_1 x^3 - \mu_2 x^5$. В результате рассматриваются две модификации уравнения Дуффинга:

$$x'' + kx' - x + \mu x^3 = f_0 \cos \omega t, \quad (33)$$

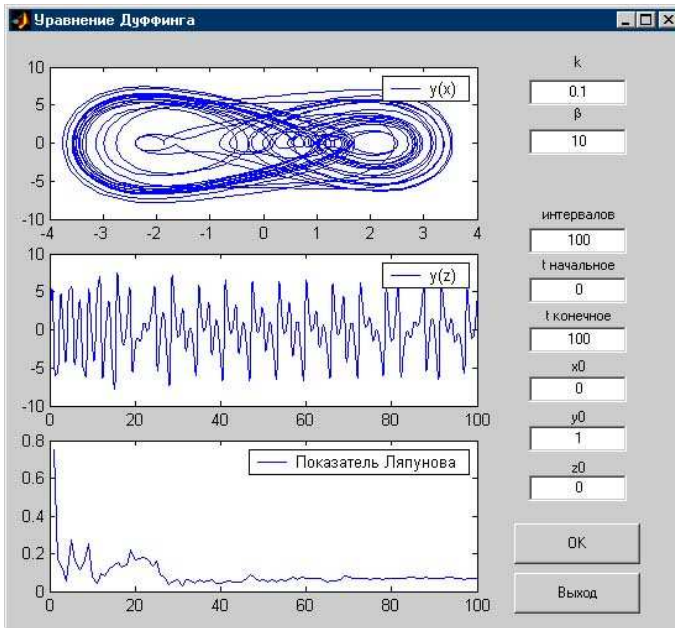


Рис. 16. Аттрактор и показатель Ляпунова для системы Дуффинга

$$x'' + kx' - x + \mu_1 x^3 - \mu_2 x^5 = f_0 \cos \omega t, \quad (34)$$

где k — коэффициент демпфирования; ω — частота внешнего возмущения.

Обобщенное уравнение Матье

Обобщенное уравнение Матье — наиболее часто используемое описание динамики ДО на волнении. Переход к стандартной форме этого уравнения от модели качки ДО осуществляется путем замены переменных и стандартизации аргумента косинуса. Детальное исследование хаотических колебаний с помощью этого уравнения применительно к задачам поведения ДО на волнении выполнено в работах [41, 42]. В отличие от стандартной формы уравнения Матье (линейная модель [31]), модифицированное уравнение представляется в следующем виде:

$$x'' + kx' + (h + \Delta h \cos \omega t)x + \mu x^3 = 0, \quad (35)$$

$$x'' + kx' + (h(x) + \Delta h(x) \cos \omega t)x = 0, \quad (36)$$

где $h(x)$ и $\Delta h(x)$ — существенно нелинейные функции, определяемые выражениями (13).

Как показали результаты моделирования, при фиксированных значениях параметров уравнение (35) имеет асимптотически устойчивое нулевое решение для определенного значения параметра $k = k^*$. При значениях $k < k^*$ в системе рождается устойчивый цикл с частотой $\omega/2$, который порождает каскад бифуркаций удвоения периода Фейгенбаума. Аналогичный характер развития хаотических колебаний наблюдается и при анализе уравнения (36). Однако вследствие чрезвычайной сложности этой модели, формирование странного аттрактора происходит по более сложному сценарию. Сначала реализуется каскад бифуркаций Фейгенбаума удвоения периода родившегося устойчивого предельного цикла, а затем — субгармонический каскад бифуркаций рождения устойчивых циклов любого периода.

Поведение фазовых траекторий в системах (35) и (36) исследовалось с помощью стандартных и нейросетевых моделей. Типичные картины поведения фазовых траекторий представлены на рис. 17 и 18.




Рис. 17. Фазовый портрет хаотических колебаний, порождаемых на основе модели (35) при наличии начального крена

Хаотические колебания нелинейных динамических систем отмечались автором не только в вычислительном эксперименте, но и при физическом моделировании. Проведенные эксперименты показали, что природа детерминированного хаоса связана с особенностями нелинейных систем разводить траектории в фазовом пространстве. Появление хаотичности является внутренним свойством нелинейных систем и не связано с действием каких-




Рис. 18. Фазовый портрет хаотических колебаний, характеризующий формирование странного аттрактора на основе модели (36)

либо случайных сил.

Сценарии перехода к хаосу и управление в хаотических системах

При исследовании хаотических систем в задачах динамики объекта на волнении рассматривают наличие двух сценариев перехода к хаосу в диссипативных системах:

- через каскад бифуркаций Фейгенбаума удвоения периода устойчивых циклов [35],
- через перемежаемость по сценарию Пома-Манневиля [39].

Сценарий Рюэля-Тakensса, связанный с разрушением трехмерного тора с образованием странного аттрактора [46] в задачах динамики объекта на волнении встречается достаточно редко и в настоящей работе не рассматривается.

Хаотическая динамика нелинейных систем при исследовании поведения ДО на волнении при вариации параметров ведется с помощью *бифуркационных диаграмм*. На таких диаграммах мера изменения параметра (максимальная амплитуда колебаний) изображается как функция параметра системы (амплитуды возмущающей силы или коэффициента демпфирования). Выборка данных осуществляется с помощью отображения Пуанкаре, что позволяет легко выделять удвоение периода и субгармонические бифуркации (рис. 19). Если при изменении параметра в системе возникают две или более бифуркации Хопфа (одновременно присутствуют три связанных предельных цикла), то становится возможным хаотическое движение.




Рис. 19. Бифуркационные диаграммы: А — бифуркация типа вил (переход из состояния с одним устойчивым положением равновесия в состояние с двумя устойчивыми точками); В — бифуркация Хопфа (переход от устойчивой спирали к колебаниям на предельном цикле)

Физические картины бифуркаций при исследовании динамики объекта на волнении получены с помощью дифференциальных уравнений типа Дуффинга (33) и Матъе (36) [27]. В качестве иллюстрации на рис. 20 представлены решения уравнения Дуффинга: сингулярный предельный цикл (рис. 20А), каскад бифуркаций удвоения периода которого порождает аттрактор Фейгенбаума (рис. 20В, С); субгармонический каскад бифуркаций устойчивых решений согласно порядку Шарковского (предельный цикл на рис. 20D) и хаотический аттрактор (рис. 20Е). Аналогичные картины хаотических колебаний отмечаются и для уравнения Матъе, содержащего периодические коэффициенты [27].

Типичный сценарий возникновения хаоса в системах, характеризующих нелинейную качку ДО, связан с явлением *перемежаемости* (рис. 21). В этом случае по мере изменения параметра системы длительные интервалы периодического движения перемежаются со вспышками хаоса 1, которые становятся все более частыми и длительными 2 (рис. 21А).

Развитие учения о хаотической динамике нелинейных систем выявило целый ряд реальных практических задач, в том числе и в гидродинамике судна [41, 42], где хаотические режимы действительно могут возникать при сложном взаимодействии судна с внешней средой. Более того, возникли практически важные классы задач, когда нелинейной системой необходимо управлять, изменяя степень ее хаотичности. Методы решения подобных задач в последние годы стали активно развиваться, особенно в приложениях, посвященных различным аспектам применения методов управления к хаотическим процессам.




Рис. 20. Динамический хаос в нелинейной системе Дуффинга

Так, например, работа [38] посвящена задаче подавления колебаний судового крана. Исследуется влияние возмущений, в качестве которых рассматривается хаотический процесс, доминирующая частота которого находится вблизи собственных колебаний системы. Для гашения колебаний предложен и исследован нечеткий регулятор. Результаты исследований показывают значительное снижение размаха колебаний по сравнению с неуправляемой системой. В работе [40] рассматривается бортовая качка судна с затопленными отсеками. Из-за наличия большого количества воды внутри корпуса возникают сложные взаимосвязанные колебания судна и находящейся в нем жидкости, напоминающие колебания связанных осцилляторов. На основе численных исследований и лабораторных экспериментов установлена возможность появления в системе сложных хаотических колебаний большой амплитуды. Показано, что соответствующим выбором времени запаздывания и коэффициентов обратной связи можно добиться сведения хаотического процесса к периодическому с малой амплитудой. К




Рис. 21. Возникновение хаоса перемежаемого типа: А — модель Дуффинга (классический алгоритм); В — модель Матье при наличии начального крена (нейросетевой алгоритм)

сожалению, эти интересные задачи не рассматривались с позиций теории нейросетевого управления, широко применяемого в нелинейных динамических системах [3].

Управление в самоорганизующихся системах

Задачи и методы управления хаосом — область интенсивных исследований последних десятилетий. Концепция детерминированного хаоса сначала считалась экзотическим явлением, представляющим интерес для математиков. Возможность возникновения хаотических колебаний в практических приложениях ставилась под сомнение. Однако в последствии хаотическая динамика была обнаружена в огромном числе различных систем: в механике, системах связи, лазерной физике и радиофизике, химии и биологии, экономике, медицине. Системы с хаосом демонстрируют одновременно и хорошую управляемость и удивительную пластичность: система чутко реагирует на внешние воздействия, сохраняя при этом тип движения. Комбинация управляемости и пластичности часть является причиной того, что хаотическая динамика является характерным типом поведения для многих систем [3, 5, 27–29].

С позиций синергетического подхода [17] модели хаотических систем открывают возможности реализации процессов самоорганизации.

Для характеристики ситуации, определяющей нелинейную динамику

объекта, можно построить *диаграмму переходов* состояний. Такая диаграмма позволяет интерпретировать сложные ситуации, возникающие в различных условиях эксплуатации. Поведение ДО, как самоорганизующейся системы, наиболее ярко проявляется в ситуациях, связанных с затоплением отсеков на основе математической модели (16). В этом случае диаграмма представляет собой сеть, вершинами которой являются события, а ориентированные ребра задают переходы между событиями. Каждое ребро содержательно интерпретируется как алгоритмически реализуемое возмущение динамической системы, под которым понимаются как внешние (волновые) воздействия, так и изменения, происходящие в самой динамической системе в результате поступления воды внутрь корпуса. Формально диаграмма переходов состояний описывается как структура вида

$$W = \langle S, R, A, B, L \rangle, \quad (37)$$

где S — множество ситуаций; R — множество ребер вида $r_{ij} = (s_i, s_j)$, $i \neq j$, A — множество присоединенных атрибутивных вершин; B — множество присоединенных алгоритмических вершин; L — множество ребер вида $l = (a_i, s_i)$ или $l_{ij} = (b_i, s_j)$ или $l_{ij} = (a_i, a_j)$; $i \neq j$, $a_j \in A$, $b_j \in B$.




Рис. 22. Фазовые портреты трехстабильной (А) и бистабильной (В) динамических систем

Результаты вычислительных экспериментов позволяют построить и проанализировать траектории системы на фазовой плоскости [9, 13] в виде аттракторов, описывающих динамику одностабильной, бистабильной и трехстабильной систем (рис. 22), а также характерные временные кривые и

одномерные отображения из точек, соответствующих максимальным значениям амплитуды для $(n+1)$ и n -го интервалов времени для аттракторных множеств.

Исследования поведения нелинейных систем показывают, что в фазовом пространстве бифуркационные границы, по разные стороны которых система имеет качественно различный характер поведения, удобно определять с помощью сепаратрис. Применительно к задаче потери устойчивости движения сложной системы стоится *поверхность сепаратрис*, разделяющая область влияния различных аттракторов (рис. 23). На этом рисунке фазовая траектория «пересекает» поверхность сепаратрис с устойчивыми колебаниями и оказывается в области неустойчивости (опрокидывание), кардинально меняя свое поведение.




Рис. 23. Фазовая траектория и поверхность сепаратрис в трехмерном пространстве (черной точкой отмечен момент пересечения фазовой траекторией поверхности сепаратрис)

Другая закономерность, иллюстрируемая компьютерной программой, заключается в моделировании пространственно-временного поведения ДО на базе центральной теоремы синергетики, определяющей динамику сложной системы как взаимосвязь растущих и затухающих ее конфигураций с параметрами порядка [17, 42]. Показано, что все пространственно-временные состояния системы управляются параметрами порядка (принцип подчинения). Переход к параметрам порядка в сложной системе приводит к

сжатию информации и к значительному сокращению числа степеней свободы. При этом параметры порядка определяют движение элементов системы, которые, в свою очередь, совместно (кооперативно) характеризуют действие параметров порядка (принцип круговой причинности).

Таким образом, богатство возможностей поведения нелинейных динамических систем снимает проблему «фатализма» однозначной парадигмы развития поведения системы и открывает простор для выбора той области параметрического и фазового пространства, которая обладает предпочтительным аттрактором. Основы нелинейной динамики сложных систем открывают перед исследователем объемный и многообразный нелинейный мир с новыми подходами, критериями упорядоченности и методами интерпретации сложных физических явлений. В этом мире свое место занимает нейросетевое моделирование, использующее преимущества этой вычислительной технологии в задачах аппроксимации и прогноза.

Управление в нестандартных ситуациях

Одно из интересных приложений нелинейной теории управления связано с задачей о поведении ДО в условиях «захвата» и разворота на нерегулярном волнении, получившей наименование брочинг (broaching) [13, 22, 43]. *Брочинг* — одна из наиболее сложных и опасных экстремальных ситуаций. Эта ситуация связана с возникновением явления «захвата» ДО попутной волной, потерей устойчивости движения, ухудшением управляемости и внезапным разворотом на волнении. Решение задачи о динамике брочинга ведется методами физического и математического моделирования с представлением результатов анализа ситуации на фазовой плоскости.

Проведенное исследование динамических картин потери устойчивости и опрокидывания ДО в условиях брочинга позволило сформулировать критериальный базис, упростить интерпретацию экстремальной ситуации и разработать алгоритм нейроуправления при принятии решений в процессе функционирования бортовой ИС контроля и прогноза мореходных качеств ДО в условиях эксплуатации [43]. Для иллюстрации на рис. 24 представлены характеристики «захвата» и картина разворота ДО в режиме «брочинг». Динамическая граница режима «захвата» отделяет эту область от области продольно-горизонтальной качки. Динамическую область «захвата» можно трактовать как совокупность условий (элементы волнения, скорость и курс), при которых теряется устойчивость режима продольно-горизонтальных колебаний.




Рис. 24. «Захват» (слева) и неуправляемый разворот ДО (справа) при воздействии группы нерегулярных волн: А — начало, В — выход из состояния «захвата»

Особенность задачи состоит в том, что эффективное управление в режиме «бронинг» возможно только с целью предотвращения возникновения этой опасной ситуации. Однако в случае ее возникновения попытки использовать управление для выхода ДО из этой ситуации могут приводить только к ее ухудшению, поскольку рулевой комплекс оказывается неэффективным в условиях полной потери управляемости [43].

Здесь вполне уместно привести слова выдающегося английского математика, философа и общественного деятеля *Рассела Бертрана Артура Уильяма*: «Во время кораблекрушения команда выполняет приказы своего капитана не задумываясь, ибо у матросов есть общая цель, да и средства для достижения этой цели очевидны и всем понятны. Однако если бы капитан принялся разъяснять матросам свои принципы управления кораблем, чтобы доказать правомерность поступающих приказов, корабль пошел бы ко дну раньше, чем закончилась его речь».

Нейросетевые модели управления

В ряде задач анализа и прогноза экстремальных ситуаций можно использовать ИНС, с помощью которых осуществляется построение функций принадлежности [1] и системы нейруправления [25]. Обучение нейронной сети ведется на основе данных динамических измерений с помощью процедуры обратного распространения или ГА [8, 12, 32].

Система реализует выбор оптимальной скорости и курса ДО в зави-

симости от интенсивности внешних возмущений. Процесс управления организуется на основе концепции нечеткой логики. Алгоритм представляется в виде матриц управления. Элементы матриц соответствует одному из возможных состояний управляющего воздействия Y . Они могут быть сгенерированы при помощи ИНС [43]. Настройка синаптических связей ИНС осуществляется в рамках принципа конкуренции с помощью процедуры обратного распространения и ГА. В качестве иллюстрации на рис. 25 представлен один из вариантов алгоритма контроля динамики объекта, разработанный на основе нечетких моделей и реализуемый в виде матриц управления размерности 5×5 .

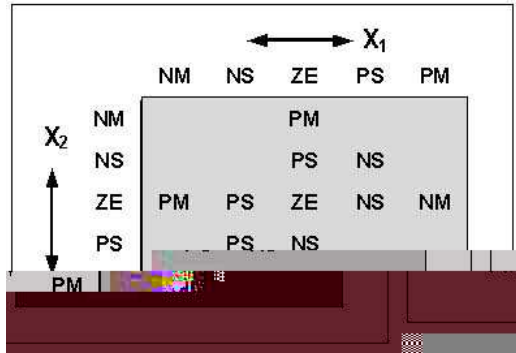


Рис. 25. Алгоритм управления при контроле динамики объекта

Схема управляющей базы знаний (рис. 26) на основе ИНС имеет четыре управляющих входа $X_1, X_2, dX_1/dt, dX_2/dt$ и один выход Y .

Обучение сети производится на основе функций принадлежности для X_1, X_2, dX_1, dX_2 которые подаются на вход системы, и значения Y на выходе. В результате использования ГА формируется сложная многомерная поверхность ошибки управления как функция параметров закона управления. ГА находит глобальный минимум этой поверхности. В сложных задачах анализа и интерпретации данных динамических измерений используется ансамбли ИНС, анализ которых ведется на основе модели нечеткого логического вывода по прецедентам [26].




Рис. 26. Нейронная сеть, обеспечивающая управление ДО в экстре-

$$\varphi_i = \frac{Z_g - Z_{CR}}{Z_G} \cdot 100; \quad \sigma =$$

Известно, что для нормальных распределений среднее арифметическое $\theta^* = \sum \theta_i / N$ как оценка параметра θ является несмещенной $E(\theta^*) = \theta$ и состоятельной $\lim P(|\theta^* - \theta| < \varepsilon) = 1, \forall \theta$ при больших значениях N . Однако если закон распределения заранее неизвестен, то может оказаться, что θ^* — смещенная оценка математического ожидания с наименьшей дисперсией, а в случае многомерных распределений эта оценка не является допустимой для квадратичной функции потерь $\sum (\theta - \theta^*)^2$. Если такая проверка при статистическом анализе исходной выборки не проводилась, то нормативные значения критериальных соотношений в системе не являются статистически обоснованными.

Парадокс выбора границ критерия. Принципиальное значение имеет парадокс выбора пороговых значений критериальных соотношений. Использование нечетких границ критериев приобретает важное значение в связи со случайным характером и неопределенностью исходной информации, на основании которой строится расчетная схема оценки поведения ДО (рис. 27).

Действительно, погрешность контроля положения центра масс (опыт кренования), неточность фактических данных о нагрузке судна и другие факторы приводят к тому, что истинное значение нормируемого параметра X в действительности равно $X_0 + \varepsilon$ или $X_0 - \varepsilon$. Тогда в соответствии с требованиями норм оценка $X^* = X_0$ (критерий соблюдается без избытка и недостатка), а на самом деле $X = \pm \varepsilon$. Область принятия гипотезы $X = X_0$, т. е. интервал $X_{1-\alpha}, X_\alpha$ составляет β (α — уровень значимости). Это означает, что вероятность допустить ошибку второго рода (нулевая гипотеза принимается, в то время как она неверна) при выявлении отклонения от гипотетического значения X_q составляет β , а величина $1 - \beta$ характеризует «мощность критерия». Уменьшая α мы снижаем вероятность допустить ошибку первого рода (нулевая гипотеза отвергается, когда в действительности она не верна). Однако при этом увеличивается вероятность β допустить ошибку второго рода и снижается мощность критерия.

Парадоксы компьютерной реализации. Немало парадоксов связано с компьютерной реализацией задач динамики сложного объекта. Любое статистическое решение, которое можно реализовать на компьютере, стало доступным для исследователей. В результате «устойчивые» и многомерные методы с огромным числом операций вошли в повседневную практику без достаточного теоретического обоснования. Между тем, многие эмпирические коллизии, используемые в статистической практике, можно

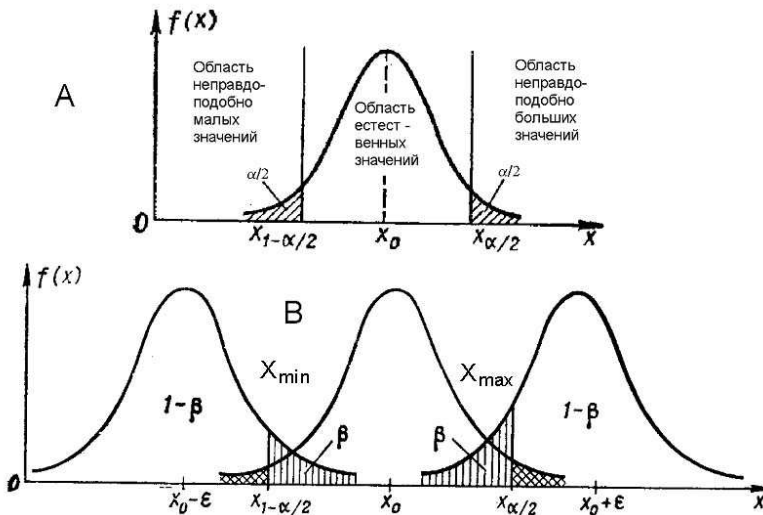


Рис. 27. Ошибки, допускаемые при практическом использовании критериев: X_0 – нормируемая характеристика; (X_{\max}, X_{\min}) – область фактического изменения X ; A – области нулевой и альтернативной гипотез; B – области, соответствующие ошибке второго рода

обосновать с помощью робастных статистик, что в практике моделирования используется крайне редко.

Заключение

Особенности разработки бортовых ИС новых поколений, как сложных программно-аппаратных комплексов, требуют, чтобы компьютерные программы приобретали свойства, обеспечивающие его жизнеспособность. Эти свойства заключаются в адаптивности и адаптируемости программных систем. Переход к таким программам приводит к необходимости использования не только современных подходов к интерпретации классической теории управления и кибернетики, но и более глубокой математической подготовки разработчиков в области программирования и вычислительной техники.

Искусство создания бортовых ИС реального времени — не только в по-

строении формализованных моделей обработки информации, но главным образом в умении организовать и поставить обоснованный эксперимент при тестировании и испытании ИС. Необходимо помнить, что результат работы ИС зависит от качества и объема исходной информации, преобразование которой определяется цепочкой: «измерения–обработка–принятие решений». Все методологические принципы и грамотно проведенный анализ окажутся ненужными, если придется применять их к посредственным данным, полученным в результате использования малоэффективных алгоритмов преобразования измерительной информации или при небрежно поставленном эксперименте. При решении этих проблем важное значение имеет теория планирования эксперимента, которая, к сожалению, сейчас почти забыта и редко преподается в университетах.

Таким образом, трудности создания бортовых ИС новых поколений обусловлены не только несовершенством современных информационных технологий в части реализации адаптивных средств функционирования динамической базы знаний, но и в значительной степени проблемами самой предметной области и психологическими аспектами, связанными с восприятием новых подходов и содержательных решений, в том числе и с отсутствием международных стандартов, регламентирующих требования к установке и эксплуатации ИС на борту судов и других плавучих ДО.

Рассмотренные задачи нелинейной динамики связаны с применением многопроцессорных вычислительных средств анализа и интерпретации информации при функционировании бортовых ИС реального времени. Вычислительные технологии реализации этих задач отражают только незначительную область научно-технических приложений, в которых находят применение методы анализа существенного нелинейных динамических систем, синергетическая парадигма и теория детерминированного хаоса. Концептуальные основы излагаемого материала объединяют понятия устойчивости и теории колебаний и предлагают методологическое средство для совместного осмысления этих двух понятий с пояснением некоторых подходов, методов и моделей. При этом автором сделан акцент именно на те приложения, которые в настоящее время вызывают большой научный и практический интерес при исследовании сложного поведения ДО в различных экстремальных ситуациях.

Автор выражает свою признательность научному редактору сборника Ю. В. Тюменцеву за содействие при подготовке рукописи к изданию.

Литература

1. *Аверкин А. Н., Батыришин А. Н., Блишун А. Ф., Силов В. Б., Тарасов В. Б.* Нечеткие множества в задачах управления и искусственного интеллекта / Под ред. *Д. А. Поспелова*. – М.: Наука, 1986.
2. *Аксак Н. Г., Тыхун А. Ю.* Вычислительная модель нейроалгоритма многослойного персептрона // Высокопроизводительные параллельные вычисления на кластерных системах. Нижний Новгород. Изд-во Нижегородского университета, 2006, с. 10–17.
3. *Андриевский Б. Р., Фрадков А. Л.* Управление хаосом: методы и приложения // *Автоматика и телемеханика*. – № 4. 2004, с. 3–34.
4. *Андронов А. А., Витт С., Хайкин С. Э.* Теория колебаний. – М.: Наука, 1981.
5. *Анищенко В. С., Владиславова Т. Е., Астахов В. В.* Нелинейная динамика стохастических и хаотических систем. – Саратов, 1999.
6. *Арнольд В. И.* Теория катастроф. – М.: Наука, 1990.
7. *Борисов Ю. Ю.* Построение прогнозирующих моделей динамических систем на основе исследования окрестностей реконструированных аттракторов // *Автоматизация и современные технологии*. – № 7, 2007, с. 32–37.
8. *Бородай И. К., Нецветаев Ю. А.* Качка судов на морском волнении. – Л.: Судостроение, 1969.
9. *Борговые интеллектуальные системы. Часть 1. Авиационные системы. Часть 2. Корабельные системы. Часть 3. Системы посадки летательных аппаратов корабельного базирования.* – М.: Радиотехника, 2006, 2008.
10. *Брусов В. С., Тюменцев Ю. В.* Синтез оптимального ансамбля нейроконтроллеров для многорежимного летательного аппарата // Тр.5-й Всероссийской конференции «Нейроинформатика-1999». МИФИ. 1999. Часть 2, с. 190–201.
11. *Васильев В. И., Жернаков С. В., Уразбахтина Л. Б.* Нейросетевой контроль параметров газотурбинного двигателя // *Нейрокомпьютеры: разработка, применение*. – №1, 2001, с. 37–43.
12. *Галушкин А. И.* Теория нейронных сетей. – М.: ИПРЖ, 2000.
13. *Интеллектуальные системы в морских исследованиях и технологиях / Под ред. Ю. И. Нечаева.* – Санкт-Петербург: ГМТУ, 2001.
14. *Катица С. П., Курдюмов С. П., Малинецкий Г. Г.* Синергетика и прогнозы будущего. – М.: Наука, 1997.
15. *Красовский А. А.* Проблемы физической теории управления // *Автоматика и телемеханика*. – 1990, № 11.

16. *Лесных В. Ю.* Динамическая реконструкция временных рядов // Сборник докладов X Международной конференции по мягким вычислениям и измерениям SCM-2007. Санкт-Петербург. 2007. т. 1, с. 199–202.
17. *Лоскутов А. Ю., Михайлов А. С.* Введение в синергетику. – М.: Наука, 1990.
18. *Малинецкий Г. Г., Потапов А. Б.* Современные проблемы нелинейной динамики. – М.: УРСС, 2002.
19. *Магницкий Н. А.* Универсальная теория динамического и пространственно-временного хаоса в сложных системах // *Нелинейные процессы в динамических системах.* – №1, т. 1, 2007, с. 18–39.
20. *Макаренко Н. Г.* Эмбедология и нейропрогноз // Тр. 5-й Всероссийской конференции «Нейроинформатика-2003». Лекции по нейроинформатике. – М.: МИФИ, 2003, с. 86–148.
21. *Неймарк Ю. И., Ланда П. С.* Стохастические и хаотические колебания. – М.: Наука, 1987.
22. *Нечаев Ю. И.* Моделирование устойчивости на волнении. Современные тенденции. – Л.: Судостроение, 1989.
23. *Нечаев Ю. И.* Нейросетевые технологии в интеллектуальных системах реального времени // Тр. 4-й всероссийской конференции «Нейроинформатика – 2002». – М.: МИФИ. 2002. Лекции по нейроинформатике. Часть 1, с. 114–163.
24. *Нечаев Ю. И.* Математическое моделирование в бортовых интеллектуальных системах реального времени // Труды 5-й всероссийской научно-технической конференции «Нейроинформатика – 2003». – М.: МИФИ. Лекции по нейроинформатике. Часть 2, с. 119–179.
25. *Нечаев Ю. И.* Нейроаппроксимация и нейропрогноз при контроле динамики сложного объекта // *Нейрокомпьютеры: разработка, применение.* – №9. 2005, с. 22–31.
26. *Нечаев Ю. И.* Нейросетевые ансамбли при интерпретации экстремальных ситуаций в бортовых интеллектуальных системах // *Нейрокомпьютеры: разработка, применение.* – №6. 2006, с. 60–69.
27. *Нечаев Ю. И.* Нелинейная динамика и парадигмы вычислений при анализе экстремальных ситуаций // Материалы международной конференции «Леонард Эйлер и современная наука». Российская академия наук. Санкт-Петербург. 2007, с. 385–390.
28. *Нечаев Ю. И.* Нейронечеткая система поддержки принятия решений при оценке поведения сложного динамического объекта // Труды X-й Всероссийской конференции «Нейроинформатика-2008». Лекции по нейроинформатике. Часть 2, М.: МИФИ. 2008, с. 97–164.

29. *Нечаев Ю.И.* Нейронечеткие технологии в интеллектуальной системе контроля посадки летательных аппаратов корабельного базирования // Сборник Научных трудов XI Всероссийской научно-технической конференции по «Нейроинформатика-2009». Лекции по нейроинформатике. М.: МИФИ. 2009, с. 209–278.
30. Справочник по теории корабля. В 3-х томах. – Л.: Судостроение, 1985.
31. *Хаяси Т.* Нелинейные колебания в физических системах. – М.: Мир, 1968.
32. *Уоссермен Ф.* Нейрокомпьютерная техника. – М.: Мир, 1992.
33. *Boukhanovsky A., Degtyarev A., Lopatoukhin L., Rozhkov V.* Stable states of wave climate: applications for risk estimation. Proceedings of the International conference STAB'2000, Launceston, Tasmania, Australia, February, 2000, vol. 2, pp. 831–846.
34. *Brusov V.S., Tiumentsev Yu. V.* High performance aircraft flight control based on artificial neural networks // Proc. of the RRDPAE-96. Warsaw, 1997, pp. 97–100.
35. *Fegenbaum N.J.* Quantitative universality for a class of nonlinear transformation // *J. Stat. Phys.*, 1978, vol. 19, pp. 25–52.
36. *France W., Levadou M., Treakle T.W., Paulling J.R., Michel R.K., Moore K.* An investigation of head-sea parametric rolling and its Influence on Container Lashing Systems // SNAME Annual Meeting 2001, pp. 1–24.
37. *Kan M.* Chaos and fractals in nonlinear rolling and capsizing of damaged ships // Proceeding of International Symposium «Ship stability in a Seaway»: Stability, Maneuverability, Nonlinear approach. Kaliningrad. 1993. Vol. 2, No. 2. – pp. 1–19.
38. *Kimiaghalam B., Homaifar A., Bikdash M.* Pedulation suppression of a shipboard crane using fuzzy controller // Proceedings of American Control Conference (ACC'99), San Diego, California, 1999, pp. 586–590.
39. *Manneville P., Pomeau Y.* Different ways to turbulence in dissipative dynamical systems // *Physica*. – 1980. Vol 1D, p. 219.
40. *Mitsubori K., Aihara K.* Delayed-feedback control of chaotic roll motion of a flooded ship in waves // Proceedings of conference RLA. 2002, pp. 2801–2813.
41. *Nechaev Yu. I.* Determined chaos in the phase portrait of ships dynamic in a seaway // Proc. of International Workshop «On the problems of physical and mathematical modeling». OTRADNOYE-93. Vol. 2, pp. 143–145.
42. *Nechaev Yu. I.* Mathematical modeling, chaos and fractals in real time systems // Report on the third International congress on industrial and applied mathematics. Edinburg. Scotland. 1999. Paper 23.
43. *Nechaev Yu. I., Zavyalova O.P.* Criteria basis for estimation of capsizing danger in broaching extreme situation for irregular following waves // Proceedings of international conference STAB-2003. Madrid. Spain. 2005. Paper 12.

44. *Nechaev Yu., Degtyarev A., Anischenko O.* Ships dynamic on Wave- Breaking condition // Proceedings of the 9th International conference on stability and ocean vehicles SATAB-2006. Rio de Janeiro. Brazil. 2006, pp. 409–417.
45. *Richards R. A.* Application of multiple artificial intelligence techniques for an aircraft carrier landing decision support tool
URL: www.shai.com
46. *Ruelle D., Takens F.* On the nature of turbulence // *Commun. Math. Phys.* – 1971, Vol. 20(3), pp. 167–192.
47. *Shuster H. G.* Deterministic chaos. – Physik-Verlag: Weinheim, 1984.
48. *Takens F.* Lectures notes in mathematics. Vol. 898. – N.Y. Springer. 1981, pp. 366–381.
49. *Winston P. N.* Artificial intelligence. – Addison Wesley Publishing Company. USA, 1993.
50. *Zadeh L.* Fuzzy logic, neural networks and soft computing // *Commun. of the ASM.* – 1994. Vol. 37, No. 3, pp. 77–84.

Юрий Иванович НЕЧАЕВ, профессор кафедры вычислительной техники и информационных технологий Санкт-Петербургского государственного морского технического университета, заведующий отделом систем поддержки принятия решений Института высокопроизводительных вычислений и информационных систем, эксперт по высокопроизводительным вычислениям и интеллектуальным системам (Вашингтон, США и Лондон, Англия), заслуженный деятель науки РФ, академик РАЕН, доктор технических наук, профессор.

НАУЧНАЯ СЕССИЯ НИЯУ МИФИ–2010

НЕЙРОИНФОРМАТИКА–2010

ХII ВСЕРОССИЙСКАЯ
НАУЧНО-ТЕХНИЧЕСКАЯ
КОНФЕРЕНЦИЯ

ЛЕКЦИИ
ПО НЕЙРОИНФОРМАТИКЕ

Оригинал-макет подготовлен Ю. В. Тюменцевым
с использованием издательского пакета $\text{\LaTeX} 2_{\epsilon}$
и набора PostScript–шрифтов *PSCyr*

Подписано в печать 01.12.2009 г. Формат 60 × 84 1/16
Печ. л. 20, 5. Тираж 170 экз. Заказ №

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