

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ
РОССИЙСКОЙ ФЕДЕРАЦИИ
ФЕДЕРАЛЬНОЕ АГЕНТСТВО ПО АТОМНОЙ ЭНЕРГИИ
РОССИЙСКАЯ АССОЦИАЦИЯ НЕЙРОИНФОРМАТИКИ
МОСКОВСКИЙ ИНЖЕНЕРНО-ФИЗИЧЕСКИЙ ИНСТИТУТ
(ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ)

НАУЧНАЯ СЕССИЯ МИФИ-2006

НЕЙРОИНФОРМАТИКА – 2006

**VIII ВСЕРОССИЙСКАЯ
НАУЧНО-ТЕХНИЧЕСКАЯ
КОНФЕРЕНЦИЯ**

**ЛЕКЦИИ
ПО НЕЙРОИНФОРМАТИКЕ**

По материалам Школы-семинара
«Современные проблемы нейроинформатики»

Москва 2006

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

НАУЧНАЯ СЕССИЯ МИФИ–2006. VIII ВСЕРОССИЙСКАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ «НЕЙРОИНФОРМАТИКА–2006»: ЛЕКЦИИ ПО НЕЙРОИНФОРМАТИКЕ. – М.: МИФИ, 2006. – 244 с.

В книге публикуются тексты лекций, прочитанных на Школе-семинаре «Современные проблемы нейронной информатики», проходившей 24–27 января 2006 года в МИФИ в рамках VIII Всероссийской конференции «Нейронная информатика–2006».

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

Ответственный редактор
Ю. В. Тюменцев, кандидат технических наук

ISBN 5–7262–0635–5 © *Московский инженерно-физический институт
(государственный университет), 2006*

Содержание

Предисловие	7
С. А. Терехов. Технологические аспекты обучения нейросетевых машин	13
Введение: Технологии обучающихся машин для анализа данных	14
Задачи, которые решают нейронные сети	16
Задачи классификации	18
Аппроксимация данных	21
Кластеризация и визуализация данных	22
Прогнозирование временных рядов и оценивание рисков	25
Другие задачи	26
Почему информационные задачи сложны?	27
Нейронные сети, которые решают задачи	30
Вероятностные деревья для задач классификации	30
Методы кластеризации данных	35
Гибридные методы классификации и кластеризации	38
Машины базовых векторов (SVM)	40
Нейросетевые обучающиеся машины	47
Что принципиально при синтезе нейросетевых моделей?	49
Иллюстрации применения технологий информационного моделирования	53
Задачи конкурса WCCI-2006	55
Задача ADA	55
Обсуждение	61
Послесловие	62
Благодарности	63
Литература	64
Приложение. О стандартизации описания моделей обучающихся машин (PMML – Predictive Model Markup Language)	65
Общие принципы PMML	67
УДК 001(06)+004.032.26 (06) Нейронные сети	3

Что дает применение PMML?	69
Задачи	70
Задача 1. Таблица данных со случайными признаками	70
Задача 2. Свойства ядерной аппроксимации	72
А. М. Иваницкий. Проблема «сознание и мозг» и искусственный ин-	
теллект	74
Введение	75
Механизмы ощущений	76
Мышление	78
Декларативная память и внимание	80
Основные механизмы сознания	82
Физиология мозга и проблема искусственного интеллекта	83
Литература	86
В. Г. Яхно. Динамика нейроноподобных моделей и процессы «созна-	
ния»	88
Введение	88
Варианты моделей нейроноподобных систем	89
Однородные нейроноподобные системы	90
Модели адаптивных распознающих систем	94
Модели взаимодействующих распознающих систем	100
Выводы	106
Литература	108
В. Г. Редько. Проблема происхождения интеллекта и модели адап-	
тивного поведения	112
Можно ли обосновать математику?	113
Модели адаптивного поведения	116
From Animal to Animat — модели адаптивного поведения	
животного и робота	116
Исследователи адаптивного поведения	118
Обучение с подкреплением	120
Теория функциональных систем П. К. Анохина как концеп-	
туальная основа исследований адаптивного поведения	127
Модели эволюционного возникновения целенаправленного	
адаптивного поведения	131
Проект «Мозг анимата»	137

Модель эволюции популяции самообучающихся агентов на базе нейросетевых адаптивных критиков	144
Выводы по моделям адаптивного поведения	163
Контуры программы будущих исследований	163
Благодарности	165
Литература	166

Игумен Феофан (Крюков). Модель внимания и памяти, основанная на принципе доминанты. Часть II: Попытка примирения конкурирующих теорий долговременной памяти **171**

Введение	172
Теория Когнитивной Карты	174
Эффект клетки места	175
Эффект точки зрения	176
Стандартная Теория	178
Эффект ретроградной амнезии (РА)	179
Эффект консолидации	182
Теория Множественных Следов	183
Эффект независимости от давности	184
Эффект диссоциации	185
Эффект антероградной амнезии	186
Теория Тета-Регулируемого Внимания	188
Эффект новизны	189
Эффект привыкания	190
«Нейролокатор» — унифицирующая модель внимания и памяти .	193
Доминантная архитектура и блок-схема «Нейролокатора» .	193
Допущения «Нейролокатора»	197
Основные свойства модели «Нейролокатор».	198
Краткое объяснение основных эффектов	200
Эффекты новизны и привыкания	201
Эффект ретроградной амнезии	203
Эффект консолидации	205
Эффект антероградной амнезии	207
Эффект диссоциации	210
Эффект клетки места	211
Эффект точки зрения	212
Эффект независимости от давности	212
Попытка примирения конкурирующих теорий	213

Заключение	218
Литература	220
<i>Л. Б. Литинский. Параметрические нейронные сети и другие архитектуры на их основе (обзор работ)</i>	231
Введение	232
ПНС-архитектуры	233
Векторный формализм	233
Распознающие характеристики ПНС-2	234
ПНС-3	236
Другие архитектуры на основе ПНС	238
Декоррелирующая ПНС	238
q -нарный идентификатор	240
Литература	242

ПРЕДИСЛОВИЕ

1. В этой книге содержатся тексты лекций, прочитанных на Шестой Школе-семинаре «Современные проблемы нейроинформатики», проходившей 24–27 января 2006 года в МИФИ в рамках VIII Всероссийской научно-технической конференции «Нейроинформатика–2006».

При отборе и подготовке материалов для лекций авторы и редактор следовали принципам и подходам, сложившимся при проведении пяти предыдущих Школ (см. [1–8]). А именно, основной целью Школы было 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 Школы-семинара «Современные проблемы нейроинформатики» на конференции «Нейроинформатика–2006» вошли следующие восемь лекций:

1. *С. А. Терехов*. Технологические аспекты обучения нейросетевых машин.
2. *А. А. Ежов*. Сознание, рефлексия и многоагентные системы.
3. *А. М. Иваницкий*. Проблема «сознание и мозг» и искусственный интеллект.
4. *В. Г. Яхно*. Динамика нейроноподобных моделей и процессы «сознания».
5. *В. Г. Редько*. Проблема происхождения интеллекта и модели адаптивного поведения.
6. *Игумен Феофан (Крюков)*. Модель внимания и памяти, основанная на принципе доминанты. Часть II: Попытка примирения конкурирующих теорий долговременной памяти.
7. *Н. Г. Макаренко*. Стохастическая динамика, марковские модели и прогноз.
8. *Л. Б. Литинский*. Параметрические нейронные сети и другие архитектуры на их основе.

Помимо Школы-семинара, в рамках конференции «Нейроинформатика–2006» проводилось также рабочее совещание «О проблеме сознания» (сопредседатели: *А. А. Фролов* и *А. А. Ежов*), где были вынесены на обсуждение следующие вопросы:

1. Можно ли объяснить сознание и что понимать под его объяснением?
2. Можно ли объяснить сознание в рамках классической физики?
3. Можно ли смоделировать сознание на компьютере или сознание — инструмент по обслуживанию тела и не может быть смоделировано без тела?
4. Как соотносятся сознание и внимание?
5. Как соотносятся сознание и движение?

Темы большей части лекций Школы оказались тесно связанными с кругом вопросов Рабочего совещания: лекции *А. А. Ежова*, *А. М. Иваницкого* и *В. Г. Яхно* непосредственно связаны с этими вопросами, а лекции *В. Г. Редько* и *игумена Феофана (Крюкова)* — тесно соприкасаются с ними.

Более традиционной нейросетевой тематике были посвящены лекции *С. А. Терехова* и *Л. Б. Литинского*, лекция *Н. Г. Макаренко* была связана с исследованиями междисциплинарного характера.

Шесть из перечисленных выше восьми лекций публикуются в данном сборнике, две лекции (*А. А. Ежова* и *Н. Г. Макаренко*) в силу технических причин будут опубликованы в сборнике лекций следующей Школы-семинара.

3. Лекция С. А. Терехова «Технологические аспекты обучения нейросетевых машин» касается круга вопросов, которым в тематике предыдущих Школ уделялось совсем немного внимания. Как в предыдущих лекциях автора [9–12], так и в других работах, которые докладывались на Школах, рассмотрение ограничивалось, большей частью, теоретическими вопросами, а также изложением соответствующих алгоритмов. Важнейшее звено процесса создания систем на базе идей и методов нейроинформатики — этап реализации полученных алгоритмов — оставалось вне поля внимания. Этот пробел и была призвана заполнить лекция *С. А. Терехова*.

4. Лекция А. М. Иваницкого «Проблема “сознание и мозг” и искусственный интеллект» рассматривает современные представления о мозговых механизмах сознания, о том, как соотносятся сознание и процессы, происходящие в мозге. Естественный вопрос, который возникает при этом: «... в какой мере знания о механизмах мышления и сознания человека могут быть использованы при создании искусственного интеллекта». В лекции *А. М. Иваницкого* предпринимается попытка ответить на этот вопрос, обсудить сходства и различия мозга и искусственного интеллекта с позиций нейрофизиологии.

5. Лекция **В. Г. Яхно**. «Динамика нейроноподобных моделей и процессы “сознания”» дает взгляд на проблемы сознания с других позиций — математического моделирования, нацеленного на создание средств описания динамических процессов обработки информационных сигналов. Эта лекция продолжает рассмотрение круга вопросов, затрагивавшихся в предыдущих лекциях автора [13, 14].

6. Лекция **В. Г. Редько** «Проблема происхождения интеллекта и модели адаптивного поведения» развивает тему, рассматривавшуюся автором в [15]. В ней указанная проблема рассматривается с позиций эволюционного подхода, а в качестве аппарата для ее изучения предлагается использовать динамически изменяющиеся модели адаптивного поведения.

7. Лекция **игумена Феофана (Крюкова)** «Модель внимания и памяти, основанная на принципе доминанты. Часть II: Попытка примирения конкурирующих теорий долговременной памяти», как это видно из ее названия, продолжает рассмотрение круга вопросов, поднятых в предыдущей лекции автора [16]. В лекции *А. М. Иваницкого* отмечалась тесная связь сознания с вниманием и памятью, указывалось на то, что «... осознается только то, на что обращается внимание». Данное обстоятельство обуславливает важность темы внимания и памяти в контексте сознания — одной из центральных тем конференции «Нейроинформатика-2006».

8. Лекция **Л. Б. Литинского** «Параметрические нейронные сети и другие архитектуры на их основе» завершает рассмотрение темы, начатой в лекции [17]. Рассматриваются работы, связанные с ассоциативными нейронными сетями, прежде всего — с параметрическими нейронными сетями. Акцент при этом сделан на то, чтобы показать основные идеи и принципы, лежащие в основе сетей данного класса.

* * *

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 [18] в списке литературы в конце предисловия). Эта библиотека, созданная и развиваемая отделением фирмы NEC в США, содержит уже около 800 тыс. публикаций, причем это число постоянно и быстро увеличивается за счет круглосуточной работы поисковой машины.

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 [19], недавно открывшийся поисковый сервис Google Scholar [20], а также портал научных вычислений [21].

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 [1–8].

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 важнейшими ее «соседями», как нейробиология, нелинейная динамика, численный анализ и т. п.

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

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. Терехов С. А. Нейросетевые аппроксимации плотности распределения вероятности в задачах информационного моделирования // В сб.: «Лекции по нейроинформатике». Часть 2. – М.: Изд-во МИФИ, 2002. – с. 94–120.
 10. Терехов С. А. Введение в байесовы сети // В сб.: «Лекции по нейроинформатике». Часть 1. – М.: Изд-во МИФИ, 2003. – с. 149–187.
 11. Терехов С. А. Нейро-динамическое программирование автономных агентов // В сб.: «Лекции по нейроинформатике». Часть 2. – М.: Изд-во МИФИ, 2004. – с. 111–139.
 12. Терехов С. А. Адаптивные нейросетевые методы в многошаговых играх с неполной информацией // В сб.: «Лекции по нейроинформатике». – М.: Изд-во МИФИ, 2005. – с. 111–139.

13. Яхно В. Г. Процессы самоорганизации в распределенных нейроноподобных системах: Примеры возможных применений // В сб.: «Лекции по нейроинформатике». – М.: Изд-во МИФИ, 2001. – с. 103–141.
14. Яхно В. Г. Нейроноподобные модели описания динамических процессов преобразования информации // В сб.: «Лекции по нейроинформатике». Часть 1. – М.: Изд-во МИФИ, 2004. – с. 136–150.
15. Редько В. Г. Эволюционная кибернетика // В сб.: «Лекции по нейроинформатике». Часть 1. – М.: Изд-во МИФИ, 2002. – с. 29–65.
16. Игумен Феофан (Крюков) Модель внимания и памяти, основанная на принципе доминанты // В сб.: «Лекции по нейроинформатике». Часть 2. – М.: Изд-во МИФИ, 2002. – с. 66–113.
17. Крыжановский Б. В., Литинский Л. Б. Векторные модели ассоциативной памяти // В сб.: «Лекции по нейроинформатике». Часть 1. – М.: Изд-во МИФИ, 2003. – с. 72–85.
18. NEC Research Institute CiteSeer (also known as ResearchIndex) — Scientific Literature Digital Library.
URL: <http://citeseer.ist.psu.edu/cs>
19. The Archive arXiv.org e-Print archive — Physics, Mathematics, Nonlinear Sciences, Computer Science.
URL: <http://arxiv.org/>
20. Google Scholar.
URL: <http://scholar.google.com/>
21. 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

С. А. ТЕРЕХОВ
ООО «Нейрок Техсофт»,
г. Троицк, Московская обл.
E-mail: alife@narod.ru

ТЕХНОЛОГИЧЕСКИЕ АСПЕКТЫ ОБУЧЕНИЯ НЕЙРОСЕТЕВЫХ МАШИН

Аннотация

В лекции представлен очерк эффективных методов практических вычислений в задачах обучения нейросетевых и других статистических моделей. Рассматриваются как особенности часто встречающихся информационных задач, так и алгоритмический «инструментарий». Значительное внимание уделено намечающейся стандартизации в области обучающихся вычислительных машин. В приложении приведен краткий обзор стандартизованного представления моделей на основе XML-структур языка PMML.

S. A. TEREKHOFF
Neurok Techsoft, LLC,
Troitsk, the Moscow Region
E-mail: alife@narod.ru

TECHNOLOGICAL ASPECTS OF LEARNING FOR NEURAL NETWORK MACHINES

Abstract

This Lecture introduces a family of methods for effective practical neural and statistical computations. Both, the peculiarities of information processing tasks and algorithmic toolboxes are considered. Significant attention is paid to standardization of learning machine models. A short review of Predictive Models Markup Language, an XML application, is also presented.

Введение: Технологии обучающихся машин для анализа данных

В основе твоих размышлений и рассуждений должны лежать данные, которые проверил ты сам.

Дао Toyota

Технология в энциклопедическом определении это «... совокупность методов обработки, изготовления, измерения состояния, свойств, формы сырья, материала или полуфабриката, осуществляемых в процессе производства продукции». В компании Toyota, производящей машины, использование технологий базируется на принципе «новая технология должна поддерживать человека, процесс и ценности».

Искусственная нейронная сеть — это тоже специфический вид *обучающихся* машин, предназначенных для статистического прогнозирования и систематизации больших объемов информации. Создание таких машин — это производственный процесс, сырьем для которого служат данные¹, ресурс данных является определяющим² в производственном процессе. Продукция или товар — это компьютерные программы или их компоненты, электронные и оптические схемы и чипы, а также результаты их использования при практической обработке данных. Товаром также являются и *сами технологии*, позволяющие производить и тиражировать обучающиеся машины.

Под обучаемой машиной в таком, утилитарном, смысле понимается такая машина или ее программная модель, производство которой допускает максимально гибкое использование сырья (т. е. данных), при этом значительная часть³ производственного процесса *выполняется самой создаваемой машиной*.

На западе, в США, ключом к успеху принято считать формализацию

¹ Данные понимаются в широком смысле — числовые, знаковые и текстовые, мультимедийные и др.

² Один из гигантов, компания Yahoo!, первой ввела специальную должность — директор по данным (Chief Data Officer). Им стал *Usama Fayyad*.

³ Идеалом служит ситуация, когда в процессе производства человек лишь формулирует цели и предоставляет источник *данных*, а все остальное делает сама машина. Известные автору примеры самовоспроизводящихся программ, к сожалению, не преследуют иную цель, кроме самовоспроизводства.

и документирование как самой технологии, так и процесса ее совершенствования. Это позволяет снизить стоимость владения технологией, а также относительно безболезненно обновлять кадровый состав. При высокой степени формализации многие этапы технологического процесса могут выполняться специалистами более низкой квалификации (более дешевыми и менее требовательными). В японских фирмах (особенно в Toyota) считают, что технология, прежде всего, должна быть хорошо проверенной и содержать «встроенное» в нее качество итоговой продукции. Успех технологии — не в документах, а в людях.

При современном уровне развития отрасли обучающихся машин многие технологические этапы просто немыслимы без людей — носителей этих технологий. Однако, если сбросить со щита аспекты стандартизации, повторяемости и доказательности свойств обучения, то использование нейронных сетей рискует оказаться непомерно дорогим для большинства потребителей. В области обучения машин приемлемым, по-видимому, можно считать такой уровень формализации технологии, при котором *этой технологии* можно обучать специалистов (не путать с обучением *нейросетевым алгоритмам* и архитектурам!).

Предыдущие лекции автора [8–10] ограничивались вопросами теории и алгоритмов информационного моделирования. Данная лекция адресована, прежде всего, начинающим специалистам, которые разрабатывают⁴ технологии моделирования и прикладные обучающиеся системы. Автор надеется, что лекция будет также полезна и специалистам, использующим или внедряющим в своих компаниях нейросетевые и информационные решения.

В этой лекции немного формул, поскольку она, в основном, содержит рекомендательные положения и примеры, относящиеся к технологическим аспектам моделирования и обучения моделей. Значительная часть материала относится не только к нейросетевым прикладным алгоритмам, но и другим статистическим методам с обучением, причем особое внимание уделено симбиозу подходов. При этом автор не отклонился от своего принципа подробного изложения в каждой лекции одного из современных

⁴ Для читателей, заинтересованных, в основном, конкретными нейросетевыми архитектурами и методами их обучения можно порекомендовать вводный курс лекций автора [15], URL: <http://alife.narod.ru/>, а также серию издаваемых в МИФИ сборников по материалам лекций Школы-семинара «Современные проблемы нейроинформатики». В конце 2005 года в издательстве «Вильямс» выходит перевод классической монографии Саймона Хайкина «Нейронные сети». Не пропустите!

алгоритмов; здесь это метод SVM (Support Vector Machine).

Первый раздел лекции вводит в проблематику практических задач, для которых предназначены обучающиеся машины, обсуждается специфическая «трудность» этих задач. Далее рассматриваются особенности самих машин и алгоритмов, отличающие поисковые разработки от производственных вариантов. Даются практические рекомендации по «портфелю» алгоритмов, которые в совокупности могут обеспечить достаточно полный анализ прикладной задачи. Некоторые элементы технологий обучения и тестирования иллюстрируются на примерах конкурсных задач классификации (WCCI 2006). В приложении к лекции дан краткий обзор стандартизованного XML-языка описания моделей обучающихся машин PMML (Predictive Model Markup Language) и обсуждаются преимущества стандартизации моделей. Как обычно, лекция завершается списком литературы, преимущественно доступной в сети Интернет, а также учебно-исследовательскими задачами, которые автор готов обсудить по электронной почте.

Задачи, которые решают нейронные сети

Практические потребности в обучающихся машинных методах обработки информации можно условно разбить на две большие группы. К первой относятся задачи поиска закономерностей в имеющихся данных, компактное аналитическое описание *уже известной* пользователю информации. Это направление ассоциируется с термином «промысел данных» (data mining). Вторая группа задач связана с прогнозированием значений *будущих* наблюдений. Иногда только это, второе, направление относят к области обучения машин (machine learning).

Между этими направлениями нет принципиального антагонизма, ведь алгоритмы, моделирующие известные данные, могут использоваться и для предсказаний, с другой стороны, обоснование прогнозов обучающимися машинами возможно, во многом, только путем статистических экспериментов на имеющихся к этому моменту данных. Поэтому в лекции под обучением машин будут подразумеваться общие для обоих направлений принципы.

Далее будут рассмотрены основные типы информационных задач. Нужно сразу отметить, что формальное распределение всех информационных задач «по полочкам» также выглядит искусственным, и этот стиль изложе-

ния, скорее, дань традиции.

Принципиально то, что заказчики и потребители решений, различают разные задачи по их *целевому назначению*, а не по используемым типам алгоритмов. Очень трудно внедрить в производство «систему классификации клиентов банка», но можно и нужно внедрять «систему снижения расходов банка за счет дифференцированного обслуживания разных групп клиентов». Разница здесь отнюдь не в названии! Целевая формулировка принципиально влияет на критерии оптимальности требуемой обучающейся машины и предполагает такую математическую постановку проблемы, при которой результат может быть встроен в имеющийся технологический или бизнес-процесс.

В практике автора встретился следующий отрицательный пример. В разработке требовалось сегментировать предприятия и отделы сети клиентских услуг по наборам услуг, наиболее востребованным клиентами в каждой группе предприятий. Определение цели такой сегментации было отложено заказчиком «на потом». В результате, стремясь к максимальной устойчивости системы, надежному выявлению всех типов имеющихся предприятий, объяснению и прогнозированию структуры их прибыли, было выявлено около 50 групп. Система позволяла удобно представлять результаты работы визуально и показывала высокую точность при классификации вновь вводимых предприятий. Однако перед этапом внедрения выяснилось, что структура взаимоотношений с поставщиками, а также логистическая организация сети допускает дифференцированный подход к управлению не более, чем пятью категориями предприятий. Более глубокая дифференциация бизнеса на данном этапе противоречит отраслевому способу производства и из-за скрытых потерь и необходимости уменьшения объемов партий поставок экономически не целесообразна. Замечательный робастный классификатор с инновационными алгоритмическими достижениями был положен на полку⁵.

Различные примеры прикладных задач в разных контекстах обсуждаются по всему ходу лекции.

⁵Разумеется, впоследствии разработанная технология использовалась в нескольких успешных проектах, но первый ее заказчик остался неудовлетворенным.

Задачи классификации

Обучаемая машина при решении задачи классификации относит каждый вектор данных к одному из заранее выбранных классов. В естественно-научном смысле *класс* — это совокупность объектов, выделенных по некоторому набору признаков. Если признаки классов четко определены и легко устанавливаются у всех объектов, то отнесение объекта к классу составляет простую логическую процедуру. Такая процедура может быть выполнена программируемой машиной-автоматом.

Необходимость в *обучаемых* машинах возникает тогда, когда объекты описываются большим множеством опосредованных и ненадежно наблюдаемых (зашумленных и противоречивых) признаков, и путем логического анализа установить принадлежность каждого объекта к одному из классов не представляется возможным. Вместе с тем, имеется набор объектов, для которых принадлежность к классам уже каким-то образом установлена, например, по факту свершения некоторого события с этим объектом в прошлом. Этот набор объектов с известными классами играет роль *обучающей выборки*. При обучении машина модифицирует свою структуру или параметрическое описание, с целью снижения ошибки классификации известных данных до такого уровня, при котором *ожидаемая* ошибка классификации будущих новых примеров будет минимальной.

Поскольку основное свойство классов — формальное описание точными признаками — в реальности утрачено, то в прикладных задачах термин *класс* может трактоваться самым широчайшим набором способов. Под выбором класса может пониматься ответ на вопрос — убедит ли покупателей шампуня новый рекламный ролик, вырастет ли завтра курс ценной бумаги, проводится ли покупка в интернет-магазине по контрафактной кредитной карточке, и множество других вопросов, обращенных к *будущим* свойствам или возможным событиям с классифицируемыми объектами. Именно направленность в будущее составляет главную ценность обучаемых машин для делового заказчика. Целевая установка для машины — *точность*.

Впрочем, остаются также и задачи классификации уже имеющихся объектов или примеров. Здесь, в основном, целевая потребность состоит в автоматизации рутинного ручного труда, а основной целью, помимо точности, выступает *экономия времени*.

Классификация является самой фундаментальной и наиболее ясно воспринимаемой задачей в области обучения машин. Минимальный шаг в переходе от *программируемых* автоматов и компьютерных программ с пред-

писанной функциональностью к *обучаемым* машинам и программам состоит во встраивании обучаемого классификатора, автоматически выбирающего одну из заранее подготовленных программ. Классификатор в таких системах принимает решение на основе вектора *внешних* наблюдаемых признаков той ситуации, в которой сейчас находится машина.

Нужно отметить, что весомое большинство используемых на практике обучающихся систем, которые сами потребители называют *интеллектуальными*, сегодня не пошло далее этого минимального шага. Более того, осторожные производители, зачастую доверяют классификаторам только тогда, когда, фактически, любая из исполняемых программ не приведет к аварии или другому недопустимому поведению машины. Классификатор лишь позволяет выбрать либо более экономную, либо более «комфортную» программу в данной ситуации, повышая качество потребительских свойств результата, но не определяя их суть. В таких приложениях классификатор, по существу, является лишь опционной компонентой, и этот «интеллект» можно без больших потерь отключить.

Такова реальность, и разработчики технологий обучаемых машин должны ее учитывать.

Совершенствование автоматике автомобиля. В процессе движения автомобиль может снабжаться дополнительными датчиками, измеряющими такие параметры, как химический состав выхлопов, вибрации механизмов, поля температур узлов и др. Вектор наблюдений обрабатывается бортовым классификатором состояний, результат классификации используется для выбора режимов подачи топлива и управления передачей.

Что составляет суть «интеллектуальности» машины или программы, содержащей обучаемый классификатор? Такая программа получает новые степени свободы за счет возможности использования дополнительной плохо формализованной информации из внешнего мира, которая без блока обучения вынужденно игнорируется.

При согласовании постановки задачи классификации с потребителями необходимо убедиться в следующих позициях:

- Для обучения системы имеется достаточный объем достоверных обучающих данных, и, при необходимости, есть возможность собрать дополнительные данные. На практике обучение рекомендуется проводить на последовательно увеличивающихся выборках данных, что позволяет ответить на вопрос о достаточности объема экспериментально. При росте числа примеров оптимальная сложность классификатора также растет.

- Данные должны содержать примеры для *всех* затребованных классов. На практике могут встречаться ситуации, когда у заказчика имеются примеры только одного класса, и требуется отличить этот класс от всего остального. Такая задача должна ставиться, как задача оценивания области, занятой данными класса в пространстве признаков (нахождения *носителя* класса).
- Определены условия, критерии, и данные для тестирования системы. Заказчик может проводить также независимое тестирование разработанной системы самостоятельно, с использованием наборов данных, составляющих его интеллектуальную собственность. В некоторых случаях результаты такого тестирования могут составлять важную промышленную тайну, охраняемую от конкурентов. Вы можете быть и не оповещены даже о факте внутреннего тестирования, но результаты согласованных *базовых* тестов должны быть доступны. В противном случае, невозможно совершенствование системы.
- Определено место задачи классификации в технологическом или производственном процессе у потребителя. Система классификации должна иметь возможность получить входную информацию той же структуры, что и при обучении и тестировании, и определен способ, как и *когда* будет извлечен и использован результат. «Когда» здесь также является важным. Нетрудно представить ситуацию, в которой примеры для классификации поступают в систему потоком, скажем, один пример в 0.001 с. Классификатор по итогам тестирования имеет высокую точность в 99%. Если при ошибочной классификации в использующем классификатор приборе подается звуковой сигнал или вспыхивает лампочка, то она будет непрерывно гореть!
- Применение обучаемого классификатора должно быть обосновано. Факт наличия программы или алгоритма у разработчика и абстрактное стремление к инновациям не является достаточным основанием! Необходимость применения классификатора должна быть ясно осознана потребителем. Исключение составляют случаи, когда обучаемая машина просто экономнее или более производительна, а потери от неконтролируемых статистических ошибок невелики.

Основная постановка задачи классификации обычно формулируется для случая двух классов. При большем числе классов задача может быть сегментирована на бинарные подзадачи различения каждого класса от всех остальных, либо различения каждой пары классов друг от друга, с после-

дующим голосованием. Многие типы информационных задач могут рассматриваться, как варианты классификации с несколькими классами.

Аппроксимация данных

Задача с несколькими дискретными исходами представляет собой задачу классификации. Если число возможных вариантов велико или непрерывно, то обучаемая машина имеет дело с аппроксимацией или регрессией данных. Результатом такой машины является функциональная зависимость выхода от вектора входов.

При формулировке задачи регрессии нужно учитывать, что получаемая зависимость следует из данных только в вероятностном смысле. Искомая функциональная связь, в причинно-следственном смысле, может в действительности и не существовать, либо реальности соответствует функция, зависящая от еще каких-то переменных, которые отсутствуют в имеющихся данных.

Вследствие конечности набора данных, на практике трудно различить две ситуации, когда дисперсия регрессионной зависимости вызвана шумом в данных, и когда она обусловлена не учетом важных факторов. В последнем случае, модель данных может в новых условиях вводить потребителя в серьезное заблуждение, хотя формально статистические критерии достоверности выявленной зависимости могут быть удовлетворены.

Еще один подводный камень в задаче аппроксимации заключается в возможной неравномерности распределения ошибки в пространстве признаков. Потребности заказчика, использующего модель, могут в течение длительного времени быть сосредоточены в какой-то относительно небольшой области пространства. Это совершенно естественно — например, происходит отработка конкретного режима технического устройства в ограниченной области параметров. Если ошибка модели *в этой области* велика, то возникают неприятности, хотя в целом, на полном корпусе данных, модель удовлетворяет всем выставленным требованиям по точности.

Существуют регулярные способы избежать этой проблемы. Для этого при обучении машины не следует ограничиваться оцениванием только математического ожидания значения функции в точке — что, например, делает аппроксимирующая нейронная сеть, уменьшающая квадрат ошибки. Одновременно с моделью среднего может обучаться и модель, аппроксимирующая локальную дисперсию и более высокие моменты распределения

невызок. При этом совместное обучение максимизирует функцию правдоподобия (likelihood) в выбранной параметрической форме, с учетом статистики распределения шума. Математические вопросы обучения такой модели рассматривались в лекции [25]. В итоге, потребитель информируется о фактическом уровне ожидаемой точности в области интересов.

Тестирование регрессионных моделей является более сложным процессом, в сравнении с классификаторами. Особенно это касается способов использования аппроксиматора, связанных с его дифференцированием. Примером такого использования являются задачи управления, где нейронная сеть обучается модели *отклика* управляемой системы, а применяется для оценки *якобиана* выходных переменных по входам. Приближение функции не означает сходимость в приближении ее производных, если не приняты соответствующие меры⁶. Потребитель должен быть об этом четко предупрежден.

Вообще, при высокой размерности данных разумно избегать постановки задачи в форме непрерывной аппроксимации, если можно ограничиться задачей классификации с несколькими классами. Классы соответствуют попаданию значений прогнозируемой функции в определенные диапазоны значений.

Заказчик может предлагать постановку в форме регрессии просто исходя из того, что выходные значения данных принимают произвольные значения (обычно из некоторого отрезка). При обсуждении же *целей* создания обучаемой машины устанавливается, что *использование* разработки состоит в принятии конечного числа решений при достижении прогнозируемой переменной некоторых пороговых уровней (цены, доходности, прочности, массы, размера области коррозии и т. п., в зависимости от приложения). В таких условиях применение классификатора обеспечит более устойчивое и робастное к шуму решение.

Кластеризация и визуализация данных

В практике возникают задачи с данными, основной корпус которых не содержит меток классов. Здесь потребителя интересуют вопросы о самом

⁶Одновременная аппроксимация нейронной сетью и функции, и ее производных по дискретному набору зашумленных значений *только* самой функции многих переменных представляет собой серьезную математическую проблему. Приложения таких алгоритмов связываются с обратными задачами и задачами управления. Аспиранты, обратите внимание.

количестве возможных классов и общей структуре данных.

Анализ потребительских корзин. Многочисленными исследованиями установлено, что мы с вами, как покупатели товаров в супермаркетах, магазинах косметики, аптеках и т. п. действуем согласно некоторому набору поведенческих сценариев и предпочитаем покупать товары или пользоваться услугами в достаточно устойчивых сочетаниях. Однако, для категорий покупателей разных торговых сетей типичные «корзины» покупок могут значительно различаться. Это обуславливает потребность в проведении специализированных исследований и, часто, разработку индивидуальных алгоритмических решений для конкретных заказчиков. Проблема состоит в выявлении групп схожих наборов покупок в базах данных кассовых транзакций или данных маркетинговых опросов. При этом «векторы» покупателей являются крайне разреженными (при ассортименте в несколько тысяч наименований, одна покупка может содержать 3–30 товаров). Они также могут частично сопровождаться метками классов, такими как, участвует ли покупатель в программе скидок, или имеет ли он карточку постоянного покупателя, выбирает ли товары по рассылаемым каталогам, или пользуется еще какими-то преимуществами современных маркетинговых технологий. Конечная цель внедрения обучаемых систем анализа данных состоит в упрощении процесса управления поставками, снижении складских запасов, уменьшении потерь при продаже скоропортящейся и дорогостоящей продукции, и, разумеется, повышении комфорта покупателей, что положительно сказывается на устойчивости и расширении бизнеса.

Обучение машины производится *без учителя*, поскольку его сигналы отсутствуют, либо не полны или не достоверны. В задачах подобного типа основное внимание нужно уделять статистической устойчивости выявленных кластерных образований в массиве данных. С потребительской точки зрения, решение должно сопровождаться наглядной визуализацией результатов — ведь при помощи машины заказчик, возможно, впервые наблюдает целостную картину данных.

При визуализации решается проблема «упаковки» многомерного набора признаков в двумерное пространство экрана компьютера или листа отчета. Однозначного наилучшего во всех смыслах решения этой задачи не существует, и в практике используются различные приближения — нейросетевые карты самоорганизации Кохонена [5], методы главных или независимых компонент [6], и другие методы, устанавливающие одностороннюю связь между метрическими отношениями в многомерном пространстве с двумерными координатами. Одно из простейших решений состоит в применении отображении Саммона [5], предложенного еще в 60-х годах. Карта

Саммона строится путем оптимизации функционала согласования относительных расстояний между центрами кластеров в исходном многомерном и двумерном пространстве:

$$Q(\vec{x}) \sim \sum \frac{[D(\vec{X}_i - \vec{X}_j) - d(\vec{x}_i - \vec{x}_j)]^2}{D(\vec{X}_i - \vec{X}_j)^2}.$$

Здесь большие буквы относятся к многомерным, а малые — к двумерным координатам кластеров. Оптимизация проводится по значениям двумерных координат. Хотя задача построения такой карты относительно трудоемка и не масштабируется на большое число кластеров, она служит удобным подспорьем в ежедневной работе.

Особо нужно остановиться на проблеме визуализации многомерных данных, изменяющихся во времени (многомерных временных рядов). Здесь цель состоит не в группировке схожих состояний, а в кластеризации *схожих сценариев изменения состояний*.

Анализ динамики складских запасов. Снижение непроизводительных затрат на хранение излишков запасов и убытков, связанных с недостатком сырья или товара на складе, в магазине, или на участке конвейерной линии, требует понимания, как устроена динамика потребления запасов. Выявление схожих сценариев потребления позволяет производить пополнение складов «пакетами» однотипно используемых ресурсов, что стабилизирует отношения с оптовыми поставщиками и упрощает логистику. Обучаемая система призвана выявить паттерны схожей динамики на разных масштабах времени, определяемых технологическими процессами предприятия.

Решение такой задачи может основываться на построении цепочки кластерных структур. Первичная карта кластеров объединяет схожие состояния, безотносительно моментов времени их возникновения. Динамика процесса на первичной карте выглядит, как последовательные «перескоки» вектора состояния из кластера в кластер. Для заданного масштаба времени собирается статистика таких перескоков (в виде частот посещения кластеров, или частот переходов между парами кластеров). Гистограммы, соответствующие выбранной статистике, служат *входными* векторами для следующей, *вторичной*, кластерной карты. Вторичная карта объединяет схожие гистограммы, которые являются отражением схожих типов динамики. Процесс построения цепочки карт, при необходимости, может быть продолжен.

Построенные машиной визуализируемые кластерные структуры могут для наглядности снабжаться метками тех примеров, для которых такие

метки известны. Приписывание наиболее часто встречающейся метки всем примерам, попадающим в данный кластер, есть, суть, первое приближение к решению уже обсуждавшейся задачи классификации.

Прогнозирование временных рядов и оценивание рисков

Общим свойством этих задач является то, что запрашиваемый результат заведомо носит вероятностный характер, и это четко осознается потребителем. Цель обучаемой машины состоит в предсказании распределений вероятности следующего или нескольких будущих состояний динамики системы или процесса. При формулировке задачи важными являются две посылки. 1) Предыдущая история может быть суммирована в виде вектора состояния, процесс эволюции которого является марковским. Это означает, что распределение вероятности сценариев будущего определяется только текущим вектором состояний. 2) Справедливо предположение о схожести динамики будущего, если она стартует из близких состояний настоящего. Например, предположение о том, что рынки ценных бумаг схожим образом реагируют на похожую информацию, а клиенты, берущие кредит, имеют одинаковые причины и мотивы для его потенциального невозврата, если их финансовые, социальные и другие параметры одинаковы.

Проверка выполнимости этих требований и связанных с ними выбор переменных вектора состояния составляют основную сложность задачи прогнозирования. Если вектор признаков, отражающих базовые свойства прошлой истории финансового ряда, или составляющих содержательное описание клиента банка, уже построен, то задача прогнозирования сводится к классификации векторов или, реже, аппроксимации вектор-функций.

Часто набор признаков ограничивается естественными возможностями заказчика по сбору данных о клиенте или рынке. Тогда задача обращается в плоскость поиска наиболее достоверной степени подробности прогнозируемого распределения вероятности, при ограничениях на информативность входных векторов. Методы синтеза обучаемой машины могут включать алгоритмы поиска оптимума с ограничениями.

Подробность представления распределения вероятности должна учитывать также цели и способ использования потребителем. Так, риски неблагоприятных исходов оцениваются интегралами «хвостов» распределений, точность же представления основной массы типичных примеров не существенна и не будет востребована.




Рис. 1. «Плохой» прогноз финансового временного ряда при высоком уровне корреляции предсказываемой и фактической доходности

На рис. 1 приведен схематический пример результатов работы системы прогнозирования рынка, когда формальные критерии точности противостоят практическим потребностям. Прогнозы доходности при ее высоких абсолютных значениях, представляющие основной интерес для трейдера или управляющего портфелем, ошибочны даже с точностью до знака. Между тем, «прекрасные», с точки зрения исследователя, результаты и высокий коэффициент корреляции обусловлены высокой точностью прогнозов для случаев с малой доходностью, т. е. там, где это никому не нужно.

К задаче оценивания рисков мы еще вернемся по ходу лекции.

Другие задачи

Приложения обучаемых машин полны также и другими задачами, которые могут быть напрямую и не связаны с прогностическим анализом данных. Среди них — оптимизация суррогатных моделей сложных технических систем, использование нейросетей, как пробных функций в вариационных математических постановках задач математической физики. Имеются зада-

чи ремонта данных, выявление выбросов и расстройек динамики временных рядов. Важное место занимает оптимизация при обучении с подкреплением, с попутным решением сторонних практических задач. Уже отмечалась задача управления, которая в ряде практических случаев может сводиться к выбору одного из режимов или одной из программ управления.

Для получения разносторонней картины имеющегося многообразия применений можно попробовать⁷ задать вопрос типа “Machine learning applications” поисковой системе Google.

Почему информационные задачи сложны?

Программирование машин относится к одному из самых сложных видов созидательной деятельности. Программирование *обучаемых* машин, по теоретическому замыслу, должно было бы стать более простым для человека — ведь значительную часть работы берет на себя сама машина. На деле, аппетит приходит во время еды, и повсеместное внедрение компьютеров и других автоматов, смещает тяжесть проблем в иную, системную плоскость. Круг потребителей машин существенно расширился, повысились требования к надежности, простоте управления и, главное, интуитивной «предсказуемости» того, как должна была бы вести себя машина, если бы на ее месте был я⁸.

«Золотое время», когда модели обучаемых машин не покидали стен научных лабораторий и компьютеры разработчиков-ученых, уходит. В исследовательских условиях в центре внимания были собираемые вручную таблицы чисел, результаты использовались при проведении экспериментов на соседнем стенде, и все изготавливалось в штучных количествах.

Если миллионы машин каждое мгновение решают миллионы задач классификации в причудливой смеси физической и виртуальной реальности, то все статистически достоверные и недостоверные события обязательно происходят, все данные, которые могли быть неполными или испорченными, обязательно такими окажутся, а чудеса с данными случаются каждые 10^{-3} секунды. Реально они будут происходить гораздо чаще, но мы с вами, с нашими скоростями обработки нервных импульсов, просто не сможем этого заметить.

⁷Нужен ли вам для ориентации в полученном наборе из 20 000 000 ссылок помощник? Им может стать обучаемая машина!

⁸А иначе зачем мне нужна такая непослушная машина?

Сложность создания обучаемых машин носит системный характер. Коснемся некоторых составляющих этой сложности, которые нужно учитывать уже сейчас.

- **Неполнота обучающих данных** и информации об их природе. Неполные данные — это отсутствие некоторых значимых входов или сигналов на имеющихся входах, неточные входные сигналы, недостоверные выходы. Статистика распределения данных всегда принципиально не полна.
- **Противоречивость данных** и другие источники информационного шума. Данные поступают от внешних сенсоров и систем накопления, передаются по неидеальным каналам, хранятся на неидеальных носителях. При росте объемов данных дополнительно вмешивается фактор времени. Часть признаков в векторах данных успевает устаревать к моменту поступления остальных фрагментов. Остановки и синхронизации при сборе данных не всегда допустимы, поэтому на практике мы имеем дело со смесью признаков и параметров, относящихся к изменяющимся объектам в непредсказуемые моменты времени. Такие данные почти наверняка содержат противоречия.
- **«Проклятие» размерности.** С ростом числа анализируемых признаков геометрия многомерных пространств работает против статистики. Можно было бы ожидать, что при разумном числе обучающих примеров достижимы близкие к теоретическим оценки вероятности правильной классификации вектора данных, так как в его окрестности имеется достаточное число близких примеров с известными классами [24]. Но в многомерных пространствах это не так. Например, даже для покрытия 10% объема 10-мерного куба требуется покрыть 80% длины каждого ребра. Таким образом, локальная статистика каждой области данных автоматически оказывается грубой.
- **Проблема масштабирования** алгоритмов. Задачу обучения классификатора для таблицы из 10 000 примеров и 10 входных признаков, по-видимому, нужно признать закрытой. Имеется большое число научных публикаций, в которых обоснованы устойчивые качественные алгоритмы обучения машин для таких масштабов. В свете практических потребностей первостепенное значение приобретают показатели роста вычислительной сложности и ресурсов требуемой памяти алгоритмов при увеличении числа содержательных обучающих примеров. Реальность такова, что даже линейный рост сложности по

числу примеров и размерности задачи начинает быть неприемлемым. Например, при обучении машины SVM (см. далее в лекции) на 1 000 000 примеров число получаемых базовых векторов памяти машины может достигать 10 000 для достижения сходимости валидационной ошибки. Такой размер классификатора оказывается нетехнологичным и по памяти и по скорости вычисления прогнозов.

- **Выбор модели.** Проблема выбора модели, обладающей преимуществами в точности решения задачи, является мета-проблемой, стоящей над задачей обучения. В идеале, обе задачи — и обучения, и оптимизации структуры должны решаться машиной самостоятельно и одновременно. Это лишь частично и приближенно выполнимо на практике, поскольку требования сходящейся точности обучения и оптимальности структуры не являются строго коллинеарными, и мы имеем дело с задачей многокритериальной оптимизации. Статистическое же сравнение множества моделей с целью выбора затрудняется проблемой масштабирования.
- **Проблемы безопасности и приватности.** Машина, выполняющая задачу от имени ее владельца, становится дополнительной угрозой возможности вторжения в его частную и деловую жизнь. Система классификации знает пароль доступа к источнику данных. Система управления заказами и покупками распоряжается финансовыми ресурсами и банковскими счетами, параметры которых она должна для этого в себе содержать. Это отдельная большая тема, выходящая далеко за рамки лекции, но не исключено, что именно проблемы безопасности (в разных смыслах) окажутся центральными при массовом внедрении обучаемых машин.
- **Технические и организационные сложности.** При массовом использовании обучаемых машин встает проблема технологического сопряжения с другими программными компонентами, машинами, сенсорными устройствами. Корень зла здесь в том, что все должно производиться, внедряться и сопрягаться очень быстро. Но до сих пор зарядные устройства мобильных телефонов не совместимы, а кодировки текстов в компьютере больше, чем языков, используемых людьми. И все тут.

На этом, позитивно-ободряющем, фоне мы далее переходим к обсуждению машинных моделей и технологий для решения информационных задач. По ходу изложения вопросы системной сложности неизбежно будут возникать вновь.

Нейронные сети, которые решают задачи

Название раздела несет, как минимум, двойную смысловую нагрузку — в нем сочетаются и математические методы, составляющие основу обучающихся машин, и наши с вами нейронные сети, играющие не последнюю роль при решении информационных задач. И хотя основное содержание касается, прежде всего, алгоритмов и машин, начнем мы именно с мнений людей.

Консалтинговой компанией KDNuggets проводятся регулярные опросы специалистов по многим базовым аспектам в области обучения машин. Один из периодических опросов связан с использованием в приложениях различных алгоритмов и технологий анализа данных. Основные результаты [1] последнего (2005 г.) опроса, в котором приняло участие 784 посетителя сайта, приведены ниже, в табл. 1. Вопрос формулировался так: «Какие технологии анализа данных вы используете наиболее часто?»

Методики нейронных сетей занимают место в середине таблицы, лидируют методы решающих деревьев. Однако, причина, по которой в лекции приведена эта таблица, конечно, не в том, чтобы при выборе метода для решения прикладной задачи руководствоваться рейтингами популярности. Таблица иллюстрирует тот факт, что в современной практике нет единого универсального средства для всех задач анализа данных. Поэтому в дальнейшем изложении мы остановимся на описании группы методов, сравнительное и совместное использование которых позволит увидеть особенности проблемы с разных сторон. Выбор, по-прежнему, остается субъективным и отвечает предпочтениям автора.

Вероятностные деревья для задач классификации

Классификатор входных векторов в форме иерархии правил, по-видимому, является самым наглядным и простым в использовании инструментом. Джером Фридман (Jerome Friedman), один из классиков в области статистического анализа данных, называет деревья правил «методом, который всегда должен находиться рядом, на полке» [24].

Существует несколько алгоритмов синтеза деревьев и вариантов «понимания» того, что является результатом их применения. Дерево может пониматься, как последовательный логический алгоритм с точками ветвления и гарантированным останом в одном из терминальных состояний (листьев). В другом варианте, дерево определяет геометрическую сегмен-

Таблица 1. Наиболее часто используемые технологии анализа данных

Технология или алгоритм	Количество «голосов»	%
Деревья решений/правил	107	14%
Кластеризация	101	13%
Методы регрессии	90	11%
Статистика	80	10%
Визуализация	63	8%
Нейронные сети	61	8%
Ассоциативные правила	54	7%
Методы оценок по ближайшим соседям	34	4%
SVM (методы минимизации структурного риска)	31	4%
Байесовы методы	30	4%
Анализ временных рядов и последовательностей	26	3%
Boosting (взвешивание и отбор данных для повышения точности комитетов классификаторов)	25	3%
Гибридные методы	23	3%
Bagging (усреднение прогнозов комитета моделей, обученных на выборках с возвратом)	20	3%
Генетические алгоритмы	19	2%
Другие	20	3%

тацию области многомерного пространства, занимаемой данными, на параллелепипеда, в пределах которых классифицируемые вектора относятся к одному классу.

Перечисленные трактовки весьма привлекательны и непосредственно воспринимаемы пользователями классификаторов. Но их особенность состоит в обращенности модели в *прошлое*, ориентации на объяснение данных, которые уже имеются к данному моменту.

Однако, если подходить к задаче классификации как к протяженному во времени технологическому процессу, при котором пользователи имеют дело с потоком *новых* примеров для классификации, более последовательной представляется вероятностная интерпретация алгоритма. Здесь дерево понимается, как модель условной плотности вероятности отнесения входного примера к одному из классов. Процесс классификации состоит в понижении условной энтропии распределения классов для данного примера при прохождении его по узлам дерева. Идеальная классификация состояла бы в достижении нулевой энтропии (полной определенности) в листьях.

Основанный на вероятностном подходе алгоритм построения дерева рассматривался в одной из предыдущих лекций автора [9]. Этот алгоритм может быть рекомендован, и как самостоятельная методика обучения машины задаче классификации. Здесь же нас, прежде всего, интересует вопрос, как метод деревьев технологически сопрягается с другими методами.

Во многих случаях использование классифицирующего дерева является экспресс-методом, *первым шагом* на пути получения окончательного решения. В практике решение почти всегда разумно начинать с применения дерева. Это вызвано как высокой вычислительной эффективностью, так и пониженными (в сравнении с другими методами) требованиями к предобработке данных. В частности, данные могут непосредственно обрабатываться без предварительного масштабирования, нормализации, с использованием тех размерных шкал, в которых они исходно представлены.

Например, при классификации свойств химических смесей, концентрации разных компонент могут описываться как в массовых, так и объемных единицах, при этом основные компоненты могут измеряться в граммах, а микродобавки — в других удобных единицах. Это упрощает первичный процесс прохождения данных и снижает вероятность ошибок на первых этапах, когда задача для исследователя является новой, и терминология между потребителем и разработчиком еще не полностью согласована.

Второй важный момент — дерево выявляет наличие противоречий в данных и позволяет получить оценку степени информационного шума в

данных. Эти показатели вычисляются на основе статистики «чистоты» листьев дерева. Наличие противоречивых примеров — когда одни и те же или близкие входные вектора относятся к разным классам — при обучении дерева не может быть устранено или «растворено» в результирующей модели (как, например, это происходит в нейронной сети). Соответствующие листья дерева в этом случае будут иметь остаточную энтропию, несмотря на малое число относящихся к ним примеров. Противоречия в последних, далее, легко выявляются (прямым просмотром).

Выявление ошибок и противоречий в данных является необходимым элементом любой технологии их анализа. Раннее информирование заказчика о реальном качестве данных позволит сэкономить уйму лишней работы на следующих этапах проекта — ведь часть противоречий в данных может возникать вследствие ошибок при их сборе, некачественной работы измерительного оборудования, недостоверной отчетности, или из-за ошибок в программном обеспечении сбора данных.

Третье достоинство вероятностных деревьев — возможность оценки сравнительной значимости признаков. По алгоритму построения дерева, решающее правило в каждом узле понижает суммарную энтропию условной вероятности при его применении. В каждом правиле задействован какой-то один признак. Уменьшение энтропии (прирост информации или *neg*-энтропии) измеряется количественно. В итоге, с каждым признаком ассоциировано суммарное уменьшение энтропии от всех правил, основанных на этом признаке. Входные признаки, указание значений которых приводит к значительному уменьшению энтропии, наиболее информативны.

Технологическая цепочка анализа данных обязательно должна включать оценки информативности признаков. Это не только позволяет построить более эффективные прогностические модели (см. Задачу 1), но и само по себе является важным результатом анализа. Иногда основная потребность заказчика как раз и состоит в том, чтобы ответить на вопрос, какие столбцы таблицы данных важны для прогноза, а сбор каких данных можно в дальнейшем не проводить. Результаты такого типа могут приводить к прямому экономическому эффекту.

Оценка кредитных рисков. Поиск значимых факторов находится в центре потребностей в такой, в последнее время ставшей особенно актуальной, проблеме, как оценка кредитных рисков. При решении задачи классификации клиентов по вероятности несвоевременного возврата кредита имеется «идеологическое» противоречие полноты и «прямоты» собираемой информации с достоверностью этой информации, особенно, когда вопросы касаются фактических уровней и источников доходов, из которых будет погашаться кредит. Часто косвенные вопросы, типа «насколько заранее Вы планируете отпуск и услугами каких турфирм пользуетесь?» дают для классификатора более точную информацию, нежели прямые вопросы о степени стабильности доходов. Важную роль здесь также играют вопросы приватности и другие юридические аспекты, поэтому при создании систем классификации для оценки рисков целесообразно проработку объема и состава собираемых данных проводить во взаимодействии экспертов из различных областей (в том числе и в области анализа данных).

Детальный анализ обученных вероятностных деревьев может дать много другой полезной информации (например, выделить области наиболее нестабильного поведения прогнозируемой переменной, указать интервалы изменений переменных, которые существенны⁹ для классификации).

Вместе с тем, алгоритмы на основе деревьев имеют и ряд специфических недостатков. Среди них [24] неустойчивость к изменению набора обучающих данных. Удаление или добавление нескольких примеров может существенно повлиять на структуру результирующего дерева, ошибки накапливаются при продвижении к листьям. Классические модели деревьев не позволяют построить гладкие приближения в задачах регрессии — вероятное значение прогнозируемой переменной меняется от ветви к ветви скачками. С точки зрения представимости функций моделями деревьев, затруднено выявление возможной аддитивной структуры функциональной зависимости. Если существенное поведение прогнозируемой величины определяется взвешенной суммой нескольких входных признаков, то этот факт не будет явно обнаружен. Это вызвано тем, что дерево на каждом уровне использует правила лишь с одной переменной.

⁹В быту, при измерении температуры тела, чаще всего нас интересует интервал в окрестности значения 36,6, а, скажем, точность измерения в диапазоне 37–38 не столь важна. В других задачах классификации такие интервалы и важные точки в значениях признаков не всегда заранее указаны и очевидны. Их нахождение может помочь потребителям модели целенаправленно изменить схему сбора данных, например, использовать для измерений более дешевое оборудование, или, наоборот, ввести дополнительные позиции в бланки запрашиваемой отчетности у дочерних отделений компании.

На практике задачи с аддитивной (или почти аддитивной) структурой могут возникать, когда компоненты входных векторов соответствуют высокой степени линейной независимости признаков. В таких задачах классы близки к линейно разделимым, и (часто к удивлению заказчиков) качественная классификация может быть получена простейшей нейронной сетью с 2–3 нейронами в скрытом слое. Решение же на основе дерева приводит к сложной иерархии трудно интерпретируемых правил. Поэтому проверку степени линейной разделимости классов также целесообразно включать на одной из ранних стадий разработки.

Таким образом, методы деревьев составляют важный элемент успешной аналитической технологии (особенно ее первых этапов), но в общем случае их разумно использовать в сочетании с другими подходами.

Методы кластеризации данных

Семейство алгоритмов кластеризации весьма обширно. Разнообразие обусловлено как особенностями постановок задач и типов обрабатываемых данных, так и базовыми статистическими принципами в основе алгоритма.

В наиболее общей форме задача кластеризации (таксономии) состоит в отыскании в массиве обучающих данных групп примеров (таксонов¹⁰), обладающих схожими групповыми свойствами. Последовательный подход в построении алгоритма кластеризации состоит в явном формулировании определенного целевого функционала качества с последующей его минимизацией.

Простейший функционал качества — суммарное по всем примерам расстояние от каждого примера до центра ближайшего к нему кластера в выбранной метрике. Этот функционал определен для условий, когда число кластеров K известно заранее. Переменными поиска являются координаты центров кластеров.

Минимизация функционала качества должна производиться по всем возможным распределениям N примеров по K кластерам. Это и определяет фундаментальную сложность задачи кластеризации. Даже если на возможные положения центров кластеров наложено дополнительное усло-

¹⁰ *Таксон* — группа дискретных объектов, связанных той или иной степенью общности свойств и признаков и благодаря этому дающих основание для присвоения им определенной таксономической категории.

вие точного совпадения центра с одним из примеров, число возможных решений равно числу сочетаний C_N^K .

Комбинаторные задачи такого типа не могут быть решены точно за полиномиальное время, поэтому все известные алгоритмы кластеризации являются *принципиально* приближенными, и от достижения точного минимума придется отказаться сразу (исключение могут составлять некоторые вырожденные задачи классификации на небольшое число классов).

Для некоторых алгоритмов удается доказать их сходимость (к одному из локальных минимумов), однако, учитывая приближенный характер решения, на практике часто используются и итерационные алгоритмы, сходимость которых теоретически не установлена. Алгоритм останавливается принудительно по числу итераций.

К такому классу алгоритмов относится, пожалуй, самый популярный алгоритм *K-средних* (k-means). Алгоритм стартует с K наудачу выбранных примеров из обучающего набора, на каждой итерации все примеры перераспределяются по степени близости к K выбранным примерам. После перераспределения центр каждого кластера помещается в «центр тяжести» его примеров, либо в точку примера, ближайшего к положению центра тяжести. Процесс повторяется либо до достижения наперед указанного числа итераций (*epoch* обучения), либо до состояния, когда распределение примеров по кластерам стабилизируется.

Для использования на практике предложен широкий набор вариантов улучшения этого базового кластерного алгоритма:

- Методы «отжига», стабилизирующие итерации и позволяющие достигнуть путем стохастического поиска более глубоких минимумов функционала качества (например, метод Тишби [2]).
- Методы с вероятностной принадлежностью примеров к кластерам. Оптимизация производится на основе EM-алгоритма [7]. В процессе итераций плотности распределения примеров по кластерам обужаются, что соответствует росту целевой функции правдоподобия или, в байесовой постановке, максимизации апостериорной вероятности объяснения обучающих примеров кластерами.
- Методы с принадлежностью примеров кластерам, определяемые нечеткими множествами, нечеткой логикой, а также интервальными и «мягкими» метриками.

Эти и другие модификации метода *K-средних* положены в основу промышленно используемых программных разработок, но полезно помнить,

что основные недостатки этого алгоритма — комбинаторная сложность, зависимость качества результатов от удачной начальной инициализации кластерной структуры и отсутствие глобальной сходимости — не устранены.

Проблема построения кластерной структуры при известном числе кластеров часто является подчиненной проблеме выбора наилучшего числа кластеров. Эта задача (которую иногда называют задачей *категоризации* данных) также может предшествовать построению классификаторов, поскольку она отвечает на вопрос о числе классов, на которые *объективно* разбиваются данные.

Поиск числа кластеров или классов также опирается на оптимизацию функционала качества. Поиск состоит в нахождении такой степени подробности кластерной структуры, при которой и уменьшение, и увеличение числа кластеров приводит к ухудшению качества кластеризации. С вероятностной точки зрения наиболее последовательным выглядит совмещение процессов построения кластеров с вариацией их числа. Для робастного поиска используются функционалы качества с регуляризацией (например, штрафами за излишнюю сложность структуры). С такими функционалами имеют дело популярные методы минимизации длины описания модели [3].

Различают два подхода к построению кластерных структур с изменяющимся числом кластеров — рост числа кластеров с расщеплением уже имеющихся, и наоборот, последовательное объединение (агломерация) отдельных примеров в мелкие группы, которые затем объединяются в более крупные кластеры. Второй подход обычно более устойчив, так как критерий объединения проще сформулировать в виде задачи оптимизации, нежели предложить эффективную эвристику для расщепления кластеров. При большом числе примеров вычислительно более эффективным является процесс роста путем расщепления.

Обучающаяся машина должна уметь «фотографировать» интересные кластерные структуры в процессе их роста. Потребителей обычно не устраивает какой-то один вариант кластерной структуры, для анализа нужно понимать внутреннюю структуру крупных кластеров.

Набор инструментов для анализа данных и построения обучающихся машин обязательно должен включать хотя бы один алгоритм кластеризации с возможностью изменения типа используемой метрики и поиском оптимальной кластерной структуры. Здесь важно учитывать, что в реальности данные могут образовывать несколько компактных структур на различных масштабах подробности. Это сопровождается наличием нескольких мини-

мумов у оптимизируемого функционала. Обратное также верно — данные могут и не образовывать четких кластерных структур вообще. В последнем случае можно остановиться на удобном для понимания результатов числе кластеров, обеспечивающих как достаточную подробность представления информации, так и отражающих общий характер пространственного расположения многомерных данных.

Эффективную кластеризацию обеспечивают гибридные методы с кластерной структурой в форме дерева решений [4]. В отличие от классификаторов, элементарное решающее правило в каждом узле дерева состоит в отнесении примера к одному из двух кластеров — потомков данного узла. Кластеризация далее продолжается до достижения одного из листьев, примеры которого, по построению, формируют компактный кластер. Итоговая кластерная структура имеет характер вложенных многомерных ячеек Вороного.

Гибридные методы классификации и кластеризации

При теоретическом рассмотрении принято различать задачи обучения машин с *учителем*, в частности классификацию в условиях, когда метки классов обучающих примеров известны, и обучение *без учителя* — кластеризацию примеров безотносительно их меток или с отсутствующими метками классов. В первой задаче искомой является условная вероятность класса при заданном примере, во второй задаче цель состоит в построении модели совместной (полной) плотности распределения примеров.

В приложениях эти задачи в чистом виде встречаются относительно редко, особенно когда компания-заказчик только приступает к систематическому анализу накопленных данных, либо, наоборот, когда уже проведено внедрение типовых решений на основе рыночных продуктов, и после использования базовых процедур классификации и/или кластеризации возникает потребность в дополнительном углубленном анализе данных и результатов.

Сформулированные при постановке задачи классы не обязательно являются в математическом смысле строгими для потребителя, а кластерный анализ может приводить к выявлению обособленных групп данных, для практического обслуживания которых целесообразно ввести новые дополнительные классы.

Даже если проблема ставится, как задача кластеризации, обучающие примеры (или их часть) могут иметь метки отношения к некоторой класси-

фикации. Естественным, ожидаемым для потребителя результатом работы алгоритма служит преимущественное попадание примеров одного класса в один или близкие кластеры. Полное игнорирование меток является отбрасыванием части существенной информации, которая в действительности имеется у заказчика.

Другой пример — собранные данные имеют метки классов, и рассматривается задача классификации. Однако, фактическая достоверность меток крайне не высока. Например, метки получены при «ручной» предварительной классификации с участием нескольких экспертов, применявших отличающиеся друг от друга нечетко сформулированные критерии определения классов. Классы могли быть назначены машиной, автоматически считывающей документы и использующей алгоритм распознавания образов, с ощутимой вероятностью ошибки. Встречается множество и других ситуаций, когда указанным классам примеров нельзя доверять безусловно.

В таких случаях целесообразно использовать гибридные подходы, сочетающие классификацию и кластеризацию. При этом «ведущим» выступает алгоритм кластеризации, так как метрические отношения близости входных векторов первичны по отношению к малодостоверным меткам классов. Можно выделить два варианта искомой гибридной технологии:

- *Априорное* использование меток классов и формирование кластерной структуры с преимущественным отнесением каждого примера к кластеру с примерами «дружественного» класса. К семейству таких методов относятся алгоритмы обучающегося векторного квантования (LVQ — learning vector quantization [5, с. 175]).
- Использование меток классов *апостериори*, путем «раскраски» готовой кластерной структуры. Для каждого кластера собирается статистика (гистограмма) частот встречаемости каждого класса. С учетом априорной вероятности классов, эта статистика служит оценкой плотности распределения условной апостериорной вероятности классов, определенной на всем пространстве данных.

В последнем случае рекомендуется использовать кластерную иерархию с отбором кластерных структур, максимизирующих апостериорную вероятность наблюдения классов. Полученный гибридный классификатор обладает ценным свойством — автоматически при классификации оценивается вероятность ее ошибки.

Оптимизация рисков при финансовом прогнозировании. В задачах управления портфелем финансовых активов разумная цель прогнозирования (предсказания будущего направления изменений цен, доходности на заданный период, оценивания будущей волатильности и др.) состоит не в создании оракула, знающего наперед, как поведет себя рынок, а в информационном обеспечении алгоритмов принятия инвестиционных решений. Гибридный классификатор, результатом работы которого является *распределение* вероятности будущих событий, позволяет вычислить суммарную вероятность (риск) неблагоприятных событий. Обоснованные управляющие решения далее принимаются с учетом анализа уровня рисков, а не благодаря «счастливому» точному прогнозу, выдаваемому таинственной нейронной сетью.

Рассмотренные здесь методы классификации деревьями правил и кластеризации с метрическими отношениями соседства принципиально основаны на моделировании плотности вероятности (условной или безусловной) в пространстве данных. Представление плотности является одним из фундаментальных принципов синтеза обучающихся машин [8].

В последнее время появилось много сообщений об успешном применении машин, основанных на иных принципах, в частности на моделировании *геометрической структуры* пространства обучающих примеров в окрестности границ классов. Основной представитель этого семейства — машины базовых векторов (дословно¹¹, «поддерживающих» векторов — SVM, Support Vector Machines). Методы SVM ранее не затрагивались в лекциях автора, поэтому рассмотрим их более подробно.

Машины базовых векторов (SVM)

Рассмотрение метода SVM мы начнем с задачи классификации множества примеров $\vec{x}_k \in R^m$, $y_k \in \{-1, 1\}$, $k = 1, \dots, n$ на два линейно разделимых¹² класса, задаваемых выходной переменной y . Решение этой задачи с использованием нейронной сети, состоящей из единственного нейрона, может быть получено градиентным алгоритмом минимизации суммарной квадратичной ошибки.

$$\hat{y}_k = \text{sign}(\vec{w} \cdot \vec{x}_k + b), \quad (1)$$

¹¹Хотя истоки метода SVM находятся в России, устойчивого эквивалента понятию support vector в отечественной литературе пока нет.

¹²Первоначальное представление об основных терминах, понятиях и алгоритмах обучения нейронных сетей можно получить из электронного учебника автора [15].

$$\Delta \vec{w}_k \propto \delta \cdot \vec{x}_k. \quad (2)$$

Соотношение (1) определяет базовую модель — пороговое решающее правило с весовыми параметрами (w, b) , поправки к которым при обучении (2) пропорциональны обучающим векторам и невязкам модели на каждом примере.

Суммирование поправок при стохастической оптимизации дает решение в виде взвешенной суммы *всех* обучающих векторов:

$$w = \sum_k \alpha_k \vec{x}_k. \quad (3)$$

Характер поведения решения изображен на рис. 2а. Векторы примеров в затененной области дают больший вклад в решение, но масса остальных векторов также влияет на значения параметров.




Рис. 2. Задача классификации множества примеров на два линейно разделимых класса: **(а)** разделение классов персептроном; **(б)** классификатор максимального зазора (maximum margin classifier)

Подход, предложенный еще в 60-70-х годах¹³ Владимиром Вапником [13], выделяет для описания решающего правила только векторы, находящиеся вблизи разделяющей границы. При этом решающее правило (рис. 2b) среди всех линейных классификаторов выделяет тот, который максимизирует «зазор» между крайними точками множеств. Векторы, лежащие точно на

¹³Как это, к сожалению, часто бывает, признание и широкое распространение метод нашел гораздо позже, только после зарубежных публикаций...

границах разделительной полосы, названы здесь базовыми (support vectors), а решение имеет вид линейной комбинации только базовых векторов:

$$w = \sum_{k \in \{SV\}} \alpha_k \vec{x}_k. \quad (4)$$

Окончательно классификатор произвольного примера x имеет вид взвешенной суммы скалярных произведений с базовыми векторами:

$$\hat{y}(\vec{x}) = \text{sign} \left[\sum_{k \in \{SV\}} \alpha_k \cdot (\vec{x} \cdot \vec{x}_k) + b \right]. \quad (5)$$

Важно понимать принципиальную разницу между формулами (3) и (4), первая из которых имеет статистическую природу, а вторая — геометрическую. Геометрическое решение тесно связано с классификацией *малых* множеств данных, когда статистические гипотезы о распределении могут оказаться несостоятельными.

В математическом и вычислительном плане, *трудная* задача оптимизации многомерной нелинейной функции при обучении нейросетевой модели заменяется *трудной* (но другой) задачей *выбора* из множества векторов тех, которые определяют геометрию границы. Как будет показано ниже, этот подход также соответствует определенной задаче оптимизации.

Как и алгоритм обучения нейрона, метод базовых векторов может формулироваться и для случая, когда точного линейного разделения классов нет. Из аналитико-геометрических выкладок, квадрат величины зазора между множествами обратно пропорционален квадрату нормы решения $\|\vec{w}\|^2$. Если допустить наличие ошибок, связанных с попаданием векторов в полуплоскость примеров другого класса, то оптимальный геометрический классификатор дается решением следующей задачи:

$$\min_{w, b, \xi} \|\vec{w}\|^2 + C \sum_{i=1}^n \xi_i, \quad (6)$$

$$\xi_i \geq 0, \quad y_i \hat{y}(\vec{x}_i) \geq 1 - \xi_i, \quad i = 1, \dots, n. \quad (7)$$

Коэффициент C , являющийся параметром алгоритма¹⁴, характеризует относительную роль штрафа за нарушения условий точной линейной делимости.

¹⁴У читателя может остаться законный вопрос, почему (в каком смысле?) максимизирующее зазор между классами решение является наилучшим с точки зрения классифи-

Большинство (?) практических задач классификации приводит к нелинейным границам классов, более того, области классов могут оказываться не выпуклыми и не односвязными. Следующее фундаментальное обобщение машины базовых векторов состоит в переходе к нелинейным решающим правилам.

Базовая идея такова: вместо рассмотрения задачи классификации в исходном векторном пространстве нужно перейти к пространству новых переменных *большой* размерности, в котором уже возможно построение линейного классификатора. Новые переменные связаны с исходными координатами нелинейными функциональными соотношениями

$$\varphi_j(\vec{x}), \quad j = 1, \dots \quad (8)$$

В новых координатах классификатор будет иметь вид:

$$\begin{aligned} \hat{y}(\vec{x}) &= \text{sign} \left[\sum_{j \in \{SV\}} \alpha_j \cdot \langle \varphi(\vec{x}) \cdot \varphi(\vec{x}_j) \rangle + b \right] = \\ &= \text{sign} \left[\sum_{j \in \{SV\}} \alpha_j \cdot K(\vec{x}, \vec{x}_j) + b \right]. \end{aligned} \quad (9)$$

Если внутреннее произведение в новых координатах вычислимо с помощью некоторой *ядерной* функции K , то система функций (8) формально может быть и бесконечной! Соответствующий математический аппарат гильбертовых пространств со скалярным произведением, порождаемым ядром ко времени выхода работ *В. Вапника* уже существовал¹⁵. В данном контексте существенно, что для получения линейного классификатора не требуется вычисление (и даже существование явного вычислимого вида) базисных функций и формальных сумм для их скалярных произведений, содержащих потенциально бесконечное число слагаемых. Все построения могут быть выполнены использованием одной лишь ядерной функции K .

кации новых векторов. В теории *В. Вапника* построены оценки верхней границы ошибки обобщения для классификационных алгоритмов, сходящиеся по вероятности. Наилучшим назван алгоритм, который минимизирует наихудшую верхнюю оценку ошибки (функционал структурного риска в терминологии Вапника). Оценки опираются на введенное в теории понятие VC-размерности (размерности Вапника-Червоненкиса) классификатора, описывающее его геометрическую сложность. Для ядерных классификаторов семейства SVM оптимизация структурного риска формально приводит к задаче (6)–(7).

¹⁵Теорию пространств, порождаемых ядрами (reproducing kernel Hilbert space) независимо разработали *N. Aronszajn* и *S. Bergman* в 1950 г.

В новых переменных прямая задача оптимизации (6)–(7) в явном виде содержит коэффициенты w разложения по базисным функциям. Для вычислений пригодна дуальная формулировка, которая выводится использованием стандартного лагранжевого формализма [16]. Функция Лагранжа строится с применением свободных множителей (неотрицательных двойственных переменных) для всех ограничений

$$L(w, \xi; \eta, \alpha) = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i - \sum_i \eta_i \xi_i - \sum_i \alpha_i [y_i \hat{y}(x_i) - 1 + \xi_i]. \quad (10)$$

Соотношения для седловой точки в двойственных переменных приводят к искомой постановке задачи:

$$\max_{\alpha} \sum_i \alpha_i y_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j K(\vec{x}_i, \vec{x}_j), \quad (11)$$

$$\sum_i \alpha_i = 0, \quad \min(0, Cy_i) \leq \alpha_i \leq \max(0, Cy_i). \quad (12)$$

Данная задача является задачей квадратичной оптимизации с простыми ограничениями. Основная трудность в решении вызвана тем, что число неизвестных переменных α равно числу обучающих примеров. В частности, матрица K для задач с числом примеров масштаба 10 000 уже не может быть целиком размещена в памяти компьютера, поэтому прямое применение процедур оптимизации затруднено.

Как уже отмечалось, в ожидаемом решении большинство примеров не участвует в описании классифицирующей границы, и коэффициенты α таких примеров в точке оптимума равны нулю. Таким образом, решением задачи (11)–(12) является разреженный вектор с относительно небольшим числом ненулевых компонент (на практике, в зависимости от сложности задачи и уровня шума в данных, можно ожидать до 99% нулевых компонент).

Это обстоятельство позволяет разработать специализированные методы оптимизации, в которых разреженность решения встроена в алгоритм поиска. К таким методам относятся методы покоординатного расщепления, в частности алгоритм последовательной минимальной оптимизации (SMO — sequential minimal optimization) [17]. Этот алгоритм является важным практическим частным случаем общего метода Немировского-Нестерова, разработанного еще в 80-х годах.

Суть метода состоит в выделении пар переменных α для пары базовых векторов, наиболее близко примыкающих к границе классов и лежащих по разные стороны от границы. Решение задачи квадратичного программирования для пары переменных с ограничениями строится аналитически в явной форме. После шага оптимизации одна или обе переменные могут обратиться в ноль, и соответствующие вектора исключаются из списка кандидатов. Процесс завершается, когда не удается найти пару векторов, оптимизация параметров которых может улучшить решение. Подробно варианты алгоритма изложены в специальной литературе по оптимизации [18,19].

Регулярность решения в методе SVM определяется параметром C в условиях (12) а также выбором ядерной функции. Стандартным выбором является использование радиальных базисных функций

$$K(\vec{x}_i, \vec{x}) = \exp(-\gamma \|\vec{x} - \vec{x}_i\|^2). \quad (13)$$

В итоге, метод параметризуется двумя величинами C и γ , оптимальные значения которых для каждой практической задачи могут быть выбраны на основе статистических кросс-валидационных экспериментов или бутстреп-выборок. Для оценок γ полезно провести оценки гистограммы распределения квадратов расстояний между векторами в подвыборке обучающих данных.

Хотя основной областью применения SVM являются задачи классификации многомерных векторов, имеются и обобщения метода на задачи регрессии и аппроксимации плотности полной вероятности. Однако в задачах регрессии ощутимого преимущества от использования базовых векторов нет, так как требуется эффективное покрытие всего множества данных. В этом случае имеется серьезная альтернатива — нейронные сети с локальными нормализованными сплайнами, о которых шла речь в предыдущей лекции автора [25]. Нейросетевые сплайны свободны от ограничений ядерных методов, связанных с фиксацией положения базисных функций строго в точках обучающих данных.

Сторонники геометрических машин SVM часто отмечают «неоспоримые преимущества» ядерных методов над нейросетевыми. Значительная доля таких заявлений преследует, конечно, маркетинговые цели — ведь потребители машинных технологий, как и все другие покупатели, нуждаются в обновлении парка алгоритмов. В реальности SVM, как и другие алгоритмы, имеет свои недостатки и свои границы применимости:

- Обучение SVM-машины сводится к решению задачи квадратичного программирования, которая, при прочих равных условиях, проще общей задачи нелинейной оптимизации, возникающей при обучении нейросетевых машин. Однако число свободных весовых параметров в практически используемых нейронных сетях редко превышает 2–3 тысячи, число же переменных в задаче SVM равно числу примеров, и во многих приложениях (например, в задачах классификации текстовых документов) может достигать миллионов. Поэтому проблема масштабирования SVM стоит весьма остро.
- Для масштабных задач число результирующих базовых векторов в SVM модели может достигать нескольких тысяч. Это затрудняет использование обучающихся по алгоритму SVM машин в портативных и встраиваемых устройствах, обладающих ограниченной памятью и быстродействием. Для нахождения результата классификации для каждого нового примера необходим расчет расстояний от него до каждого базового вектора и вычисление такого же числа нелинейных ядерных функций. Быстродействие таких моделей на современных PC не превышает 10^{-2} – 10^{-3} секунды на один пример. Это может оказаться слишком медленным, например, для систем управления и реального времени.
- Принцип минимизации структурного риска, положенный в основу SVM классификаторов, дает оценку ошибки обобщения в вероятностном (не абсолютном) смысле. Поэтому получаемая граница между классами оптимальна лишь в смысле статистики примеров *в ее окрестности*. Например, перемещение вдоль границы значительных объемов примеров, находящихся на удалении от нее, никак не отражается на классификаторе. Напротив, решение, даваемое оптимальными байесовыми классификаторами и нейросетевыми алгоритмами, будет адекватно отражать изменения в пространственном расположении примеров.

Методы SVM целесообразно использовать в сочетании с пониманием особенности задачи, достигнутым при помощи других алгоритмов и совместно с ними. Например, может быть предложена интересная гибридная методика, в которой для обучения нейронной сети задачи классификации используются не все обучающие данные, а лишь базовые вектора, выделенные алгоритмом SVM. При достижении сравнимой точности классификации нейросетевая модель будет значительно выигрывать в вычислительной эффективности.

Далее мы переходим к обзорному рассмотрению нейронных методов анализа данных для задач классификации, кластеризации и регрессии.

Нейросетевые обучающиеся машины

К *вычислительным* нейросетевым методам относятся алгоритмы, использующие в своей основе векторные операции с массивным параллелизмом и нелинейные базисные функции *одной* переменной. Структурно, вычисления производятся в узлах сети с направленными связями, при этом каждый узловый элемент (*нейрон*) обрабатывает только информацию, поступившую к нему от других, непосредственно связанных с ним, нейронов.

Базовая операция нейрона, как правило, состоит в вычислении скалярного произведения вектора входных сигналов с хранящимся в локальной памяти весовым вектором, и в последующем применении нелинейной переходной функции к этому скалярному произведению:

$$n(\vec{x}; \vec{w}) = f\left(\sum x_j w_j + w_0\right). \quad (14)$$

Вместо скалярного произведения формально может рассматриваться и расстояние между входным вектором и вектором памяти, но это принципиально не меняет сути вычислений:

$$\begin{aligned} n(\|\vec{w} - \vec{x}\|^2) &= n(\|w\|^2 + \|x\|^2 - 2\vec{w} \cdot \vec{x}) = \\ &= n(\|x\|^2, \vec{x}; [w_0 + \|w\|^2, 1, -2\vec{w}]) \equiv n(\vec{y}; \vec{v}). \end{aligned} \quad (15)$$

В набор входных сигналов добавлена новая компонента, равная норме входного вектора (общая «интенсивность» сигнала), и переобозначены компоненты весового вектора.

При помощи выбора весовых коэффициентов, наборов входных сигналов и вида переходной функции f могут быть вычислены и другие операции, встречающиеся в нейросетевой литературе, такие как нахождение победителя при соревновательном функционировании, нормализация и контрастирование компонент векторов. Более сложные операции, например масштабирование одной группы входов другими входами, реализуются введением дополнительных элементов с базовой функцией (14).

Функция, вычисляемая всей нейронной сетью в целом, дается рекурсивным применением элементарных нейронных функций (14):

$$NN(\vec{x}; W) = f\left(w_0 + \sum_j w_j f_j\left(w_{j0} + \sum_k \sum_j \dots\right)\dots\right). \quad (16)$$

Разнообразие имеющихся нейросетевых архитектур не противоречит основной модели (16). Так, для описания моделей с рекуррентными связями, к (16) добавляются условия попарного равенства некоторых векторов памяти и тождественности векторов входных сигналов. Нейронные сети с конечными временными задержками представляются дополнительными слоями рекурсивного ряда (16). Специальные архитектуры с симметричными (не направленными) связями также описываются дублированием слоев и условиями на равенство весовых векторов. В ряде моделей выходом (результатом применения) нейросети служит не только итоговое значение формулы (16), но дополнительно и значения некоторых из переменных, полученных на предыдущих стадиях рекурсии, например значения отдельных нейронных функций (14) для выбранной группы нейронов. В этом случае нейронная сеть осуществляет, в общем случае, нелинейное отображение входного вектора \vec{x} в выходной вектор $\vec{z} = NN(\vec{x})$, другой или той же размерности.

Таким образом, далее в лекции без ограничения общности, рассматриваются только рекурсивные вычислительные алгоритмы класса (16). Нужно заметить, что общность вида (16) в специальной литературе часто завуалирована конструктивными описаниями архитектуры, способа функционирования и обучения. Такое, общепринятое, описание наиболее часто используемых моделей в интуитивной форме можно найти, например, в электронном учебнике [15].

Минимально достаточной моделью вида (16) является нейронная сеть с одним скрытым слоем равноправных нейронов, называемая также сетью прямого распространения (feed-forward):

$$FF(\vec{x}; V, W) = g(v_0 + \sum_j v_j f_j(w_{j0} + \sum_k \sum_j w_{jk} x_k)). \quad (17)$$

Для задач регрессии данных выходная функция g может быть выбрана линейной. Алгоритмы функционирования и дифференцирования модели (17) также подробно рассмотрены в электронном учебнике, в приложении к которому имеется интерактивные иллюстрации¹⁶.

Под обучением нейросетевой машины понимается модификация свободных весовых коэффициентов W и, реже, самой структуры связей, с целью оптимизации выбранного критерия качества обучения. Нейронные

¹⁶Исходный код программы с использованием javascript доступен в HTML-тексте страницы.

сети имеют принципиальную общность с методами статистического обучения, при этом в обучении и тестировании моделей используются одни и те же функционалы качества и методы регуляризации. В основе обучения лежит алгоритм многомерной оптимизации¹⁷.

Важным практическим достоинством нейронного алгоритма (16) является возможность эффективного вычисления градиента функции качества по компонентам весов W . Рекурсивная структура позволяет применить правила дифференцирования сложной функции, при этом необходимые промежуточные вычисления проводятся заранее, при прямом применении формулы (16). Такой способ дифференцирования получил название алгоритма обратного распространения ошибки.

В семейство алгоритмов (16) формально попадают и многие алгоритмы, которые традиционно не относят к нейронным сетям (например, ранее рассмотренная машина SVM). В обширной литературе по вычислительным нейронным сетям часто выделяются дополнительные свойства, сужающие класс (16), например, *ассоциативность* памяти весовых векторов. Под ассоциативностью можно понимать¹⁸ тот факт, что обучающие примеры, или их подмножества, не хранятся в узлах сети по определенным адресам (как в ядерных алгоритмах), а в сжатой форме «распределены» в значениях всех весовых коэффициентов. Приближение к выходному вектору $\vec{z} = NN(\vec{x})$ может быть получено по неточной копии входного вектора \vec{x} .

Что принципиально при синтезе нейросетевых моделей?

Нейросетевые модели представляют собой существенно нелинейные функции с большим числом степеней свободы. Такая гибкость и широта класса представимых функций накладывает особые требования к технологии их использования. Нейросеть является тонким прецизионным инструментом, предполагающим аккуратность в обращении.

- **Данные.** Нейронная сеть представляет собой статистическую модель обучающих данных. Первичным здесь являются именно дан-

¹⁷В некоторых случаях явная формулировка оптимизируемого функционала может быть затруднена. Например, в широко используемых картах самоорганизации Кохонена [5] алгоритм обучения формулируется конструктивно.

¹⁸Это, скорее, вопрос условностей и истории. Так, например, при аппроксимации значений некоторой функции системой полиномов, коэффициенты этих полиномов также являются сжатой формой представления таблицы значений, при этом сами значения нигде не запоминаются. С другой стороны, в задаче *интерполяции* данных, полином Лагранжа содержит табличные значения в явном виде.

ные. Значительная доля всех затрат (и временных, и человеческих) при синтезе моделей связана со сбором, согласованием, и обеспечением достоверности данных.

Математические вопросы возникают при предобработке и кодировании данных. Предобработка преследует, в целом, одну цель — повышение информативности данных и связанную с ней регулярность алгоритма обучения. Важность снижения шума в данных иллюстрируется задачей 1, приведенной в конце лекции.

Масштабирование данных и преобразование координат позволяют упростить задачу оптимизации, в частности статистически выравняются компоненты градиента. Перед проведением обучения необходимо изучить гистограммы распределений координат обучающих примеров. Если визуальная инспекция невозможна, то требуется разработка алгоритмов, собирающих статистические параметры гистограмм. При высокой неравномерности распределений, и особенно их многомодовости, выравнивание¹⁹ достигается применением кумулятивных табличных функций распределения.

Программные системы, предназначенные для промышленных применений нейросетевых моделей обычно содержат развитую библиотеку средств предобработки. Полная автоматизация процесса предобработки²⁰ представляет собой сложную интеллектуальную и алгоритмическую проблему.

- **Оптимизация.** Обоснованные алгоритмы обучения нейросетевых моделей базируются на решении той или иной задачи оптимизации. По существу, обучение машины — это оптимизация ее структуры и параметров. Конечно, для практической пригодности машины требование ее оптимальности не является обязательным, скорее, наоборот, оно избыточно. Достаточно достигнуть некоторого *допустимого* состояния в пространстве параметров, в котором функциональность машины может быть *обоснована* (путем проведения формальных тестов). Однако достижение допустимого состояния параметров из некоторого исходного состояния, суть, выполнение процедуры оптимизации с ее остановом по достижении критерия допустимости. Поэтому раз-

¹⁹Или «выбеливание» — whitening.

²⁰Разумеется, предобработка может, наоборот, приводить и к усложнению задачи и ухудшению результатов :-).

работка или применение мощного алгоритма оптимизации является одним из ключей к успешному созданию модели.

Нужно понимать, что многие опубликованные алгоритмы обучения нейросетевых моделей носят иллюстративный характер, являются «концептуальными автомобилями», показывающими, как *в принципе* может возникать обучение²¹ данной нейросети. Часто авторы алгоритмов преследуют далекие от технологических потребностей цели, например, биологические аналогии или реализуемость обучения в специальных условиях. Перед машиной может ставиться задача адаптации в нестационарных условиях. Так, автомат, собирающий информацию в недоступных человеку условиях, вообще может иметь своей целью как можно более длительное выживание при произвольной блуждающей активности. Конечно, алгоритмы, разработанные для таких специфических задач, не всегда пригодны для вычислительных применений при анализе данных.

- **Статистическая интерпретация.** Обучение нейросети останавливается в одном из множества локальных минимумов функционала качества. Поэтому *точное* воспроизведение одной и той же модели при повторном обучении из произвольной начальной точки не вероятно. Близость моделей должна пониматься в вероятностном смысле — сходимости статистических оценок точности и др. Это может привести в замешательство как пользователей, так и, например, специалистов ИТ-подразделений предприятия, внедряющего нейросетевые модели. С их точки зрения, программный комплекс, содержащий нейросеть, не удовлетворяет одному из важных принципов повторяемости результатов при неизменности условий использования. Так, например, системы баз данных возвращают по одному и тому же запросу одинаковое число записей, если содержимое таблиц не изменилось. Эта проблема в целом не так проста, как может показаться на первый взгляд — ведь работа предприятий может базироваться на установленных технологических требованиях к программному обеспечению и процедурах обеспечения его устойчивого функционирования.

Это замечание также справедливо и по отношению к другим методам, использующим рандомизированную инициализацию или стоха-

²¹Классический пример — алгоритм обратного распространения ошибки с градиентным обновлением весов. В его исходной формулировке, этот алгоритм для обучения нейросетей на практике непригоден.

стику²² в алгоритме обучения. К ним относятся, например, машины SVM, обучающиеся итерационными методами расщепления.

Никакая практическая модель не может быть получена обучением *ровно одной* нейросети, хотя бы потому, что неудачная начальная инициализация не позволяет достигнуть допустимого обученного состояния. В приложениях широко используются комитеты из множества нейросетей, обученных на различных подвыборках данных. Сравнительный анализ нескольких моделей различной сложности позволяет содержательно оценить ошибки. Разные нейросети могут использоваться для моделирования отдельных областей пространства данных, сочетаясь с методами кластеризации или деревьев решающих правил.

- **Встроенное оценивание точности.** Уже отмечалось, что для улучшения потребительских свойств, целесообразно проводить одновременное обучение среднему значению выхода и, как минимум, его дисперсии. Нейросеть с несколькими выходами (или набор отдельных нейросетей) аппроксимирует несколько первых моментов условной вероятности выходов при известных входах.
- **Тестирование.** Все затраты по сбору данных и созданию моделей нужно отнести к убыткам, если доказательство правильности работы обученной машины не проведено или невозможно. Хотя имеются уже вошедшие в учебники теоретические построения для оценок ошибок обобщения нейронных сетей, зачастую проверка выполнения условий их применимости к конкретной задаче затруднена. Некоторые оценки могут требовать достижения окрестности точного минимума функционала качества. Другие предъявляют жесткие требования к статистике и объему данных. Маргинальные оценки обеспечивают границы ошибки с доверительной вероятностью. Другими словами, на практике статистического экспериментирования с нейросетевыми моделями не избежать.

Одной из рекомендованных технологий тестирования является кросс-валидация. Процедура кросс-валидации заключается в обучении множества нейронных сетей тестируемой архитектуры на частичных выборках данных, полученных последовательным удалением части обучающих примеров. Оценивание производится по статистике ошибок на удаленных примерах. Здесь важны два момента.

²²Популярное онлайн-обучение является примером стохастического метода. Результаты зависят от порядка, в котором предъявляются обучающие векторы.

- 1) Значение ошибки обобщения является *случайной величиной*, поэтому способ усреднения экспериментальных результатов должен обеспечивать состоятельность и несмещенность ее оценки. Для корректного проведения статистического анализа рекомендуется обратиться к литературе по математической статистике и методам анализа результатов экспериментов (например, [7]).
- 2) Обеспечивающее достоверную оценку расщепление обучающей выборки на кросс-валидационные подмножества зависит от объема данных и сложности модели (здесь — числа степеней свободы весовых параметров). Часто рекомендуемое расщепление выборки на 10 (или 2, или ...) частей может использоваться только для первичных оценок. Этот вопрос также относится к области математической статистики [20,21].

Среди важных прикладных вопросов находятся также проблемы стандартизации²³ моделей и технологий их внедрения в производственные системы потребителей. Эта тема затронута в Приложении.

Иллюстрации применения технологий информационного моделирования

Для апробации разрабатываемых технологий на этапах, предшествующих практическому внедрению, целесообразно экспериментально выяснить границы их применимости и сравнить с другими решениями. Один из доступных полигонов — конкурсы решения информационных задач, проводимые в рамках научных конференций или, независимо, компаниями, заинтересованными в сравнительном оценивании их собственных технологий.

Конечно, конкурсные задачи — это только набор частных случаев, кроме того, конкурсы могут дополнительно акцентировать некоторые специальные свойства алгоритмов (например, конкретные формальные показатели качества обучения). Технологии широкого применения редко занимают в конкурсах лидирующие позиции, побеждают обычно специализированные разработки из университетов. Так и должно быть — поток инноваций из научных коллективов должен быть впереди тщательно отбираемых практических методов.

²³Полезно вспомнить слова *Генри Форда* «... если вы понимаете стандарт, как ограничение, прогресс остановится» (*Дж. Лайкер. Дао Toyota.* — М.: Альпина, 2005, с. 190)

На рис. 3 приведены результаты одного из таких конкурсов (EUNITE Symposium 2003). Цель состояла в прогнозе по 29 входным переменным динамики 5 выходных переменных, описывающих качественные показатели продукции в производстве стекла. Точность оценивалась как по каждой из переменных в отдельности, так и совокупности²⁴.




Рис. 3. Итоговый показатель точности прогноза в конкурсе EUNITE-2003. Результат коллектива автора отмечен стрелкой.

Технология АФИНА (см. заключительную часть лекции) показала седьмой результат (на 15% уступив лучшему результату и почти вдвое опережая средний показатель). Это — типичный ожидаемый уровень для промышленных технологий, не адаптировавшихся специально к условиям конкурса.

Ниже мы рассмотрим задачи одного из новых конкурсов, в котором читатель лекции может еще успеть принять участие.

²⁴URL: <http://www.eunite.org/eunite/events/eunite2003/competition2003-winners.htm>

Задачи конкурса WCCI-2006

Конкурс объявлен в рамках²⁵ Всемирного конгресса по компьютерному интеллекту (IEEE WCCI-2006). На конкурс предложены 5 задач классификации на два класса. Цель — построить машину, обладающую не только наименьшей ошибкой обобщения, но и получить *наилучшую оценку* этой ошибки. Ошибка обобщения будет вычисляться по итогам конкурса на тестовых данных, с учетом баланса относительных частот встречаемости классов:

$$BER = \frac{1}{2} \left(\frac{b}{a+b} + \frac{c}{c+d} \right),$$

где a и b — число правильных и ошибочных классификаций примеров класса -1 , d и c — правильные и ошибочные срабатывания классификатора для примеров, истинный класс которых $+1$.

Пять наборов данных (с собственными именами) отличаются числом примеров, размерностью пространства входов, одна из задач классификации ставится для разреженной матрицы данным в пространстве размерности более 10 000. Для каждой задачи имеется набор обучающих данных с известными метками классов, набор валидационных данных, метки которых будут опубликованы на поздних этапах конкурса, и набор тестовых данных, метки которых не будут известны участникам.

В лекции эти задачи будут использоваться для иллюстрации некоторых элементов технологии разработки классификаторов на примере одной из задач. Следуя общей идее лекции, мы не ограничиваемся применением только нейронных сетей.

Задача ADA

Таблица обучающих данных содержит 4147 примеров размерности 48. Валидационных данных в 10 раз меньше, тестовых — в 10 раз больше.

Шаг 1. Визуализация данных. Для размерности масштаба 10–100 анализ можно начать с визуальной инспекции гистограмм распределений значений входов. Цель — общее понимание характера данных, наличие выбросов, резкой неравномерности, постоянных входов и других аномалий в данных. Поскольку, по условиям, входная часть информации из тестового набора может быть свободно использована, то гистограммы строятся

²⁵Сайт конгресса: URL: <http://www.wcci2006.org/home.html>. Адрес страницы с условиями конкурса и наборами данных URL: <http://www.modelselect.inf.ethz.ch/index.php>.

по все имеющимся данным (включая тесты). На этом этапе выявлено, что около половины входов являются булевыми (0 или 1), при этом имеются переменные с высокой асимметрией распределения.

При большей размерности данных визуальный анализ гистограмм затрудняется²⁶. Для автоматизации анализа аномалий и выбросов необходима разработка специализированного программного обеспечения. Некоторые коммерчески распространяемые пакеты статистического анализа включают такой анализ.

Шаг 2. Предобработка. Характер гистограмм данных в задаче ADA показывает, что целесообразно применить выравнивание распределений. Для этого строятся кумулянты гистограмм, и полученные табличные зависимости используются для перевода данных в отрезок $-1..1$. Наиболее густонаселенные области данных отображаются в широкие поддиапазоны, а участки, на которых данные отсутствуют, сжимаются. Предобработка выходов не требуется — они явно представлены в виде кодов классов.

Шаг 3. Линейный анализ. Анализ линейных корреляций, линейной разделимости данных, выделение главных компонент и другие линейные методы всегда предшествуют нелинейным подходам. Последние используются для уточнения линейных приближений, при этом линейный метод автоматически дает нижнюю границу оценок ошибки и вычислительной сложности. При анализе линейных корреляций большим значениям соответствуют индивидуально значимые входы, но отсутствие корреляций не означает неинформативность входа при его использовании в нелинейной модели.

В данной задаче корреляции входов с выходами не образуют компактной группы входов, объясняющих значительную часть дисперсии. Модули коэффициентов корреляции практически равномерно заполняют отрезок $0.05..0.45$. Таким образом, для дальнейшего анализа сохраняются все входные переменные.

Шаг 4. Планирование статистических экспериментов. В цели конкурса (и часто, в цели практических разработок) входит не только получение наилучшей ошибки обобщения, но и ее оценка на этапе обучения. Универсальных гарантированных теоретических оценок для всех условий не существует, поэтому экспериментальный анализ фактически неизбежен. Однако, перед началом серий расчетов необходимо как можно более четко

²⁶Хотя в ответственных приложениях его все равно рекомендуется провести. Это — рабочие будни нашей профессии.

сформулировать цели экспериментов, выбрать его план, и, по возможности, представить себе ожидаемые результаты.

В нашей ситуации цели таковы:

- получение результатов и оценок точности более чем одной моделью;
- для каждого типа моделей определение уровня ее структурной сложности, который для имеющихся данных дает наилучшую ошибку обобщения;
- поскольку прогноз ошибки на тестовых данных индуктивно выводится из качества работы на данных с известными классами, то необходимо оценить надежность такой индукции, путем постепенного увеличения числа обучающих примеров.

Итак, план эксперимента включает минимум две модели. Это первая размерность матрицы плана эксперимента. Для задачи классификации таким набором могут быть метод вероятностных деревьев правил, и нейронная сеть прямого распространения. В лекции для основных иллюстраций выбраны нейронные сети прямого распространения с одним скрытым слоем. Алгоритм обучения основан на решении задачи оптимизации методом BFGS. Функционал качества обучения включает штраф за рост весов. Собственно нейросетевые вычисления, в целом, следуют книге [22].

Во-вторых, для каждой модели необходимо варьировать ее сложность. В выбранных моделях простейшим из вариантов является однопараметрическое изменение числа нейронов скрытого слоя нейросети и ограничение роста дерева по числу ветвей.

В более общем случае методы контроля сложности могут включать параметры регуляризирующих функционалов ошибки при обучении (например, ранний останов итераций), а также различные алгоритмы конструктивного упрощения структуры (прореживание связей и ветвей, и др.) При использовании комитетных методов объединения нескольких моделей (Adaboost, bagging и др.), контроль сложности должен вестись с учетом параметров всего комитета. Так или иначе, для экспериментального оценивания сложность формализуется небольшим числом параметров. Если используется какая-то теоретическая модель выбора или контроля сложности, не стоит полностью отказываться от вычислительных экспериментов. Они помогут установить применимость предпосылок модели для конкретного набора данных.

Третья размерность матрицы плана — доля примеров из обучающей выборки, которая будет использоваться в конкретном эксперименте. Для

выяснения характера зависимости оценки ошибки расчеты будут проводиться на изменяющемся от 10% до 100% объеме данных.

Нас интересует ошибка обобщения, которую можно получить при помощи кросс-валидации. Для этого отобранные для обучения данные разбиваются на несколько групп, и в каждом расчете одна из групп не участвует в обучении, а используется для оценивания ошибки. Методика кросс-валидации чувствительна к пропорции обучающих и валидационных данных, этот вопрос уже обсуждался в лекции. Для уменьшения фактора смещенности оценки при больших объемах данных можно рекомендовать результат [20], согласно которому каждая группа должна содержать $\sim 1/\sqrt{2m}$ примеров, где m — число свободных параметров модели (число весов для нейронной сети или удвоенное число решающих правил для дерева).

Таким образом, определены наборы из трех параметров, составляющих план эксперимента. В нашем случае можно выполнить *полный* план с перебором всех троек. На практике число экспериментов можно сократить, используя частичный план (например, латинский гиперкуб). При частичных планах интерпретация результатов должна проводиться путем построения регрессионной модели, согласованной с типом плана.

Перед проведением расчетов определимся с объемом собираемой информации. В соответствии с целями, будем фиксировать тип модели, параметр ее сложности (число нейронов или правил), объем используемых данных, ошибку обучения (для каждого класса), ошибку валидации, ошибку тестирования на неиспользуемых данных из обучающей выборки. Дополнительно могут также собираться такие данные, как время вычислений, тип и значение критерия останова обучения, и другие данные, характеризующие расчет.

И, наконец, обсудим, что в целом ожидается в результате эксперимента. Ясно, что при малом объеме данных ошибка обучения будет быстро уменьшаться с ростом сложности модели. Оцениваемая ошибка обобщения в идеале должна (сверху) стремиться к ошибке валидации и обучения с ростом числа данных. При большом объеме данных повышается вероятность отсутствия сходимости итерационного обучения нейросетевой модели, поэтому из статистики следует исключить случаи раннего останова обучения в локальных минимумах. Это будет проявляться в выбросах во времени обучения. Для оцениваемой ошибки тестирования хотелось бы получить тенденцию к насыщению при увеличении объема выборки. Теоретически, кривая ошибки тестирования и валидации может иметь минимум при росте сложности модели, но при высокой скорости сходимости обучения этот

минимум может быть слабо выраженным.

Шаг 5. Проведение экспериментов с базовыми нелинейными моделями. Экспериментальные вычисления удобно оформить пакетными заданиями, если это позволяет программное обеспечение. При проектировании программ нужно учитывать такую практическую потребность, иначе поисковые расчеты приведут к сильному удорожанию технологии.

Основные результаты экспериментов приведены ниже на рис. 4–6.

Методика вероятностных деревьев вычислительно более эффективна, поэтому ее всегда целесообразно использовать для экспресс-оценок и с нее начинать выбор моделей. Для удобства практического использования кривых ошибок удобно рисовать (и экстраполировать) данные в зависимости от обратного числа примеров.




Рис. 4. Зависимость ошибок обучения (ooo), валидации (xxx) и тестирования (+++) от числа решающих правил вероятностного дерева (левый рисунок). Сходимость ошибок для модели из 50 правил.

Валидационная ошибка дерева демонстрирует практически линейный тренд и сходится к значению 17.5%. Эту оценку, видимо, следует считать наилучшим вариантом для данной модели. Эксперименты с нейронными сетями должны показать, можно ли ее улучшить.




Рис. 5. Зависимость ошибок обучения (ooo), валидации (xxx) и тестирования (+++) от объема данных для нейронной сети с переобучением (6 нейронов, правый рисунок) и оптимальной модели (4 нейрона, график слева).

По итогам расчетов, оптимальная нейросетевая модель для этой задачи имеет 4 нейрона в скрытом слое. На рис. 6 наблюдается тенденция к сходимости ошибок, но практическая сходимость еще не достигнута. Экстраполированная оценка при возрастании числа примеров 14.7%, что несколько уточняет экспресс-результат, полученный вероятностным деревом.

Шаг 6. Применения моделей. После выбора оптимального уровня сложности моделей проводится обучение итоговых систем на полном наборе обучающих данных. При создании окончательных вариантов нужно учитывать, что сходимость обучения гарантируется только в вероятностном смысле. Поэтому должно быть опробовано несколько вариантов, отличающихся инициализацией свободных параметров. Отбираются модели по соответствию их показателей данным предыдущих экспериментов. Обычной практикой может служить выбор варианта, обладающего ошибкой обучения, равной медиане значений всех пробных вариантов.




Рис. 6. Зависимость ошибок от числа нейронов в скрытом слое (слева) и сходимости ошибок тестирования и валидации в зависимости от обратного числа обучающих примеров

Обсуждение

Наблюдаемое в задаче ADA соотношение точности нейросетевых классификаторов и моделей деревьев является типичным для практики, но бывают и исключения (см. Задачу 1 в приложении).

Другие задачи конкурса имеют свои особенности. Две наиболее важные из них — рост размерности пространства входов, и разреженность данных (задача NOVA имеет около 16 000 входных переменных). Такого типа задачи могут встречаться при анализе текстов по статистике встречаемых слов, а также в упоминавшихся в лекции задачах анализа покупательских корзин.

Для устойчивой классификации при таких больших размерностях необходимо сжатие признакового пространства. Как отмечено в [23, с. 83], при объемах данных, незначительно превышающих размерность пространства, более эффективной является использование методов кластеризации данных. Кластеризация обычно обеспечивает сжатие в 20–100 раз без суще-

ственной потери свойств делимости классов²⁷. В качестве новых, более компактных, координат примеров могут служить взвешенные расстояния (или функции от них) от примера до каждого кластера. Кластеризация сильно разреженных векторов требует специальных методик — при простой метрической кластеризации данные объединяются по признаку *отсутствия* тех или иных компонент, что не всегда соответствует сути решаемой задачи.

Описанные этапы решения информационной задачи не должны рассматриваться, как прямое руководство к действию. Иногда некоторые этапы можно опустить, случается, что суть задачи можно проявить, сосредоточившись на предобработке данных и методе оценивания модели. Есть ситуации, где многое зависит от параметров и алгоритмов самого метода обучения.

Послесловие

Вы ознакомились с лекцией о практической стороне и технологиях создания вычислительных нейронных сетей и других обучаемых машин. Многие положения и утверждения в тексте носят философский и полемический характер. В них отражена точка зрения автора, основанная на 15-летнем опыте работы в отрасли.

Трудности в построении изложения технологий в виде перечня рекомендуемых действий, которые нужно проделать для гарантированного получения качественного решения, носят системный характер. Мы имеем дело с современной практикой в условиях начала массового внедрения обучаемых элементов во все сферы деятельности.

Критически возрастают скорости и объемы обрабатываемой машинами информации. Кто-то из ведущих математиков сказал, что каждый раз, когда размерность анализируемой матрицы возрастает на порядок, следует кардинально пересматривать всю схему вычислений. В области обучаемых машин и алгоритмов мы имеем дело с прогрессирующим ростом размерностей на несколько порядков.

В итоге картина, нарисованная в лекции, скорее мозаична, в стиле художников-примитивистов, поскольку на ней изображен еще не суще-

²⁷Конечно, значения 20–100 являются некоторыми условными оценками того, что можно ожидать на практике. Известны задачи, когда сжатие можно довести до 1–2 переменных, сохранив точность классификатора.

ствующий, только нарождающийся образ.

Но этот образ уже начинает радовать глаз — сообщения об успехах в практическом внедрении *умнеющих* машин поступают все чаще, формируется соответствующий рынок услуг, потребители потихоньку привыкают к особенностям и доверяют машинным системам все большую часть аналитической работы.

Система АФИНА. Ряд и научных, и программно-технических, и организационных аспектов, затронутых в лекции, воплощен в комплексе технологий и программ АФИНА²⁸ (Анализ и Формализация Интеллектуальных Нейросетевых Алгоритмов), с момента выхода первой версии которого исполнилось 10 лет. В разное время в создании комплекса под руководством автора принимали участие *А. Квичанский, Н. Федорова, Е. Диянкова, С. Диянкова, Р. и Т. Мухамадиевы, Е. Воленко, Ю. Кузнецов, Ю. Конотоп* и многие другие специалисты — математики, программисты, электроники и инженеры. Финансовая поддержка начальных этапов работ оказывалась Международным Научно-Техническим Центром (МНТЦ).

Сегодня семейство технологий АФИНА включает несколько комплексов и программных модулей с общими принципами и подходами к формированию заказных решений для потребителей в областях бытовой химии, нефтедобычи и транспорта нефти, финансового прогнозирования, проектирования вычислительных систем и других. В компании Нейрок Техсофт (г. Троицк) происходит постоянное совершенствование и расширение спектра алгоритмов семейства АФИНА, разрабатываются новые подходы к созданию прикладных разработок и оказанию консалтинговых услуг в области моделирования и обработки информации, составляющих основу деятельности компании.

Благодарности

Автор выражает глубокую благодарность разработчикам системы АФИНА — коллективу соратников и коллег и поздравляет их с 10-летним юбилеем технологии.

²⁸АФИНА — в греческой мифологии, богиня разума, изящных и боевых искусств. Название технологического комплекса происходит от транслитерации AFINA (Algorithms For Intelligent Neural Applications).

Литература

1. WWW-страница компании KD Nuggets.
URL: http://www.kdnuggets.com/polls/2005/data_mining_techniques.htm
2. *Tishby N., Pereira F., Bialek W.* The Information Bottleneck Method // Invited paper to the 37th Annual Allerton Conference on Communication, Control, and Computing, 1999.
URL: <http://www.cs.huji.ac.il/labs/learning/Papers/allerton.ps.gz>
3. *Hansen M., Yu B.* Model selection and Minimum Description Length principle // *J. Amer. Statist. Assoc.*, 1998.
URL: <http://cm.bell-labs.com/cm/ms/departments/sia/binyu/ps/mdl.ps>
4. *Нарымов С.* Алгоритм растущего нейронного дерева // «Нейроинформатика-2005», Сборник трудов, МИФИ, 2005.
5. *Kohonen T.* Self-Organizing Maps. – Springer-Verlag, 1995.
6. *Huvarinen A., Karhunen J., Oja E.* Independent Component Analysis. – Wiley, 2001.
7. Справочник по прикладной статистике. В 2-х томах, под ред. Э.Ллойда, У. Ледермана. – М. Финансы и Статистика, 1989.
8. *Терехов С.А.* Нейросетевые аппроксимации плотности в задачах информационного моделирования // Лекция для Школы-семинара «Современные проблемы нейроинформатики», Москва, МИФИ, 25–27 января 2002 года.
9. *Терехов С.А.* Введение в байесовы сети // Лекции по нейроинформатике. – М.: МИФИ, 2003, ч. 1. – с. 149.
10. *Терехов С.А.* Нейродинамическое программирование автономных агентов // Лекция для Школы-семинара *Современные проблемы нейроинформатики*. – М.: МИФИ, 2004. Часть 2. – с. 111–139.
11. *Mead W.C., Brown S.K., Jones R.D., Bowling P.S., Barnes C.W.* Optimization and control of a small-angle negative ion source using an on-line adaptive controller based on the connectionist normalized local spline neural network // *Nuclear Instruments and Methods*. – Vol. A352, 309, (1994).
12. *Jones R.D., Lee Y.C., Qian S., Barnes C.W., Bisset K.R., Bruce G.M., Flake G.W., Lee K., Lee L.A., Mead W.C., O'Rourke M.K., Poli I., Thode L.E.* Nonlinear adaptive networks: A little theory, a few applications // In: *Proceedings of the First Los Alamos Conference on Cognitive Modeling in System Control*, June 10–14, 1990, Santa Fe, NM.
13. *Вапник В.Н.* Восстановление зависимостей по эмпирическим данным. – М.: Наука, 1979.
14. *Вапник В.Н.* The nature of statistical learning theory. – Springer-Verlag, 1995.

15. *Терехов С.А.* Вводные лекции по нейроинформатике.
URL: http://alife.narod.ru/lectures/neural/Neu_index.htm
16. *Бертсекас Д.* Условная оптимизация и методы множителей Лагранжа. – М.: Радио и связь, 1987.
17. *Keerthi S.S., Shevade S.K., Bhattacharyya C., Murthy K.R.K.* Improvements to Platt's SMO algorithm for SVM classifier design. – Tech Rep., Univ of Singapore, 1999.
URL: <http://citeseer.ist.psu.edu/244558.html>
18. *Bordes A., Ertekin S., Weston J., Bottou L.* Fast kernel classifiers with online and active learning // *JMLR*. – 6(Sep): 1579–1619, 2005.
19. *Osuna E., Freund R., Girosi F.* Support vector machines: Training and applications. – Technical Report AIM-1602, MIT A.I. Lab., 1996.
URL: <ftp://ftp.ai.mit.edu/pub/cbcl/sv-memo.ps.gz>
20. *Amari S., Murata N., Müller K.-R., Finke M., Yang H.* Statistical theory of overtraining is cross-validation asymptotically effective? // *NIPS*, 1996.
URL: <http://citeseer.ist.psu.edu/amari96statistical.html>
21. *Kearns M.* A bound on the error of cross validation using the approximation and estimation rates, with consequences for the training-test split. – Tech. Rep ATT, 1996.
URL: <http://www.informatik.uni-bonn.de/III/lehre/seminare/Mustererkennung/WS99/cv.ps.gz>
22. *Bishop C.M.* Neural networks for pattern recognition. – Oxford University Press, 1995.
23. *Ежов А.А., Шумский С.А.* Нейрокомпьютинг и его приложения в экономике и бизнесе. – М.: МИФИ, 1998.
24. *Hastie T., Tibshirani R., Friedman J.* The elements of statistical learning. – Springer, 2001.
25. *Терехов С.А.* Адаптивные нейросетевые методы в многошаговых играх с неполной информацией // *Лекции по нейроинформатике*. – М.: МИФИ, 2005, с. 92–135.
26. *Муркес Е.* Нейрокомпьютер: Проект стандарта. – Новосибирск, Наука, 1999.

Приложение. О стандартизации описания моделей обучающихся машин (PMML — Predictive Model Markup Language)

При расширении областей применения новых информационных методов вопросы стандартизации приобретают первостепенное значение. Нужно

отметить, что вопросы стандартизации уже поднимались в отечественной литературе [26]. При этом в книге [26] была предпринята попытка стандартизации всех, в том числе *исследовательских* процессов (структуры данных, алгоритмов, архитектуры, способов оценивания и т. д.), сопровождающих разработку программных систем, составляющих основу моделей нейрокompьютеров.

Два аспекта здесь представляются особенно важными.

1. Потребности предприятий и организаций, использующих методы анализа накопленных ими данных при помощи обучающихся машин, выходят за рамки только нейронных сетей. На единой платформе должны унифицироваться самые разнообразные системы (математическая статистика, деревья решений, методы исчисления байесовых вероятностей и др.) Совместная стандартизация всех математических и технологических аспектов всех этих систем крайне затруднена.
2. В современной технологии создания обучающихся машин присутствуют этапы, на которых принципиально задействован естественный интеллект (т. е. человек). Стандартизация этих этапов также крайне затруднена.

С точки зрения автора, к таким этапам и компонентам относятся:

- Процессы первичного отбора признаков переменных, определяющих задачу. Такой отбор опирается на априорные экспертные знания, не обязательно содержащиеся и выводимые из имеющегося набора данных.
- Ограничения на переменные и результаты. Ограничения могут также возникать из соображений, внешних по отношению к решаемой задаче анализа данных.
- (Не-)использование выводов обучающихся машин в условиях невозможности получения полноценного формального обоснования их применимости (включая ограничения на доступный объем тестирования).
- Процессы принятия решений на основе выводов обучающихся машин *и других* (не учтенных) особенностей задачи.

Наличие трудно формализуемых этапов технологии с одной стороны, и потребностей потребителей с другой, ограничивает направления стандартизации. А именно, *стандартизируется только то, что непосредственно внедряется*, т. е. встраивается в бизнес-процессы потребителей. Объектом

стандартизации являются окончательные модели обучающихся машин, а также способы получения ими исходных данных и способы выдачи «на-гора» результатов.

За рамками промышленной стандартизации остаются алгоритмы и методы обучения и другие исследовательские и технологические процессы и «открытия», которые позволили получить²⁹ итоговую модель, готовую к применению.

По этому пути пошли разработчики языка описания прогностических моделей (PMML — the Predictive Model Markup Language). Этот язык, являясь приложением языка разметки XML³⁰, формализует понятие «модель для анализа данных и прогнозирования» и позволяет использовать такие модели совместно различными приложениями в разнообразных условиях, определяемых потребителем.

Процесс разработки PMML был начат в 1998 году. О поддержке PMML уже в 2001 году заявили такие компании, как Angoss, IBM, Magnify, Microsoft, MINEIT, NCDM, NCR, Oracle, Salford Systems, SPSS, SAS и Xchange. К моменту написания лекции вышла версия PMML 3.0 и список компаний насчитывает около 20 ведущих поставщиков информационных и аналитических систем.

Разработка PMML координируется независимой группой DMG (The Data Mining Group), включающей представителей компаний-членов. WWW-адрес DMG: URL: <http://www.dmg.org/pmml-v3-0.html>

Общие принципы PMML

Объектом стандартизации в PMML являются прогностические модели, которые на основе значений определенных входных переменных (или факторов) позволяют получить статистические оценки значений целевых выходных переменных. Способ стандартизации состоит в фиксации формальной

²⁹Сказанное ни в коей мере не означает, что разработчики и поставщики информационных технологий, моделей и консалтинговых услуг не должны стремиться к стандартизации и унификации своих внутренних процессов синтеза моделей. Такая стандартизация, упорядочение и документирование, наряду с человеческими ресурсами, составляет основу бизнес-потенциала компании или иного коллектива разработчиков, обеспечивая конкурентные преимущества и среду для плодотворного творчества. Упомянутая в тексте лекции система АФИНА является примером такой внутренней стандартизации процесса синтеза нейросетевых моделей, применяемого в компании Нейрок Техсофт.

³⁰Что само по себе уже является устойчивой почвой для создания стандартов в области обработки данных.

схемы (XML-schema), которой обязан удовлетворять XML-объект, описывающий модель или набор моделей с общим предметным пространством данных.

Язык выделяет следующие компоненты:

- Служебная и идентификационная информация (*заголовок*).
- Блок описания примененного *способа получения модели*. Содержимое этого блока не специфицировано и оставлено на усмотрение поставщика. В применении модели этот блок никак не используется.
- *Словарь данных*, описывающий способ извлечения и интерпретации входных и выходных данных моделей. В частности, могут указываться столбцы во входных потоках или файлах, поля баз данных и др.
- *Словарь преобразований*. Здесь описываются преобразования (арифметические, логические и функциональные), способы кодирования переменных и другие преобразования, которые переводят наборы сырых данных в числовые данные, которыми непосредственно оперируют модели
- *Блоки, описывающие модели*, включенные в спецификацию. В версии 3.0 формализованы 12 наиболее часто используемых типов моделей — ассоциативные правила, кластерные модели, модели обобщенной регрессии, нейронные сети, системы формальных правил, машины SVM (Support Vector Machine), модели анализа текстов, деревья правил и некоторые другие. Каждый тип моделей описывается своим соответствующим набором элементов, при этом выделены общие сущности, такие как тип решаемой задачи (классификация, регрессия, кластеризация, анализ последовательностей, выявление ассоциаций), описание выходных переменных, сведения о способе верификации модели.

Остановимся несколько подробнее на спецификации нейросетевых моделей, имеющих непосредственное отношение к тематике лекции. Модель нейронной сети определяет элементарные вычислительные нейроны и связи между ними. Нейроны могут объединяться в слои, функционирующие в том порядке, в каком они описаны. Дополнительные свойства (например, ширина радиальной базисной функции) могут быть приписаны индивидуальному нейрону, слою, либо сети в целом. Для выходов нейронов слоя могут применяться общие процедуры (например, выявление победителя или нормировка).

«Весы» и «нейроны» представлены как различные объекты, формирующие сеть с практически не ограниченной топологией соединений.

Спецификация PMML предполагает возможность расширений и дополнений, вносимых различными поставщиками, что позволяет либо расширить базовую функциональность либо использовать некоторые уникальные дополнительные возможности моделей, разработанных и используемых в программном обеспечении данного поставщика. Сам *способ* проектирования расширений специфицирован, при этом наличие расширений не препятствует стандартному использованию базовых возможностей. Так, в случае нейросетевых моделей, которые предполагается в дальнейшем *добучать*, в качестве дополнительных параметров могут быть специфицированы текущие значения производных по значениям весов, либо значения последних внесенных поправок к весовым коэффициентам.

Отметим, что, например, такой элемент как функционал оценки обучающейся нейросети языком PMML не специфицирован, поскольку он не относится к этапу *применения* нейросетевой модели. Однако он может быть добавлен к модели через механизм расширений.

Примеры нейросетевых моделей в формате PMML можно найти на WWW-узле разработчиков.

Что дает применение PMML?

Применение стандарта PMML дает целый ряд важных технологических и организационных преимуществ в сравнении с (возможно, более вычислительно эффективными и компактными) уникальными спецификациями.

- Прежде всего, **процесс синтеза и обучения моделей отделен от условий применения**. Разработка модели может проводиться на производительных UNIX-станциях или на кластерах. Используется же модель в самых разных условиях, вплоть до карманных компьютеров, коммуникаторов, смартфонов и встраиваемых (embedded) систем и в составе самого разнообразных программ — от WWW-страниц и электронных таблиц Excel до промышленных CRM-систем
- Во-вторых, **процесс тестирования отделен от процесса разработки**. В компаниях могут создаваться специализированные стенды для тестирования и экспериментального обоснования применений для прогностических моделей. Облегчается сравнительное тестирование

моделей, основанных на разных принципах. Организационно, тестирование проводится специалистами по тестированию, при этом процесс приемки моделей может быть эффективно формализован.

- Упрощается **процесс документирования и учета моделей**. Этот аспект важен в условиях, когда разрабатываются библиотеки моделей (например, аппроксимационные модели химических или механических свойств материалов, используемые при математическом моделировании), или при одновременной эксплуатации множества моделей для отдельных элементов бизнес-процессов (например, прогностические модели работы сети поставщиков или торговых предприятий).
- Снимается ряд ограничений на **использование моделей в программных системах от сторонних разработчиков**, особенно в ситуации с «закрытым» исходным кодом.
- Упрощается **процесс внедрения** программных решений. Окончательные версии модели могут быть встроены в систему на последних этапах внедрения, не сдерживая общий процесс.
- Упрощается **процесс сопровождения и поддержки** — путем поставок сменных PMML-модулей с обновленными версиями моделей, без перекомпиляции кода программной системы. Большая часть поддержки может быть обеспечена дистанционно.

В итоге, применение стандарта направлено на минимизацию целевой функции «время-до-потребителя». В современном мире часто именно этот показатель оказывается решающим при принятии решений об использовании инновационных разработок.

Задачи

ЗАДАЧА 1. Таблица данных со случайными признаками

Эта задача иллюстрирует поведение методик классификации при обучении на данных, содержащих неинформативные входы. Таблица обучающих данных содержит 10 столбцов-входов со случайными значениями в диапазоне $[-1, 1]$. Выходной столбец содержит два возможных значения $\{-1, +1\}$, определяющие код класса. Значение $+1$ соответствует примерам, у которых значения *первой* из 10 координат удовлетворяют условию.

$$\sin(5 \cdot \pi \cdot x_1) \geq 0.1. \quad (P1.1)$$

Остальные входы не участвуют в определении класса примера.

На рис. P1 и P2 приведены результаты двух обученных классификаторов: 1) нейронная сеть сигмоидальных нейронов при разном числе нейронов в скрытом слое, 2) вероятностное дерево с критерием останова по достижении заданного числа ветвей. Каждый из классификаторов обучался на выборках из 1 000 примеров (рис. P1) и 10 000 примеров (рис. P2). Тестирование проводилось на независимой выборке из 10 000 примеров.

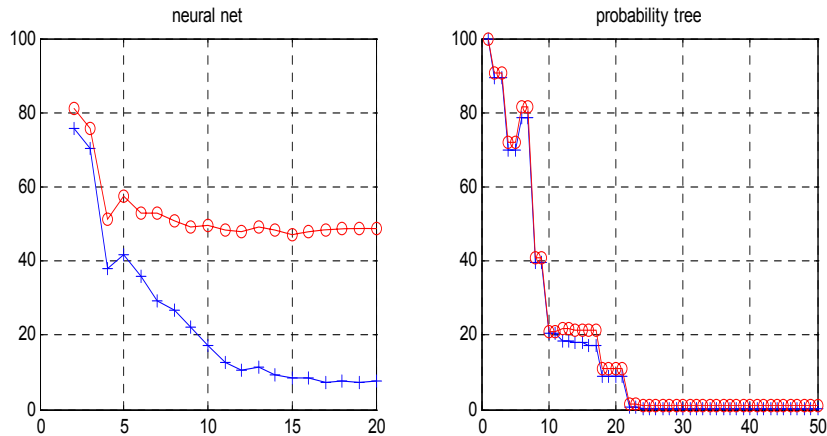


Рис. P1. Ошибка обучения (+++) и тестирования (ooo) как функция сложности модели при обучении на 1 000 примеров. Левый рисунок — нейронная сеть с числом нейронов от 2 до 20. Правый рисунок — вероятностное дерево с числом ветвей от 2 до 50.

Результаты утверждают следующее. Методика вероятностного дерева устойчиво обучается до практически нулевой ошибки и обобщения при числе ветвей около 25. Сходимость достигается и для тысячи, и для 10 тысяч примеров.

Нейронная сеть при малом числе примеров систематически уменьшает ошибку обучения, при этом ошибка тестирований остается на уровне 50% (это уровень «подбрасывания монеты»). При большом числе примеров (10,000) изменения ошибок обучения и тестирования согласованы, при этом обучение достигается при числе нейронов более 10 и лишь в 4 из 20 вариантов.

Являются ли эти результаты неожиданными? Как их объяснить?

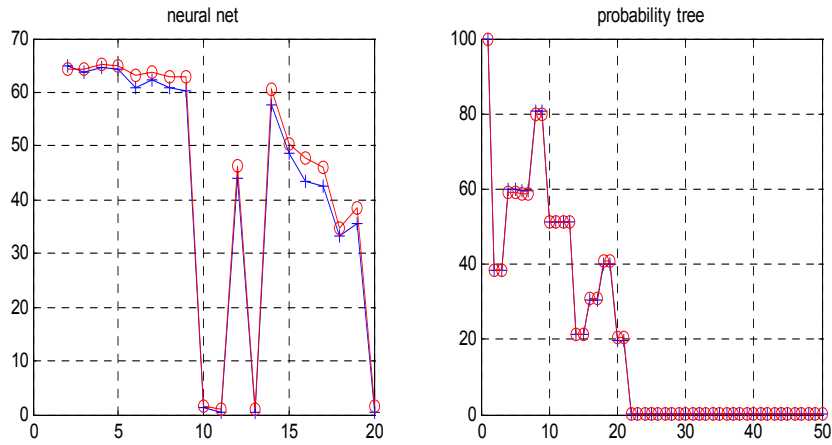


Рис. P2. Те же зависимости, что и на рис. П1, при 10 000 обучающих примерах

ЗАДАЧА 2. Свойства ядерной аппроксимации

Цель состоит в аппроксимации ступенчатой функции

$$f(x) = \begin{cases} 1, & |x| \leq 1, \\ 0, & |x| > 1 \end{cases} \quad (\text{P2.1})$$

с использованием ряда ядерных функций с фиксированным значением параметра ширины ядра γ

$$\hat{f}(x, \gamma) = \sum_j \alpha_j K(|x_j - x|^2; \gamma) = \sum_j \alpha_j \exp(-\gamma \cdot |x_j - x|^2). \quad (\text{P2.2})$$

Свободными переменными являются наборы действительных чисел — узловых точек x_j и коэффициентов α_j .

Сходится ли аппроксимация (P2.2) к функции (P2.1) в метрике \mathbf{L}_2 (интеграл от квадрата разности на действительной оси)? Если нет, то можно ли указать оценку точной нижней грани уклонения, как функции параметра γ ?

$$E(\gamma) = \inf_{\gamma} \int |f(x) - \hat{f}(x; \gamma)|^2 dx. \quad (\text{P2.3})$$

Существует ли функция (P2.2), дающая наилучшее приближение? Можно ли указать соответствующие оценки, если сумма (P2.2) содержит не более N слагаемых?

Сергей Александрович ТЕРЕХОВ, кандидат физико-математических наук, заместитель Генерального директора ООО «Нейрок Техсофт» (г. Троицк, Московская обл.). Область научных интересов — анализ данных при помощи искусственных нейронных сетей, генетические алгоритмы, марковские модели, байесовы сети, методы оптимизации, моделирование сложных систем. Автор 1 монографии и более 50 научных публикаций.

А. М. ИВАНИЦКИЙ

Институт высшей нервной деятельности и нейрофизиологии РАН,
Москва

E-mail: alivanit@aha.ru

**ПРОБЛЕМА «СОЗНАНИЕ И МОЗГ» И ИСКУССТВЕННЫЙ
ИНТЕЛЛЕКТ**

Аннотация

В работе рассмотрены современные представления о мозговых механизмах сознания. Сознание возникает в результате сопоставления и синтеза в коре мозга сведений, поступающих из внешней среды, извлекаемых из памяти и приходящих из центров мотиваций. Информационный синтез в проекционной коре лежит в основе ощущений, в ассоциативной коре — в основе мышления и принятия решений. Синтез обеспечивается возвратом возбуждения к местам первоначальных проекций после опроса других структур мозга («повторный вход»). Обсуждаются вопросы сходства и различия мозга и искусственного интеллекта, в частности, ставится вопрос о том, что такое понимание, которым обладает мозг и которого нет у компьютера.

A. M. IVANITSKY

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

E-mail: alivanit@aha.ru

**“BRAIN AND CONSCIOUSNESS” PROBLEM AND ARTIFICIAL
INTELLIGENCE**

Abstract

Contemporary ways to study brain mechanisms of consciousness are discussed. An idea is offered that the conscious event emerges in result of a synthesis in the cortical areas for information messages coming via sensory systems, retrieved from memory and arriving from motivational centers. The informational synthesis in the projection cortex is a brain base for sensation and in the associative cortex — for thinking and decision making. This synthesis are provided with the mechanism returning nerve impulses to the sites of their primary projections (“re-entry”). The similarities and the differences between brain and artificial intelligence are also discussed, particularly a problem of comprehension, characteristic for brain, but not available for computers.

Введение

Говоря об изучении физиологических механизмов сознания, можно поставить вопрос, насколько правомерно объяснить движением нервных импульсов то, что мы ощущаем как цвет, звук, мысль или эмоцию. Субъективный мир — это внутреннее чувство каждого и задача науки о мозге — понять, какие нервные процессы приводят к его возникновению. Несмотря на видимую сложность, загадка «сознание и мозг» по своей методологической трудности не уникальна и стоит в ряду других тайн природы. По существу, возникновение нового качества происходит на каждом этапе принципиального усложнения природных процессов. Как пример такого качественного перехода *Ф. Крик* и *К. Кох* приводят возникновение жизни в результате некоторых особенностей цепочек ДНК и ферментных белков. Присущие живым объектам свойства не вытекают непосредственно из физической химии каждой из этих молекул. Этот пример кажется особенно убедительным в устах одного из первооткрывателей генетического кода.

В решении проблемы «сознание и мозг» можно выделить два основных подхода, которые не исключают, а взаимно дополняют друг друга. Первый из них — представление о том, что субъективный опыт возникает на основе поступательного распространения возбуждения от первичных зон коры к структурам более высокого уровня, к которым, в первую очередь, относится лобная кора. Она обладает тремя уникальными свойствами: способностью к оперированию абстрактными символами, запоминанию временной последовательности происходящих событий и наличием центров речи. Эти три качества могут быть непосредственно соотнесены с признаками сознания.

Второй подход основан на предположении, что субъективный опыт возникает в результате определенной организации процессов мозга и сопоставления в зонах коры вновь поступившей информации с той, которая извлечена из памяти. Благодаря этому информация о внешних событиях как бы проецируется на индивидуальный опыт субъекта, встраиваясь в личностный контекст. Данная гипотеза в настоящее время разделяется большим числом авторов. Впервые она была выдвинута нами в 1970-х годах в результате проведенных исследований мозговых механизмов ощущений.

Механизмы ощущений

В работе была поставлена задача сравнить количественные показатели физиологии и психологии, описывающие ответ на поступивший сигнал. Исследуемый решал задачу по различению интенсивности двух раздражителей. На предъявляемые стимулы записывалась электрическая активность мозга в виде так называемых вызванных потенциалов (ВП), то есть ответа мозга на сигнал от органов чувств. Для получения количественных параметров ощущений были использованы методы психофизики, то есть «науки о количественном соотношении души и тела», как определил эту науку ее основатель *К. Фехнер*. В данном случае были применены методы теории обнаружения сигнала, которая рассматривает восприятие как результат взаимодействия сенсорных и мотивационных факторов.

После получения соответствующих количественных показателей физиологии и психологии вычислялись корреляции между ними. Наиболее существенной была корреляция промежуточных волн ВП с обоими факторами восприятия: показателем сенсорной чувствительности d' и критерием решения. Эта двойная корреляция отражала синтез информации о физических и сигнальных свойствах стимула на нейронах проекционной коры. Пиковая латентность соответствующих волн ВП составляла около 150 мс.

Принципиально важно, что это время достаточно точно совпало со временем возникновения ощущений, полученным ранее в психофизических экспериментах. В основном, эти измерения были проведены с использованием феномена «обратной маскировки». Суть ее заключается в том, что, если после первого слабого стимула через короткий интервал следует второй, более сильный, первый стимул не воспринимается. Постепенно увеличивая промежуток времени между первым и маскирующим сигналом, можно найти интервал, при котором маскирующий эффект исчезает, так как ощущение на первый сигнал уже сформировано. Таким путем было установлено, что ощущение появляется примерно через 150 мс после действия стимула. Наиболее точные данные были, однако, получены в начале 1990-х годов, когда в качестве маскирующего сигнала была использована прямая стимуляция коры коротким магнитным импульсом, приложенным к поверхности кожи головы. Полученные здесь данные также показали цифры, близкие к приведенным выше. При этом существенно, что магнитный импульс вызывал маскирующий эффект только в том случае, когда он прикладывался к проекционной, в данном случае, зрительной коре, то есть только там, где наблюдалась описанная выше двойная корреляция волн ВП

с показателями восприятия. Все эти данные свидетельствовали о том, что ощущение возникает значительно позднее прихода сенсорных импульсов в кору и, следовательно, является результатом сложной организации нервных процессов, которая и была изучена в нашей работе.

Основываясь на данных о физиологическом генезе волн вызванного потенциала, нами был описан механизм, обеспечивающий информационный синтез. Он включал кольцевое движение возбуждения из проекционной коры в ассоциативную кору (височную для зрительных стимулов), затем в область гиппокампа, мотивационные центры гипоталамуса с последующим возвратом по системе диффузных проекций в кору, включая и зоны первичной проекции (рис. 1). Условно этот цикл был назван нами «кругом ощущений». Суть его в том, что он обеспечивает сравнение сенсорного сигнала со сведениями, извлеченными из памяти, что, как мы предполагаем, и лежит в основе перехода физиологического процесса на уровень психических, субъективно переживаемых явлений. Эти представления были обозначены как гипотеза информационного синтеза.




Рис. 1. «Круг ощущений»

Синтез информации о физических и сигнальных свойствах стимула на нейронах зрительной коры приводит к возникновению ощущения, которое затем опознается, категоризируется при участии лобной коры. Числа в рамках — время в миллисекундах после предъявления стимула.

За прошедшие 25 лет в литературе появилось много работ, подтверждающих эти мысли, включая как данные о топографии отделов мозга, входящих в «круг ощущений», так и использование самой идеи возврата возбуждения для объяснения механизмов сознания. Среди последних работ наиболее фундаментальны исследования Дж. Эдельмана, нобелевского лауреата за изучение структуры антител, который так же, как и Ф. Крик, а до него И. П. Павлов, после получения этой высшей научной награды стал заниматься проблемами сознания. Дж. Эдельман использовал термин «повторный вход (re-entering)». Созданная им нейробиологическая теория сознания и сам термин повторный вход получили достаточно широкое распространение. Повторный вход обеспечивает и интеграцию отдельных признаков стимула в единый образ. Ощущение относится к достаточно простым психическим феноменам, которые некоторые авторы относят к так называемому «первичному сознанию».

Мышление

Более сложные психические феномены, в первую очередь, связанные с появлением речи, относят к сознанию высшего порядка. По мнению П. В. Симонова, оно имеет коммуникативную природу и возникло в процессе общения между людьми. В исследовании более сложных функций мозга, таких как мышление, значительный вклад внесли также работы Н. П. Бехтеревой и ее школы.

Современные данные показывают, что кора высоко специализирована, и разные ее поля отвечают за различные когнитивные операции. Поэтому существенную роль в процессе мышления приобретают корковые связи. В исследовании связей велика роль русской нейрофизиологической школы. Ведущей идеей здесь является то, что возникновению связи способствует согласование ритмов работы нейронных ансамблей (А. А. Ухтомский, М. Н. Ливанов, В. С. Русинов). В наших работах по изучению мышления был применен новый метод картирования корковых связей, базирующийся на тех же идеях. В работе были использованы задачи на образное, пространственное и абстрактно-вербальное мышление. Главным результатом этих исследований было установление факта, что симметричный в покое рисунок связей при решении задачи изменялся: связи начинали сходиться к определенным полям коры. Возникающие в результате этого центры связей были обозначены как фокусы взаимодействия. Их топография была

различна при разных видах мышления. Так, при образном мышлении (опознании эмоций на фотографиях лица) фокусы локализовались в теменно-височной коре. При абстрактно-вербальном мышлении (на примере решения анаграмм или категоризации слов) они были расположены в лобной коре (рис. 2). При пространственном мышлении, включающем элементы как образного, так и абстрактного мышления, образование фокусов происходило в теменной и лобной коре.

В фокусе происходит синтез поступающей по связям информации, благодаря чему, как можно предполагать, и достигается решение. Тем самым

ОБРАЗНОЕ (опознание эмоций)



ВЕРБАЛЬНОЕ (решение анаграмм)



Рис. 2. Топография фокусов взаимодействия при двух видах мышления

На картах мозга интенсивностью окраски обозначены области коры, в зависимости от нормированного числа подходящих к ним связей. При образном мышлении фокусы расположены в теменно-височной, а при вербальном — в лобной коре. Центр восприятия речи в левой височной коре (зона Вернике) задействована в обоих случаях.

идея информационного синтеза была распространена и на процессы мышления. Различие заключается в том, что вместо двух информационных потоков при ощущении при мышлении их число значительно больше. Сюда относятся сигналы от органов чувств, из оперативной и долговременной памяти и, что очень важно, мотивация из мотивационных центров. Другое различие в том, что центры синтеза при мышлении находятся в ассоциативной, а не в проекционной, как при возникновении ощущений, коре. Интересно также, что при всех видах задач, даже в том случае, когда речевой ответ испытуемого не требовался, на последнем этапе решения фокусы возникали в речевой левой височной области, что свидетельствует о том, что вербализация является у человека важным компонентом мышления. В этом смысле можно говорить о конвергенции двух подходов к решению проблемы «сознание и мозг» — психическое возникает на основе определенной организации нервных процессов, которая захватывает и некоторые ключевые области лобной коры.

Декларативная память и внимание

Важным свойством сознания является способность к запоминанию и воспроизведению последовательности событий. В исследовании механизмов человеческой памяти в последние годы был достигнут значительный прогресс. Работами ряда отечественных и американских авторов была установлена важная роль гиппокампальных структур, расположенных в височных отделах полушарий, в оперативной памяти. Эти образования имеют обширные связи как между собой, так и с сенсорными и ассоциативными отделами коры (рис. 3). Считается, что при запоминании они направляют сигнал в ассоциативную кору для длительного хранения, а при воспроизведении указывают адрес, где хранится связанная с поступившим сигналом информация.

Гиппокампальный комплекс выполняет, таким образом, роль, сходную, в известной мере, с библиотечным каталогом, благодаря которому можно быстро найти нужную книгу. Различие между этими двумя основными структурами комплекса заключается в том, что энторинальная кора участвует в запоминании информации вне ее связи с контекстом, а гиппокамп играет важную роль в декларативной памяти, которая представляет собой осознаваемую память о событиях, сведения о которых могут быть переданы другим лицам. Для пояснения различия между семантической и деклара-

Долговременная память – ассоциативная кора:
лобная височная теменная




Рис. 3. Структуры мозга, связанные с функцией памяти

тивной памятью можно привести простой пример. Предположим, что вы встречаете человека, лицо которого вам знакомо, но вы не помните, кто он. Это узнавание, связанное с семантической памятью. В случае декларативной памяти вы знаете, кто это, и при каких обстоятельствах вы с ним познакомились.

Наряду с гиппокампом, важную роль в запоминании последовательности событий играет и лобная кора. Там находятся группы нейронов, способные сохранять след от действовавшего сигнала до того момента, когда необходимо дать поведенческий ответ на него (*П. Гольдман-Ракич*).

Сознание также тесно связано со вниманием: осознается только то, на что обращается внимание. Нашими исследованиями было показано, что память играет важную роль и в механизмах избирательного вербального внимания, когда человек должен воспринимать и реагировать лишь на определенный класс сигналов, выделяя их из массы других. Способность к этому иногда называют «эффектом коктейль-парти», когда человек должен поддерживать диалог с собеседником, выделяя его речь и других разговоров и других звуков. В работе использовалась запись вызванных потенциалов мозга на слова, одновременно предъявлявшиеся на экране монитора и звучавшие из компьютерных колонок. Задача испытуемого состояла в необходимости запомнить как можно больше слов, поступавших по одному

из каналов, игнорируя другие. Запоминание и извлечение вербальной информации имеет определенное электрофизиологическое выражение в виде «когнитивных» компонентов вызванного потенциала с латентностью от 400 до 700 мс. Было установлено, что ВП на игнорируемый сигнал характеризовался сдвигом потенциала, обратным по полярности тому, который имеет место при запоминании, что свидетельствовало об активном торможении процессов памяти. Это дает возможность считать, что избирательность внимания обеспечивается тем, что ненужная информация воспринимается, и человек слышит и видит слово, но затем имеет место блокада передачи сведений на структуры гиппокампа, вследствие чего ненужная информация не сохраняется в декларативной памяти и вытесняется из сознания.

Основные механизмы сознания

Подведем итог представлениям о возможных механизмах сознания:

1. Возврат возбуждения и сравнение новой информации с памятью — фундаментальный принцип организации процессов мозга, лежащих в основе субъективного опыта. Его специфика определяется топографией центров синтеза.
2. Синтез информации в проекционной коре лежит в основе ощущений, в ассоциативной коре — в основе мышления и поиска решений.
3. Лобная кора ответственна за абстракцию и речь. Вместе с височной корой она осуществляет объединение существительного и глагола, что образует элементарную единицу вербального мышления.
4. Гиппокамп вместе с лобной корой обеспечивает сохранение в памяти последовательности событий и избирательность внимания.

Общим для всего перечисленного является участие в механизмах сознания памяти. Постоянное сопоставление вновь поступившей информации с памятью определяет содержание сознания как постоянную корректировку личного опыта, того, что можно определить как чувство внутреннего «я».

Решение проблемы о происхождении сознания и его связи с мозгом — одна из важнейших проблем современной науки. Оно необходимо для создания непротиворечивой картины мироздания, которая бы объединяла естественно-научное и гуманитарное знание. Не менее существенно оно и для практики: организации труда и отдыха, образования и воспитания. Особое значение имеет проблема для медицины.

Скажем и о некоторых следствиях из наших знаний о природе сознания, которые носят более общий характер. Сознание человека формируется в течение жизни индивидуума. В центре сознания находится ощущение своего «я» как хозяина и распорядителя своих действий. Чувство свободы поэтому изначально, его неоправленное ограничение деформирует сознание. Разумным ограничением свободы каждого является требование не нарушать свободу других людей. Это основная нравственная заповедь, которая, в отличие от первичного чувства свободы, должна быть предметом воспитания. Сознание не только отражает бытие, оно обладает и способностью к прогнозу, формируя бытие будущего. Опираясь на знания, мы можем и должны создавать общество будущего, в котором принципы общественного устройства находились бы в гармонии с базисными свойствами сознания человека.

Физиология мозга и проблема искусственного интеллекта

Встает вопрос, в какой мере знания о механизмах мышления и сознания человека могут быть использованы при создании искусственного интеллекта. Ведь, в принципе, создание искусственного разума возможно и без использования принципов работы мозга, как, например, конструкция автомобиля не имитирует естественные методы передвижения человека в виде ходьбы или бега. Есть, однако, причина, по которой использование принципов работы мозга может оказаться полезным. Дело в том, что мозг по многим важным параметрам превосходит искусственные вычислительные устройства: он более надежен, экономичен и легко обучаем. Можно предполагать, что простое усовершенствование уже имеющихся искусственных систем не может, очевидно, достичь поставленных целей, так как принципы работы мозга во многом отличаются от тех, на которых построен современный компьютер. Мозг отличается от компьютера тем, что он не имеет центрального процессора, который в компьютере оперирует четкими сигналами и который обрабатывает эти сигналы по заданным программам. Напротив, мозг получает, как правило, недостаточно определенные сигналы, оценка которых во многом зависит от контекста, и сам создает программы в результате обучения. Наряду с жесткими связями, мозг использует и гибкие связи, которые образуются на основе синхронизации ритмов деятельности нейронных ансамблей. Благодаря этому, мозг осуществляет эффективный поиск хранящейся в памяти информации, актуальной для выполнения

определенной функции. Этот поиск включает в себя и элементы эвристики, неожиданных, но полезных решений.

Надежность мозга при наличии таких, в общем, несовершенных систем анализа сигналов обеспечивается их многократным дублированием. Важной находкой эволюции является также принцип возврата информации к местам первоначальных проекций. Благодаря этому новая информация в мозге постоянно сопоставляется с той, которая хранится в памяти. При мышлении механизм информационного синтеза получает наибольшее развитие. Как уже говорилось, при этом в коре возникают центры связей — фокусы взаимодействия, принимающие информацию из других отделов мозга и осуществляющие ее синтез. Данное положение важно с той точки зрения, что оно указывает на существенный и не неиспользуемый в большинстве искусственных нейросетей прием: нейронные сети мозга не гомогенны, а построены по иерархическому принципу.

Высшие функции мозга возникают, таким образом, на основе высокой степени интеграции специализированных звеньев в единую систему. Эта система представляет собой более высокий уровень организации и обладает поэтому иной логикой и закономерностями саморазвития. Эти законы могут в порядке нисходящей детерминации влиять на протекание процессов, входящих в состав системы и образующих ее. Так логика и грамматика речи могут управлять движением нервных импульсов, управляющих артикуляцией. По мысли философа *Д. И. Дубровского*, отсутствие такой нисходящей детерминации от общего к частному является существенным отличием компьютера от живого мозга. По существу, видением общей задачи вычислением обладает лишь программист, но не центральный процессор.

Перейдем к, может быть, самому таинственному отличию мозга от компьютера. По мнению английского математика и физика *Р. Пенроуза*, сознание не может быть сведено к вычислениям, так как живой мозг отличается от компьютера тем, что обладает способностью к пониманию. На вопрос, что такое понимание и каковы его мозговые механизмы, ответ должен дать физиолог. Почему же животное, например кошка, понимает, а компьютер — совершенное создание высокого интеллекта — нет. Представляется, что понимание возникает в результате подкрепления, то есть на основе такого фундаментального принципа работы мозга, как условный рефлекс, который связывает внешний стимул и ответные действия субъекта с удовлетворением определенной потребности. Понимание, таким образом, имеет глубокие эволюционные корни и высокий жизненный смысл. В естественных условиях животное научается производить определенные действия, чтобы

удовлетворить ту или иную потребность, то есть начинает понимать связь внешних событий, своего поведения и достижение желаемого результата. На этом же основана и дрессировка: чтобы научить собаку выполнять, то есть понимать, определенные команды, дрессировщик использует подкрепление в виде пищи или наказания. По существу, все это изначально относится и к человеку. Так, хороший работник имеет более высокую зарплату, а нерадивого работника штрафуют, герой получает награду, а преступника сажают в тюрьму, чтобы он понял, что нельзя нарушать закон. Но это, конечно, крайние случаи. Практически же все поведение основано на тех же принципах.

Для обоснования своих взглядов *Р. Пенроуз* использует теорему Гёделя о том, что нельзя доказать вычислением правильность основных действий арифметики, например, что $1+1=2$. Но живое существо в этом убеждается, когда получает два банана, двух врагов или двух жен, добавляя в результате тех или иных действий к первому объекту (или субъекту) второй (или вторую). При этом понимание сущности удвоения (или сложения вообще) возникает в эволюции раньше, чем умение считать. Описан, например, случай, когда коренной житель севера не знал, сколько у него оленей, но легко мог перечислить каждого из них по их признакам. Ребенок также может перебрать в памяти всех окружающих его людей или свои игрушки, хотя еще не знает счета.

Подкрепление показывает, является ли поведение верным или ошибочным. В стохастической машине, какой является мозг, такое указание может быть решающим фактором. При этом собственно информационная составляющая в виде вычислений и показатель ее правильности, как правило, поступают по разным каналам и являются, в известной степени, ортогональными. Два компонента «понимания» могут быть представлены сенсорным сигналом и импульсами из мотивационных центров, которые, как говорилось выше, необходимо присутствуют при переходе чисто физиологического процесса в его психический эквивалент. Импульсы из центров мотивации первично непосредственно сигнализируют об удовлетворении потребности. Впоследствии они также могут быть включать систему вычислений, которая оценивает успешность продвижения к цели и выдает команду, когда достигается приемлемая в данной ситуации вероятность получения полезного результата. При этом мотивационная составляющая выступает как аксиома и завершает вычисления. Аксиоматичность подкрепления базируется на знаковой оценке полезности или вреда, которая воспринимается как не требующие доказательств. Мозг вынужден действо-

вать по методу проб и ошибок и учиться на них, так как реальные жизненные условия настолько сложны, что их практически невозможно просчитать до конца. Связь понимания с мотивацией подчеркивается и самой этимологией слова «понимание», которое происходит от корня «иметь». То же мы имеем и в английском языке: понимание (comprehension) родственно слову prehension — завладение.

Сказанное выше, конечно, является далеко не полным. Мы еще многое не знаем о работе мозга, и особенно о том, что лежит в основе его высших функций и человеческого сознания. Тем не менее, прогресс в этой области в последние годы достаточно очевиден. Оптимистичны и те рекомендации, которые наука о мозге может дать создателям искусственного интеллекта. И мозг, и компьютер находятся в физическом мире и подчиняются его законам. Никакой из перечисленных выше принципов работы мозга не выходит за эти рамки и может быть воспроизведен и усовершенствован в устройствах, созданных человеком.

Работа выполнена при поддержке Российского гуманитарного научного фонда (проект № 05-06-06-215а), программы Президиума РАН «Фундаментальные науки — медицине» и программы ОБН РАН «Интегративные механизмы регуляции функций и организмов».

Литература

1. *Иваницкий А. М., Стрелец В. Б., Корсаков И. А.* Информационные процессы мозга и психическая деятельность. — М.: Наука, 1984. — 200 с.
2. *Иваницкий А. М.* Главная загадка природы: как на основе процессов мозга возникают субъективные переживания // *Психологический журнал*. — 1999, т. 20, вып. 3. — с. 93–104.
3. *Ливанов М. Н.* Пространственная организация процессов головного мозга. — М.: Наука, 1972. — 181 с.
4. *Пенроуз Р.* Тени разума. В поисках науки о сознании. Часть 1. Понимание разума и новая физика. — М.-Ижевск: Институт компьютерных технологий, 2003. — 368 с.
5. *Симонов П. В.* Лекции о работе головного мозга: Потребностно-информационная теория высшей нервной деятельности. — М.: Наука, 2001. — 96 с.
6. *Edelman G. M., Tononi G.* Consciousness: How matter becomes imagination. — London: Pinguin Books, 2000. — 274 pp.

7. *Ivanitsky A. M., Nikolaev A. R., Ivanitsky G. A.* Cortical connectivity during word association search // *Int. J. Psychophysiol.* – 2001. – Vol. 42, No. 1. – pp. 35–53.
8. *Mishkin M., Suzuki W., Gadian D. G., Varha-Khadem F.* Hierarchical organization of cognitive memory // *Phi. Trans. R. Soc. Lond. B.* – 1997. – v. 352. – pp. 1461–1467.
9. *Posner M. I., Raichle M., E.* Images of Mind. – New York: Scientific American Library, 1997. – 255 pp.

Алексей Михайлович ИВАНИЦКИЙ, член-корреспондент РАН, профессор, доктор медицинских наук. Заведующий Лабораторией высшей нервной деятельности человека Института высшей нервной деятельности и нейрофизиологии РАН.

В. Г. ЯХНО

Институт прикладной физики РАН,
Нижний Новгород

E-mail: yakhno@appl.sci-nnov.ru

**ДИНАМИКА НЕЙРОНОПОДОБНЫХ МОДЕЛЕЙ И ПРОЦЕССЫ
«СОЗНАНИЯ»**

Аннотация

Рассмотрены варианты базовых моделей нейроноподобных систем для описания динамических процессов обработки информационных сигналов. Проведено сопоставление некоторых динамических процессов в этих системах с процессами осознания внешних стимулов и внутренних состояний нейроноподобных систем.

V. YAKHNO

Institute for Applied Physics, RAS,
Nizhny Novgorod

E-mail: yakhno@appl.sci-nnov.ru

**DYNAMICS OF NEURON-LIKE MODELS AND CONSCIOUSNESS
PROCESSES**

Abstract

The variants of basic neuron-like models for dynamical processes of information flow transformation are considered. Some dynamic modes of neuron-like models are compared with examples of consciousness processes in living being.

Введение

Обсуждению процессов сознания, или описанию того, что интуитивно обозначается «сознанием», посвящена обширная литература (см., например

[1–5].) В тоже время, в связи со сложностью самого объекта рассмотрения, не сразу удастся найти формализованные базовые модели, адекватные определения и описания динамических процессов. Примеры модельного описания осознанного поведения живых систем имеются, в частности, в работах [5–13]. Основная трудность при дальнейшем развитии таких моделей связана с определением минимально необходимого набора функциональных переменных и конструирования таких систем, в которых могут происходить динамические процессы аналогичные известным данным об осознанном поведении живых систем.

В докладе предлагается использовать функциональные модели нейроноподобных систем. С их помощью возможно описание динамики адаптивного преобразования информационных сигналов, процессов обмена моделями (алгоритмами обработки сигналов) в элементарных адаптивных распознающих системах, рассмотрение деталей взаимодействия между нелинейными системами принятия решений с иерархической архитектурой [13–21]. Варианты режимов реагирования таких адаптивных систем распознавания на внешние сигналы сравниваются с известными психологическими реакциями живых систем.

Варианты моделей нейроноподобных систем

Многие экспериментальные результаты, связанные с поведением иерархических систем распознавания, могут быть рассмотрены на основе как минимум трех групп базовых моделей (примеры схематического представления моделей для случая нейроноподобных систем приведены на рис. 1–3):

- 1) различные варианты однородных нейронных сетей для выделения заданного набора признаков в параллельном режиме (рис. 1);
- 2) адаптивные ячейки распознавания, содержащие алгоритмы кодирования и реконструкции входных изображений, базы данных, алгоритмы вычисления полей невязок (мотиваций), алгоритмы принятия решений по виду полей невязок, а также базы используемых алгоритмов (знаний) (рис. 2);
- 3) иерархические системы из адаптивных ячеек распознавания, каждая из которых настроена на заданный для нее набор операций (рис. 3 и рис. 4).

Фактически каждая из приведенных базовых моделей с характерными для них переменными и наборами функциональных динамических режи-

$$\frac{du}{dt} = -\frac{u}{\tau_1} + \beta_{F_1}(g) \cdot F_1 \left[-t_1(g) + \int_{-\infty}^{\infty} \Phi_1[(\xi - r), g] u(\xi, t) d\xi \right] + D_1 \frac{\partial^2 u(t, \vec{r})}{\partial r^2}, \quad (1)$$

$$\frac{dg}{dt} = -\frac{g}{\tau_2} + \beta_{F_2}(g) \cdot F_2 \left[-t_2(g) + \int_{-\infty}^{\infty} \Phi_2[(\xi - r), g] u(\xi, t) d\xi \right] + D_2 \frac{\partial^2 u(t, \vec{r})}{\partial r^2}. \quad (2)$$

Рис. 1. Модель для однородных систем

Функциональные операции, выполняемые моделью: Параллельные режимы выделения необходимых наборов признаков, вычисление мер сравнения.

Характерные динамические режимы: Различные процессы формирования структур коллективной активности (например, автоволновые процессы, упрощенные изображения для вычисления признаков).

мов представляют собой те базовые понятийные элементы языка, на основе которых строится описание возможных вариантов поведения автономных распознающих систем. Предполагается, что они могут настраиваться на вид обрабатываемого изображения и условия работы системы. Использование таких моделей позволяет проводить классификацию и вводить новые определения для ряда динамических режимов, которые аналогичны известным психологическим или социальным реакциям живых систем.

Однородные нейроноподобные системы

Однородные нейроноподобные системы могут быть отнесены к **первому типу** моделей и записываются, например, в виде интегро-дифференциальных уравнений типа (1)–(2), показанных на рис. 1. Такая двухкомпонентная модель первоначально была получена из уравнений, описывающих взаимодействие нейронов с возбуждающими и тормозными связями в участке коры головного мозга животных, содержащем сотни тысяч нервных клеток в приближении однородности рассматриваемого участка [13, 21–24]. При

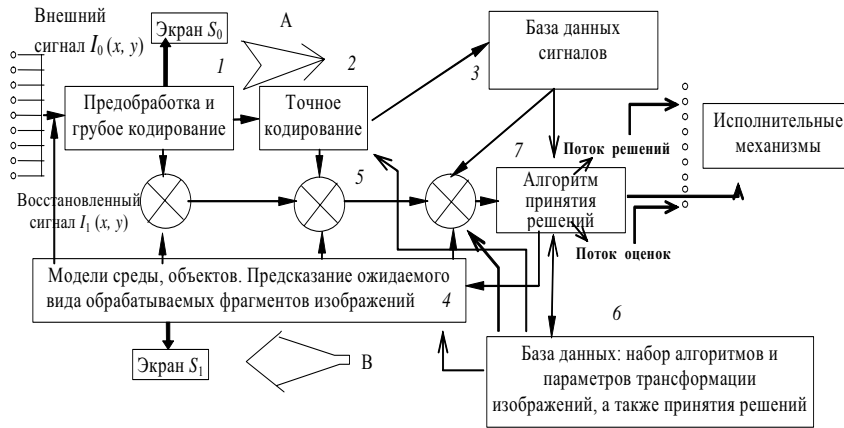


Рис. 2. Адаптивная нейроноподобная система распознавания. Показаны этапы трансформации потоков информационных данных и взаимодействие между различными обрабатывающими блоками в адаптивной системе принятия решений с фиксированным набором алгоритмов.

Функциональные операции, выполняемые моделью: Для повышения точности принятых решений и определения особенностей распознаваемых фрагментов изображений выполняется оценка качества работы алгоритмов, используемых в системе.

Характерные динамические режимы: Входное изображение последовательно несколько раз кодируется, а затем восстанавливается. По динамике изменения величин на поле невязок вычисляются оценки качества кодирования. Подбираются параметры алгоритмов или выбираются наиболее адекватные алгоритмы на основе целевой функции, вычисляемой из данных поля невязок.

интегральном описании активности многих ансамблей из нейроноподобных элементов используются две наиболее важные переменные: $u(t, \vec{r})$ и $g(t, \vec{r})$. Первая переменная обычно описывает уровень активности популяций возбуждающих нейронов, а вторая переменная — уровень активности популяций тормозных нейронов. Функции $\Phi_i(\vec{\xi} - \vec{r})$ имеют вид так называемого «латерального» торможения, $\Phi(R) = (1 - akR^2)e^{-aR^2}$, а $F_m[\cdot]$ имеет монотонный, ступенчато-подобный вид. Изначально система (1)–(2) была ориентирована на описание процессов в однородных нейронных сетях сет-




Рис. 3. Иерархическая система распознавания из трех однотипных блоков: распознавания статических изображений; распознавание временных изменений; распознавание ситуаций

Показаны пути передачи информационных данных и управляющих воздействий между различными блоками принятия решений.

Функциональные операции, выполняемые моделью: Разные блоки настраиваются на обработку сигналов только «своей» модальности и выполнение инструкций от «вышестоящих» управляющих блоков.

Характерные динамические режимы: Динамика настройки, зависящая от особенностей информационных сигналов разных модальностей и используемого набора целей.




Рис. 4. Иерархическая система взаимодействующих популяций адаптивных распознающих систем

Функциональные операции, выполняемые моделью: Выполнение операций преобразования потока информационных сигналов сетью взаимосвязанных распознающих систем, потребляющих выделенные «энергетические» и «информационные» ресурсы.

Характерные динамические режимы: Различные процессы формирования динамических структур коллективной активности взаимодействующих распознающих систем.

чатки глаза, коры некоторых отделов головного мозга и т. п. [13, 22–24]. В то же время понятно, что уравнения типа (1)–(2) представляют собой универсальную модель, описывающую динамику распределенной среды из активных элементов, имеющих произвольную физическую природу. Модель (1)–(2) справедлива для однородных молекулярных систем, процессов активности в клетках, клеточных популяциях, тканях организмов, популяциях организмов, различного вида однородных сетях из процессорных

элементов [18–21]. Предполагается существование взаимосвязанных активных (триггероподобных) элементов в ядрах [25], в лабораторной плазме [26–30], и, возможно, в плазменных облаках космических масштабов. Следовательно, функциональные процессы преобразования информационных сигналов, описываемых моделью (1)–(2), могут происходить аналогичным образом в системах с широким диапазоном пространственных масштабов, а временные характеристики процессов будут определяться конкретными механизмами активности в соответствии с теми или иными пространственными масштабами.

Было показано, что в системах типа (1)–(2) базовые пространственно-временные автоволновые процессы представлены:

- фронтами переключений между различными стационарными состояниями;
- разнообразными импульсными решениями;
- автономными источниками волн;
- разнообразными структурами синхронизации и фазировки для систем из автоколебательных нейроноподобных элементов.

В работах [14, 18–33] приведены примеры результатов таких исследований. Неизменность коэффициентов и функций (типа $\Phi_i(\vec{\xi} - \vec{r})$ и $F_m[\cdot]$) в модельных системах означает неизменность уровня неравновесности в активных элементах. Такое возможно лишь в системах, обеспеченных всеми необходимыми энергетическими ресурсами.

Однородные системы из взаимосвязанных активных элементов моделируют либо функциональные процессы кодирования (вычисления признаков) информационного сигнала в параллельном режиме, либо варианты генерации разнообразных изображений из начальных упрощенных стимулов. Такие процессы составляют только часть процесса «сознания».

Модели адаптивных распознающих систем

Ко второму типу моделей относятся «элементарные» системы принятия решений с фиксированными алгоритмами, в которых используются управляющие алгоритмы для повышения точности режимов распознавания. Оптимизация проводится как под особенности вида сигнала, так и под задачи, решаемые такой адаптивной распознающей системой.

Такой тип адаптивных моделей рассматривался в [14–17, 34–35].

Функциональная модель для элементарных распознающих систем с адаптивными свойствами (см. рис. 2) состоит из блоков преобразования (кодирования и восстановления) информационных сигналов, блоков сохранения кодового описания этих сигналов и используемых для их обработки алгоритмов (моделей), блоков оценки близости восстановленного сигнала к виду исходного сигнала, и принятия решений [14–17]. Если требуется использование режимов параллельного преобразования сигналов, то для выполнения операций во всех этих блоках могут быть задействованы модели однородных нейроноподобных систем [13, 14, 18–21, 28, 31–33]. Это означает, что модели второго типа можно полностью построить из слоев, преобразование сигналов в которых описывается моделями первого типа (однородных систем).

Вариант функциональной модели с адаптивными свойствами показан на рис. 2. Такая элементарная система состоит из следующих подсистем:

- блоки кодирования (1, 2), восстановления или имитации информационных сигналов (4);
- блоки сохранения кодового описания этих сигналов (3) и используемых для их обработки алгоритмов — моделей (6);
- блоки оценки близости сигналов (5) и принятия решений (7).

Важное отличие рассматриваемой здесь архитектуры адаптивных систем [14–17], соответствующих «живым» прототипам, от «обычных» систем распознавания заключается в обязательном существовании в них специальных подсистем для создания имитации ожидаемого входного сенсорного сигнала и сравнения его с реально поступившим сигналом (блоки 4 и 5).

Фактически, алгоритмы блока 4 позволяют распознающей системе создавать «виртуальную реальность», которую необходимо сравнивать с реальными входными сигналами для принятия адекватных решений. Имеется множество подтверждений существования таких блоков создания «виртуальной реальности» в живых системах. К наиболее известным из них можно отнести процессы сна, возможных галлюцинаций, различных режимов анализа проблемных ситуаций, когда на «внутреннем экране» могут возникать яркие образы объектов или ситуаций, с которыми живое существо играет или просто наблюдает динамику этого процесса.

Опираясь на формальную схему с архитектурой типа показанной на рис. 2, можно сказать, что в функциональном смысле каждая система «спит в своем сне». Термин «сон» подразумевает активность системы, связанную

с обработкой исключительно внутренних информационных сигналов, использованием наборов моделей поведения, которые были активированы в этой живой или технической системе внешними воздействиями. Степень адекватности внутренних информационных сигналов смыслу внешних, «реальных», воздействий зависит от возможностей рассматриваемой адаптивной системы настроить свой «сон» на эти внешние сигналы.

В технических адаптивных системах, по аналогии с живыми системами, естественно ожидать большую оптимизацию их работы в режимах предварительной настройки этих систем на планируемую ситуацию и наборы действий, которые эти системы будут совершать.

Функциональная модель с адаптивными свойствами позволяет на количественном уровне описывать различные динамические реакции на внешние сигналы. Ее можно использовать для оптимизации процессов в технических системах, а можно, из сопоставления с данными нейрофизиологических исследований [36–47], предлагать варианты механизмов для интерпретации психологических режимов реагирования живых систем в процессе осознания ими действующих на них информационных сигналов.

В функциональной модели, показанной на рис. 2, используются следующие переменные:

- I_n — входное изображение — сигнал, поступающий на обработку в распознающую систему;
- $A_n(E_{n-1})$ — формализованное представление знаний в системе, включающих используемые идеи, методы, модели и алгоритмы;
- $Code_n$ — векторы кодового описания входного сигнала;
- Int_n — изображение, интерпретирующее входной информационный сигнал, которое генерируется распознающей системой из кодового описания входного изображения;
- $M_n(Code_{n-1})$ — вектор (или изображение) для величин невязок — мотиваций, полученных из сравнения наборов кодов входного изображения и кодовых описаний для предварительно ожидаемого системой изображения;
- D_n — решения, принятые распознающей системой;
- R_n — оценки уверенности, статистической достоверности принятого решения;
- I_{n+1} — сигнал на выходе распознающей системы, состоящий из набора величин $D_n, R_n, A_n(E_{n-1}), Int_n$;

- E_{n-1} — необходимые ресурсы для обеспечения активного состояния распознающего устройства при работе тех или иных алгоритмов. В самом простом случае, этот параметр может описывать только одну величину: потребляемые энергетические ресурсы, требуемые для работы конкретного алгоритма.

Уровень выходной величины E_n — созданные или оставшиеся ресурсы — определяется особенностями работы исполнительных механизмов, которые запускаются на основании решения распознающей системы D_n , R_n .

Использование схематического описания адаптивной распознающей системы (рис. 2) позволяет ввести формальные определения для ряда динамических процессов и используемых переменных, которые обычно связаны с понятиями, вызывающими споры при обсуждении информационных систем.

Данными называются наборы признаков или кодовых описаний, вычисленные с входных изображений или сами эти изображения. Хранятся данные в блоке 3 (см. рис. 2).

Знаниями в рассматриваемой системе естественно назвать наборы алгоритмов $A_n(E_{n-1})$, которые могут использоваться в процессах обработки и принятия решений. Знания в соответствии с используемой архитектурой адаптивной системы расположены в блоке 6.

Ценность входного информационного сигнала может определяться по величинам невязок в блоке 5, вычисляемых из сравнения наборов кодовых описаний для предварительно ожидаемого системой изображения (блок 4) и реально вычисленными кодами от входного изображения (блоки 1, 2). Эти же величины невязок служат стимулом для формирования **мотиваций** и принимаемых решений в блоке 7 для дальнейшего функционирования системы. Фактически через алгоритмы принятия решений в блоке 7 осуществляется управление состояниями всех частей распознающей системы. Если учитывать иерархию отношений между программами, то программы принятия решений и поддержки их возможной реализации в блоке 7 представляют собой **операционную систему**, под управлением которой работают все остальные элементы распознающей системы, представленные на рис. 2.

Элементарный режим проявления «сознания» в такой формализованной системе естественно определить как динамический процесс кодирования-восстановления и поиска оптимальных алгоритмов в системе (рис. 2).

Важно понимать, что более сложные режимы «сознания», реально наблюдаемые в живых системах, обычно включают в себя дополнительные динамические процессы, отражающие взаимодействие многих элементарных распознающих ячеек. Об этом речь пойдет чуть ниже.

Рассмотрим наиболее очевидные динамические режимы, возможные в модельной системе в ответ на входной сигнал.

Вычисленные с помощью алгоритмов кодирования параметры и признаки входного сигнала $Code_n$ (входные и промежуточные изображения, разные варианты кодовых описаний) сравниваются с изображениями и кодовыми описаниями, взятыми из базы данных, а также вычисленными с помощью алгоритмов декодирования, для ожидаемого объекта. Результат (мера сравнения) представлен в величинах вектора (изображения) невязок $M_n(Code_{n-1})$. Алгоритм принятия решений сравнивает эту меру с заданными порогами. Обычно используется два порога.

Если мера больше большего порога, то система принимает решение «Этот сигнал мне неизвестен» и, чаще всего, такой сигнал в живой системе не замечается. Он выпадает из процесса осознания.

Если мера меньше меньшего порога, то система принимает решение «Да, это то, что ожидалось». В этом процессе, по данному выше определению, «сознание» еще отсутствует. Этот режим, по-видимому, аналогичен инстинктивным, неосознанным, реакциям в живых системах.

Если же величина результирующей меры сравнения лежит в диапазоне между заданными величинами порогов, то система начинает изменять параметры алгоритмов кодирования-декодирования или изменять сами эти алгоритмы $A_n(E_{n-1})$, пока мера не станет меньше меньшего порога. После этого система принимает решение «Да, это то, что ожидалось». Система принимает отрицательное решение в случае, если при всех тестах на оптимизацию (изменениях параметров или алгоритмов) величина меры сравнения остается в прежнем, исходном диапазоне: между меньшим и большим порогами принятия решения. Естественно, что система с исследовательскими целями может запоминать «неизвестный сигнал» для последующего анализа и его классификации.

Эти процессы, в соответствии с приведенным выше определением, связаны с проявлением элементарного «сознания» в системе, вне зависимости от того, положительное или отрицательное решение было принято. При этих процессах «осознания» система в ответ на входной информационный сигнал I_n формирует выходной результирующий информационный сигнал в виде $I_{n+1}(D_n, R_n, A_n(E_{n-1}), Int_n)$. Если процесса осознания не было,

то в выходном сигнале $I_{n+1}(D_n, R_n, A_n(E n_{n-1}), -)$ будет отсутствовать имитация входного сигнала Int_n .

При реализации процессов «сознания» возможно существование, как минимум, двух режимов настроек.

В первом случае, решение об оптимизирующей процедуре подбора параметров или алгоритмов принимается непосредственно по виду вектора невязок из сравнения с кодовыми описаниями ожидаемого объекта.

Во втором, могут вычисляться дополнительные признаки для оценки качества работы используемых алгоритмов распознавания. Для этого проводят сравнения с кодовыми описаниями анализируемого изображения на предыдущих шагах кодирования. Такой режим возможен за счет использования пары согласованных алгоритмов кодирование-восстановление. Полученное кодовое описание входного изображения восстанавливается в интерпретацию этого входного изображения, затем восстановленное изображение снова запускается на кодирование и так далее. Скорость сходимости величин невязок $M_n(Code_{n-1})$ в этом цикле «кодирование \rightarrow восстановление \rightarrow кодирование $\rightarrow \dots$ » и величины отличий от первоначально полученных значений характеризуют адекватность и качество работы выбранных алгоритмов для обрабатываемого изображения. Вычисление оценок качества используемых алгоритмов выполняется для одного входного изображения, но на основе статистического опыта в предварительной процедуре обучения.

Данные нейрофизиологических исследований [36–42] определенно указывают на важную роль циклических процессов кодирования и восстановления сенсорных сигналов для осознания внешнего сигнала. Например, результаты пионерских работ *А. М. Иваницкого* показали, что психологические процессы осознания внешних сенсорных сигналов обязательно связаны с круговой активацией подкорковых структур мозга и возвратом этой активности на те же самые нейроны коры, с которых сенсорный сигнал запускался на обработку в мозг [38–40].

При анализе нелинейных режимов функциональной системы очень интересно рассмотреть детали динамики циклического процесса «кодирование \rightarrow восстановление \rightarrow кодирование $\rightarrow \dots$ », процедуры вычисления оценок качества работы алгоритмов преобразования тех или иных входных изображений, а также возможные особенности последующего принятия решений. Действительно, по сформированным векторам (изображениям) мотивационных сигналов $M_n(Code_{n-1})$ определяются условия, при которых необходимо корректировать параметры используемых алгоритмов или про-

водить замену «старых» алгоритмов на «новые» алгоритмы кодирования. Важно обратить внимание, что термины «старые» и «новые» алгоритмы фактически обозначают различные модельные представления распознающей системы о распознаваемом объекте и условиях работы этой системы. При этом, возможность выполнения операций замены одних алгоритмов на другие в блоках кодирования-восстановления означает очень важную техническую особенность рассматриваемой системы распознавания: все используемые алгоритмы должны обладать одинаковыми интерфейсами!

Выполняется ли это требование и в живых системах? Если ответ утвердительный, то такие функциональные режимы адаптации распознающей системы фактически подтверждают возможность осознания живыми системами ощущений, которые отсутствовали в их жизненном опыте. Частично это снимает завесу таинственности с многочисленных данных о некоторых мистических ощущениях людей в измененных состояниях сознания [44, 45]. В то же время, остается открытым вопрос о существующих в природе вариантах физических механизмов передачи новых знаний живым системам [46]. С какими динамическими процессами в функциональной модели может быть связано осознание факта получения нового алгоритма (знания) в блоке 7 адаптивной системы?

Известно, что в реальной жизни адаптивные распознающие системы заинтересованы в получении точных решений D_n , R_n , Int_n для того, чтобы обеспечить доступ к необходимым ресурсам при выполнении поставленных целей, а также получить возможность усовершенствования или модернизации доступного им набора знаний. Данные о динамических процессах в нелинейных моделях позволяют формализовать описание ряда режимов непонимания при взаимодействии между адаптивными распознающими системами [36, 37, 46]. Хотя с житейской точки зрения непонимание легко объяснимо. Чаще всего, именно отсутствие внутренних ресурсов для усовершенствования или модернизации необходимого для общения набора знаний приводит к конфликтам непонимания. Модельная система позволяет классифицировать эти процессы.

Модели взаимодействующих распознающих систем

К третьему типу естественно отнести модели, описывающие различные варианты возможных взаимодействий между «элементарными» адаптивными распознающими системами.

Иерархически организованные взаимосвязанные распознающие системы очень широко распространены в природных системах. Для понимания эволюционной динамики мотиваций работы таких сформировавшихся симбиозов необходимо рассмотреть их модельные описания. Известно, что в таких системах происходит обмен и алгоритмическими, и «энергетическими» ресурсами. В результате может оптимизироваться достижение целей, связанное с процессами усовершенствования, модернизации алгоритмов во всех или только в части взаимосвязанных распознающих системах.

Вариант, представленный моделью на рис. 3, позволяет на основе однотипных блоков сформировать систему, обрабатывающую информационные сигналы разных модальностей. Например, первый блок выделяет признаки статических изображений, второй блок выделяет признаки временных изменений в потоке поступающих изображений, третий блок выделяет «ситуационные» признаки данного потока изображений и управляет работой двух предыдущих блоков с целью повышения точности принятия окончательного решения.

Понятно, что любая живая система состоит из множества взаимосвязанных систем с архитектурой аналогичной модели на рис. 3. Естественно предположить однотипно функционирующие архитектуры для распознающих систем, настроенных на обработку визуальных, акустических, тактильных, болевых, «эмоциональных», и тому подобных сенсорных сигналов, а также сигналов, оценивающих состояние внутренних органов системы. В этом случае, аналогично архитектуре на рис. 3, строится иерархическая схема для сбора данных о картине состояний внутреннего «Я» живой или технической системы. То есть, фактически, наше «Я» или «ЭГО» есть набор моделей в одной из верхних распознающих ячеек (типа модели «ситуаций» на рис. 3), описывающих возможные состояния или реакции, которым система была предварительно обучена.

Другой вид иерархической системы может быть получен из схем на рис. 2 или рис. 3. Нетрудно представить, что функциональные операции в каждом блоке такой системы могут выполняться системой с точно такой же архитектурой адаптивной распознающей системы. Такое конструирование можно повторять для каждого блока вновь получаемой системы. В результате получается самоподобная система, в которой архитектура вложенных функциональных блоков для нижележащих уровней повторяет архитектуру вышележащих уровней. При этом может быть построено произвольное число уровней. Понятно, что некоторые системы вышележащих уровней должны бы иметь возможность контролировать состояния систем нижеле-

жащих уровней, а для этого они должны обладать знаниями (алгоритмами) о возможных динамических режимах систем нижележащих уровней. Интересно, что могут осознавать системы нижележащих уровней, когда они получают управляющее воздействие со стороны систем вышележащих уровней? Если в системах нижележащих уровней отсутствуют знания (алгоритмы) о механизмах работы вышележащих уровней, то этот процесс может выглядеть и как «Случайные» влияния, а может быть и как «Божественное» управление?

А что произойдет в случае обратной ситуации, когда системы нижележащих уровней обладают большим набором знаний (алгоритмов) о механизмах работы доступной им части иерархической системы, чем системы вышележащих уровней, контролирующие эту же территорию? Какие будут при этом режимы взаимодействия?

Для исследований подобных динамических режимов могут использоваться функциональные модели, приведенные на рис. 1–3.

Для компактного представления функциональных моделей иерархических систем, состоящих из популяций взаимодействующих адаптивных распознающих систем желательно перейти от схемы на рис. 2 к упрощенному рисунку, сохранив лишь самые важные переменные.




Рис. 5. Схематическое представление трансформации входного информационного потока $En_{n-1}; I_{n-1}$ в выходные данные $En_n; I_n$ в адаптивной системе принятия решений с фиксированным набором алгоритмов.

Если рассматривать функциональную схему адаптивного распознавателя как преобразователь входного информационного потока $(En_{n-1}; I_{n-1})$ в выходной информационный поток $(D_n; R_n; A_n(En_n); Int_n)$, то упрощенное представление этой схемы будет иметь вид, показанный на рис. 5.

Теперь более разнообразные варианты возможных взаимодействий между «элементарными» адаптивными распознающими системами можно представить в виде модельной схемы приведенной на рис. 4. Такого типа модели описывают процессы передачи фоновых потоков ресурсов и информационных данных с нижних уровней для последующей их обработки, и передачи на вышележащие по иерархии уровни. В качестве компенсации верхние уровни могут поставлять на нижние уровни дополнительные энергетические ресурсы ΔEn_n , а также ресурсы в виде новых знаний — моделей, алгоритмов ΔA_n [3]. В каждом слое осуществляются «горизонтальные» взаимодействия распознающих систем друг с другом. Динамику их коллективного поведения можно описывать с помощью моделей однородных систем (рис. 1). Каждый вышележащий слой распознающих систем имеет возможность управлять притоком дополнительных ресурсов на нижележащие слои из двух дополнительных, специализированных резервуаров как для энергетических ресурсов, обеспечивающих активное состояние распознающих систем, так и для знаний, обеспечивающих выполнение «правильных» действий. При этом управление на каждый нижележащий слой подается в виде инструкций, которые в текущий момент предписывают системам нижележащего уровня:

- формы использования дополнительных энергетических поддержек;
- дополнительные знания (алгоритмы), необходимые для выполнения рабочих операций и исполнения выданных инструкций.

Представленная архитектура управления энергетическими ресурсами считается вполне привычной. Гораздо больше вопросов вызывает происхождение и механизмы работы специализированного резервуара для знаний. Достаточно хорошо известны две точки зрения на функционирование механизмов производства, создания новых знаний (идей, методов, моделей, алгоритмов).

В соответствии с одной из этих точек зрения, новые знания создаются в результате комбинирования из ранее известных алгоритмических блоков. Этим могут заниматься, например, автономные специализированные «исследовательские» распознающие системы. Они могут использовать доступные им библиотеки, Интернет или общение с другими распознающими

системами. Этот процесс аналогичен конструированию более совершенных алгоритмов из наборов упрощенных базовых блоков, «кирпичиков знаний», наборов «алгоритмических преобразований».

Другая точка зрения основана на представлении, что все необходимые вариации знаний или алгоритмических блоков уже существуют в некотором хранилище знаний (место этого хранилища разные авторы указывают по-разному). По мере необходимости адаптивные распознающие системы получают требуемые алгоритмы в уже готовом виде. Для этого необходимо существование специальной процедуры запроса от системы «жаждущей знаний» и контролируемых каналов для передачи ей информационных сигналов. Обсуждение гипотез о физических механизмах этих каналов выходит за рамки данной статьи. Жизненный опыт показывает, что обычно такая доставка новых знаний происходит, если в них возникает очень сильная потребность. Такой точке зрения соответствуют многочисленные экспериментальные данные, описывающие особенности ощущений людей при холотропных состояниях сознания [44–45]. При изучении возможных динамических режимов функциональной модели (рис. 4) можно рассматривать степень влияния обоих этих механизмов.

Возможные варианты динамики коллективной активности систем на рассматриваемых уровнях иерархической модели (рис. 4) в значительной мере определяются теми приоритетными переменными, которые используются в распознающих системах. При этом, режимы зависят не только от особенностей взаимосвязей между распознающими системами, но и от предоставления дополнительных энергетических ресурсов $\Delta E n_n$, и внесения новых знаний ΔA_n для обеспечения проводимых работ. Описание этих режимов, определение их устойчивости и классификация наиболее характерного поведения систем в такой иерархии представляет весьма интересную область исследований. Интегральное описание процессов коллективной активности распознающих систем можно выполнить, например, с помощью моделей однородных нейроноподобных систем типа (1)–(2).

Приведем здесь наиболее очевидные варианты формирования активных «коллективов» для обработки информационных потоков. Структуры этих «коллективов» зависят от того, через какие основные переменные осуществляется преимущественное взаимодействие адаптивных распознающих систем.

Например, если для взаимодействия в первую очередь используются:

- сходные алгоритмы кодирования, то должен сформироваться режим работы, где будут оптимизироваться именно процессы кодирования

(их можно было бы назвать как «структуры специалистов, формирующих описания»);

- сходные алгоритмы восстановления из имеющихся кодов, то должен сформироваться режим работы, где будут оптимизироваться именно процессы создания «виртуальной реальности» (такие «коллективы» можно было бы назвать жаргонным словом «имитаторы»);
- сходные алгоритмы формирования полей невязок-мотиваций, то должны формироваться «коллективы» распознающих систем по сходству решаемых «проблем»;
- сходные алгоритмы принимаемых решений (по параметрам «новизна-консервативность», динамические особенности принимаемых решений и т. п.) должны бы приводить к формированию структур с жаргонным названием «менеджеры-управленцы, игроки»;
- сходные алгоритмы привлечения ресурсов («энергетических» или «информационных»), то должны бы формироваться «группы» с жаргонным названием «менеджеры-снабженцы».

Этот упрощенный вариант классификации возможного разнообразия процессов только для одного уровня взаимодействующих адаптивных распознающих систем наглядно показывает процедуру формализованного описания, основанную на использовании набора определяющих переменных отдельного элемента системы (модельная схема на рис. 2).

Поиск интегральных переменных для функциональной модели типа схемы на рис. 4 приводит к следующему представлению. На каждом уровне такой системы происходит интегральный процесс, в котором «коллективы» адаптивных распознающих систем преобразуют входную энергию En_n на основе своих знаний $A_n(En_n)$ и связанных с ними процессов «сознания» в новый информационный поток с дополнительно аккумулированной энергией для следующего уровня иерархической системы. Действительно, на вход каждого уровня этой модели поступает поток

$$I_n(D_{n-1}, R_{n-1}, A_{n-1}(En_{n-1}), Int_{n-1})$$

и En_n , который за счет пространственно-временных режимов коллективной активности взаимодействующих систем преобразует его в выходные значения

$$I_{n+1}(D_n, R_n, A_n(En_n), Int_n)$$

и En_{n+1} . Ключевая роль при этом, несомненно, принадлежит процессам «сознания».

Следует признать, что формализованное описание динамических процессов в рамках приведенных модельных схем воспринимается лишь заинтересованными специалистами. Специалисты с другим кругом интересов или обычные люди лучше воспринимают образный язык искусства, наглядного сенсорного восприятия. Именно поэтому в дальнейшем необходимо представить результаты этого доклада не в виде скучного изложения схем, а в виде набора динамических картинок: изображение на входе системы \Rightarrow динамика процесса на выходе. Однако, в полном соответствии с модельными системами, для этого, кроме знаний и взаимодействия заинтересованных специалистов на уровне нашего обсуждения, необходимо также обеспечить и ресурсо-стимулирующие взаимодействия с верхним уровнем иерархии и опору на нижележащие уровни, из которых мы растем.

Выводы

Приведенные функциональные модели «элементарных адаптивных распознающих систем», а также модели для взаимодействующих ансамблей распознающих систем, показали перспективность их практического применения для широкого круга процессов, связанных с обработкой информации. Подобные модели позволяют формировать элементы языка для описания режимов поведения сложных природных систем. В частности, для ряда динамических режимов таких моделей находятся естественные аналогии с известными психологическими или социальными реакциями живых систем, включая режимы, традиционно относимые к мистическим.

1. Из рис. 1–3 и приведенного описания видно, что модели позволяют конструировать большой (но конечный) набор функциональных систем, в которых присутствуют все необходимые переменные для описания основных динамических процессов в живых системах, связанных с обработкой информации. Классификацию такого вида моделей необходимо продолжить.
2. Каждая модель из набора возможных функциональных систем обладает своим спектром внутренних динамических режимов, определяющих конкретные операции обработки информации. Каждому режиму могут быть сопоставлены либо «нормальные» либо «патологические» процессы функционирования живой или технической системы. Формирование перечня наиболее важных динамических режимов начато на основе уже существующих моделей.

3. Показано, что простейшие процессы «сознания» могут быть определены через функциональные операции оптимизации используемых алгоритмов для достижения заданных целей. В отдельных «элементарных адаптивных распознающих системах» эти процессы «сознания» связаны с процессами кодирования-восстановления входного сенсорного сигнала.
4. Обращается внимание, что такие функциональные системы, представленные искусственными техническими или природными системами (на основе физических, химических, биологических сред) могут быть реализованы на неравновесных средах различной физической природы и в очень широком диапазоне пространственных масштабов.
5. Продемонстрирована функциональная «вложенность» или самоподобие режимов для приведенных базовых моделей. Известные автору примеры процессов принятия решений природными информационными системами удастся объяснить с помощью этих моделей. Было бы интересно найти ограничения предлагаемого модельного описания для объяснения экспериментальных данных о динамике нейроноподобных систем.

Варианты нейроноподобных систем с элементами «осознанного» поведения уже сейчас могут программироваться и реализовываться в аппаратуре для конкретных технических приложений. Разнообразие поведенческих реакций таких систем определяется набором модельных преобразований, которые предварительно были заложены в систему. Как известно, и в живых системах возможное разнообразие поведения также определяется процедурой выбора наиболее оптимальных режимов среди уже имеющихся у этой системы модельных представлений.

Однако самое важное, анализ базовых моделей для систем обладающих «сознанием» и формализованное описание закономерностей их поведения позволяет понимать механизмы гармонии мира как внутри каждого из нас, так и в окружающей нас вселенной.

Работа выполнялась при частичной поддержке гранта АФГИР № RMO-10214-BNL № 36943.

Литература

1. Сознание — Википедия, URL: <http://ru.wikipedia.org/>
2. *Peter Russell*. The Evolution of consciousness, from basic awareness to business awareness to global awareness.
3. *Брамари Ананда, Према Шакти Ананда, Бала Янтра*. Манифест Эволюции. — М.: Амрита-Русь, 2005. — 365 с.; Манифест эволюции, 2003. URL: <http://www.sarasvati.comtv.ru>
4. Сайт «Сознание», URL: <http://soznanie.org/>
Сайт «Сознание и память» URL: <http://soznanie-mnema.narod.ru/>
5. *Крылов К.* Поведение. Дополнение. Базовые эмоции. Три свойства сознания. URL: <http://www.traditio.ru/>
URL: <http://www.traditio.ru/krylov/pv1.html>
6. *Анохин П.К.* Философский смысл проблемы естественного и искусственного интеллекта // *Вопросы философии*. — 1973, №6. — с. 83–97; *Синергетика и психология*. Тексты. Выпуск 3. Когнитивные процессы. — М.: «Когито-Центр», 2004. — с. 301–319.
7. *Анохин П. К.* Избранные труды. — М.: Наука, 1978. — 400 с.
8. *Самарин А.И.* Модель адаптивного поведения мобильного робота, реализованная с использованием идей самоорганизации нейронных структур // *Синергетика и психология*. Тексты. Выпуск 3. Когнитивные процессы. М.: «Когито-Центр», 2004. — с. 182–196.
9. *Редько В.Г.* Эволюция когнитивных способностей животных и проблемы интеллектуального управления, Синергетика и психология // *Синергетика и психология*. Тексты. Выпуск 3. Когнитивные процессы. М.: «Когито-Центр», 2004. — с. 155–181.
10. *Редько В.Г., Прохоров Д.В.* Нейросетевые адаптивные критики // Научная сессия МИФИ-2004. VI Всесоюзная конференция «Нейроинформатика-2004», Сб. научных трудов. — Часть 2. — М.: МИФИ, 2004. — с. 77–84.
11. *Жданов А.А.* О методе автономного адаптивного управления // Научная сессия МИФИ-2004. VI Всесоюзная конференция «Нейроинформатика-2005», *Лекции по нейроинформатике*. — Часть 2. — М.: МИФИ, 2004. — с. 15–56.
12. *Станкевич Л.А.* Нейрологические средства систем управления интеллектуальных роботов // Научная сессия МИФИ-2004. VI Всесоюзная конференция «Нейроинформатика-2005», *Лекции по нейроинформатике*. — Часть 2. — М.: МИФИ, 2004. — с. 57–110.

13. Яхно В.Г., Нуйдель И.В., Иванов А.Е. Модельные нейроноподобные системы: примеры динамических процессов // В кн.: *Нелинейные волны-2004* / Отв. ред. А.В.Гапонов-Грехов, В.И.Некоркин. – Н. Новгород: ИПФ РАН, 2005. – с. 362–375.
14. Yakhno V.G., Belliustin N.S., Krasilnikova I.G., Kuznetsov S.O., Nuidel I.V., Panfilov A.I., Perminov A.O., Shadrin A.V., Shevryev A.A. Research decision-making system operating with composite image fragments using neuron-like algorithms // *Radiophysics*. – Vol. 37, No. 8, pp. 961–986, 1994.
15. Тельных А.А., Яхно В.Г. Нейроноподобные модели второго и третьего уровней – адаптивные распознающие системы // Труды XII Международной конференции по Нейрокибернетике «Проблемы нейрокибернетики». – 1999. – с. 164–168.
16. Яхно В.Г., Нуйдель И.В., Тельных А.А., Бондаренко Б.Н., Сборщиков И.Ф., Хилько А.И. Метод адаптивного распознавания информационных образов и система для его осуществления // Российский патент № 2160467, 1999.
17. Ковальчук А.В., Иванов А.Е., Яхно В.Г. Оценка качества работы алгоритмов бинаризации по динамике процессов кодирования-восстановления // Научная сессия МИФИ-2005. VII Всесоюзная конференция «Нейроинформатика-2005». – Сб. научных трудов. Часть 1. – М.: МИФИ, 2005. – с. 274–282.
18. Yakhno V.G. Basic models of hierarchy neuron-like systems and ways to analyse some of their complex reactions // *Optical Memory & Neural Network*. – 1995. – v. 4, No. 2. – pp. 141–155.
19. Яхно В.Г. Процессы самоорганизации в распределенных нейроноподобных системах. Примеры возможных применений // «Нейроинформатика 2001». Лекции по нейроинформатике. – М.: МИФИ, 2001. – с. 103–141.
20. Яхно В.Г. Нейроноподобные модели описания динамических процессов преобразования информации // *Нейроинформатика-2004. Лекции по нейроинформатике*. Часть 1. – М.: МИФИ, 2004. – с. 136–150.
21. Яхно В.Г. Модели нейроноподобных систем. Динамические режимы преобразования информации // *Нелинейные волны 2002* / Отв. ред. А. В. Гапонов-Грехов, В. И. Некоркин. – Нижний Новгород: ИПФ РАН, 2003, с. 90–114.
22. Wilson H.R., Cowan J.D. A mathematical theory of the functional dynamics of cortical and thalamic neuron tissue // *Kybernetic*. – 1973. – v. 13. – pp. 55–80.
23. Сбитнев В.И. Преобразования потока спайков в статистических нейронных ансамблях // *Биофизика*. – V1975. – Т. 20. – С. 699–702; 1976. – Т. 21. – С. 1072–1076; 1977. – т. 22. – с. 523–528.
24. Кудряшов А.В., Яхно В.Г. Распространение областей повышенной импульсной активности в нейронной сети // *Динамика биологических систем*. – 1978. – Вып. 2. – с. 45–59.

25. Беркович С.Я. Клеточные автоматы как модель реальности: Поиски новых представлений физических и информационных процессов. Пер. с англ. – М.: Изд-во МГУ, 1993. – 112 с.
26. Франк-Каменецкий Д.А. Диффузия и теплопередача в химической кинетике. – М.: Наука, 1967.
27. Райзер Ю.П. Лазерная искра и распространение разрядов. – М.: Наука, 1974.
28. Vasiliev V. A., Romanovskii Y. M., Chernavskii D. C., Yakhno V. G. Autowave processes in kinetic systems. Spatial and temporal self-organization in physics, chemistry, biology, and medicine. – D. Reidel Publishing Company, 1987.
29. Поляков С.В., Яхно В.Г. О термодиффузионном механизме генерации неоднородностей электронной концентрации в F-слое ионосферы // *Физика плазмы*. – 1980. – Т. 6, №2. – с. 383–387.
30. Семенов В.Е. Волна пробоя в самосогласованном поле электромагнитного волнового пучка // *Физика плазмы*. – 1982. – Т. 8, №3. – с. 613–618.
31. Belliustin N. S., Kuznetsov S. O., Nuidel I. V., Yakhno V. G. Neural networks with close nonlocal coupling for analyzing composite images // *Neurocomputing*. – v. 3. – 1991. – pp. 231–246.
32. Masterov A. V., Rabinovich M. I., Tolkov V. N., Yakhno V. G. Investigation of the autowave-autostructure interaction regimes in neural media // Collection of Institute of Applied Physics “*Collective dynamics of excitations and structure formation in biological tissues*”. – Gorky, 1988. – pp. 89–104.
33. Chua L. O., Yang L. Cellular neural networks: Theory. Applications // *IEEE Trans. On Circuit and Systems, (CAS)*, Vol. 35. – pp. 1257–1290, 1988.
34. Fukushima K. Neural network model of selective attention in visual pattern recognition and associative recall // *Applied Optics*. – 1983. – v. 26, No. 23. – pp. 4985–4992; Neural network for visual pattern recognition // *Computer*. – 1988. – pp. 65–67.
35. Zverev V. A. Physical Foundation of image formation by wave fields. – IAP RAS. – 1998. – 252 pp.
36. Скупченко В.В. Фазотонный мозг. – Хабаровск: ДВО АН СССР, 1991. – 144 с.
37. Грэй У. Живой мозг. – М.: Мир, 1966. – 295 с.
38. Иваницкий А.М. Мозговые механизмы оценки сигналов. – М., 1976.
39. Иваницкий А. М. Физиологические основы психики // *Природа*. – 1999. – № 8. – с. 156–162.
40. Иваницкий А. М. Главная загадка природы: как на основе работы мозга возникают субъективные переживания // *Психологический журнал*. – 1999. – т. 20, № 3. – с. 93–104.

41. *Архипов В. И.* Воспроизведение следов долговременной памяти, зависимой от внимания // *Журнал высшей нервной деятельности.* – 1998. – т. 48, вып. 5. – с. 836–845.
42. *Сергин В. Я.* Психофизиологические механизмы осознания: гипотеза самоотжествления // *Журнал высшей нервной деятельности.* – 1998. – т. 48, вып. 3. – с. 558–570.
43. *Пригожин И. Р. (ред.)* Человек перед лицом неопределенности. – Москва-Ижевск: Институт компьютерных исследований, 2003. – 304 с.
44. *Гроф С.* Психология будущего: Уроки современных исследований сознания: Пер. с англ. *С.Офертаса и О.Цветковой.* – М.: ООО «Издательство АСТ» и др., 2002. – 458 с.
45. *Гроф С.* Космическая игра: Исследование рубежей человеческого сознания: Пер. с англ. *О.Цветковой.* – М.: ООО «Издательство АСТ» и др., 2004. – 248 с.
46. *Роджерс Р.* 40 Исследований, которые потрясли психологию. Секреты выдающихся экспериментов. – СПб: «прайм-ЕВРОЗНАК», 2003. – 416 с.

Владимир Григорьевич ЯХНО, ведущий научный сотрудник, доктор физико-математических наук, заведует лабораторией автоволновых процессов в Институте прикладной физики РАН (Нижний Новгород). Научные интересы связаны с исследованием процессов самоорганизации в распределенных неравновесных системах и применением автоволновых представлений для моделирования процессов обработки сенсорных сигналов, развитием компьютерных алгоритмов кодирования сложных изображений (разработка биометрических систем), рассмотрением характерных процессов при настройке систем распознавания. Имеет более 140 научных публикаций (в том числе 2 монографии и 5 патентов).

В. Г. РЕДЬКО

Институт оптико-нейронных технологий РАН, Москва

E-mail: redko@iont.ru

**ПРОБЛЕМА ПРОИСХОЖДЕНИЯ ИНТЕЛЛЕКТА И МОДЕЛИ
АДАПТИВНОГО ПОВЕДЕНИЯ¹**

Аннотация

Обсуждается подход к исследованию проблемы происхождения интеллекта на основе построения моделей эволюции адаптивного поведения. Характеризуются работы ведущих лабораторий в области моделирования адаптивного поведения. Особое внимание уделяется методу обучения с подкреплением, в частности нейросетевым адаптивным критикам. Излагается проект «Мозг анимата», нацеленный на формирование общей «платформы» для систематического построения моделей адаптивного поведения. Приводятся результаты исследования конкретной модели эволюции самообучающихся адаптивных агентов на основе адаптивных критиков. В порядке обсуждения предлагается программа будущих исследований эволюции адаптивного поведения.

V. G. RED'KO

Institute of Optical Neural Technologies, RAS, Moscow

E-mail: redko@iont.ru

**PROBLEM OF EVOLUTIONARY ORIGIN OF INTELLIGENCE AND
MODELS OF ADAPTIVE BEHAVIOR**

Abstract

An approach to the problem of evolutionary origin of intelligence is discussed; the approach is based on modeling of evolution of adaptive behavior. The works of leading laboratories in the field of simulation of adaptive behavior are characterized. A special attention is paid to reinforcement learning and adaptive critic designs. The project "Animat Brain" directed to development of a general platform for systematic designing of models of adaptive behavior is described. The results of the concrete model of evolution of self-learning agents that are based of adaptive critic designs are represented. The sketch program for future research of evolution of adaptive behavior is proposed.

¹Работа выполнена при финансовой поддержке программы Президиума РАН «Интеллектуальные компьютерные системы» (проект 2-45) и РФФИ (проект № 04-01-00179).

Можно ли обосновать математику?

Каждый, кто достаточно серьезно изучал классический математический анализ, мог по достоинству оценить красоту математической строгости. Благодаря работам *О. Коши*, *Б. Больцано*, *К. Вейерштрасса* и других математиков XIX века, одна из наиболее содержательных частей математики — дифференциальное и интегральное исчисление — получила столь серьезное обоснование, что невольно возникает желание распространить подобную строгость на возможно большую часть человеческих знаний. Однако, если посмотреть широко на естественные науки в целом, то может возникнуть вопрос: а насколько вообще обоснована применимость математики к познанию природы? Ведь те процессы, которые происходят в мышлении математика, совсем не похожи на те процессы, которые происходят в природе и изучаются естествоиспытателями.

Действительно, рассмотрим физику, наиболее фундаментальную из естественнонаучных дисциплин. Мощь физики связана с эффективным применением математики. Но математик строит свои теории чисто логическим путем, совсем независимо от внешнего мира, используя свое мышление (в тиши кабинета, лежа на диване, в изолированной камере...). Почему же результаты, получаемые математиком, применимы к реальной природе?

Итак, возникает определенное сомнение в обоснованности самой математической строгости. В более общей формулировке проблему можно поставить так: *почему логика человеческого мышления применима к познанию природы?* Действительно, с одной стороны, логические процессы вывода происходят в нашем, человеческом мышлении, с другой стороны, процессы, которые мы познаем посредством логики, относятся к изучаемой нами природе. Эти два типа процессов различны. Поэтому далеко не очевидно, что мы можем использовать процессы первого типа для познания процессов второго типа.

Можно ли конструктивно подойти к решению этих вопросов? Скорее всего, да. По крайней мере, можно попытаться это сделать. Почему можно ожидать положительный ответ на этот вопрос? А давайте попробуем рассуждать следующим образом.

Рассмотрим одно из элементарных правил, которое использует математик в логических выводах, правило *modus ponens*: «если имеет место A и из A следует B , то имеет место B », или $\{A, A \rightarrow B\} \Rightarrow B$.

А теперь перейдем от математика к собаке *И. П. Павлова*. Пусть у собаки вырабатывают условный рефлекс, в результате в памяти собаки форми-

руется связь «за УС должен последовать БС» (УС — условный стимул, БС — безусловный стимул). И когда после выработки рефлекса собаке предъявляют УС, то она, «помня» о хранящейся в ее памяти «записи»: $УС \rightarrow БС$, делает элементарный «вывод» $\{УС, УС \rightarrow БС\} \Rightarrow БС$. И у собаки, ожидающей БС (скажем, кусок мяса), начинают течь слюнки.

Конечно, применение правила *modus ponens* (чисто дедуктивное) математиком и индуктивный «вывод», который делает собака, явно различаются. Но можем мы ли думать об эволюционных корнях логических правил, используемых в математике? Да, вполне можем — умозаключение математика и «индуктивный вывод» собаки качественно аналогичны.

Мы можем пойти и дальше — можем представить, что в памяти собаки есть семантическая сеть, сеть связей между понятиями, образами. Например, мы можем представить, что у собаки есть понятия «пища», «опасность», «другая собака». С понятием «пища» могут быть связаны понятия «мясо», «косточка». При выработке пищевого условного рефлекса, например, на звонок (скажем, УС = «звонок», БС = «мясо») у собаки, по-видимому, формируется простая семантическая связь (рис. 1).




Рис. 1. Гипотетическая семантическая связь, формируемая в памяти собаки

Далее можно представить процессы формирования разнообразных семантических сетей в процессе жизни собаки и накопления ей жизненного опыта. Такие семантические сети, формируемые в памяти собаки, по-видимому, аналогичны семантическим сетям, исследуемым разработчиками искусственного интеллекта [1].

Итак, мы можем думать над эволюционными корнями логики, мышления, интеллекта. И более того, было бы очень интересно попытаться строить модели эволюционного происхождения мышления. По-видимому, наиболее четкий путь такого исследования — построение математических и компьютерных моделей «интеллектуальных изобретений» биологической эволюции, таких как безусловный рефлекс, привыкание, классический условный рефлекс, инструментальный условный рефлекс, цепи рефлексов,

..., логика (рис.2) [2]. То есть, целесообразно с помощью моделей представить общую картину эволюции когнитивных способностей животных и эволюционного происхождения интеллекта человека.




Рис. 2. «Интеллектуальные изобретения» биологической эволюции. «Авторы изобретений» и «даты приоритетов» представлены довольно условно

Естественно, что такие исследования — это огромный фронт работы, и задачу построения теории происхождения мышления можно пока рассматривать как сверхзадачу. Разработка такой теории могла бы обеспечить определенное обоснование применимости нашего мышления в научном познании, то есть, укрепить фундамент всего величественного здания науки. Чтобы вести эту работу серьезно, целесообразно идти именно по пути построения математических и компьютерных моделей когнитивной эволюции.

Есть ли задел таких исследований? Оказывается, что да, есть. Сравнительно недавно сформировалось направление исследований «Адаптивное

поведение», дальняя цель которого очень близка к задаче построения теории происхождения мышления. В следующем разделе мы обсудим модели адаптивного поведения.

Модели адаптивного поведения

From Animal to Animat — модели адаптивного поведения животного и робота

Направление «Адаптивное поведение» (АП) активно развивается с начала 1990-х годов [3–5]. Основной подход этого направления — конструирование и исследование искусственных (в виде компьютерной программы или робота) «организмов», способных приспосабливаться к внешней среде. Эти организмы называются *«аниматами»* (от англ. animal + robot = animat). Также часто используется термин «агент».

Поведение аниматов имитирует поведение животных. Исследователи направления АП стараются строить именно такие модели, которые применимы к описанию поведения *как реального животного, так и искусственного анимата* [6,7].

Программа-минимум направления «Адаптивное поведение» — исследовать архитектуры и принципы функционирования, которые позволяют животным или роботам жить и действовать в переменной внешней среде.

Программа-максимум этого направления — попытаться проанализировать эволюцию когнитивных способностей животных и эволюционное происхождение человеческого интеллекта [8].

Программа-максимум близка к очерченной выше задаче построения теории происхождения мышления.

Для исследований АП характерен *синтетический подход*: здесь конструируются архитектуры, обеспечивающие «интеллектуальное» поведение аниматов. Причем это конструирование проводится как бы с точки зрения инженера: исследователь сам «изобретает» архитектуры, подразумевая конечно, что какие-то подобные структуры, обеспечивающие адаптивное поведение, должны быть у реальных животных.

При этом направление исследований АП рассматривается как бионический подход к разработке систем искусственного интеллекта [9].

Хотя «официально» направление АП было провозглашено в 1990 году, были явные провозвестники этого направления. Приведем примеры из

истории отечественной науки.

В 1960-х годах блестящий кибернетик и математик *М. Л. Цетлин* предложил и исследовал модели автоматов, способных адаптивно приспосабливаться к окружающей среде. Работы *М. Л. Цетлина* инициировали целое научное направление, получившее название «коллективное поведение автоматов» [10,11].

В 1960–70-х годах под руководством талантливого кибернетика *М. М. Бонгарда* был предложен интересный проект «Животное», направленный на моделирование адаптивного поведения искусственных организмов с иерархией целей и подцелей [12,13].

Хороший обзор ранних работ по адаптивному поведению, представлен в книге *М. Г. Гаазе-Рапопорта* и *Д. А. Поспелова* «От амебы до робота: модели поведения» [13].

В исследованиях АП используется ряд нетривиальных компьютерных методов:

- нейронные сети,
- генетические алгоритмы и другие методы эволюционной оптимизации [14–17],
- классифицирующие системы (Classifier Systems) [18],
- обучение с подкреплением (Reinforcement Learning) [19].

Метод обучения с подкреплением будет кратко охарактеризован ниже, в одноименном разделе (см. с. 120).

Подчеркнем, что в АП в основном используется *феноменологический* подход к исследованиям систем управления адаптивным поведением. То есть предполагается, что существуют формальные правила адаптивного поведения, и эти правила не обязательно связаны с конкретными микроскопическими нейронными или молекулярными структурами, которые есть у живых организмов. Скорее всего, такой феноменологический подход для исследований АП вполне имеет право на существование. В пользу этого тезиса приведем аналогию из физики. Есть термодинамика, и есть статистическая физика. Термодинамика описывает явления на феноменологическом уровне, статистическая физика характеризует те же явления на микроскопическом уровне. В физике термодинамическое и статфизическое описания относительно независимы друг от друга и, вместе с тем, взаимодополнительны. По-видимому, и для описания живых организмов может быть аналогичное соотношение между феноменологическим (на уровне

поведения) и микроскопическим (на уровне нейронов и молекул) подходами. При этом, естественно ожидать, что для исследования систем управления адаптивным поведением феноменологический подход должен быть более эффективен (по крайней мере, на начальных этапах работ), так как очень трудно сформировать целостную картину поведения на основе анализа всего сложного многообразия функционирования нейронов, синапсов, молекул.

Исследователи адаптивного поведения

Исследования по адаптивному поведению ведутся в ряде университетов и лабораторий, таких как:

- AnimatLab (Париж, руководитель — один из инициаторов данного направления *Жан-Аркадий Мейер*) [3,8,20]. В этой лаборатории ведется широкий спектр исследований адаптивных роботов и адаптивного поведения животных. Подход AnimatLab предполагает, что система управления анимата может формироваться и модифицироваться посредством 1) *обучения*, 2) индивидуального *развития* (онтогенеза) и 3) *эволюции*.
- Лаборатория искусственного интеллекта в университете Цюриха (руководитель *Рольф Пфейфер*) [21,22]. Основной подход этой лаборатории — познание природы интеллекта путем его создания (“understanding by building”). Он включает в себя 1) построение моделей биологических систем, 2) исследование общих принципов естественного интеллекта животных и человека, 3) использование этих принципов при конструировании роботов и других искусственных интеллектуальных систем.
- Лаборатория искусственной жизни и роботики в Институте когнитивных наук и технологий (Рим, руководитель *Стефано Нолфи*) [23,24], ведущая исследования в области эволюционной роботики и принципов формирования адаптивного поведения.
- Лаборатория информатики и искусственного интеллекта в Массачусетском технологическом институте (руководитель *Родни Брукс*) [25,26], которая ведет исследования широкого спектра интеллектуальных и адаптивных систем, включая создание интеллектуальных роботов.

- Институт нейронаук *Дж. Эдельмана*, где ведутся разработки поколений моделей работы мозга (Darwin I, Darwin II, ...) и исследования поведения искусственного организма NOMAD (Neurally Organized Mobile Adaptive Device), построенного на базе этих моделей [27–29].

В России исследования адаптивного поведения менее масштабны по объему, пока они ведутся лишь усилиями ученых-энтузиастов. Среди выполненных работ следует отметить:

- модели поискового адаптивного поведения на основе спонтанной активности, приводящей к переключениям между разными тактиками поиска, например, тактикой движения по градиенту источника запаха (при поиске пищи) и тактикой случайного поиска [6,7,30,31] (*В. А. Непомнящих*, Институт биологии внутренних вод им. И. Д. Папанина РАН, Борок, Ярославская область);
- концепции и модели автономного адаптивного управления на основе аппарата эмоций [32,33] (*А. А. Жданов*, Институт системного программирования РАН, Москва);
- разработку принципов построения систем управления антропоморфных и гуманоидных роботов [34] (*Л. А. Станкевич*, Санкт-Петербургский политехнический университет);
- разработку нейросетевых моделей поведения роботов и робототехнических устройств [35] (*А. А. Самарин*, НИИ нейрокибернетики им. А. Б. Когана РГУ, Ростов-на-Дону);
- модели адаптивного поведения на основе эволюционных и нейросетевых методов, в частности, модели эволюционного возникновения целенаправленного адаптивного поведения [36–40] (*В. Г. Редько*, *М. С. Бурцев*, *О. П. Мосалов*, Институт оптико-нейронных технологий РАН, Институт прикладной математики им. М. В. Келдыша РАН, Москва).

Один из ключевых методов, используемых при разработке моделей адаптивного поведения — метод обучения с подкреплением. В следующем разделе мы охарактеризуем этот метод, а также кратко опишем интересное направление работ, развиваемое в рамках теории обучения с подкреплением, именуемое «нейросетевые адаптивные критики».

Обучение с подкреплением

Теория обучения с подкреплением (reinforcement learning) была разработана в цикле работ *Р. Саттона* и *Э. Барто* (Массачусетский университет), который подробно отражен в книге [19].

Идейным вдохновителем этих работ был *А. Г. Клопф* (Air Force, USA), который в книге «Целеустремленный нейрон» предложил несколько спорную, но достаточно четкую и последовательную методологию исследований памяти, обучения, адаптивного поведения [41].

Общая схема обучения с подкреплением [19] показана на рис. 3.




Рис. 3. Схема обучения с подкреплением

Рассматривается анимат, взаимодействующий с внешней средой. Время предполагается дискретным: $t = 1, 2, \dots$. В текущей ситуации анимат $S(t)$ выполняет действие $a(t)$, получает подкрепление $r(t)$ и попадает в следующую ситуацию $S(t+1)$. Подкрепление может быть положительным (награда) или отрицательным (наказание).

Цель анимата — максимизировать суммарную награду, которую можно получить в будущем в течение длительного периода времени. Предполагается, что анимат может иметь свою внутреннюю «субъективную» оценку суммарной награды и в процессе обучения постоянно совершенствует эту оценку. Эта оценка определяется с учетом коэффициента забывания:

$$U(t) = \sum_{k=0}^{\infty} \gamma^k r(t+k), \quad (1)$$

где $U(t)$ — оценка суммарной награды, ожидаемой после момента времени t , γ — коэффициент забывания (дисконтный фактор), $0 < \gamma < 1$. Коэффициент забывания учитывает, что чем дальше анимат «заглядывает» в будущее,

тем меньше у него уверенность в оценке награды («рубль сегодня стоит больше, чем рубль завтра»).

В процессе обучения анимат формирует *политику* (стратегию поведения). Политика определяет выбор (детерминированный или вероятностный) действия в зависимости от ситуации. Р. Саттон и Э. Барто [19] исследовали ряд методов формирования политики, основанных на динамическом программировании и методах Монте-Карло.

Если множество возможных ситуаций $\{S_i\}$ и действий $\{a_j\}$ конечно, то существует простой метод обучения SARSA, каждый шаг которого соответствует цепочке событий $S(t) \rightarrow a(t) \rightarrow r(t) \rightarrow S(t+1) \rightarrow a(t+1)$.

Метод SARSA. Кратко опишем метод SARSA. В этом методе итеративно формируются оценки величины суммарной награды $Q(S(t), a(t))$, которую получит анимат, если в ситуации $S(t)$ он выполнит действие $a(t)$. Математическое ожидание суммарной награды равно:

$$Q(S(t), a(t)) = E\{r(t) + \gamma r(t+1) + \gamma^2 r(t+2) + \dots\} | S = S(t), a = a(t). \quad (2)$$

Из (1) и (2) следует

$$Q(S(t), a(t)) = E[r(t) + \gamma Q(S(t+1), a(t+1))].$$

Ошибка естественно определить так [19]:

$$\delta(t) = r(t) + \gamma Q(S(t+1), a(t+1)) - Q(S(t), a(t)). \quad (3)$$

Величина $\delta(t)$ называется ошибкой временной разности.

Здесь $\delta(t)$ — разность между той оценкой суммарной величины награды, которая формируется у анимата для момента времени t после выбора действия $a(t)$ в следующей ситуации $S(t+1)$ в момент времени $t+1$, и предыдущей оценкой этой же величины, которая была у анимата в момент времени t . Предыдущая оценка равна $Q(S(t), a(t))$, новая оценка равна $r(t) + \gamma Q(S(t+1), a(t+1))$, что и отражает формула (3) для величины $\delta(t)$. В соответствии с этим $\delta(t)$ анимат и обучается (см. ниже, формулу (4)).

Каждый такт времени происходит как выбор действия, так и обучение анимата. Выбор действия происходит так:

- в момент t с вероятностью $1 - \varepsilon$ выбирается действие, соответствующее максимальному значению $Q(S(t), a_i) : a(t) = a_k, k = \arg \max_i \{Q(S(t), a_i)\}$;

- с вероятностью ε выбирается произвольное действие, $0 < \varepsilon \ll 1$.
Такую схему выбора действия называют « ε -жадным правилом».

Обучение, т. е. переоценка величин $Q(S, a)$ происходит в соответствии с оценкой ошибки $\delta(t)$ — к величине $Q(S(t), a(t))$ добавляется величина, пропорциональная ошибке временной разности $\delta(t)$:

$$\begin{aligned} \Delta Q(S(t), a(t)) &= \alpha \delta(t) = \\ &= \alpha [r(t) + \gamma Q(S(t+1), a(t+1)) - Q(S(t), a(t))], \end{aligned} \quad (4)$$

где α — параметр скорости обучения.

Так как число ситуаций и действий конечно, то здесь происходит формирование матрицы $Q(S_j, a_i)$, соответствующей всем возможным ситуациям S_j и всем возможным действиям a_i .

Метод обучения с подкреплением идейно связан с методом динамического программирования, и в том и в другом случае общая оптимизация многошагового процесса принятия решения происходит путем упорядоченной процедуры одношаговых оптимизирующих итераций, причем оценки эффективности тех или иных решений, соответствующие предыдущим шагам процесса, переоцениваются с учетом знаний о возможных будущих шагах. Например, при решении задачи поиска оптимального маршрута в лабиринте от стартовой точки к определенной целевой точке сначала находится конечный участок маршрута, непосредственно приводящий к цели, а затем ищутся пути, приводящие к конечному участку, и т.д. В результате постепенно прокладывается трасса маршрута от его конца к началу. Обучение с подкреплением, адаптивные критики и подобные методы часто называют приближенным динамическим программированием [42].

Важное достоинство метода обучения с подкреплением — его простота. То есть анимат получает от учителя или из внешней среды только сигналы подкрепления $r(t)$. Здесь учитель поступает с обучаемым объектом примитивно: «бьет кнутом» (если действия объекта ему не нравятся, $r(t) < 0$), либо «дает пряник» (в противоположном случае, $r(t) > 0$), не объясняя обучаемому объекту, как именно нужно действовать. Это радикально отличает этот метод от таких традиционных в теории нейронных сетей методов обучения, как метод обратного распространения ошибки, для которого учитель точно определяет, что должно быть на выходе нейронной сети при заданном входе.

Метод обучения с подкреплением был исследован рядом авторов (см. подробную библиографию в [19]) и был использован в многочисленных приложениях. В частности, применения этого метода включают в себя:

- оптимизацию игры в триктрак (достигнут уровень мирового чемпионата);
- оптимизацию системы управления работы лифтов;
- формирование динамического распределения каналов для мобильных телефонов;
- оптимизацию расписания работ на производстве.

Подчеркнем, что метод обучения с подкреплением может рассматриваться как развитие автоматной теории адаптивного поведения, разработанной в работах *М. Л. Цетлина* и его последователей [10,11].

В свою очередь, метод обучения с подкреплением получил свое развитие в работах по адаптивным критикам, в которых рассматриваются методы обучения, использующие нейросетевые аппроксиматоры функций оценки качества функционирования анимата. Простейшие схемы адаптивных критиков рассмотрим в следующем разделе.

Нейросетевые адаптивные критики [43]. Конструкции адаптивных критиков можно рассматривать как развитие моделей обучения с подкреплением на случай, когда как ситуации, так и действия задаются векторами **S** и **A** и изложенная выше схема итеративного формирования матрицы $Q(S_j, a_i)$ не работает. В этом случае характеристики системы управления целесообразно представить с помощью параметрически задаваемых аппроксимирующих функций (например, с помощью искусственных нейронных сетей), а обучение проводить путем итеративной оптимизации параметров. В случае аппроксимации с помощью нейронных сетей, параметрами аппроксимирующих функций являются веса синапсов нейросети, оптимизация производится путем подстройки весов, например, аналогично тому, как это делается в методе обратного распространения ошибки.

В конструкции систем управления аниматов на основе адаптивных критиков входят два важных блока: Критик и Контроллер (иногда используют также термин Актор).

Критик — это блок системы управления, который оценивает качество ее работы.

Контроллер — блок системы управления, формирующий действия этой системы.

Ниже мы опишем две простые конструкции адаптивных критиков: Q -критик и V -критик. Обе конструкции используют нейросетевую аппроксимацию характеристик системы управления.

Q -критик. Схема Q -критика представлена на рис. 4. Предполагаем, что как Критик, так и Контроллер представляют собой многослойные персептроны (такие же, какие используются в методе обратного распространения ошибки) с весами синапсов \mathbf{W}_C и \mathbf{W}_A , соответственно.




Рис. 4. Схема Q -критика

Функционирование этой схемы происходит следующим образом. В момент времени t Контроллер по вектору входной ситуации $\mathbf{S}(t)$ определяет вектор действия $\mathbf{A}(t)$ (команды на эффекторы). На входы Критика подаются два вектора: $\mathbf{S}(t)$ и $\mathbf{A}(t)$. По этому составному входному вектору Критик делает оценку качества $Q(t) = Q(\mathbf{S}(t), \mathbf{A}(t))$ действия $\mathbf{A}(t)$ в текущей ситуации $\mathbf{S}(t)$. Действие $\mathbf{A}(t)$ выполняется, анимат получает награду $r(t)$. Далее происходит переход к следующему моменту времени $t + 1$. Все операции повторяются, в том числе делается оценка значения $Q(t + 1)$. После этого определяется ошибка временной разности:

$$\delta(t) = r(t) + \gamma Q(t + 1) - Q(t). \quad (5)$$

Обучение нейросетей выполняется следующим образом:

$$\Delta W_C = \alpha_1 \text{grad}_{W_C}(Q(t)) \delta(t), \quad (6)$$

$$\Delta W_A = \alpha_2 \sum_k \left\{ \frac{\partial Q(t)}{\partial A_k(t)} \text{grad}_{W_A} A_k(t) \right\}, \quad (7)$$

где α_1 и α_2 — параметры скорости обучения. Производные по весам синапсов $\text{grad}_{WC}(\cdot)$ и $\text{grad}_{WA}(\cdot)$ в (6) и (7), а также $\partial Q(t)/\partial A_k(t)$ в (7) рассчитываются как производные сложных функций, аналогично тому, как это делается в методе обратного распространения ошибки [19]. В формуле (7) учитывается, что нужно брать производные по всем компонентам вектора $\mathbf{A}(t)$ и суммировать по всем этим компонентам.

Смысл изменений весов синапсов по формулам (6), (7) состоит в том, что веса Критика и Контроллера меняются таким образом, чтобы уменьшить ошибку в оценке ожидаемой суммарной награды (обучение Критика) и увеличить значение самой награды при попадании анимата в близкие ситуации (обучение Контроллера).

V-критик. Схема *V*-критика представлена на рис. 5.

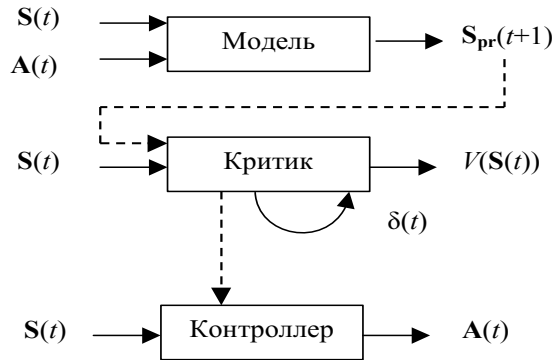


Рис. 5. Схема *V*-критика

В этой схеме блок Критик, в отличие от схемы *Q*-критика, оценивает качество ситуации $V(\mathbf{S}(t))$ независимо от выполняемого действия. Однако эта схема содержит блок Модель, в котором прогнозируется будущая ситуация $\mathbf{S}_{pr}(t+1) = \mathbf{S}_{pr}(\mathbf{S}(t), \mathbf{A}(t))$ в зависимости от текущей ситуации $\mathbf{S}(t)$ и выполняемого действия $\mathbf{A}(t)$. И для этого прогнозируемой ситуации $\mathbf{S}_{pr}(t+1)$ блок Критик может сделать оценку ее качества

$$V_{pr} = V(\mathbf{S}_{pr}(t+1)) = V(\mathbf{S}_{pr}(\mathbf{S}(t), \mathbf{A}(t))).$$

Предполагаем, что Критик, Контроллер и Модель представляют собой многослойные перцептроны с весами синапсов \mathbf{W}_C , \mathbf{W}_A и \mathbf{W}_M , соответственно.

Функционирование этой схемы происходит следующим образом. В момент времени t Контроллер по вектору входной ситуации $\mathbf{S}(t)$ определяет вектор действия $\mathbf{A}(t)$. Критик делает оценку качества $V(t) = V(\mathbf{S}(t))$ текущей ситуации $\mathbf{S}(t)$. Модель прогнозирует следующее состояние

$$\mathbf{S}_{pr}(t+1) = \mathbf{S}_{pr}(\mathbf{S}(t), \mathbf{A}(t)).$$

Критик оценивает качество прогнозируемой ситуации $V_{pr} = V(\mathbf{S}_{pr}(t+1))$. Действие $\mathbf{A}(t)$ выполняется, анимат получает награду $r(t)$. Оценивается ошибка временной разности:

$$\delta(t) = r(t) + \gamma V(\mathbf{S}_{pr}(t+1)) - V(\mathbf{S}(t)). \quad (8)$$

Обучаются Критик:

$$\Delta \mathbf{W}_C = \alpha_1 \text{grad}_{\mathbf{W}_C}(V(t)) \delta(t) \quad (9)$$

и Контроллер:

$$\Delta \mathbf{W}_A = \alpha_2 \sum_k \left\{ \frac{\partial V(\mathbf{S}_{pr}(t+1))}{\partial A_k(t)} \text{grad}_{\mathbf{W}_A} A_k(t) \right\}, \quad (10)$$

$$\frac{\partial V(\mathbf{S}_{pr}(t+1))}{\partial A_k(t)} = \sum_j \left\{ \frac{\partial V}{\partial S_{prj}} \cdot \frac{\partial S_{prj}}{\partial A_k(t)} \right\}. \quad (11)$$

Производные в (11) берутся в соответствии с формулами нейронных сетей Критика и Модели.

Далее происходит переход к следующему моменту времени $t+1$. Сравниваются прогнозируемая $\mathbf{S}_{pr}(t+1)$ и реальная ситуация $\mathbf{S}(t+1)$. В соответствии с ошибкой этого прогноза обучается Модель обычным методом обратного распространения ошибки.

Обучение Критика состоит в том, чтобы итеративно уточнять оценку качества ситуаций $V(\mathbf{S}(t))$ в соответствии с поступающими подкреплениями.

Обучение Контроллера состоит в том, чтобы постепенно формировать действия, приводящие к ситуациям с высокими значениями качества $V(\mathbf{S})$.

Смысл обучения Модели — уточнение прогнозов будущих ситуаций.

Отметим, что оценка функции качества ситуации $V(\mathbf{S}(t))$ в этой схеме аналогична эмоциональной оценке текущего состояния системы в моделях А. А. Жданова [32,33].

Более полно теория адаптивных критиков и ее современное состояние характеризуется в работах [44,45].

Теория функциональных систем П. К. Анохина как концептуальная основа исследований адаптивного поведения

Для осмысления многообразия форм адаптивного поведения необходимо не только исследование конкретных моделей, но и разработка общих концепций и схем, позволяющих взглянуть сверху, «с высоты птичьего полета» на эти исследования.

Одной из таких концептуальных теорий может служить теория функциональных систем, предложенная и развитая в 1930–70 годах известным советским нейрофизиологом П. К. Анохиным [46,47].

Функциональная система по П. К. Анохину — схема управления, нацеленного на достижение полезных для организма результатов.

Работа функциональной системы (рис. 6) может быть описана следующим образом.

Сначала происходит *афферентный синтез*, который включает в себя нейронные возбуждения, обусловленные 1) доминирующей мотивацией (понятие «мотивация» кратко обсуждается ниже), 2) обстановочной и пусковой афферентацией, 3) врожденной и приобретаемой памятью.

За афферентным синтезом следует *принятие решения*, при котором происходит уменьшение степеней свободы для афферентного синтеза и выбор конкретного действия в соответствии с доминирующей мотивацией и с другими составляющими афферентного синтеза.

Затем следует формирование *акцептора результата действия*, т. е. прогноза результата. Прогноз включает в себя оценку параметров ожидаемого результата.

Эфферентный синтез — подготовка к выполнению действия. При эфферентном синтезе происходит генерация определенных нейронных возбуждений перед подачей команды на выполнение действия.

Все этапы достижения результата сопровождаются *обратной афферентацией*. Если параметры фактического результата отличаются от параметров акцептора результата действия, то действие прерывается и происходит




Рис. 6. Структура функциональной системы
Здесь: ОА — обстановочная афферентация, ПА — пусковая афферентация.

новый афферентный синтез. В этом случае все операции повторяются до тех пор, пока не будет достигнут конечный потребный результат.

Таким образом, функциональная система имеет циклическую (с обратными афферентными связями) саморегулирующуюся архитектуру.

Теория П. К. Анохина подразумевает *динамизм функциональных систем*. Для каждого конкретного поведенческого акта может быть сформирована своя функциональная система.

Функциональные системы формируются в процессе *системогенеза*. Теория системогенеза, которая исследует закономерности формирования функциональных систем в *эволюции, индивидуальном развитии и обучении* [48], может рассматриваться как отдельная ветвь теории функциональных си-

стем. Отметим, что указанные составляющие системогенеза соответствуют составляющим формирования систем адаптивного поведения в трактовке AanimatLab [20].

Каждая функциональная система ориентирована на достижение *конечного потребного результата*.

Необходимо подчеркнуть, что теория функциональных систем была разработана, в первую очередь, для интерпретации нейробиологических данных и зачастую сформулирована в очень интуитивных терминах. Поэтому, хотя она и хорошо известна, она не общепризнанна и практически не использовалась при разработке серьезных моделей адаптивного поведения. Можно сказать, что попытки формализации теории функциональных систем только начинаются [49–52]. Тем не менее, эта теория базируется на многочисленных биологических экспериментальных данных и представляет собой хорошую концептуальную основу для исследования широкого спектра проблем адаптивного поведения.

Отталкиваясь от теории П. К. Анохина, можно предложить общую кибернетическую схему управления целенаправленным адаптивным поведением естественного или искусственного организма (рис. 7). Здесь под организмом можно подразумевать как животное, так и робот или социально-экономическую систему: промышленную фирму, государство, человечество.

Теория функциональных систем обеспечивает концептуальную основу для построения конкретных моделей и для разработки общих проектов, направленных на разработку широкого спектра моделей адаптивного поведения. Далее в разделе «Модели эволюционного возникновения целенаправленного адаптивного поведения» (см. с. 131) кратко характеризуются конкретные модели эволюционного возникновения целенаправленного адаптивного поведения, а разделе «Проект “Мозг анимата”» (см. с. 137) излагается основанный на теории функциональных систем проект «Мозг анимата», который ориентирован на формирование общей платформы для исследования и моделирования широкого круга проблем адаптивного поведения.

Важное понятие функциональной системы — *мотивация*. Роль мотивации состоит в формировании цели и поддержке целенаправленных форм поведения. Мотивация может рассматриваться как активная движущая сила, которая стимулирует нахождение такого решения, которое адекватно потребностям организма в рассматриваемой ситуации. И имеет смысл провести моделирование эволюционного возникновения *целенаправленного*




Рис. 7. Общая схема управления целенаправленным адаптивным поведением (в духе П. К. Анохина)

адаптивного поведения и анализ роли мотиваций в формировании целенаправленного поведения. Также следует отметить, что целенаправленность могла возникнуть на очень ранних стадиях эволюции, до появления каких-либо форм индивидуально приобретаемой памяти [53], поэтому, следуя пути, пройденному эволюцией, разумно начать с анализа этого свойства. Кроме того, свойство целенаправленности важно само по себе — это существенная особенность поведения *именно живых существ*.

Модели эволюционного возникновения целенаправленного адаптивного поведения были построены и исследованы в работах [36–38]. Основные результаты этого моделирования излагаются в следующем разделе.

**Модели эволюционного возникновения целенаправленного
адаптивного поведения**

Модель «Кузнечик». Роль мотиваций в формировании адаптивного поведения [36,37]. В данной модели исследовался возможный механизм эволюционного возникновения целенаправленного поведения, обусловленного мотивациями.




Рис. 8. Агенты в одномерной клеточной среде

Основные предположения модели состоят в следующем:

- Имеется популяция агентов (искусственных организмов), имеющих естественные потребности: 1) *потребность энергии* и 2) *потребность размножения*.
- Популяция эволюционирует в одномерной клеточной среде (рис. 8), в клетках может эпизодически вырастать трава (пища агентов). Каждый агент имеет *внутренний энергетический ресурс R* , который пополняется при съедании травы и расходуется при выполнении каких-либо действий. Уменьшение ресурса до нуля приводит к смерти агента. Агенты могут скрещиваться, рождая новых агентов.
- Потребности характеризуется количественно *мотивациями*. Если энергетический ресурс R агента уменьшается, то возрастает мотивация к пополнению энергетического ресурса (соответствующая потребности энергии) и уменьшается мотивация к размножению. При увеличении R мотивация к пополнению ресурса уменьшается, а мотивация к размножению растет.
- Поведение агента управляется его *нейронной сетью*. Сеть имеет один слой нейронов. На входы нейронов подаются сигналы, характеризую-

шие внешнюю и внутреннюю среду агента, выходы нейронов определяют действия агента. Каждому возможному действию соответствует ровно один нейрон. В каждый такт времени совершается действие, соответствующее максимальному сигналу на выходе нейрона.

- Агенты «близоруки» — агент воспринимает состояние внешней среды только из трех клеток его поля зрения (рис. 8): той клетки, в которой агент находится, и двух соседних клеток.
- Агент может выполнять следующие *действия*: 1) быть в состоянии покоя («отдыхать»), 2) двигаться, т. е. перемещаться на одну клетку вправо или влево, 3) прыгать через несколько клеток в случайную сторону, 4) есть (питаться), 5) скрещиваться. В силу способности агентов прыгать, мы называем их «кузнечиками».
- Нейронная сеть имеет специальные входы от мотиваций. Если имеется определенная мотивация, то поведение агента может меняться с тем, чтобы удовлетворить соответствующую потребность. Такое поведение можно рассматривать как *целенаправленное* (есть цель удовлетворить определенную потребность).
- Популяция агентов *эволюционирует*. Веса синапсов нейронной сети, управляющей поведением агента, составляют геном агента. Геном потомка формируется на основе геномов родителей при помощи рекомбинаций и мутаций.
- Мотивация к пополнению энергетического ресурса M_E и мотивация к размножению M_R определялись как простые функции энергетического ресурса агента R :

$$M_E = \max\{(R_0 - R)/R_0, 0\}, \quad M_R = \min\{R/R_1, 1\},$$

где R_0, R_1 — параметры (обычно полагалось $R_0 = 2R_1$).

Модель исследовалась путем компьютерного моделирования эволюции популяции агентов. Нейронная сеть агентов исходной популяции определяла некоторые простые изначальные инстинкты, обеспечивающие питание и размножение агентов. Далее наблюдалось, как в процессе эволюции изменялись нейронная сеть агентов и определяемое ей поведение агентов.

Для того чтобы исследовать влияние мотиваций на поведение агентов, были проведены две серии компьютерных экспериментов. В первой серии моделировалась эволюция популяции агентов с «выключенными» мотивациями (входы нейронов от мотиваций были «задавлены»), во второй серии мотивации «работали» (так, как это изложено выше).




Рис. 9. Пример зависимостей численности популяции от времени. Здесь как **1** обозначена зависимость для агентов без мотиваций и как **2** — с мотивациями. Видно, что популяция агентов с мотивациями имеет значительные селективные преимущества по сравнению с популяцией агентов без мотиваций.




Рис. 10. Схема управления агента без мотиваций. Поведение агента состоит из простых безусловных рефлексов, при котором выбор действия напрямую определяется текущим состоянием окружающей среды.

Основные результаты проведенного моделирования таковы:

- Мотивации играют важную роль в исследованных эволюционных процессах. А именно, если сравнить популяцию агентов без мотиваций с популяцией агентов с мотивациями, то, как показывают компьютерные эксперименты, эволюционный процесс приводит к тому, что вторая популяция (с мотивациями) имеет значительные селективные преимущества по сравнению с первой (без мотиваций). Этот вывод иллюстрируется рис. 9.
- Анализ нейронных сетей и поведения агентов демонстрирует, что управление поведением агента без мотиваций (рис. 10) можно рассматривать как набор простых инстинктов (несколько отличающихся от изначально заданных), а управление агентом с мотивациями (рис. 11) — как *иерархическую систему управления*, состоящую из двух уровней: уровня простых инстинктов и метауровня, обусловленного мотивациями. При этом иерархическая система управления обеспечивает более эффективное управление, чем одноуровневая си-

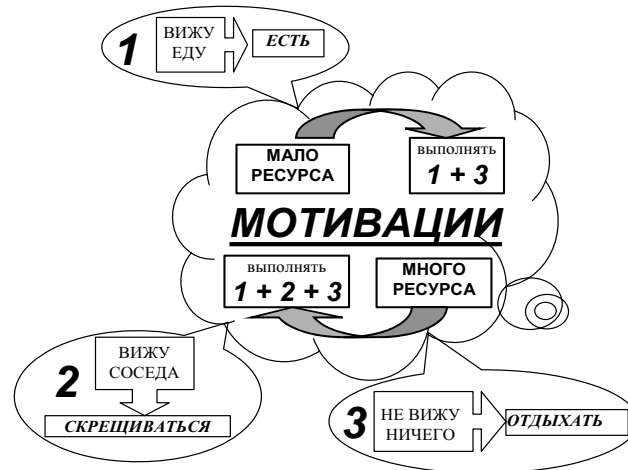


Рис. 11. Схема управления агента, обладающего мотивациями. Мотивации формируют новый уровень иерархии в системе управления агентами.

стема, в которой поведение определяется одними лишь простыми инстинктами. Переход от схемы управления без мотиваций (рис. 10) к схеме управления с мотивациями (рис. 11) подобен метасистемному переходу от простых рефлексов к сложному рефлексу в теории метасистемных переходов В. Ф. Турчина [54].

Развитие модели «Кузнечик» — возникновение естественной разветвленной иерархии целей. Изложенная модель была развита в работе М. С. Бурцева [38], в которой исследовалось поведение популяции агентов в двумерном мире (рис. 12). При этом дополнительно в модель были введены 1) возможность борьбы между агентами и 2) эволюционное изменение структуры нейронной сети, состоящей из рецепторов, эффекторов и связей между рецепторами и эффекторами.




Рис. 12. Агент в двумерной клеточной среде

Агент ориентирован (стрелка показывает направление вперед), кружки — поле зрения агента. Действия агента: двигаться вперед, поворачиваться направо или налево, есть, размножаться, бороться с другими агентами. Система управления агента — однослойная нейронная сеть, оптимизируемая эволюционным методом.

Как и в предыдущей модели, для агентов исходной популяции задавалась некоторая минимальная система управления, обеспечивающая питание и размножение агентов. Поведение агентов начальной популяции (имеющих минимальный набор рецепторов и эффекторов) схематично представлено на рис. 13.

В ходе эволюции поведение агентов структурируется. Стратегия агентов, сформированная в процессе эволюции, может быть представлена в виде схемы, показанной на рис. 14. Видно, что развивается достаточно

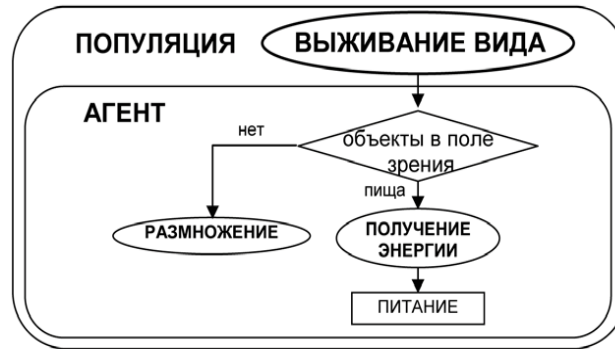


Рис. 13. Дерево условий для управления выбором подцелей агента начальной популяции

сложное поведение, которое можно считать целенаправленным. Так первоначальный «инстинкт» агента, направленный на получение энергии, оптимизируется за счет появления еще одного уровня подцелей, направленных, соответственно: на собственно питание, на поиск пищи, на борьбу.

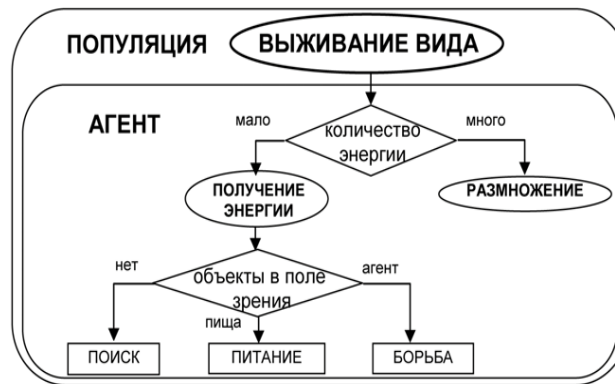


Рис. 14. Дерево условий для управления выбором подцелей, формирующееся в результате эволюции

В целом моделирование, выполненное в [38], продемонстрировало, что в процессе исследованных эволюционных процессов возникает естественная иерархическая структура целей и подцелей.

Проект «Мозг анимата» [52]²

Отталкиваясь от теории функциональных систем П. К. Анохина (см. раздел «Теория функциональных систем П. К. Анохина как концептуальная основа исследований адаптивного поведения», с. 127), можно предложить достаточно общую «платформу» для систематического построения моделей адаптивного поведения. В работах [51,52] предложен проект «Мозг анимата», который как раз и нацелен на формирование общей схемы построения таких моделей. Кратко опишем данный проект. В работе [51] была предложена первая версия проекта, описывающая архитектуру системы управления анимата на основе нейросетевых блоков прогноза, обучаемых с помощью метода обратного распространения ошибки. Ниже излагается следующая версия архитектуры [52], основанная на нейросетевых адаптивных критиках (см. раздел «Обучение с подкреплением», с. 120)

Предполагается, что система управления аниматом имеет иерархическую архитектуру (рис. 15). Базовым элементом системы управления является отдельная функциональная система (ФС).

Первый уровень (ФС1, ФС2, ...) соответствует основным потребностям организма: питания, размножения, безопасности, накопления знаний. Более низкие уровни системы управления соответствуют тактическим целям поведения. Блоки всех этих уровней (включая первый) реализуются с помощью функциональных систем. Управление с верхних уровней может передаваться на нижние уровни (от «суперсистем» к «субсистемам») и возвращаться назад.

Самый верхний уровень соответствует выживанию вида (см. также схему иерархии управления на рис. 14). Этот уровень подразумеваемый, он не реализуется с помощью конкретной функциональной системы.

Предполагается, что система управления аниматом функционирует в дискретном времени. Также предполагается, что каждый такт времени активна только одна ФС.

Рассматривается простая формализация функциональной системы на основе нейросетевых адаптивных критиков. Функциональная система мо-

²Термин «Мозг анимата» был предложен К. В. Анохиным.

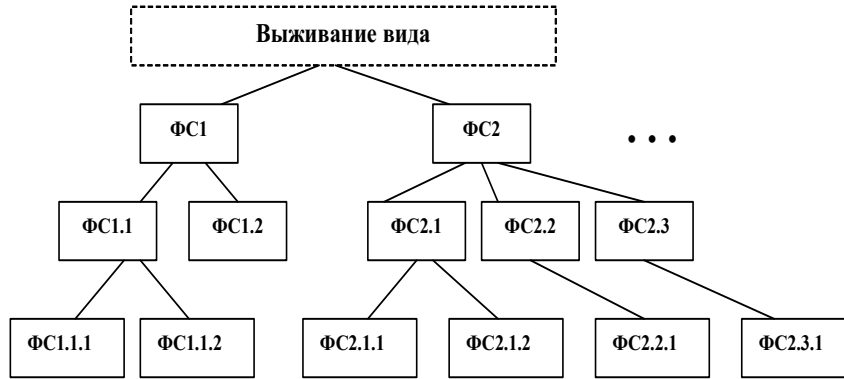


Рис. 15. Архитектура системы управления аниматором (ФС — функциональная система).

делирует следующие важные особенности ее биологического прототипа: 1) прогноз результата действия, 2) сравнение прогноза и результата, 3) коррекцию прогноза путем обучения в соответствующих нейронных сетях, 4) принятие решения. Принятие решения в данной схеме ФС соответствует выбору одного из альтернативных действий. Функциональная система использует одну из возможных схем адаптивных критиков, представленную ниже.

Схема адаптивного критика. Рассматриваемая схема адаптивного критика состоит из двух блоков: Модель и Критик (рис. 16). Предполагается, что Модель и Критик — многослойные перцептроны, и что производные по весам нейронных сетей этих блоков могут быть вычислены обычным методом обратного распространения ошибки [55]. Предполагается, что адаптивный критик предназначен для выбора одного из нескольких действий. Например, при управлении движением действиями могут быть: двигаться вперед, поворачивать вправо, поворачивать влево, стоять на месте. В каждый момент времени t адаптивный критик должен выбрать одно из возможных действий.




Рис. 16. Схема адаптивного критика, используемая в функциональной системе

Модель предсказывает следующую ситуацию $\mathbf{S}_i^{pr}(t + \tau)$ для всех возможных действий $a_i, i = 1, 2, \dots, n_a$. Текущая ситуация $\mathbf{S}(t)$, прогнозы $\mathbf{S}_i^{pr}(t + \tau)$ и реальная следующая ситуация $\mathbf{S}(t + \tau)$ подаются на вход Критика (одна и та же нейронная сеть Критика показана в два последовательных момента времени), на выходе которого формируются оценки качества ситуаций $V(\mathbf{S}(t)), V(\mathbf{S}_i^{pr}(t + \tau))$ и $V(\mathbf{S}(t + \tau))$.

Цель адаптивного критика — максимизировать функцию суммарной награды $U(t)$ [19]:

$$U(t_j) = \sum_{k=0}^{\infty} \gamma^k r(t_{j+k}), \quad (12)$$

где $r(t_j)$ — текущее подкрепление (награда, $r(t_j) > 0$ или наказание, $r(t_j) < 0$), полученное адаптивным критиком в данный момент времени t_j , γ — коэффициент забывания, $0 < \gamma < 1$. В общем случае разность $t_{j+1} - t_j$ может зависеть от времени, но для простоты обозначений предполагается, что $\tau = t_{j+1} - t_j = \text{const}$.

Подчеркнем, что $U(t)$ есть алгебраическая сумма (с учетом коэффициента забывания) ожидаемых в будущем наград и наказаний. Значение $U(t)$ оценивается блоком Критик для каждой из возможных ситуаций $\mathbf{S}(t)$ величиной $V(\mathbf{S}(t))$. Эти оценки характеризуют качество той или ситуации

и постепенно уточняются в процессе обучения. На основе этих оценок осуществляется выбор действий таким образом, чтобы максимизировать величину суммарной награды $U(t)$.

Принцип работы рассматриваемого адаптивного критика (рис. 16) излагается ниже.

Модель имеет два типа входов: 1) входы, характеризующие текущую ситуацию $\mathbf{S}(t)$ (сигналы из внешней и внутренней среды анимата), и 2) входы, характеризующие действия. Предполагается, что каждое возможное действие a_i кодируется своей собственной комбинацией входов, и что число возможных действий невелико. Роль Модели — прогноз следующей ситуации для всех возможных действий a_i , $i = 1, 2, \dots, n_a$.

Роль Критика — оценка качества ситуации $V(\mathbf{S})$ для текущей ситуации $\mathbf{S}(t)$, следующей ситуации $\mathbf{S}(t + \tau)$ и прогнозируемых ситуаций $\mathbf{S}_i^{pr}(t + \tau)$ для всех возможных действий. Величины V — оценки функции суммарной награды $U(t)$.

В каждый момент времени выполняются следующие операции:

1. Модель предсказывает следующую ситуацию $\mathbf{S}_i^{pr}(t + \tau)$ для всех возможных действий a_i , $i = 1, 2, \dots, n_a$.
2. Критик оценивает качество ситуации для текущей ситуации $V(t) = V(\mathbf{S}(t))$ и всех прогнозируемых ситуаций $V_i^{pr}(t + \tau) = V(\mathbf{S}_i^{pr}(t + \tau))$.
3. Применяется ε -жадное правило [19], а именно, выбирается действие a_k следующим образом:
 - с вероятностью $1 - \varepsilon$ выбирается действие с максимальным значением $V(\mathbf{S}_i^{pr}(t + \tau))$: $k = \arg \max_i \{V(\mathbf{S}_i^{pr}(t + \tau))\}$;
 - с вероятностью ε выбирается произвольное действие a_k , $0 < \varepsilon \ll 1$, k — индекс выбираемого действия a_k .
4. Действие a_k выполняется.
5. Оценивается текущее подкрепление $r(t)$ и происходит переход к следующему моменту времени $t + \tau$. Наблюдается следующая ситуация $\mathbf{S}(t + \tau)$ и сравнивается с прогнозом $\mathbf{S}_i^{pr}(t + \tau)$. Корректируются веса \mathbf{W}_M нейронной сети Модели методом обратного распространения ошибки с целью минимизации ошибки прогноза:

$$\Delta \mathbf{W}_M = \alpha_M \text{grad}_{\mathbf{W}_M} (\mathbf{S}_k^{pr}(t + \tau))^T (\mathbf{S}(t + \tau) - \mathbf{S}_k^{pr}(t + \tau)), \quad (13)$$

где α_M — скорость обучения нейронной сети Модели.

6. Критик оценивает величину $V(\mathbf{S}(t + \tau))$. Считается ошибка временной разности [19]:

$$\delta(t) = r(t) + \gamma V(\mathbf{S}(t + \tau)) - V(\mathbf{S}(t)). \quad (14)$$

Величина $\delta(t)$ характеризует ошибку в оценке $V(\mathbf{S}(t))$ — суммарной награды, которую можно получить, исходя из состояния $\mathbf{S}(t)$. Ошибка $\delta(t)$ рассчитывается с учетом текущей награды $r(t)$ и оценки суммарной награды $V(\mathbf{S}(t + \tau))$, которую можно получить, исходя из следующего состояния $\mathbf{S}(t + \tau)$.

7. Корректируются веса \mathbf{W}_C нейронной сети Критика:

$$\Delta \mathbf{W}_C = \alpha_C \delta(t) \text{grad}_{\mathbf{W}_C}(V(t)), \quad (15)$$

где α_C — скорость обучения нейронной сети Критика. Градиенты $\text{grad}_{\mathbf{W}_M}(\mathbf{S}_k^{pr}(t + \tau))$ и $\text{grad}_{\mathbf{W}_C}(V(t))$ означают производные выходов нейронных сетей относительно соответствующих весов синапсов. Градиенты считаются так же, как в методе обратного распространения ошибки [55].

Обучение по формулам (14), (15) — минимизация ошибки $\delta(t)$ путем подстройки весов синапсов нейронной сети Критика градиентным методом.

Смысл обучения Модели по формуле (13) — уточнение прогнозов будущих ситуаций.

Смысл обучения Критика по формулам (14), (15) состоит в том, чтобы итеративно уточнять оценку качества ситуаций $V(\mathbf{S}(t))$ в соответствии с поступающими подкреплениями.

Изложенная схема адаптивного критика — ядро рассматриваемой функциональной системы. Множество функциональных систем формируют полную систему управления аниматором (рис. 15).

Функционирование системы управления аниматором. Детальная структура модели ФС представлена на рис. 17. В основу ФС положена изложенная выше схема адаптивного критика. Дополнительные свойства ФС по сравнению со схемой адаптивного критика таковы: 1) ФС дополнительно формирует команды подсистемам и посылает отчеты о результатах действий суперсистеме, и 2) сравнение между прогнозом $\mathbf{S}_k^{pr}(t + \tau)$ и результатом $\mathbf{S}(t + \tau)$ может быть отложено до момента $t + \tau$, когда поступит отчет

от подсистем (детальнее см. ниже). Связи данной ФС с супер/подсистемами показаны вертикальными жирными/пунктирными стрелками.

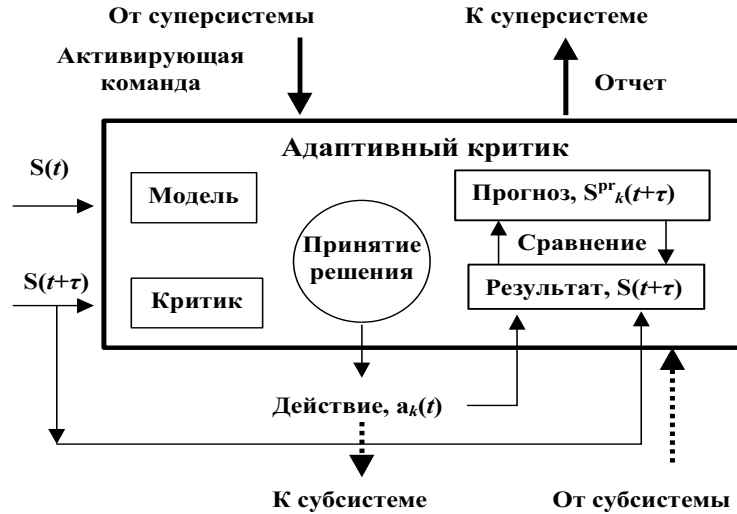


Рис. 17. Схема функциональной системы на основе адаптивного критика.

Предполагается следующая схема работы ФС в рамках функционирования всей системы управления аниматором. Данная ФС активизируется командой от суперсистемы. Модель и Критик функционируют так же, как описано выше в схеме работы адаптивного критика. В результате осуществляется выбор действия a_k . Дальнейшее зависит от вида действия a_k .

Если действие — команда для исполнительных элементов (сплошная стрелка вправо), то такое действие выполняется сразу; в этом случае $\tau = \tau_{min}$ — интервал между тактами времени минимален. Далее аниматор получает подкрепление r из внешней или внутренней среды, и производится обучение в нейронных сетях адаптивного критика.

Другой тип действий — команды для подсистем (пунктирная стрелка вниз). Для такого действия подается команда активизации определенной подсистемы (выбор конкретной подсистемы определяется номером действия a_k). В этом случае сравнение прогноза и результата, оценка подкрепления r и обучение нейронных сетей откладывается до получения отчета

от подсистемы, то есть до момента $t + \tau$, где $\tau > \tau_{min}$.

Обучение в обоих случаях осуществляется изложенным выше способом (раздел «Схема адаптивного критика», с. 138).

После выполнения всех этих действий ФС посылает отчет об окончании своей работы соответствующей суперсистеме.

Описанный способ работы ФС представляет собой обычный режим функционирования. Вводится также экстраординарный режим, который имеет место, если прогноз существенно отличается от фактического результата: $\|\mathbf{S}_k^{pr}(t_j) - \mathbf{S}(t_j)\| > \Delta > 0$, где $\|\cdot\|$ обозначает некоторую норму, например, евклидову. Предполагается, что в экстраординарном режиме величина ε (вероятность выбора случайного действия) в данной ФС и ее подсистемах резко возрастает, и поиск новых решений включает большую случайную компоненту. Этот поиск может сопровождаться случайным формированием и селекцией новых функциональных систем, аналогично селекции нейронных групп в теории нейродарвинизма Дж. Эдельмана [56]. Таким образом, обычный режим функционирования может рассматриваться как тонкая настройка системы управления аниматом, в то время как экстраординарный режим — это грубый поиск подходящего адаптивного поведения в чрезвычайных ситуациях.

Отметим, что в данную схему управления поведением анимата несложно включить процедуру прерывания верхними уровнями работы нижних уровней иерархии функциональных систем, с помощью специальных связей между ФС. Например, если в ФС1, отвечающую за безопасность, поступил сигнал, характеризующий серьезную опасность для жизни анимата, а анимат занимался поиском «пищи» в дереве решений, «возглавляемом» ФС2, ответственной за потребность питания, то ФС1 имеет право прервать работу ФС2 и дать команду на избежание опасности.

Память о старых навыках в нейронных сетях ФС может «портиться» при обучении новым навыкам, что соответствует известной дилемме пластичности-стабильности. Рассматриваемая архитектура системы управления аниматом позволяет естественным образом долговременную память о приобретенных навыках. Если некоторый тип поведения был хорошо апробирован, то соответствующая ему ФС может быть скопирована в долговременную память, а именно, в ФС, в которой величины ε и α_C , α_M равны нулю. Обе ФС — долгосрочная и краткосрочная, с долговременной и кратковременной памятью, соответственно — могут играть одну и ту же роль в общей архитектуре системы управления. Для надежных навыков долговременная ФС имеет приоритет по отношению к краткосрочной. Однако

если прогнозы ситуаций S^{pr} , сделанные долгосрочной ФС, начинают отличаться от фактических S , то управление возвращается к краткосрочной ФС.

Итак, предложенная архитектура системы управления обеспечивает общий подход к моделированию адаптивным поведением анимата с естественными потребностями и соответствующими целями и подцелями. Сразу надо отметить, что использование адаптивных критиков в качестве функциональных систем - только один из возможных вариантов конструирования таких систем управления. Тем не менее, предложенная схема Мозга анимата позволяет уже сразу начинать работу по разработке конкретных моделей адаптивного поведения. По-видимому, одной из первых модельных реализаций могло бы быть воспроизведение адаптивного поведения агентов с иерархией целей и подцелей, описанного в разделе «Развитие модели “Кузнечик” — возникновение естественной разветвленной иерархии целей» (см. с. 135; см. также рис. 14).

Подчеркнем, что роль проекта «Мозг анимата» может быть глубокой и серьезной: этот проект может быть положен в основу базовых моделей «интеллектуальных» изобретений биологической эволюции (см. раздел «Можно ли обосновать математику?», с. 113; см. также рис. 2 на с. 115).

Проект «Мозг анимата» основан на нейросетевых адаптивных критиках, для развития проекта важно оценить возможности адаптивных критиков и проверить, как функционируют простые схемы адаптивных критиков в конкретных моделях. В следующем разделе излагаются результаты исследования такой модели.

Модель эволюции популяции самообучающихся агентов на базе нейросетевых адаптивных критиков [57]

Описание модели. В данном разделе исследуется модель эволюции популяции самообучающихся автономных агентов и анализируется взаимодействие между обучением и эволюцией. Система управления отдельного агента основана на нейросетевых адаптивных критиках [43,44] (см. также раздел «Обучение с подкреплением», с. 120). Модель отрабатывается на примере агента-брокера.

Схема агента-брокера. Рассматривается модель агента-брокера, который имеет ресурсы двух типов: деньги и акции; сумма этих ресурсов со-

ставляет капитал агента $C(t)$; доля акций в капитале равна $u(t)$. Внешняя среда определяется временным рядом $X(t)$, $t = 0, 1, 2, \dots$; $X(t)$ — курс акций на бирже в момент времени t . Агент стремится увеличить свой капитал $C(t)$, изменяя значение $u(t)$. Динамика капитала определяется выражением [58]:

$$C(t+1) = C(t)\{1 + u(t+1)\Delta X(t+1)/X(t)\}[1 - J|u(t+1) - u(t)|], \quad (16)$$

где $\Delta X(t+1) = X(t+1) - X(t)$ — текущее изменение курса акций, J — параметр, учитывающий расходы агента на покупку/продажу акций. Используется логарифмическая шкала для ресурса агента, $R(t) = \log C(t)$ [59]. Текущее подкрепление агента $r(t) = R(t+1) - R(t)$ равно:

$$r(t) = \log\{1 + u(t+1)\Delta X(t+1)/X(t)\} + \log[1 - J|u(t+1) - u(t)|]. \quad (17)$$

Для простоты предполагается, что переменная u может принимать только два значения $u = 0$ (весь капитал в деньгах) или $u = 1$ (весь капитал в акциях).

Алгоритм обучения. Система управления агента — это простой адаптивный критик, состоящий из двух нейронных сетей (НС): Модель и Критик (рис. 18). Цель адаптивного критика — максимизировать функцию полезности $U(t)$ [19]:

$$U(t) = \sum_{j=0}^{\infty} \gamma^j r(t+j), \quad t = 1, 2, \dots, \quad (18)$$

где $r(t)$ — текущее подкрепление, полученное агентом, а γ — фактор забывания ($0 < \gamma < 1$).

Схема данного адаптивного критика подобна более общей схеме, предложенной в проекте «Мозг анимата» (раздел «Схема адаптивного критика», с. 138), однако имеет свою специфику, связанную с тем, что временной ряд $X(t)$ не зависит от действий агента.

В предположении $\Delta X(t) \ll X(t)$ считается, что ситуация $\mathbf{S}(t)$, характеризующая состояние агента, зависит только от двух величин, $\Delta X(t)$ и $u(t)$: $\mathbf{S}(t) = \{\Delta X(t), u(t)\}$.

Модель предназначена для прогнозирования изменения курса временного ряда. На вход Модели подается m предыдущих значений изменения

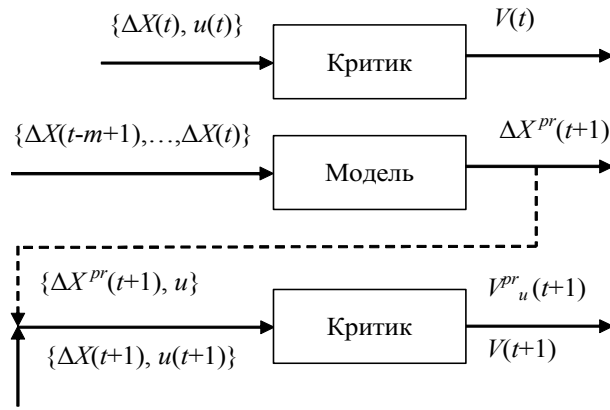


Рис. 18. Схема системы управления агента

НС Критика показана для двух последовательных тактов времени. Модель предназначена для прогнозирования изменения курса временного ряда. Критик предназначен для оценки качества ситуаций $V(\mathbf{S})$ для текущей ситуации $\mathbf{S}(t) = \{\Delta X(t), u(t)\}$, для ситуации в следующий такт времени $\mathbf{S}(t+1)$ и для предсказываемых ситуаций для обоих возможных действий $\mathbf{S}_u^{pr}(t+1) = \{\Delta X^{pr}(t+1), u\}$, $u = 0$, либо $u = 1$.

курса $\Delta X(t-m+1), \dots, \Delta X(t)$, на выходе формируется прогноз изменения курса в следующий такт времени $\Delta X^{pr}(t+1)$. Модель представляет собой двухслойную НС, работа которой описывается формулами:

$$\begin{aligned} \mathbf{x}^M &= \{\Delta X(t-m+1), \dots, \Delta X(t)\}, \\ y_j^M &= \text{th}\left(\sum_i w_{ij}^M x_i^M\right), \\ \Delta X^{pr}(t+1) &= \sum_j v_j^M y_j^M, \end{aligned}$$

где \mathbf{x}^M — входной вектор, \mathbf{y}^M — вектор выходов нейронов скрытого слоя, w_{ij}^M и v_j^M — веса синапсов НС.

Критик предназначен для оценки качества ситуаций $V(\mathbf{S})$, а именно, оценки функции полезности $U(t)$ (см. формулу (18)) для агента, находящегося в рассматриваемой ситуации \mathbf{S} . Критик представляет собой двухслой-

ную НС, работа которой описывается формулами:

$$\begin{aligned} \mathbf{x}^C &= \mathbf{S}(t) = \{\Delta X(t), u(t)\}, \\ y_j^C &= \text{th}\left(\sum_i w_{ij}^C x_i^C\right), \\ V(t) &= V(\mathbf{S}(t)) = \sum_j v_j^C y_j^C, \end{aligned}$$

где \mathbf{x}^C — входной вектор, \mathbf{y}^C — вектор выходов нейронов скрытого слоя, w_{ij}^C и v_j^C — веса синапсов НС.

В каждый момент времени t выполняются следующие операции:

1. Модель предсказывает следующее изменение временного ряда

$$\Delta X^{pr}(t+1).$$

2. Критик оценивает величину V для текущей ситуации $V(t) = V(\mathbf{S}(t))$ и для предсказываемых ситуаций для обоих возможных действий $V_u^{pr}(t+1) = V(\mathbf{S}_u^{pr}(t+1))$, где $\mathbf{S}_u^{pr}(t+1) = \{\Delta X^{pr}(t+1), u\}$, $u = 0$, либо $u = 1$.
3. Применяется ε -жадное правило [19]: действие, соответствующее максимальному значению $V_u^{pr}(t+1)$ выбирается с вероятностью $1 - \varepsilon$, альтернативное действие выбирается с вероятностью ε ($0 < \varepsilon \ll 1$). Выбор действия есть выбор величины $u(t+1)$: перевести весь капитал в деньги, $u(t+1) = 0$; либо в акции, $u(t+1) = 1$.
4. Выбранное действие $u(t+1)$ выполняется. Происходит переход к моменту времени $t+1$. Подсчитывается подкрепление $r(t)$ согласно (17). Наблюдаемое значение $\Delta X(t+1)$ сравнивается с предсказанием $\Delta X^{pr}(t+1)$. Веса НС Модели подстраиваются так, чтобы минимизировать ошибку предсказания методом обратного распространения ошибки. Скорость обучения Модели равна $\alpha_M > 0$.
5. Критик подсчитывает

$$V(t+1) = V(\mathbf{S}(t+1)); \mathbf{S}(t+1) = \{\Delta X(t+1), u(t+1)\}.$$

Рассчитывается ошибка временной разности:

$$\delta(t) = r(t) + \gamma V(t+1) - V(t). \quad (19)$$

6. Веса НС Критика подстраиваются так, чтобы минимизировать величину $\delta(t)$, это обучение осуществляется градиентным методом, аналогично методу обратного распространения ошибки. Скорость обучения Критика равна $\alpha_C > 0$.

Схема эволюции. Эволюционирующая популяция состоит из n агентов. Каждый агент имеет ресурс $R(t)$, который изменяется в соответствии с подкреплениями агента: $R(t+1) = R(t) + r(t)$, где $r(t)$ определено в (17).

Эволюция происходит в течение ряда поколений, $n_g = 1, 2, \dots, N_g$. Продолжительность каждого поколения n_g равна T тактов времени (T — длительность жизни агента). В начале каждого поколения начальный ресурс каждого агента равен нулю, т. е., $R(T(n_g - 1) + 1) = 0$.

Начальные веса синапсов обоих НС (Модели и Критика) формируют геном агента $\mathbf{G} = \{\mathbf{W}_{M0}, \mathbf{W}_{C0}\}$. Геном \mathbf{G} задается в момент рождения агента и не меняется в течение его жизни. В противоположность этому, текущие веса синапсов НС \mathbf{W}_M и \mathbf{W}_C подстраиваются в течение жизни агента путем обучения, описанного выше.

В конце каждого поколения определяется агент, имеющий максимальный ресурс $R_{max}(n_g)$ (лучший агент поколения n_g). Этот лучший агент порождает n потомков, которые составляют новое $(n_g + 1)$ -е поколение. Геномы потомков \mathbf{G} отличаются от генома родителя небольшими мутациями.

Более конкретно предполагается, что в начале каждого нового $(n_g + 1)$ -го поколения для каждого агента его геном формируется следующим образом

$$G_i(n_g + 1) = G_{best,i}(n_g) + \text{rand}_i, \quad \mathbf{W}_0(n_g + 1) = \mathbf{G}(n_g + 1),$$

где $\mathbf{G}_{best}(n_g)$ — геном лучшего агента предыдущего n_g -го поколения и rand_i — это $N(0, P_{mut}^2)$, т. е., нормально распределенная случайная величина с нулевым средним и стандартным отклонением P_{mut} (интенсивность мутаций), которая добавляется к каждому весу.

Таким образом, геном \mathbf{G} (начальные веса синапсов, получаемые при рождении агента) изменяется только посредством эволюции, в то время как текущие веса синапсов \mathbf{W} дополнительно к этому подстраиваются посредством обучения. При этом в момент рождения агента $\mathbf{W} = \mathbf{W}_0 = \mathbf{G}$.

Результаты моделирования. Рассмотрим в качестве примера использование введенной выше модели в серии компьютерных экспериментов.

Общие особенности адаптивного поиска. Изложенная модель была реализована в виде компьютерной программы. В компьютерных экспериментах использовалось два варианта временного ряда:

- 1) синусоида

$$X(t) = 0.5(1 + \sin(2\pi t/20)) + 1, \quad (20)$$

- 2) стохастический временной ряд, использованный в [58]:

$$\begin{aligned} X(t) &= \exp[p(t)/1200], \\ p(t) &= p(t-1) + \beta(t-1) + k\lambda(t), \\ \beta(t) &= \alpha\beta(t-1) + \mu(t), \end{aligned} \quad (21)$$

где $\lambda(t)$ и $\mu(t)$ — два нормальных процесса с нулевым средним и единичной дисперсией, $\alpha = 0.9$, $k = 0.3$.

Некоторые параметры модели имели одно и то же значение для всех экспериментов: фактор забывания $\gamma = 0.9$; количество входов НС Модели $m = 10$; количество нейронов в скрытых слоях НС Модели и Критика $N_{hM} = N_{hC} = 10$; скорость обучения Модели и Критика $\alpha_M = \alpha_C = 0.01$; параметр ε -жадного правила $\varepsilon = 0.05$; интенсивность мутаций $P_{mut} = 0.1$; расходы агента на покупку/продажу акций $J = 0$. Остальные параметры (продолжительность поколения T и численность популяции n) принимали разные значения в разных экспериментах (см. ниже).

Были проанализированы следующие варианты рассматриваемой модели:

- случай L (чистое обучение); в этом случае рассматривался отдельный агент, который обучался методом временной разности;
- случай E (чистая эволюция), т. е. рассматривается эволюционирующая популяция без обучения;
- случай LE (эволюция + обучение), т. е. полная модель, изложенная выше.

Было проведено сравнение ресурса, приобретаемого агентами за 200 временных тактов для этих трех способов адаптации. Для случаев E и LE бралось $T = 200$ (T — продолжительность поколения) и регистрировалось максимальное значение ресурса в популяции $R_{max}(n_g)$ в конце каждого




Рис. 19. Зависимости $R_{max}(n_g)$

Кривая LE соответствует случаю эволюции, объединенной с обучением, кривая E — случаю чистой эволюции, кривая L — случаю чистого обучения. Временная шкала для случаев LE и E (номер поколения n_g) представлена снизу, для случая L (индекс n_g) — сверху. Моделирование проведено для синусоиды, кривые усреднены по 1000 экспериментам; $n = 10$, $T = 200$.

поколения. В случае L (чистое обучение) рассматривался только один агент, ресурс которого для удобства сравнения со случаями E и LE обнулялся каждые $T = 200$ тактов времени: $R(T(n_g - 1) + 1) = 0$. В этом случае индекс n_g увеличивался на единицу после каждых T временных тактов, и полагалось $R_{max}(n_g) = R(Tn_g)$.

Графики $R_{max}(n_g)$ для синусоиды (20) показаны на рис. 19. Чтобы исключить уменьшение значения $R_{max}(n_g)$ из-за случайного выбора действий при применении ε -жадного правила для случаев LE и L, полагалось $\varepsilon = 0$ после $n_g = 100$ для случая LE и после $n_g = 2000$ для случая L (на рис. 19 видно резкое увеличение $R_{max}(n_g)$ после $n_g = 100$ и $n_g = 2000$ для соответствующих случаев). Результаты усреднены по 1000 экспериментам; $n = 10$, $T = 200$.

Рис. 19 показывает, что обучение, объединенное с эволюцией (случай LE), как и чистая эволюция (случай E) дают одно и то же значение конечного ресурса $R_{max}(500) = 6.5$. Однако эволюция и обучение вместе обеспечивают нахождение больших значений R_{max} быстрее, чем эволюция отдельно — существует симбиотическое взаимодействие между обучением и эволюцией.




Рис. 20. Зависимости максимального по популяции ресурса $R_{max}(n_g)$, приобретаемого в течение поколения, а также стандартного отклонения $\sigma(n_g)$ величины $R_{max}(n_g)$ от номера поколения n_g
 Случай LE. Значения $\sigma(n_g)$ характеризуют разброс значений $R_{max}(n_g)$ для различных реализаций моделируемых процессов. Моделирование проведено для синусоиды, кривые усреднены по 1000 экспериментам; $n = 10, T = 200$.

Из (17) следует, что существует оптимальная стратегия поведения агента (затрагами на покупку/продажу акций пренебрегалось, $J = 0$): вкладывать весь капитал в акции ($u(t + 1) = 1$) при росте курса ($\Delta X(t + 1) > 0$), вкладывать весь капитал в деньги ($u(t + 1) = 0$) при падении курса ($\Delta X(t + 1) < 0$). Анализ экспериментов, представленных на рис. 19, показал, что в случаях LE (обучение + эволюция), и E (чистая эволюция)

такая оптимальная стратегия находится. Это соответствует асимптотическому значению ресурса $R_{max}(500) = 6.5$.

В случае L (чистое обучение) асимптотическое значение ресурса ($R_{max}(2500) = 5.4$) существенно меньше. Анализ экспериментов для этого случая показал, что одно обучение обеспечивает нахождение только следующей «субоптимальной» стратегии поведения: агент держит капитал в акциях при росте и при слабом падении курса и переводит капитал в деньги при сильном падении курса. Та же тенденция к явному предпочтению вкладывать капитал в акции при чистом обучении наблюдалась и для экспериментов на стохастическом ряде (21).

Итак, результаты, представленные на рис. 19, демонстрируют, что хотя обучение в настоящей модели и несовершенно, оно способствует более быстрому нахождению оптимальной стратегии поведения по сравнению со случаем чистой эволюции (см. графики LE и E на рис. 19).

Интересную особенность процесса поиска оптимального решения демонстрирует рис. 20. Этот рисунок показывает график $R_{max}(n_g)$ наряду со стандартным отклонением $\sigma(n_g)$ для случая LE. Значения $\sigma(n_g)$ характеризуют разброс значений $R_{max}(n_g)$ для различных реализаций моделируемых процессов. Рис. 20 показывает, что рост $R_{max}(n_g)$ сопровождается и ростом разброса значений R_{max} : кривая $\sigma(n_g)$ имеет максимум в области быстрого роста $R_{max}(n_g)$. Эта особенность имеет общий характер: кривые $\sigma(n_g)$ имеют аналогичные максимумы и для случаев L и E.

Стоит отметить, что эта особенность — увеличение числа случайных вариантов возможных решений на активной стадии поиска — сходна с явлением генерализации при выработке условного рефлекса [60]. При выработке условного рефлекса на стадии генерализации также происходит интенсификация случайной поисковой активности: реакция возникает не только на условный стимул, но на различные подобные ему (дифференцировочные) раздражители. И только затем происходит специализация, при которой реакция на дифференцировочные стимулы постепенно ослабевает и сохраняется только реакция на условный стимул. При выработке условного рефлекса зависимость условной реакции от числа экспериментов подобна кривой $R_{max}(n_g)$ на рис. 20. Увеличение интенсивности случайного поиска при генерализации сходно с ростом величины $\sigma(n_g)$ в области быстрого увеличения величины $R_{max}(n_g)$.

Особенности обучения (чистое обучение без эволюции). Рис. 19 демонстрирует, что рассмотренная простая форма обучения при данной структуре НС (см. разд. «Описание модели», с. 144) несовершенна, так как она может привести лишь к «субоптимальной» стратегии поведения, даже если обучение происходит в течение большого числа поколений. Асимптотическое значение R_{max} для синусоиды составляет только $R_{max} = 5.4$ (см. кривую L на рис.19), что значительно меньше асимптотического значения $R_{max} = 6.5$, соответствующего оптимальной стратегии (кривые LE и E на рис. 19). Это обусловлено тем, что чистое обучение способно найти лишь «субоптимальную» стратегию: агент покупает акции, когда их цена растет или слегка падает и продает акции, когда их цена падает значительно. Такое поведение агента для синусоидального и стохастического временного ряда показано на рис. 21 и 22, соответственно.




Рис. 21. Динамика поведения обучающегося агента для синусоиды (20)

Действия агента характеризуются величиной $u(t)$ (сплошная линия): при $u = 0$ весь капитал переведен в деньги, при $u = 1$ весь капитал переведен в акции. Временной ряд $X(t)$ показан пунктирной линией. Случай чистого обучения.

Таким образом, в случае чистого обучения агент явно предпочитает хранить свой капитал в акциях, а не в деньгах.




Рис. 22. Динамика поведения обучающегося агента для стохастического ряда (21)

Действия агента характеризуются величиной $u(t)$ (сплошная линия): при $u = 0$ весь капитал переведен в деньги, при $u = 1$ весь капитал переведен в акции. Временной ряд $X(t)$ показан пунктирной линией. Случай чистого обучения.

Взаимодействие между обучением и эволюцией. Эффект Балдвина. Как показано на рис. 19 (кривая E) для синусоидального временного ряда чистая эволюция способна найти оптимальную стратегию во всех экспериментах. В случае стохастического временного ряда оптимальная стратегия также обнаруживалась в экспериментах с чистой эволюцией, но лишь в некоторых расчетах. Например, при $N_g = 300$ и $T = 200$ эволюция смогла найти оптимальную стратегию в восьми из 10 экспериментов. Пример найденной таким образом оптимальной стратегии представлен на рис. 23.

Рис. 19 также демонстрирует, что поиск оптимальной стратегии посредством только эволюции происходит медленнее, чем при эволюции, объединенной с обучением (см. кривые E и LE на этом рисунке). Хотя обучение в данной модели само по себе не оптимально, оно помогает эволюции находить лучшие стратегии.




Рис. 23. Стратегия поведения лучшего агента в популяции Действия агента характеризуются величиной $u(t)$ (сплошная линия): при $u = 0$ весь капитал переведен в деньги, при $u = 1$ весь капитал переведен в акции. Временной ряд $X(t)$ показан пунктирной линией. Здесь $n = 10$, $T = 200$. Случай чистой эволюции. Стратегия поведения агента практически оптимальна: агент покупает/продает акции при росте/падении курса акций.

Если длительность поколения T была достаточно большой (1000 и более тактов времени), то для случая LE часто наблюдалось и более явное влияние обучения на эволюционный процесс. В первых поколениях эволюционного процесса существенный рост ресурса агентов наблюдался не с самого начала поколения, а спустя 200–300 тактов, т. е. агенты явно обучались в течение своей жизни находить более или менее приемлемую стратегию поведения, и только после смены ряда поколений рост ресурса начинался с самого начала поколения. Это можно интерпретировать как проявление известного *эффекта Балвина*: исходно приобретаемый навык в течение ряда поколений становился наследуемым [61–63]. Этот эффект наблюдался в ряде экспериментов, один из которых представлен на рис. 24.

Для этого эксперимента было проанализировано, как изменяется значение ресурса наилучшего агента в популяции $R_{max}(t)$ в течение первых пяти поколений. Расчет был проведен для синусоидального ряда (20). Рис. 24 показывает, что в течение первых двух поколений значительный рост ресурса




Рис. 24. Зависимость ресурса лучшего в популяции агента R_{max} от времени t для первых пяти поколений
 Случай LE (эволюция, объединенная с обучением); размер популяции $n = 10$, длительность поколения $T = 1000$. Моменты смены поколений показаны вертикальными линиями. Для первых двух поколений есть явная задержка в 100–300 тактов времени в росте ресурса агента. К пятому поколению лучший агент «знает» хорошую стратегию поведения с самого рождения, т. е. стратегия, изначально приобретаемая посредством обучения, становится наследуемой.

лучшего в популяции агента начинается только после задержки 100–300 тактов времени; т. е., очевидно, что агент оптимизирует свою стратегию поведения при помощи обучения. От поколения к поколению агент находит хорошую стратегию поведения все раньше и раньше. К пятому поколению лучший агент «знает» хорошую стратегию поведения с самого рождения, и обучение не приводит к существенному улучшению стратегии. Таким образом, рис. 24 показывает, что стратегия, изначально приобретаемая посредством обучения, становится наследуемой (эффект Балдвина).

Были проанализированы различные наборы параметров модели и выяснено, что эффект Балдвина стабильно проявляется, если продолжительность поколения T составляет 1000 и более тактов времени, что обеспечивает достаточно эффективное обучение в течение жизни агента.

Особенности предсказания Модели. Практика не есть критерий истины. Система управления каждого агента включает в себя нейронную сеть Модели, предназначенную для предсказания изменения значения $\Delta X(t+1)$ временного ряда в следующий такт времени $t+1$. Анализ работы Модели обнаружил очень интересную особенность. Нейронная сеть Модели может давать неверные предсказания, однако агент, тем не менее, может использовать эти предсказания для принятия верных решений. Например, рис. 25 показывает предсказываемые изменения $\Delta X^{pr}(t+1)$ и реальные изменения $\Delta X(t+1)$ стохастического временного ряда в случае чистой эволюции (случай E). Предсказания нейронной сети Модели достаточно хорошо совпадают по форме с кривой ΔX . Однако, предсказанные значения $\Delta X^{pr}(t+1)$ отличаются примерно в 25 раз от значений $\Delta X(t+1)$.




Рис. 25. Предсказываемые $\Delta X^{pr}(t+1)$ (пунктирная линия) и реальные изменения $\Delta X(t+1)$ (сплошная линия) стохастического временного ряда

Случай чистой эволюции. Здесь $n = 10$, $T = 200$. Хотя обе кривые имеют сходную форму, по величине $\Delta X^{pr}(t+1)$ и $\Delta X(t+1)$ радикально различаются.

На рис. 26 приведен другой пример особенностей предсказания нейронной сети Модели в случае LE (эволюция, объединенная с обучением).




Рис. 26. Предсказываемые $\Delta X^{pr}(t+1)$ (пунктирная линия) и реальные изменения $\Delta X(t+1)$ (сплошная линия) стохастического временного ряда
Случай эволюции, объединенной с обучением. Здесь $n = 10$, $T = 200$. Кривые $\Delta X^{pr}(t+1)$ и $\Delta X(t+1)$ различаются как по величине, так и знаком.

Этот пример показывает, что предсказания нейронной сети Модели могут отличаться от реальных данных не только масштабом, но и знаком.

Хотя предсказания Модели могут быть неверными количественно, можно предположить, что правильность их формы или правильность после линейных преобразований (например, изменения знака) приводит к тому, что Модель является полезной для адаптивного поведения. Эти предсказания эффективно используются системой управления агентов для нахождения оптимальной поведения: стратегия поведения агентов для обоих приведенных примеров работы Модели была подобна стратегии, представленной на рис. 23.

По-видимому, наблюдаемое увеличение значений ΔX^{pr} нейронной сетью Модели полезно для работы нейронной сети Критика, так как реальные значения $\Delta X(t+1)$ слишком малы (порядка 0.001). Таким образом, нейронная сеть Модели может не только предсказывать значения $\Delta X^{pr}(t+1)$, но также осуществлять полезные преобразования этих значений.

Эти особенности работы нейронной сети Модели обусловлены доминирующей ролью эволюции над обучением при оптимизации системы управления агентов. На самом деле, из-за малой длительности поколений ($T = 200$) в проведенном моделировании, веса синапсов нейронных сетей изменяются большей частью за счет эволюционных мутаций. Такой процесс делает предпочтительными такие системы управления, которые устойчивы в эволюционном смысле. Кроме того, важно подчеркнуть, что задача, которую «решает» эволюция в рассматриваемой модели, значительно проще, чем та задача, которую «решает» обучение. Эволюции достаточно обеспечить выбор действий (покупать или продавать), приводящий к награде. А схема обучения предусматривает довольно сложную процедуру прогноза ситуации S , оценки качества прогнозируемых ситуаций, итеративного формирования оценок качества ситуаций $V(S)$ и выбора действия на основе этих оценок. То есть эволюция идет к нужному результату более прямым путем, а так как задача агентов проста, то эволюция в определенной степени «задавливает» довольно сложный механизм обучения. Тем не менее, есть определенная синергия во взаимодействии обучения и эволюции: обучение ускоряет процесс поиска оптимальной стратегии поведения.

Сравнение с поведением простейших животных. Исследуемые агенты имеют две поведенческие тактики (продавать или покупать акции) и выбирают действия, переключаясь между этими тактиками. Можно сопоставить особенности этого поведения с переключением между двумя тактиками при поисковом поведении простейших животных. Например, некоторые виды личинок ручейников используют аналогичные тактики [30,64]. Личинки живут на речном дне и носят на себе «домик» — трубку из песка и других частиц, которые они собирают на дне водоемов. Личинки строят свои домики из твердых частичек разной величины. Они могут использовать маленькие или большие песчинки [64]. Большие песчинки распределены случайно, но обычно встречаются группами. Используя большие песчинки, личинка может построить домик гораздо быстрее и эффективнее, чем используя маленькие, и, естественно, предпочитает использовать большие частицы. Личинка использует две тактики: 1) тестирование частиц вокруг себя и использование выбранных частиц, 2) поиск нового места для сбора частиц. Исследование поведения личинок обнаруживает инерцию в переключении с первой тактики на вторую [30,64]. Если личинка находит большую частицу, она продолжает тестировать частицы, пока не найдет

несколько маленьких, и только после нескольких неудачных попыток найти новую большую частицу, переходит ко второй тактике. Во время поиска нового места личинка время от времени тестирует частицы, которые попадают на ее пути. Она может переключиться со второй тактики на первую, если найдет большую частицу; при этом переключении также может проявляться инерция. Таким образом, переключение между тактиками имеет характер случайного поиска с явным эффектом инерции. Процесс инерционного переключения позволяет животному использовать только общие крупномасштабные свойства окружающего мира и игнорировать мелкие случайные детали.




Рис. 27. Стратегия поведения лучшего агента в популяции. Действия агента характеризуются величиной $u(t)$ (сплошная линия): при $u = 0$ весь капитал переведен в деньги, при $u = 1$ весь капитал переведен в акции. Временной ряд $X(t)$ показан пунктирной линией. Здесь $n = 100$, $T = 200$. Стратегия агента подобна поведению животных с инерционным переключением между двумя тактиками. Агент игнорирует мелкие флуктуации динамики курса акций, переключение между при выбором действия $u = 0$ и выбором действия $u = 1$ обладает свойством инерционности.

В компьютерных экспериментах поведение агента-брокера, подобное поведению животных с инерционным переключением между двумя такти-

ками, наблюдалось, когда система управления агента оптимизировалась с помощью чистой эволюции при достаточно большой численности популяции. То есть фактически происходила оптимизация методом случайного поиска в достаточно большой области возможных решений. Рис. 27 показывает фрагмент стратегии поведения агента, найденной на ранней стадии эволюции в большой популяции, $n = 100$. Эта стратегия агента подобна описанному выше поведению животных с инерционным переключением между двумя тактиками. Стратегия переключения между $u = 0$ и $u = 1$ представляет собой реакцию только на общие изменения в окружающей среде (агент игнорирует мелкие флуктуации в изменении курса акций). Кроме того, переключение явно обладает свойством инерционности.

Выводы по модели эволюции самообучающихся агентов. В рассмотренной модели оптимальная стратегия обеспечивается в случаях чистой эволюции или комбинации обучения и эволюции. Чистое обучение не обеспечивает нахождения оптимальной стратегии. Тем не менее, хотя обучение и несовершенно, оно способствует более быстрому нахождению оптимальной стратегии поведения для случая комбинации обучения и эволюции по сравнению со случаем чистой эволюции.

При достаточно большой длительности жизни агентов часто наблюдалось и более явное влияние обучения на эволюционный процесс. В первых поколениях эволюционного процесса агенты явно обучались находить удачную стратегию поведения в течение своей жизни, а после смены ряда поколений такая стратегия была у агентов с самого рождения. То есть исходно приобретаемый навык в течение ряда поколений становился наследуемым, что можно интерпретировать как проявление известного эффекта Балдина.

Моделирование продемонстрировало очень интересный феномен: нейронная сеть Модели может давать неверные предсказания (Модель предсказывает правильно лишь форму изменений временного ряда, причем, возможно, с неправильным знаком), тем не менее, на основе этого неверного прогноза формируется оптимальная стратегия поведения агента. По-видимому, эта особенность работы системы управления агента обусловлена тем, что задача, которую «решает» эволюция в рассматриваемой модели значительно проще, чем та задача, которую решает обучение. Эволюции достаточно обеспечить выбор действий (покупать или продавать), приводящий к награде. А схема обучения предусматривает значительно более

сложную процедуру прогноза ситуации, оценки качества прогнозируемых ситуаций, итеративного формирования оценок качества ситуаций и выбора действия на основе этих оценок. То есть эволюция идет к нужному результату более прямым путем, а так как задача агентов проста, то эволюция в определенной степени «задавливает» сложный механизм обучения.

Интересные особенности выявились при сравнении поведения модельного агента-брокера с поисковым поведением простых животных. Простые животные в поисковом поведении используют несколько тактик. Например, бабочка может чередовать 1) тактику двигаться в выбранном направлении и 2) искать новое направление движения, а ручейник чередует 1) тактику собрать частицы в удачном месте и 2) искать новое место для сбора частиц [30,31,64]. Переключение между тактиками у животных происходит с эффектом инерции, что позволяет животным игнорировать мелкие, случайные изменения в складывающихся ситуациях, и решать стоящие перед ними проблемы «стратегически», по крупному счету. При анализе поведения агента-брокера оказалось, что поведение, подобное поведению простых животных, находится самым простым путем — методом эволюционного поиска. Причем такое инерционное поведение формируется на ранних стадиях эволюции, единственное, что при этом требуется, чтобы была достаточно большая численность популяции.

Опыт работы с моделью показывает важность вопроса о том, какие системы управления автономных агентов являются эволюционно устойчивыми. Под эволюционной устойчивостью подразумевается свойство фенотипа (и соответствующего ему генотипа) становиться практически нечувствительным к мутациям. В частности, проведенное моделирование продемонстрировало, что сложные нейросетевые схемы обучения могут быть эволюционно нестабильны, если процесс обучения неустойчив относительно к возмущениям весов синапсов нейронных сетей.

Эволюционная неустойчивость работы рассмотренной схемы адаптивного критика показывает, что необходима определенная осторожность в выборе базовой модели функциональной системы (ФС) для проекта «Мозг анимата» (см. с. 137). А, именно, хотя схема адаптивного критика, используемая в качестве основы ФС в изложенной в разделе «Проект “Мозг анимата”» версии проекта, моделирует прогноз результата действия и принятие решения на основе этого прогноза, что существенно для теории функциональных систем, тем не менее, имеет смысл рассмотреть и другие возможности для базовой модели ФС.

Выводы по моделям адаптивного поведения

Исследования адаптивного поведения — актуальное, содержательное и конструктивное направление, которое непосредственно связано с моделированием когнитивной эволюции, исследованием проблемы происхождения интеллекта. Также это направление исследований важно как биологически инспирированная научная основа разработок систем искусственного интеллекта. Это направление использует серьезные математические и компьютерные методы, и здесь построено множество интересных и содержательных моделей. Однако, результаты этих исследований пока достаточно скромные, в целом, результаты моделирования еще далеки от решения стратегически задач, поставленных при инициировании этого направления.

Один из значительных и достаточно неожиданных выводов этих исследований состоит в том, что часто нетривиальное поведение может быть сформировано простой системой управления [6]. Причем, таких систем управления, до которых сам конструктор системы управления может и не догадаться, а система управления формируется в процессе эволюционной самоорганизации, например, с помощью генетического алгоритма.

Определенная фрагментарность разработанных моделей показывает необходимость разработки общей «платформы» для систематизированного построения широкого спектра моделей адаптивного поведения. Такой платформой может стать изложенный выше проект «Мозг анимата».

Контур программы будущих исследований

Анализ моделей адаптивного поведения показывает, что хотя проделана большая работа, ученые еще очень далеки от понимания того, как возникли и развивались системы управления живых организмов, как развитие этих систем способствовало эволюции когнитивных способностей животных, и как процесс когнитивной эволюции привел к возникновению интеллекта человека. То есть, есть огромная область чрезвычайно интересных исследований, которые только-только начинаются.

Предложим контур программы будущих исследований проблемы происхождения интеллекта.

1. **Разработка схем и моделей адаптивного поведения анимата на базе проекта «Мозг анимата».** В разделе «Проект “Мозг анимата”», (с. 137) изложен одноименный проект [52], который предложен как

общая «платформа» для систематизированного построения широкого спектра моделей адаптивного поведения. И реализация в моделях схем и конструкций Мозга анимата могла бы стать первым и важным шагом планируемых исследований.

Воплощение в конкретные модели этих конструкций разумно начать с анализа целостного адаптивного поведения простых агентов, имеющих естественные потребности: питания, размножения, безопасности. Эволюционная схема формирования нейросетевой системы управления подобных агентов, обеспечивающей достаточно нетривиальную структуру целей и подцелей, была исследована *М. С. Бурцевым* [38] («раздел Развитие модели “Кузнечик” — возникновение естественной разветвленной иерархии целей», с. 135). Теперь было бы полезно промоделировать подобные системы управления в рамках конструкций Мозга анимата.

Дальнейшая работа могла бы включать в себя анализ интеллектуальных изобретений биологической эволюции, таких как привыкание и условные рефлексы (рис. 2, см. с. 115), на основе исследований проекта «Мозг анимата».

2. **Исследование перехода от физического уровня обработки информации в нервной системе животных к уровню обобщенных образов.** Такой переход можно рассматривать, как появление в «сознании» животного свойства «понятие». Обобщенные образы можно представить как мысленные аналоги наших слов, не произносимых животными, но реально используемых ими. Например, у собаки явно есть понятия «хозяин», «свой», «чужой», «пища». И важно осмыслить, как такой весьма нетривиальный переход мог произойти в процессе эволюции.
3. **Исследование процессов формирования причинной связи в памяти животных.** По-видимому, запоминание причинно-следственных связей между событиями во внешней среде и адекватное использование этих связей в поведении — одно из ключевых свойств активного познания животным закономерностей внешнего мира. Такая связь формируется, например, при выработке условного рефлекса: животное запоминает связь между условным стимулом (УС) и следующим за ним безусловным стимулом (БС), что позволяет ему предвидеть события в окружающем мире и адекватно использовать это предвидение. При моделировании причинных связей было бы интересно

«копнуть вглубь»: проанализировать процессы формирования таких связей на уровне отдельных нейронов и проследить схемы причинно-следственных связей от нейронного до поведенческого уровня.

Естественный следующий шаг — переход от отдельных причинных связей к «базам знаний», к логическим выводам на основе уже сформировавшихся знаний.

4. **Исследование процессов формирования логических выводов в «сознании» животных.** Фактически, уже на базе классического условного рефлекса животные способны делать «логический вывод» вида: $\{УС, УС \rightarrow БС\} \Rightarrow БС$ или «Если имеет место условный стимул, и за условным стимулом следует безусловный, то нужно ожидать появления безусловного стимула». Можно даже говорить, что такие выводы подобны выводам математика, доказывающего теоремы (раздел «Можно ли обосновать математику?», с. 113). И целесообразно разобраться в системах подобных выводов, понять, насколько адаптивна логика поведения животных и насколько она подобна нашей, человеческой логике. Возможно, здесь были бы полезны семантические сети, предложенные разработчиками искусственного интеллекта, и сопоставление процессов выводов на семантических сетях с «выводами» поведенческой логики животных.
5. **Исследование коммуникаций, возникновения языка.** Наше мышление тесно связано с языком, с языковым общением между людьми. Поэтому целесообразно проанализировать: как в процессе биологической эволюции возникал язык общения животных, как развитие коммуникаций привело к современному языку человека, как развитие коммуникаций и языка способствовало развитию логики, мышления, интеллекта человека.

Конечно же, перечисленные пункты формируют только контуры плана будущих исследований. Тем не менее, уже сейчас видно, сколь широк фронт исследований, и как много нетривиальной, интересной и важной работы предстоит сделать.

Благодарности

Автор благодарен *О. П. Мосалову* за проведение части расчетов по модели агента-брокера (раздел «Модель эволюции популяции самообучающихся

агентов на базе нейросетевых адаптивных критиков»), Д. В. Прохорову за многочисленные консультации по теории адаптивных критиков и В. А. Непомнящих за ряд обсуждений поведения биологических организмов.

Литература

1. Semantic Networks in Artificial Intelligence / Fritz Lehmann, Ed. – Pergamon Press, Oxford, 1992.
2. Воронин Л. Г. Эволюция высшей нервной деятельности. – М.: Наука, 1977. – 128 с.
3. Meyer J.-A., Wilson S. W. (Eds.) From animals to animats // Proceedings of the First International Conference on Simulation of Adaptive Behavior. – The MIT Press: Cambridge, Massachusetts, London, England, 1990.
4. Meyer J.-A., Guillot A. From SAB90 to SAB94: Four years of Animat research // In: Proceedings of the Third International Conference on Simulation of Adaptive Behavior. – The MIT Press: Cambridge, Cliff, Husbands / Meyer J.-A., Wilson S. W. (Eds.), 1994. See also: URL: <http://animatlab.lip6.fr/index.en.html>
5. Guillot A., Meyer J.-A. From SAB94 to SAB2000: What's new, Animat? // In Meyer et al. (Eds). From Animals to Animats 6. Proceedings of the Sixth International Conference on Simulation of Adaptive Behavior. – The MIT Press, 2000. See also: URL: <http://animatlab.lip6.fr/index.en.html>
6. Непомнящих В. А. Аниматы как модель поведения животных // IV Всероссийская научно-техническая конференция «Нейроинформатика-2002». Материалы дискуссии «Проблемы интеллектуального управления — общесистемные, эволюционные и нейросетевые аспекты». – М.: МИФИ, 2003. – с. 58–76. См. также URL: <http://www.keldysh.ru/pages/BioCyber/RT/Nepomn.htm>
7. Непомнящих В. А. Поиск общих принципов адаптивного поведения живых организмов и аниматов // *Новости искусственного интеллекта*. – 2002. – № 2. – с. 48–53.
8. Donnat J. Y., Meyer J. A. Learning reactive and planning rules in a motivationally autonomous animat // *IEEE Transactions on Systems, Man, and Cybernetics. Part B: Cybernetics*. – 1996. – v. 26, No. 3. – pp. 381–395. See also: URL: <http://animatlab.lip6.fr/index.en.html>
9. Wilson S. W. The animat path to AI // In: [3]. –pp. 15–21.
10. Цетлин М. Л. Исследования по теории автоматов и моделирование биологических систем. – М.: Наука, 1969. – 316 с.

11. *Варшавский В. И., Поспелов Д. А.* Оркестр играет без дирижера: Размышления об эволюции некоторых технических систем и управлении ими. – М.: Наука, 1984. – 208 с.
12. *Бонгард М. М., Лосев И. С., Смирнов М. С.* Проект модели организации поведения — «Животное» // Моделирование обучения и поведения. – М.: Наука, 1975. – с. 152–171.
13. *Гаазе-Рапонорт М. Г., Поспелов Д. А.* От амебы до робота: Модели поведения. – М.: Наука, 1987. – 288 с.
14. *Holland J. H.* Adaptation in natural and artificial systems. – Ann Arbor, MI: The University of Michigan Press, 1975 (1st edn). Boston, MA: MIT Press., 1992 (2nd edn).
15. *Курейчик В. М.* Генетические алгоритмы и их применение. – Таганрог, ТРТУ, 2002.
16. *Емельянов В. В., Курейчик В. М., Курейчик В. В.* Теория и практика эволюционного моделирования. – М.: Физматлит, 2003.
17. *Редько В. Г.* Эволюционная кибернетика. – М.: Наука, 2001. – 156 с.
18. *Holland J. H., Holyoak K. J., Nisbett R. E., Thagard P.* Induction: Processes of inference, learning, and discovery. – Cambridge, MA: MIT Press, 1986.
19. *Sutton R., Barto A.* Reinforcement learning: An introduction. – Cambridge: MIT Press, 1998. See also:
URL: <http://www.cs.ualberta.ca/~sutton/book/the-book.html>
20. Сайт AnimatLab:
URL: <http://animatlab.lip6.fr/index.en.html>
21. Сайт AI Laboratory of Zurich University:
URL: <http://www.ifi.unizh.ch/groups/ailab/>
22. *Pfeifer R., Scheier C.* Understanding intelligence. – MIT Press, 1999.
23. Сайт Laboratory of Artificial Life and Robotics:
URL: <http://gral.ip.rm.cnr.it/>
24. *Nolfi S., Floreano D.* Evolutionary robotics: The biology, intelligence, and technology of self-organizing machines. – Cambridge, MA: MIT Press/Bradford Books, 2000. – 384 pp.
25. Сайт MIT Computer Science and Artificial Intelligence Laboratory: URL: <http://www.csail.mit.edu/index.php>
26. *Brooks R. A.* Cambrian Intelligence: The early history of the new AI. – MIT Press, 1999.

27. Сайт Neuroscience Institute:
URL: <http://www.nsi.edu/>
28. Krichmar J. L., Edelman G. M. Machine psychology: Autonomous behavior, perceptual categorization and conditioning in a brain-based device // *Cerebral Cortex*. – 2002. – v. 12. – pp. 818–830.
29. Krichmar J. L., Edelman G. M. Brain-based devices: intelligent systems based on principles of the nervous system // In *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. – Las Vegas, NV, 2003. – pp. 940–945.
30. Непомнящих В. А. Как животные решают плохо формализуемые задачи поиска // *Синергетика и психология: Тексты. Выпуск 3: Когнитивные процессы* / Ред. Аришинов В. И., Трофимова И. Н., Шендяпин В. М. – М.: Когито-Центр, 2004. – с. 197–209.
31. Неротныашчих В. А., Подгорный К. А. Emergence of adaptive searching rules from the dynamics of a simple nonlinear system // *Adaptive Behavior*. – 2003. – v. 11, No. 4. – pp. 245–265.
32. Жданов А. А. Метод автономного адаптивного управления // *Изв. РАН. Теория и системы управления*. – 1999. – № 5. – с. 127–134.
33. Жданов А. А. О методе автономного адаптивного управления // VI Всероссийская научно-техническая конференция «Нейроинформатика-2004». Лекции по нейроинформатике. Часть 2. – М.: МИФИ, 2004. – с. 15–56.
34. Станкевич Л. А. Нейрологические средства систем управления интеллектуальных роботов // VI Всероссийская научно-техническая конференция «Нейроинформатика-2004». Лекции по нейроинформатике. Часть 2. – М.: МИФИ, 2004. – с. 57–110.
35. Самарин А. И. Модель адаптивного поведения мобильного робота, реализованная с использованием идей самоорганизации нейронных структур // IV Всероссийская научно-техническая конференция «Нейроинформатика-2002». Материалы дискуссии «Проблемы интеллектуального управления — общесистемные, эволюционные и нейросетевые аспекты». – М.: МИФИ, 2003. – с. 106–120.
36. Бурцев М. С., Гусарев Р. В., Редько В. Г. Модель эволюционного возникновения целенаправленного адаптивного поведения. 1. Случай двух потребностей // *Препринт ИПМ РАН*. – 2000. – № 43. См. также
URL: <http://www.keldysh.ru/pages/BioCyber/PrPrint/PrPrint.htm>
37. Бурцев М. С., Гусарев Р. В., Редько В. Г. Исследование механизмов целенаправленного адаптивного управления // *Изв. РАН. Теория и системы управления*. – 2002. – № 6. – с. 55–62.
38. Бурцев М. С. Модель эволюционного возникновения целенаправленного адаптивного поведения. 2. Исследование развития иерархии целей // *Препринт ИПМ РАН*. – 2002, № 69.

39. Мосалов О. П., Редько В. Г., Непомнящих В. А. Модель поискового поведения анимата // *Препринт ИПМ РАН*. – 2003, № 19.
40. Мосалов О. П., Прохоров Д. В., Редько В. Г. Модели принятия решений на основе нейросетевых адаптивных критиков // *Девятая Национальная конференция по искусственному интеллекту с международным участием (КИИ-2004)*. Труды конф. в 3-х тт. – М.: Физматлит, 2004. – т. 3. – с. 1156–1163.
41. Klopff A. H. The Hedonistic neuron: A theory of memory, learning, and intelligence. – Hemisphere, Washington, 1982. – 140 pp.
42. Learning and approximate dynamic programming: Scaling up to the real world (Edited by Jennie Si, Andrew Barto, Warren Powell, and Donald Wunsch). – IEEE Press and John Wiley & Sons, 2004.
43. Редько В. Г., Прохоров Д. В. Нейросетевые адаптивные критики // Научная сессия МИФИ-2004. VI Всероссийская научно-техническая конференция «Нейроинформатика-2004». Сб. науч. трудов. Часть 2. – М.: МИФИ, 2004. – с. 77–84.
44. Prokhorov D. V., Wunsch D. C. Adaptive critic designs // *IEEE Trans. Neural Networks*. – 1997. – v. 8, No. 5. – pp. 997–1007.
45. Prokhorov D. V. Backpropagation through time and derivative adaptive critics: a common framework for comparison // In [42]. See also:
URL: <http://mywebpages.comcast.net/dvp/>
46. Анохин П. К. Системные механизмы высшей нервной деятельности. – М.: Наука, 1979. – 453 с.
47. Анохин П. К. Принципиальные вопросы общей теории функциональных систем // *Принципы системной организации функций*. – М.: Наука, 1973. – с. 5–61.
48. Судаков К. В. (ред.). Теория системогенеза. – М.: Горизонт, 1997.
49. Умрюхин Е. А. Механизмы мозга: информационная модель и оптимизация обучения. – М.: Горизонт, 1999. – 96 с.
50. Моделирование функциональных систем (под ред. Судакова К. В. и Викторова В. А.) – М.: РАМН, РСМАН, 2000. – 254 с.
51. Анохин К. В., Бурцев М. С., Зарайская И. Ю., Лукашев А. О., Редько В. Г. Проект «Мозг анимата»: разработка модели адаптивного поведения на основе теории функциональных систем // *Восьмая Национальная конференция по искусственному интеллекту с международным участием*. Труды конференции. – М.: Физматлит, 2002. – т. 2. – с. 781–789.
52. Red'ko V. G., Prokhorov D. V., Burtsev M. S. Theory of functional systems, adaptive critics and neural networks // *International Joint Conference on Neural Networks*. – Budapest, 2004. – pp. 1787–1792.

53. *Tsitolovsky L. E.* A model of motivation with chaotic neuronal dynamics // *Journ. of Biological Systems*. – 1997. – v. 5, No. 2. – pp. 301–323.
54. *Турчин В. Ф.* Феномен науки. Кибернетический подход к эволюции. – М.: Наука, 1993. – 295 с. (1-е изд). М.: ЭТС, 2000. – 368 с. (2-е изд). См. также URL: <http://www.refal.ru/turchin/phenomenon/>
55. *Rumelhart D. E., Hinton G. E., Williams R. G.* Learning representation by back-propagating error // *Nature*. – 1986. – v. 323, No. 6088. – pp. 533–536.
56. *Edelman G. M.* Neural Darwinism: The Theory of Neuronal Group Selection. – Oxford: Oxford University Press, 1989.
57. *Red'ko V. G., Mosalov O. P., Prokhorov D. V.* A model of Baldwin effect in populations of self-learning Agents // *International Joint Conference on Neural Networks*, Montreal, 2005.
58. *Prokhorov D., Puskorius G., Feldkamp L.* Dynamical neural networks for control // In: *J. Kolen and S. Kremer (Eds.) A field guide to dynamical recurrent networks*. – NY: IEEE Press, 2001. – pp. 257–289.
59. *Moody J., Wu L., Liao Y., Saffel M.* Performance function and reinforcement learning for trading systems and portfolios // *Journal of Forecasting*. – 1998, vol. 17. – pp. 441–470.
60. *Котляр Б. И., Шульговский В. В.* Физиология центральной нервной системы. – М.: Изд-во МГУ, 1979. – 342 с.
61. *Baldwin J. M.* A new factor in evolution // *American Naturalist*. – 1896, vol. 30. – pp. 441–451.
62. *Turney P., Whitley D., Anderson R. (Eds.)*. Evolution, learning, and instinct: 100 years of the Baldwin effect // *Special Issue of Evolutionary Computation on the Baldwin Effect*. – v. 4, No. 3, 1996.
63. *Weber B. H., Depew D. J. (Eds.)* Evolution and learning: The Baldwin effect reconsidered. – MA: MIT Press, 2003.
64. *Nepomnyashchikh V. A.* Selection behaviour in caddis fly larvae // In *R. Pfeifer et al (Eds.) From Animals to Animats 5: Proceedings of the Fifth International Conference of the Society for Adaptive Behavior*. – Cambridge, MA: MIT Press, 1998. – pp. 155–160.

Владимир Георгиевич РЕДЬКО, доктор физико-математических наук, заместитель директора Института оптико-нейронных технологий РАН. Область научных интересов — эволюционная кибернетика. Автор 2 монографий и более 50 научных публикаций.

ИГУМЕН ФЕОФАН (КРЮКОВ)

Свято-Данилов монастырь, Москва

E-mail: kryukov@msdm.ru

**МОДЕЛЬ ВНИМАНИЯ И ПАМЯТИ, ОСНОВАННАЯ НА
ПРИНЦИПЕ ДОМИНАНТЫ. ЧАСТЬ II: ПОПЫТКА ПРИМИРЕНИЯ
КОНКУРИРУЮЩИХ ТЕОРИЙ ДОЛГОВРЕМЕННОЙ ПАМЯТИ**

Аннотация

Существует несколько попыток примирить ряд конкурирующих теорий о роли гиппокампа в долговременной памяти. Однако эти попытки не убедительны, так как не объясняют характеристические (основополагающие) эффекты этих теорий с единых позиций. Мы приводим критический обзор четырех основных теорий и с помощью ранее опубликованной в лекциях «Нейроинформатика-2002» математической модели внимания и памяти показываем, что только одна из них способна примирить эти теории, сохраняя вклад каждой из них, путем единообразного объяснения характеристических эффектов каждой из теорий. Ключевым вопросом при этом оказывается вопрос о наличии или отсутствии памяти в самом гиппокампе, без решения которого примирение невозможно.

HEGUMEN THEOPHAN (KRYUKOV)

St. Daniel Monastery, Moscow

E-mail: kryukov@msdm.ru

**AN ATTENTION AND MEMORY MODEL BASED ON THE
PRINCIPLE OF DOMINANTIA. Part II: AN ATTEMPT TO
RECONCILE CONCURRENT THEORIES**

Abstract

Several attempts have been made to reconcile a number of concurrent theories on the role of the hippocampus in long-term memory functions. Those attempts have not been successful, however, as they fail to explain the characteristic effects of the theories from the same standpoint. We are making a review of the four major theories and shall demonstrate, with the use of mathematical models of attention and memory, that only one of them is capable to reconcile them all by explaining the characteristic effects of each theory in a unified fashion without sacrificing their individual contributions. The key issue here is whether or not a memory trace is ever stored in the hippocampus itself, and there is no reconciliation unless it is resolved.

Введение

Гиппокамп играет критическую роль во многих видах обучения и памяти [Dudai 2004]. Но вопрос о том, какова его конкретная функция при этом, есть предмет многолетних дебатов, возможно, без правильной постановки вопросов [Redish 2001] и остается предметом отчаянных поисков [Riedel & Micheau 2001]. Одна из наиболее влиятельных теорий основана на гипотезе о том, что гиппокамп — хранилище пространственной информации, но в последнее время становится более распространенной гипотеза, что гиппокамп — хранилище декларативной/эпизодической памяти. Существуют и многие другие влиятельные теории и гипотезы, недавний обзор которых приведен в работе [Holsher 2003]. Поскольку известно, что разрушение гиппокампа оставляет сохраненной кратковременную память [Alvarez et al 1994], то почти все теории памяти предполагают, что гиппокамп более или менее долговременно хранит следы прошлого опыта. Вот некоторые высказывания известных специалистов.

«Главное утверждение теории когнитивной карты состоит в том, что обработка и хранение пространственной информации является первичной и, может быть, исключительной ролью гиппокампа у крыс» [O'Keefe 1999, p. 352].

«Пространственная информация и информация о целых объектах могут быть объединены вместе в памяти гиппокампа» [Mayes & Roberts, 2001, p. 1400].

«Гиппокампальная память, подобно другим видам памяти, может быть разделена на четыре процесса: кодирование, хранение, консолидацию и считывание. Мы утверждаем, что синаптическая пластичность является критической для кодирования и промежуточного хранения памятных следов, которые автоматически записываются в гиппокампе» [Morris et al 2003, p. 773].

«Новые данные проясняют природу консолидации, идентифицируют типы памяти, которые должны оставаться закодированными в гиппокампальной системе в течение долгого времени и помогают разграничить семантическую и эпизодическую память» [Shastri 2002, p. 162].

«Две конкурирующие теории считают, что медиальная височная кора и, конкретнее, гиппокамп является местом временного хранения информации, предназначенной для консолидации, или местом постоянного хранения множества памятных следов» [Riedel & Micheau 2001].

Хотя эти высказывания согласны между собой в главном вопросе о том,

что гиппокамп накапливает и хранит памятные следы, но одновременно они поднимают, соответственно, следующий ряд нерешенных вопросов:

1. Является ли обработка пространственной информации в гиппокампе более первичной или более важной среди других типов информации?
2. Как и где в гиппокампе комбинируются пространственная и непространственная информация?
3. Играет ли синаптическая модификация в гиппокампе критически важную роль в формировании памяти или она играет при этом менее специфическую, вспомогательную роль?
4. Существует ли четкое различие между обработкой эпизодической и семантической информации в гиппокампе?
5. Является ли гиппокамп постоянным или временным хранилищем памятных следов?

В настоящее время существует четыре главных теории, связывающие гиппокамп и память: Теория Когнитивной Карты [O'Keefe & Nadel 1978], которая утверждает первичную роль гиппокампа в обработке и хранении пространственной информации; Стандартная Теория [Alvarez & Squire 1994], согласно которой гиппокамп не хранит долговременную память, но является промежуточным хранилищем декларативной памяти на время, необходимое для консолидации этой памяти; Теория Множественных Следов [Nadel & Moscovitch 1997] считает, что гиппокамп — долговременное хранилище, но не всей декларативной памяти, но лишь ее части, неокортикального индекса или адреса, где хранится сама эта память; Теория Тета-Регулируемого Внимания [Vinogradova 2001] вообще отрицает существование долговременной и промежуточной памяти в гиппокампе, считая, что неокортекс есть место хранения всех видов памяти.

Существует несколько попыток «навести мосты» между некоторыми из этих теорий и построить единую теорию памяти и гиппокампа. Среди них в [Moita et al 2003] и [Knierim 2003] сделана попытка примирить первые две теории на основе общей для них функции внимания. В [Morris et al 2003] сообщается о нейробиологическом синтезе всех основных теорий, кроме четвертой. Еще одну попытку отождествить процессы эпизодической памяти и внимания на основе данных о полном совпадении структур мозга, активных в этих процессах [Cabeza et al 2003] можно рассматривать как попытку примирить вторую и третью теорию с четвертой. Однако многолетние дискуссии о функции гиппокампа свидетельствуют о том, что

каждая из этих теорий, согласно обзору [Holsher 2003], делает две ошибки: во-первых, исключает или игнорирует данные, ей противоречащие, и, во-вторых, изолирует гиппокамп из большой системы, частью которой он является, приписывая специальные функции каждой анатомической области мозга, несмотря на то, что есть много данных, что они — части единой функциональной системы.

В этих условиях, на пути решения проблемы функции гиппокампа в памяти, возникает тупик (*impasse*), из-за несогласных интерпретаций, отмеченный в обзоре [Kriegel 2003], который, мы считаем, не может быть преодолен путем дальнейшего накопления экспериментальных данных без детальной нейронной модели внимания и памяти. В настоящем критическом обзоре мы кратко фиксируем основные допущения, утверждения и трудности каждой из четырех теорий памяти в гиппокампе, приводим характеристические (т. е. основополагающие) эффекты каждой из теорий, которые должны быть объяснены единой моделью, даем вариант такой унифицирующей модели, единообразно объясняющая их и в конце заключаем, что одна только четвертая теория способна примирить все теории, так как только она позволяет построить нейронную модель внимания и памяти, которая с единых позиций объясняет все важнейшие эффекты связи памяти и гиппокампа.

Теория Когнитивной Карты

Основные допущения и утверждения этой теории довольно критичны в отношении принятой терминологии, и поэтому мы даем их в авторском изложении. Согласно этой теории, «существует, по крайней мере, одна нейронная система, которая служит основой целостной модели окружающей среды. Она лежит в основе понятия абсолютного единого пространства, в котором движется организм с его эгоцентрическими пространствами. . . Мы будем называть систему, отображающую это абсолютное пространство, когнитивной картой и идентифицировать ее с гиппокампом. Она позволяет животному определить свое местоположение в знакомой окружающей среде без использования сенсорных входов, переходить с одного места в другое независимо от специфических входов и выходов и соединять части окружающей обстановки, которые одновременно никогда не были в опыте животного. . . У человека левый гиппокамп отображает семантическую карту, в то время как правый гиппокамп остается пространственной кар-

той, как и у всех более низших животных» [O'Keefe & Nadel 1978. p. 1–3]. «Гиппокамп создает и хранит когнитивные карты (p. 374). Гиппокамп есть интеграл долговременного хранения локальной информации, что придает этой структуре центральную роль в механизмах памяти» [O'Keefe & Nadel 1978, p. 377].

Огромное число экспериментов было выполнено, основываясь на гипотезах этой теории, и обширные работы по моделированию были проведены в попытках понять основные пространственные эффекты, связанные с этой теорией. Мы приведем лишь два характеристических эффекта, которые должна объяснить любая нейронная модель функции гиппокампа и его роли в формировании долговременной памяти.

Эффект клетки места [O'Keefe & Nadel 1978]. Гиппокамп крыс содержит локально-специфические клетки, которые интенсивно срабатывают преимущественно тогда, когда крыса входит в некоторую ограниченную область пространства, называемую полем клетки места (place field). Вне этого поля клетки места срабатывают редко. Наиболее существенные общие свойства этих клеток следующие:

- *Ненаправленность*. Срабатывание клеток места в цилиндрической камере зависит от положения головы крысы в пространстве и фактически не зависит от направления, в котором повернута голова [Muller 1996].
- *Реконфигурация (remapping)*. При изменении внешних или внутренних условий клетки места способны к одновременному полному или частичному изменению паттернов срабатывания. Поля места тех клеток, которые активны в старых и измененных пространственных условиях, обычно не связаны друг с другом [Muller 1996]. Топологическое соответствие между анатомическим положением клеток места в гиппокампе и полем клеток места в пространстве отсутствует [O'Keefe et al 1998].
- *Стабильность*. Поле клетки места обычно стабильно по крайней мере в течение получаса, и даже в темноте, причем долговременная стабильность полей клеток, необходимая для решения пространственных задач, коррелирует с мерой внимания, определяемой как относительное время, в течение которого животное придает большее значение пространственным стимулам, чем другим элементам сенсорного опыта [Kentros et al 2004].

- *Двойной код.* Средняя частота срабатывания и время появления спайков клеток места по отношению к фазе тета-ритма ЭЭГ меняются по мере прохождения крысы через поле клетки места, причем первая лучше отражает скорость движения крысы при переходе через поле клетки места, а второе монотонно падает и лучше отражает текущее положение крысы внутри поля [Nuxter et al 2003]. Однако оба кода могут сигнализировать как о пространственном, так и непространственном поведении крысы [Harris et al 2002].
- *Дирекциональность.* Поле клетки места асимметрично и зависит от обстановки и направления движения крысы. При вращении внешних обстановочных ключевых стимулов оно синхронно вращается [Redish et al 2001], точнее, пространственное вращение производит примерно одинаковое вращение пространственно-разрядных корреляций [Muller 1996]. Поля, записанные у крысы бегущей по линейному треку, удлиняются с опытом в направлении, противоположном движению крысы [Mehta et al 2000]. В открытом поле со свободным поведением крысы дирекциональность не образуется [Redish 1999, p. 108–109].
- *Многомодальность.* Клетки места в определенных условиях отвечают на сенсорные стимулы различной модальности. Так, после выработки условного рефлекса избегания, клетки места отвечают на условный стимул (звук), но только тогда, когда крыса находится в поле места этих клеток [Moita et al 2003]. Однако условный стимул может индуцировать реконфигурацию, даже если внешняя обстановка остается неизменной [Moita et al 2004].

Эффект точки зрения [King et al 2002]. Двухсторонняя патология гиппокампа (пациент Jon) дает сильное ухудшение опознавания положения объектов, если тестирование производится не из начального положения пациента при обучении, а из другого положения со сдвинутой точкой зрения. В отсутствии сдвига точки зрения ухудшение опознавания у такого пациента было умеренным, зависящим от длины списка объектов для опознавания. В случае отсутствия патологии, время опознавания объекта при изменении угла сдвига менялось не очень значительно и было пропорционально углу сдвига между начальной и конечной точкой зрения [Diwadkar & McNamara 1997].

Этот эффект, по мнению авторов, не может объяснить ни одна из суще-

ствующих теорий памяти, кроме теории пространственной аллоцентрической (т. е. независимой от точки зрения) памяти в гиппокампе. Напротив, **эффект клетки места**, особенно свойство *многомодальности*, часто служит аргументом в пользу несколько более общей теории эпизодической памяти (см., напр., [Eichenbaum et al 1999]). Заметим, однако, что в настоящее время не существует нейросетевой модели, которая могла бы объяснить все указанные свойства клетки места одновременно.

Основное предсказание теории в первоначальном варианте состояло в том, что гиппокампальные клетки места являются нейронным субстратом когнитивной карты. Более поздние формулировки ослабляют это предсказание тем, что гиппокамп запоминает аллоцентрическое представление пространственных локусов [Burgess et al 2001], или еще слабее, что не гиппокамп, а весь гиппокампальный комплекс в медиальной височной коре запоминает и хранит пространственно-временной контекст эпизодов [King et al 2002, Nadel et al 2003, Nadel & Hardt 2004].

Данные, которые противоречат теории когнитивной карты, слишком многочисленны, чтобы можно было привести здесь хотя бы наиболее важные из них (см. [Holsher 2003]), но почти все они сводятся к тому, что активность гиппокампа отражает более общий тип обработки, чем обработка пространственной информации, например запоминание и консолидацию эпизодической памяти, или представление и запоминание байндинг-кодов. Соответствующие две конкурирующие теории будут рассмотрены ниже. Заклучим этот раздел следующим выводом: «Клетки места кодируют не место как таковое, но более сложные комбинации-совпадения пространственных и непространственных свойств стимулов, которые могут быть субстратом эпизодической памяти. Тогда отпадает вопрос о существовании когнитивной карты в смысле О'Keefe и Nadel, поскольку карта оказывается распределенной по столь многим структурам, что ее совсем нельзя по настоящему называть картой» [Jeffery et al 2003, p. 35–36].

Что касается хранения пространственной информации в самом гиппокампе, хотя бы как части контекста эпизода, то один из авторов теории когнитивной карты недавно признал: «Остается неясным, запоминаются ли контекстные следы в самом гиппокампе, как первоначально предполагали О'Keefe и Nadel, или вместо этого они запоминаются в парагиппокампальных областях, как это подсказывают недавние исследования» [Nadel et al 2003]. Упомянутые здесь недавние результаты, подсказывающие отсутствие памяти контекста в самом гиппокампе, получены в работе [Hayes et al 2004]: парагиппокампальная область, а не гиппокамп, преимущественно

участвует в обработке и считывании пространственной локальной информации. Отсутствие пространственной карты в гиппокампе подтверждено в работе [Maviel et al 2004]. Согласно данным этой работы, гиппокамп лишь временно участвует в формировании пространственной карты в префронтальной и цингулятной коре. Но еще остается возможность, что гиппокамп хранит пространственную или контекстную информацию лишь временно, до тех пор пока память не консолидируется в неокортексе. Чтобы оценить эту возможность, нам необходимо рассмотреть две основные теории консолидации долговременной памяти.

Стандартная Теория

Эта теория, в отличие от предыдущей, полагает, что гиппокамп участвует в формировании как пространственной, так и непространственной декларативной памяти, но сам не является окончательным хранилищем памяти, а вместе с близлежащими структурами медиальной височной коры (MTL) выполняет функции временной буферной памяти [Alvarez & Squire 1994, Squire et al 2004], решая, таким образом, известную теоретическую проблему коннекционизма под названием *проблема катастрофической интерференции* [McClelland et al 1995]. Последняя состоит в том, что ассоциативная нейронная сеть с модифицируемыми хеббовскими синаптическими связями, формируя в неокортексе ячейки (аттракторы) памяти, оказывается неспособной к быстрому обучению и катастрофически разрушается при поступлении новой информации вскоре после первоначального обучения. Гиппокамп и близлежащие структуры по предположению Стандартной Теории не имеют этого недостатка и, быстро запоминая новую информацию «на линии», затем медленно пересылают ее в неокортекс, предположительно во время сна, или же участвуют в более или менее продолжительной перестройке структуры неокортикальной сети таким образом, что со временем необходимость в гиппокампе отпадает. Процесс передачи информации из гиппокампа в неокортекс или соответствующая перестройка структуры памяти называется в этой теории *консолидацией*.

Более точно основные допущения этой теории были сформулированы в следующем виде [Alvarez & Squire 1994]:

1. Критическое событие для формирования хранения и считывания долговременной декларативной памяти есть взаимодействие между множественными, пространственно удаленными областями неокортекса

- и структурами МТЛ, включающим в себя гиппокамп и близлежащие области.
2. Ключевое событие консолидации внутри неокортекса — это постепенный байндинг множества пространственно распределенных кортикальных областей, которые совместно образуют представительство целого события. Постепенный байндинг — есть нейрофизиологический субстрат консолидации.
 3. Обучение в МТЛ происходит быстро, но МТЛ имеет ограниченную емкость. Неокортекс обучается медленно (т. е. разрозненные области связываются вместе медленно) и имеет большую емкость. В обоих случаях обучение идет согласно простому хеббовскому правилу изменения силы синаптических связей.
 4. Консолидация происходит тогда, когда нейронная активность в МТЛ коактивирует пространственно разнесенные области неокортекса. Эти области, первоначально слабо связанные, становятся более связанными при повторной активации посредством МТЛ и постепенно становятся независимыми от гиппокампа.

Из этих допущений следует, что гиппокамп вместе с прилегающими областями МТЛ вовлечен в формирование и воспроизведение долговременной памяти лишь временно в качестве буфера, пока не завершится консолидация, и что гиппокамп не требуется для воспроизведения следов отдаленной памяти. Последнее было подтверждено в нескольких случаях амнестических пациентов [Bayley et al 2003], но не всегда подтверждается в опытах на крысах [Squire et al 2004, Clark et al 2005a, 2005b], а также и на здоровых людях (см., напр., **эффект независимости от давности** в следующем разделе). Тем не менее, эта теория утверждает, что способна в принципе объяснить следующее наиболее загадочное свойство памяти [Squire & Alvarez 1995, Squire et al 2001].

Эффект ретроградной амнезии (РА). При повреждении гиппокампальной системы человека и связанных с ней неокортикальных структур вследствие травмы, хирургической операции, нейродегенерации или применения амнестических агентов, утрачивается память на события, предшествовавшие повреждению. При этом временной ход потери памяти, устанавливаемой с помощью специальных тестов, имеет один из следующих типов:

- *Градиент РА* возникает в значительном числе случаев РА и характеризуется тем, что больше утрачиваются следы непосредственно предшествовавшие повреждению гиппокампа, чем более ранние следы [Squire & Alvarez 1995, Fujii et al 2000, Nadel & Bohbot 2001, Chan et al 2002, Anagnostaras 2002, Brown 2002], причем для крыс — даже в случае полных перерезок гиппокампа [Winocur et al 2001, Clark et al 2002].
- *Обратный градиент РА* возникает у пациентов с семантической деменцией и характеризуется тем, что недавняя персональная память сравнительно сохранна, в то время, как более ранняя автобиографическая память утрачивается [Graham & Hodges 1997, Kopelman 2002, Piolino et al 2003, Nestor et al 2002].
- *Плоская РА* возникает при сильных повреждениях гиппокампа, при которых неспособность пациентов воспроизвести информацию, полученную до повреждения, охватывает почти всю прошлую жизнь пациента [Cipolotti et al 2001, Fujii et al 2000, Spiers et al 2001]. Аналогичные результаты получены на крысах (см. [Martin et al 2005] и ссылки в нем).
- *Напоминание*. Применение амнестических агентов (для животных — электрический удар, гипотермия, торможение синтеза протеинов, селективное поражение гиппокампа) вскоре после реактивации старых следов путем напоминания условий существовавших при обучении, вызывает РА этих следов независимо от их возраста, причем без напоминания РА не возникает [Miller & Matzel 2000, Millin et al 2001, Riccio et al 2002].

Стандартная Теория объясняет все эти случаи, кроме *плоской РА* и *напоминания*, тем, что амнестический агент подействовал на пациента до или после завершения консолидации следов, так что прерывание консолидации на разных фазах и создает различную степень повреждения памяти. Одна из фундаментальных проблем такого объяснения состоит в том, что существование обширной РА, охватывающей иногда несколько десятилетий [Brown 2002, Fujii et al 2000], вынуждает считать, что физиологическая консолидация тоже должна продолжаться очень долго [Kopelman 2002], что в свою очередь поднимает трудный вопрос [Nadel & Moscovitch 1997]: «Зачем 25 лет консолидации?», т. е. вопрос о биологической целесообразности такой долговременной консолидации.

Другая проблема возникает при интерпретации плоской РА [Fujii et al 2000, Nadel & Bohbot 2001, Anagnostaras et al 2002], поскольку этот случай, по-видимому, свидетельствует о том, что гиппокамп необходим все время, пока существуют следы памяти, в то время как Стандартная Теория *предсказывает*, что гиппокамп вовлечен в консолидацию лишь ограниченное время, а случай плоской РА пытается объяснить возможными повреждениями либо парагиппокампа, либо других структур вне МТЛ. Но тщательные исследования свидетельствуют против этой возможности. Так, в работах [Cipolotti et al 2001, Chan et al 2002] показано, что плоская РА возникает при изолированных перерезках гиппокампа, при полной сохранности неокортикальных структур. Фактически случай плоской РА фальсифицирует Стандартную Теорию, т.е. дает основание ее отвергнуть [Meeter & Murre 2004].

Еще одна трудность состоит в том, что эта теория *предсказывает* при поражении гиппокампа эквивалентное поражение эпизодической и семантической памяти в РА [Squire & Zola 1998, Squire et al 2004], что находит подтверждение в некоторых данных [Manns et al 2003], в то время как многие другие данные это не подтверждают (см. **эффект диссоциации** в следующем разделе).

Наконец, самая серьезная, на наш взгляд, трудность состоит в том, что во многих случаях динамика в гиппокампе и неокортексе, вопреки допущению 3, имеет при обучении не сильно различающийся, но сходный временной масштаб [Zeineh et al 2003, Maviel et al 2004, Dash et al 2004] и установление представительства обучающего события в неокортексе происходит в течение 0,5 сек. [Miller & Matzel 2000]. Это в корне подрывает идею буферной памяти в гиппокампе.

Кроме этих основных проблем, которые сторонники Стандартной Теории не признают или дают свою альтернативную интерпретацию соответствующих данных, есть ряд проблем, которые они признают, например, проблема большой модельной сети [Alvarez & Squire 1994; Meeter & Murre 2004], аналогичная проблеме комбинаторного взрыва [Malsburg 1995, Игумен Феофан 2005], или проблема реконсолидации [Meeter & Murre 2004], аналогичная проблеме феномена *напоминания* (см. **эффект ретроградной амнезии**), т.е. неспособность объяснить, почему после завершения консолидации память снова становится зависимой от гиппокампа при напоминании части условий, существовавших при обучении [Fujii et al 2000, Nadel & Bohbot 2001, Riccio et al 2003].

На наш взгляд все эти проблемы возникают из-за того, что Стандартная Теория чрезмерно упростила представление процесса консолидации, определив его как процесс байндинга, посредством которого кортикальная память, постепенно усиливая свои связи, становится независимой от гиппокампальной области (см. [Squire & Alvarez 1995]). На самом деле процесс консолидации гораздо более сложен и труден для понимания, как об этом свидетельствуют приведенные ниже данные.

Эффект консолидации. Он проявляется в следующих свойствах.

- *Интерференция.* Память о недавно выученной информации разрушается при заучивании другой новой информации или применении электрического болевого раздражения и других амнестических агентов после начального обучения, но она становится более устойчивой к разрушению при увеличении времени до нового обучения или применения амнестического воздействия. При этом активация амигдалы и других областей, связанных с эмоциональным эраузалом, играют модулирующую роль в консолидации, в то время как гиппокамп и центральная холинергическая система играют критически важную роль в консолидации [McGaugh 2000, Power et al 2003, Hasselmo & McGaughy 2004].
- *Избирательность.* Клетки места поля CA1 гиппокампа мутантных мышей, у которых удалены NMDA-рецепторы в поле CA3, имеют большие размеры полей места в новой ситуации (у мутантов ухудшается пространственная избирательность) по сравнению с немутантным контролем, но имеют нормальные размеры полей места в знакомой ситуации, причем нормализация наступает спустя одни сутки [Nakazawa et al 2003].
- *Постепенность.* Большинство клеток места поля CA1 гиппокампа нормальных крыс при побежке по хорошо знакомому треку за пищевой приманкой давали разряды на положительном пике гиппокампального тета-ритма, но в течение последующего за этим периода быстрого сна их средняя фаза менялась почти на 180 градусов по сравнению с фазой бодрствования. Если часть трека была знакомой, а часть новой, и крыса бегала по такому треку в течение 7 дней, то фаза активности в быстром сне убывала значительно больше по сравнению с бодрствованием и менялась *постепенно* от нуля до 180 градусов [Poe et al 2000].

- *Ассоциативность*. При сочетании условного стимула (звука определенной частоты) с безусловным стимулом (электрическим болевым раздражением или раздражением базального ядра), условный рефлекс у морской свинки (частота дыхания или сердцебиения) без дополнительного обучения усиливается по амплитуде и по частотной избирательности в течение от одного часа до трех дней, в зависимости от величины частотной расстройки условного звукового сигнала по отношению к собственной (лучшей) частоте нейронов слуховой коры, причем собственная частота нейронов изменяется в сторону частоты условного стимула. Выработанный условный рефлекс сохраняется по крайней мере в течение 10 дней. Автор считает, что это — первое прямое наблюдение долговременной консолидации памяти [Weinberger 2003, 2004].

В заключение этого раздела отметим, что некоторые из указанных выше проблем разные авторы пытались разрешить с помощью различных модификаций Стандартной Теории [Nadel & Moscovitch 1997, Meeter & Murre 2005, Wiltgen et al 2004, Wittenberg & Tsien 2002, Shimizu et al 2000], но все они исходили из того, что в гиппокампе есть долговременная или промежуточная память. В следующем разделе мы подробно рассмотрим наиболее существенную из этих модификаций и покажем, что на этом пути нет удовлетворительного решения основных проблем Стандартной Теории.

Теория Множественных Следов

Основные допущения этой теории следующие [Nadel & Moscovitch 1997, Fujii et al 2000].

1. Всякая информация, которая входит во внимание и сознательно воспринимается, быстро и автоматически создает в гиппокампе распределенные байндинг-коды, которые используются в процессе интеграции свойств в коре.
2. Полный ансамбль этих байндинг-кодов, совместно со следами, распределенными в ассоциативных областях, составляют след памяти специфических событий.
3. Байндинг-коды в гиппокампе служат как указатели или индексы места нейронов в ассоциативной коре или как коды пространственного контекста событий.

4. Каждая реактивация памяти в процессе считывания автоматически создает новые байндинг-коды в гиппокампе в новом нейронном и экспериментальном контексте.
5. Входная информация будет либо реактивирована и усилена при повторении либо потеряна, если повторение редкое. Чем старше память, тем больше кодов накапливается в гиппокампе и в ассоциативной коре, и тем устойчивее они при повреждении.

Эта теория возникла как альтернатива к Стандартной Теории для устранения в основном двух ее недостатков [Nadel & Moscovitch 1997]: 1) биологически неоправданно длительного переноса следов в течение почти всей жизни из гиппокампа в неокортекс в процессе консолидации; 2) отсутствие объяснения двух диссоциаций: эпизодической и семантической памяти, а также ретроградной амнезии (РА) и антероградной амнезии. Первый недостаток теоретически устраняется тем, что кортико-гиппокампальный комплекс обеспечивает байндинг любых элементов памяти в течении короткого периода консолидации, длящегося секунды, минуты, но не более нескольких дней [Moscovitch & Nadel, 1998, Fujii et al 2000]. При этом градиент РА объясняется тем, что старые следы, множественно представленные в гиппокампе, более устойчивы к повреждениям, чем новые [Nadel & Bohbot 2001]. Плоская РА, т.е. РА без временного градиента, *предсказывается* теорией как случай полного поражения гиппокампа [Fujii et al 2000, Nadel & Moscovitch 1997], что и было подтверждено последующими экспериментами [Cipolotti et al 2001].

Второй недостаток Стандартной Теории тоже как будто устраняется как следствие описанных выше допущений 1-5 и естественной малой повторяемостью эпизодической информации по сравнению с семантической информацией, приводящей, как доказывают [Rosenbaum et al 2001], к большей устойчивости семантических следов при разрушении гиппокампа по сравнению с эпизодическими следами и, наоборот, к постоянной необходимости гиппокампа для записи и воспроизведения редкой и однократной эпизодической информации. Последнее неоднократно проверялось и было подтверждено с помощью fMRI, мы этот факт ниже отметим как характеристическое свойство этой теории.

Эффект независимости от давности. Величина fMRI активации гиппокампа при его сканировании и одновременном воспоминании прошлых эпизодических и автобиографических событий здоровых нормальных лю-

дей в большинстве случаев не зависит от давности воспоминаемых событий, даже если они происходили 20–45 лет назад [Nadel et al 2000, Ryan et al 2001, Mayes et al 2000, Maguire et al 2001, Piolino et al 2002, Gilboa et al 2004, Bernard et al 2004, Douville et al 2005]. Вместе с тем бывают случаи как уменьшения активации [Haist et al 2001, Piefke et al 2003, Niki & Luo 2002], так и увеличения PET-активации [Piolino et al 2004], и даже есть случай, когда правый гиппокамп показывает уменьшение активности с возрастом памяти, а левый неизменно активен в течение всей жизни [Maguire & Frith 2003]; похожий случай описан также в работе [Douville et al 2005].

Независимость активации гиппокампа от возраста памяти авторы этой теории интерпретируют в пользу накопления и хранения байбиндиг-кодов долговременной эпизодической памяти в гиппокампе или по крайней мере в гиппокампальном комплексе, с помощью которых воспроизводится эта память в ассоциативной коре [Moscovitch & Nadel 1998, Nadel & Moscovitch 2001, Nadel & Bohbot 2001]. Что касается места хранения семантической информации, то обычно его помещают вне гиппокампа в различные области мозга, в зависимости от типа информации [Maguire & Frith, 2004], главным образом в левую височную кору [Nestor et al 2002, Kopelman & Kapur 2001, Martin & Chao 2001, Schmolck et al 2002]. В дискуссиях сторонники этой теории часто высказывают мнение, что для воспроизведения семантической информации гиппокамп не требуется [см., напр., Maguire et al 2000], но он требуется, может быть, лишь для ее записи [Miyashita 2004]. На самом деле, ситуация более сложная, как видно из следующего эффекта.

Эффект диссоциации. При повреждении гиппокампа человека поражается как эпизодическая, так и семантическая память [Holdstock et al 2002, Bayley & Squire 2002, 2005, Squire & Zola 1998, Manns et al 2003]. Однако чаще и больше поражается эпизодическая память, например, при двустороннем повреждении гиппокампа [Mishkin et al 1997, Spiers et al 2001], а также у пациентов с болезнью Альцгеймера [Chan et al 2001], а также у здоровых людей при естественном старении [Levine et al 2002, Piolino et al 2002]. Вместе с тем существуют данные о том, что иногда селективно поражается либо эпизодическая память [Levine et al 1998, McKenna & Gerhand 2002, Vargha-Khadem et al 1997, Verfaellie et al 2000, Rosenbaum et al 2005], либо (при поражении в левом полушарии) семантическая память [Grossi et al 1988, Graham et al 2000, Murre et al 2001].

Ограничения и недостатки. Среди них на первом месте стоит тот факт, что полные перерезки или деактивация гиппокампа, вопреки *предсказанию* теории, могут приводить к градиенту ретроградной амензии [см. напр. Winocur et al 2001]. Уже по этой причине данная теория по мнению некоторых аналитиков [Meeter & Murre, 2004] должна быть отвергнута и, значит, должна быть отвергнута ее главная идея о постоянном хранении байндинг-кодов в гиппокампе. Об этом же, по-видимому, свидетельствует факт отсутствия корреляции объема гиппокампа и степени потерь памяти [Kopelman et al 2003], хотя объем всей MTL имеет такую корреляцию [Gilboa et al 2005].

На втором месте стоит неудачная попытка объяснить диссоциацию эпизодической и семантической памяти с помощью различной степени накопления соответствующих следов в гиппокампе: семантическая память в процессе консолидации должна стать независимой от гиппокампа [Nadel et al 2000], и в тоже время она, как часто повторяющаяся, имеет в нем несравненно больше байндинг-кодов, чем эпизодическая память. Даже если допустить, что такое семантическое насыщение каким-то образом отключает гиппокамп от неокортекса, все же необходимо показать, каким образом чрезмерное накопление старых семантических следов не срывает накопление и консолидацию новых, особенно эпизодических следов, поскольку, как показывают оценки [Wittenberg et al 2002, p. 645] емкость памяти гиппокампа, выраженная в количестве его пирамидных нейронов, весьма ограничена и перегрузка неизбежна. Попытку авторов Теории Множественных Следов обойти эту трудность путем дополнительного искусственного (ad hoc) предположения о том, что число следов максимального возраста ограничено [Nadel et al 2000] или, что тоже, что время реактивации следов в гиппокампе ограничено, можно считать признанием неудачи теории в главном ее пункте. Действительно, по справедливому замечанию [Meeter & Murre, 2004] теперь вместо прежнего вопроса «Зачем 25 лет консолидации?» возникает вопрос «Зачем 25 лет реактивации?»

На третьем месте стоит неспособность теории объяснить сосуществование сильной АА с кратковременной РА [Kopelman & Karig 2001], а также экстенсивной РА и слабой АА [Fujii et al 2000], не говоря уже о других важных случаях, описанных ниже, без которых нельзя понять механизм долговременной памяти.

Эффект антероградной амнезии. При двухстороннем повреждении гиппокампа человека в следствие травмы или в результате хирургической операции в большинстве случаев наблюдается явление антероградной амнезии (АА), состоящее в том, что при сохранении кратковременной памяти и внимания имеет место полная неспособность фиксировать новую информации, т. е. наблюдается почти полная утрата памяти на новые сообщения и события, происшедшие после такого повреждения. При этом частично теряется память на все события, происшедшие до повреждения (РА). В литературе описаны следующие частные случаи соотношений АА и РА:

- *Положительная корреляция* [Squire & Alvarez 1995, Clark et al 2002]: чем больше АА, тем экстенсивнее РА.
- *Диспропорциональность*: сильная АА сочетается с кратковременной РА [Nadel & Moscovitch 1997, Kopelman & Kapur 2001, Kopelman 2002]; новые ассоциации диспропорционально повреждаются по сравнению с памятью одиночных предметов [Giovannella et al 2003].
- *Фокальная РА (FRA)*: сильная РА и почти полное отсутствие АА [Sellal et al 2002, Manning 2002, Wheeler & McMillan 2001, Fujii et al 2000, Evans et al 2003, Kopelman 2002]; чаще всего эпизодическая РА больше семантической РА, но бывает и «чистые» варианты [Wheeler & McMillan 2001].
- *Временная общая амнезия (TGA)*: после небольшой травмы или эмоционального стресса быстро исчезает АА, остается РА, но скоро (через сутки или месяцы) исчезают обе. Бывает и обратная картина: сначала быстро исчезает РА и затем более постепенно АА [Guillery-Girard et al 2004, Kapur et al 1998], причем особенно страдает эпизодическая память, а восстанавливается раньше семантическая память.

В заключение раздела отметим, что Теория Множественных Следов, предположив существование постоянной памяти в гиппокампе, не только не разрешила основные проблемы Стандартной Теории, но их усугубила, причем три главных недостатка Теории Множественных Следов сохраняются и во всех других модификациях Стандартной Теории, в которых предполагается, что гиппокамп — постоянное место хранения памятных следов [Wiltgen et al 2004, Wittenberg & Tsien 2002, Shimizu et al 2000, Morris et al 2003]. Обе теории явно фальсифицированы, но пока не отвергаются за счет принятия либо дополнительных случайных (ad hoc) предположений, либо путем игнорирования противоречащих фактов. Обе теории без отказа от предположения о памяти в гиппокампе, примирить невозможно, их можно

только одновременно отвергнуть, что уже сделали некоторые исследователи на основании своих результатов [см., напр., Evans et al 2003, Korelman et al 2003], хотя и работы по синтезу их идей продолжаются (см., напр., [Morris et al 2003]).

Теория Тета-Регулируемого Внимания

На основе анализа мультисенсорной информации морфологических подразделов гиппокампальной системы животных с помощью экстраклеточной регистрации О. С. Виноградова [Vinogradova, 2001] пришла к следующим выводам, которые мы принимаем как основные положения или допущения Теории Тета-Регулируемого Внимания:

1. Гиппокамп активно участвует в двух морфофункциональных круговых лимбических подсистемах: регуляторной, основанной на поле СА3, и информационной, основанной на поле СА1, которые совместно выполняют функции внимания и начальной стадии фиксации памятных следов.
2. При этом поле СА3 выполняет сравнительно простую компараторную функцию сличения (match-mismatch) текущей и следовой информации, появляющейся соответственно на двух его входах — ретикуло-септальном и кортикальном — и выдачи сигнала рассогласования состояний этих входов на подкорковые структуры, управляющие эраузalom — общим неспецифическим возбуждением мозга, приводящим его в активное состояние, оптимальное для ориентирования и обработки информации. При постоянных условиях окружающей среды поле СА3 поддерживает тормозный контроль ретикулярной формации.
3. В период рассогласования входов, когда этот тормозный контроль снимается, формируется сначала ориентировочный рефлекс, общее неспецифическое возбуждение с поведенческими проявлениями готовности внимания, затем селективное внимание и, наконец, осуществляется начальная фиксация памяти о текущем раздражителе.
4. Когда рассогласование двух входов исчезает, т. е. когда отсутствующий вначале кортикальный сигнал появляется на входе гиппокампа с некоторой задержкой относительно ретикуло-септального, высокий эраузал от ретикулярной формации снижается до фонового уровня, и вся система приходит в исходное состояние, ожидая новый стимул.

5. Всякий новый стимул, способный запустить тета-ритмическую активность медиального септума, вызывает тормозные реакции в большинстве пирамидных нейронов поля СА3 (inhibitory reset) и тем самым снимает тормозный контроль с ретикулярной формации. Состояние новизны, соответствующее приходу тета-модулированного сигнала на ретикуло-септальный вход поля СА3, длится до тех пор, пока из коры не придет после соответствующей задержки сигнал, подтверждающий, что фиксация следов закончена.
6. Когда тета-ритм запущен стимулом, все другие сигналы, появляющиеся на его фоне, не могут перезапустить (reset) текущий ритмический процесс и не получают доступа к механизму обработки в гиппокампе. Если известный стимул появляется спустя некоторое время, то начальный процесс с реакциями нейронов поля СА3, эраузalom и ориентировочным рефлексом может появиться снова. Однако он будет немедленно остановлен, потому что соответствующий кортикальный сигнал уже сформирован и быстро появится на входе системы.
7. Информационная подсистема на основе поля СА1 выполняет в состоянии новизны функцию интегратора и линии задержки, предотвращая преждевременную фиксацию следов от случайных, маловероятных и неинтересных сигналов. Отклики в выходных отделах этой подсистемы рассматриваются как окончательный сигнал для фиксации информации в соответствующих областях неокортекса.

Основное предсказание или, скорее, следствие теории состоит в следующем. Гиппокампальная система абсолютно необходима: для организации селективного восприятия, для подавления мешающей посторонней информации, для привыкания к неизменным сигналам, для детекции новых и значительных изменений, которые должны быть записаны в памяти [Vinogradova 2001, p. 596].

Ниже приведены два характеристических эффекта этой теории.

Эффект новизны. Нейроны поля СА3 гиппокампа отвечают практически на любой раздражитель длительными тоническими реакциями, если он является новым, при этом входной сигнал появляется вначале на ретикуло-септальном входе и лишь после некоторой задержки он появляется на кортикальном входе, после чего этот сигнал теряет качество новизны. Реакции большинства пирамидных нейронов поля СА3 во время действия нового стимула тормозные, соответствующие по времени синхронному запуску

тета-колебаний в медиальном септум [Vinogradova, 2001]. В литературе описаны следующие аспекты этого эффекта.

- *Распределенность.* Кроме гиппокампа чувствительные к новизне нейроны имеются в структурах лимбической системы и ассоциативной коры [Yamaguchi et al 2004, Knight 1996, Habib et al 2003].
- *Колокализация.* Области префронтальной и височной коры, чувствительные к новизне, предсказывают (по данным fMRI) последующее запоминание соответствующих раздражителей, указывая на колокализацию новизны и памяти в этих корковых структурах [Kirchhoff et al, 2000].
- *Гиппокампальность.* Две крупно-масштабные неперекрывающиеся и когерентно работающие нейронные сети активированы при обработке отдельно нового и соответственно знакомого стимула. Гиппокамп участвует в обеих как единственная их общая часть [Habib et al, 2003].

Эффект привыкания. При повторении новых раздражителей пирамидные нейроны поля СА3 постепенно привыкают к ним, ослабляя тормозные реакции и восстанавливая начальную высокую фоновую активность. Целостность обоих входов в гиппокамп (кортикального и ретикуло-септального) необходима для постепенного привыкания сенсорных ответов. При повторном применении раздражителя или при стимуляции зубчатой фасции происходит устойчивая (до 12 часов и более) долговременная потенциация (LTP) ответов пирамидных нейронов в некоторой зоне поля СА3, которая блокирует реакции нейронов на новизну. За пределами этой зоны сохраняется нормальная реактивность к сенсорным сигналам [Vinogradova 2001, Виноградова и Дудаева 1972, Брагин и др. 1976].

- *Восстановление (dehabituation).* Угасшие реакции восстанавливаются вновь при любых изменениях параметров сигнала либо при краткой электрической стимуляции ретикулярной формации [Vinogradova 2001, Виноградова и Дудаева 1972, Брагин и др. 1976].
- *Колокализация.* Кроме гиппокампа, по данным fMRI, привыкание в течение нескольких первых стимулов есть в тех же областях мозга, где идут реакции на новизну и процессы запоминания (двухсторонняя медиальная и нижне-височная кора, правая амигдала, префронтальная кора) [Fischer et al 2003, Yamaguchi et al 2004].
- *Специфичность.* При повторении стимула реакции долго не угасают в «стержневой» системе применяемого стимула, например в физи-

формной (fusiform) и цингулятной коре при восприятии со вниманием геометрических фигур или человеческих лиц [Yamaguchi et al 2004, Haxby et al 2000].

- *Быстрое привыкание.* Только в гиппокампе и в префронтальной коре наблюдалось сравнительно быстрое затухание реакции на новизну, причем затухание было сравнимо по величине как при наличии внимания к новым стимулам, так и без него [Yamaguchi et al 2004]. Последнее, по мнению авторов, подтверждает предположение о ключевой роли гиппокампа и префронтальной коры в быстром и автоматическом обнаружении новизны и привыкании к неожиданным внешним событиям.
- *Десинхронизация.* Успешное запоминание при обучении сопровождается начальным повышением гамма-синхронизации с последующей десинхронизацией между гиппокампом и энторинальной корой [Fell et al 2001]. Аналогичное усиление синхронизации в неокортексе, а затем активной десинхронизации в диапазоне гамма-ритма при опознании объекта зафиксировано в работе [Rodriguez et al 1999], а в диапазоне тета-ритма для более сложной задачи опознания — в работе [Raghavachari et al 2001].

Основное возражение против отсутствия памяти в гиппокампе и, значит, против Теории Тета-Регулируемого Внимания, состоит в том, что должно быть предложено объяснение, почему гиппокамп критически важен для считывания, если следы всегда накапливаются вне гиппокампа [Nadel & Bohbot 2001]. Этот вопрос подробно обсуждается в следующем разделе, но краткий ответ на него состоит в том, что воспроизведение записанной в неокортексе информации осуществляется с помощью синхронизации тетаритмических колебаний гиппокампа и неокортекса, однозначно задающих местоположение соответствующих памятных следов, причем без всякой необходимости накапливать в гиппокампе кортикальные метки этих мест.

Другое возможное возражение против отсутствия памяти в гиппокампе состоит в том, что гиппокамп после начальной фиксации следов участвует в их консолидации, длительность которой простирается от нескольких секунд до нескольких дней, так что без какой-то памяти в гиппокампе консолидация невозможна. Краткий ответ состоит в том, что процесс консолидации может быть либо простым переходом в неактивное состояние, либо усилением следов. Последнее, как будет показано в следующем разделе, происходит путем синхронизации и рекрутирования новых кортикальных

ТАБЛИЦА 1. Критичность (+/·) и нейронное объяснение (·/+) эффектов для каждой теории: ТКК — Теория Когнитивной Карты, СТ — Стандартная Теория, ТМС — Теория Множественных Следов, ТТВ — Теория Тета-Регулируемого Внимания. Объяснения в тексте.

Эффект	ТКК	СТ	ТМС	ТТВ
клетки места	+/·	-/-	-/-	-/+
точки зрения	+/·	-/-	-/-	-/+
ретроградной амнезии	-/-	+/-	+/-	-/+
антероградной амнезии	-/-	+/-	+/-	-/+
консолидации	-/-	+/-	+/-	-/+
независимости от давности	-/-	+/-	+/-	-/+
диссоциации	-/-	+/-	+/-	-/+
новизны	-/-	-/-	-/-	+/+
привыкания	-/-	-/-	-/-	+/+

областей при циклическом воспроизведении первичных следов, поэтому роль гиппокампа в консолидации сводится, грубо говоря, к участию в воспроизведении первичных следов, но не их хранению. Таким образом, ответ на второе возражение, по существу, сводится к ответу на первое возражение.

В заключение этого раздела рассмотрим Табл. 1. В ней отображено два свойства каждой теории: критичность (+) или некритичность (-) каждого эффекта и через косую черту (/) — наличие полного (+) или частично (-) объяснения каждого эффекта в терминах нейронной модели. Например, две нижние строки таблицы показывают, что только для Теории Тета-Регулируемого Внимания эффекты новизны и привыкания, во-первых, являются критическими и, во-вторых, имеют полное нейронное объяснение, что отображено знаком (+/+). Другие эффекты не являются для этой теории критическими, но она, как будет показано в следующем разделе, может их полностью объяснить, что отображено в последнем столбце таблице знаком (-/+). К сожалению, в этой таблице не удалось отобразить положительный вклад остальных теорий, но это будет сделано в разделе «Попытка примирения конкурирующих теорий» (см. с. 213).

«Нейролокатор» — унифицирующая модель внимания и памяти

Доминантная архитектура и блок-схема «Нейролокатора». Она отличается от обычной коннекционистской архитектуры в каждом из пяти указанных ниже признаков.

1. Функциональной единицей является не одиночный нейрон, а элементарный кортикальный осциллятор (например, микроколонка), т. е. сравнительно небольшая сеть, названная «базовой нейронной моделью» и состоящая из синаптически связанных пороговых нейронов с экспоненциальным затуханием мембранного потенциала — как универсальный суб-модуль [Крюков 1991], в которую добавлен тормозный интернейрон, чтобы в ней могли возникнуть колебания за счет возвратного торможения.
2. Информация записывается в большой системе таких пространственно распределенных первоначально независимых элементарных кортикальных осцилляторов, оптимальная лабильность или натуральная частота которых модифицируется в процессе обучения и консолидации в соответствии с данными Weinberger (2003, 2004). Другими словами, это — пространственно-временное ассоциативное кодирование изолабильными ансамблями осцилляторов, у которых «собственные» частоты различаются, скажем, на 10–15%, но которые способны к синхронизации на общей частоте с усвоением (запоминанием) этой частоты.
3. Упрощенная доминантная архитектура, представляется в виде системы из группы независимых периферических осцилляторов и одного центрального осциллятора, имеющего двусторонние связи с каждым из периферических (рис. 1).
4. Центральный осциллятор выполняет функции Центрального Управителя или «дирижера», способного изменять свою текущую частоту в некоторых пределах и вовлекать периферические осцилляторы в различные ансамбли на основе прямых (reset) и обратных (reply) связей с ними.
5. Появление внимания соответствует возникновению синхронных колебаний центрального осциллятора и небольшого подмножества *параллельно* работающих периферических осцилляторов. Переключение внимания с одной группы осцилляторов на другую осуществляет-

ся *последовательно*, путем изменения частоты центрального осциллятора. Обработка информации, таким образом, *параллельно-последовательного типа*.




Рис. 1. Упрощенная доминантная архитектура
Здесь: СО — септальный осциллятор, КО — кортикальный осциллятор.

В целом, сравнивая описанную архитектуру с коннекционистской, замечаем некоторое формальное их сходство, выражающееся в одинаковом составе компонентов-аттракторов и в возможности их параллельной работы. Однако различие между ними принципиальное, качественное и оно примерно соответствует различию между проволочным телеграфом и радиосвязью. В доминантной архитектуре все связи между компонентами (осцилляторами) — функционально-синхронные, а не синаптические. Поэтому здесь отсутствуют такие известные проблемы коннекционизма, как комбинаторный взрыв, катастрофа переполнения, катастрофа объединения [Malsburg 1995] и катастрофическая интерференция [McClelland et al 1995]. Другое важное отличие в том, что информация хранится не в синаптических связях, а в пространственно-временных изолабельных конфигурациях или ансамблях осцилляторов с близкими собственными частотами, причем обучение не локальное (не-хеббовское), а центрально-управляемое, как это видно из допущения 6 «Нейролокатора» (см. ниже).

Система внимания и памяти, построенная на основе Теории Тета-Регулируемого Внимания, во многих отношениях подобна радарной системе,

причем как на поведенческом, так и на нейронном уровне. Краткий обзор применения этой аналогии в нейропсихологии приведен в работе [Kryukov et al 1990]. Здесь мы отметим, что радарная аналогия учитывает также следующие свойства долговременной памяти: **(а)** параллельное считывание на основе наиболее легкого доступа; **(б)** изменяющаяся во времени и в пространстве мультимодальная ассоциативность различных объектов и их свойств; **(в)** простое и быстрое сканирование памяти путем изменения частоты сканирования; **(г)** простая автоматическая связь с кратковременной памятью, которая является активированным подмножеством долговременной памяти.

Упрощенная блок-схема обычной радарной следящей системы изображена на рис. 2А. Она состоит из пяти стандартных узлов: управляемого генератора, фазового детектора, фильтра низких частот, приемника-смесителя и сумматора. Ее нейронная «реализация» изображена на рис. 2С. При этом мы опираемся на хорошо установленные функции различных частей лимбической системы [Vinogradova 1975, 2001]: гиппокампальная зубчатая фасция (FD) — это смеситель и интегратор специфических входов; медиальный септум (Sm) — это центральный осциллятор или синхронизатор не только для поля САЗ гиппокампма, но и для многих других структур мозга; латеральный септум (Sl) — это выходной смеситель САЗ полей отдельных ламелл, т. е. параллельных структурно-функциональных почти независимых секций гиппокампальной формации [Witter et al 2000], соответствующих различным независимым группам корковых осцилляторов. Все эти структуры согласно [Vinogradova 1975, 2001] соединены между собой, образуя два замкнутых контура, как показано на рис. 2В. Первый контур — информационный. Он включает в себя гиппокампальное поле СА1, передний таламус АТ), неокортекс (NC) и другие структуры, сохраняющие, по крайней мере частично, сигнальную специфичность. Этот контур активен при начальной фиксации памяти в неокортексе, а также при обработке информации «на линии», например обеспечивая длительную задержку или рециркуляцию сигналов для *рабочей памяти*. Второй контур — неспецифическая регуляторная петля, включающая в себя поле САЗ, септум медиальный (Sm) и септум латеральный (Sl), мезенцефалическую ретикулярную формацию (mRF) и некоторые другие структуры, например амигдалу (Am), участвующую в эмоциональном и волевом управлении. Эта петля обеспечивает неспецифическую активацию мозга, регулируя эраузаль и одновременно автоматически устанавливая оптимальную частоту тета-ритма в соответствии с выполняемой задачей. Поскольку известно, что гиппо-

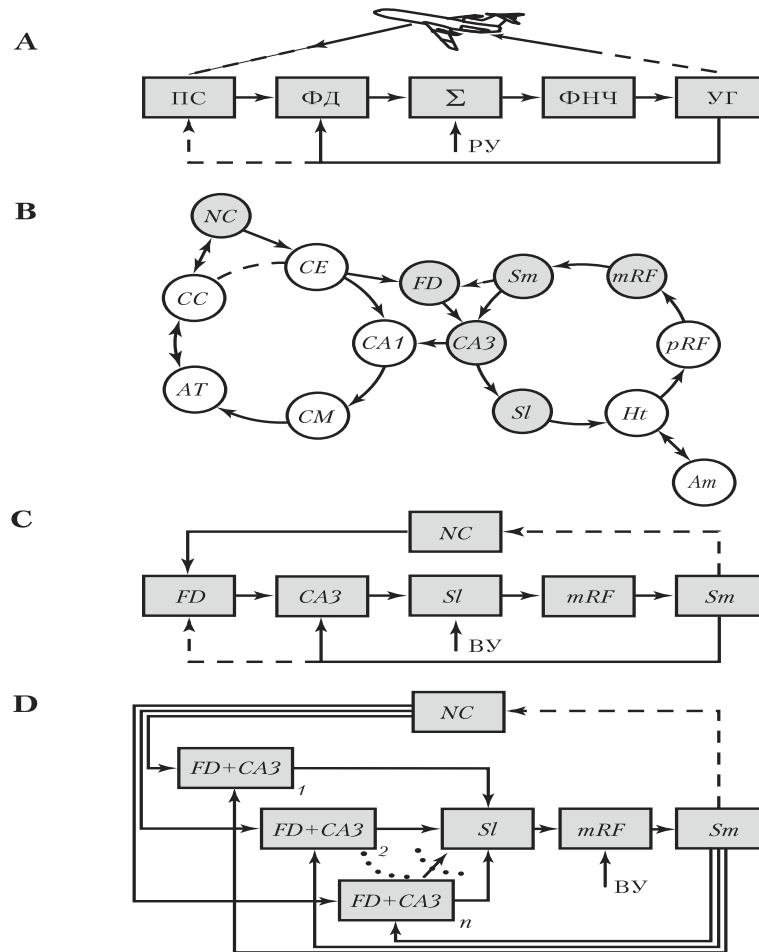


Рис. 2. Блок-схема радарной следящей системы (А), лимбической системы мозга (В), «Нейролокатора» (С) и «Нейролокатора» с учетом ламеллярности гиппокампа (D).

ПС — приемник-смеситель; ФД — фазовый детектор или компаратор; Σ — сумматор; ФНЧ — фильтр низких частот; УГ — управляемый генератор; РУ, ВУ — ручное и волевое управление; NC — неокортекс; FD — зубчатая фасция; CA₁, CA₂ — поля гиппокампа; Sm, Sl — медиальное и латеральное ядро септума; mRF и pRF — мезенцефалическое и пентобулбарная часть ретикулярной формации [Виноградова,1975].

камп тормозит активирующую ретикулярную формацию, то второй контур является фактически *петлей отрицательной обратной связи* как для регулирования эраузала в мозге, так и для регулирования частоты септального осциллятора. Обе петли имеют важное значение для нашей модели, но мы ограничимся минимальным вариантом, показанным тонировкой на рис. 2В, чтобы лучше уяснить себе ключевую роль септо-гиппокампальной системы для работы всего мозга. Для этого теперь необходимо напомнить описанные в работе [Игумен Феофан 2002] допущения минимальной модели в нейронных терминах и извлечь из этой модели ее основные свойства как системы автоматического регулирования.

Допущения «Нейролокатора». Они в основном повторяют допущения нашей более ранней модели «Нейролокатор» [Игумен Феофан 2002, Kryukov et al 1990] и состоят в следующем.

1. Системная модель «Нейролокатор» включает в себя шесть главных подсистем, показанных на рис. 2С. Каждая подсистема является небольшой модификацией базовой нейронной модели, описанной в работах [Игумен Феофан 2002; Kryukov et al 1990; Kryukov 1991].
2. Все корковые осцилляторы помимо неспецифических входов от mRF имеют сенсорные входы определенной модальности, являясь, таким образом, анализаторами свойств стимула (формы, цвета, яркости и т. п.) Их собственные частоты колебаний распределены равномерно в тета-гамма-частотном диапазоне, причем неспецифические входы от mRF в отсутствие специфических входов не вызывают колебаний, но лишь способствуют появлению этих колебаний, если соответствующие стимулы обеспечивают достаточный эраузала.
3. Фазовый детектор поля САЗ есть детектор совпадений (AND-gate) двух главных входов, септального и неокортикального. Их максимальное совместное действие на поле САЗ обозначим через коэффициент A , выражающий силу корреляционной связи этих входов, зависимость которой от сдвига во времени τ этих входов обозначим через $g(\tau)$.
4. Низкочастотный фильтр mRF характеризуется функцией передачи первого порядка $F(p) = K/(1 + Tp)$, где K — константа, T — постоянная времени, составляющая несколько сотен миллисекунд — в соответствии с объяснением инерционности, данным в работе [Игумен Феофан 2002].

5. Главное предположение модели состоит в том, что внимание может быть описано как глобальное, внезапно возникающее свойство системы при некотором значении эраузала, блок-схема которой представлена на рис. 2 С и 2 D и это свойство соответствует прерывистой (transient) фазовой синхронизации некоторого подмножества корковых осцилляторов на частоте септального осциллятора, в том числе по типу reset.
6. Когда число синхронизованных корковых осцилляторов в ансамбле превысит критическое значение, оптимальные лабильности этих осцилляторов уравниваются, т. е. те осцилляторы, которые усваивают общий ритм, постепенно в течение некоторого времени меняют «собственную» частоту, реализуя изолабильное кодирование. Память о стимуле, вызвавшем такую синхронизацию, стирается, если осцилляторы вскоре после этого вовлекаются в другие ансамбли, не успевая погасить эти колебания для перехода в долговременную память.

Основные свойства модели «Нейролокатор». В работе [Kryukov et al 1990] было показано, что модель «Нейролокатор» описывается следующей системой стохастических интегро-дифференциальных уравнений:

$$\frac{d\varphi_i}{dt} = \Lambda_{0i} - \left[\sum_{j=1}^n A_{0j} g_j(\varphi_j) + N_j(t) \right] F(p), \quad i = 1, \dots, n, \quad (1)$$

где φ_i — средняя разность фаз колебаний корковых осцилляторов и септального осциллятора, соответствующих i -й ламелле; Λ_{0i} — их частотная расстройка; A_{0i} — активность неокортикальных осцилляторов, соответствующих i -й ламелле; $g_i(\varphi)$ — нелинейная функция фазового дискриминатора, выражающая кросс-интенсивность двух его основных входов; $N_i(t)$ — «белый» шум i -й ламеллы; n — общее число ламелл; $F(p)$ — передаточная функция низкочастотного фильтра mRF (операторное умножение на $F(p)$ в правой части уравнения (1) означает операцию свертки с функцией $f(t)$, для которой $F(p)$ является изображением Лапласа, а коэффициенты A_{0i} и A связаны соотношением $A = \sum_{j=1}^n A_{0j}$).

Эта система будет использована для объяснения всех описанных в статье эффектов, однако мы начнем ее применение с очень простого частного случая, а именно без учета ламеллярности гиппокампа ($n = 1$), без шумов ($N_i(t) = 0$) и без фильтра ($F(p) = K$), когда она редуцируется к одному

нелинейному обыкновенному дифференциальному уравнению

$$\frac{d\varphi}{dt} = \Lambda_0 - AKg(\varphi), \quad (2)$$

где параметр AK пропорционален эраузале, а $g(\varphi)$ — взаимная интенсивность двух основных входов в гиппокамп, и поэтому не обязательно синусоидальная, а скорее S -образная функция, причем $g_{\min} > 0$ соответствует отсутствию взаимной зависимости двух входных потоков. В этих условиях для захвата внимания данным раздражителем необходимо выполнение неравенства

$$\frac{1}{g_{\max}} < \frac{AK}{\Lambda_0} < \frac{1}{g_{\min}}, \quad (3)$$

которое соответствует приведенному ниже свойству 1 модели «Нейролокатор». Другие свойства этой модели соответствуют известным свойствам стандартной фазо-частотной следящей системы [Линдсей 1978, Игумен Феофан 2004] и мы приведем их здесь без доказательства — для удобства ссылок при объяснении эффектов внимания и памяти.

1. Внимание невозможно как при низком эраузале ($AK/\Lambda_0 < 1/g_{\max}$), так и при слишком высоком эраузале ($AK/\Lambda_0 > 1/g_{\min}$).
2. Внимание возникает скачкообразно при возрастании эраузала ($AK/\Lambda_0 > 1/g_{\max}$) и проявляется как «выбор» одного из множества внешних или внутренних сигналов того сигнала, который в данный момент и «захватывает» управление «Нейролокатора».
3. Внимание контролируется изменением расстройки (Λ_0) как автоматически, так и волевым усилием. Существует режим, при котором i -я ламелла функционально отключается от системы (например, автоматически при высоком $A_{0i}K$).
4. Внимание унитарно, но при сравнительно невысоком эраузале AK оно делимо по правилу Миллера (7 ± 2) или по правилу Коуэна (4 ± 1). Другими словами, система способна следить по частоте и фазе одновременно сразу за 4–7 первоначально независимыми корковыми осцилляторами, которые совместно управляют септальным осциллятором.
5. Срыв внимания может быть внезапным (в результате действия шумов или синхронизации от другой группы корковых осцилляторов) или постепенным, в результате постепенного изменения параметров модели, например в привыкании.

6. «Сопряженное» торможение всех стимулов, не попавших в фокус внимания, осуществляется двумя механизмами: во-первых, за счет десинхронизации, во-вторых, за счет уменьшения эраузала, который согласно допущению 2 эффективен лишь для сигналов, попавших в фокус внимания.
7. Внимание возможно не только при одинаковых частотах септального и коркового осцилляторов (синхронизация 1:1), но и при различающихся частотах (синхронизация типа $p : q$). Можно показать, что при $p = 1$ наиболее устойчивая синхронизация для случая $g(\varphi) = \sin \varphi$ будет при $q = 4$ (например, синхронизация колебаний с частотами 10 Гц и 40 Гц не только возможна, но и может быть преобладающей).

В заключение этого раздела заметим, что модель «Нейролокатор» способна решать не только вопросы внимания, описанные в работе [Игумен Феофан 2002], но и вопросы памяти, описанные во Введении. Причина этого в том, что внимание и память представляют фактически единый процесс, и поэтому «Нейролокатор» дает основу для согласования и примирения различных конкурирующих теорий памяти, в которых внимание играет существенную роль. Что касается вычислительных возможностей модели, то они весьма обнадеживающие: 1) фактически неограниченное время хранения информации; 2) фактически неограниченная емкость схемы изолабельного кодирования; 3) высокая помехозащищенность системы фазо-частотного регулирования; 4) естественное обобщение на случай памяти временных последовательностей эпизодов; 5) простота алгоритмов для имитации различных нейропсихологических эффектов, перспективных для технического применения. Каждый из этих пунктов заслуживает отдельного обсуждения, но выходит за рамки данной работы.

Краткое объяснение основных эффектов

Наше объяснение приведенных в разделах Теория Когнитивной Карты, Стандартная Теория, Теория Множественных Следов и Теория Тета-Регулируемого Внимания (с. 174–188) эффектов основано на описанных выше свойствах модели «Нейролокатор». Эта модель, построенная в соответствии с основными допущениями Теории Тета-Регулируемого Внимания, математически представляет из себя систему стохастических интегро-дифференциальных уравнений (1). Эта система описывает динамику замкнутой многоконтурной следящей системы фазо-частотного регулирования,

хорошо известной в технике связи [Линдсей 1978], в частности в радиолокационных системах. Модель способна имитировать процессы внимания, поиска, захвата и сопровождения движущихся целей, а так же фиксацию памятных следов, как это описано в семи основных свойствах модели «Нейролокатор».

Процесс внимания начинается с ориентировочного рефлекса и с поиска соответствующего раздражителя в пространстве. Модельный поиск раздражителя, подобно поиску цели в радиолокаторе, состоит в первом приближении из двух стадий: стадии *синхронизации по частоте* и стадии *синхронизации по фазе*, являющиеся радиолокационными аналогами «захвата по частоте повторения» и «захвата по дальности». На первой стадии частота тета-ритма септального осциллятора внешней установкой задания, или изменением эмоционального эраузала быстро меняется во времени до тех пор, пока не будет совпадения с частотой основной группы неокортикальных осцилляторов места цели, находящихся в префронтальной и теменной коре. Эта стадия описывается первым слагаемым в правой части выражения (2) и соответствует наличию сигнала только на одном ретикуло-септальном входе в гиппокамп и отсутствию сигналов на его кортикальном входе. На второй, завершающей, стадии частота септального осциллятора почти не меняется, зато с помощью его «зондирующих» (reset) импульсов на эту частоту «затягиваются» частоты неокортикальных осцилляторов свойств искомой цели. Эта стадия определяется обоими слагаемыми в правой части уравнения (1) и, соответственно, сигналами на обоих входах гиппокампа.

Таким образом, процесс установления селективного внимания есть переходной процесс взаимной синхронизации септального тета-осциллятора и сравнительно небольшого подмножества неокортикальных тета- и гамма-осцилляторов, представляющих свойства данного раздражителя, и вообще говоря, он возможен без гиппокампа, т.е. без второй стадии, если есть reset. Но без этой стадии, т.е. при повреждении гиппокампа, невозможна нормальная, быстрая фиксация новой информации. Чтобы это пояснить, вначале рассмотрим подробнее условия захвата внимания данным раздражителем в нормальных условиях, а затем распространим их на случай патологии и перерезок.

Эффекты новизны и привыкания. В разделе «Нейролокатор» — унифицирующая модель внимания и памяти (см. с. 193) было показано, что

необходимым условием захвата внимания является выполнение неравенства (3), в котором в соответствии с допущениями Теории Тета-Регулируемого Внимания положим:

$$A = A_1 + A_2 + A_3, \quad (4)$$

где A_1 соответствует воздействию выхода информационной подсистемы на регуляционную подсистему, A_2 — воздействие неокортекса на регуляционную подсистему, A_3 — учитывает изменение структуры регуляционной подсистемы (см. ниже). В начальный момент после появления нового раздражителя $A_1 = A_2 = A_3 = 0$, до тех пор, пока $A_1 K$ не превысит нижний порог синхронизации, в соответствии с левым неравенством (3). После этого A_1 остается постоянным, а A_2 начинает довольно быстро возрастать при повторении нового раздражителя, в следствие фазо-частотной синхронизации кортикальных осцилляторов до тех пор, пока не будет достигнут верхний предел синхронизации, указанный в правой части неравенства (3). После этого начальный этап фиксации информации заканчивается десинхронизацией между гиппокампом и неокортексом, тета-ритм срывается, и система ожидает прихода сигналов новых раздражителей, в соответствии с Основным свойством 5 «Нейролокатора». Если после этого на входе сенсорной системы появляется тот же или уже знакомый раздражитель, то благодаря высокому значению A_2 , система быстро достигает верхнего порогового уровня и, после генерации краткой (фазической) реакции, приходит в исходное состояние ожидания нового раздражителя. Если на вход приходит новый раздражитель, то весь описанный выше процесс повторяется, сопровождаемый длительными (тоническими) реакциями как в самом гиппокампе, так и в неокортексе. Взаимные помехи от различных раздражителей устраняются согласно системе (1) тем, что их сигналы приходят в гиппокамп различными параллельными путями в различные ламеллы [Whitter et al 2000], причем долговременная потенциация (LTP) в зоне каждой ламеллы, блокирующая реакции нейронов на новизну [Vinogradova 2001, Виноградова и Дудаева 1972, Брагин и др. 1976], учитывается слагаемым A_3 в выражении (4), и тем увеличивается надежность отключения ламеллы, если она соответствует уже знакомому раздражителю, предотвращая наложение новых следов на старые. Потенциация кортикального входа эквивалентна знакомости (familiarity) стимула [Vinogradova 2001].

Наблюдаемая при успешном обучении синхронизация и последующая десинхронизация между энторинальной корой и гиппокампом [Fell et al

2001], также и аналогичные этому явления синхронизации и десинхронизации в диапазоне гамма- и тета-ритмов [Rodriguez et al 1999, Raghavachari et al 2001] есть динамическое проявление эффектов новизны и привыкания. Одновременная синхронизация в диапазоне тета- и гамма-ритмов следует из Основного свойства 7 «Нейролокатора» и является, мы считаем, важной компонентой механизма формирования декларативной памяти, существование которой предположено в работе [Fell et 2003].

Легко проверить, что приведенный выше механизм способен объяснить все свойства **эффектов новизны и привыкания**. Так, например, наиболее загадочное свойство *восстановления* становится менее загадочным, если заметить, что при изменении параметров сигнала меняется представляющая этот сигнал система кортикальных осцилляторов, так что *восстановление* означает не возобновление прежней угасшей реакции, а новую тоническую реакцию, соответствующую фактически новому сигналу и активации новой ламеллы. Почти очевидные свойства *распределенности, колокализации, гиппокампальности, специфичности и быстрого привыкания* однозначно свидетельствуют о том, что памятные следы формируются и фиксируются вне гиппокампа, а гиппокамп обеспечивает интеграцию этих следов в единую крупно-масштабную когерентно-работающую нейронную сеть [Habib et al 2003], и затем сам от нее быстро отключается [Yamaguchi et al 2004].

Заметим, что в модели «Нейролокатор» долговременная потенция (LTP) не является нейронным субстратом памяти, но играет вспомогательную роль отключения отдельных ламелл гиппокампа от неокортекса на время (минуты, часы), пока неокортикальная кратковременная память (синхронные колебания изолабильных осцилляторов) не перейдет в долговременную, неактивную стабильную форму «угасших» осцилляторов. Новый сигнал поступает в область другой ламеллы гиппокампа, не дожидаясь, пока затухнет LTP уже использованной ламеллы. Таким способом решается проблема защиты от интерференции и наложения старых и новых следов, катастрофически неразрешимая в коннекционистских моделях, в которых LTP используется для записи специфической информации. По этой же причине неспецифичности LTP в модели «Нейролокатор» нет проблем, возникающих из-за 5-дневного времени жизни синаптических NMDA рецепторов, препятствующих долговременному хранению специфической информации в синапсах [Shimizu et al 2000, Wittenberg & Tsien 2002].

Эффект ретроградной амнезии. Модель «Нейролокатор» объясняет *градиент PA* не консолидацией следов во времени, которая может быть кратковременной, но постепенным увеличением числа осцилляторов с близкими частотами и фазами колебаний, т. е. увеличением параметра A с возрастом памяти, поскольку каждое воспроизведение следов сопровождается их перезаписью в новых условиях. Такое возможно только в случае, когда частота реактивации осцилляторов выше частоты вовлечения этих осцилляторов в другие конфигурации, и следовательно, PA убывает с возрастом памяти, особенно для более часто повторяющейся семантической информации. В противном случае, особенно для редкой эпизодической информации, PA возрастает с возрастом памяти, объясняя, таким образом, *обратный градиент PA*.

Такое объяснение градиента PA напоминает объяснение Теории Множественных Следов за счет накопления многих дубликатов одних и тех же памятных следов, но имеет три существенных отличия от него. Во-первых, не требуется запоминание кортикального адреса этих следов в гиппокампе, поскольку автоматическая настройка частоты тета-ритма на собственную частоту доминантной группы неокортикальных осцилляторов автоматически возрождает всю пространственно-временную конфигурацию следа, если заданы ключевые свойства или какие-либо другие напоминания для поиска выученной конфигурации. Во-вторых, случай *плоской PA* на всю жизнь может быть объяснен не только полным разрушением гиппокампа, как это имеет место в Теории Множественных Следов, но и любым другим серьезным повреждением фазо-частотной следящей системы, например, перерезками основных входов в септо-гиппокампальную систему [Vinogradova 2001, Gaffan et al 2001]. В-третьих, *градиент PA* может быть объяснен в случае полного разрушения гиппокампа [Winocur et al 2001], поскольку синхронизация кортикальных осцилляторов идет не от гиппокампа, а от септального осциллятора, и хотя без гиппокампа нет быстрой автоматической настройки частоты, все-таки остается возможность медленного поиска и считывания старых следов, например, за счет обратной связи с неокортекса на септум через амигдалу (см. Рис. 2В). В-четвертых, *обратный градиент PA* может быть объяснен не только селективным поражением соответствующих кортикальных структур, характерных, например для семантической деменции, но и ухудшением синхронизации за счет постепенного устойчивого сдвига текущего эраузала (AK), например, при естественном старении, что делает отдаленную, и особенно эпизодическую память все более недоступной из-за постепенно возникающего диссоции-

рованного состояния эраузала. Это согласуется со многими возрастными диссоциациями, описанными, например, [Levine et al 2002].

Подобным же образом за счет ухудшения синхронизации объясняется феномен *напоминания*. Только здесь диссоциированное состояние эраузала, как основная причина РА, возникает не постепенно, как при старении памяти, а внезапно в результате специального амнестического воздействия на предварительно реактивированные старые следы. В результате происходит перезапись этих следов в новом контексте, и эти перезаписанные следы в прежних, нормальных условиях уже не воспроизводятся из-за диссоциации состояний и имеют все свойства РА. Без предварительной реактивации старых следов РА не возникает, так как эти следы находятся в неактивном состоянии. Таким образом модель «Нейролокатор» объясняет необычный и лишь недавно «узаконенный», хотя давно известный в литературе феномен *напоминания*, который без достаточных оснований теперь нередко называют реконсолидацией [Nader et al 2000, Sara et al 2000]. Наше объяснение феномена *напоминания* близко к объяснению теории воспроизведения [Riccio et al 2002, Millin et al 2001], которая требует похожего внутреннего контекста при записи и при считывании, но отличается от него конкретным осцилляторным нейронным механизмом, вместо простого ограничения на нейробиологическую интерпретацию.

Эффект консолидации. Он является важнейшим эффектом для понимания памяти, и в особенности его свойство *ассоциативности*. Это свойство утверждает новый тип пластичности при запоминании и усилении запомненной сенсорной информации в течение некоторого времени после обучения. Новый тип пластичности состоит в постепенном изменении собственной частоты осцилляторов слуховой коры при повторении условного звукового сигнала, но он применим в общем случае для любой модальности условного стимула. Соответствующие данные [Weinberger 2003, 2004], подтверждающие специфичность, быстрое запоминание, консолидацию и неограниченный срок хранения следов, являются прямым экспериментальным подтверждением Основного свойства 6 «Нейролокатора»: когда число синхронизированных корковых осцилляторов в ансамбле превысит критическое значение, оптимальные лабильности этих осцилляторов стремятся уравниваться, т. е. те осцилляторы, которые усваивают общий ритм постепенно в течение некоторого времени меняют «собственную» частоту в сторону общей частоты. Эта частота, точнее, ей соответствующая лабиль-

ность сохраняется и после угашения колебаний в долговременной памяти в неактивном состоянии и воспроизводится при считывании, когда эти осцилляторы под воздействием внешней активации и повышения эраузала снова станут активными. Это согласуется с главным заключением обзора [Davachi 2004]: «Ансамбль, который играет вместе, остается вместе».

Считывание информации из памяти — это восстановление изолабильной конфигурации, которая была при записи. В неактивном состоянии, т. е. при угашении колебаний осцилляторов, такие памятные следы защищены от помех и *интерференции*, от наложения следов нового обучения, разрушения электрическим ударом и т. п. Первоначальный смысл термина консолидация состоял в переходе от хрупкого и вначале уязвимого состояния памяти к такому защищенному состоянию [McGaugh 2000]. Позднее смысл этого термина расширился и стал включать в себя время-зависимое усиление следов памяти. В этом новом смысле консолидация требует участия гиппокампальной системы в режиме off line, т. е. в отсутствие дополнительного обучения. В модели «Нейролокатор» это происходит следующим образом.

Допустим, в неравенстве (3) параметр K уменьшился и стал равным $K' < K$, например, за счет отдыха или сна, вследствие уменьшения эраузала. Тогда при частичном напоминании одной из ранее запомненных конфигураций прежнее условие отключения гиппокампа от неокортекса $AK/\Lambda_0 > 1/g_{\min}$ уже не выполняется, и система оказывается в условиях эффекта новизны, и поэтому за счет синхронизации кортикальных осцилляторов и рекрутирования новых осцилляторов параметр A возрастает до A' , при котором начинает выполняться неравенство $A'K'/\Lambda_0 > 1/g_{\min}$, после чего наступает привыкание и гиппокамп отключается от неокортекса. В результате без всякого дополнительного обучения след усиливается, как по амплитуде ($A' > A$), так и по частотной избирательности, поскольку последняя, в результате уравнивания собственных частот осцилляторов, и есть причина возрастания амплитуды A' . Время, потребное для такого возрастания, увеличивается по сравнению со временем первоначального обучения примерно K/K' раз, так что для консолидации может потребоваться несколько часов и даже ночей, но во всяком случае — не десятилетий, как в Стандартной Теории.

Процессы внимания и памяти во сне заслуживают отдельного обсуждения. Но ограничения места не позволяют обсудить их здесь подробно. Здесь лишь отметим, что наиболее вероятная причина изменения параметра K во сне — это изменение физиологического эраузала и амплитуды

тета-ритма, что согласно работе [Vinogradova et al 1995] обусловлено изменением уровня ацетилхолина в медиальном септум. Поэтому указанный выше механизм усиления следов без дополнительного обучения очень просто объясняет кажущийся парадоксальным результат работы [Hasselmo & McGaugh 2004]: высокие уровни ацетилхолина устанавливают динамику сети в режим внимания и кодирования, а низкие уровни — в режим консолидации. Этот же механизм следующим образом объясняет такие свойства консолидации, как *постепенность* и *избирательность*.

Если уменьшить параметр K модели, имитируя удаление NMDA рецепторов поля CA3 у мутантных мышей, то в модели происходит ухудшение частотной и, следовательно, пространственной избирательности. Тогда в системе происходит самонастройка параметров на оптимальное значение за счет консолидации памятных следов во время сна путем выравнивания собственных частот локальных осцилляторов к общей частоте синхронизации, подобно тому, как это было описано при консолидации во сне у нормальных мышей.

Свойство *постепенности* консолидации, трудно обнаруживаемое во время бодрствования [Poe et al 2000], хорошо выявляется путем сравнения фаз во время быстрого сна и бодрствования. Постепенное обучение в незнакомой части пространства приводит к выравниванию собственных частот в сторону постоянной частоты тета-ритма, в том числе и во сне, благодаря чему их средняя фаза по отношению к фазе тета-ритма убывает, но это убывание делается более заметным в стадии быстрого сна, чем при бодрствовании. Это очевидно из формулы $\varphi = g^{-1}(\Lambda_0/AK)$, полученной приравниванием нулю правой части уравнения (2), где g^{-1} есть функция, обратная g , а ее крутизна во сне значительно выше, так как крутизна g во сне уменьшается за счет изменения активности холинергической системы [Nakazava et al 2003, Hasselmo & McGaugh 2004].

Эффект антероградной амнезии. Данный эффект со всеми его частными случаями единообразно объясняется следующим образом. Полная неспособность фиксировать новую информацию в результате повреждения гиппокампа в модели «Нейролокатор» возникает в том случае, когда неравенство (3) не выполняется ни при каких значениях параметров AK и Λ_0 . Это возможно в единственном случае, когда после поражения гиппокампа g_{\max} уменьшается и становится равным $g'_{\max} \cong g'_{\min}$, сводя к нулю область фазовой синхронизации и как бы уменьшая до нуля рабочий объем

гиппокампа и сигнальной коры. Фактически нашли [Fama et al 2004], что мера антероградной памяти зрительных образов связана с объемом гиппокампа, но не с объемом белого вещества зрительной коры. Аналогично этому нашли [Anagnastaras et al 2002], что степень поражения коры лучше предсказывает дефицит контекст-зависимой памяти прошлого, чем степень поражения гиппокампа, в то время, как потери новой эпизодической автобиографической памяти, согласно [Schmidtke & Vollmer 1997], связаны исключительно с повреждением гиппокампа. Эти данные помогают понять связь АА с РА и сами хорошо согласуются с нижеследующим объяснением.

В терминах модели «Нейролокатор» объем поврежденного гиппокампа соответствует уменьшению области значений параметра AK/Λ_0 , для которой справедливо неравенство (3), т. е. соответствует обужению полосы захвата, т. е. области фазовой синхронизации (см. рис. 3А и 3Б, наиболее затемненная область), а повреждение неокортекса — с изменением коэффициента A на фиксированную величину или, что эквивалентно, сдвигу на эту величину области полосы сигналов (см. рис. 3Г и 3Д) влево (гипометаболизм, гипотермия и т. п.), либо вправо (гиперактивация, гипервозбуждение). Комбинируя эти два вида деформации (обужение и сдвиг) области справедливости неравенства (3) получаем следующее объяснение всех случаев соотношений АА и РА, условно изображенных на рис. 3:

- *Положительная корреляция* — это результат сужения полосы фазовой синхронизации: чем больше сужение, т. е. чем больше область АА, тем больше область РА.
- *Диспропорциональность* — тоже результат сужения полосы фазовой синхронизации, приводящей к большой АА, но, в данном случае, малой РА, вследствие того, что в случае неассоциативной информации роль фазовой синхронизации невелика и считывание может быть на основе лишь синхронизации по частоте, либо от reset, т. е. непосредственно от септум без участия гиппокампа. Это согласуется с данными о том, что fMRI активация гиппокампа у нормальных людей тем больше, чем больше считывание зависит реляционной обработки [Giovanello et al 2004], и что у амнестиків диспропорционально большой дефицит ассоциативного узнавания, чем дефицит узнавания одиночных предметов [Giovanello et al 2003]. Наша модель объясняет участие гиппокампа как в реляционной, так и в однопредметной (item-based) обработке информации, но это участие будет больше в первом случае, чем во втором — в соответствии с данными [Davachi & Wagner 2002], так как роль фазовой синхронизации в первом случае

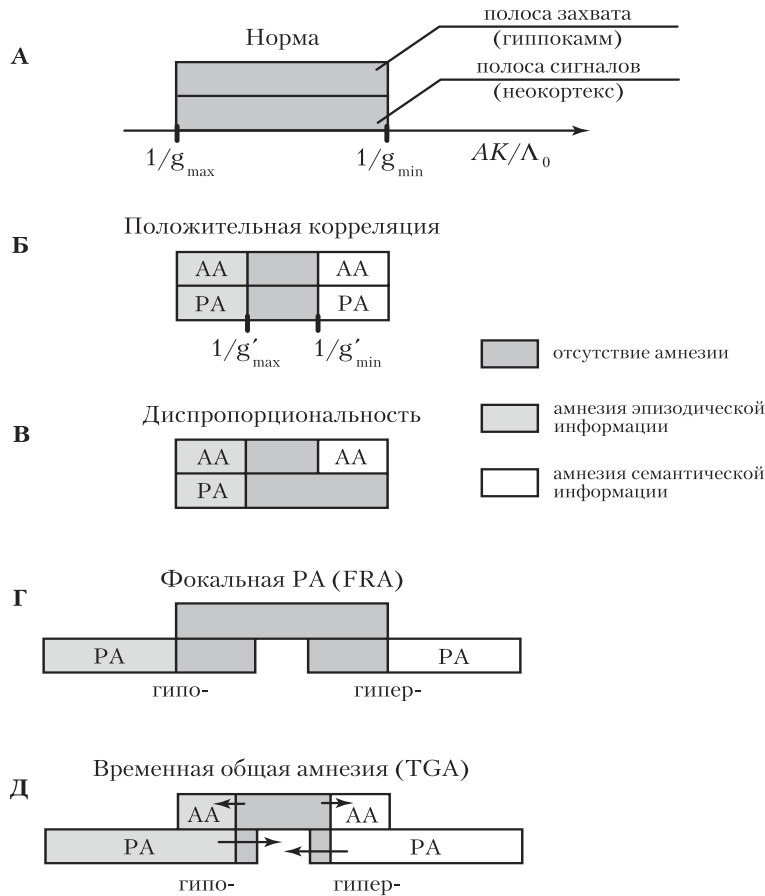


Рис. 3. Условное изображение эффекта антероградной амнезии и ее связи с ретроградной амнезией

Повреждение гиппокампа условно отмечено сужением области полосы захвата, а повреждение неокортекса — сдвигом рабочей области эраузала, или полосы сигнала, влево (гипо-метаболизм) или вправо (гипер-активация). Здесь **А** — интактные гиппокамп и неокортекс; **Б** — поврежденный гиппокамп, интактный неокортекс + ассоциативная информация; **В** — поврежденный гиппокамп, интактный неокортекс + неассоциативная информация; **Г** — интактный гиппокамп и поврежденный неокортекс; **Д** — повреждены временно гиппокамп и неокортекс; стрелки указывают ход восстановления памяти во времени; AA, PA — антероградная и ретроградная амнезия.

больше.

- *Фокальная РА* — случай сдвига без обужения (РА без АА).
- *Временная общая амнезия* (ТГА) — это различные комбинации временного сдвига и временного обужения, причем с разными скоростями ликвидации сдвига и обужения. Почему чаще и больше страдает эпизодическая память, чем семантическая, и восстанавливается раньше семантическая память, чем эпизодическая — станет ясно после объяснения **эффекта диссоциации**.

В целом наше объяснение эффекта антероградной амнезии согласуется с гипотезой комбинации двух механизмов повреждения: гиппокамально-антероградного и неокортикального запись/считывания [Schmidtke & Vollmer 1997], но охватывает значительно более широкий спектр данных и вместо статистической интерпретации дает им единообразное объяснение в терминах нейронных сетей.

Эффект диссоциации. «Нейролокатор» описывает различие между семантической и эпизодической памятью в нормальных условиях не как различие между многократными и однократными событиями, а как различие, аналогичное различию между унитарным и разделенным вниманием [Круиков 1991], поскольку семантическая память имеет более или менее абстрактный, редуцированный характер, в то время как в эпизоде участвует одновременно несколько объектов. В первом случае система (1) допускает одномерное стационарное решение. Во втором случае, возникающем при более низком значении AK/Λ_0 , эта система может иметь векторное решение $\{\varphi_i\}$, содержащее до семи компонент (см. Основное свойство 4 модели «Нейролокатор»). Поэтому при повреждении гиппокампа, когда полоса захвата внимания сужается, поражается как эпизодическая, так и семантическая память (см. рис. 3Б, 3В и 3Д), но больше эпизодическая, не только потому, что следов семантической памяти в неокортексе больше, вследствие большей частоты ее реактивации, но и потому, что при повреждении гиппокампа часто исчезает разделенное внимание. Случай селективного поражения эпизодической или семантической памяти объясняется наподобие *фокальной РА* тем, что после поражения мозга возможно как уменьшение, так и увеличение эраузала, в следствие гипометаболизма или образования локальной очаговой активности, соответственно. Это согласуется с данными о том, что при повреждении левого полушария, нормально работающего с более высоким эраузalom, чем правое полушарие, больше

поражается семантическая память, а при поражении правого полушария больше страдает эпизодическая память [Korelman & Karur, 2001].

Эффект клетки места. Данный эффект — это проявление взаимной корреляции двух основных входов в гиппокамп. Согласно Теории Тета-Регулируемого Внимания, поле CA3 регистрирует совпадения или несовпадения во времени сигналов двух основных входов независимо от модальности. Поэтому естественно считать, что активность клетки места поля CA3 есть микроскопический аналог кросс-корреляционной функции этих двух входов, т. е. индивидуальным нейронным вкладом в функцию $Ag(\varphi)$, стоящую в уравнении (2), откуда следуют почти все свойства эффекта клетки места, если учесть, что поле CA1 дополнительно фиксирует совпадение активности с выхода поля CA3 и неокортекса, усиливая пространственную специфичность; согласно [Muller 1996] клетки места полей CA3 и CA1 имеют почти идентичные свойства.

- *Ненаправленность* — это независимость $Ag(\varphi)$ для случая цилиндрического аппарата от направления, в котором повернута голова, аналогичная тому, что авто-корреляционная функция стационарного процесса зависит лишь от временного сдвига φ и не зависит от начального времени, в данном случае — угла поворота головы.
- *Вращение* — это плавное изменение $Ag(\varphi)$ при изменении частоты тета-ритма вследствие вращения обстановочных ключевых стимулов без срыва синхронизации, т. е. без реконфигурации.
- *Реконфигурация* — это резкое изменение $Ag(\varphi)$ при изменении частоты тета-ритма вследствие изменения внутренних или внешних условий или при изменении условного стимула [Moita et al 2004]. При этом непредсказуемо меняется изолабельная конфигурация кортикальных осцилляторов, и поэтому топологические отношения между полями различных клеток места не сохраняются, и, следовательно, нет топологического соответствия между анатомическим положением клеток места в гиппокампе и полем клеток места в пространстве.
- *Стабильность* — это стабильность активности $Ag(\varphi)$ и есть следствие стабильности тета-ритма в условиях преобладающего внимания к какому-либо пространственному стимулу.
- *Двойной код* — это пара: активность $Ag(\varphi_t)$ и фаза φ_t . Первая компонента, вследствие сильной зависимости A и g_{\min} от эраузала, оказывается связанной со скоростью движения крысы, потому что эта

скорость тоже сильно зависит от эраузала. Вторая компонента вследствие зависимости от расстройки Λ_0 согласно уравнению (2), лучше отражает отклонение положения крысы от центра поля клетки места, где $\Lambda_0 = 0$, монотонно убывая с расстоянием от него, так как различным локусам соответствуют различные собственные частоты осцилляторов места.

- *Дирекциональность* — следствие постепенного затягивания новых кортикальных осцилляторов в формирование поля клетки места при повторных направленных движениях крысы.
- *Многомодальность* — почти очевидное свойство, поскольку $Ag(\varphi_t)$ описывает кросс-корреляции пространственной информации и условного сигнала любой модальности в поле СА3, а дополнительная пространственная селекция на поле СА1, усиливая пространственные свойства, сохраняет многомодальность представления объекта, находящегося в поле места данной клетки.

Эффект точки зрения. Он объясняется тем, что при двухстороннем поражении гиппокампа пациент способен распознать выученный объект из неизменной точки зрения из-за того, что только при этом частота тета-ритма за счет обратной связи с неокортекса на септум устанавливается примерно той же самой, что и при обучении, при условии, что обучение было достаточно продолжительным. В случае отсутствия патологии почти независимость времени распознавания от угла сдвига объясняется тем, что система внимания при поиске в долговременной памяти быстро и автоматически устанавливает частоту тета-ритма, которая была при обучении, что проявляется в резком повышении коэффициента A на этой частоте или на кратной частоте, а затем в его падении вследствие фазовой синхронизации и последующей десинхронизации гиппокампа и неокортекса, подобно тому, как это было при объяснении эффекта новизны и привыкания.

Эффект независимости от давности. Этот эффект объясняется двумя особенными свойствами модели «Нейролокатор». Во-первых, тем, что в ней для воспроизведения эпизодической информации как и при записи всегда требуется гиппокампальный компаратор как часть общего пути, обнаруженного в работе [Daselaar et al 2004]. Во-вторых, хотя время активации fMRI старых следов и удержания внимания к ним из-за шума $N(t)$ в системе (1) есть величина случайная, зависящая от степени подробно-

сти, выученности информации и детальности задания на воспроизведение, среднее значение этого времени, тем не менее, может быть во многих случаях слабо зависящим от возраста памяти. Действительно, аналитические и вычислительные расчеты этого времени, приведенные в работе [Kryukov et al 1990, Fig. 9.3], показывают, что среднее значение времени удержания внимания, т. е. время синхронизации неокортикальных осцилляторов и септального тета-генератора, как функция параметра Λ_0/AK , имеет плато и, следовательно, в некоторой области этого параметра не зависит от возраста, несмотря на то, что параметр A может заметно зависеть от возраста. Этим плато мы объясняем наиболее часто встречающуюся в литературе независимость величины fMRI активации от возраста следов. В общем случае возможна не только стабилизация, но и возрастание или убывание времени активации гиппокампа — в зависимости от эраузала, от начальных условий и принятой методологии регистрации. В частности, необычные данные [Maguire & Frith 2003] о различном характере активации левого и правого гиппокампа мы объясняем различием времени активации следов в левом и правом полушарии за счет различия эраузала в них. Такое объяснение согласуется с данными [Ryan et al 2001] о том, что fMRI активация в аналогичных условиях достигает максимума за 2 с в левом гиппокампе и за 6–8 с в правом. Подобное же объяснение данных [Maguire & Frith 2003] дается в работе [Gilboa et al 2004] с тем, однако, отличием, что наше объяснение единообразно охватывает все известные в литературе случаи зависимости от давности и объясняет почему преобладают случаи независимости от давности следов.

Попытка примирения конкурирующих теорий

Приведенное единообразное объяснение основополагающих эффектов четырех теорий основано на радарной аналогии и на теории синхронизации, которые еще мало известны в области моделирования памяти. Поэтому мы поясним их необходимость и основной результат данной работы на примере более простой оптической аналогии. Так, Стандартную Теорию, считающую, что гиппокамп необходим для быстрой фиксации информации, но не для воспроизведения старых следов, можно, следуя [Shastri 2002], уподобить фотокамере, а Теорию Множественных Следов, особенно в случае однократных временных эпизодов, можно уподобить видеокамере, которая, в отличие от фотокамеры, действительно всегда требуется для воспро-

изведения эпизодических событий. Аналогично тому, как в видеокамере легко реализуется режим стоп-кадров фотокамеры, Теория Множественных Следов нередко претендует на то, чтобы включить в себя не только Стандартную Теорию, но и Теорию Когнитивной Карты. На это последняя справедливо возражает, что фото- и видеокамеры фиксируют только ту информацию, на которую «эгоцентрически» смотрит объектив, в то время как требуется фиксация «аллоцентрической» информации всего окружающего пространства, т. е. независимо от того, куда направлен объектив. Эта информация, как адресный контекст, позволяет затем восстановить память эпизодов, обосновывая этим первичность и большую фундаментальность Теории Когнитивной Карты.

Существует точка зрения, что все указанные теории — правильные, но неполные и должны рассматриваться как взаимно дополнительные, подобно тому, как видеокамера не может полностью заменить профессиональный аппарат или картограф. На это Теория Тета-Регулируемого Внимания замечает, что указанные выше оптические аналогии, хотя и имеют некоторые основания, но упускают из вида одну очень важную биологическую особенность о том, что недопустимо записывать в память все, что входит в объектив видеокамеры, иначе такая память скоро превращается в большую мусорную свалку, но одновременно недопустимо лишь иногда делать фотоснимки, пусть даже «аллоцентрические», так как при этом можно пропустить жизненно важную информацию, которая способна преждевременно оборвать сам процесс съемки. Поэтому простое объединение теорий не может быть оправданно — нужна новая, более гибкая теория, которая была бы способна одновременно решать все указанные выше задачи, и в тоже время лучше бы учитывала свойство живых организмов жаждать новой информации и привыкать ко всему, часто повторяющемуся и второстепенному. Другими словами, более общая теория должна лучше отражать механизм внимания в процессе формирования памяти. Ближайшая техническая аналогия — система автоматического сопровождения движущихся целей, радарная установка. Аналогия внимания в виде пассивного фильтра, повсеместно применяемого в моделировании памяти, совершенно недостаточна, так как фильтр новизны должен иметь в наличии почти всю ранее зафиксированную информацию, чтобы вынести решение о том, что данная входная информация — новая и должна быть записана в память для последующего руководства к действию. Поэтому гиппокамп не может быть хранилищем такой информации.

На рис. 4 схематически изображено соотношение между различными

теориями, рассмотренными в этой работе. Главная идея схемы состоит в том, что Теория Тета-Регулируемого Внимания, функционально объединяя с помощью синхронизации в диапазоне тета- и гамма- ритмов различные структуры мозга, оказалась способной объяснить характеристические эффекты всех четырех теорий долговременной памяти и тем самым учесть индивидуальный вклад каждой из теорий и значит примирить их на общей основе. Однако это примирение происходит при одном важном условии о том, что памятные следы в гиппокампе не накапливаются и не хранятся. Без этого условия невозможно примирение конкурирующих теорий.

Интересно отметить удивительное соответствие рассмотренных выше четырех теорий памяти с четырьмя психофизическими теориями внимания, краткий обзор которых приведен в работе [Игумен Феофан, в печати]. В обоих случаях каждая из существующих теорий опирается на свои характеристические эффекты и поэтому не может быть сведена к другой альтернативной теории. В обоих случаях существует одна теория, которая отличается от остальных утверждением уникальной и первичной роли пространства, занимаемого объектом. Наконец, в обоих случаях многие исследователи считают, что для объяснения данных необходимо допустить существование теории комбинированного типа, причем в обеих областях трудный, важный и нерешенный вопрос состоит в том, как комбинируется пространственная и непространственная информация.

Такое сопоставление теорий наводит на мысль о единстве механизмов памяти и внимания как на психофизическом, так и нейропсихологическом уровнях, так что четыре теории памяти различаются между собой по существу тем, что они акцентируют внимание на четырех отдельных аспектах единого механизма внимания и памяти. И поэтому ни одна из теорий не может быть сведена к какой-либо другой, если отсутствует единая теория, их всех объединяющая, в чем и состоит причина тупика, отмеченного во Введении. В этом отношении не была исключением и Теория Тета-Регулируемого Внимания как теория формирования памяти, по крайней мере до тех пор, пока она с помощью модели не объяснила характеристические эффекты остальных теорий. Поэтому мы утверждаем, что указанный тупик не может быть преодолен путем дальнейшего накопления экспериментальных данных без детальной модели внимания и памяти.

Модель «Нейролокатор», единообразно объясняя все характеристические эффекты всех основных четырех теорий, свидетельствует тем самым, что процесс внимания — самый существенный системный процесс при запоминании и считывании информации. При этом первичную роль игра-




Рис. 4. Условное изображение отношений между различными теориями памяти

Это изображение показывает внимание как общую психофизиологическую основу теорий памяти, их несводимость друг к другу, их ближайшие технические аналогии, возможность их примирения в единой теории. Здесь: **ТКК** — Теория Когнитивной Карты, **СТ** — Стандартная Теория, **ТМС** — Теория Множественных Следов, **ТТРВ** — Теория Тета-Регулируемого Внимания.

ет синхронизирующий септальный тета-ритм, совмещающий во времени пространственную локализацию объекта и его непространственные свойства, причем эти последние свойства объекта как бы «сидят верхом» (ride) на этом пространственном свойстве, как на коне. Точнее, центр внимания реализуется на частоте осциллятора локуса объекта, а другие свойства сопровождают эту частоту как его гармоники. Это согласуется за заключением обзора [Игумен Феофан, в печати]: хотя базовые единицы, на которые действует внимание, могут оказаться в разных экспериментальных условиях различными, имеются данные, которые указывают на существенно пространственную природу базовых единиц в смысле фундаментальности, доминированности и первичности локусов, занимаемых объектами. Поэтому в определенной мере справедливо утверждение Теории Когнитивной Карты о первичной и исключительной роли обработки пространственной информации в гиппокампе, несмотря на то, что Теория Когнитивной Карты, в целом, как было показано в разделе, посвященном этой теории (см. с. 174), неверна, и когнитивной карты в гиппокампе не существует. Гиппокамп также не запоминает аллоцентрическое (независящее от точки зрения) представление положения объекта, но он каждый раз заново участвует в его формировании на основе неокортикальных эгоцентрических представлений.

Из обсуждения, приведенного в разделах «Стандартная Теория» (см. с. 178) и «Краткое объяснение основных эффектов» (см. с. 200), следует, что Стандартная Теория уже содержит некоторые положения модели «Нейролокатор» о том, что **(а)** декларативная память — единый системный процесс, не разделяющийся на множество систем памяти, таких, как семантическая и эпизодическая память; **(б)** окончательное хранилище долговременных следов находится не в гиппокампе, а в неокортексе; **(в)** гиппокамп существенно необходим для быстрой фиксации информации в мозге. Но, вопреки этой теории, время, в течение которого следы стабилизируются в неокортексе — не годы, но лишь небольшие интервалы времени, в течение которых соответствующие стимулы еще привлекают к себе внимание (ср. [Kentros et al 2004]).

В свою очередь, Теория Множественных Следов права в том смысле, что множественные эпизодические следы, пространственно рассеянные в неокортексе, объединяются с помощью байндинг-кодов с участием гиппокампа, независимо от возраста памяти. Но, вопреки этой теории, сами эти байндинг-коды не хранятся в гиппокампе, а заново формируются на основе взаимодействия неокортекса и гиппокампальной системы для каждого

акта внимания, т. е. для каждого объекта, привлечшего к себе внимание. Байндинг-код — это та частота тета-ритма, на которой синхронизируются все те кортикальные осцилляторы свойств, которые были вместе при записи, и эта частота автоматически возникает в акте внимания к ассоциативным ключам без всякой необходимости записывать этот код в гиппокампе.

Наконец, в целом несомненно верная, но не вполне доказанная современными средствами Теория Тета-Регулируемого Внимания связывает воедино пространственную, декларативную и эпизодическую память, т. е. связывает все четыре теории, так что оказывается справедливым следующее, ранее высказанное предположение: «Хотя эпизодическая информация и не накапливается в гиппокампе и в медиальной височной коре, эти области вовлечены в ориентирование посредством новизны, приводящему к эраузалу, без которого ключевой процесс [фиксации следов и — *И. Ф.*] консолидации не происходит» [Mayes & Roberts 2001, p. 1399]. При этом становятся понятными ранее загадочные данные [Moita et al 2003] и [Cabeza et al 2003] о пространственном и функциональном взаимодействии, и даже почти полном совпадении, мозговых структур, участвующих в процессах внимания, эпизодической памяти и пространственной обработки информации.

Заключение

Таким образом, Теория Тета-Регулируемого внимания с помощью модели «Нейролокатор» примиряет все основные теории памяти и гиппокампа и, преодолевая *тупик памяти в гиппокампе*, открывает дорогу для дальнейшего изучения загадок памяти и внимания. В частности, эта модель дает ответы на вопросы, поставленные во Введении.

1. Пространственную информацию можно рассматривать как более первичную среди других типов информации об объекте в том смысле, что выходные отделы дорзального тракта («Где?») работают на частоте тета-ритма системы внимания и имеют больший вес среди других видов информации даже в случае непространственных задач, в то время как вентральный тракт («Что?»), кодируя непространственные свойства объекта, синхронизируется на частотах, кратных частоте тета-ритма, которые имеют меньший вес. Но только на основе взаимодействия этих двух каналов возможно формирование аллоцентрических представлений объектов.

2. Пространственная и непространственная информация взаимодействуют в гиппокампе вдоль его продольной оси и совместно управляют частотой септального тета-ритма, но фактическое взаимодействие (байндинг) этих двух типов информации не локализовано в гиппокампе, но распределено во всех основных структурах мозга, синхронизирующихся на частотах тета- и гамма-ритмов и это в известной степени возможно при полных перерезках гиппокампа.
3. Новые данные [Weinberger 2003, 2004] показывают, что кроме синаптической пластичности существует частотно-пространственная пластичность нейронов и микроколонок, изменяющих свою наилучшую частоту под действием внешней стимуляции, которая имеет все свойства ассоциативной памяти, включая консолидацию и поведенческие корреляты. Модель «Нейролокатор» показывает, что этот тип пластичности может служить нейробиологическим субстратом долговременной памяти, лишенной известных недостатков памяти, построенной на модификации синаптических весов. Гиппокампальная LTP при этом выполняет неспецифическую вспомогательную функцию, в основном защиту от наложения новых памятных следов на старые.
4. Не существует четкой демаркационной линии между обработкой эпизодической и семантической информации в том смысле, что гиппокамп якобы не требуется для семантической памяти. Их различие лишь в степени его участия, а так же в степени латерализации областей неокортекса, нормально работающих при различающихся значениях эраузала.
5. Гиппокамп участвует в двух различных функциональных системах и выполняет различающиеся, но согласованные между собою функции, обеспечивающие нормальную работу внимания и фиксации следов памяти в неокортексе. Однако он не является ни долговременным, ни промежуточным, ни кратковременным хранилищем памятных следов эпизодов или их контекста, но является критически важной структурой для организации селективного восприятия, для подавления мешающей информации, для привыкания к неизменным сигналам, для детекции новых и значительных изменений, которые должны быть записаны в памяти, и для воспроизведения ассоциативной информации, особенно памяти временных последовательностей эпизодов.

Литература

1. Брагин А.Г., Виноградова О.С., Емельянов В.В. Влияние зубчатой фасции на сенсорные реакции нейронов поля СА3 гиппокампа // *ЖВНД*. – **26** (3), с. 605–611, 1976.
2. Виноградова О.С., Дудаева К.И. О компараторной функции гиппокампа // *Доклады АН СССР*. – **202** (2), с. 486–489, 1972.
3. Линдсей В. Системы синхронизации в связи и управлении. – М.: Советское радио, 1978.
4. Игумен Феофан (Крюков). Модель внимания и памяти, основанная на принципе доминанты // *IV Всероссийская конференция «Нейроинформатика-2002»*. – Москва, МИФИ, 2002, ч.1. – с. 66–113.
5. Игумен Феофан (Крюков). Модель внимания и памяти, основанная на принципе доминанты и компараторной функции гиппокампа // *ЖВНД*. – **54** (1), с. 10–29, 2004.
6. Игумен Феофан (Крюков). Принципы сенсорной интеграции: иерархичность и синхронизация // *ЖВНД*. – **55** (2), с. 163–169, 2005.
7. Игумен Феофан (Крюков). Что селективируется вниманием // *ЖВНД*, 2004 (в печати).
8. Alvarez P., Squire L.R. Memory consolidation and the medial temporal lobe: A simple network model // *Proc. Natl. Acad. Sci. (USA)*. – **91** (15), pp. 7041–7045, 1994.
9. Alvarez P., Zola-Morgan S., Squire L.R. The animal model of human amnesia: Long-term memory impaired and short-term memory intact // *Proc. Natl. Acad. Sci. (USA)*. – **91** (12), pp. 5637–5641, 1994.
10. Anagnostaras S.G., Gale G.D., Fanselow M.S. The hippocampus and Pavlovian fear conditioning: Reply to Bast et al. // *Hippocampus*. – **12** (4), pp. 561–565, 2002.
11. Bayley P.J., Hopkins R.O., Squire L.R. Successful recollection of remote autobiographical memories by amnesic patients with medial temporal lobe lesions // *Neuron*. – **38** (1), pp. 135–144, 2003.
12. Bayley P.J., Squire L.R. Failure to acquire new semantic knowledge in patients with large medial temporal lobe lesions // *Hippocampus*. – **15** (2), pp. 273–280, 2005.
13. Bayley P.J., Squire L.R. Medial temporal lobe amnesia: Gradual acquisition of factual information by nondeclarative memory // *J. Neurosci.* – **22** (13), pp. 5741–5748, 2002.
14. Bernard F.A., Bullmore E.T., Graham K.S., Thompson S.A., Hodges J.R., Fletcher P.C. The hippocampal region is involved in successful recognition of both remote and recent famous faces // *Neuroimage*. – 2004. – **22**, pp. 1704–1714.

15. *Brown A.S.* Consolidation theory and retrograde amnesia in humans // *Psychon. Bull. Rev.* – **9** (3), pp. 403–425, 2002.
16. *Burgess N., Becker S., King J.A., O'Keefe J.* Memory for events and their spatial context: models and experiments // *Philos. Trans. R. Soc. Lond. B. Biol. Sci.* – **356**, pp. 1493–1503, 2001.
17. *Cabeza R., Dolcos F., Prince S.E., Rice H.J., Weissman D.H., Nyberg L.* Attention-related activity during episodic memory retrieval: a cross-function fMRI study // *Neuropsychologia.* – **41** (3), pp. 390–399, 2003.
18. *Chan D., Fox N.C., Scahill R.I., Crum W.R., Whitwell J.L., Leschziner G., Rossor A.M., Stevens J.M., Cipolotti L., Rossor M.N.* Patterns of temporal lobe atrophy in semantic dementia and Alzheimer's disease // *Ann. Neurol.* – **49** (4), pp. 433–442, 2001.
19. *Chan D., Revesz T., Rudge P.* Hippocampal, but not parahippocampal, damage in a case of dense retrograde amnesia: a pathological study // *Neurosci. Lett.* – **329** (1), pp. 61–64, 2002.
20. *Cipolotti L., Shallice T., Chan D., Fox N., Scahill R., Harrison G., Stevens J., Rudge P.* Long-term retrograde amnesia... the crucial role of the hippocampus // *Neuropsychologia.* – **39** (2), pp. 151–172, 2001.
21. *Clark R.E., Broadbent N.J., Squire L.R.* Hippocampus and remote spatial memory in rats // *Hippocampus.* – **15** (2), pp. 260–272, 2005.
22. *Clark R.E., Broadbent N.J., Squire L.R.* Impaired remote spatial memory after hippocampal lesions despite extensive training beginning early in life // *Hippocampus.* – **15** (3), pp. 340–346, 2005.
23. *Clark R.E., Broadbent N.J., Zola S.M., Squire L.R.* Anterograde amnesia and temporally graded retrograde amnesia for a nonspatial memory task after lesions of hippocampus and subiculum // *J. Neurosci.* – **22** (11), pp. 4663–4669, 2002.
24. *Daselaar S.M., Veltman D.J., Witter M.P.* Common pathway in the medial temporal lobe for storage and recovery of words as revealed by event-related functional MRI // *Hippocampus.* – **14** (2), pp. 163–169, 2004.
25. *Dash P.K., Hebert A.E., Runyan J.D.* A unified theory for systems and cellular memory consolidation // *Brain Res. Brain Res. Rev.* – **45** (1), pp. 30–37, 2004.
26. *Davachi L.* The ensemble that plays together, stays together // *Hippocampus.* – **14** (1), pp. 1–3, 2004.
27. *Davachi L., Wagner A.D.* Hippocampal contributions to episodic encoding: insights from relational and item-based learning // *J. Neurophysiol.* – **88** (2), pp. 982–990, 2002.

28. Diwadkar V.A., McNamara T.P. Viewpoint dependence in scene recognition // *Psychol. Sci.* – **8**, pp. 302–307, 1997.
29. Douville K., Woodard J.L., Seidenberg M., Miller S.K., Leveroni C.L., Nielson K.A., Franczak M., Antuono P., Rao S.M. Medial temporal lobe activity for recognition of recent and remote famous names: an event-related fMRI study // *Neuropsychologia.* – **43** (5), pp. 693–703, 2005.
30. Dudai Y. Memory from A to Z. Keywords, Concepts, and Beyond. – Oxford University Press, 2004.
31. Eichenbaum H., Dudchenko P., Wood E., Shapiro M., Tanila H. The hippocampus, memory, and place cells: is it spatial memory or a memory space? // *Neuron.* – **23**, pp. 209–226, 1999.
32. Evans J.J., Graham K.S., Pratt K.H., Hodges J.R. The impact of disrupted cortico-cortico connectivity: a long-term follow-up of a case of focal retrograde amnesia // *Cortex.* – **39** (4–5), pp. 767–790, 2003.
33. Fama R., Marsh L., Sullivan E.V. Dissociation of remote and anterograde memory impairment and neural correlates in alcoholic Korsakoff syndrome // *J. Int. Neuropsychol. Soc.* – **10** (3), pp. 427–441, 2004.
34. Fell J., Klaver P., Elfadil H., Schaller C., Elger C.E., Fernandez G. Rhinal-hippocampal theta coherence during declarative memory formation: interaction with gamma synchronization? // *Eur. J. Neurosci.* – **17** (5), pp. 1082–1088, 2003.
35. Fell J., Klaver P., Lehnertz K., Grunwald T., Schaller C., Elger C.E., Fernandez G. Human memory formation is accompanied by rhinal-hippocampal coupling and decoupling // *Nat. Neurosci.* – **4** (12), pp. 1259–1264, 2001.
36. Fischer H., Wright C.I., Whalen P.J., McInerney S.C., Shin L.M., Rauch S.L. Brain habituation during repeated exposure to fearful and neutral faces: A functional MRI study // *Brain Res. Bull.* – **59**, pp. 387–392, 2003.
37. Fujii T., Moscovitch M., Nade L. Memory consolidation, retrograde amnesia, and the temporal lobe // In *Handbook of Neuropsychology*, 2nd edition, Vol. 2, Eds. F. Boller, J. Grafman. – Amsterdam, Netherlands: Elsevier Press, 2000, pp. 223–250.
38. Gaffan D., Parker A., Easton A. Dense amnesia in the monkey after transection of fornix, amygdala and anterior temporal stem // *Neuropsychologia.* – **39** (1), pp. 51–70, 2001.
39. Gilboa A., Ramirez J., Kohler S., Westmacott R., Black S.E., Moscovitch M. Retrieval of autobiographical memory in Alzheimer’s disease: relation to volumes of medial temporal lobe and other structures // *Hippocampus.* – **15** (4), pp. 535–550, 2005.
40. Gilboa A., Winocur G., Grady C.L., Hevenor S.J., Moscovitch M. Remembering our past: functional neuroanatomy of recollection of recent and very remote personal events // *Cereb. Cortex.* – **14** (11), pp. 1214–1225, 2004.

41. Giovanello K.S., Schnyer D.M., Verfaellie M. A critical role for the anterior hippocampus in relational memory: evidence from an fMRI study comparing associative and item recognition // *Hippocampus*. – **14** (1), pp. 5–8, 2004.
42. Giovanello K.S., Verfaellie M., Keane M.M. Disproportionate deficit in associative recognition relative to item recognition in global amnesia // *Cogn. Affect. Behav. Neurosci.* – **3** (3), pp. 186–194, 2003.
43. Graham K.S., Hodges J.R. Differentiating the roles of the hippocampal complex and the neocortex in long-term memory storage: evidence from the study of semantic dementia and Alzheimer’s disease // *Neuropsychology*. – **11** (1), pp. 77–89, 1997.
44. Graham K.S., Simons J.S., Pratt K.H., Patterson K., Hodges J.R. Insights from semantic dementia on the relationship between episodic and semantic memory // *Neuropsychologia*. – **38** (3), pp. 313–324, 2000.
45. Grossi D., Trojano L., Grasso A., Orsini A. Selective “semantic amnesia” after closed-head injury. A case report // *Cortex*. – **24** (3), pp. 457–464, 1988.
46. Guillery-Girard B., Desgranges B., Urban C., Piolino P., de la Sayette V., Eustache F. The dynamic time course of memory recovery in transient global amnesia // *J. Neurol. Neurosurg. Psychiatry*. – **75** (11), pp. 1532–1540, 2004.
47. Habib R., McIntosh A.R., Wheeler M.A., Tulving E. Memory encoding and hippocampally-based novelty/familiarity discrimination networks // *Neuropsychologia*. – **41** (3), pp. 271–279, 2003.
48. Haist F., Bowden Gore J., Mao H. Consolidation of human memory over decades revealed by functional magnetic resonance imaging // *Nat. Neurosci.* – **4** (11), pp. 1139–1145, 2001.
49. Harris K.D., Henze D.A., Hirase H., Leinekugel X., Dragoi G., Czurko A., Buzsaki G. Spike train dynamics predicts theta-related phase precession in hippocampal pyramidal cells // *Nature*. – **417** (6890), pp. 738–741, 2002.
50. Hasselmo M.E., McGaughy J. High acetylcholine levels set circuit dynamics for attention and encoding and low acetylcholine levels set dynamics for consolidation // *Prog. Brain Res.* – **145**, pp. 207–231, 2004.
51. Haxby J.V., Hoffman E.A., Gobbini M.I. The distributed human neural system for face perception // *Trends Cogn. Sci.* – **4** (6), pp. 223–233, 2000.
52. Hayes S.M., Ryan L., Schnyer D.M., Nadel L. An fMRI study of episodic memory: retrieval of object, spatial, and temporal information // *Behav. Neurosci.* – **118**, pp. 885–896, 2004.
53. Holdstock J.S., Mayes A.R., Isaac C.L., Gong Q., Roberts N. Differential involvement of the hippocampus and temporal lobe cortices in rapid and slow learning of new semantic information // *Neuropsychologia*. – **40** (7), pp. 748–768, 2002.

54. *Holscher C.* Time, space and hippocampal functions // *Rev. Neurosci.* – **14** (3), pp. 253–284, 2003.
55. *Huxter J., Burgess N., O'Keefe J.* Independent rate and temporal coding in hippocampal pyramidal cells // *Nature.* – **425** (6960), pp. 828–832, 2003.
56. *Jeffery K.J., Gilbert A., Burton S., Strudwick A.* Preserved performance in a hippocampal-dependent spatial task despite complete place cell remapping // *Hippocampus.* – **13**, pp. 175–189, 2003.
57. *Kapur N., Millar J., Abbott P., Carter M.* Recovery of function processes in human amnesia: evidence from transient global amnesia // *Neuropsychologia.* – **36** (1), pp. 99–107, 1998.
58. *Kentros C.G., Agnihotri N.T., Streater S., Hawkins R.D., Kandel E.R.* Increased attention to spatial context increases both place field stability and spatial memory // *Neuron.* – **42**, pp. 283–295, 2004.
59. *King J.A., Burgess N., Hartley T., Vargha-Khadem F., O'Keefe J.* Human hippocampus and viewpoint dependence in spatial memory // *Hippocampus.* – **12**, pp. 811–820, 2002.
60. *Kirchhoff B.A., Wagner A.D., Maril A., Stern C.E.* Prefrontal-temporal circuitry for episodic encoding and subsequent memory // *J. Neurosci.* – **20**, pp. 6173–6180, 2000.
61. *Knierim J.J.* Hippocampus and memory. Can we have our place and fear it too? // *Neuron.* – **37** (3), pp. 372–374, 2003.
62. *Knight R.T.* Contribution of human hippocampal region to novelty detection // *Nature.* – **383** (6597), pp. 256–259, 1996.
63. *Kopelman M.D.* Disorders of memory // *Brain.* – **125** (Pt 10), pp. 2152–2190, 2002.
64. *Kopelman M.D., Kapur N.* The loss of episodic memories in retrograde amnesia: single-case and group studies // *Philos. Trans. R. Soc. Lond. B. Biol. Sci.* – **356** (1413), pp. 1409–1421, 2001.
65. *Kopelman M.D., Lasserson D., Kingsley D.R., Bello F., Rush C., Stanhope N., Stevens T.G., Goodman G., Buckman J.R., Heilpern G., Kendall B.E., Colchester A.C.* Retrograde amnesia and the volume of critical brain structures // *Hippocampus.* – **13** (8), pp. 879–891, 2003.
66. *Kryukov V.I.* An attention model based on the principle of dominanta // In *Neurocomputers and Attention. I. Neurobiology, Synchronization and Chaos*, Eds. *A.V. Holden, V.I. Kryukov.* – Manchester: Manchester University Press, 1991, pp. 319–351.
67. *Kryukov V.I., Borisyuk G.N., Borisyuk R.M., Kirillov A.B., Kovalenko Ye.I.* Metastable and unstable states in the brain // In *Stochastic Cellular Systems: Ergodicity, Memory, Morphogenesis*, Eds. *R.L. Dobrushin, V.I. Kryukov, A.L. Toom.* – Manchester, UK, New York, NY: Manchester University Press, 1990, pp. 226–357.

68. Levine B., Black S.E., Cabeza R., Sinden M., Mcintosh A.R., Toth J.P., Tulving E., Stuss D.T. Episodic memory and the self in a case of isolated retrograde amnesia // *Brain*. – **121** (Pt 10), pp. 1951–1973, 1998.
69. Levine B., Svoboda E., Hay J.F., Winocur G., Moscovitch M. Aging and autobiographical memory: dissociating episodic from semantic retrieval // *Psychol. Aging*. – **17** (4), pp. 677–689, 2002.
70. Maguire E.A., Frith C.D. Aging affects the engagement of the hippocampus during autobiographical memory retrieval // *Brain*. – **126** (Pt 7), pp. 1511–1523, 2003.
71. Maguire E.A., Frith C.D. The brain network associated with acquiring semantic knowledge // *Neuroimage*. – **22** (1), pp. 171–178, 2004.
72. Maguire E.A., Henson R.N., Mummery C.J., Frith C.D. Activity in prefrontal cortex, not hippocampus, varies parametrically with the increasing remoteness of memories // *Neuroreport*. – **12** (3), pp. 441–444, 2001.
73. Maguire E.A., Mummery C.J., Buchel C. Patterns of hippocampal-cortical interaction dissociate temporal lobe memory subsystems // *Hippocampus*. – **10** (4), pp. 475–482, 2000.
74. Malsburg C. von der. Binding in models of perception and brain function // *Curr. Opin. Neurobiol.* – **5**, pp. 520–526, 1995.
75. Manning L. Focal retrograde amnesia documented with matching anterograde and retrograde procedures // *Neuropsychologia*. – **40** (1), pp. 28–38, 2002.
76. Manns J.R., Hopkins R.O., Squire L.R. Semantic memory and the human hippocampus // *Neuron*. – **38** (1), pp. 127–133, 2003.
77. Martin A., Chao L.L. Semantic memory and the brain: structure and processes // *Curr. Opin. Neurobiol.* – **11** (2), pp. 194–201, 2001.
78. Martin S.J., de Hoz L., Morris R.G. Retrograde amnesia: neither partial nor complete hippocampal lesions in rats result in preferential sparing of remote spatial memory, even after reminding // *Neuropsychologia*. – **43** (4), pp. 609–624, 2005.
79. Maviel T., Durkin T.P., Menzaghi F., Bontempi B. Sites of neocortical reorganization critical for remote spatial memory // *Science*. – **305** (5680), pp. 96–99, 2004.
80. Mayes A.R., Roberts N. Theories of episodic memory // *Philos. Trans. R. Soc. Lond. B. Biol. Sci.* – **356** (1413), pp. 1395–1408, 2001.
81. Mayes A.R., Mackay C.E., Montaldi D., Downes J.J., Gong Q.Y., Singh K.D., Roberts N. Does Retrieving Decades-old Spatial Memories Activate the Medial Temporal Lobes Less than Retrieving Recently Acquired Spatial Memories? // *Neuroimage*. – **11** (5), pp. 421, 2000.

82. *McClelland J.L., McNaughton B.L., O'Reilly R.C.* Why there are complementary learning systems in the hippocampus and neocortex: insights from the successes and failures of connectionist models of learning and memory // *Psychol. Rev.* – **102** (3), pp. 419–457, 1995.
83. *McGaugh J.L.* Memory — a century of consolidation // *Science.* – **287** (5451), pp. 248–251, 2000.
84. *McKenna P., Gerhand S.* Preserved semantic learning in an amnesic patient // *Cortex.* – **38** (1), pp. 37–58, 2002.
85. *Meeter M., Murre J.M.* Consolidation of long-term memory: evidence and alternatives // *Psychol. Bull.* – **130** (6), pp. 843–857, 2004.
86. *Meeter M., Murre J.M.* TraceLink: A model of consolidation and amnesia // *Cogn. Neuropsychol.* – **22** (5), pp. 559–587, 2005.
87. *Mehta M.R., Quirk M.C., Wilson M.A.* Experience-dependent asymmetric shape of hippocampal receptive fields // *Neuron.* – **25** (3), pp. 707–715, 2000.
88. *Miller R.R., Matzel L.D.* Memory involves far more than 'consolidation' // *Nat. Rev. Neurosci.* – **1** (3), pp. 214–216, 2000.
89. *Millin P.M., Moody E.W., Riccio D.C.* Interpretations of retrograde amnesia: old problems redux // *Nat. Rev. Neurosci.* – **2** (1), pp. 68–70, 2001.
90. *Mishkin M., Suzuki W.A., Gadian D.G., Vargha-Khadem F.* Hierarchical organization of cognitive memory // *Philos. Trans. R. Soc. Lond. B. Biol. Sci.* – **352** (1360), pp. 1461–1467, 1997.
91. *Miyashita Y.* Cognitive memory: cellular and network machineries and their top-down control // *Science.* – **306** (5695), pp. 435–440, 2004.
92. *Moita M.A., Rosis S., Zhou Y., LeDoux J.E., Blair H.T.* Hippocampal place cells acquire location-specific responses to the conditioned stimulus during auditory fear conditioning // *Neuron.* – **37**, pp. 485–497, 2003.
93. *Moita M.A., Rosis S., Zhou Y., LeDoux J.E., Blair H.T.* Putting fear in its place: remapping of hippocampal place cells during fear conditioning // *J. Neurosci.* – **24** (31), pp. 7015–7023, 2004.
94. *Morris R.G., Moser E.I., Riedel G., Martin S.J., Sandin J., Day M., O'Carroll C.* Elements of a neurobiological theory of the hippocampus: the role of activity-dependent synaptic plasticity in memory // *Philos. Trans. R. Soc. Lond. B. Biol. Sci.* – **358** (1432), pp. 773–786, 2003.
95. *Moscovitch M., Nadel L.* Consolidation and the hippocampal complex revisited: in defense of the multiple-trace model // *Curr. Opin. Neurobiol.* – **8** (2), pp. 297–300, 1998.
96. *Muller R.* A quarter of a century of place cells // *Neuron.* – **17**, pp. 979–990, 1996.

97. Murre J.M., Graham K.S., Hodges J.R. Semantic dementia: relevance to connectionist models of long-term memory // *Brain*. – **124** (Pt 4), pp. 647–675, 2001.
98. Nadel L., Bohbot V. Consolidation of memory // *Hippocampus*. – **11** (1), pp. 56–60, 2001.
99. Nadel L., Hardt O. The spatial brain // *Neuropsychology*. – **18**, pp. 473–476, 2004.
100. Nadel L., Moscovitch M. The hippocampal complex and long-term memory revisited // *Trends Cogn. Sci.* – **5** (6), pp. 228–230, 2001.
101. Nadel L., Moscovitch M. Memory consolidation, retrograde amnesia and the hippocampal complex // *Curr. Opin. Neurobiol.* – **7** (2), pp. 217–227, 1997.
102. Nadel L., Ryan L., Hayes S.M., Gilboa A., Moscovitch M. The role of the hippocampal complex in long-term episodic memory // In *Cognition and Emotion in the Brain*. International Congress Series, Vol. 1250. – Elsevier, 2003, pp. 215–234.
103. Nadel L., Samsonovich A., Ryan L., Moscovitch M. Multiple trace theory of human memory: computational, neuroimaging, and neuropsychological results // *Hippocampus*. – **10** (4), pp. 352–368, 2000.
104. Nader K., Schafe G.E., LeDoux J.E. The labile nature of consolidation theory // *Nat. Rev. Neurosci.* – 2000. – **1**, pp. 216–219.
105. Nakazawa K., Sun L.D., Quirk M.C., Rondi-Reig L., Wilson M.A., Tonegawa S. Hippocampal CA3 NMDA receptors are crucial for memory acquisition of one-time experience // *Neuron*. – **38** (2), pp. 305–315, 2003.
106. Nestor P.J., Graham K.S., Bozeat S., Simons J.S., Hodges J.R. Memory consolidation and the hippocampus: further evidence from studies of autobiographical memory in semantic dementia and frontal variant frontotemporal dementia // *Neuropsychologia*. – **40** (6), pp. 633–654, 2002.
107. Niki K., Luo J. An fMRI study on the time-limited role of the medial temporal lobe in long-term topographical autobiographic memory // *J. Cogn. Neurosci.* – **14** (3), pp. 500–507, 2002.
108. O'Keefe J. Do hippocampal pyramidal cells signal non-spatial as well as spatial information? // *Hippocampus*. – **9** (4), pp. 352–364, 1999.
109. O'Keefe J., Burgess N., Donnett J.G., Jeffery K.J., Maguire E.A. Place cells, navigational accuracy, and the human hippocampus // *Philos. Trans. R. Soc. Lond. B. Biol. Sci.* – **353**, pp. 1333–1340, 1998.
110. O'Keefe J., Nadel L. *The Hippocampus as a cognitive map*. – Oxford, UK: Clarendon Press, 1978.
111. Piefke M., Weiss P.H., Zilles K., Markowitsch H.J., Fink G.R. Differential remoteness and emotional tone modulate the neural correlates of autobiographical memory // *Brain*. – **126** (Pt 3), pp. 650–668, 2003.

112. Piolino P., Desgranges B., Belliard S., Matuszewski V., Lalevee C., De la Sayette V., Eustache F. Autobiographical memory and auto-noetic consciousness: triple dissociation in neurodegenerative diseases // *Brain*. – **126** (Pt 10), pp. 2203–2219, 2003.
113. Piolino P., Desgranges B., Benali K., Eustache F. Episodic and semantic remote autobiographical memory in ageing // *Memory*. – **10** (4), pp. 239–257, 2002.
114. Piolino P., Giffard-Quillon G., Desgranges B., Chetelat G., Baron J.C., Eustache F. Re-experiencing old memories via hippocampus: a PET study of autobiographical memory // *Neuroimage*. – **22** (3), pp. 1371–1383, 2004.
115. Poe G.R., Nitz D.A., McNaughton B.L., Barnes C.A. Experience-dependent phase-reversal of hippocampal neuron firing during REM sleep // *Brain Res.* – **855** (1), pp. 176–180, 2000.
116. Power A.E., Vazdarjanova A., McGaugh J.L. Muscarinic cholinergic influences in memory consolidation // *Neurobiol. Learn. Mem.* – **80** (3), pp. 178–193, 2003.
117. Raghavachari S., Kahana M.J., Rizzuto D.S., Caplan J.B., Kirschen M.P., Bourgeois B., Madsen J.R., Lisman J.E. Gating of human theta oscillations by a working memory task // *J. Neurosci.* – **21** (9), pp. 3175–3183, 2001.
118. Redish A.D. Beyond the cognitive map: From place cells to episodic memory. – MIT Press: Cambridge MA, 1999.
119. Redish A.D. The hippocampal debate: are we asking the right questions? // *Behav. Brain Res.* – **127** (1–2), pp. 81–98, 2001.
120. Riccio D.C., Millin P.M., Gisquet-Verrier P. Retrograde amnesia: Forgetting back // *Current Directions in Psychological Science*. – **12** (2), pp. 41–44, 2003.
121. Riccio D.C., Moody E.W., Millin P.M. Reconsolidation reconsidered // *Integr. Physiol. Behav. Sci.* – **37** (4), pp. 245–253, 2002.
122. Riedel G., Micheau J. Function of the hippocampus in memory formation: desperately seeking resolution // *Prog. Neuropsychopharmacol. Biol. Psychiatry*. – **25** (4), pp. 835–853, 2001.
123. Rodriguez E., George N., Lachaux J.P., Martinerie J., Renault B., Varela F.J. Perception's shadow: long-distance synchronization of human brain activity // *Nature*. – **397** (6718), pp. 430–433, 1999.
124. Rosenbaum R.S., Kohler S., Schacter D.L., Moscovitch M., Westmacott R., Black S.E., Gao F., Tulving E. The case of K.C.: contributions of a memory-impaired person to memory theory // *Neuropsychologia*. – **43** (7), pp. 989–1021, 2005.
125. Rosenbaum R.S., Winocur G., Moscovitch M. New views on old memories: re-evaluating the role of the hippocampal complex // *Behav. Brain Res.* – **127** (1–2), pp. 183–197, 2001.

126. Ryan L., Nadel L., Keil K., Putnam K., Schnyer D., Trouard T., Moscovitch M. Hippocampal complex and retrieval of recent and very remote autobiographical memories: evidence from functional magnetic resonance imaging in neurologically intact people // *Hippocampus*. – **11** (6), pp. 707–714, 2001.
127. Sara S.J. Strengthening the shaky trace through retrieval // *Nat. Rev. Neurosci.* – **1** (3), pp. 212–213, 2000.
128. Schmidtke K., Vollmer H. Retrograde amnesia: A study of its relation to anterograde amnesia and semantic memory deficits // *Neuropsychologia*. – 1997. **35**, pp. 505–518.
129. Schmolck H., Kensinger E.A., Corkin S., Squire L.R. Semantic knowledge in patient H.M. and other patients with bilateral medial and lateral temporal lobe lesions // *Hippocampus*. – **12** (4), pp. 520–533, 2002.
130. Sella F., Manning L., Seegmuller C., Scheiber C., Schoenfelder F. Pure retrograde amnesia following a mild head trauma: a neuropsychological and metabolic study // *Cortex*. – **38** (4), pp. 499–509, 2002.
131. Shastri L. Episodic memory and cortico-hippocampal interactions // *Trends Cogn. Sci.* – **6** (4), pp. 162–168, 2002.
132. Shimizu E., Tang Y.P., Rampon C., Tsien J.Z. NMDA receptor-dependent synaptic reinforcement as a crucial process for memory consolidation // *Science*. – **290** (5494), pp. 1170–1174, 2000.
133. Simons J.S., Hodges J.R. Transient global amnesia: A review of the recent literature // *Neurocase*. – **6**, pp. 211–230, 2000.
134. Spiers H.J., Maguire E.A., Burgess N. Hippocampal amnesia // *Neurocase*. – **7** (5), pp. 357–382, 2001.
135. Squire L.R., Alvarez P. Retrograde amnesia and memory consolidation: a neurobiological perspective // *Curr. Opin. Neurobiol.* – **5** (2), pp. 169–177, 1995.
136. Squire L.R., Clark R.E., Knowlton B.J. Retrograde amnesia // *Hippocampus*. – **11** (1), pp. 50–55, 2001.
137. Squire L.R., Stark C.E., Clark R.E. The medial temporal lobe // *Annu. Rev. Neurosci.* – **27**, pp. 279–306, 2004.
138. Squire L.R., Zola S.M. Episodic memory, semantic memory, and amnesia // *Hippocampus*. – **8** (3), pp. 205–211, 1998.
139. Vargha-Khadem F., Gadian D.G., Watkins K.E., Connelly A., Van Paesschen W., Mishkin M. Differential effects of early hippocampal pathology on episodic and semantic memory // *Science*. – **277** (5324), pp. 376–380, 1997.
140. Verfaellie M., Koseff P., Alexander M.P. Acquisition of novel semantic information in amnesia: Effects of lesion location // *Neuropsychologia*. – **38** (4), pp. 484–492, 2000.

141. *Vinogradova O.S.* Expression, control, and probable functional significance of the neuronal theta-rhythm // *Prog. Neurobiol.* – **45** (6), pp. 523–583, 1995.
142. *Vinogradova O.S.* Hippocampus as comparator: role of the two input and two output systems of the hippocampus in selection and registration of information // *Hippocampus.* – **11**, pp. 578–598, 2001.
143. *Wheeler M.A., McMillan C.T.* Focal retrograde amnesia and the episodic-semantic distinction // *Cogn. Affect. Behav. Neurosci.* – **1** (1), pp. 22–36, 2001.
144. *Weinberger N.M.* The nucleus basalis and memory codes: auditory cortical plasticity and the induction of specific, associative behavioral memory // *Neurobiol. Learn. Mem.* – **80** (3), pp. 268–284, 2003.
145. *Weinberger N.M.* Specific long-term memory traces in primary auditory cortex // *Nat. Rev. Neurosci.* – **5** (4), pp. 279–290, 2004.
146. *Wiltgen B.J., Brown R.A., Talton L.E., Silva A.J.* New circuits for old memories: the role of the neocortex in consolidation // *Neuron.* – **44** (1), pp. 101–108, 2004.
147. *Winocur G., McDonald R.M., Moscovitch M.* Anterograde and retrograde amnesia in rats with large hippocampal lesions // *Hippocampus.* – **11** (1), pp. 18–26, 2001.
148. *Wittenberg G.M., Sullivan M.R., Tsien J.Z.* Synaptic reentry reinforcement based network model for long-term memory consolidation // *Hippocampus.* – **12** (5), pp. 637–647, 2002.
149. *Wittenberg G.M., Tsien J.Z.* An emerging molecular and cellular framework for memory processing by the hippocampus // *Trends Neurosci.* – **25** (10), pp. 501–505, 2002.
150. *Witter M.P., Wouterlood F.G., Naber P.A., Van Haeflen T.* Anatomical organization of the parahippocampal-hippocampal network // *Ann. NY Acad. Sci.* – **911**, pp. 1–24, 2000.
151. *Yamaguchi S., Hale L.A., D'Esposito M., Knight R.T.* Rapid prefrontal-hippocampal habituation to novel events // *J. Neurosci.* – **24**, pp. 5356–5363, 2004.
152. *Zeineh M.M., Engel S.A., Thompson P.M., Bookheimer S.Y.* Dynamics of the hippocampus during encoding and retrieval of face-name pairs // *Science.* – **299** (5606), pp. 577–580, 2003.

Игумен Феофан (Крюков), кандидат физико-математических наук, игумен Свято-Данилова монастыря. Область научных интересов — теория функций мозга, взаимодействие науки и религии.

Л. Б. ЛИТИНСКИЙ

Институт оптико-нейронных технологий РАН, Москва

E-mail: litin@iont.ru

**ПАРАМЕТРИЧЕСКИЕ НЕЙРОННЫЕ СЕТИ И ДРУГИЕ
АРХИТЕКТУРЫ НА ИХ ОСНОВЕ (ОБЗОР РАБОТ)**

Аннотация

Дается обзор работ по ассоциативным нейронным сетям, выполненных за последние четыре года в ИОНТ РАН. В основу изложения положено описание параметрических нейронных сетей (ПНС), введенных и разработанных авторским коллективом института. ПНС обладают рекордными на сегодняшний день распознающими характеристиками (емкостью памяти, помехоустойчивостью и быстродействием). Акцент сделан на изложении основных идей и принципов.

L. B. LITINSKII

Institute of Optical Neural Technologies, RAS, Moscow

E-mail: litin@iont.ru

**PARAMETRICAL NEURAL NETWORKS AND SOME OTHER
SIMILAR ARCHITECTURES**

Abstract

Some results are considered for associative neural networks (NNs) based on investigations carried out at the Institute of Optical Neural Technologies (IONT) during the last four years. A discussion centers on parametrical neural networks offered and developed by researchers of the IONT. The parametrical NNs have got very high performances (memory capacity, noise stability, operating speed). Basic concepts and features for this kind of neural networks are emphasized.

Введение

Параметрическая нейронная сеть (ПНС) — это вариант ассоциативной памяти, основанный на нелинейно-оптических принципах обработки информации [1, 2]. Элементной базой ПНС являются *параметрические нейроны* — обладающие кубической нелинейностью элементы, способные к преобразованию и генерации частот в процессах параметрического четырехволнового смещения [3]. Нейроны обмениваются между собой квазимонохроматическими импульсами на q различных частотах $\{\omega_L\}_1^q$ с фазами $\phi = \{0/\pi\}$.

Уже первые оценки, сделанные в [1, 2], показали, что при правильно организованной архитектуре такой сети ее емкость памяти в q^2 раз превосходит емкость памяти модели Хопфилда [4, 5]. Резко возрастает и помехоустойчивость сети. Основываясь на этом, был выполнен ряд исследований [6]–[19], в которых удалось, с одной стороны, разобраться в механизмах такого улучшения распознающих характеристик, а с другой — разработать новые эффективные архитектуры.

Адекватным языком описания ПНС оказался векторный формализм — прием, основанный на том, что q различных состояний нейронов изображаются векторами-ортами q -мерного пространства. Правильная организация архитектуры свелась к образованию межнейронных связей по обобщенному хеббовскому правилу с использованием тензорного произведения q -мерных векторов вместо скалярного. Динамика системы векторов нейронов непосредственно копирует стандартную асинхронную динамику, повсеместно используемую в теории нейронных сетей. Векторный формализм позволил увидеть ресурс модели и создать несколько новых архитектур, обладающих теми или иными полезными свойствами. Обзору полученных результатов посвящено это сообщение.

В следующем разделе излагается векторный формализм и описаны две основные ПНС. В заключительном разделе будет рассказано о том, как ПНС можно использовать для создания других нейросетевых архитектур.

ПНС-архитектуры

Векторный формализм

Для описания q различных состояний нейронов будем использовать векторы-орты \mathbf{e}_l пространства \mathbf{R}^q , $q \geq 1$:

$$\mathbf{e}_l = \begin{pmatrix} 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{pmatrix}, \quad l = 1, \dots, q. \quad (1)$$

Состояние i -го нейрона задается вектором \mathbf{x}_i ,

$$\begin{aligned} \mathbf{x}_i &= x_i \mathbf{e}_{l_i}, \quad x_i = \pm 1, \\ \mathbf{e}_{l_i} &\in \mathbf{R}^q, \quad 1 \leq l_i \leq q, \quad i = 1, \dots, N. \end{aligned} \quad (2)$$

Весь N -мерный образ (с q -нарными координатами) задается набором N q -мерных векторов \mathbf{x}_i : $X = (\mathbf{x}_1, \dots, \mathbf{x}_N)$, а M исходных образов (*паттернов*) — это M наперед заданных подобных наборов:

$$\begin{aligned} X^{(\mu)} &= (\mathbf{x}_1^{(\mu)}, \mathbf{x}_2^{(\mu)}, \dots, \mathbf{x}_N^{(\mu)}), \quad \mathbf{x}_i^{(\mu)} = x_i^{(\mu)} \mathbf{e}_{l_i^{(\mu)}}, \\ x_i^{(\mu)} &= \pm 1, \quad 1 \leq l_i^{(\mu)} \leq q, \quad \mu = 1, \dots, M. \end{aligned} \quad (3)$$

(Апеллируя к первоначальной нелинейно-оптической модели поясним, что бинарная переменная x_i моделирует наличие у квазимонохроматических импульсов фазы $\phi = \{0/\pi\}$, а орты \mathbf{e}_l отвечают наличию q различных частот ω_l .)

Локальное поле на i -м нейроне имеет, как всегда, вид

$$\mathbf{h}_i = \frac{1}{N} \sum_{j=1}^N \mathbf{T}_{ij} \mathbf{x}_j,$$

где $(q \times q)$ -матрица \mathbf{T}_{ij} задает межсвязь между i -м и j -м нейронами. Межсвязи выбираются в обобщенном хеббовском виде:

$$\mathbf{T}_{ij} = (1 - \delta_{ij}) \sum_{\mu=1}^M \mathbf{x}_i^{(\mu)} \mathbf{x}_j^{(\mu)+}, \quad i, j = 1, \dots, N, \quad (4)$$

где \mathbf{x}^+ означает q -мерную вектор-строку, а через $\mathbf{x}\mathbf{y}^+$ обозначено произведение вектор-столбца \mathbf{x} на вектор-строку \mathbf{y}^+ , выполняемое по правилам матричного умножения.

Матрицы \mathbf{T}_{ij} в выражении для локального поля \mathbf{h}_i действуют на векторы $\mathbf{x}_j \in \mathbf{R}^q$. После суммирования по всем j локальное поле на i -м нейроне есть некая линейная комбинация ортов \mathbf{e}_l . Динамическое правило, копирующее асинхронную динамику, задается следующим образом: i -й нейрон в момент времени $t + 1$ ориентируется в направлении, ближайшем к направлению локального поля \mathbf{h}_i в момент времени t . Или, подробнее: если в момент времени t

$$\mathbf{h}_i(t) = \sum_{l=1}^q A_l^{(i)} \mathbf{e}_l,$$

где

$$A_l^{(i)} \sim \sum_{j(\neq i)}^N \sum_{\mu=1}^M (\mathbf{e}_l \mathbf{x}_i^{(\mu)}) (\mathbf{x}_j^{(\mu)} \mathbf{x}_j(t))$$

и $A_k^{(i)}$ есть наибольшая по модулю амплитуда,

$$|A_k^{(i)}| = \max_{1 \leq l \leq q} |A_l^{(i)}|,$$

то

$$\mathbf{x}_i(t+1) = \text{sign}(A_k^{(i)}) \mathbf{e}_k.$$

Эволюция системы состоит в последовательной ориентации векторов-нейронов по этому правилу. Нетрудно показать, что при этом энергия состояния

$$E(t) \sim - \sum_{i=1}^N \mathbf{x}_i^+(t) \mathbf{h}_i(t)$$

монотонно убывает. В конце концов система свалится в локальный минимум по энергии, являющийся неподвижной точкой сети.

Данная модель получила название ПНС-2. При $q = 1$ она превращается в обычную модель Хопфилда.

Распознающие характеристики ПНС-2

Оценки распознающих характеристик ПНС-2 даны в [6]–[10]. Их можно получить стандартными теоретико-вероятностными рассуждениями [4],

разделяя локальное поле \mathbf{h}_i на две составляющие — *полезный сигнал* и *внутренний шум* — и вычисляя их средние значения и дисперсии. В отличие от (описанной в [4]) стандартной ситуации, парциальные шумовые компоненты будут здесь не независимыми случайными величинами, но только некоррелированными. Это не позволяет использовать центральную предельную теорему для оценки характеристик внутреннего шума. Можно, однако, воспользоваться статистической техникой Чебышева-Чернова [21], которая и в случае некоррелированных случайных величин позволяет получить экспоненциальную часть оценки.

Все вычисления аккуратно проделаны в [9]. Оказывается, что дисперсия внутреннего шума уменьшается по сравнению с моделью Хопфилда в q^2 раз. Связано это только с тем, что громадное большинство произведений $\mathbf{x}_i^{(\mu)} \mathbf{x}_j^{(\mu)+} \mathbf{x}_j$, возникающих при вычислении парциальных шумовых компонент, обращается в ноль; дисперсия внутреннего шума при этом уменьшается. Тогда как при аналогичных вычислениях для модели Хопфилда возникают произведения $x_i^{(\mu)} x_j^{(\mu)} x_j$, каждое из которых может равняться только ± 1 и неизбежно вносит свой вклад в увеличение дисперсии.

Запишем окончательное выражение для вероятности ошибки распознавания поданного на вход сети искаженного паттерна. Пусть a — вероятность искажения координат паттерна по спиновой переменной x_i (по фазе), b — вероятность искажения его координат по одному из q возможных направлений (на языке параметрических нейронов — вероятность искажения по частоте). Тогда, для рандомизированного набора паттернов (3) получаем оценку вероятности неправильного распознавания паттерна:

$$\Pr_{err} < \sqrt{NM} \cdot \exp\left(-\frac{N(1-2a)^2}{2M} \cdot q^2(1-b)^2\right). \quad (5)$$

При $M, N \rightarrow \infty$ эта вероятность стремится к нулю, если число паттернов M не превосходит критического значения

$$M_c = \frac{N(1-2a)^2}{2 \ln N} \cdot q^2(1-b)^2. \quad (6)$$

Последнюю величину можно рассматривать как асимптотически достижимую емкость памяти ПНС-2.

При $q = 1$ эти выражения превращаются в известные результаты для модели Хопфилда (в этом случае шум по частоте отсутствует и следует положить $b = 0$). С ростом q экспоненциально спадает вероятность ошибки

распознавания — существенно растет помехоустойчивость сети. Одновременно, пропорционально q^2 растет и емкость памяти M_c . Если иметь в виду обработку цветных изображений, то нейроны суть пиксели экрана. Стандарты, принятые при компьютерной обработке изображений, позволяют считать, что число различных состояний нейронов $q \sim 10^2$ (число различных цветов). При таком q емкость памяти ПНС-2 превосходит емкость памяти модели Хопфилда на 4 порядка.

В любом случае, ПНС-2 позволяет хранить число паттернов, во много раз превосходящее число нейронов N . Например, зададимся уровнем надежности распознавания $\text{Pr}_{rec} = 1 - \text{Pr}_{err} = 0.99$. В модели Хопфилда с такой надежностью распознавания можно хранить только $M = N/10$ паттернов, уровень искажений которых не может превышать 30%. В то же время, ПНС-2 при $q = 64$ способна восстанавливать любой из $M = 5N$ паттернов с искажениями до 90% или любой из $M = 50N$ паттернов с искажениями до 65%. Компьютерные эксперименты подтверждают эти оценки.

ПНС-3

С точки зрения реализации ПНС в виде электронно-оптического устройства представляет интерес тот ее вариант, когда у квазимонохроматических импульсов (которыми обмениваются параметрические нейроны) отсутствует фаза. На векторном языке это означает, что для описания различных состояний нейронов используются только орты \mathbf{e}_l , а спиновая переменная x_i отсутствует:

$$\mathbf{x}_i = \mathbf{e}_{l_i}, \quad \mathbf{e}_{l_i} \in \mathbf{R}^q, \quad 1 \leq l_i \leq q, \quad i = 1, \dots, N.$$

Нейроны могут теперь находиться в одном из q состояний, тогда как в ПНС-2 число различных состояний равно $2q$ (за счет спиновой переменной x_i).

Эта модель получила название ПНС-3 и была рассмотрена в [12, 15]. Оказалось, что для этой модели невозможно провести описанную выше схему рассуждений: парциальные шумовые компоненты становятся здесь коррелированными, что ведет к катастрофическому нарастанию дисперсии внутреннего шума. Прием, который позволяет выйти из затруднения, аналогичен тому, что применяется в *редком кодировании* [22]–[24]: конструируя матрицы межсвязей \mathbf{T}_{ij} , из вектор-координат $\mathbf{x}_i^{(\mu)}$ необходимо

вычесть среднее значение нейронной активности по паттерну, которое в данном случае равно \mathbf{e}/q , где вектор \mathbf{e} есть сумма всех ортов \mathbf{e}_l :

$$\mathbf{e} = \sum_{l=1}^q \mathbf{e}_l.$$

Иными словами, если вместо выражения (4) для матриц межсвязей \mathbf{T}_{ij} использовать

$$\mathbf{T}_{ij} = (1 - \delta_{ij}) \sum_{\mu=1}^M (\mathbf{x}_i^{(\mu)} - \mathbf{e}/q)(\mathbf{x}_j^{(\mu)} - \mathbf{e}/q)^+, \quad i, j = 1, \dots, N, \quad (7)$$

парциальные шумовые компоненты становятся некоррелированными и можно осуществить всю описанную в предыдущем пункте программу. Аналогами оценок (5) и (6) здесь будут:

$$\text{Pr}_{err} < \sqrt{NM} \cdot \exp\left(-\frac{N}{2M} \cdot \frac{q(q-1)}{2}(1-\bar{b})^2\right). \quad (8)$$

и

$$M_c = \frac{N}{2 \ln N} \cdot \frac{q(q-1)}{2}(1-\bar{b})^2, \quad \text{где } \bar{b} = \frac{q}{q-1} b. \quad (9)$$

По сравнению с ПНС-2 емкость памяти ПНС-3 уменьшилась вдвое. Это связано с тем, что в ПНС-3 число состояний нейронов в 2 раза меньше, чем в ПНС-2. В целом, обе модели очень близки по своим характеристикам.

Замечание. ПНС-3 является очищенным от ненужных сложностей вариантом *Поттс-стекольной нейросети*, впервые исследованной 15 лет назад [24], когда активно разрабатывались модели q -нарных ассоциативных нейросетей. Неудачно выбранные обозначения и сжатый стиль изложения создали публикации [24] репутацию заумного и малопонятного текста. На самом деле Поттс-стекольная нейросеть и ПНС-3 почти в точности совпадают. В обеих моделях матрицы межсвязей \mathbf{T}_{ij} определяются с помощью векторов $\mathbf{x}_l = \mathbf{e}_l - \mathbf{e}/q$, которые в Поттс-стекольной модели используются и для описания q различных состояний нейронов; в ПНС-3 для этой цели служат орты \mathbf{e}_l . Распознающие характеристики ПНС-3 и Поттс-стекольной модели идентичны.

В заключение раздела еще раз обратим внимание на то, что с ростом числа состояний q распознающие характеристики ПНС улучшаются. Это свойство ПНС будет активно использовано в следующем разделе.

Другие архитектуры на основе ПНС

Замечательные распознающие характеристики ПНС могут быть использованы для создания других архитектур, ориентированных на решение тех или иных специальных задач. *Декоррелирующая ПНС* позволяет хранить полиномиально много бинарных паттернов, и, что особенно важно, даже когда эти паттерны сильно коррелированы. Другой вариант — это *q-нарный идентификатор*, который позволяет на порядки ускорить процесс распознавания и уменьшить физическую память, необходимую для хранения межсвязей.

Декоррелирующая ПНС

Известно, что корреляции между бинарными паттернами катастрофически сказываются на емкости памяти модели Хопфилда. Выходом из положения является *редкое кодирование* [22]–[24]. Декоррелирующая ПНС [11, 13, 14] составляет альтернативу этому подходу.

Основная идея декоррелирующей ПНС такова: бинарные паттерны отображаются в промежуточное, внутреннее представление, использующее векторы-нейроны большой размерности q . Затем на векторно-нейронных паттернах строится ПНС-2. Свойства отображения таковы, что, во-первых, корреляции между векторно-нейронными паттернами становятся пренебрежимо малыми; и, во-вторых, размерность q векторов-нейронов растет экспоненциально по параметру отображения. Поскольку распознающие характеристики ПНС тем лучше, чем больше размерность векторов-нейронов, можно ожидать существенного увеличения емкости памяти сети.

Алгоритм отображения бинарных паттернов в векторно-нейронное представление очень прост. Пусть имеется N -мерный бинарный вектор $Y = (y_1, y_2, \dots, y_N)$, $y_i = \pm 1$. Разобьем его мысленно на n фрагментов, каждый из которых содержит $k + 1$ координат: $N = n(k + 1)$. Каждому фрагменту сопоставим снабженное знаком целое число по правилу: 1) первый элемент фрагмента определяет знак целого числа; 2) остальные k элементов фрагмента — абсолютное значение целого числа l :

$$l = 1 + \sum_{i=2}^{k+1} (y_i + 1) \cdot 2^{k-i}, \quad 1 \leq l \leq 2^k.$$

(Фактически, последние k элементов фрагмента используются как двоич-

ная запись целого числа l .)

После этого сопоставим бинарному фрагменту $(y_1, y_2, \dots, y_{k+1})$ вектор $\mathbf{x} = \pm \mathbf{e}_l$, где \mathbf{e}_l есть орт q -мерного пространства \mathbf{R}^q размерности $q = 2^k$, а знак вектора определяется первым элементом фрагмента. Иными словами, отображение бинарного фрагмента в q -мерный вектор происходит следующим образом:

$$(y_1, y_2, \dots, y_{k+1}) \rightarrow \pm l \rightarrow \mathbf{x} = \pm \mathbf{e}_l \in \mathbf{R}^q, \quad q = 2^k. \quad (10)$$

По этой схеме весь бинарный вектор $Y \in \mathbf{R}^N$ может быть взаимно-однозначно отображен в набор из n q -мерных ортов:

$$Y = (y_1, \dots, y_{k+1}, \dots, y_{N-k}, \dots, y_N) \rightarrow X = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n).$$

Результат такого отображения называется *внутренним образом* бинарного вектора Y . Число k называется *параметром отображения*.

Проделав такое отображение для данного набора бинарных паттернов $\{Y^{(\mu)}\}_1^M$, получим векторно-нейронные образы $\{X^{(\mu)}\}_1^M$, на которых строится ПНС-2. Отметим, что при сколь угодно коррелированных бинарных паттернах $Y^{(\mu)}$ их векторно-нейронные образы можно рассматривать как рандомизированные. Таковы свойства отображения (10) — оно практически устраняет корреляции между паттернами. Действительно, достаточно двум бинарным фрагментам различаться хотя бы в одной координате, и фрагменты отображаются в два совершенно разных, ортогональных друг другу орта пространства \mathbf{R}^q .

Теперь можно воспользоваться приведенными выше оценками для емкости памяти ПНС-2. Если, как и раньше, a есть вероятность искажения бинарных координат (уровень искажений исходных паттернов), то подстановка параметров сконструированной векторно-нейронной сети в (5) дает:

$$M_c \sim \frac{N(1-2a)^2}{2 \ln N} \cdot \frac{(2(1-a))^{2k}}{k(1+k/\ln N)}.$$

Первый сомножитель в правой части есть емкость памяти модели Хопфилда (в отсутствие корреляций!), а второй сомножитель дает экспоненциальный по параметру отображения k рост емкости памяти, поскольку всегда выполняется $2(1-a) > 1$.

Необходимо, однако, проявить осторожность: параметр k нельзя брать произвольно большим. Во-первых, число n векторов-нейронов должно

быть достаточно велико, чтобы можно было применять теоретико-вероятностные оценки. Это приводит к требованию $k \ll N$. Во-вторых, среди векторов-нейронов искаженного образа должен быть хотя бы один неискаженный — чтобы его вклад в локальное поле позволил восстановить правильное значение координаты паттерна. Из тех же соображений следует, что лучше бы неискаженных векторов-нейронов было не меньше двух. Поскольку число неискаженных вектор-координат образа равно $n(1-a)^{k+1}$, это дает еще одно ограничение: $n(1-a)^{k+1} \geq 2$. Аккуратный учет обоих этих требований позволяет выразить максимально возможное значение k_c через N и a . Когда k меняется от 0 до k_c , емкость памяти сети растет экспоненциально. Когда k становится больше k_c , сеть перестает распознавать паттерны. Однако, еще до достижения предельного значения k_c , емкость памяти может быть сделана достаточно большой. Например, при уровне искажений $a = 0.1$ максимально возможная емкость памяти $M_c \sim N^6$, при уровне искажений $a = 0.2$ она составляет $M_c \sim N^3$, а при $a = 0.3$ равняется $M_c \sim N^{1.5}$. Подчеркнем, что эти результаты справедливы при любой степени коррелированности исходных бинарных паттернов.

q -нарный идентификатор

Основная идея данной архитектуры [14, 17, 18] основана на том наблюдении, что когда сеть работает не на пределе своих возможностей (когда число паттернов хотя бы на порядок меньше критического значения M_c), восстановление правильного значения текущей координаты происходит сразу, при первой обработке этой координаты. Иными словами, для восстановления паттерна сеть пробегает по всем координатам всего один раз. Тогда можно попытаться осуществить следующую программу.

Имеем M паттернов, каждый из которых описывается набором N координат, принимающих q различных значений. Пронумеруем все паттерны и запишем их номера в q -ичной системе счисления, для чего потребуется n q -ичных позиций (связь между n , q и N будет проанализирована позже). Отнесемся к этим n q -ичным числам как к дополнительным координатам паттерна: просто автоматически присоединим эти новые n координат к описанию паттерна. Если раньше размерность паттерна была N , то теперь она станет $N + n$. Затем на M паттернах расширенной размерности $N + n$ строится сеть типа ПНС-3, с матрицами межсвязей как в выражении (7). Однако межсвязи эти «прокинуты» только от N «настоящих» нейронов к n «нумерующим», а все остальные $N^2 + n^2$ связей оборваны.

Когда на вход такой сети поступит искаженный паттерн, сеть будет восстанавливать только его нумерующие координаты. Если мы находимся в условиях, когда правильное значение координаты восстанавливается сетью сразу, без многократных пробегов по всему паттерну, номер паттерна будет восстановлен сразу. Ну а если мы знаем номер паттерна, больше нам ничего и не требуется.

Число нумерующих координат паттерна n должно быть таким, чтобы n^q равнялось критической емкости памяти ПНС-3 (9), уменьшенной, скажем, в 10 раз. Из этого требования легко получить асимптотическую оценку для n :

$$n \sim 2 + \frac{\ln N}{\ln q}, \quad N, q \gg 1.$$

Например, при числе пикселей экрана $N \sim 10^4$ и числе цветов $q \sim 10^2$ получаем, что $n \approx 4$. Иначе говоря, число искусственно введенных нумерующих координат пренебрежимо мало.

Достоинства q -нарного идентификатора очевидны. Во-первых, существенно ускоряется процесс распознавания — сеть должна восстановить правильные значения всего $n \sim 4-5$ координат. И, во-вторых, резко уменьшаются затраты на физическую память, необходимую для хранения межсвязей T_{ij} : таких матриц теперь требуется только Nn , а не $(N+n)^2$.

Сеть в данном случае перестает быть авто-ассоциативной и работает как q -нарный перцептрон, межсвязи которого устроены по обобщенному хеббовскому правилу (7). Отсутствует и процедура распознавания паттерна (восстановления правильных значений его координат). Вместо этого происходит идентификация номера паттерна. Поэтому данная архитектура получила название q -нарный идентификатор. Компьютерное моделирование показало ее высокую работоспособность.

В заключение необходимо сказать, что освоение ассоциативных нейронных сетей для практического применения фактически еще не начиналось. По-видимому, это вызвано невысокими распознающими характеристиками модели Хопфилда. В этом плане ПНС оказались очень плодотворной и многообещающей архитектурой. Можно надеяться, что разработка ПНС и нейросетей на их основе послужит активизации интереса как к теории ассоциативных нейронных сетей, так и к их практическому применению.

Работа выполнялась в рамках проекта «Интеллектуальные компьютерные системы» (программа 2.45) при финансовой поддержке грантом РФФИ 04-07-90038.

Литература

1. Крыжановский Б.В., Микаэлян А.Л. О распознающей способности нейронной сети на нейронах с параметрическим преобразованием частот // *ДАН (мат.-физ.)*, т. 383(3), стр. 318-321, 2002.
2. Fonarev A., Kryzhanovsky B.V. et al. Parametric dynamic neural network recognition power // *Optical Memory & Neural Networks*, vol. 10(4), pp. 31- 48, 2001.
3. Бломберген Н. Нелинейная оптика. М.: Мир, 1966.
4. Hertz J., Krogh A., Palmer R. Introduction to the Theory of Neural Computation. NY: Addison-Wesley, 1991.
5. Ежов А.А., Шумский С.А. Нейрокомпьютинг и его приложения. М.: МИФИ, 1998.
6. Крыжановский Б.В., Литинский Л.Б. О векторной модели параметрической нейросети // *Искусственный интеллект*. – 2002, т. 4, стр. 710-718.
7. Kryzhanovsky B.V., Litinskii L.B., Fonarev A. Parametrical neural network based on the four-wave mixing process // *Nuclear Instruments and Methods in Physics Research. Section A*. – 2003, v. 502. – pp. 517-519.
8. Крыжановский Б.В., Литинский Л.Б. Векторные модели ассоциативной памяти // V Всероссийская н/т конференция. *Лекции по нейроинформатике*, т. 1. – М: МИФИ, 2003. – с. 72-85.
9. Крыжановский Б.В., Литинский Л.Б. Векторные модели ассоциативной памяти // *Автоматика и телемеханика*. – 2003, № 11. – с. 152-165.
10. Kryzhanovsky B.V., Litinskii L.B., Mikaelian A.L. Parametrical neural network // *Optical Memory & Neural Networks*. – 2003, v. 12(3). – pp. 138-156.
11. Крыжановский Б.В., Микаэлян А.Л. Ассоциативная память, способная распознавать сильно коррелированные образы // *ДАН (информатика)*. – 2003, т. 390(1). – с. 27-31.
12. Алиева Д.И., Крыжановский Б.В. Бесфазовая модель параметрической нейронной сети // *Международная конференция по искусственному интеллекту (IEEE AIS'2003)*. М.: Физматлит, 2003. – с. 511-517,
13. Kryzhanovsky B., Litinskii L., Fonarev A. An effective associative memory for pattern recognition // In: *Advances in Intelligent Data Analysis V*. 5th International Symposium on Intelligent Data Analysis (IDA 2003), Berlin: Springer, 2003. – pp. 179-186.
14. Kryzhanovsky B.V., Kryzhanovsky V.M., Fonarev A.B. Decorrelating parametrical neural network // In: *Proceedings of International Joint Conference on Neural Network-2005 (IJCNN05)*, Montreal, 2005, pp. 153-157.

15. Крыжановский Б.В., Литинский Л.Б., Микаэлян А.Л. Векторно-нейронные модели ассоциативной памяти // *Информационные технологии и вычислительные системы*. – 2004, № 1. – с. 68–81.
16. Крыжановский Б.В., Крыжановский В.М. Быстрая система распознавания и принятия решений на основе векторной нейросети // *Искусственный интеллект*. – 2004, № 4. – с. 534–541.
17. Kryzhanovsky B.V., Mikaelian A.L., Fonarev A.B. Vector neural net identifying many strongly distorted and correlated patterns // *Int. Conf. on Information Optics and Photonics Technology*, Photonics Asia-2004, Beijing-2004. Proc. of SPIE, vol. 5642, pp. 124–133.
18. Kryzhanovsky B.V., Kryzhanovsky V.M., Magomedov B.M., Mikaelian A.L. Vector perceptron as fast search algorithm // *Optical Memory & Neural Network*. – 2004. – vol. 13, No. 2. – pp. 103–108.
19. Alieva D.I., Kryzhanovsky B.V., Kryzhanovsky V.M., Fonarev A.B. q -valued neural network as a system of fast identification and pattern recognition // *Pattern Recognition and Image Analysis*. – 2005. – Vol. 15, No. 1. – pp. 30–33.
20. Kryzhanovsky B.V., Mikaelian A.L., Koshelev V.N. et al. On recognition error bound for associative Hopfield memory // *Optical Memory & Neural Networks*. – 2000. – vol. 9(4). – pp. 267–276.
21. Perez-Vicente C.J., Amit D.J. Optimized network for sparsely coded patterns // *Journal of Physics A*. – 1989. – vol. 22. – pp. 559–569.
22. Palm G., Sommer F.T. Information capacity in recurrent McCulloch-Pitts networks with sparsely coded memory states // *Network*. – 1992. – vol. 3. – pp. 1–10.
23. Frolov A.A., Murav'ev I.P. Informational characteristics of neural networks capable of associative learning based on Hebbian plasticity // *Network*. – 1995. – vol. 4. – pp. 495–536.
24. Kanter I. Potts-glass models of neural networks // *Phys. Rev. A*. – 1988, vol. 37. – pp. 2739–2742.

Леонид Борисович ЛИТИНСКИЙ, старший научный сотрудник, кандидат физико-математических наук, заведующий сектором динамических нейронных сетей в Институте оптико-нейронных технологий РАН. Область научных интересов: ассоциативные нейронные сети, распознавание образов, многоэкстремальные задачи. Автор более 30 научных публикаций.

НАУЧНАЯ СЕССИЯ МИФИ-2006

НЕЙРОИНФОРМАТИКА–2006

VIII ВСЕРОССИЙСКАЯ
НАУЧНО-ТЕХНИЧЕСКАЯ
КОНФЕРЕНЦИЯ

ЛЕКЦИИ
ПО НЕЙРОИНФОРМАТИКЕ

Оригинал-макет подготовлен Ю. В. Тюменцевым
с использованием издательского пакета $\LaTeX 2_{\epsilon}$
и набора PostScript-шрифтов PSCyr

Подписано в печать 21.11.2005 г. Формат 60 × 84 1/16
Печ. л. 15,25. Тираж 190 экз. Заказ №

*Московский инженерно-физический институт
(государственный университет)
Типография МИФИ
115409, Москва, Каширское шоссе, 31*