

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ  
РОССИЙСКОЙ ФЕДЕРАЦИИ  
ФЕДЕРАЛЬНОЕ АГЕНТСТВО ПО АТОМНОЙ ЭНЕРГИИ  
РОССИЙСКАЯ АКАДЕМИЯ НАУК  
РОССИЙСКАЯ АССОЦИАЦИЯ НЕЙРОИНФОРМАТИКИ  
МОСКОВСКИЙ ИНЖЕНЕРНО-ФИЗИЧЕСКИЙ ИНСТИТУТ  
(ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ)  
ИНСТИТУТ ОПТИКО-НЕЙРОННЫХ ТЕХНОЛОГИЙ РАН

---

**НАУЧНАЯ СЕССИЯ МИФИ–2007**

**НЕЙРОИНФОРМАТИКА–2007**

**IX ВСЕРОССИЙСКАЯ  
НАУЧНО-ТЕХНИЧЕСКАЯ  
КОНФЕРЕНЦИЯ**

**ЛЕКЦИИ  
ПО НЕЙРОИНФОРМАТИКЕ  
Часть 2**

По материалам Школы-семинара  
«Современные проблемы нейронинформатики»

Москва 2007

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

**НАУЧНАЯ СЕССИЯ МИФИ–2007. IX ВСЕРОССИЙСКАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ «НЕЙРОИНФОРМАТИКА–2007»: ЛЕКЦИИ ПО НЕЙРОИНФОРМАТИКЕ. Часть 2.** – М.: МИФИ, 2007. – 148 с.

В книге публикуются тексты лекций, прочитанных на Школе-семинаре «Современные проблемы нейроинформатики», проходившей 24–26 января 2007 года в МИФИ в рамках IX Всероссийской конференции «Нейроинформатика–2007».

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

Ответственный редактор  
*Ю. В. Тюменцев*, кандидат технических наук

ISBN 5–7262–0708–4    © *Московский инженерно-физический институт  
(государственный университет), 2007*

## Содержание

<b>Предисловие</b>	<b>5</b>
<b>С. А. Терехов. Гениальные комитеты умных машин</b>	<b>11</b>
Введение: Почему вообще возможно повышение точности? . . .	12
Бустинг (усиление) ансамбля классификаторов . . . . .	17
Ранние варианты бустинга . . . . .	18
Семейство алгоритмов AdaBoost . . . . .	20
Обсуждение AdaBoost . . . . .	24
Параллельные ансамбли равноправных моделей . . . . .	28
Комбинирование классификаторов с использованием бут- стрепа . . . . .	28
Почему бэггинг работает? . . . . .	30
Бэггинг-комитеты, обучаемые в реальном времени . . . . .	31
Специализация экспертов и другие методы . . . . .	32
Карты экспертов . . . . .	33
Смеси экспертов . . . . .	33
Распределенное обучение экспертов на фрагментах данных	35
Перспективы . . . . .	37
Благодарности . . . . .	38
Литература . . . . .	38
Приложение. Большие наборы данных для экспериментов . . . .	41
Задачи . . . . .	41
Задача 1. Созидательное (?) разрушение . . . . .	41
Задача 2. Вероятность ошибки алгоритма Boost1 . . . . .	42
Задача 3. (Без решения) . . . . .	42
<b>Ю. Р. Цой. Введение в нейроэволюционный подход: основные кон- цепции и приложения</b>	<b>43</b>
Введение . . . . .	44
Эволюционные алгоритмы . . . . .	44
 УДК 001(06)+004.032.26 (06) Нейронные сети	 3

Адаптация в ЭА . . . . .	49
Проблема формирования обучающего множества данных для ИНС	52
Нейроэволюционный подход . . . . .	53
Эволюционная настройка весов связей ИНС . . . . .	53
Эволюционная настройка структуры ИНС . . . . .	56
Одновременная эволюционная настройка весов связей и струк- туры ИНС . . . . .	58
Приложения НЭ-подхода . . . . .	60
НЭ алгоритмы в мире . . . . .	65
Заключение . . . . .	67
Благодарности . . . . .	68
Литература . . . . .	68
<b>В. Я. Сергин. Биологически правдоподобная модель зрительного вос- приятия: Иерархия объемлющих сенсорных характеристик</b>	<b>77</b>
Введение . . . . .	78
Объемлющие сенсорные характеристики . . . . .	84
Формирование объемлющих характеристик . . . . .	89
Нисходящая стимуляция . . . . .	98
Мозг обнаруживает сенсорные объекты, а не комбинирует их из признаков . . . . .	104
Компьютерные эксперименты по распознаванию трехмерных объ- ектов . . . . .	109
Заклучение . . . . .	115
Литература . . . . .	117
<b>В. Л. Введенский. Построение смыслового пространства языка че- ловека</b>	<b>121</b>
Введение . . . . .	122
Базовый словарный состав языка . . . . .	124
Строение корней слов индоевропейских языков . . . . .	127
Пространство близости языков . . . . .	129
Множество корней глаголов . . . . .	131
Усвоение языка детьми . . . . .	138
Пространство смысловой близости слов . . . . .	139
Заклучение . . . . .	145
Литература . . . . .	146

## ПРЕДИСЛОВИЕ

1. В этой книге содержатся тексты ряда лекций, прочитанных на Седьмой Школе-семинаре «Современные проблемы нейроинформатики», проходившей 24–26 января 2007 года в МИФИ в рамках IX Всероссийской научно-технической конференции «Нейроинформатика–2007» (они включены в Часть 2 данного сборника), а также тексты трех лекций, представленных на Шестой Школе-семинаре, не вошедшие по ряду причин в состав сборника [9] (они включены в Часть 1).

При отборе и подготовке материалов для лекций авторы и редактор следовали принципам и подходам, сложившимся при проведении шести предыдущих Школ (см. [1–9]). А именно, основной целью Школы было, как всегда, рассказать слушателям о современном состоянии и перспективах развития важнейших направлений в теории и практике нейроинформатики, о ее применениях.

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

2. В Части 1 данного сборника публикуются тексты трех лекций из программы Шестой Школы-семинара, не вошедшие ранее в состав сборника [9]:

1. *А. А. Ежов*. Сознание, рефлексия и многоагентные системы.
2. *Н. Г. Макаренко*. Стохастическая динамика, марковские модели и прогноз.
3. *В. Кецман*. Новый SVM-алгоритм для сверхбольших наборов данных.

3. В программу Седьмой Школы-семинара «Современные проблемы нейроинформатики» на конференции «Нейроинформатика–2007» вошли следующие шесть лекций:

1. *В. Я. Сергин*. Биологически правдоподобная модель зрительного восприятия: Иерархия объемлющих сенсорных характеристик.
2. *А. А. Фролов*. Что такое интерфейс мозг-компьютер.
3. *С. А. Терехов*. Гениальные комитеты умных машин.

4. Ю. Р. Цой. Введение в нейроэволюционный подход: Основные концепции и приложения.
5. Н. Г. Макаренко. Топология изображений.
6. В. Л. Введенский. Построение смыслового пространства языка человека.

Четыре из перечисленных выше шести лекций публикуются в данном сборнике (в Части 2), две лекции (А. А. Фролова и Н. Г. Макаренко) в силу технических причин будут опубликованы в сборнике лекций следующей Школы-семинара.

4. В лекции **А. А. Ежова** «Сознание, рефлексия и многоагентные системы» предпринимается попытка нащупать пути решения проблемы сознания в рамках концепции многоагентных систем. Достаточно распространенной является точка зрения, согласно которой базой для решения данной проблемы должна служить квантовая механика. В лекции показано, что необходимо также использование аппарата статистической физики.

5. Лекция **Н. Г. Макаренко** «Стохастическая динамика, марковские модели и прогноз» продолжает серию выступлений автора, призванных обратить внимание нейроинформационного сообщества на ряд разделов математики, перспективных с точки зрения использования их при решении задач нейроинформатики. В данной лекции представлен новый метод марковского предсказания временных рядов, основанный на инвариантной мере случайной динамики, реализованной через сжимающие отображения, снабженные вероятностями (систему итеративных функций).

6. В лекции **В. Кецмана** «Новый SVM-алгоритм для сверхбольших наборов данных» рассматривается случай работы со сверхбольшими наборами данных (порядка нескольких миллионов обучающих пар). Дается сравнение нейронных сетей и машин опорных векторов с точки зрения решения задач классификации (распознавания образов) и регрессии (аппроксимации функций). Для решения задач рассматриваемого класса предлагается новый итерационный алгоритм, получивший наименование ISDA (Iterative Single Data Algorithm), основывающийся на последовательном использовании обучающих пар данных из имеющегося обучающего набора.

7. В лекции **В. Я. Сергина** «Биологически правдоподобная модель зрительного восприятия: Иерархия объемлющих сенсорных характеристик» вводится понятие объемлющей характеристики. Она представляет собой ответ данного перцептивного уровня на сенсорные признаки уровня, лежащего ниже, такие, что их специфическое сочетание составляет адаптивно

значимую целостность. Последовательность таких характеристик образует иерархию, от сенсорных признаков до целостных образов и сцен.

**8. Лекция С. А. Терехов** «Гениальные комитеты умных машин» посвящена актуальной проблеме повышения точности обучения машин путем объединения их в комитеты. Основная цель ее состоит в обсуждении алгоритмов для обработки очень больших наборов обучающих данных, пригодных к использованию на современных и перспективных многоядерных компьютерах.

**9. В лекции Ю. Р. Цоя** «Введение в нейроэволюционный подход: Основные концепции и приложения» дается обзор исследований, находящихся на стыке искусственных нейронных сетей и эволюционных вычислений. Проанализированы преимущества и недостатки нейроэволюционного подхода при решении задач эволюционной настройки весов и структуры нейросетей. Рассматривается применение нейроэволюционных алгоритмов при решении задач адаптивного управления, адаптивного поведения, многоагентных систем, эволюционной робототехники, поиска игровых стратегий и компьютерного творчества.

**10. Лекция В. Л. Введенского** «Построение смыслового пространства языка человека» посвящена изложению нетрадиционного подхода к проблеме представления человеческого языка в форме, приемлемой для компьютера. Объектом исследования является множество словарей разных языков. Было обнаружено, что устройство лексиконов разных языков подчиняется строгим математическим закономерностям, опираясь на которые, можно установить способ представления языка в мозге человека. Полученные результаты могут быть полезны для разработки систем речевого контакта с компьютером.

\* \* \*

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 [10] 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 [11], недавно открывшийся поисковый сервис Google Scholar [12], а также портал научных вычислений [13].

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 [1–9].

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](mailto:tium@mai.ru) Тюменцеву Юрию Владимировичу.

## Литература

1. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // III Всероссийская научно-техническая конференция «Нейроинформатика-2001», 23–26 января 2001 г. / Отв. ред. Ю. В. Тюменцев. – М.: Изд-во МИФИ, 2001. – 212 с.

2. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // IV Всероссийская научно-техническая конференция «Нейроинформатика-2002», 23–25 января 2002 г. / Отв. ред. Ю. В. Тюменцев. Часть 1. – М.: Изд-во МИФИ, 2002. – 164 с.
3. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // IV Всероссийская научно-техническая конференция «Нейроинформатика-2002», 23–25 января 2002 г. / Отв. ред. Ю. В. Тюменцев. Часть 2. – М.: Изд-во МИФИ, 2002. – 172 с.
4. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // V Всероссийская научно-техническая конференция «Нейроинформатика-2003», 29–31 января 2003 г. / Отв. ред. Ю. В. Тюменцев. Часть 1. – М.: Изд-во МИФИ, 2003. – 188 с.
5. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // V Всероссийская научно-техническая конференция «Нейроинформатика-2003», 29–31 января 2003 г. / Отв. ред. Ю. В. Тюменцев. Часть 2. – М.: Изд-во МИФИ, 2003. – 180 с.
6. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // VI Всероссийская научно-техническая конференция «Нейроинформатика-2004», 28–30 января 2004 г. / Отв. ред. Ю. В. Тюменцев. Часть 1. – М.: Изд-во МИФИ, 2004. – 200 с.
7. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // VI Всероссийская научно-техническая конференция «Нейроинформатика-2004», 28–30 января 2004 г. / Отв. ред. Ю. В. Тюменцев. Часть 2. – М.: Изд-во МИФИ, 2004. – 200 с.
8. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // VII Всероссийская научно-техническая конференция «Нейроинформатика-2005», 26–28 января 2005 г. / Отв. ред. Ю. В. Тюменцев. – М.: Изд-во МИФИ, 2005. – 216 с.
9. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // VIII Всероссийская научно-техническая конференция «Нейроинформатика-2006», 24–27 января 2006 г. / Отв. ред. Ю. В. Тюменцев. – М.: Изд-во МИФИ, 2006. – 244 с.
10. NEC Research Institute CiteSeer (also known as ResearchIndex) – Scientific Literature Digital Library.  
URL: <http://citeseer.ist.psu.edu/cs>
11. The Archive arXiv.org e-Print archive – Physics, Mathematics, Nonlinear Sciences, Computer Science.  
URL: <http://arxiv.org/>

12. Google Scholar.  
URL: <http://scholar.google.com/>
13. 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](mailto:tium@mai.ru)

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

## **ГЕНИАЛЬНЫЕ КОМИТЕТЫ УМНЫХ МАШИН**

### **Аннотация**

Лекция посвящена актуальной проблеме повышения точности обучения машин путем объединения их в комитеты. Основная цель — обсуждение алгоритмов для обработки очень больших наборов обучающих данных, пригодных к использованию на современных и перспективных многоядерных компьютерах.

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

## **INGENIOUS COMMITTEES FROM CLEVER MACHINES**

### **Abstract**

This Lecture is devoted to committee methods in the machine learning. The main objective is to review most promising algorithms for very large scale classifiers, capable of training on modern and forthcoming multicore computers.

... Эфиопские драконы в поисках лучших пастбищ регулярно переплывают Красное море, направляясь в Аравию. Для этого четыре-пять драконов, переплетаясь, образуют некое подобие плота, причем головы их торчат над водой.

---

*Х. Л. Борхес. Книга вымышленных существ*

## **Введение: Почему вообще возможно повышение точности?**

Основным предметом этой лекции является статистическая задача классификации в постановке, принятой в области обучения машин (machine learning). Имеется множество векторов  $\{\vec{x}\}$  из многомерного числового пространства, координаты которого будем называть признаками. Векторы независимо получены выборкой из некоторого (неизвестного) вероятностного распределения, обладающего плотностью  $\rho(\vec{x})$ . Для части векторов известно значение (метка) класса из оговоренного конечного набора возможных классов. Требуется установить, к каким классам относятся оставшиеся векторы, а также любые другие векторы, порожденные той же плотностью<sup>1</sup>.

Из векторов-примеров с известными метками можно образовать обучающую выборку, для которой с использованием алгоритмов обучения машин (например, искусственных нейронных сетей или деревьев правил), строится функция-классификатор  $h(\vec{x})$ . Выходом классификатора является метка класса для каждого входного вектора  $\vec{x}$ .

С практической точки зрения, обучаемые классификаторы различаются по таким показателям, как точность, производительность, устойчивость к погрешностям в исходных векторах, а также по затратам на их обучение и тестирование.

---

<sup>1</sup>Более строгие постановки задачи классификации, включающие формализацию понятия ошибки и ее измерения, риска, требования к признаковому пространству и др., приведены в специальной литературе (см., например, [2-4]).

В лекции речь пойдет о рациональном распределении усилий на обучение машин при решении сложных задач классификации и регрессии для больших объемов данных (100 тысяч и более примеров). Масштабирование алгоритмов распознавания классов становится одной из основных проблем [1] в таких областях, как анализ финансовых данных, обработка транзакций в сетях электронной торговли, мониторинг операций с кредитными картами, фильтрация почтовых сообщений, анализ белка и генных структур и др.

Дилемма состоит в поиске ответа на вопрос: что проще — построить и обучить один глобальный классификатор, либо сегментировать проблему на серию задач меньшего масштаба и обучить, а затем объединить, большое количество моделей, желательно, меньшей сложности. Последнее может оказаться предпочтительным, если при объединении моделей достигается требуемая точности прогнозирования.

Откуда может появиться резерв точности множества моделей, каждая из которых настроена на свою подзадачу, и, вообще говоря, не обязана быть высокоточной на всем исходном множестве данных?

Эмпирически феномен повышения точности и надежности результата при объединении нескольких мнений в единое решение был замечен давно<sup>2</sup>. Первые серьезные математические основания для этого факта, по-видимому, связываются с центральной предельной теоремой теории вероятности. Ранние формулировки<sup>3</sup> теоремы появились только в середине XVIII века.

В нашем контексте суть теоремы состоит в том, что последовательности частичных средних, вычисленных по наборам из  $n$  независимых случайных величин, даже имеющих большую дисперсию  $\sigma$ , стремятся к нормальному распределению с дисперсией, в корень из  $n$  раз меньшей. Тем самым, при определенных условиях, если использовать в качестве результата среднее от значений прогнозов отдельных моделей, то неопределенность такого результата окажется ниже неопределенности отдельной модели.

В реальности условия ЦПТ могут оказаться трудно выполнимыми<sup>4</sup>,

---

<sup>2</sup>Занятно, что около тысячи лет назад, согласно исторической легенде, царь хазар при решении вопроса о выборе веры для своего народа руководствовался мнением трех мудрецов различного вероисповедания. Вопрос, который он задавал каждому — какая, из оставшихся двух, вера ближе к твоей? (см. *Артур Кестлер. Тринадцатое колено. Крушение империи хазар и ее наследие.* — С.-Петербург: Евразия, 2006).

<sup>3</sup>Работа А. Муавра, 1733 год.

<sup>4</sup>Существует еще и проблема скорости сходимости.

поэтому сама теорема может рассматриваться, как «не запрещающая» понижать ошибку путем комбинирования прогнозов.

Прежде, чем приступить к обсуждению практических путей и алгоритмов целенаправленного объединения моделей, рассмотрим простой пример.

Пусть в нашем распоряжении имеются три алгоритма, каждый из которых решает определенную задачу бинарной классификации с вероятностью успеха  $p$ , независимо от остальных. Тогда при классификации очередного примера возможны 8 исходов, когда все классификаторы выдали верный ответ, либо два из трех не ошиблись (три варианта), либо не ошибся лишь один (еще три варианта), и, наконец, когда ошиблись все три алгоритма одновременно. Вероятности этих комбинаций исходов равны, очевидно,  $p^3$ ,  $3p^2(1-p)$ ,  $3p(1-p)^2$  и  $(1-p)^3$ .

Если из данных алгоритмов образовать *комитет большинства*<sup>5</sup>, принимающий коллегиальное решение путем простого голосования, то вероятность благоприятного исхода определяется двумя из четырех комбинаций и составляет величину

$$q = p^3 + 3p^2(1-p) = 3p^2 - 2p^3. \quad (1)$$

График зависимости  $q(p)$  приведен на рис. 1.

Эта зависимость аккумулирует в себе многие ключевые вопросы, связанные с использованием ансамблей классификаторов.

**НАБЛЮДЕНИЕ 1.** Кривая имеет два существенно различных участка  $p < 1/2$  и  $p > 1/2$ . Если точность отдельного классификатора хуже точности угадывания класса путем честного бросания честной монетки, то комитет таких моделей только *ухудшит* точность<sup>6</sup>.

<sup>5</sup>В лекции термины «комитет», «ансамбль» будут использоваться в широком смысле «объединенная модель», выходом которой является функциональная комбинация выходов отдельных моделей. Конкретные формализации способов композиции выходов будут вводиться по ходу изложения. Этот подход представляется автору оправданным вследствие большого разнообразия возможностей таких объединений, что приведет к значительной перегрузке текста множеством определений. Строгие аксиоматические построения в области композиций алгоритмов развиты в работах академика Ю. И. Журавлева [6]. См. также электронные лекции [7].

<sup>6</sup>Это очень важно в контексте обучения нейронных сетей методами повышенных порядков. Такие методы могут очень быстро приводить к раннему останову в ближайшем локальном минимуме, причем состояние обученности такого классификатора может оказаться произвольным. Если при обучении большого числа нейросетей этот процесс не контролировать, то итоговый комитет окажется весьма далеким от желаемой цели.




Рис. 1. Вероятность верной классификации комитетом большинства (по оси ординат), как функция точности отдельного классификатора (ось абсцисс).

НАБЛЮДЕНИЕ 2. Выигрыш в точности в области обученных до  $p > 1/2$  классификаторов, определяемый степенью превышения сплошной кривой над пунктирной на рис. 1, значительно варьируется в зависимости от достигнутого  $p$ .

НАБЛЮДЕНИЕ 3. Важно, что во всей области  $1 > p > 1/2$  объединение алгоритмов в комитет систематически превышает точность отдельной модели. Поэтому, потенциально, можно было бы неограниченно повышать точность путем построения комитетов их комитетов, затем комитетов из комитетов комитетов и т. д. В реальности, этого можно достигнуть при отсутствии противоречий в данных, но лишь для *ошибки обучения*. Растущая система комитетов начинает наизусть выучивать информационный шум в

данных, и точность на новых примерах (*ошибка обобщения*) деградирует.

Итак, точность ансамбля моделей можно улучшить, если: 1) повысить точность каждой отдельной модели и, одновременно, 2) обеспечить статистическую независимость ошибок разных членов ансамбля.

Как нередко бывает, эти требования, отчасти, противоречат друг другу. Действительно, для каждого классификатора, достижение точности *при условии независимости* его ошибок от других классификаторов является более сложной задачей, чем аналогичное обучение *при отсутствии ограничивающих условий*.

Проверка статистической независимости распределений ошибок в общем случае может оказаться самостоятельной проблемой, поэтому на практике обычно останавливаются на более простой ситуации анализа линейных корреляций ошибок всех пар классификаторов комитета. Если коэффициенты корреляции для различных пар отличаются, то можно предложить более эффективную схему выбора относительных весов отдельных членов комитета, а именно [5]:

$$w_i = \frac{\sum_{j=1}^M (C^{-1})_{ij}}{\sum_{k=1}^M \sum_{j=1}^M (C^{-1})_{kj}}. \quad (2)$$

Здесь  $M$  — число моделей в ансамбле,  $C^{-1}$  — матрица, обратная к матрице парных корреляций. Строго говоря, этот результат справедлив для задачи регрессии линейной комбинацией моделей

$$h(\vec{x}) = \sum_i w_i h_i(\vec{x}), \quad (3)$$

однако общий смысл зависимости (2) сохраняется: чем больше похож данный член комитета на остальных, тем меньшую пользу он приносит, и тем меньше его вес.

Коэффициенты корреляций в (2) невозможно точно вычислить для будущих данных, однако их можно оценить по некоторой, не зависящей от обучающих данных, выборке<sup>7</sup>.

В дальнейшем изложении в лекции будут обсуждаться различные методические подходы к оптимальному комбинированию моделей, включая как

<sup>7</sup>Для этих целей некорректно будет использовать ту *валидационную* выборку, по которой проводится прогноз окончательной ошибки обобщения модели, поскольку оптимальный выбор весов членов комитета является частью процесса обучения.

общие идеи, так и готовые к применению алгоритмы. Также будут затронуты вопросы оптимизации самих моделей с целью более эффективного использования их в комитетах.

В завершающем разделе рассматриваются вопросы масштабирования ансамблей классификаторов, особенно актуальные в связи с грядущим распространением общедоступных параллельных (многоядерных) процессоров и открывающимися широкими возможностями по массовому использованию высокопроизводительных обучающихся машин.

В приложении приведены некоторые задачи, цель которых стимулировать критическое отношение к изложенному в лекции материалу.

### **Бустинг (усиление) ансамбля классификаторов**

При формировании ансамбля моделей необходимо содержательно оптимизировать два критерия — качественное обучение отдельного классификатора и оптимальное их объединение. Голосующие алгоритмы принято разделять на два класса [12]: алгоритмы, которые для новых классификаторов изменяют распределение обучающих примеров исходя из показателей точности предыдущих моделей, и те, в которых новые члены ансамбля обучаются независимо от остальных. Первый класс еще 5–10 лет назад выглядел более привлекательным, поскольку позволял целенаправленно улучшать обучение. Однако в контексте обучения систем на больших объемах данных возможность распараллеливания обучения ансамблей независимых моделей становится все более актуальной, и, по мнению автора, основные усилия разработчиков в ближайшее время будут сконцентрированы вокруг второго класса ансамблей, обладающих естественной параллельностью<sup>8</sup>.

Поэтому начнем рассмотрение с систем последовательно обучающихся классификаторов.

Идея *бустинга* (boosting) предложена Робертом Шепайре (Robert E. Schapire) в конце 80-х годов (см. обзор [8]) в контексте фундаментального вопроса об эквивалентности *слабого и сильного* обучения. Смысл постановки проблемы состоит в следующем.

Пусть имеется некоторый алгоритм классификации, точность которого для заданной плотности распределения данных лишь незначительно пре-

<sup>8</sup>Логика параллельной обработки информации вносит свои коррективы в приоритеты не только в области обучения машин. Аналогичные примеры все чаще появляются и в других, более традиционных, областях, таких как вычислительная линейная алгебра, методы оптимизации, численное решение уравнений математической физики.

вышает точность угадывания:  $p = 1/2 + \varepsilon$ . Возможна ли, с использованием только такого (слабого) классификатора и набора данных, практическая<sup>9</sup> реализация программы по достижению сильного (сходящегося по вероятности) обучения, такого, что для всяких  $0 \leq \gamma, \delta \leq 1/2$  с вероятностью более  $1 - \gamma$  ошибка окажется меньше  $\delta$ .

### Ранние варианты бустинга

Приведенный во введении пример показывает, что на пути к повышению точности желательно обеспечивать независимость ошибок классификаторов. Напрашивающийся первый шаг в этом направлении — построение цепочки последовательно обучающихся классификаторов, каждый из которых осведомлен об ошибках предыдущих. Так как мы имеем дело с одним алгоритмом, способным достигнуть слабого обучения, то единственный<sup>10</sup> способ внести разнообразие в ошибки получающихся членов ансамбля — это использовать при обучении каждый раз другие данные. В первых вариантах бустинга [10] (см. также [9,11]) рассматривались тройки последовательно обучающихся слабых алгоритмов, достигающих уровня ошибки  $\alpha = (1 - p) < 1/2$ . Ниже приводится прототипический алгоритм их комбинирования.

#### АЛГОРИТМ BOOST1

1. Первый классификатор  $h_1$  обучается на множестве из  $m$  примеров.
2. Второй классификатор также обучается на  $m$  примерах, выбираемых так, что первый классификатор ровно на половине из них дает точный ответ.
3. Наконец, третий классификатор обучается на таких  $m$  примерах, на которых мнения первого и второго классификаторов расходятся.

Окончательная гипотеза формируется голосованием трех классификаторов

<sup>9</sup>Теоретически, как было видно из вводной части лекции, сильного обучения достигнуть не сложно, если иметь набор, вообще говоря, разных моделей с гарантированной независимостью ошибок.

<sup>10</sup>При обучении нейросетей с ранним остановом в локальном минимуме определенное разнообразие достигается при различном случайном выборе начальных весов нейронов. Однако такое разнообразие отражает собой лишь статистику локальных минимумов ошибки и никак не связано с независимостью ошибок сетей, находящихся в разных минимумах. Улучшение алгоритма обучения (и, например, переход к онлайн-обучению или постраничному обучению) нивелирует искусственный эффект влияния начальных весов.

по большинству:

$$h(x) = \text{sign}\left(\sum_{k=1}^3 h_k(x)\right). \quad (4)$$

В формуле (4) принято, что ответы классификаторов принадлежат множеству  $\{-1, +1\}$ . Несложные рассуждения и арифметика вероятностей приводят к вероятности ошибки для тройки  $3\alpha^2 - 2\alpha^3$  (совпадение с формулой (1) для независимых ошибок случайно!), что меньше ошибки каждого  $h_k$ .

Смысл алгоритма `Boost1` состоит в последовательной фильтрации примеров предыдущими обученными классификаторами, причем так, что задача для каждого последующего классификатора становится труднее. Проиллюстрируем логику работы алгоритма на примере игрушечной задачи о классификации двух множеств точек (50/50) на плоскости на два класса линейными пороговыми классификаторами (т. е. единичными формальными нейронами). Распределение точек и результат применения `Boost1` показаны на рис. 2. Сформированное в результате обучения решающее правило имеет вид ломаной линии, сепарирующей классы значительно лучше, чем каждый из классификаторов в отдельности.

Интересно увидеть, как оказались распределены обучающие примеры для самой сложной задачи последнего классификатора. Они включают только множество тех точек, по которым результаты первых двух нейронов не совпадают (выборка для обучения необходимой длины 100, равная по объему исходному множеству примеров, была получена случайным ресамплингом<sup>11</sup> с возвратом).

Характерная особенность этой выборки состоит в том, что исходная плотность распределения оказывается начисто забытой (о ней «помнит» только первый из классификаторов) в угоду точности. Это сохраняется и для других методов бустинга — целью обучения является лишь аппроксимация геометрической границы классов, поэтому результаты бустинга алгоритмов при наличии шума могут значительно уклоняться от оптимального байесова решающего правила, существенно учитывающего характер плотности данных во всем пространстве.

Базовая идея `Boost1` получила дальнейшее развитие в семействе адаптивных алгоритмов, позволяющих комбинировать произвольное число ал-

<sup>11</sup>Применение ресамплинга, строго говоря, не предусматривалось в оригинальной версии алгоритма, формулировка которого проведена для некоторого «оракула» (неограниченного источника, порождающего новые данные).




Рис. 2. Обучение ансамбля линейных пороговых классификаторов методом Boost1. Решающее правило соответствует границе ABCDE. Первый классификатор — линия ABD, второй — CDE, третий — BC.

горитмов с близким к оптимальному сочетанием их относительных весов. Такие алгоритмы могут, при отсутствии шума и противоречий в данных, достигать произвольной точности обучения, т.е. являются сильными алгоритмами в статистической терминологии PAC (probably asymptotically correct — асимптотически точные по вероятности).

### Семейство алгоритмов AdaBoost

Примерно через 5 лет после опубликования оригинальной идеи бустинга, ее автору с коллегами удалось существенно обобщить этот подход. В




Рис. 3. Обучающие примеры для третьего классификатора в методе Boost1

новой работе [13]<sup>12</sup> предложен алгоритм AdaBoost (Adaptive Boosting — адаптивное усиление), в котором в ансамбль могут объединяться произвольное число моделей, обучение проходит на одной обучающей выборке, точности различных моделей могут отличаться (но сохраняется требование слабой обучаемости), что учитывается в относительных весах моделей в коллегиальном решении.

Ниже приводится вариант алгоритма в чуть более поздней формулировке [8].

Пусть классификатор со слабым обучением формирует гипотезу (функцию) из пространства входных признаков во множество двоичных ответов  $h_t : X \rightarrow \{-1, 1\}$ . Качество этой гипотезы измеряется в количестве оши-

<sup>12</sup>Только по статистике сайта CiteSeer эта работа процитирована около 500 раз.

бок относительно указанного распределения  $D_t$  примеров с известными метками классов  $x_i \in X \rightarrow y_i \in \{-1, 1\}$ :

$$\varepsilon_t = \Pr_{(x,y) \sim D_t} [h_t(x_i) \neq y_i] = \sum_{i: h_t(x_i) \neq y_i} D_t(i). \quad (5)$$

Оценка ошибки (5) существенно зависит от характера распределения  $D_t$ , которое в вычислениях описывается относительными весами примеров в выборке. Выражение (5) также справедливо для случая нескольких классов, что отражено в приведенном ниже алгоритме.

#### АЛГОРИТМ ADABOOST

1. Дан набор обучающих примеров  $(x_1, y_1), \dots, (x_m, y_m)$  с метками  $y \in \{1, \dots, k\}$ . Начальные веса примеров одинаковы:  $D_1 = 1/m$ . Шаги 2–4 повторяются для итераций  $t = 1, \dots, T$ .
2. Обучить классификатор на распределении  $D_t$ , получить классифицирующую гипотезу  $h_t$  с оценкой ошибки

$$\varepsilon_t = \sum_{i: h_t(x_i) \neq y_i} D_t(i).$$

3. Вычислить

$$\alpha_t = \frac{1}{2} \cdot \ln\left(\frac{1 - \varepsilon_t}{\varepsilon_t}\right).$$

4. Обновить распределение примеров

$$D_{t+1}(i) = \frac{D_t(i) \cdot \exp[-\alpha_t y_i h_t(x_i)]}{Z_t},$$

где  $Z_t$  — нормировка суммы  $D_{t+1}$  на единицу (так что получается нормированное весовое распределение).

5. Сформировать окончательную гипотезу-классификатор


$$H(x) = \text{sign}\left(\sum_{t=1}^T \alpha_t h_t(x)\right)$$

для случая двух классов, или


$$H(x) = \operatorname{argmax}_{y \in \{1, \dots, k\}} \left[ \sum_{t: h_t(x)=y} \alpha_t \right]$$

для  $k$  классов.

Суть алгоритма заключается в последовательном, адаптивном к результатам предыдущих классификаторов, повышении относительного веса при-



(a)



(b)

Рис. 4. Решающее правило после четырех итераций метода AdaBoost: а) AdaBoost для линейного порогового классификатора; б) обучение нейронной сети с двумя нейронами в скрытом слое методом AdaBoost.

меров, на которых допускались ошибки. Индивидуальный вес  $\alpha_t$  очередного классификатора остается положительным, если его ошибка ниже 50% на том распределении, на котором он обучался. Чем больше ошибка классификатора, тем меньше его вес.

Характер работы алгоритма иллюстрируется на рис. 4 на решении модельной задачи классификации, описанной в предыдущем разделе. Для сравнения приведены результаты для линейного порогового классификатора (1 нейрон) и нейронной сети с двумя нейронами в скрытом слое.

При прямом применении AdaBoost к достаточно гибким классификаторам наблюдается переобучение.

### Обсуждение AdaBoost

Одно из достоинств алгоритма AdaBoost состоит в возможности проведения всего цикла обучения для одного исходного набора обучающих примеров, путем повторного использования их на разных шагах.

Основной теоретический результат [14] относительно ошибки обучения итогового ансамбля сформулирован в теореме: Если алгоритм AdaBoost порождает гипотезы с ошибками

$$\varepsilon_{D_t}(h_t) = 1/2 - \gamma_t,$$

то ошибка *обучения* комитетной гипотезы

$$E(H) \leq \exp\left(-2 \sum_t \gamma_t^2\right).$$

Таким образом, ошибки обучения в благоприятной ситуации убывают экспоненциально. Доказательство теоремы приведено в [14] и многократно воспроизведено в других работах. Интуитивно, суть теоремы можно понять, если заметить, что если пример неверно классифицирован комитетом, то он также ошибочно классифицирован большинством индивидуальных моделей. Следовательно, такой пример имеет (экспоненциально) большой относительный вес. А так как распределение весов нормировано, то доля таких примеров (экспоненциально) мала.

Вопрос о качестве обобщения моделей, обученных по AdaBoost, широко дискутируется в литературе, в основном, с экспериментальной точки зрения. Теоретические оценки степени обобщения, оперирующие поня-

тием VC-размерности<sup>13</sup> классификатора  $d$ , приводят к слишком широким интервалам, чтобы представлять практический интерес. Ошибка имеет тенденцию уменьшаться как  $\sim \sqrt{Td/m}$ .

Экспериментально обнаружено, что алгоритм весьма эффективен, но может приводить к переобучению при большом числе шагов, хотя это наблюдается относительно нечасто. Это — хорошая новость, поскольку, по построению, AdaBoost все жестче концентрируется на малом числе трудных примеров в процессе добавления новых членов комитета, что должно приводить к переобучению. Отчасти факт отсутствия переобучения во многих практических примерах объяснен автором алгоритма [14], исходя из рассмотрения динамики *зазора* (или *отступа*, margin) между классами.

Зазор (удаление от границы классов) для индивидуального примера равен  $y_i h(x_i)$ . Эта величина положительна только тогда, когда пример классифицирован безошибочно. Суть алгоритма AdaBoost заключается в последовательной минимизации на каждом шаге величины

$$Z_t = \sum_t D_t(i) \cdot \exp(-\alpha_t y_i h_t(x_i)) \quad (6)$$

как функции  $\alpha_t$ , при этом предыдущие веса  $\alpha_1, \dots, \alpha_{t-1}$  остаются неизменными. Таким образом, алгоритм является «жадным» покоординатным методом максимизации зазора, поскольку экспоненциальная функция в (6) является мажорантой (верхней границей) риска ошибки, который равен 1, если зазор отрицателен, и нулю (нет ошибки) при положительном зазоре. Это иллюстрирует рис. 5.

В статистической теории обучения [3] максимизация зазора интерпретируется, как малый риск ошибки обобщения — чем больше ширина зазора, тем менее вероятно его преодоление и попадание нового примера за границу класса.

Соотношение между понятиями «большой зазор» и «качество обобщения» вызывает определенную полемику в технической литературе. «Мягкий» текущий вывод ([20], с. 168) из этой полемики таков: бустинг эффективен для классификаторов, которые слегка недообучаются (в противоположность рассмотренному далее в лекции бэггингу, для которого рекомендованы алгоритмы, которые слегка переобучаются на данных).

<sup>13</sup>Имеются замкнутые оценки для размерности Вапника-Червоненкиса [3] некоторых типов классификаторов, в частности, для линейных решающих правил размерность имеет масштаб числа свободных параметров. Рассмотрение этой теории выходит за рамки данной лекции.




Рис. 5. Зависимость теоретического риска ошибки (сплошная пороговая линия) и его оценки в AdaBoost (штрих-пунктир) от величины зазора (margin)

Методы максимизации зазора, и в частности, основанные на них машины опорных векторов (SVM — Support Vector Machine) обсуждались в предыдущей лекции автора [15]. Отметим здесь, что возможна формальная постановка AdaBoost, как задачи оптимизации, аналогичной задаче оценивания плотности<sup>14</sup> алгоритмом SVM [16,17]. При этом отличие в постановках состоит в минимизации разных норм весовых векторов — нормы  $L_2$  для SVM и  $L_1$  (суммы модулей) для AdaBoost. Это отличие, однако оказывается существенным — в признаковом пространстве  $X$  решение для AdaBoost оказывается разреженным (число членов комитета конечно и

<sup>14</sup>Имеется в виду алгоритмы «SVM для классификации в один класс» (1-class SVM), которые оценивают носитель области в признаковом пространстве, занятой данными.

относительно невелико), решение же для SVM приводит к плотному вектору (оно является разреженным в дуальном пространстве весов примеров). В итоге, несмотря на определенное сходство математического аппарата, получаемые обученные классификаторы дают разные приближения к границе классов.

Формально, алгоритм AdaBoost применим и к общему случаю  $k$  классов, но его прямое использование при  $k > 2$  затруднено, поскольку требование к ошибке  $\varepsilon_t < 1/2$  трудно удовлетворить для множества классов. В литературе обсуждаются многочисленные модификации алгоритма, позволяющие обойти данную трудность [8,18,19].

Относительно недавний прогресс [21] в разработке методов семейства AdaBoost связывается с учетом того факта, что многие алгоритмы классификации (включая нейронные сети) способны выдавать на выходе не только метку класса со значениями  $\{-1, 1\}$ , но и вещественнозначную оценку уверенности в прогнозе этой метки. В частности, для этих целей может использоваться не контрастированный выход нейронной сети в интервале  $[-1, 1]$ .

Первый шаг состоит в формальном сохранении алгоритма в исходном виде, но теперь в качестве гипотезы отдельного классификатора следует понимать значение в интервале  $h(x) \in [-1, 1]$ . Это приводит к более консервативному выбору весов примеров  $D(i)$  и лучшему приближению покоординатного поиска  $\alpha_t$  (правда, за счет увеличения числа членов комитета). Следующий шаг сводится к замене приближенного значения  $\alpha_t$  (шаг 3 алгоритма AdaBoost) прямой численной минимизацией функции (6). Авторы [21] также предлагают использование целевой функции (6) при обучении самих классификаторов. Так, например, алгоритм обучения нейронной сети на основе обратного распространения ошибок легко может быть обобщен на оценку (6), поскольку производные оценки по выходу нейросети вычисляются явно.

Другие варианты целевого улучшения базового алгоритма могут быть получены путем использования в формуле (6) иных оценок риска (вместо величины зазора  $y_i h(x_i)$ ). На этом пути предложены методы классификации на несколько классов и для ситуации, когда пример может принадлежать сразу нескольким классам [21, с. 13]. Имеются также алгоритмы на основе AdaBoost для задачи регрессии [9] (классификации в континуум классов).

Методы AdaBoost весьма популярны и эффективны для задач малой и средней сложности (до нескольких десятков тысяч примеров). В контексте

этой лекции, основными сдерживающими моментами к широкому применению методов бустинга к задачам *увеличивающегося масштаба* являются:

- Принципиальная последовательная структура алгоритмов AdaBoost. Обучение каждой новой модели ансамбля может начаться только после получения результатов предыдущей модели.
- Все члены комитета обучаются на масштабных выборках, требующих просмотра и пробного применения классификатора ко всем обучающим примерам на каждой итерации. Это требование сразу ограничивает снизу скейлинг алгоритма — сложность заведомо не лучше, чем линейная по числу примеров. Это уже может оказаться серьезным препятствием для ряда приложений.

Нашей следующей целью будут алгоритмы, способные преодолеть эти ограничения.

### Параллельные ансамбли равноправных моделей

Желаемого разнообразия моделей и определенной независимости их ошибок, что благоприятно сказывается на точности при объединении в комитет, можно достигнуть и без использования одних моделей для изменения других. Модели могут обучаться независимо, что является принципиальным ресурсом при использовании параллельных вычислений.

### Комбинирование классификаторов с использованием бутстрепа

Равноправные модели становятся разнообразными при обучении на различных выборках данных. Если в нашем распоряжении имеется лишь один набор из  $m$  примеров, то различающиеся подвыборки с близкой статистикой можно получить путем применения *бутстрепа* [22] — случайной выборки с возвратом.

Эмпирическая плотность распределения данных, оцененная по набору примеров, дается выражением

$$\rho_{emp}(x) = \frac{1}{m} \sum_{j=1}^m \delta(x - x_j). \quad (7)$$

Эту плотность можно использовать для генерации новых выборок. А именно, для получения очередного примера следует случайно выбрать одно из

слагаемых в (7) и далее формально выполнить выборку из плотности, даваемой этим слагаемым. В случае дельта-функции результат, очевидно, детерминирован и равен соответствующему примеру  $x_j$ . Эта процедура и есть бутстреп-метод.

Вероятность появления в выборке каждого примера, по построению, равна

$$p_{bs} = 1 - (1 - 1/m)^m \xrightarrow{m \rightarrow \infty} 0.632.. \quad (8)$$

т.е. некоторые примеры встречаются несколько раз, а какие-то ни разу. Многие статистические особенности исходного набора данных воспроизводятся и в бутстреп-выборках, что позволяет использовать этот метод для построения перекрестных оценок<sup>15</sup>.

Подход, основанный на независимом обучении отдельных моделей на бутстреп-выборках из обучающего набора данных и объединении полученных моделей в комитет большинства, был предложен в 1994 году Лео Брейманом (Leo Breiman) [23]. Метод получил название «бэггинг» (bagging — bootstrap aggregating).

Формальный алгоритм весьма прост:

#### АЛГОРИТМ BAGGING

1. Дан набор обучающих примеров  $(x_1, y_1), \dots, (x_m, y_m)$  с метками  $y \in \{1, \dots, k\}$ .
2. Получить  $T$  бутстреп-выборок  $D_t$ .
3. Независимо (параллельно) обучить  $t$  классификаторов  $h_t$ , каждый на своей выборке  $D_t$ .
4. Сформировать окончательную гипотезу-классификатор

$$H(x) = \text{sign} \left( \sum_{t=1}^T h_t(x) \right)$$

для случая двух классов, или

$$H(x) = \underset{y \in \{1, \dots, k\}}{\text{argmax}} \left[ \sum_{t: h_t(x)=y} 1 \right]$$

для  $k$  классов.

<sup>15</sup>Обращение с бутстреп-выборками требует известной аккуратности. К ним нельзя относиться как к неиссякаемому источнику новых данных, отдельные выборки являются специфически *зависимыми*. В частности, если исходная выборка примеров была неудачной по отношению к реальной плотности распределения данных (например, давала смещенную оценку матожидания), то все бутстреп-реплики также окажутся неудовлетворительными с большой вероятностью.

Метод бэггинга демонстрирует устойчивые результаты на практике<sup>16</sup>, и очень удобен в реализации. Разброс значений выходов различных классификаторов может быть использован для дополнительной оценки ошибки (ее верхней границы). При последовательной реализации комитет может расширяться поэтапно, при этом первые результаты классификации система начинает выдавать уже после обучения первых моделей.

Полностью аналогично алгоритм бэггинга формулируется и для задачи регрессии, в которой модели образуют линейную комбинацию с одинаковыми весами.

### Почему бэггинг работает?

Теоретические оценки достижимой точности [23] основываются на общепринятой декомпозиции квадратичной ошибки на два члена — «смещение» (bias) и «дисперсию» (variance). Дальнейшие выкладки показывают, что бэггинг уменьшает дисперсию, не изменяя смещение оценки ансамбля.

Однако, ситуация до конца не ясна, в частности, обнаружено, что бэггинг может улучшать оценки, даже не приводя к уменьшению дисперсии. Суть вопроса в том, что при построении комитета борются две тенденции — благоприятное усреднение моделей и факт того, что каждая модель обучалась на неполном (и искаженном) наборе данных.

Экспериментально показано [5,12,23], что бэггинг обеспечивает *равномерное* улучшение точности на всех задачах (хотя бустинг демонстрирует лучшие результаты на многих из них, но в ряде случаев ухудшает точность). Наилучшие результаты достигаются при комбинировании так называемых неустойчивых моделей (к ним относятся нейронные сети и деревья правил)<sup>17</sup>, но не улучшает и не ухудшает устойчивые к изменениям в наборе данных алгоритмы (такие, как метод  $k$ -ближайших соседей).

<sup>16</sup>В 2001–2002 годах коллективом под руководством автора лекции была разработана система CNet для задач классификации и регрессии, использующая бэггинг-ансамбль нейросетевых моделей. Вычислительный сервер CNet успешно применялся для промышленных приложений в области бытовой химии, неразрушающего контроля трубопроводов, а также в нефтедобывающей отрасли. В настоящее время он продолжает использоваться в проектах, выполняемых компанией Нейрок Техсофт.

<sup>17</sup>Увы, общепринятый в математической статистике термин здесь не отражает сущности дела. Речь идет о *гибкости* моделей в их способности отражать изменения в данных. Неустойчивость же обычно ассоциируется с отсутствием сходимости — однако отмеченные «неустойчивые» алгоритмы прекрасно сходятся, если сходятся соответствующие последовательности наборов данных.

С практической точки зрения интересен также вопрос — можно ли добиваться улучшения точности при бэггинге моделей, если объем обучающих бутстреп-выборок *меньше* объема исходного набора данных. Как далеко можно двигаться в сторону уменьшения выборок без существенных последствий для точности? Автору известны лишь экспериментальные оценки для частных случаев.

По-видимому, численные эксперименты являются основным инструментом при анализе бэггинга — сам *Лео Брейман*, отвечая на вопрос, сколько моделей следует использовать в комитете, апеллирует к экспериментальным оценкам — не более 50 для задач классификации и вдвое меньше для регрессии.

### Бэггинг-комитеты, обучаемые в реальном времени

В исходной постановке метод бэггинга требует наличия всех обучающих примеров до начала процесса обучения. Это нельзя признать полностью соответствующим многим практическим потребностям. В приложениях данные могут поступать в систему последовательно и обучение целесообразно было бы совместить с процессом сбора данных.

Техническая трудность состоит в онлайн-генерации бутстреп-выборок. Более точно, в принятии решения по каждому примеру в отдельности, сколько раз (с каким весом) он должен участвовать в обучении каждой из моделей комитета.

Возможное решение состоит в аппроксимации бутстреп-распределения путем генерации случайного веса примера из распределения Пуассона со средним, равным единице. Вероятность встретить пример ровно  $k$  раз для  $k = 0, 1, \dots$  в законе Пуассона равна

$$P(K = k) = \exp(-1)/k!. \quad (9)$$

При поступлении нового примера он копируется искомое число раз (свое для каждого классификатора) и далее участвует в обучении онлайн-алгоритмом. Такой способ построения выборки не вполне точно воспроизводит бутстрэп. В частности, по получении  $m$  примеров нет гарантии того, что ровно такое же число примеров будет отобрано для каждой модели. Это, потенциально, может вносить дополнительные искажения в статистику (впрочем, существенные только с теоретической точки зрения).

В другом подходе [24] предлагается рассматривать бутстреп-выборку как исходную выборку, но с весами, принимающими точные значения

$$\left\{0, \frac{1}{m}, \frac{2}{m}, \dots\right\},$$

причем сумма весов равна единице. Тогда возможна байесова интерпретация весов примеров, как вектора вероятностей, следующего  $m$ -мерному распределению Дирихле. Если алгоритм обучения может оперировать с весами примеров (в частности, аддитивная по примерам ошибка нейронной сети может суммироваться с весами), то искомое онлайн-решение — это учет каждого примера при обучении каждой модели с последовательной генерацией весов. В этом случае все классификаторы автоматически являются равно нагруженными примерами.

Оценка комитета может формироваться после каждого шага обучения на новом примере и использоваться одновременно с обучением (примеры с известными метками поступают в каналы обучения, а для примеров с неизвестными метками вычисляется класс из комитета оценок текущих классификаторов).

### Специализация экспертов и другие методы

Рассмотренные в предыдущих разделах методы формирования ансамблей классификаторов неявно предполагают, что ошибки отдельной модели относительно *равномерно* распределены в пространстве признаков, и, при ее оптимальном добавлении в комитет, достаточно воспользоваться единой оценкой ошибки.

Это предположение может нарушаться в больших неоднородных наборах данных. Различные области пространства могут качественно описываться разными членами комитета, поэтому их объединение должно учитывать такую специализацию. Прямое применение этого наблюдения приводит к подходу динамической интеграции классификаторов [25].

Суть идеи состоит в том, что после обучения все примеры сохраняются вместе с оценками ошибок, которые делались на них всеми членами ансамбля. Далее, при поступлении нового примера, в базе данных производится поиск ближайших прототипов из обучающей выборки и в голосовании участвуют только те члены комитета, которые допускали малые ошибки на найденных прототипах. Таким образом, происходит динамическое объединение *некоторых* членов комитета для решения каждой новой задачи.

### Карты экспертов

Идею динамического объединения нетрудно развить дальше, если вместо хранения прототипов использовать кластерную структуру (например, карту Кохонена), построенную на обучающей выборке без меток классов, и приписать каждому кластеру список моделей, демонстрировавших лучшие результаты на данных этого кластера. Для классификации теперь достаточно найти ближайший кластер и применить ассоциированные с ним модели<sup>18</sup>.

Каждый член комитета приписывается ко всем кластерам, на данных из которых он мало ошибается, таким образом, кластеры ведут свои рейтинги-листы моделей.

Нейросетевая карта специализированных экспертов может использоваться не только в процессе распознавания, но и для аналитических целей. В частности, на основе карты по мере поступления запросов можно сделать вывод о «проблемных областях» комитета. Им соответствуют кластеры, заполненные данными, но бедные связанными с ними классификаторами. Это дает новую стратегию обучения и пополнения комитета новыми моделями.

### Смеси экспертов

Карта экспертов является наглядным простым примером более общей методологии смесей экспертов [26–28]. Смеси экспертов очень широко обсуждаются в специальной литературе<sup>19</sup>. В Российской школе нейроинформатики [29] также предложен свой оригинальный подход к этой проблематике. В целом, данная тема достойна отдельной лекции, поэтому остановимся только на общей структуре системы.

Объединение экспертов в ансамбль при решении задачи классификации нового примера производится с весами, которые определяются выходами управляющей нейронной сети (рис. 6).

Задача управляющей нейронной сети — выбрать веса смеси, наиболее соответствующие классифицируемому в данный момент входному вектору. В простейшем варианте управляющая сеть состоит из одного слоя нейронов, число которых равно числу членов комитета. Выход сети определяется

---

<sup>18</sup>Предлагается назвать такую гибридную архитектуру картой экспертов (ExpertMap).

<sup>19</sup>Работа [26] также является одним из лидеров по цитированию, наравне со статьей Schapire об AdaBoost.




Рис. 6. Архитектура модели смеси экспертов

методом «мягкого максимума» (softmax):

$$c_i = \sum_j x_j w_{ij}, \quad g_i = \frac{\exp(c_i)}{\sum_j \exp(c_j)}. \quad (10)$$

Выход всей системы дается выражением

$$H_{mix} = \sum_i g_i h_i(x). \quad (11)$$

При использовании квадратичной функции ошибки, выражения для обучения управляющей сети получаются ее дифференцированием и применением обратного распространения:

$$\frac{\partial E(x, y)}{\partial g_i} = h_i(x) \cdot \left( \sum_j g_j h_j(x) - y \right). \quad (12)$$

В различных вариантах модели в качестве управляющей сети используются гауссовы смеси (радиальные базисные функции) с обучением EM-алгоритмом [30], системы нечетких правил, иерархические структуры [26] и другие модели.

Смеси экспертов являются примером *нелинейного* объединения алгоритмов в комитет — веса в выражении (11) зависят от координат входного вектора. В общем случае, получение теоретических построений, описывающих точность таких моделей, затруднено. На практике используют обычные методы перекрестного оценивания и валидационные выборки.

### Распределенное обучение экспертов на фрагментах данных

Дальнейшее движение в сторону усложнения проблемы и роста ее масштаба состоит в рассмотрении задач, в которых данные распределены по узлам сети, а сбор всех данных в одном месте является одновременно и дорогим, и нерациональным, поскольку данные заведомо не помещаются в память одного компьютера.

Распределение данных по некоторой сети может соответствовать деловой или производственной логике прикладной области (например, географически распределенное производство компонент оборудования, сетевая структура поставщиков и потребителей торговых сетей, медицинские и социологические данные о населении, архивы специальных государственных структур, метеорологические данные, банки генома и др.). В таких приложениях допустим лишь сетевой *обмен моделями* или группами моделей, обучаемыми локально.

Реалистичным приближением к этой ситуации является распределенное обучение ансамбля классификаторов, выполняемое на многопроцессорной ЭВМ, причем весь объем данных превышает возможности отдельных узлов. Такая задача рассмотрена в работе [1] в контексте использования суперкомпьютерных вычислений<sup>20</sup> для обучения машин задаче классификации.

Подход состоит в построении независимых комитетов на каждом процессорном узле и далее в объединении всех моделей в один ансамбль путем простого голосования. Алгоритм разделения на малые подмножества (*pasting small votes* — “bites”) был предложен *Лео Брейманом* еще в 1999 году [31]. В работе [1] он обобщен на случай распределенной обработки данных без коммуникаций.

---

<sup>20</sup>Работа [1] частично спонсировалась Сандийскими Национальными лабораториями США.

## АЛГОРИТМ DИVOTE

1. Дан набор обучающих примеров  $(x_1, y_1), \dots, (x_m, y_m)$  с метками  $y \in \{1, \dots, k\}$ .
2. Разделить данные на  $T$  непересекающихся подмножеств  $D_t$ , разместить каждое из подмножеств на отдельном процессорном узле.
3. В каждом узле получить бутстреп-выборку размера  $N$  и обучить первый набор классификаторов. Далее повторять шаги 4–6 до выполнения критерия останова (стабилизации ошибки или заданное число итераций).
4. На шаге  $k$  вычислить ошибку  $e(j)$  на данных, не включенных в подвыборку, использованную при обучении (речь идет только о данных локального множества  $D_t$  на каждом процессорном узле), и вычислить вероятность  $c(j)$  переиспользования примеров без ошибок:

$$e(j) = p \cdot e(j-1) + (1-p) \cdot r(j), \quad p = 3/4,$$

$r(j)$  — вероятность ошибки текущего комитета большинства из  $j$  классификаторов на всем локальном множестве  $D_t$ ,

$$c(j) = e(j)/(1 - e(j)).$$

5. Сформировать новую обучающую выборку из  $N$  примеров. Примеры просматриваются случайно, с возвратом. Если пример ошибочно классифицируется множеством классификаторов данного узла, для которых он не встречался в их обучающих выборках<sup>21</sup>, то он включается безусловно. Пример, верно классифицируемый этими классификаторами, включается в подвыборку с вероятностью  $c(j)$ .
6. Обучить  $(j+1)$ -й классификатор  $h_{t,j+1}$  на выборке, полученной на шаге 5.
7. Собрать все полученные модели классификаторов на одном процессорном узле и сформировать окончательную гипотезу-классификатор

$$H(x) = \text{sign} \left( \sum_{t=1}^T \sum_j h_{t,j}(x) \right)$$

для случая двух классов, или

$$H(x) = \operatorname{argmax}_{y \in \{1, \dots, k\}} \left[ \sum_{t,j: h_{t,j}(x)=y} 1 \right]$$

для  $k$  классов.

Алгоритм DИvote был интенсивно экспериментально исследован [1] в сравнении с онлайн-методами бустинга и другими алгоритмами. Полученные высокие показатели по точности комитета авторы объясняют высокой

<sup>21</sup>Такая оценка ошибки обычно называется *out-of-bag error* (ошибка на оставшихся данных).

степенью попарного разнообразия классификаторов, оцениваемой по так называемой  $\varkappa$ -метрике:

$$\theta_1 = \frac{\sum_{i=1}^k C_{ii}}{m}, \quad \theta_2 = \sum_{i=1}^k \left( \sum_{j=1}^k \frac{C_{ij}}{m} \cdot \sum_{j=1}^k \frac{C_{ji}}{m} \right), \quad \varkappa = \frac{\theta_1 - \theta_2}{1 - \theta_1}. \quad (13)$$

Здесь матричные элементы  $C_{ij}$  равны числу примеров, которые первый классификатор относит к  $i$ -му, а второй к  $j$ -му классу. Показатель  $\varkappa$  равен нулю, если два классификатора дают совпадающие ответы случайно, и близок к единице, если классификаторы точно соответствуют друг другу на каждом примере. Экспериментальные зависимости ошибок от статистики пар показывают, что малые значения ошибок наблюдаются при высокой степени диверсификации моделей ансамбля.

### Перспективы

Рассмотренные в лекции алгоритмы разделения больших задач обучения на множество отдельных подзадач с последующим объединением моделей в ансамбли позволяют значительно повысить точность прогнозирования в условиях ограничения на вычислительные ресурсы и возможность одновременной обработки всего массива данных. Однако, в своем большинстве, алгоритмы обучения многократно переиспользуют данные, хотя и в параллельном режиме.

Дальнейшее масштабирование систем классификации, по мнению автора, возможно при разработке алгоритмов, использующих ровно *один проход* по подмножеству данных (*one-pass learning algorithms*). Алгоритмы такого класса позволят значительно расширить области применения масштабных систем классификации с наступлением эры доступных многоядерных процессоров. В настоящий момент типичным является применение двухядерных систем, но не за горами 8 и 16-ядерные процессоры для персональных компьютеров. Такой уровень параллельности еще нельзя назвать массивным, поэтому основной ресурс — это обращение к дисковой памяти (к базе данных) при потоковой обработке.

Автор прогнозирует значительное повышение интереса и рост числа публикаций по однопроходным параллельным алгоритмам.

Второе важное обстоятельство — отсутствие строгих теоретических обоснований для многих, интересных в прикладном плане, разработок.

В частности, затруднительно признать окончательно, что поняты все причины повышения точности алгоритмов с бутстреп-выборками (класс бэггинга). Эти алгоритмы наиболее эффективно распараллеливаются, но нет ясных, *оцениваемых одновременно с обучением*, критериев выбора их параметров — числа моделей в комитете, достаточного объема каждой из подвыборок, а также рациональной сложности каждой из моделей.

Возможности по независимому обучению комитетов классификаторов по географически или организационно распределенным фрагментам данных могут в будущем значительно повлиять на бизнес-логику обращения с данными в крупных компаниях и государственных учреждениях. *Обмен моделями* вместо дорогого или затрудненного по соображениям информационной безопасности *обмена данными* может стать основным механизмом синхронизации бизнес-процессов. Это обстоятельство уже широко осознается специалистами в области мультиагентных информационных систем. Очередь за распределенными системами поддержки принятия решений.

### Благодарности

Автор благодарит коллег по компании Нейрок Техсофт, стимулирующих поисковые разработки своими достижениями в практическом использовании методов обучения машин в договорных работах, проводимых компанией.

### Литература

1. Nitesh V. Chawla, Lawrence O. Hall, Kevin W. Bowyer, W. Philip Kegelmeyer. Learning ensembles from bites: A scalable and accurate approach // *Journal of Machine Learning Research*. – 5(Apr):421–451, 2004.  
URL: <http://www.jmlr.org/papers/v5/chawla04a.html>
2. Bishop C. M. *Neural Networks for Pattern Recognition*. – Oxford University Press, 1995.
3. Vapnik V. N. *The nature of statistical learning theory*. – Springer-Verlag, 1995.
4. T. Hastie, R. Tibshirani, J. Friedman. *The Elements of statistical learning*. Springer, 2001
5. Gavin Brown. *Diversity in neural network ensembles*. – PhD Thesis, Univ. of Birmingham, 2003.  
URL: [ftp.cs.bham.ac.uk/pub/authors/J.L.Wyatt/gxb\\_thesis.pdf](ftp.cs.bham.ac.uk/pub/authors/J.L.Wyatt/gxb_thesis.pdf)

6. Журавлев Ю. И. Об алгебраическом подходе к решению задач распознавания или классификации // В сб. «Проблемы кибернетики», 1978, т. 33, с.5.
7. Воронцов К. В. Лекции по алгоритмическим композициям. – 2006.  
URL: <http://www.ccas.ru/voron/download/Composition.pdf>
8. Yoav Freund, Robert E. Schapire. A short introduction to boosting // *Journal of Japanese Society for Artificial Intelligence*. – 14 (5): 771–780, September, 1999.  
URL: <http://www.cs.princeton.edu/sim.schapire/uncompress-papers.cgi/FreundSc99.ps>
9. R. Avnimelech, N. Intrator. Boosting regression estimators // *Neural Computation*. – 11: 491–513, 1999.  
URL: <http://citeseer.ist.psu.edu/avnimelech99boosting.html>
10. Robert E. Schapire. The strength of weak learnability // *Machine Learning*. – 5 (2): 197–227, 1990.  
URL: <http://citeseer.ist.psu.edu/schapire90strength.html>
11. Drucker H. Boosting using neural networks // In: *Combining Artificial Neural Nets: Ensemble and Modular Multi-Net Systems* (Edited by A. J. C. Sharkey). – 1998.  
URL: <http://www.boosting.org/papers/Dru99.pdf>
12. Eric Bauer, Ron Kohavi. An empirical comparison of voting classification algorithms: Bagging, boosting, and variants // *Machine Learning*. – 36 (1999) pp. 105–142.  
URL: <http://citeseer.ist.psu.edu/bauer99empirical.html>
13. Yoav Freund, Robert E. Schapire. A decision-theoretic generalization of on-line learning and an application to boosting // *Second European Conference on Computational Learning Theory*. – 1995.  
URL: <http://citeseer.ist.psu.edu/89601.html>
14. Robert E. Schapire. Theoretical views of boosting and applications // *Algorithmic Learning Theory*, 10th International Conference, ALT '99, Tokyo, Japan, December 1999, Proceedings.  
URL: <http://citeseer.ist.psu.edu/231645.html>
15. Терехов С. А. Технологические аспекты обучения нейросетевых машин // Лекция для VIII школы-семинара «Современные проблемы нейроинформатики». – М.: МИФИ, январь 2006. – с. 13–73.
16. Gunnar Ratsch, Bernhard Schokopf, Sebastian Mika, Klaus-Robert Muller. SVM and boosting: One class. – Tech. Report GMD RIRST, 2000.  
URL: <http://citeseer.ist.psu.edu/516656.html>
17. Gunnar Ratsch, Manfred K. Warmuth. Efficient margin maximizing with boosting // *JMLR*. – 6 (Dec): 2131–2152, 2005.  
URL: <http://jmlr.csail.mit.edu/papers/volume6/ratsch05a/ratsch05a.pdf>

18. Материалы Интернет-узла <http://www.boosting.org/>
19. *Gunther Eibl, Karl-Peter Pfeiffer*. Multiclass boosting for weak classifiers // *JMLR*. – 6 (Feb): 189–210, 2005.  
URL: <http://jmlr.csail.mit.edu/papers/volume6/eibl05a/eibl05a.pdf>
20. *R. Meir, G. Ratsch*. An introduction to boosting and leveraging // In: *S. Mendelson and A. Smola*, editors, *Advanced Lectures on Machine Learning*, LNCS, pp. 119–184. – Springer, 2003.  
URL: <http://www.boosting.org/papers/MeiRae03.pdf>
21. *Robert E. Schapire, Yoram Singer*. Improved boosting algorithms using confidence-rated predictions // *Machine Learning*. – 37 (3): 297–336, 1999.  
URL: <http://citeseer.ist.psu.edu/schapire99improved.html>
22. *T. Hastie, R. Tibshirani, J. Friedman*. The elements of statistical learning: Data mining, inference, and prediction. – Springer, 2001.
23. *Leo Breiman*. Bagging predictors // *Machine Learning*. – 24 (1996), 123–140. Also, Univ. California Technical Report No. 421, September 1994.  
URL: <http://citeseer.ist.psu.edu/breiman96bagging.html>
24. *Herbert K. H. Lee, Merlise A. Clyde*. Lossless online Bayesian bagging // *JMLR*. 5 (2004). – pp. 143–151.  
URL: <http://jmlr.csail.mit.edu/papers/volume5/lee04a/lee04a.pdf>
25. *Alexey Tsymbal, Seppo Puuronen*. Bagging and boosting with dynamic integration of classifiers // In *Proceedings of PKDD 2000*, Lyon, France, *Lecture Notes in Artificial Intelligence*, Springer Verlag, volume 1910, pp. 116–125, 2000.  
URL: [http://www.boosting.org/papers/upload\\_30017\\_tsymbal1.pdf](http://www.boosting.org/papers/upload_30017_tsymbal1.pdf)
26. *Jordan M. I., Jacobs R. A.* Hierarchical mixtures of experts and the EM algorithm // *Neural Computation*. – 6 (1994), pp. 181–214.  
URL: <http://citeseer.ist.psu.edu/jordan93hierarchical.html>
27. *Steve Waterhouse, David Mackay, Tony Robinson*. Bayesian methods for mixtures of experts // *Advances in Neural Information Processing Systems (NIPS)*, 1996.  
URL: <http://citeseer.ist.psu.edu/waterhouse96bayesian.html>
28. *R. A. Jacobs, M. I. Jordan, S. J. Nowlan, G. E. Hinton*. Adaptive mixtures of local experts // *Neural Computation*. – 3 (1): 79–87, 1991.
29. *Гилев С. Е., Горбань А. Н., Миркес Е. М.* Малые эксперты и внутренние конфликты в обучаемых нейронных сетях // *Доклады Академии Наук СССР*. – 1991. – т. 320, № 1. – с. 220–223.
30. Справочник по прикладной статистике. В 2-х томах, под ред. *Э.Ллойда, У. Ледермана*. – М. Финансы и Статистика, 1989.

31. L. Breiman. Pasting bites together for prediction in large data sets // *Machine Learning*, 36 (2): 85–103, 1999.  
URL: <http://citeseer.comp.nus.edu.sg/137761.html>

## Приложение. Большие наборы данных для экспериментов

Разрабатываемые масштабируемые алгоритмы для решения задач классификации требуют, как правило, экспериментальной отработки и верификации. Встает вопрос об источниках данных соответствующего замыслу масштаба.

Пример такой базы данных — это данные по прогнозированию лесного покрытия на основе картирования (без применения удаленного зондирования территорий).

URL-адрес базы данных Forest CoverType:  
<http://kdd.ics.uci.edu//databases/covertime/covertime.html>

Данные собраны в университете штата Колорадо (Remote Sensing and GIS Program, Department of Forest Sciences, College of Natural Resources, Colorado State University). Массив включает более полумиллиона примеров с 54 признаками и 7 выходными классами. Задача осложняется неравномерным распределением классов, но благоприятным моментом является отсутствие пропусков в данных.

Достижимая точность классификации составляет примерно 70%.

## Задачи

### Задача 1. Созидательное (?) разрушение

Некто имеет в своем распоряжении  $N$  строго одинаковых копий одного классификатора, обладающего точностью  $p$ . Желая повысить точность путем комбинирования моделей, он вносит в выход каждой из копий свой источник случайных ошибок, причем ошибки от действия различных источников статистически независимы. Далее, полученные классификаторы объединяются в комитет. Можно ли таким способом достигнуть точности выше, чем исходная  $p$ ?

Изменится ли ответ задачи, если независимые ошибки прибавляются ко входам тождественных копий обученного классификатора, объединенных в комитет?

**Задача 2. Вероятность ошибки алгоритма Boost1**

Используя арифметику вероятностей, показать, что ошибка тройки классификаторов в алгоритме Boost1 составляет  $3\alpha_2 - 2\alpha_3$ , где  $\alpha$  — вероятность ошибки одного классификатора.

**Задача 3. (Без решения)**

Получите оценки скорости деградации точности бэггинг-комитета при уменьшении числа примеров в каждой из бутструп-выборок при сохранении общего числа членов комитета. Имеет ли смысл в каждой бутструп-выборке иметь *большее* число примеров, чем в исходном наборе данных?

**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.

**Ю. Р. ЦОЙ**

Томский политехнический университет,

г. Томск

**E-mail: qai@mail.ru**

**ВВЕДЕНИЕ В НЕЙРОЭВОЛЮЦИОННЫЙ ПОДХОД: ОСНОВНЫЕ  
КОНЦЕПЦИИ И ПРИЛОЖЕНИЯ**

**Аннотация**

В лекции рассматривается нейроэволюционный (НЭ) подход — направление исследований, находящееся на стыке искусственных нейронных сетей (ИНС) и эволюционных вычислений. Выделены преимущества и недостатки НЭ-подхода при решении задач эволюционной настройки весов и структуры ИНС. Рассматривается применение НЭ-алгоритмов к решению задач адаптивного управления, адаптивного поведения, многоагентных систем, эволюционной робототехники, поиска игровых стратегий и компьютерного творчества.

**Yu. R. TSOY**

Tomsk Polytechnic University,

Tomsk

**E-mail: qai@mail.ru**

**AN INTRODUCTION TO NEURO-EVOLUTIONARY APPROACH:  
MAIN CONCEPTS AND APPLICATIONS**

**Abstract**

This lecture concerns neuroevolutionary (NE) approach — a research domain inspired by both artificial neural networks (ANNs) and evolutionary computations. Advantages and disadvantages of NE approach for ANN design and training are lined out. Application of the NE algorithms for problems of adaptive control, adaptive behavior, multi-agent systems, evolutionary robotics, game strategies search and computer creativity is described.

## Введение

Выбор топологии и настройка весов связей искусственной нейронной сети (ИНС) [7, 11] являются одними из важнейших этапов при использовании нейросетевых технологий для решения практических задач. От этих этапов напрямую зависит качество (адекватность) полученной нейросетевой модели, системы управления и т. д. В данной лекции в общем виде рассматривается нейроэволюционный (НЭ) подход, как один из возможных вариантов решения проблем настройки структуры и обучения ИНС.

Статья организована следующим образом. В первом разделе обзорно описываются эволюционные алгоритмы и методы адаптации эволюционного поиска. Во втором разделе кратко формулируется проблема формирования обучающего множества данных, необходимого для обучения ИНС с использованием градиентных алгоритмов. В третьем разделе в общем виде описывается нейроэволюционный подход и рассматриваются задачи эволюционного поиска структуры и весов связей ИНС. Некоторые приложения НЭ-алгоритмов для решения трудноформализуемых задач описаны в четвертом разделе. Пятый раздел посвящен краткому освещению исследований НЭ-подхода в мире и России.

## Эволюционные алгоритмы

Рассмотрим следующую «математическую» игру, в которой есть ведущий и участники.

Ведущий загадывает произвольную функцию  $F$  одного переменного, непрерывную на некотором промежутке (например,  $[-10; 10]$ ) и имеющую на нем минимум. Игра состоит из этапов. На каждом этапе все участники по очереди называют по одному значению аргумента, а ведущий вслух объявляет соответствующие значения функции  $F$ , после чего участники на основе полученных ответов «измышляют» новые значения переменной. Победителем считается тот участник, который первым сумеет найти значение переменной, при котором  $F$  принимает минимальное значение (с заданной точностью).

На самом первом этапе значения переменной будут, скорее всего, названы участниками случайно. Но уже на втором этапе, зная предыдущие ответы ведущего, участники будут стараться подобрать значения аргумента

так, чтобы они, например, были как можно ближе к предыдущему «лучшему» значению. По мере прохождения все большего числа этапов, участники будут накапливать информацию о функции  $F$  и по прошествии достаточно большого промежутка времени можно предположить, что значение аргумента, доставляющего минимум функции  $F$ , будет отгадано и при этом практически «вслепую», методом проб и ошибок, без какой-либо информации о свойствах функции, кроме ее значений в определенных точках.

Данный «игрушечный» пример необходим для того, чтобы показать саму суть идеи угадывания с использованием множества (*популяции*) решений-кандидатов, которую можно применить и для решения более сложных задач. При этом можно провести аналогии между процессом игры и природной эволюцией, выявив аналогии принципов наследственности (используется информация о значениях функции для рассмотренных на предыдущих этапах значений аргумента), изменчивости (ясно, что на следующем этапе целесообразно использовать не встречавшиеся ранее значения переменной) и естественного отбора (значения переменной, в которых значение  $F$  сравнительно велико не стоит, по всей видимости, рассматривать в дальнейшем). И здесь, очевидно, представляет интерес разработка определенной общей стратегии «угадывания», которую можно формализовать и запрограммировать, и которая могла бы использоваться для генерации новых вариантов решений, на основании информации о значениях функции  $F$ .

Группу методов и алгоритмов, опирающихся на механизмы, аналогичные описанным выше, называют *эволюционными алгоритмами* (*evolutionary algorithms*) (ЭА), а соответствующую область исследований и разработок — *эволюционными вычислениями* (*evolutionary computation*) [3,4,22,26]. Каждое генерируемое решение-кандидат представляют в виде вектора параметров, называемого *хромосомой* или *особью*. Множество особей, сгенерированных на одной этапе, именуют популяцией. Подмножество особей, используемое для генерации новых особей, называют *родительской подпопуляцией*, а множество сгенерированных новых особей именуют, соответственно, *популяцией потомков*. Операции, используемые для создания популяции потомков, называют *генетическими операторами*. Качество (*приспособленность*) каждого решения-кандидата определяется в результате оценивания этого решения с помощью функции  $F$ , которую называют *функцией приспособленности*. Общая схема эволюционного поиска, описывающая большинство существующих моделей ЭА, и соответствующие каждому этапу эволюционные принципы представлены на рис. 1. Также

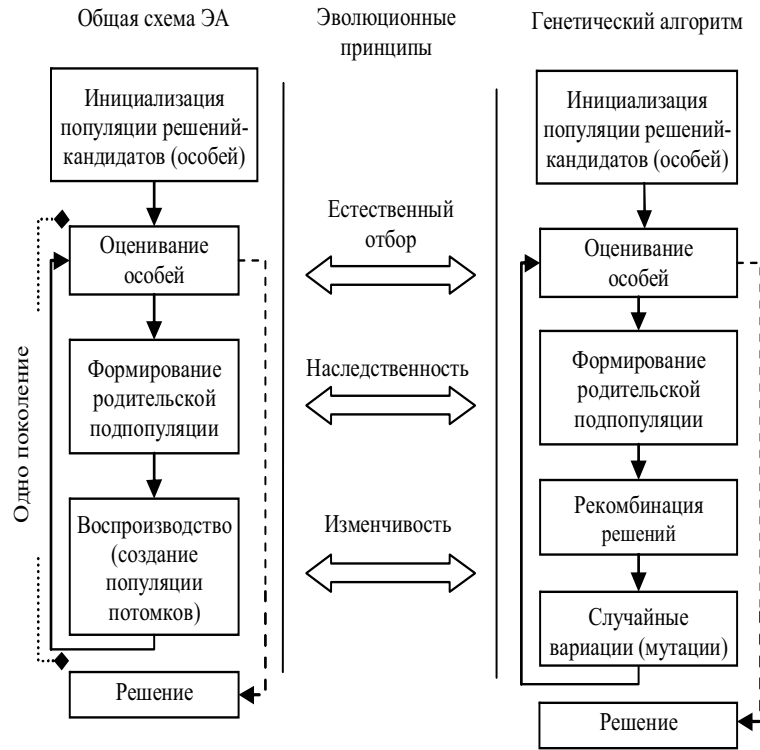


Рис. 1. Общая схема эволюционного поиска, пример схемы генетического алгоритма и соответствующие эволюционные принципы

на рис. 1 для сравнения показана общая схема *генетического алгоритма* (ГА), одного из самых распространенных видов ЭА. В ГА для генерации потомков в качестве основных используются два оператора: *кроссинговер* и *мутация*. Первый оператор необходим для рекомбинации параметров фиксированного числа родительских особей (как правило, двух), выбираемых из родительской подпопуляции, при этом создаются особи-потомки (обычно 1 или 2). Второй оператор используется для внесения случайных изменений (вариаций) в существующие хромосомы для более интенсивного поиска. Таким образом, популяция потомков наследует некоторые свойства родительской подпопуляции, но отличается от них.

Сама идея применения эволюционных принципов для машинного обучения присутствует также и в известном труде А. Тьюринга, посвященном проблемам создания «мыслящих» машин [89]. Использование одновременно множества решений делает возможным параллельный поиск и часто позволяет компенсировать возможную неопределенность при вычислении приспособленностей [20], а также исправить, «починить» (repair) ненужные изменения хромосом [25].

Одним из преимуществ использования ЭА при решении задач оптимизации является их нетребовательность к «знанию» предметной области. Эффективность и качество работы ЭА во многом определяется следующими составляющими и их параметрами:

1. *Генетическое кодирование*. Определяет исследуемое пространство поиска и отношение между генотипом (хромосомами) и фенотипом (соответствующими решениями) («один-к-одному», «один-к-многим», «многие-к-одному»)
2. *Генетические операторы*. Используются для рекомбинации и вариации представленных в популяции хромосом и соответствующих им решений. Сюда же относятся операторы селекции и формирования нового поколения.
3. *Функция приспособленности*. Необходима для определения качества получаемых решений и определяет характеристики ландшафта пространства поиска (количество локальных экстремумов, наличие плато, ограничения).
4. *Общая схема эволюционного поиска*. Определяет последовательность выполнения различных операций эволюционного поиска.

Настройка параметров ЭА существенно влияет на его эффективность и качество получаемых решений. Различные параметры влияют на разные аспекты эволюционного поиска, среди которых выделим два наиболее общих [30]:

1. *Исследование пространства поиска (exploration)*.
2. *Использование найденных «хороших» решений (exploitation)*.

Первый аспект отвечает за способности ЭА к эффективному поиску решения и характеризует способности алгоритма избегать локальных экстремумов. Второй аспект важен для постепенного улучшения имеющихся результатов от поколения к поколению на основе уже найденных «промежуточных» решений.

Пренебрежение исследовательскими способностями приводит к существенному увеличению времени работы ЭА и ухудшению результатов из-за «застывания» алгоритма в локальных экстремумах. В итоге становится возможной *преждевременная сходимост* генетического алгоритма (также говорят о *вырождении популяции*), когда решение еще не найдено, но в популяции практически все особи становятся одинаковыми и долгое время (порядка нескольких десятков и сотен поколений) не наблюдается улучшения приспособленности. Игнорирование найденных решений может привести к тому, что работа ГА будет напоминать случайный поиск, что также отрицательно сказывается на эффективности поиска и качестве получаемых решений.

Основная цель в настройке параметров ГА и, одновременно, необходимое условие для стабильного получения хороших результатов — это достижение баланса между исследованием пространства поиска и использованием найденных решений [3, 30]. Взаимосвязь между параметрами генетического алгоритма, а также их влияние на эволюционный процесс носит сложный характер. На рис. 2 схематично изображено влияние изменения некоторых параметров ГА на характеристики эволюционного поиска.

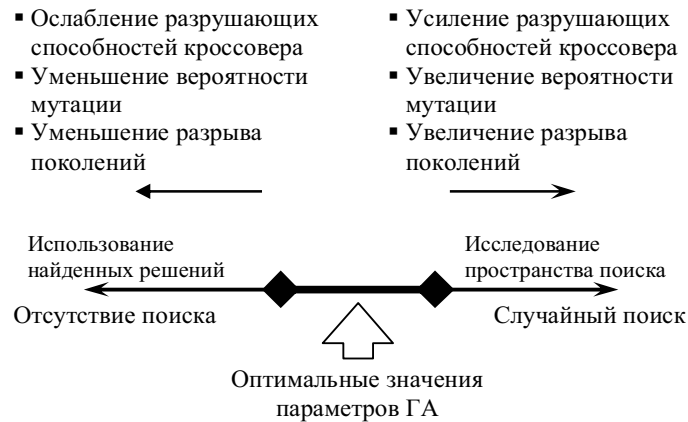


Рис. 2. Влияние некоторых параметров ГА на характеристики эволюционного поиска

**Адаптация в ЭА**

Одной из отличительных особенностей ЭА являются их адаптивные способности, что дает возможность реализовать подстройку параметров ЭА в процессе его работы для повышения эффективности ЭА и качества результатов. Целесообразно выделить следующие варианты настройки значений параметров ЭА [48]:

1. Детерминированная настройка параметров.
2. Адаптивная настройка параметров.
3. Адаптивная самонастройка параметров.

В случае детерминированной настройки параметров ЭА [12,46,65] задается процедура, управляющая изменением значений параметров. При этом состояние процесса эволюционного поиска не учитывается, а принимается во внимание только количество поколений, прошедших с момента запуска ЭА. Например, в [46] предложена следующая формула для подстройки вероятности битовой мутации  $P_m$  в зависимости от номера поколения  $t$ :

$$P_m(t) = \sqrt{\frac{\alpha}{\beta} \frac{\exp(-\gamma t/2)}{N\sqrt{L}}},$$

где  $N$  — размер популяции,  $L$  — длина хромосомы в битах,  $\alpha$ ,  $\beta$  и  $\gamma$  — константы.

При использовании варианта с адаптивной настройкой параметров ЭА [3, 33, 53, 60, 96] также определяется процедура изменения значений параметров. Но, в отличие от предыдущего варианта, параметры изменяются в зависимости от характеристик эволюционного поиска. В данном варианте становится доступен уровень адаптации, учитывающий приспособленность, генотипические и фенотипические характеристики каждой отдельной особи. Например, уменьшение вероятности мутации для более приспособленных особей, и увеличение — для менее приспособленных. Из ранних работ отметим известное эмпирическое правило «1/5» Рехенберга [74], где предполагается, что доля успешных мутаций составляет 1/5 часть от общего числа мутаций и вероятность мутации адаптивно настраивается, чтобы соответствовать этому правилу. В работе [21] предлагается алгоритм подстройки размера популяции, основанный на идее из [19], где вводится дополнительный параметр, время жизни  $\Lambda_i$  хромосомы, вычисляемый в зависимости от ее приспособленности  $F_i$  [21] (для задачи

минимизации целевой функции  $F$ ):

$$\Lambda_i = \begin{cases} \Lambda_{min} + \mu \frac{F_{worst}(t) - F_i}{F_{worst}(t) - F_{avg}(t)}, & \text{если } F_i \geq F_{avg}(t), \\ \frac{1}{2}(\Lambda_{max} + \Lambda_{min}) + \mu \frac{F_{worst}(t) - F_i}{F_{worst}(t) - F_{best}(t)}, & \text{если } F_i < F_{avg}(t), \end{cases}$$

$$\mu = \frac{1}{2}(\Lambda_{max} - \Lambda_{min}),$$

где  $\Lambda_{min}$  и  $\Lambda_{max}$  — минимальное и максимальное возможное время жизни;  $F_{worst}(t)$ ,  $F_{best}(t)$  и  $F_{avg}(t)$  — соответственно, худшая, лучшая и средняя приспособленность в поколении  $t$ . В каждом поколении время жизни всех особей, кроме лучшей, уменьшается на 1 и при  $\Lambda_i = 1$  хромосома удаляется из популяции.

При адаптивной самонастройке [9, 31, 41, 44, 47, 55, 74, 75, 81] значения параметров кодируются в хромосоме особи и, как и оптимизируемые параметры решения, претерпевают эволюционные изменения. Значения закодированных параметров ЭА не влияют на величины приспособленностей особей напрямую, но «хорошие» значения параметров часто способствуют улучшению особей и с течением времени распространяются в популяции. Часто подобным образом кодируют вероятности операторов скрещивания и мутации, а также их параметры. В [78] самоадаптация использовалась для определения позиции и числа точек разрыва кроссинговера. Для этого к  $L$ -разрядным хромосомам добавлялись  $L$  дополнительных бит, в которых кодировалось наличие («1») или отсутствие («0») точки разрыва в соответствующей позиции хромосомы. При скрещивании точки разрыва определялись по единичным разрядам в дополнительных разрядах хромосом скрещиваемых особей.

Необходимо отметить, что возможно комбинирование различных вариантов настройки параметров ЭА. К примеру, возможна адаптация размера популяции вместе с самоадаптацией оператора мутации [49].

Адаптация в ЭА возможна не только на уровне параметров, но и на уровне кодирования и использования генетических операторов скрещивания (рекомбинации) и мутации. Неоднократно отмечалось, что использование проблемно-зависимых способов кодирования и операторов позволяет повысить эффективность работы ЭА [3, 23, 57]. Причина заключается в том, что по «классической схеме» генетические операторы применяются

на уровне хромосом (на уровне генотипов), но не на уровне декодированных решений (фенотипический уровень), что может привести к непредсказуемым изменениям соответствующих решений, однако позволяет реализовать унифицированную схему поиска. Выходом из данной ситуации может быть использование специализированных генетических операторов, работающих на уровне фенотипов и адаптирующихся к характеристикам декодированных решений, учитывающих особенности поставленной задачи, хотя такая организация эволюционного поиска менее универсальна. Отличия между двумя схемами поиска представлены на рис. 3.

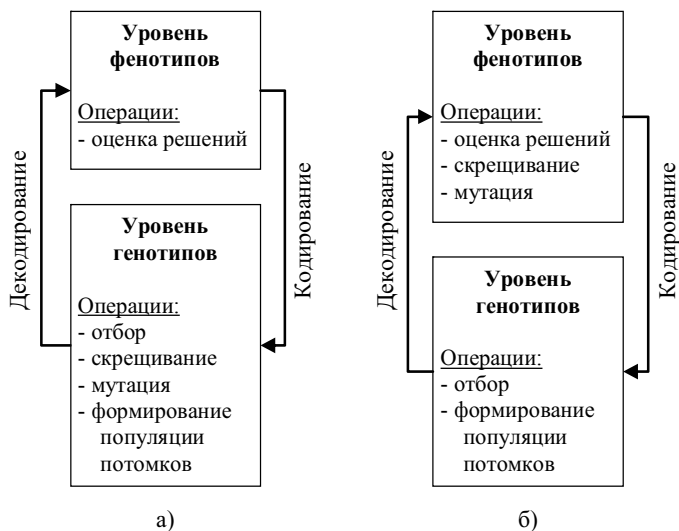


Рис. 3. Различия между схемами эволюционного поиска при реализации генетических операторов, работающих на уровне а) генотипов; б) фенотипов

Использование генетических операторов скрещивания и мутации на уровне фенотипов показало свою эффективность в генетическом программировании [57], в задачах настройки и обучения ИНС [42, 83], при решении многих задач на графах [3], а также в ряде других случаев.

## Проблема формирования обучающего множества данных для ИНС

Обучение ИНС, с «классической» точки зрения, подразумевает использование обучающей выборки, включающей наборы входных сигналов  $\mathbf{X} = \{\mathbf{X}_i : 1 \leq i \leq N\}$  и соответствующих эталонных значений выходных сигналов  $\mathbf{Y} = \{\mathbf{Y}_i : 1 \leq i \leq N\}$ . Использование обучающего множества данных дает возможность подстраивать веса связей ИНС с помощью градиентных алгоритмов, на основании информации об отклонении значений действительных выходных сигналов ИНС  $\mathbf{F} = \{\mathbf{F}_i : 1 \leq i \leq N\}$  от требуемых, которое часто представляется в виде ошибки  $\varepsilon$  ИНС, например, для  $\mathbf{F}_i = \{f_{ij} : 1 \leq j \leq K\}$ ,  $\mathbf{Y}_i = \{y_{ij} : 1 \leq j \leq K\}$ :

$$\varepsilon = \frac{1}{NK} \sum_i \sum_j (f_{ij} - y_{ij})^2.$$

Традиционные подходы к обучению ИНС чаще всего основываются на схеме обратного распространения ошибки [76], обычно использующей алгоритмы градиентного типа, в частности, метод сопряженных градиентов [82], метод Левенберга-Марквардта [63] и ряд других. Однако в ряде случаев формирование обучающей выборки сопряжено со сложностью определения значений компонент вектора  $\mathbf{Y}$  из обучающего множества. Данная проблема возникает при решении некорректных задач, а также если необходимо оценить последовательность выходных сигналов ИНС. К таким задачам относятся задачи, связанные с адаптивным поведением, игровыми стратегиями, обработкой изображений и др.

Одним из возможных решений этой проблемы является обучение ИНС с использованием приближенной интегральной оценки, отражающей качественные, внешние особенности функционирования сети, когда оценивается не соответствие выходных сигналов ИНС эталонным, а качество результата работы сети в целом. Примерами таких оценок являются: время поддержания стабильного состояния объекта управления для задачи нейроуправления [15, 39, 51, 67, 83]; процент выигранных игр, либо оценка позиции для задачи поиска игровых стратегий [54, 61, 71, 84]; качество изображения для задачи обработки изображений [17] и т. д. Такие оценки более естественны и «интуитивны», однако, как следствие, они не могут быть использованы градиентными алгоритмами обучения для подстройки весов связей. Поэтому «подходящий» обучающий алгоритм должен из-

менять веса связей ИНС, не имея информации о величине ошибки для каждого выхода этой сети. Одним из подходов, позволяющих использовать подобные «качественные» оценки, является рассмотренный в следующем разделе нейроэволюционный подход.

### **Нейроэволюционный подход**

Комбинация ИНС и ЭА дает возможность совместить гибкость настройки ИНС и адаптивность ЭА, что позволяет реализовать во многом унифицированный подход к решению широкого спектра задач классификации, аппроксимации и моделирования [2, 16, 53, 68, 80, 93]. Предлагались различные варианты названий для данного направления исследований. В настоящей работе будет использоваться термин «нейроэволюция» (НЭ) [67], а соответствующий подход будем называть нейроэволюционным. Отметим, что предлагаемый вариант не является устоявшимся и окончательным.

Первые работы, посвященные применению ЭА для обучения и настройки ИНС, появились около 20 лет назад. Исследования в этой области, связаны, как правило, с решением следующих задач:

- поиск значений весов связей ИНС при фиксированной структуре;
- настройка структуры ИНС без поиска весов связей;
- настройка параметров алгоритма обучения;
- настройка параметров активационных функций нейронов;
- фильтрация обучающих данных;
- различные комбинации вышеперечисленных задач.

Рассмотрим некоторые из перечисленных выше задач и отметим их особенности.

#### **Эволюционная настройка весов связей ИНС**

Одной из типичных задач, решаемых в рамках НЭ подхода, является задача поиска весов связей ИНС при ее фиксированной структуре [1, 2, 5, 6, 39, 66, 71, 87, 90, 92]. При этом, как правило, рассматривается задача минимизации ошибки выхода ИНС, а в качестве оптимизируемых параметров используются веса связей, значения которых подбираются с помощью ЭА. Одним из обоснований эволюционного обучения ИНС является «застревание» градиентных алгоритмов в локальных экстремумах в процессе

обучения ИНС. Преимуществами использования эволюционной настройки весов связей ИНС являются:

1. Независимость от структуры ИНС и характеристик функций активации нейронов.
2. Отсутствие необходимости в обучающем множестве данных.

Первое преимущество дает возможность использовать единый подход к обучению ИНС с различной структурой. Второе преимущество позволяет осуществлять обучение ИНС без информации об эталонных значениях выходных сигналов, а на основе оценки функционирования ИНС «в целом». Для градиентных алгоритмов оптимизации обучающее множество необходимо, чтобы подстраивать веса связей ИНС на основе расхождения значений реального и требуемого выходного сигнала ИНС.

При использовании ЭА для настройки весов связей ИНС достаточно использовать оценку, отражающую качество нейросетевого решения в целом. Здесь важна адекватность оценки, т.е. если согласно используемой оценке качество первой ИНС лучше качества второй ИНС, то из этого должно следовать, что первая ИНС лучше второй. Кроме адекватности оценки также важно ее существование для любого решения, которое может быть закодировано в хромосоме. При этом такая оценка может вычисляться независимо от расхождения выходного сигнала ИНС с эталонным значением. Таким образом, отсутствие обучающей выборки не является серьезным препятствием для эволюционного обучения ИНС, если существует альтернативный способ оценки ее функционирования. При этом появляется возможность использовать приблизительные оценки функционирования ИНС и оцениваться может не каждый выходной сигнал сети, а последовательность сигналов. Это позволяет расширить круг практических приложений нейроинформатики, а также упростить процесс решения многих задач, связанных с адаптивным нейроуправлением, адаптивным поведением и моделированием.

К недостаткам использования ЭА для обучения ИНС следует отнести следующие:

1. Трудность «тонкой» настройки весов связей на поздних этапах эволюционного поиска.
2. Большие, по сравнению с градиентными алгоритмами, требования к объему оперативной памяти из-за использования популяции ИНС.
3. Проблема конкурирующих решений.

Первая проблема во многом обусловлена использованием целочисленного кодирования весов связей ИНС, что может привести к значительным «скачкам» в пространстве поиска в результате применения операторов скрещивания и мутации. Данное свойство полезно на начальном этапе работы НЭ-алгоритма, когда необходимо быстро исследовать пространство поиска, но затрудняет работу алгоритма на более поздних этапах. При использовании вещественно кодирования эта проблема не так актуальна, но не исчезает полностью из-за необходимости адаптивной настройки параметров операторов ЭА, т.к. характеристики эволюционного поиска изменяются с течением времени.

*Проблема конкурирующих решений (competing conventions problem)* [79, 91] известная также как *проблема перестановки (permutation problem)* [72, 77] связана с кодированием весов связей ИНС. Ее суть заключается в том, что генетическое представление допускает существование нескольких вариантов хромосом, кодирующих одну и ту же ИНС (рис. 4).




Рис. 4. Проблема перестановки. Две одинаковые ИНС могут быть закодированы различным образом «перестановкой» скрытых нейронов. Считается, что «скрещивание» таких сетей практически бесполезно [83]

Предложено несколько вариантов решения проблемы перестановки, среди которых необходимо отметить следующие:

1. Упорядочение списка весов связей кодируемых ИНС (выравнивание хромосом) по значениям весов [87], либо с использованием специальных меток [83]. Считается, что такие меры позволят уменьшить вероятность появления особей, представляющих одинаковые ИНС.

Также возможно раннее удаление особей-дубликатов на этапе формирования популяции следующего поколения.

2. Разработка адаптивных операторов скрещивания [72, 77], уменьшение размера популяции, а также повышение вероятности мутации.
3. Уменьшение роли оператора кроссинговера, либо полный отказ от его использования [18, 94]. При этом предполагается, что: (а) вероятность возникновения одинаковых ИНС в результате мутаций различных особей незначительна; (б) в случае, если такие особи все-таки появились, мутации приведут к меньшим «разрушениям», чем скрещивание.

Отметим, что вопрос об актуальности проблемы конкурирующих решений остается открытым. Из-за того, что, в общем случае, вероятность появления в одной популяции двух одинаковых ИНС мала, проблема конкурирующих решений может игнорироваться [43, 62, 67].

### Эволюционная настройка структуры ИНС

Еще одной типичной задачей НЭ подхода является задача эволюционной настройки структуры ИНС. В хромосоме кодируется топология ИНС, а настройка весов осуществляется, например, с использованием градиентных алгоритмов [13, 36, 56]. Каждая особь, представляющая собой сеть той или иной структуры, оценивается в зависимости от результатов обучения: чем лучше результат, тем более приспособлена особь. Поскольку выбор топологии ИНС является, как правило, сложной задачей, решаемой методом проб и ошибок, то эволюционный поиск нейросетевой структуры способен облегчить и в определенной степени автоматизировать процесс решения задачи настройки и обучения ИНС.

Перечислим преимущества и недостатки эволюционной настройки структуры ИНС.

Преимущества:

1. Возможность автоматического поиска топологии ИНС и получения более точной нейросетевой модели за счет рассмотрения «нестандартных», нерегулярных топологий.
2. Независимость от характеристик функций активации нейронов.

Для упрощения задачи и повышения качества результатов, в процессе поиска топологии ИНС возможно использование дополнительных регулирующих ограничений, помогающих избежать чрезмерного «разрастания»

сети, которое выражается в быстром увеличении количества скрытых нейронов и связей между ними.

Недостатки:

1. Сложность оценки структуры ИНС без информации о значениях весов связей.
2. Сложность организации поиска топологии ИНС.

Первый недостаток представляет основную проблему эволюционной настройки структуры ИНС. Он, в основном, обусловлен чувствительностью результатов обучения к начальным условиям и значениям параметров алгоритма обучения. Таким образом, хромосоме, представляющей ИНС с некоторой структурой, могут соответствовать совершенно разные нейросетевые модели с точки зрения их качества и свойств (в таких случаях говорят, что одному генотипу соответствует множество фенотипов). Для уменьшения влияния случайных факторов на оценку структуры ИНС проводится несколько независимых операций обучения [13, 36], усредненный результат которых и используется в качестве оценки топологии ИНС. Несмотря на существующее мнение, что ИНС с более простой структурой обладают лучшими способностями к обобщению, этот вопрос все еще нельзя считать до конца решенным, т. к. многое зависит от результатов обучения [14].

Сложность объективной оценки топологии ИНС порождает также сложность оценки отдельных структурных частей сети и возможных структурных модификаций. Данная проблема характерна также и для алгоритмов одновременной настройки и обучения ИНС (см. раздел «Одновременная эволюционная настройка весов связей и структуры ИНС»), поэтому многие дальнейшие замечания относятся в равной степени и к эволюционному поиску структуры ИНС, и к одновременной настройке структуры и весов связей ИНС. Для изменения структуры ИНС часто применяются следующие операции:

- добавление/удаление нейронов;
- добавление/удаление связей.

Встречаются также модификации этих операций, включающие, например, «расщепление» существующего нейрона, «перенаправление» связи [67, 68] и др.

Итак, выбор типа структурного изменения ИНС в общем случае неоднозначен из-за того, что оценка необходимости модификации топологии ИНС и варианта этой модификации не всегда возможна. Известны следующие

варианты решения проблемы выбора операции модификации структуры ИНС:

- определение эффективности каждой операции преобразования топологии ИНС на основании оценки качества получаемых НС-решений [52];
- использование дополнительной информации об ИНС для ее модификации (например, вычисление «значимости» связей [94], эвристическая оценка структуры ИНС [15, 18]).

Заметим, что существуют неэволюционные подходы к настройке топологии ИНС либо во время ее обучения (алгоритм каскадной корреляции Фальмана [34] и его модификации [59] и др.), либо по завершении процесса обучения (алгоритмы Optimal Brain Damage (OBD) [58], Optimal Brain Surgeon (OBS) [45] и др.). Несмотря на то, что в [73] показана эффективность использования эволюционного подхода для настройки топологии ИНС по сравнению с алгоритмами OBD и OBS, однако детального исследования на эту тему, насколько известно автору, не проводилось.

### **Одновременная эволюционная настройка весов связей и структуры ИНС**

Использование эволюционного подхода позволяет одновременно настраивать веса связей и структуру ИНС [15, 18, 42, 51–53, 61, 67, 68, 83, 84, 86, 94]. При этом в хромосоме кодируется информация о весах и межнейронных связях ИНС. Возможно использование как бинарного, так и вещественного кодирования для записи весов связей, а структура сети может быть представлена с использованием различных способов кодирования [16, 93].

В силу того, что в случае одновременной настройки весов связей и структуры ИНС фактически комбинируются две различные задачи, пространство поиска многократно увеличивается и часто включает подпространства различной размерности (для ИНС с разным количеством связей). Для упрощения задачи поиска в таком сложном пространстве часто в явном или неявном виде вводятся ограничения на топологию ИНС и/или ее изменения:

- ограничение количества скрытых нейронов [18, 52, 53, 67, 68];
- ограничение количества связей [35, 67, 68];
- ограничение изменения топологии ИНС (рассматриваются только растущие ИНС [83, 86], либо только многослойные ИНС [8]).

Следствием первых двух ограничений часто является фиксация длины хромосомы, что существенно уменьшает пространство возможных решений и не способствует эффективному поиску структуры ИНС, но существенно упрощает задачу и позволяет использовать «стандартные» операторы скрещивания и мутации. Для повышения гибкости поиска НЭ-алгоритма используют генетическое кодирование с переменной длиной хромосомы, которое позволяет добавлять и (в некоторых реализациях) удалять гены в процессе работы алгоритма [15, 52]. Это ведет к изменению общего порядка следования генов и требует реализации специализированных генетических операторов, учитывающих особенности используемого кодирования.

Одновременное решение двух отдельных задач — настройки весов связей и структуры ИНС, позволяет в некоторой степени скомпенсировать недостатки, присущие каждой из них в отдельности и объединить их преимущества. С другой стороны, «платой» за это является огромное пространство поиска, а также объединение ряда недостатков, вызванных использованием эволюционного подхода. Суммируя, перечислим преимущества и недостатки.

Преимущества:

1. Независимость от структуры ИНС и характеристик функций активации нейронов.
2. Отсутствие необходимости в обучающей выборке.
3. Возможность автоматического поиска топологии ИНС и получения более точной нейросетевой модели.

Одним из основных преимуществ одновременной эволюционной настройки весов связей и структуры ИНС является возможность автоматизированного поиска ИНС, располагая только критерием оценки ИНС для осуществления эволюционного поиска. При этом, как и для эволюционного обучения ИНС (см. раздел «Эволюционная настройка весов связей ИНС»), наличие обучающей выборки не является обязательным, а НЭ-алгоритм может применяться для поиска ИНС с любыми активационными функциями нейронов.

По сравнению с раздельным эволюционным поиском структуры ИНС и настройкой весов связей, одновременное решение этих задач позволяет избежать некоторых недостатков. Так появление в популяции особей, которым соответствуют ИНС с различными топологиями, уменьшает значимость проблемы конкурирующих решений (см. раздел «Эволюционная

настройка весов связей ИНС»), а наличие информации о весах связей позволяет обойти проблему субъективной оценки структуры ИНС, в силу того, что оценивается не структура нейросети, а вся ИНС «целиком».

Недостатки:

1. Сложность «тонкой» настройки весов связей на поздних этапах эволюционного поиска.
2. Большие, по сравнению с градиентными алгоритмами, требования к объему оперативной памяти из-за использования популяции ИНС.
3. Сложность организации поиска топологии ИНС.

### Приложения НЭ-подхода

Помимо «стандартных» нейросетевых задач классификации и аппроксимации с использованием обучающего множества данных НЭ-алгоритмы представляют большой интерес для решения трудноформализуемых задач, где присутствует сложность формирования обучающего множества и/или затруднена оценка качества работы ИНС. Рассмотрим коротко примеры таких задач и некоторые особенности использования НЭ-подхода.

**Адаптивное управление** [2, 15, 40, 53, 67, 83]. При использовании НЭ-алгоритмов для решения задач адаптивного управления можно перейти к безмодельному обучению, когда не нужно знать прямую либо обратную математическую модель объекта управления<sup>1</sup> (ОУ), а ИНС оценивается в зависимости от используемого ОУ.

Например, в [2] для обучения ИНС управлению инерционным колебательным звеном второго порядка с передаточной функцией вида

$$W = \frac{k}{T^2 s^2 + 2T\zeta s + 1}$$

использовалась следующая оценка:

$$F = \frac{1}{3} \sum_{i=1}^3 \left( \frac{1}{t_{max}} \int_0^{t_{max}} (x(t) - u_r(t))^2 dt \right),$$

где  $x(t)$  и  $u_r(t)$  — соответственно выход ОУ и сигнал задания в момент времени  $t$ ;  $t_{max}$  — время интегрирования переходного сигнала в системе.

<sup>1</sup>Поиск такой модели сам по себе часто является нетривиальной задачей.

В [15, 67, 83] при решении задачи балансирования на тележке одного либо двух шестов разной длины использовалась следующая оценка ИНС:

$$F = t,$$

где  $t$  — количество итераций, в течение которых удавалось удержать шесты от падения. В случае использования двух шестов без информации о скорости их движения, когда появляется дополнительное требование подавления колебательных движений тележки, в [40, 53, 83] оценка ИНС определяется уже следующим образом (обозначения из [83]):

$$F = 0.1f_1 + 0.9f_2,$$

$$f_1 = t/1000,$$

$$f_2 = \begin{cases} 0, & t < 100, \\ \frac{0,75}{\sum_{i=1}^{100} (|x^i| + |\dot{x}^i| + |\theta_1^i| + |\dot{\theta}_1^i|)}, & t \geq 100, \end{cases}$$

где  $x^i$  и  $\dot{x}^i$  — положение и скорость тележки,  $\theta_1^i$  и  $\dot{\theta}_1^i$  — положение и угловая скорость первого шеста.

**Адаптивное поведение и многоагентные системы** [1, 6, 37, 85]. Здесь большой интерес представляет возможность реализации интеллектуальных агентов [10] с использованием ИНС, при этом возможно наличие коллективного поведения [85, 95]. В качестве примера можно привести проект NERO (Neuro-Evolution of Robotic Operatives<sup>2</sup>) [85]. Ключевой технологией проекта является модифицированный алгоритм NEAT для одновременной настройки структуры и весов связей ИНС, разработанный Кеннетом Стэнли (Kenneth Stanley). Пользователь сначала тренирует на специальном полигоне команду НС-агентов, а затем его команда «соревнуется» с агентами компьютера или другого пользователя на своеобразном «поле боя». Поведение агентов определяется соответствующими им ИНС, которые настраиваются в процессе обучения на полигоне. Действия агентов зависят от создающейся на тренировочном полигоне ситуации и определяются приоритетами поведения (расстояние до противника, подвижность агентов,

<sup>2</sup>URL: [http://dmc.ic2.org/nero\\_public](http://dmc.ic2.org/nero_public)

активность стрельбы и др.), заданными пользователем. Более приспособленные с точки зрения выбранных приоритетов агенты используются для генерации агентов-потомков, которые замещают худших из существующих агентов.

Для выбора действия (направление движения и стрельба) агентам доступна следующая информация:

- расположение агентов-противников, находящихся в поле зрения агента;
- находится ли агент-противник на линии огня;
- расположение препятствий (стены, различные объекты);
- направление стрельбы ближайшего агента-противника.

Использование для реализации проекта NERO НЭ-алгоритма позволяет в реальном времени осуществлять поиск разнообразных стратегий поведения агентов. В процессе обучения агенты учатся решать такие задачи, как поиск маршрута движения в присутствии препятствий, преследование агентов-противников, использование стен для прикрытия от огня и др. Отметим, что во время обучения агентов задачи ставятся в общем виде (дойти до определенной точки, атаковать цель и т. д.) и возникновение сложных стратегий поведения (например, укрытие за стенами) зависит от ситуации, которую создается на тренировочном полигоне.

**Эволюционная робототехника** (Evolutionary robotics) [28, 70]. Представляет собой сравнительно молодое направление исследований, направленное на создание и исследование автономных роботов, которые рассматриваются как искусственные организмы, поведение которых развивается без человеческого вмешательства в результате взаимодействия с окружающей средой. Эволюционная робототехника во многом опирается на науки о природе, биологию и этологию, и использует такие концепции и подходы, как нейронные сети, генетические алгоритмы, динамические системы и бионика. Основное отличие исследований в области эволюционной робототехники от исследований адаптивного поведения интеллектуальных агентов заключается в использовании реальных роботов, а не их программных моделей. Это ограничивает условия проведения экспериментов (нельзя выйти за рамки действующих физических законов и технических и материальных ограничений), но добавляет значительно больше реализма за счет необходимости учета инерции, помех, характеристик датчиков, микроконтроллеров и материалов и т. д., что представляет интерес с практической

точки зрения. Для управления роботами используются, как правило, разнообразнейшие модели ИНС и нейронов. Например, в [37] рассматривается обучение микроробота Alice [27] навигации с избеганием препятствий с использованием эволюционной настройки структуры ИНС с упрощенной моделью спайкового нейрона (используются обозначения из [37]):

$$o_i^t = \begin{cases} 1 \text{ and } v_i^t = v_i^{min}, & v_i^t > v_i^{max} + r^t, \\ 0, & v_i^t \leq v_i^{max} + r^t, \end{cases}$$

где  $o_i^t$  — выходной сигнал;  $v_i^t$ ,  $v_i^{min}$  и  $v_i^{max}$  — соответственно текущий, минимальный и максимальный мембранный потенциал нейрона;  $r^t$  — случайное целое, необходимое для предотвращения осцилляций и «блокировок» в ИНС с обратными связями. Значение мембранного потенциала накапливается с течением времени с учетом входных сигналов нейрона и постоянной утечки. Оценка ИНС определяется в зависимости от скорости движения робота и расстояния до препятствий, которые необходимо максимизировать:

$$F = \sum_t V^t (1 - \Delta V^t) (1 - i),$$

где  $V^t$  — суммарная скорость вращения колес робота;  $\Delta V^t$  — модуль разности скорости вращения левого и правого колеса;  $i$  — максимальная текущая активность одного из инфракрасных датчиков препятствий.

**Поиск игровых стратегий** [54, 61]. Данное направление исследований рассматривает использование ИНС для принятия решений в настольных играх. Часто рассматриваются крестики-нолики [54] и го [61, 71, 84]. Здесь оценка работы ИНС затрудняется необходимостью учета большого количества различных вариантов развития событий и связанной с этим неопределенностью, что делает саму оценку неточной. В [84] показано, что при использовании НЭ-подхода возможно успешное обучение ИНС игре в го против программы с детерминированным алгоритмом [38] на поле  $5 \times 5$  на основе оценки

$$F = 100 - \left( \frac{2 \sum_{i=1}^n e_i}{n} + e_f \right),$$

где  $e_i$  — счет в партии после  $i$ -го хода,  $n$  — число ходов в партии,  $e_f$  — финальный счет партии. Также отметим вариант с «автообучением», когда

настройка ИНС осуществляется путем соревнования одной эволюционирующей популяции ИНС с другой [61] (так называемая конкурентная коэволюция (competitive coevolution)). При этом оценка ИНС формируется в результате серии матчей с ИНС из «противоборствующей» популяции:

$$F = \sum_{i \in O} \frac{1}{L_i},$$

где  $O$  — множество оппонентов, побежденных данной ИНС, а  $L_i$  — число проигранных  $i$ -й побежденной ИНС. НЭ-обучение направлено на минимизацию оценки  $F$ .

**Компьютерное творчество** [24, 64]. Применение ЭА-алгоритмов для компьютерного синтеза изображений [86, 88], звуков и мелодий [29, 32] и геометрических форм [69, 86] возможно благодаря использованию концепции *эстетической селекции* (*aesthetic selection*, называемой также *aesthetic evolution*, *interactive evolution*) [64]. Особенностью этой концепции является интерактивное взаимодействие ЭА с пользователем, который «вручную» определяет, какие решения (изображения, звуки и т. д.) в популяции являются более приемлемыми и, следовательно, какие особи будут допущены к скрещиванию. Это существенно увеличивает время эволюционного обучения и накладывает значительные ограничения на параметры ЭА и получаемых решений (нельзя использовать популяцию большого размера; решения должны быть такими, чтобы их можно было оценить за сравнительно небольшой промежуток времени и др. [64]), однако позволяет решать поставленную задачу, избежав очевидных и неразрешенных в настоящее время трудностей с формализацией критериев оценки решений.

Например, в [86] описан способ генерации разнообразных геометрических образов и узоров, где ИНС реализует следующее преобразование:  $L = g(x_1, x_2, d)$ , здесь  $L$  — нормированная яркость пикселя с прямоугольными координатами  $(x_1, x_2)$ ,  $d$  — расстояние до центра изображения. Таким образом, ИНС используется для «рисования», при этом яркость пикселей зависит от их координат. Отбор ИНС по всей популяции осуществляется пользователем путем выбора понравившихся ему соответствующих образов. Пример эволюции образа, названного «космический корабль» («spaceship»), сгенерированного ИНС в различных поколениях эволюционного поиска, показан на рис. 5.




Рис. 5. Пример эволюции образа «космический корабль», сгенерированного ИНС в различных поколениях: а) начальный образ; б) появление узоров на «крыльях»; с) изменение формы «хвоста»; д) появление «выхлопов» за «крыльями».

### НЭ-алгоритмы в мире

Отдельными вопросами разработки НЭ-алгоритмов активно начали заниматься в конце 80-х – начале 90-х годов, несмотря на то, что сама идея применения эволюционного подхода к настройке ИНС появилась значительно раньше (например, в [50]). В настоящее время в мире существуют лаборатории и исследовательские группы, среди которых отметим следующие.

**Группа нейросетевых исследований** (Neural Networks Research Group) в Университете Остина, штат Техас, под руководством *Ристо Мииккулайнена* (Risto Miikkulainen). Тематика исследований этой группы необычайно широка и включает в себя:

- обучение навигации Индивидуального Спутника-Ассистента (Personal Satellite Assistant) космонавта;
- использование НЭ в компьютерных играх реального времени;
- разработка сложных систем с использованием эволюционирующих генераторов образов (evolving patterns generators);
- разработка автомобильной системы предупреждений об опасности;
- кооперативная коэволюция (coevolution) в многоагентных системах.

Приведенный список не является полным. Также отметим, что термин «нейроэволюция», использованный применительно к моделям эволюционирующих нейронных сетей, появился именно в статьях этой группы.

**Лаборатория интеллектуальных систем** (The Laboratory of Intelligent Systems) в Цюрихе, под руководством *Дарио Флореано* (Dario Floreano). Исследования лаборатории направлены на развитие робототехнических систем и методов искусственного интеллекта, основанных на биологических принципах самоорганизации. Основные темы исследований:

- бионические летающие микророботы;
- эволюционное аппаратное и программное обеспечение, включая также эволюционную робототехнику;
- исследование коллективных и ройных (swarm) систем.

**Лаборатория автономных роботов и искусственной жизни** (Laboratory of Autonomous Robotics and Artificial Life), Рим, под руководством *Стефано Нолфи* (Stefano Nolfi). Основное направление исследований — изучение адаптивных искусственных организмов, взаимодействующих со внешней средой и управляемых ИНС, направленное на понимание механизмов, лежащих в основе индивидуального и коллективного поведения.

**Центр исследований вычислительного интеллекта и его приложений** (The Centre of Excellence for Research in Computational Intelligence and Applications — CERCIА) в Университете Бирмингема под руководством *Зина Яо* (Xin Yao). Среди многочисленных направлений исследований центра есть немало проектов по разработке и применению НЭ-алгоритмов с использованием эволюционного программирования.

**Группа исследований оптимизации адаптивных систем** (Research Group Optimization of Adaptive Systems), Институт нейроинформатики в Университете Бохума, Германия, под руководством *Кристиана Игеля*

(Christian Igel). Исследования направлены на изучение взаимодействия самоорганизации, обучения и эволюции при создании адаптивных систем и анализ роли структуры в нейросетевой обработке информации.

В **России** исследования НЭ-алгоритмов ведутся в следующих вузах и научных институтах (в скобках указаны основные направления исследований):

- Ульяновский государственный технический университет (интеллектуальные системы, принятие решений);
- Калужское отделение МГТУ им. Н. Э. Баумана (интеллектуальные системы, принятие решений);
- Институт оптико-нейронных технологий совместно с Институтом прикладной математики им. М. В. Келдыша (адаптивное поведение);
- Красноярский государственный технический университет (классификация и медицинская диагностика);
- Томский политехнический университет (обработка изображений).

### Заключение

Актуальность НЭ-подхода объясняется следующими его возможностями:

- облегчение решения ряда существующих трудноформализуемых задач в силу отсутствия необходимости в этапе формирования обучающей выборки, который сам по себе может быть достаточно ресурсоемким и сложным;
- расширение прикладных областей нейроинформатики и эволюционных вычислений (например, улучшение качества цифровых изображений);
- развитие перспективных направлений, связанных с созданием интеллектуальных агентов, робототехникой, компьютерным творчеством и др.

Исследования в области ИНС, НЭ и ЭА также представляют интерес ввиду активного развития аппаратных и программных средств параллельных и распределенных вычислений. Так, например, представляет интерес реализация НЭ-алгоритмов с использованием геометрических сопроцессоров современных видеокарт.

В заключение отметим, что часто для успешного решения задачи с использованием НЭ-алгоритма достаточно адекватного понимания самой

проблемы и НЭ-подхода, свидетельством чего является большое число интересных и успешных работ в данном направлении.

### Благодарности

Автор выражает благодарность *В. Г. Редько* и *Ю. В. Тюменцеву* за помощь в подготовке материала и *Ю. В. Тюменцеву* за консультации по использованию пакета  $\LaTeX$ .

### Литература

1. *Бурцев М. С.* Эволюция кооперации в многоагентной системе // VII Всероссийская научно-техническая конференция «Нейроинформатика-2005»: Сб. науч. трудов. В 2-х частях. Ч. 1. – М.: МИФИ, 2005. – с. 217–224.  
URL: <http://mbur.narod.ru/>
2. *Вороновский Г. К., Махотило К. В., Петрашев С. Н., Сергеев С. А.* Генетические алгоритмы, искусственные нейронные сети и проблемы виртуальной реальности. – Харьков: Основа, 1997.  
URL: <http://neuroschool.narod.ru/books/gannvirt.html>
3. *Емельянов В. В., Курейчик В. М., Курейчик В. В.* Теория и практика эволюционного моделирования. – М.: Физматлит, 2003.
4. *Гладков Л. А., Курейчик В. М., Курейчик В. В.* Генетические алгоритмы. – М.: Физматлит, 2006.
5. *Комарцова Л. Г.* Исследование алгоритмов обучения многослойного персептрона // *Нейрокомпьютеры: Разработка и применение.* – 2002, № 12.
6. *Мосалов О. П., Редько В. Г.* Модель эволюционной ассимиляции приобретенных навыков в нейросетевых системах управления адаптивных агентов // VII Всероссийская научно-техническая конференция «Нейроинформатика-2005»: Сб. науч. трудов. В 2-х частях. Ч. 1. – М.: МИФИ, 2005. – с. 210–217.  
URL: <http://www.iont.ru/projects/rfbr/90197/>
7. *Осовский С.* Нейронные сети для обработки информации. – М.: Финансы и статистика, 2002.
8. *Паклин Н.* Обучаем нейронную сеть генетическим алгоритмом. 2003.  
URL: <http://paklin.newmail.ru>
9. *Редько В. Г.* К теории эволюции. Модель возникновения «программ жизнедеятельности» // *Журнал общей биологии.* – 1991, № 3. – с. 334–342.

10. *Тарасов В. Б.* От многоагентных систем к интеллектуальным организациям: Философия, психология, информатика. – М.: Эдиториал УРСС, 2002.
11. *Хайкин С.* Нейронные сети: Полный курс. Пер. с англ. 2-е издание. – М.: Издательский дом «Вильямс», 2006.
12. *Хомич А. В., Жуков Л. А.* Анализ и оптимизация операций мутации и кроссовера в генетических алгоритмах // Доклады V Всероссийской конференции «Новые информационные технологии в исследовании сложных структур». – Томск, Вестник ТГУ, 2004. – с. 111–114.
13. *Хомич А. В., Жуков Л. А.* Эволюционный метод оптимизации структуры нейронной сети с учителем // VII Всероссийская научно-техническая конференция «Нейроинформатика–2005»: Сб. науч. трудов. В 2-х частях. Ч. 1. – М.: МИФИ, 2005. – с. 11–18.
14. *Царегородцев В. Г.* Редукция размеров нейросети не приводит к повышению обобщающих способностей // Материалы XII Всероссийского семинара «Нейроинформатика и ее приложения». – Красноярск, 2004. – с. 163–165.  
URL: <http://www.neuropro.ru/>
15. *Цой Ю. Р., Спицын В. Г.* Применение генетического алгоритма для решения задачи адаптивного нейроуправления. // VII Всероссийская научно-техническая конференция «Нейроинформатика–2005»: Сб. науч. трудов. В 2-х частях. Ч. 1. – М.: МИФИ, 2005. – с. 35–43.  
URL: <http://qai.narod.ru/Publications/>
16. *Цой Ю. Р., Спицын В. Г.* Эволюционный подход к настройке и обучению искусственных нейронных сетей // Электронный рецензируемый журнал «Нейроинформатика». – 2006, том 1, № 1. – с. 34–61.  
URL: <http://ni.iont.ru/Journal/N1/>
17. *Цой Ю. Р., Спицын В. Г., Чернявский А. В.* Способ улучшения качества монохромных и цветных изображений, основанный на применении эволюционирующей нейронной сети // Информационные технологии. – 2006, №. 7. – с. 27–33.
18. *Angeline P.J., Saunders G.M., Pollack J.B.* An evolutionary algorithm that constructs recurrent neural networks // *IEEE Transactions on Neural Networks*. – January 1994.  
URL: <http://citeseer.ist.psu.edu/>
19. *Arabas J., Michalewicz Z., Mulawka J.* GAVAPS – a genetic algorithm with varying population size // Proc. of the *First IEEE International Conference on Evolutionary Computation*. – New York: IEEE Press, 1994. – pp. 73–78.
20. *Arnold D. V., Beyer H.-G.* Performance analysis of evolution strategies with multi-recombination in high-dimensional  $R^N$ -search spaces disturbed by noise. – Reihe CI 94/00, SFB 531, University of Dortmund, Germany, 2000.  
URL: <http://sfbc.cs.uni-dortmund.de>

21. Baeck T., Eiben A. E., van der Vaart N. A. L. An empirical study on GAs “without parameters” // *Proceedings of the 6th Conf. on Parallel Problem Solving from Nature*. – LNCS No. 1917. – Berlin: Springer, 2000. – pp. 315–324.  
URL: <http://www.wi.leidenuniv.nl/~gusz/>
22. Baeck T., Fogel D., Michalewicz Z. *Evolutionary computation*. – Berlin: Springer-Verlag, 2000.
23. Barnett L. *Evolutionary search on fitness landscapes with neutral networks*. – PhD Thesis. The University of Sussex, England, 2003.  
URL: <http://www.cogs.susx.ac.uk/users/lionelb/>
24. Banzhaf W. *Interactive evolution* / In Baeck et al. (Eds.): *Evolutionary Computation I: Basic Algorithms and Operators*. – Bristol and Philadelphia: IOP Publishing, 2000. – pp. 228–234.
25. Beyer H.-G. An alternative explanation for the manner in which genetic algorithms operate // *BioSystems*. – 1997, No. 41, pp. 1–15.  
URL: <http://sfbc.cs.uni-dortmund.de>
26. Beyer H.-G., Schwefel H.-P., Wegener I. *How to analyse evolutionary algorithms*. – Technical Report No. CI-139/02. University of Dortmund, Germany, 2002.  
URL: <http://sfbc.cs.uni-dortmund.de>
27. Caprari G., Estier T., Siegart R. Fascination of downscaling – Alice the sugarcube robot // *Journal of Micro-Mechatronics*. – 2002, vol. 3, No. 1. – pp. 177–189.
28. Cliff D., Harvey I., Husbands P. Explorations in evolutionary robotics // *Adaptive Behavior*. – 1993, No. 2. – pp. 73–110.
29. Chen C.-C. J., Miikkulainen R. Creating melodies with evolving recurrent neural networks // In: *Proc. of the 2001 International Joint Conference on Neural Networks (IJCNN-01)*. – IEEE, 2001.  
URL: <http://nn.cs.utexas.edu/>
30. De Jong K. A., Sarma J. Generation gaps revisited // *Foundations of Genetic Algorithms 2*. – 1993. – pp. 19–28.  
URL: <http://www.cs.gmu.edu/~eclab>
31. Deb K., Beyer H.-G. Self-adaptive genetic algorithms with simulated binary crossover // *Evolutionary Computation*. – 2000, vol. 9, No. 2. – pp. 197–221.
32. “Eden” Project.  
URL: [www.csse.monash.edu.au/~jonmc/projects/eden/](http://www.csse.monash.edu.au/~jonmc/projects/eden/)
33. Eiben A. E., Marchiori E., Valko V. A. Evolutionary algorithms with on-the-fly population size adjustment / In: X. Yao et al. (Eds.): *Parallel Problem Solving from Nature, PPSN VIII, LNCS Vol. 3242*. – Berlin: Springer-Verlag, 2004. – pp. 41–50.  
URL: <http://www.wi.leidenuniv.nl/~gusz/>

34. *Fahlman S.E., Lebiere C.* The cascade-correlation learning architecture / In: *Touretzky D.S.* (Ed.) *Advances in Neural Information Processing Systems 2.* – San Mateo, CA: Morgan Kaufman Publishers, 1990. – pp. 524–532.
35. *Ferreira C.* Gene expression programming: Mathematical modeling by an artificial intelligence. – Angra do Heroismo, Portugal, 2002.  
URL: <http://gene-expression-programming.com/>
36. *Fiszelew A., Britos P., Perichisky G., Garcia-Martinez R.* Automatic generation of neural networks based on genetic algorithms // *Revista Eletronica de Sistemas de Informacao.* – 2003, vol. 2, No. 1.  
URL: <http://citeseer.ist.psu.edu/>
37. *Floreano D., Epars Y., Zufferey J.C., Mattiussi C.* Evolution of spiking neural circuits in autonomous mobile robots // *International Journal of Intelligent Systems.* – 2006, vol. 21, No. 9. – pp. 1005–1024.  
URL: <http://asl.epfl.ch/>
38. URL: <http://www.gnu.org/software/gnugo/gnugo.html>
39. *Gomez F., Miikkulainen R.* Incremental evolution of complex general behavior // *Adaptive Behavior.* – 1997, No. 5. – pp. 317–342.  
URL: <http://www.nn.cs.utexas.edu/>
40. *Gomez F., Miikkulainen R.* Solving non-markovian control tasks with neuroevolution // *Proc. of the International Joint Conference on Artificial Intelligence.* – San Francisco, CA, 1999. – pp. 1356–1361.  
URL: <http://www.nn.cs.utexas.edu/>
41. *Gomez J.* Self adaptation of operator rates in evolutionary algorithms // *Proc. of Genetic and Evolutionary Computation Conference 2004 (GECCO 2004).* – LNCS No. 3102, 2004. – pp. 1162–1173.  
URL: <http://citeseer.ist.psu.edu/>
42. *Gruau F.* Neural network synthesis using cellular encoding and the genetic algorithm. – PhD Thesis. – l’Universite Claude Bernard, Lyon, 1994.  
URL: <http://citeseer.ist.psu.edu/>
43. *Hancock P.* Recombination operators for the design of the neural nets by genetic algorithm // *Parallel Problem Solving from Nature (PPSN-II).* – North-Holland, 1992. – pp. 441–450.
44. *Hansen N., Ostermeier A.* Completely derandomized self-adaptation in evolution strategies // *Evolutionary Computation.* – 2000. – vol. 9, No. 2. – pp. 159–195.
45. *Hassibi B., Stork D.G.* Second order derivatives for network pruning: Optimal brain surgeon / In: *Hanson S.J., Cowan J.D., Giles C.L.* (Eds.) *Advances in Neural Information Processing Systems 5.* – San Mateo, CA: Morgan Kaufman Publishers, 1993. – pp. 164–171.

46. *Hesser J., Manner R.* Towards an optimal mutation probability for genetic algorithms / In: *H.-P. Schwefel, R. Manner* (Eds.): Proc. of the 1st Conference on Parallel Problem Solving from Nature. – LNCS No. 496. – Berlin: Springer-Verlag, 1990. – pp. 23–32.
47. *Hinterding R.* Gaussian mutation and self-adaptation in numeric genetic algorithms // *IEEE International Conference on Evolutionary Computation*. – IEEE Press, 1995. – pp. 384–389.
48. *Hinterding R., Michalewicz Z., Eiben A.E.* Adaptation in evolutionary computation: A survey // Proc. of the 4th IEEE International Conference on Evolutionary Computation. – Indianapolis, 1997. – pp. 65–69.  
URL: <http://www.wi.leidenuniv.nl/~gusz/>
49. *Hinterding R., Michalewicz Z., Peachey T.* Self-adaptive genetic algorithm for numeric functions / In: *H.-M. Voigt, W. Ebeling, I. Rechenberg, H.-P. Schwefel* (Eds.): Parallel Problem Solving from Nature – PPSN IV, LNCS Vol. 1141. – Berlin: Springer-Verlag, 1996. – pp. 420–429.
50. *Holland J.H.* Adaptation in natural and artificial systems. – The University of Michigan Press, 1975.
51. *Igel C.* Neuroevolution for reinforcement learning using evolution strategies // Proc. of *Congress on Evolutionary Computation 2003* (CEC 2003), Vol. 4. – IEEE Press, 2003. – pp. 2588–2595.  
URL: <http://www.neuroinformatik.ruhr-uni-bochum.de/ini/PEOPLE/igel/top.html>
52. *Igel C., Kreutz M.* Operator adaptation in evolutionary computation and its application to structure optimization of neural networks // *Neurocomputing*. – 2003, vol. 55, No. 1–2. – pp. 347–361.  
URL: <http://www.neuroinformatik.ruhr-uni-bochum.de/ini/PEOPLE/igel/top.html>
53. *Igel C., Wiegand S., Friedrichs F.* Evolutionary optimization of neural systems: The use of strategy adaptation / In: *M.G. de Bruin, D.H. Mache, J. Szabados* (Eds.): Trends and Applications in Constructive Approximation. International Series of Numerical Mathematics. – Birkhauser Verlag, 2005.  
URL: <http://www.neuroinformatik.ruhr-uni-bochum.de/ini/PEOPLE/igel/top.html>
54. *James D., Tucker P.* A comparative analysis of simplification and complexification in the evolution of neural network topologies // Proc. of *Genetic and Evolutionary Computation Conference* (GECCO-2004). – New York, NY: Springer-Verlag, 2004.  
URL: <http://citeseer.ist.psu.edu/>
55. *Kita H.* A comparison study of self-adaptation in evolution strategies and real-coded genetic algorithms // *Evolutionary Computation*. – 2000, vol. 9, No. 2. – pp. 223–241.
56. *Kitano H.* Designing neural network using genetic algorithm with graph generation system // *Complex Systems*. – 1990, No. 4. – pp. 461–476.

57. *Koza J.* Genetic programming: a paradigm for genetically breeding computer population of computer programs to solve problems. – MIT Press, Cambridge, MA, 1992.
58. *LeCun Y., Denker J. S., Solla S. A.* Optimal brain damage / In: *Touretzky D. S.* (Ed.): *Advances in Neural Information Processing Systems 2.* – San Mateo, CA: Morgan Kaufman Publishers, 1990. – pp. 598–605.  
URL: <http://yann.lecun.com/>
59. *Littmann E., Ritter H.* Cascade network architectures // *Proc. of International Joint Conference on Neural Networks*, 1992, vol. 2. – pp. 398–404.
60. *Lobo F.* The parameter-less genetic algorithm: Rational and automated parameter selection for simplified genetic algorithm operation. – PhD Thesis. – The University of Lisbon, Portugal, 2000.
61. *Lubberts A., Miikkulainen R.* Co-evolving a go-playing neural network // *Proc. of Coevolution: Turning Adaptive Algorithms upon Themselves*, Birds-of-a-Feather Workshop, Genetic and Evolutionary Computation Conference (GECCO-2001). – San Francisco, CA: Kaufmann, 2001. – pp. 14–19.  
URL: <http://www.nn.cs.utexas.edu/>
62. *Maniezzo V.* Genetic evolution of the topology and weight distribution of neural networks // *IEEE Transactions of on Neural Networks.* – 1994, vol. 5, No. 1.
63. *Marquardt D.* An algorithm for least squares estimation of nonlinear parameters // *SIAM*, 1963. – pp. 431–442.
64. *McCormack J.* New challenges for evolutionary music and art // *SIGEVolution newsletter.* – 2006, vol. 1, No. 1. – pp. 5–11.
65. *Michalewicz Z.* Genetic Algorithms + Data Structures = Evolution Programs. – Berlin: Springer-Verlag, 1992.
66. *Montana D., Davis L.* Training feedforward neural networks using genetic algorithms // *Proc. of the 11th International Joint Conference on Artificial Intelligence.* – San Mateo, CA: Morgan Kaufmann, 1989. – pp. 762–767.
67. *Moriarty D., Miikkulainen R.* Efficient reinforcement learning through symbiotic evolution // *Machine Learning*, 1996, No. 22. – pp. 11–33.  
URL: <http://www.nn.cs.utexas.edu/>
68. *Moriarty D. E., Miikkulainen R.* Forming neural networks through efficient and adaptive coevolution // *Evolutionary Computation.* – 1998, vol. 5, No. 4.  
URL: <http://www.nn.cs.utexas.edu/>
69. *Nguyen T. C., Huang T. S.* Evolvable 3D modeling for model-based object recognition systems / In: *Kinnear K.* (Ed.): *Advances in Genetic Programming.* – Cambridge, MA: MIT Press, 1994. – pp. 459–475.

70. *Nolfi S., Floreano D.* Evolutionary robotics: The biology, intelligence, and technology of self-organizing machines. – Cambridge, MA: MIT Press/Bradford Books, 2000.
71. *Perez-Bergquist A.S.* Applying ESP and region specialists to neuro-evolution for go. – Technical Report CSTR01-24. The University of Texas at Austin, 2001.  
URL: <http://www.nn.cs.utexas.edu/>
72. *Radcliffe N.* Genetic set recombination and its application to neural network topology optimization // *Neural Computing and Applications*. – 1993, vol. 1. – pp. 67–90.
73. *Ragg T., Braun H., Landsberg H.* A comparative study of neural network optimization techniques // In Proc. of the *ICANN'97*. – Springer-Verlag, 1997.
74. *Rechenberg I.* Evolutionsstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution // *Werkstatt Bionik und Evolutionstechnik*. – Stuttgart: Frommann-Holzboog, 1973.
75. *Rudolph G.* Self-adaptive mutations may lead to premature convergence // *IEEE Transactions on Evolutionary Computation*. – 2001, vol. 5, No. 4. – pp. 410–414.
76. *Rumelhart D.E., Hinton G.E., Williams R.J.* Learning representations of back-propagation errors // *Nature* (London). – 1986, vol. 323. – pp. 533–536.
77. *Saravanan N., Fogel D.B.* Evolving neural control systems // *IEEE Expert*. – 1995, pp. 23–27.
78. *Schaffer J.D., Morishima A.* An adaptive crossover distribution mechanism for genetic algorithms / In: *J.J. Grefenstette* (Ed.): Proc. of the 2nd International Conference on Genetic Algorithms and Their Applications. – Lawrence Erlbaum Associates, 1987. – pp. 36–40.
79. *Shaffer J., Whitley D., Eshelmann L.* Combination of genetic algorithms and neural networks: A survey of the state of the art // In Proc. of the *International Workshop on Combination of Genetic Algorithms and Neural Networks* (COGANN-92). – Los Alamos, CA: IEEE Computer Society Press, 1992. – pp. 1–37.  
URL: <http://www.cs.colostate.edu/~genitor/>
80. *Schmidhuber J., Wierstra D., Gomez F.J.* Evolino: Hybrid neuroevolution / Optimal linear search for sequence learning // Proc. of the *19th International Joint Conference on Artificial Intelligence* (IJCAI), Edinburgh, 2005. – pp. 853–858.  
URL: <http://www.idsia.ch/~juergen>
81. *Schwefel H.-P.* Numerische Optimierung von computer-modellen mittels der evolutionsstrategie // *Interdisciplinary Systems Research*, 1977, vol. 26.
82. *Shewchuk J.R.* An introduction to the conjugated gradient without the agonizing pain. – Carnegie-Melon University, Pittsburg, PA, 1994.

83. Stanley K. O., Miikkulainen R. Evolving neural networks through augmenting topologies // *Evolutionary Computation*. – 2002, vol. 10, No. 2. – pp. 99–127.  
URL: <http://www.nn.cs.utexas.edu/>
84. Stanley K. O., Miikkulainen R. Evolving a roving eye for go // In Proc. of *Genetic and Evolutionary Computation Conference (GECCO-2004)*. – New York, NY: Springer-Verlag, 2004.  
URL: <http://www.nn.cs.utexas.edu/>
85. Stanley K. O., Bryant B. D., Miikkulainen R. Real-time neuroevolution in the NERO videogame // *IEEE Transactions on Evolutionary Computation: Special Issue on Evolutionary and Games*. – 2005, vol. 9, No. 6. – pp. 653–668.  
URL: <http://www.nn.cs.utexas.edu/>
86. Stanley K. Patterns without development. – Technical Report CS-TR-06-01. – University of Central Florida, 2006.
87. Thierens D. Non-redundant genetic coding for neural networks. – Technical Report No.UU-CS-1998-46. – Utrecht University, Netherlands, 1998.  
URL: <http://www.cs.uu.nl/research/techreps/aut/dirk.html>
88. Todd S., Latham W. Evolutionary art and computers. – London: Academic, 1992.
89. Turing A. M. Computing machinery and intelligence // *Mind*. – 1950, vol. 236, No. 59.
90. Valsalam V., Bednar J., Miikkulainen R. Constructing good learners using evolved pattern generators // In Proc. of the *Genetic and Evolutionary Computation Conference (GECCO)*. – Washington, DC, 2005.  
URL: <http://www.nn.cs.utexas.edu/>
91. Whitley D., Starkweather T., Bogart C. Genetic algorithms and neural networks: Optimizing connections and connectivity // *Parallel Computing*. – 1990, vol. 14. – pp. 341–361.  
URL: <http://www.cs.colostate.edu/~genitor/>
92. Yamamichi T., Saito T., Taguchi K., Torikai H. Synthesis of binary cellular automata based on binary neural networks // Proc. of *International Joint Conference on Neural Networks*. – Montreal, Canada, 2005. – pp. 1361–1365.
93. Yao X. Evolving artificial neural networks // *Proc. of the IEEE*. – 1999, vol. 87, No. 9. – pp. 1423–1447.  
URL: <http://www.cs.bham.ac.uk/~xin>
94. Yao X., Liu Y. Making use of population information in evolutionary artificial neural networks // *IEEE Transactions on Systems, Man, and Cybernetics*. Part B: Cybernetics, 1998. – vol. 28, No. 3. – pp. 417–425.  
URL: <http://www.cs.bham.ac.uk/~xin>

95. *Yong C.H., Miikkulainen R.* Cooperative coevolution of multi-agent systems. – Technical Report AI01-287. – The University of Texas at Austin, 2000.  
URL: <http://www.nn.cs.utexas.edu/>
96. *Yu T.-L., Sastry K., Goldberg D.E.* Online population size adjusting using noise and substructural measurements. – IlliGAL Report No. 2005017. – The University of Illinois, 2005.  
URL: <http://www-illigal.ge.uiuc.edu:8080/>

**Юрий Робертович ЦОЙ**, ассистент кафедры вычислительной техники Томского политехнического университета (г. Томск). Область научных интересов — эволюционные вычисления, нейроэволюционные алгоритмы, самоорганизация. Автор более 20 научных публикаций.

**В. Я. СЕРГИН**

Институт математических проблем биологии РАН,  
г. Пущино, Московской обл.  
**E-mail: v.sergin@mtu-net.ru**

**БИОЛОГИЧЕСКИ ПРАВДОПОДОБНАЯ МОДЕЛЬ ЗРИТЕЛЬНОГО  
ВОСПРИЯТИЯ: ИЕРАРХИЯ ОБЪЕМЛЮЩИХ СЕНСОРНЫХ  
ХАРАКТЕРИСТИК**

**Аннотация**

Вводится понятие объемлющей характеристики, которая является ответом данного перцептивного уровня на те сенсорные признаки нижележащего уровня, специфическое сочетание которых составляет адаптивно значимую целостность. Последовательность объемлющих характеристик образует иерархию, от сенсорных признаков до целостных образов и сцен. Специфические паттерны электрической активности, отображающие объемлющие характеристики, передаются с верхних уровней обработки на нижние, стимулируя те нейронные структуры, сигналы которых соответствуют высшей объемлющей характеристике данного акта восприятия.

**V. Ya. SERGIN**

Institute of Mathematical Problems of Biology RAS,  
Pushchino, the Moscow Region  
**E-mail: v.sergin@mtu-net.ru**

**A BIOLOGICALLY PLAUSIBLE MODEL OF VISUAL PERCEPTION:  
THE HIERARCHY OF INCLUSIVE SENSORY CHARACTERISTICS**

**Abstract**

A concept of inclusive characteristic is introduced which is a response of a given perceptual level to the same sensory features of a lower level whose specific organization constitutes an adaptively meaningful entirety. A sequence of inclusive characteristics forms a hierarchy: from sensory features to unified images and scenes. Specific patterns of electric activity which map inclusive characteristics are relayed by back projections from upper to lower neuronal levels. They stimulate neuronal structures whose signals correspond to the higher inclusive characteristic of a given act of a perception.

## Введение

Несмотря на длительную историю изучения восприятия, нейробиологические механизмы его многих важных свойств остаются невыясненными. Например, известно, что данные о цвете, движении, форме и других зрительных качествах окружающего мира обрабатываются в различных зрительных областях коры, количество которых, возможно, достигает нескольких десятков [1]. Перед реальностью этой анатомической разделенности обработки сенсорных сигналов требует объяснения способность психики людей и животных к целостному восприятию окружающего мира. Эта проблема известна в психологии и нейробиологии как «проблема связывания». Вопрос состоит в том, как и посредством каких механизмов мозг связывает сенсорные признаки в целостные образы и сцены?

Другое фундаментальное свойство восприятия, требующее объяснения, известно как инвариантность восприятия. Например, мы воспринимаем летящую птицу как ту же самую, хотя ее геометрическая форма и характеристики светового потока, падающего на сетчатку глаз, кардинально изменяются. Почему мы воспринимаем объект как тот же самый, даже если его форма, размеры, экспозиция, освещенность, положение в поле зрения и другие физические характеристики изменяются?

Известно, что обучение восприятию сенсорных категорий связано с формированием автоматизмов или условных рефлексов, что требует достаточной тренировки. Однако, во многих случаях, обучение восприятию новых сенсорных категорий у человека и высших млекопитающих происходит очень быстро, буквально с первого предъявления. Как может происходить столь быстрое обучение, если оно основано на выработке автоматизмов или условных рефлексов?

Миллиарды фотонов падают на сетчатку глаз, образуя бесконечные комбинации сенсорных сигналов, которые кодируются электрической активностью нейронов и передаются в вышестоящие структуры мозга. Огромная избыточность первичных сенсорных сигналов, идущих от рецепторов, могла бы быстро переполнить память, что сделало бы восприятие невозможным. Поэтому мозг, как кажется, должен фильтровать избыточную информацию, чтобы обеспечить выделение значимых сигналов. Такая проблема хорошо известна в нейробиологии и, начиная со времен *К. Прибрама* [2], возникла обширная научная литература, где исследуется множество весьма изощренных методов, которые, как предполагается, использует мозг для подавления и фильтрации избыточной информации. В свете этих изыска-

ний деятельность мозга выглядит интригующе: мозг принимает устрашающе избыточную информацию, а затем борется с ней всеми доступными средствами.

Согласно воззрениям недавнего прошлого, сенсорные данные образуют восходящий поток от рецепторов к ассоциативной коре. Эти данные интегрируются, образуя в коре головного мозга внутреннюю репрезентацию сенсорного объекта [3]. Если это действительно так, то должна существовать нейронная структура, пусть даже весьма обширная, куда стекаются все сенсорные данные, — некий «познающий гомункулус». Но такой нейронной структуры не обнаружено и от «гомункулуса» пришлось отказаться. Однако взамен не было предложено ничего, обладающего сколько-нибудь эквивалентными объяснительными возможностями. Как пишут *G. Chose* и *J. Maunsell* [4], «... нам по-прежнему не хватает обоснованной механистической структуры для объяснения того, как паттерны нейронной активности трансформируются в восприятие и поведение». Поэтому, несмотря на официальное отречение, «гомункулус» продолжает неявно присутствовать во многих современных теориях восприятия.

Известна давняя проблема, которая до сих пор остается открытой: каким образом материальная, объективно регистрируемая нейронная активность мозга порождает идеальный субъективный образ? Единственным непосредственным источником наших ощущений может быть только активность нейронных структур. Однако мы воспринимаем окружающий мир не в характеристиках нейронной активности, а в категориях внешних событий. Нейронную активность мы не ощущаем вообще. Таким образом, давний вопрос состоит в следующем: как субъективное восприятие сенсорных событий связано с нейронной активностью мозга?

Существует и множество других пока еще не решенных проблем восприятия. В настоящее время их экспериментальное изучение ведется совершенно новыми, беспрецедентно эффективными техническими средствами, которые, похоже, превосходят наши возможности создавать концепции, обеспечивающие понимание экспериментальных данных. Можно указать три основные идеи, которые доминируют в современных исследованиях организации и функционирования системы восприятия. Наиболее продвинутой выглядит концепция иерархической организации восприятия. В иерархических моделях сенсорная информация проходит последовательные стадии обработки, начиная от выделения простых признаков, которые затем интегрируются на более высоких уровнях и формируют отображения все более сложных объектов и событий окружающего мира. *Хьюбел* и *Визел*

[5] предложили модель иерархии зрительных областей коры, составленных из различных клеток, от простых до более сложных и гиперсложных. Общая черта всех иерархических моделей — последовательная обработка в восходящих сенсорных путях и формирование отображений возрастающей сложности.

Иерархические модели опираются на данные анатомии и физиологии головного мозга и подтверждаются экспериментальными данными психофизики восприятия. Тем не менее, в рамках этих моделей существует проблема «комбинаторного взрыва» (экспоненциального роста числа нейронов, необходимых для отображения объекта, при увеличении числа его признаков), проблемы сегментации зрительного поля и инвариантного распознавания объектов [6, 7]. Кроме того, возникают трудности распознавания объектов с ранее не встречавшимися сочетаниями признаков — «проблема новизны» [8, 9].

Массированные обратные связи из ассоциативных областей коры в проекционные области и подкорковые структуры мозга служат анатомической основой концепции управления восприятием сверху вниз. Предполагается, что нисходящий процесс облегчает обнаружение объекта, существенно сокращая число отображений, подлежащих распознаванию. Исследования последних лет постепенно выдвигают нисходящее облегчение в число интенсивно изучаемых корковых функций, но как такая обработка инициируется — остается загадкой [10]. Не известны ни место встречи, ни способ взаимодействия нисходящей стимуляции и восходящего сенсорного возбуждения. Неопределенность усугубляется еще и тем обстоятельством, что меры специфичности/абстрактности у восходящего и нисходящего потоков совершенно различны [6, 11]. Отсутствуют прямые доказательства причинной связи активности префронтальной коры и модулирующей активности в сенсорных областях мозга [12]. Серьезные сомнения в роли стимуляции сверху связаны также с тем, что распознавание объекта в сложных зрительных сценах происходит приблизительно за 150 мс [13]. Это соизмеримо со временем передачи сигнала из сетчатки в инферотемпоральную кору, которая играет ключевую роль в распознавании объектов [14]. Времени для отбора объекта, посредством нисходящей стимуляции, как будто бы просто не остается.

*Von der Malsburg* [15] постулировал специальный механизм связывания — синхронную колебательную активность ансамбля нейронов, которая связывает вместе признаки одного объекта. Предполагается, что модуляция нейронной активности частотой 30–70 Гц синхронизирует генерацию спай-

ков нейронами, представляющими элементы одного объекта [16]. Различные частоты или фазы модуляции могут использоваться для одновременной маркировки разных объектов. В рамках этого подхода можно динамически и селективно связать нейроны, распределенные по зрительной коре или принадлежащие разным сенсорным и моторным системам [17].

Гипотеза синхронизации основана на множестве нейрофизиологических исследований, которые показывают, что нейроны, активируемые общим стимулом, обычно генерируют синхронно [17, 18]. Эта синхронизация наблюдается между нейронами в разных зрительных областях, между зонами в разных полушариях головного мозга, а также между сенсорными и моторными областями [16, 19].

Однако возможности гипотезы синхронизации оказываются все же ограниченными. Она не объясняет, как специфическая группа нейронов сегментируется от других активных нейронов, как достигается синхрония и как она формирует унитарное восприятие, решения или действия [4]. Поскольку нейроны кодируют изменения стимула с точностью в несколько миллисекунд, то информация о быстрых изменениях будет потеряна, если сигналы будут модулироваться частотой ниже 100 Гц, как должно быть в соответствии с гипотезой синхронизации. Серьезную проблему для гипотезы синхронизации представляют временные различия ответов нейронов зрительной коры. Нейроны с быстрыми ответами могут прекратить свою активность прежде, чем другие нейроны начнут интенсивно отвечать [20]. Для кратковременных стимулов ответы нейронов в зоне V1 могут завершиться раньше, чем высшие уровни зрительной коры получают необходимые сигналы [21].

Несмотря на проблемы, возникающие в рамках упомянутых концепций восприятия, следует иметь в виду, что каждая из них базируется на внушительном фундаменте экспериментальных данных анатомии и физиологии головного мозга человека и высших млекопитающих. Нейрофизиологические механизмы, представленные в этих исследованиях, хорошо аргументированы, поэтому вполне естественно выглядят попытки объединить их в одной концепции [22, 23]. Такие исследования обнаруживают новые аспекты организации восприятия и дают более глубокое понимание нейробиологических механизмов. Но все же сомнительно, чтобы простое объединение разных моделей привело к органически целостной концепции, лишенной недостатков составляющих частей. Нам представляется, что необходим новый подход, основанный на нейробиологических данных, из которого могли бы следовать ключевые механизмы современных концепций восприятия

в такой взаимной связи, которая порождает функционально целостную систему.

Заметим, что способность системы восприятия отображать сенсорные признаки окружающего мира, такие как линии, границы, пятна, цвет, движение и т. д., является нейробиологическим фактом. Способность человека воспринимать объекты, образы и сцены также является фактом. В отличие от этих утверждений, способность системы восприятия связывать сенсорные признаки в образы и сцены является областью теоретических предположений. Идея о том, что образ является результатом связывания признаков кажется вполне очевидной и не вызывает сомнений у большинства исследователей. Тем не менее, нет никаких нейробиологических данных, доказывающих, что связывание признаков в объекты действительно существует.

В основе предлагаемой гипотезы восприятия лежит фундаментальный нейробиологический факт: размеры рецептивных полей нейронов увеличиваются от проекционной коры вверх по сенсорному пути [24]. Поэтому нейронные структуры вышележащих уровней обработки не могут отображать деталей стимульного поля, которые имеются на нижележащих уровнях и требуют высокого пространственного разрешения. Однако, нейронная структура каждого последующего уровня обработки может формировать собственную характеристику, объемлющую данные нижележащего уровня и выражающую адаптивно значимую целостность. Требования к точности отображения целого ниже, чем требования к точности отображения деталей. Поэтому формирование иерархии объемлющих характеристик хорошо согласуется с тем фактом, что размеры рецептивных полей нейронов растут от проекционных к ассоциативным областям.

Другой фундаментальный нейробиологический факт состоит в том, что система восприятия извлекает из сенсорного возбуждения дифференциальные признаки. Дифференциация обеспечивает формирование многомерно пространства признаков, соответствующих каждому акту восприятия. Дифференциация в разных аспектах обнаруживает специфичность актуального стимульного поля и, в сущности, является средством многоуровневого отображения специфичности.

Специфические сочетания признаков соответствуют значимым целостностям различных уровней обработки. Система восприятия выявляет специфичность стимульного поля, посредством дифференциации сенсорного возбуждения на последовательных уровнях обработки, и порождает иерархию характеристик, объемлющих специфические сочетания признаков. Си-

стема восприятия не комбинирует и не интегрирует сенсорные данные, а обнаруживает такие специфические сочетания признаков, которые соответствуют значимым объектам или событиям.

В этой гипотезе иерархическая организация восприятия естественным образом вытекает из определения объемлющей характеристики. Ни на одном уровне обработки не происходит ни комбинирования, ни интегрирования признаков. Поэтому проблемы комбинаторного взрыва просто не существует, а другие проблемы иерархических моделей имеют ясные перспективы решения [25]. В такой модели нисходящая стимуляция должна, по необходимости, соответствовать иерархии объемлющих характеристик. Предполагается, что стимуляция сверху уменьшает время реакции отобранных нейронов нижележащих уровней до миллисекундного диапазона. В результате нейронные популяции нижележащих уровней, участвующие в данном акте восприятия, становятся детекторами совпадений и синхронно отвечают на одновременно приходящие спайки. В этом и состоит взаимодействие нисходящей стимуляции с восходящим сенсорным возбуждением. Иерархически упорядоченный набор нейронных ансамблей из детекторов совпадений формирует быстрый сенсорный путь, единственный и уникальный для каждого акта восприятия.

Таким образом, давно соперничающие теории иерархической организации, синхронизации нейронной активности и управления восприятием сверху вниз оказываются естественным образом связанными в единой концепции восприятия. Выполненные исследования показывают, что в модели объемлющих характеристик удачно сочетаются достоинства этих теоретических воззрений на природу восприятия и, возможно, отсутствуют их недостатки [26, 27, 28]

К этому следует добавить, что гипотеза объемлющих характеристик хорошо согласуется с принципом доминанты А.А. Ухтомского [29], который был положен в основу обширного цикла исследований внимания [30, 31, 32, 33]. Хотя представленная в данной работе модель восприятия не является осцилляторной, из дальнейшего изложения станет ясным, что она вполне совместима с представлениями о доминирующей констелляции совозбужденных локальных нейронных групп или центров, характеризующихся единым ритмом и единым действием.

### Объемлющие сенсорные характеристики

Известно, что сетчатка глаза проецируется в первичную кору с высокой топографической точностью и нейроны проекционной коры имеют минимальные рецептивные поля. При движении вверх по зрительному пути рецептивные поля нейронов увеличиваются, а точность топографического отображения падает [24]. Это правило справедливо для всей сенсорной коры: размеры рецептивных полей нейронов растут от проекционных к ассоциативным областям. Поэтому нейронные структуры вышележащих уровней обработки не могут отображать деталей стимульного поля, которые имеются на нижележащих уровнях и требуют высокого пространственного разрешения. Но тогда, что именно могут отображать нейронные структуры вышележащих уровней?

Мы полагаем, что нейронная структура каждого последующего уровня обработки может порождать собственную характеристику, объемлющую данные нижележащего уровня в некотором адаптивно важном аспекте. Объемлющая характеристика может выражать некоторую целостность, обладающую качественной специфичностью на более высоком уровне. Например, наборы линий образуют решетку, последовательность звуков — ритм, глаза и нос — лицо и т. п. Требования к точности отображения целого ниже, чем требования к точности отображения деталей. Поэтому формирование иерархии объемлющих характеристик хорошо согласуется с тем фактом, что размеры рецептивных полей нейронов растут от проекционных к ассоциативным областям.

Объемлющая характеристика — это перцептивная гипотеза о том, что данное специфическое сочетание признаков соответствует определенному объекту или событию. Если идентификация объекта или сенсорного события дает организму новые адаптивные преимущества, то характеристика, объемлющая соответствующие им признаки, может быть построена в процессе обучения.

Витальная ценность отдельных признаков стимула состоит в том, что организм может реагировать на те из них, которые биологически значимы. Но отдельные признаки порознь могут оказаться незначимыми сами по себе и только специфическое сочетание признаков приобретает биологический смысл. Связывание признаков, относящихся к одному объекту, требует их синхронного отображения [16, 18]. Однако это необходимое условие связывания не является достаточным условием целостного восприятия. Целостное восприятие требует формирования объемлющей характеристики,

обладающей качественной специфичностью на более высоком когнитивном уровне. Объемлющая характеристика обеспечивает организму новые возможности, недостижимые средствами подчиненных уровней когнитивной иерархии.

Объемлющая характеристика выражает специфическое сочетание признаков объекта или события, которое, в определенных обстоятельствах, оказалось адаптивно значимым для данного организма. Повторение этого сочетания признаков, при сходных обстоятельствах, ведет к повторению адаптивного поведения. Если объемлющая характеристика подкрепляется, обеспечивая организму новые адаптивные преимущества, реакция сенсорной системы фиксируется в качестве автоматизма или условного рефлекса. Возникновение условного рефлекса означает формирование специализированной нейронной структуры, порождающей эту реакцию, и замыкание связей «стимул–реакция». Чем выше адаптивная (биологическая или социальная) ценность объекта и чем сильнее потребность организма в этом объекте, тем быстрее формируется в процессе обучения специализированная нейронная структура, порождающая его объемлющую характеристику. В результате этот объект может выделяться и избирательно восприниматься среди множества других объектов.

Объемлющая характеристика является ответом данного перцептивного уровня на специфическое сочетание признаков, выделенных из множества других посредством обучения. Из множества признаков нижележащего уровня отбираются только те, пространственная организация или специфическая временная последовательность которых составляет значимую целостность. Например, из множества отрезков разных размеров и ориентаций, расположенных на плоскости, отбираются те, которые образуют треугольники, квадраты или другие геометрические фигуры. При восприятии речи из множества звуков и шумов отбираются только специфические звуки человеческой речи, которые образуют слоги, слова и фразы — адаптивно значимые целостности.

Формирование объемлющей характеристики иллюстрируется схемой на рис. 1. Нейронная структура, сформированная посредством обучения, отвечает на специфическое сочетание признаков, выражающее значимую целостность. Тем самым, из большого разнообразия признаков, которые отображаются нижележащим уровнем, отбираются только адаптивно значимые сочетания. Выходной паттерн электрической активности специализированной нейронной структуры — паттерн категоризации — отображает значимую целостность данного уровня обработки.



Рис. 1. Пример формирования объемлющей характеристики в психологических (а) и нейрофизиологических (б) терминах

Следует подчеркнуть отличие объемлющей характеристики от интегральной. Интегрирование, в своей сущности, является процессом суммирования (определяемое как предел аппроксимирующей суммы фрагментов при их неограниченном измельчении). Интегральная форма представления — это представление суммарных данных. Интегральные характеристики (виды интегралов и процедуры их вычисления) формально определены, что обеспечивает объективное представление данных, на которые не влияет биологическая специфичность.

Объемлющая характеристика выражает такое специфическое сочетание признаков, которое образует новое сенсорное качество — адаптивно значимую целостность. На каждом уровне обработки, из большого разнообразия признаков и сочетаний нижележащего уровня, отбираются только значимые целостности. Отбор признаков и их специфических сочетаний изначально субъективны и определяются эволюционным опытом и прижизненным обучением организма. Объемлющие характеристики биологически специфичны и субъективно избирательны.

В модели объемлющих характеристик нейронная организация обра-




Рис. 2. Схема передачи возбуждения по одному из сенсорных путей. Овалами показаны нейронные популяции ( $A_i$ ,  $B_i$ ,  $C_i$ ), которые образуют нейронные структуры последовательных уровней обработки  $A$ ,  $B$  и  $C$ . Большими овалами отмечены те популяции, которые отвечают на данный стимул и составляют нейронные ансамбли данного акта восприятия. Связи между популяциями одного уровня не показаны, чтобы не усложнять схему.

ботки (рис. 2) может соответствовать принципам Д. Хебба [34], согласно которым совокупность популяций нейронов одного уровня обработки, отвечающих на отдельный стимул, составляет нейронный ансамбль. Одни и те же популяции нейронов, в разных актах восприятия, могут входить в состав различных ансамблей. Ответ нейронного ансамбля физиологически выражается паттерном электрической активности, специфичность которого отображает определенную сенсорную характеристику (например, движение в определенном направлении). Нейронные ансамбли различных уровней обработки функционально специализированы и их ответы отображают различные сенсорные качества стимула. Любой отдельный стимул вызывает ответ множества нейронных ансамблей различных уровней обработки.

Все популяции одного уровня обработки, имеющие одинаковую функциональную специализацию (например, отвечающие на движение), обра-

зуют нейронную структуру. Специализированная нейронная структура порождает паттерны электрической активности различных специфичностей, которые отображают различные характеристики данного сенсорного качества (например, движение в разных направлениях).

В модели объемлющих сенсорных характеристик нейронные уровни обработки совпадают с уровнями восприятия, но не совпадают со специализированными областями коры, которые могут содержать больше одного уровня. Объемлющая характеристика выражает некоторую значимую целостность и отображается специфическим паттерном электрической активности нейронной структуры, обученной распознавать этот сенсорный объект. Таким образом, психическая характеристика (значимая целостность) имеет материальный носитель (специфический паттерн электрической активности) и именно поэтому может оказывать влияние на другие психические и физиологические процессы. Психическое и физиологическое — разные выражения одной и той же реальности (две стороны одного процесса), поэтому они существуют и протекают одновременно [35, 36].

Сенсорная характеристика является объемлющей в той мере, в какой она обладает качественной специфичностью, отличающей ее от компонент, по отношению к которым она является характеристикой более высокого уровня. Объемлющую характеристику нельзя разложить на компоненты и свести к ним, поскольку при этом будут разрушены те отношения между компонентами, которые порождают значимую целостность, определяющую качественную специфичность объемлющей характеристики.

Целостность предполагает относительную обособленность объекта: влияние не входящих в него окружающих признаков не должно изменять качественной специфичности объекта. Целостность и качественная специфичность объекта порождаются не сходством частей и не их физической связанностью, а адаптивным смыслом данного сочетания для воспринимающего субъекта. Например, сцена может включать разнородные части, не имеющие устойчивых связей, тем не менее, адаптивный смысл ситуации порождает целостность и качественную специфичность сцены.

Компоненты не определяют целостность. Например, если отрезки, образующие решетку, заменить дугами, все равно это будет решетка. Даже если отрезки заменить произвольными узорами, качественная специфичность решетки сохранится: сквозь нее можно видеть, но нельзя проникнуть. Объемлющая характеристика существует и выражает значимую целостность лишь в той мере, в какой существуют специфические отношения компонент. Специфичность этих отношений определяет качественно иную

сущность, обладающую собственными свойствами, отличными от свойств ее компонент. Например, решетка обладает такими свойствами как плотность, узор, длина, высота и т. д., которые нельзя получить из свойств ее компонент — прямолинейных или криволинейных отрезков.

Сенсорная характеристика, объемлющая данное специфическое сочетание признаков, должна быть единственной. В противном случае восприятие может порождать замешательство, препятствующее адекватной моторной реакции организма. Единственность объемлющей характеристики является условием ее адаптивной ценности.

Теперь можно сформулировать необходимые и достаточные условия существования объемлющей характеристики. Объемлющая характеристика существует тогда и только тогда, когда: 1) имеют место такие отношения компонент, которые порождают адаптивно значимую целостность, обладающую качественной специфичностью, отличающей ее от компонент; 2) эта значимая целостность единственна в данном акте восприятия.

Мы полагаем, что нейронная структура, соответствующая любому уровню восприятия, порождает характеристику, объемлющую те данные нижележащего уровня, специфическое сочетание которых составляет адаптивно значимую целостность. Сенсорное событие, не порождающее объемлющей характеристики, не может восприниматься как осмысленное целое. Только отобранные признаки и их объемлющие характеристики являются сенсорными данными. Сенсорные системы не воспринимают и не передают в вышестоящие структуры мозга никакой другой информации [26, 27].

### **Формирование объемлющих характеристик**

Если некоторая часть зрительного поля содержит один и тот же признак (например, зеленый цвет или штриховку), то первичная объемлющая характеристика может определять просто конфигурацию пространства, занятого этим признаком. Функциональная роль первичных объемлющих характеристик может состоять в отображении конфигурации однородных областей зрительной сцены. Тогда представление зрительного поля несколькими первичными объемлющими характеристиками должно порождать хорошо выраженную разделенность поля на области. Действительно, как показывают экспериментальные данные, если участки текстуры отличаются ориентацией, пространственной частотой, размером или цветом своих элементов, то эти различия ведут к мгновенной сегментации текстуры, не

требующей внимания [37, 38]. Участок текстуры, имеющий один общий признак, автоматически отделяется от другого участка текстуры, имеющего другой общий признак [39].

Функциональная роль первичных объемлющих характеристик позволяет объяснить одно важное свойство зрительного восприятия. Известно, что если область вокруг слепого пятна однообразно и равномерно занимает, например, серия линий, то мозг заполняет пропущенное пространство подобными линиями, которые совпадают с реальными линиями [40]. Механизм заполнения, в таких случаях, может состоять в формировании первичной объемлющей характеристики, определяющей конфигурацию пространства, занятого данным признаком.

Границы между однородными областями также представляют собой первичные объемлющие характеристики. Первичные объемлющие характеристики — поверхности и границы — участвуют в формировании объемлющих характеристик более высокого уровня, отображающих объекты окружающего мира.

Проекционная кора V1 отображает локальные признаки объектов. Эти признаки доступны для обработки нейронным структурам области V2. Рецептивные поля специализированных нейронов области V2, отвечающих на определенное сенсорное качество, например, длину световой волны или ориентацию линий, образуют непрерывную топографическую карту сетчатки глаза [24]. Область V2, вероятно, включает набор нейронных структур, обеспечивающих отображение признаков всех субмодальностей во всем зрительном поле. Но рецептивные поля нейронов области V2 значительно больше, чем у нейронов проекционной коры, поэтому здесь могут отображаться характеристики, объемлющие локальные признаки. Мы полагаем, что формирование первичных объемлющих характеристик может быть одной из функций нейронных структур области V2.

Известно, что нейроны проекционной коры V1, избирательно реагирующие на элементы формы, не реагируют на иллюзорные контуры или отсутствующие отрезки линий. Нейроны зрительной области V2 получают сенсорное возбуждение от нейронов области V1 и, тем не менее, они реагируют на иллюзорные контуры, как бы «подразумеваемая» недостающие отрезки линий [24]. Если функциональная специализация области V2 состоит в формировании первичных объемлющих характеристик, то она может отображать контуры и простейшие формы. Специализация нейронной структуры происходит в процессе обучения, поэтому порождение объемлющей характеристики после обучения не требует полной входной ин-

формации. Тогда нейронная структура зрительной области V2, в ответ на сенсорное возбуждение, может порождать перцептивную гипотезу, например, геометрическую фигуру, даже если часть ее контура или некоторые отрезки линий отсутствуют. Поэтому от нейронных структур области V2 не требуется никаких аналитических способностей, чтобы заполнять пустые места или достраивать недостающие линии.

Известно, что разрушение специализированных зрительных областей коры ведет к полной и специфической утрате способностей воспринимать соответствующие сенсорные качества. Например, разрушение области V4 ведет к ахроматопсии, а разрушение области V5 — к акинетопсии. На этом фоне кажется удивительным отсутствие полной и специфической утраты способности видеть форму в случаях разрушения престриарной коры [24]. Разрушение престриарной коры, не затрагивающее область V1, предполагает хотя бы частичное сохранение области V2, которая тесно прилегает к области V1. Если объемлющие характеристики, которые формируются зрительной областью V2, действительно отображают простейшие формы, то способность видеть форму может не утрачиваться полностью даже при разрушении зрительных областей V3 и V4, специализация которых связана с восприятием формы объектов.

Каким образом в зрительном поле, разделенном на области по простым признакам, выявляются объекты? Связанные с объектом признаки появляются одновременно, изменяются синхронно и исчезают также одновременно. Одновременное отображение комбинации признаков, локализованных в одном месте, делает возможным построение объемлющей характеристики объекта, выражающей его качественную специфичность. Экспериментально установлено, что пространственно распределенные элементы изображения объекта в самом деле связываются перцептивно и интерпретируются как один объект, если они появляются одновременно или изменяются синхронно [41].

Однородные части зрительного поля составляют компоненты фона, которые характеризуются определенной конфигурацией и взаимным расположением. Фон и объекты составляют сцену, качественная специфичность которой может быть выражена объемлющей характеристикой более высокого уровня.

Компоненты фона — это квазиобъекты, конфигурация и взаимное расположение которых выражаются первичными объемлющими характеристиками. Некоторые из этих квазиобъектов могут оказаться объектами, если характеризующие их комбинации признаков будут идентифицированы как

обладающие соответствующей качественной специфичностью. Тогда предварительная локализация объекта — это унаследованное пространственное положение данного квазиобъекта по отношению к другим квазиобъектам. Формирование объемлющей характеристики объекта ведет к уточнению его пространственного положения. Выделение объектов из сенсорного фона делает возможным формирование объемлющей характеристики более высокого уровня — сцены. Восприятие объекта в контексте сцены завершает его пространственную локализацию.

Из нашей схемы следует, что идентификация объекта и определение его местоположения являются связанными итерационными процессами. Следовательно, дорсальный париетальный путь должен итерационно взаимодействовать с вентральным путём. Объекты имеют различное положение на фронтальной плоскости и по глубине, поэтому, вопреки представлениям *Roelfsema et. al* [42], не должно возникать никакой неопределенности при появлении в поле зрения двух и более объектов. Однако могут возникать трудности идентификации в тех случаях, когда один объект частично маскируется другими объектами. К этой проблеме мы еще вернемся.

Идентификация сенсорных признаков, таких как пятна, линии, углы, их размещение, ориентация, движение и цвет, требует поточечного анализа всего поля зрения и, следовательно, требует высокого пространственного разрешения, большой вычислительной мощности и большого объема памяти. Формирование характеристик, объемлющих идентифицированные признаки, не требует столь высокого пространственного разрешения или большой вычислительной мощности. Например, сочетания отрезков, образующих решетку, крест или треугольник, можно обнаружить по специфическим отношениям между отрезками, что не требует поточечного анализа поля зрения. Идентификация образов может состоять в выявлении специфических отношений сенсорных объектов ниже лежащего уровня (например, определенное расположение глаз, носа и губ могут порождать образ лица).

Чем выше когнитивный уровень объемлющей характеристики предмета или события, тем она может быть проще и схематичнее по отношению к исходному набору признаков. Это позволяет увеличивать количество специфических сочетаний признаков, объемлемых характеристикой более высокого уровня, при неизменной скорости обработки. Следовательно, может возрастать ширина охвата сенсорных качеств окружающего мира, увеличиваться разнообразие объемлющих характеристик, их специфичность и уникальность. Благодаря такой организации восприятия возможно практи-

чески безграничное разнообразие уникальных сенсорных объектов, которые мы способны распознавать.

Формирование объемлющей характеристики в процессе обучения — это индуктивный процесс установления значимой целостности, которая проявляется специфическими сочетаниями признаков во многих ситуациях. Обучение должно включать выявление значимых сочетаний признаков и игнорирование всех остальных данных нижележащего уровня. Тогда иерархию объемлющих характеристик можно рассматривать как продукт последовательных этапов абстрагирования. Объемлющая характеристика каждого последующего уровня выражает более абстрактные свойства стимула, присущие ему как целому, и представляет его в схематической или символической форме. Вопреки традиционным представлениям об иерархической организации восприятия как последовательности от простого к сложному, иерархия объемлющих характеристик является последовательностью от сложного к простому.

Иерархия объемлющих характеристик — это путь от восприятия физических к формированию семантических характеристик (рис. 3). Каждый следующий перцептивный уровень порождает характеристику, объемлющую более широкий спектр свойств окружающего мира, и формирует новое сенсорное качество, имеющее более сложный и опосредованный адаптивный смысл. Чем выше уровень в системе восприятия, тем меньше физических подробностей содержит соответствующая объемлющая характеристика и тем более уникальные семантические черты окружающего мира она выражает. Высшая объемлющая характеристика выражает ключевые черты целостного образа, его схему, концепцию.

Важно заметить, что высшая объемлющая характеристика, — это не образ и не сцена, а уникальная схема сочетания объектов нижележащего уровня, порождающая образ или сцену. Стимульное поле может отображаться набором вложенных сенсорных характеристик, что обеспечивает детальность (за счет нижних уровней) и целостность отображения (за счет верхних уровней). Вложенность означает последовательность все более объемлющих отображений, что обеспечивает глобальную упорядоченность сенсорных структур.

На каждом уровне восприятия отбираются только значимые целостности из данных нижележащего уровня. Поэтому в модели объемлющих характеристик не существует тотального потока данных, которые последовательно передаются с нижних уровней восприятия вверх по сенсорному пути. Сенсорные данные остаются на том уровне восприятия, где они бы-

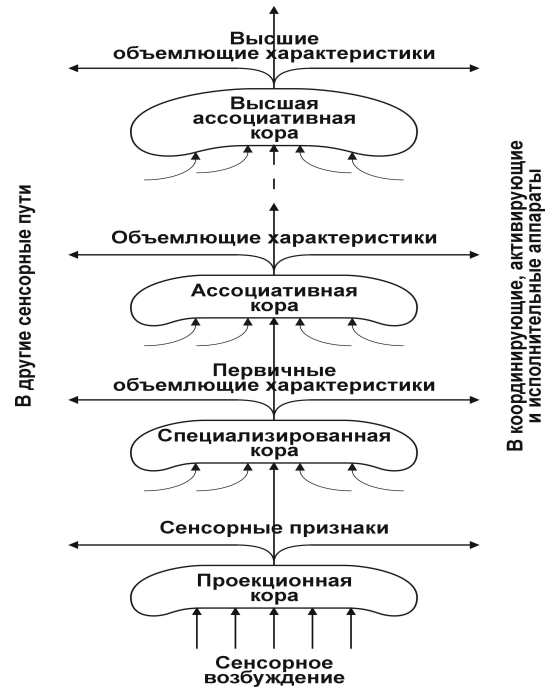


Рис. 3. Функциональная схема одного из восходящих сенсорных путей. Стрелки снизу вверх указывают на поток сенсорных данных, а последовательность формирования объемлющих характеристик. Тонкие стрелки показывают входы от других нейронных структур.

ли идентифицированы. Сенсорные данные никуда не стекаются и нигде не отображаются в интегральной форме. В такой модели разместить всезнающий гомункулус просто негде.

Чем выше уровень в системе восприятия, тем меньше объем выборки. На высшем уровне, в каждом акте восприятия, существует только одна характеристика, объемлющая данные нижележащего уровня в значимую целостность — образ или сцену (рис. 4). Поэтому в модели объемлющих характеристик комбинаторный взрыв невозможен, как его нет и в реальном восприятии. Объемлющие характеристики являются альтернативой доминирующим в науках о мозге представлениям об интегральных характери-

стиках и интегральных образах. Аппарат интегрирования — техническое средство математического и компьютерного моделирования — приобрел в науках о мозге неадекватный концептуальный статус.




Рис. 4. Зависимость возможного числа сенсорных объектов от уровня обработки в модели связывания признаков (а) и в модели объемлющих характеристик (б)

Интегральных образов восприятия, включающих все сенсорные данные, от признаков до сцен, не существует. Хотя нам кажется, что мы видим все и сразу, ни в какой области мозга интегральных образов нет. Модель объемлющих характеристик позволяет понять те свойства восприятия, которые порождают ощущение, будто окружающий мир доступен нашему зору в целом и во всех подробностях одновременно.

Зрительное поле отображается параллельным набором вложенных сенсорных характеристик (рис.4), что обеспечивает детальность и целост-

ность отображения. Восприятие может фокусироваться на отдельных объектах или их фрагментах, что автоматически сопровождается высоким пространственным разрешением, или охватывать всю сцену целиком, но лишь в общих чертах (вследствие схематичности высших объемлющих характеристик). Изменение пространственного масштаба и детальности видения происходят так же автоматически, как перенос взора, и не требуют волевых усилий.

Любая сенсорная характеристика восприятия неразрывно связана с другими сенсорными данными объемлющей характеристикой более высокого уровня. Это может порождать органически встроенное и подвижное отображение сенсорных событий различного когнитивного уровня и пространственного масштаба в их неразрывном единстве. Иерархически упорядоченная последовательность вложенных сенсорных характеристик, позволяет нам произвольно рассматривать детали видимой сцены, отдельные объекты или всю сцену целиком и обеспечивает незаметный и плавный переход от одного к другому. В результате мы видим окружающий мир, как того пожелаем: в целом или во всем разнообразии его подробностей, что порождает ощущение, будто он весь и сразу представлен нашему взору.

«Проблема новизны» в иерархических моделях возникает из-за трудностей распознавания сенсорных объектов с ранее не встречавшимися сочетаниями признаков. Эти трудности, казалось бы, можно преодолеть посредством обучения. Но тогда возникает вопрос: если восприятие сенсорных категорий связано с обучением (выработкой автоматизмов или условных рефлексов), то как объяснить, что во многих случаях восприятие новых категорий человеком и высшими млекопитающими происходит очень быстро, буквально с первого предъявления? Модель объемлющих характеристик позволяет ответить на этот вопрос. Вложенные сенсорные характеристики определяют такую структуру восприятия, которая облегчает формирование новых категорий. Формирование категорий никогда не начинается с нуля. Всегда существует широкий ассортимент признаков и первичных объемлющих характеристик, которые могут служить компонентами новых категорий. Одновременно существуют сформированные объемлющие характеристики более высокого уровня, которые могут включать в себя новые категории. Например, новое слово может быть характеристикой, объемлющей новую комбинацию известных ранее слогов, что ускоряет процесс его формирования. С другой стороны, это слово с первого предъявления может встраиваться в сформированную ранее логико-грамматическую структуру, выражающую отношения между словами, фразу — объемлющую характе-

ристику более высокого уровня. Таким образом, новая сенсорная категория любого когнитивного уровня может формироваться очень быстро, несмотря на то, что в основе восприятия лежат процессы обучения.

Аналогичная процедура распознавания незнакомого объекта следует из нейрофизиологической модели сенсориума [43]. В этой модели предъявление незнакомого объекта активирует нейроны низких синаптических уровней, только те из них, которые соответствуют знакомым свойствам и под-свойствам этого незнакомого объекта. Постановка в соответствие этому новому объекту (как целому) нового символического нейрона завершает процедуру обучения.

В модели вложенных сенсорных характеристик, с физиологической точки зрения, каждый нейронный уровень осуществляет перцепцию на множестве нейронных популяций нижележащего уровня, подобно тому, как первичный нейронный уровень осуществляет перцепцию на множестве рецепторов. В процессе эволюции каждый следующий нейронный уровень мог надстраиваться как новый уровень перцепции, «рецепторами» которого служили нейронные популяции нижележащего уровня. В результате мог формироваться последовательный ряд нейронных структур, обеспечивающих охват все более широкого разнообразия сенсорных качеств окружающего мира.

Каждый уровень восприятия был высшим на своем этапе эволюционного процесса, отображал витально значимые целостности и был связан со всеми координирующими, активирующими и моторными структурами нервной системы. Эти связи перцептивных уровней с другими отделами нервной системы и исполнительными органами, хотя и модифицируются в эволюционном процессе, но вероятно, сохраняются, образуя параллельный ряд подсистем, формирующих весь спектр реакций организма на сенсорные события. В основе нашего восприятия окружающего мира, включающего все модальности и масштабы сенсорных событий, от отдельных признаков до целостных образов и сцен, может лежать реакция нервной системы на параллельные входы, отображающие вложенные сенсорные характеристики стимульного поля. Целостность реакции обеспечивается высшей объемлющей характеристикой данного акта восприятия.

Типичные временные интервалы порождения объемлющих характеристик образуют иерархию: от нескольких миллисекунд — времени порождения первичных объемлющих характеристик, до нескольких секунд — времени отбора данных нескольких фиксаций взора и порождения высших объемлющих характеристик, формирующих образы или сцены. Время

порождения объемлющих характеристик является естественным количественным критерием иерархической упорядоченности сенсорных структур. Тогда организацию восприятия можно представить отношениями включения

$$P_1 \subset P_2 \subset P_3 \subset \dots \subset P_n,$$

где  $P_1$  — перцептивный уровень, порождающий первичные объемлющие характеристики. Каждый следующий перцептивный уровень  $P_2$ ,  $P_3$  и т. д. характеризуется временем отбора значимых целостностей приблизительно на порядок превышающем время нижележащего уровня. Здесь  $P_n$  — перцептивный уровень, порождающий высшие объемлющие характеристики.

Модель вложенных сенсорных характеристик устанавливает иерархию уровней восприятия в соответствии с их типичными временами отбора значимых целостностей. Время порождения объемлющей характеристики является динамическим параметром процесса восприятия и, как параметр, оно аналогично времени установления (релаксации) в механике и физике. Этот количественный критерий позволяет разделить динамическую структуру процессов восприятия на качественно различные подсистемы, формирующие значимые целостности различных иерархических уровней. Динамическая организация, представленная отношениями включения, позволяет, в частности, использовать формальный аппарат теории сингулярно возмущенных дифференциальных (или интегро-дифференциальных) уравнений для построения имитационных моделей многоуровневых систем восприятия и это влечет за собой тем более значительное уменьшение объема вычислений, чем сложнее исходная задача.

### Нисходящая стимуляция

Передача возбуждения по сенсорным путям не является простым восходящим процессом. Обилие и упорядоченность обратных проекций с верхних нейронных уровней восприятия на нижние, включая таламус и более глубокие структуры мозга, свидетельствуют о важной роли обратных связей. В соответствии с изложенными ранее представлениями, передача детальных данных сверху по обратным проекциям невозможна, так как на верхних уровнях их просто нет. Но возможна передача возбуждения, отображающего объемлющие характеристики, из ассоциативной коры на нейронные структуры нижележащих уровней. Возбуждение, передаваемое сверху вниз, может избирательно стимулировать нейронные популяции нижележа-

щих уровней, облегчая передачу тех компонентов сенсорного возбуждения, которые соответствуют данной объемлющей характеристике. Например, если объемлющей характеристикой является решетка, то могут стимулироваться нейронные популяции нижележащего уровня, реагирующие на линии определенной ориентации.

На рис. 5 показана схема восприятия по одному из сенсорных путей. Мы полагаем, что передача возбуждения вниз происходит только на непосредственно нижележащий уровень обработки. Стимуляция нейронных структур, отображающих различные сенсорные характеристики одного перцептивного уровня, позволяет связать их в осмысленное целое. Например, определенное сочетание формы и цвета может отображать объект, а определенное сочетание объектов может отображать образ или сцену.

Обратные связи образуют каскад переноса возбуждения сверху вниз в соответствии с иерархией вложенных сенсорных характеристик. Стимуляция сверху может облегчать передачу тех компонентов сенсорного возбуждения, которые соответствуют высшей объемлющей характеристике данного акта восприятия. Многоуровневый иерархический отбор сенсорных признаков и адаптивно значимых целостностей обеспечивает передачу в вышестоящие структуры мозга только тех сенсорных данных, которые отвечают потребностям и целям организма.

В чем состоит физиологический механизм стимуляции сверху? Мы полагаем, что стимуляция сверху уменьшает время реакции отобранных нейронов нижележащего уровня на одновременно приходящие спайки до миллисекундного диапазона [25]. В результате популяции нейронов нижележащего уровня, участвующие в данном акте восприятия, на короткое время становятся детекторами совпадений. Они интенсивно отвечают на синхронное сенсорное возбуждение, вызванное стимулом, и слабо реагируют на сигналы, распределенные во времени.

Объемлющая характеристика, посредством стимуляции сверху, отбирает популяции нейронов нижележащего уровня, которые могут отображать признаки данного объекта по прошлому опыту. Те признаки данного объекта в данном месте, которые действительно обнаружены рецепторами, отображаются когерентной разрядкой активированных популяций. Тем самым стимул отбирает ансамбль популяций, участвующих в данном акте восприятия, из совокупности, активированной сверху. Посредством итераций по всем иерархическим уровням сверху вниз и снизу вверх синхронизируется уникальный набор нейронных ансамблей. Этот набор ансамблей из детекторов совпадений формирует быстрый сенсорный путь, единственный и



Рис. 5. Схема восприятия по одному из сенсорных путей. Обратные проекции образуют многозвенный каскад нисходящего возбуждения. Тонкие стрелки показывают входы от других нейронных структур.

уникальный для каждого акта восприятия.

Существуют различные способы уменьшения времени реакции нейронов посредством стимуляции сверху. Эта довольно сложная проблема требует специального изучения, и мы не будем здесь на ней останавливаться. Заметим только, что можно управлять чувствительностью нейрона к одновременно приходящим спайкам посредством изменения временной константы его мембраны. Более прямой способ состоит в том, чтобы непосредственным возбуждением сверху перевести нейроны отобранных популяций в состояние, близкое к порогу срабатывания. Известно [44], что состояние, близкое к порогу срабатывания, характерно для нейронов коры. Ответ нейронного ансамбля в предпороговом состоянии на одновременно

приходящие спайки может быть высоко когерентным.

Стимуляция сверху, соответствующая объемлющей характеристике, отбирает и синхронизирует разрядку нейронов согласно критерию значимой целостности для каждого данного уровня обработки. Если это действительно так, то в ответ на стимул должна наблюдаться точная синхрония разрядки нейронов, принадлежащих различным специализированным областям зрительной коры, но относящихся к одному уровню перцептивной иерархии.

Такая схема позволяет понять, почему в пространственно разделенных нейронах возникает синхронизация, если они отвечают на один и тот же зрительный объект. Если два пространственно разделенных нейрона отвечают на один объект, то они одновременно стимулируются сверху одной и той же объемлющей характеристикой и их разрядка может быть синхронной с точностью до миллисекунд. Если эти два нейрона отвечают на разные объекты, существующие одновременно, то они стимулируются сверху разными объемлющими характеристиками и нет причин для точной синхронизации их разрядки.

Синхронизация разрядки нейронов посредством избирательной стимуляции сверху может возникать на самой ранней стадии восприятия, как только сформируется первичная объемлющая характеристика, выражающая качественную специфичность квазиобъекта. Стимуляция становится более избирательной, если квазиобъект окажется объектом, качественная специфичность которого выражается объемлющей характеристикой более высокого уровня. Такой процесс может увеличивать точность синхронии разрядки нейронов данного уровня обработки, отвечающих на данный объект. Тогда популяции нейронов, отвечающие на данный объект, оказываются связанными синхронией, что отделяет их от других популяций нейронов, синхронно отвечающих на другие объекты. Такой механизм синхронии, как кажется, может выделять объект из фона и отделять его от других объектов, даже если они частично маскируют друг друга.

Стимуляция сверху, соответствующая объемлющей характеристике объекта, может синхронизировать активность нейронов, отвечающих на разные части объекта, даже если эти части имеют несходные признаки. Принадлежность частей одному объекту, а не сходство их признаков, является необходимым условием синхронии. Это решает проблему, о которой пишут *P. R. Roelfsema et al.* [42]: «Однако, отдельные объекты могут состоять из частей, показывающих довольно несходные признаки, и это открытый вопрос, имеет ли место синхронизация, и если имеет, то как нейроны, отве-

чающие на несходные признаки отдельного объекта, синхронизируются?»

Трудность связывания несходных частей целого относится к более общей проблеме, которую *Р. Миллер* сформулировал (в частной переписке) следующим образом: «Как может существовать органическое единство между компонентами, у которых также может иметься своя собственная отдельная индивидуальность?» Создать органическое единство из частей, обладающих индивидуальностями, вероятно, невозможно никакими техническими средствами, даже такими мощными, как синхронизация разрядки нейронов. Но можно обнаружить естественную принадлежность индивидуальностей к единству более высокого уровня. Объемлющая характеристика как раз и выражает это органическое единство более высокого иерархического уровня.

Объемлющая характеристика должна порождать феномен превосходства целого над частью. Действительно, эффекты превосходства сцены, объекта, фразы, слова и т. п. существуют в самом деле [45]. Например, эффект превосходства слова состоит в ускорении восприятия букв в контексте слова по сравнению с восприятием отдельных букв. Слово, предъявленное в смысловом контексте, воспринимается быстрее, чем при изолированном предъявлении. Ложная смысловая преднастройка увеличивает время реакции, и это вполне понятно: ложная объемлющая характеристика порождает специфическую стимуляцию сверху, что мешает восприятию сенсорных признаков реального стимула.

Формирование объемлющей характеристики объекта является ключевым моментом, с которого начинается стимуляция сверху, синхронизирующая все нижележащие уровни, ответственные за восприятие этого объекта. Когерентность и интенсивность отображения объекта возрастают, что может увеличивать его заметность на психическом уровне. Воспринимаемый объект должен отображаться более интенсивно по сравнению с окружающим фоном, даже если освещенность объекта и фона одинаковы. Объект может восприниматься субъективно как более светлый или более яркий с момента его распознавания.

Действительно, экспериментальные данные показывают, что сочетание фигуры и фона оказывает «поразительное» влияние на восприятие светлоты [46, 47]. Участок изображения, воспринимаемый как фигура, кажется светлее, чем фон. Фигура, как правило, кажется более светлой или более интенсивной (по цвету), нежели фон с такой же светлотой. *Х. Шиффман* [47] приходит к выводу, что эффект светлоты вторичен по отношению к восприятию фигуры. Это хорошо согласуется с нашей моделью восприя-

тия, согласно которой более высокая интенсивность отображения объекта является результатом его распознавания.

Объекты выделяются из фона и распознаются из-за их важности для жизни субъекта в окружающем мире. Поэтому, как это ни удивительно, интенсивность или яркость восприятия объектов должна зависеть от их субъективно переживаемой витальной значимости. Из повседневного опыта мы знаем, что знакомое лицо в толпе «бросается в глаза». Оно предстает с такой интенсивностью, что все остальное становится фоном. Знакомые очертания здания в незнакомом городе, опасный объект, привлекательный человек, животное или пейзаж — все это субъективно значимые события, которые воспринимаются с высокой интенсивностью за счет стимуляции сверху.

В этом отношении большой интерес представляет выяснение механизмов восприятия рисунков, имеющих две или больше интерпретаций. В ответ на предъявление двусмысленного рисунка, восприятие порождает различные образы, хотя рисунок остается одним и тем же. Известно, что восприятие определенного образа зависит от того, какие части рисунка интерпретируются как фон, а какие — как объект [47]. Но остается неясным, почему система восприятия относит некоторые части рисунка к объекту и как отделяет их от окружающего фона.

Объемлющая характеристика объекта — это перцептивная гипотеза, в порождении которой решающее значение имеют хорошо известные субъекту образы или объекты. Распознавание любых признаков очертаний знакомого объекта может порождать перцептивную гипотезу и стимуляцию сверху, которая отбирает те части рисунка, которые относятся к этому объекту. Когерентное отображение отобранных признаков порождает интенсивное восприятие объекта, что выделяет его из окружающего фона.

Как только перцептивная гипотеза подтверждается, она начинает тормозить любые другие интерпретации рисунка. Но время доминирования подтвержденной гипотезы ограничено временем привыкания нейронных структур, которое, судя по экспериментам с фиксированным изображением на сетчатке глаза, составляет несколько секунд. По истечении этого времени, возможно схватывание характерных очертаний другого объекта из деталей того же рисунка, что вызывает интенсивное отображение этого объекта и обращение в фон всех остальных деталей.

Из нашей концепции следует, что первыми должны схватываться очертания того объекта, который наиболее хорошо знаком субъекту. Если такого объекта на двусмысленном рисунке нет, требуется подсказка, чтобы

субъект мог увидеть один из объектов. Если нет подсказки, необходимо длительное разглядывание и работа воображения, чтобы увидеть на таком рисунке неожиданный или мало знакомый объект.

### **Мозг обнаруживает сенсорные объекты, а не комбинирует их из признаков**

В первичной проекционной коре отображаются локальные признаки стимульного поля, такие как границы, линии, углы, пятна и т. п., которые по своей сути являются дифференциальными характеристиками. На следующих уровнях зрительного восприятия дифференциальные данные первичной проекционной коры дифференцируются по сенсорным субмодальностям, порождая разделенные отображения цвета, движения и других признаков стимульного поля в различных областях претриарной коры.

Эти факты с полной очевидностью показывают, что мозг не интегрирует сенсорные сигналы, а извлекает из них дифференциальные признаки. Дифференциация обеспечивает формирование многомерного пространства признаков, соответствующих каждому акту восприятия. Дифференциация в разных аспектах обнаруживает специфичность актуального стимульного поля и, в сущности, является средством многоуровневого отображения специфичности. Дифференциальные признаки, обнаруженные любой нейронной структурой, должны передаваться на множество других нейронных структур. Следовательно, дивергенция сигналов, на каждом уровне обработки, является необходимым свойством системы восприятия.

Специфические сочетания признаков соответствуют значимым целостностям различных когнитивных уровней. Система восприятия выявляет специфичность стимульного поля посредством дифференциации сенсорного возбуждения в разных аспектах, и порождает иерархию характеристик, объемлющих специфические сочетания признаков. Поэтому дивергенция и конвергенция сигналов должны осуществляться на каждом уровне обработки, как это показано на рис. 2 и 3. Отсюда становится понятной функциональная организация коркового нейрона, который имеет тысячи входов от других нейронов, что обеспечивает конвергенцию сигналов. Единственный выход через аксон, посредством ветвления на его конце, обеспечивает дивергенцию сигнала и его передачу на тысячи других нейронов.

Нейронная структура, отображающая сенсорный объект, имеет множество входов, но только один выход — специфический паттерн электрической

активности, который отображает объемлющую характеристику и передается на множество других нейронных структур. Это напоминает систему связей одиночного нейрона, который имеет множество входов через дендриты и только один выход через аксон. Функциональная организация микроуровня, вероятно, повторяется на множестве иерархически упорядоченных макроуровней системы восприятия.

Мозг, с его медленными нейронами, обладает более высокой скоростью распознавания объектов окружающего мира по сравнению с компьютером. В качестве причины высокой эффективности мозга обычно указывают на массивованно-параллельную архитектуру, которая обеспечивает высокую скорость вычислений. Это обстоятельство, конечно, важно. Но еще более существенно то, что мозг ничего не вычисляет. Уже на ранних стадиях восприятия мозг, на основании прошлого опыта, порождает перцептивные гипотезы о содержании зрительного поля и проверяет эти гипотезы. Мозг не столько распознает, сколько «догадывается» о том, что видит.

Современная парадигма восприятия основана на представлениях о том, что мозг комбинирует, связывает или интегрирует признаки в образы или объекты. Такие представления будто бы подтверждаются обширными экспериментальными данными. Однако рассмотрение этих экспериментов показывает, что предлагаемые интерпретации их результатов не являются единственно возможными. Например, в известных экспериментах *А. Трейсман* [48, 49] испытуемым предлагали найти символ доллара среди знаков *S* и отрезков прямых. Испытуемые обнаруживали символ доллара в этих условиях. Но они часто видели символ доллара и в тех случаях, когда на изображениях его на самом деле не было. Если знаки *S* демонстрировались совместно с треугольниками так, что одна из сторон треугольника могла бы дополнять знак *S* до символа доллара, испытуемые также часто видели иллюзорный символ доллара. *А. Трейсман* делает вывод, что иллюзорный символ доллара возникает из-за ошибочной комбинации признаков (*S* и отрезка прямой), даже когда отрезок принадлежит другому объекту.

Однако результаты этих экспериментов можно интерпретировать иначе. Знак *S* — это специфический признак символа доллара, который демонстрируется на дисплее. Если времени экспозиции достаточно, чтобы распознать знак *S*, то система восприятия может породить перцептивную гипотезу — символ доллара. С другой стороны, если времени экспозиции недостаточно для проверки этой гипотезы, символ доллара может оказаться иллюзорным. Таким образом, условием возникновения иллюзии, в данном эксперименте, является длительность экспозиции, которая должна быть достаточной для

распознавания специфического признака  $S$ , но недостаточной для проверки перцептивной гипотезы — символа доллара. Увеличение длительности экспозиции позволяет испытуемым легко обнаруживать отсутствие символа доллара среди знаков  $S$  и отрезков прямых (или треугольников).

В другой серии экспериментов демонстрировались прямые углы, составленные двумя отрезками, и отдельные отрезки, которые могли бы дополнять их до треугольников. Испытуемые изредка видели треугольники, которых на самом деле не было. Однако, если изображение дополнялось кружочками, то испытуемые видели треугольники гораздо чаще. По мнению А. Трейсмана [49], кружочки вносили новый признак — замкнутость фигуры, что приводило к формированию системой восприятия ошибочной комбинации — замкнутого треугольника.

Специфическими признаками треугольников являются углы, образованные парами отрезков. Распознавание специфического признака может породить перцептивную гипотезу — треугольник. Время экспозиции, в данном эксперименте, оказывается достаточным не только для порождения, но и для проверки перцептивной гипотезы, поэтому испытуемые редко видят иллюзорный треугольник. Но если изображение дополняется кружочками, оно становится значительно сложнее и прежнего времени экспозиции оказывается недостаточно для проверки гипотезы, поэтому испытуемые чаще видят иллюзорный треугольник. Простое увеличение длительности экспозиции ведет к исчезновению иллюзии. Таким образом, отсутствуют основания постулировать способность системы восприятия комбинировать разрозненные признаки в замкнутые геометрические фигуры.

Можно показать, что и никакие другие эксперименты не доказывают способность системы восприятия комбинировать или интегрировать сенсорные признаки. Зато известные экспериментальные данные хорошо совмещаются с идеей о том, что система восприятия обнаруживает сочетания признаков, образующих значимые целостности.

Мозг не комбинирует и не интегрирует сенсорные данные, а обнаруживает такие специфические сочетания дифференциальных признаков, которые соответствуют значимым объектам или событиям. Термин «комбинировать» означает, что система восприятия может создавать сенсорные объекты из признаков, как это следует из работ А. Трейсмана [48, 49] и многих других. Термин «обнаруживать» означает, что система восприятия может находить такие специфические сочетания признаков, которые соответствуют сенсорным объектам. Например, система восприятия не связывает три отрезка в треугольник. Но если три отрезка соединены концами, то система

восприятия обнаруживает эту специфическую комбинацию как значимую целостность — треугольник. Ассоциативная структура любого уровня восприятия не комбинирует признаки, а обнаруживает (находит) адаптивно значимые сочетания признаков. «Комбинировать» или «обнаруживать» — это не игра в слова. За этими словами стоят принципиально разные концепции, из них мы выбираем ту, которая соответствует нашему пониманию природы восприятия.

Специфическое сочетание признаков, выражающее значимую целостность, является сенсорным основанием для перцептивной гипотезы — объемлющей характеристики объекта. Например, специфическое пространственное сочетание отрезков и их пересечений (крестообразных фигур) может служить сенсорным основанием для перцептивной гипотезы — треугольника, квадрата или другой плоской фигуры. Специфическое пространственное сочетание плоских фигур может служить сенсорным основанием для формирования объемлющей характеристики трехмерного объекта.

Поверхности трехмерного объекта имеют различную экспозицию по отношению к источнику света и, поэтому, должны отличаться освещенностью. Первичные объемлющие характеристики, в этом случае, определяют конфигурацию поверхностей разной освещенности. Специфическое сочетание поверхностей разной освещенности может служить сенсорным основанием для формирования объемлющей характеристики трехмерного объекта. Специфическое сочетание поверхностей разного цвета или разных оттенков одного цвета также может служить сенсорным основанием для формирования объемлющей характеристики трехмерного объекта.

Заметим, что хотя поверхности выражаются объемлющими характеристиками, по отношению к трехмерной фигуре они выполняют функции признаков, дающих сенсорное основание для порождения перцептивной гипотезы, — объемлющей характеристики объекта. Тогда сенсорным основанием для порождения объемлющей характеристики трехмерного объекта могут служить: специфическое сочетание отрезков и крестообразных фигур, сочетание поверхностей разной освещенности, сочетание поверхностей разного цвета или разных оттенков одного цвета и другие. Каждый из этих наборов признаков может порождать объемлющую характеристику объекта, если соответствующие нейронные структуры обучены распознавать этот объект.

В такой системе восприятия один и тот же трехмерный объект распознается одновременно и параллельно на основе сочетаний разных специфических признаков. Нейронные структуры каждого сенсорного пути отвечают

высокой активностью на те и только те признаки или их сочетания, которые они обучены распознавать. Такая система восприятия может обладать высокой надежностью, поскольку при повреждении одной или нескольких нейронных структур, способность к восприятию может сохраняться за счет параллельного функционирования других нейронных структур.

Объемлющая характеристика объекта отображается специфическим паттерном электрической активности, который передается на нейронные структуры нижележащего уровня, отображающие признаки данного объекта в данном месте. Те признаки, которые действительно обнаруживаются рецепторами в это время и в этом месте, акцентируются благодаря стимуляции сверху. Интенсивность отображения объекта возрастает, что может служить сенсорным подтверждением перцептивной гипотезы.

Перцептивные гипотезы порождаются в параллельных путях, подтверждая друг друга и обеспечивая высокую надежность восприятия. Если только часть сенсорных путей порождает согласованную перцептивную гипотезу, это не должно препятствовать распознаванию объекта, хотя скорость восприятия может уменьшаться. Подтверждение перцептивной гипотезы, в этом случае, требует дополнительной стимуляции сверху и повторения процедуры распознавания, что увеличивает время восприятия. Какова бы ни была объемлющая характеристика объекта, она должна соответствовать высшей объемлющей характеристике данного акта восприятия - зрительной сцене. Если объемлющая характеристика объекта не соответствует содержанию или смыслу сцены, то это должно вызывать ориентировочную реакцию и порождение новой перцептивной гипотезы.

Порождение объемлющей характеристики объекта не требует присутствия в поле зрения всех его признаков. Частичный набор специфических признаков может служить сенсорным основанием для порождения перцептивной гипотезы. Поэтому система восприятия может эффективно функционировать в условиях недостатка сенсорных данных. Время восприятия может быть небольшим, поскольку перцептивные гипотезы порождаются на основе данных первых корковых уровней обработки, а время ответа нейронных структур переводится в миллисекундный диапазон посредством стимуляции сверху.

Нейронные структуры восприятия не обучены распознавать шумы и, поэтому, не могут отвечать на них интенсивной активностью. Каждый уровень обработки игнорирует шумы как незначимые сигналы, а их передача вверх по сенсорному пути не стимулируется сверху. Система восприятия не столько фильтрует шумы, сколько просто их игнорирует. Таким образом,

модель объемлющих характеристик отвечает принципу оптимальности: она требует минимум сенсорной информации, осуществляет процедуру распознавания за минимальное время, игнорирует шумы любого происхождения и обладает высокой живучестью, поскольку может эффективно функционировать даже в случае частичного повреждения нейронных структур.

### **Компьютерные эксперименты по распознаванию трехмерных объектов**

Подходящий математический аппарат, позволяющий описать иерархию объемлющих характеристик, дает теория графов. В качестве первой версии модели, построен алгоритм распознавания объектов на перспективной проекции сцены, составленной из белых прямых параллелепипедов с черными ребрами на белом фоне [27, 28]. Поскольку перспективная проекция переводит отрезок в отрезок, то можно считать, что на вход подается набор отрезков. Такая упрощенная постановка задачи позволяет сосредоточить внимание на содержательной стороне проблемы распознавания: среди разрозненных и не наделенных функциональным смыслом входных данных (отрезков) обнаружить важные для функционирования организма трехмерные объекты. Похожая задача может возникать перед роботом, который перекладывает коробки на складе, или разбирает нагромождение из кирпичей. В табл. 1 представлена иерархия объемлющих характеристик, соответствующая этой задаче.

Поиск объемлющих характеристик (значимых целостностей) сводится к тому, чтобы: (1) выявить типы парных (двуместных) отношений между характеристиками из правой части таблицы; (2) построить граф-шаблон, где вершинами будут характеристики из правой части таблицы, а ребрами — отношения между ними; (3) построить граф-данные, где вершинами будут все характеристики нижележащего уровня, а ребрами — их отношения; (4) найти все изоморфные вложения графа-шаблона в граф-данные (как части, с учетом типов отношений); (5) для каждого вложения проверить определение, указанное в правой части таблицы.

Описанная процедура применяется для построения объемлющих характеристик второго уровня, затем третьего уровня и так далее, вплоть до высших объемлющих характеристик — прямых параллелепипедов. Схема формирования иерархии объемлющих характеристик показана на рис. 6.

Разработан алгоритм поиска изоморфных вложений графа-шаблона в

Таблица 1. Иерархия объемлющих характеристик в задаче распознавания прямых параллелепипедов. Слова, набранные жирным шрифтом, означают объемлющие характеристики, все остальное — общепринятые термины.

Перцептивный уровень	Объемлющая характеристика	Пространственная организация: определение объемлющих характеристик в терминах нижележащих уровней
1 В картинной плоскости	<b>Отрезок</b>	Отрезок
	<b>Псевдоотрезок</b>	Или отрезок, или два отрезка, лежащие на одной прямой
2 В картинной плоскости	<b>Плоская Y-фигура</b>	Три <b>отрезка</b> , попарно не лежащие на одной прямой, но имеющие общую для всех трех вершину
	<b>Плоский четырехугольник</b>	Четыре <b>псевдоотрезка</b> , такие, что каждый из них: 1) имеет общую вершину с предыдущим и с последующим, и не лежит ни с одним из них на одной прямой; 2) не пересекается с <b>псевдоотрезком</b> через одного
3 В трехмерном пространстве	<b>Прямой трехгранный угол</b>	Одна <b>плоская Y-фигура</b> , такая, что она может быть проекцией прямого трехгранного угла
	<b>Прямоугольник</b>	Один <b>плоский четырехугольник</b> , такой, что восстановленный по нему параллелограмм: 1) является прямоугольником; 2) целиком находится в той же стороне от фокуса, что и картинная плоскость
4	<b>Прямой параллелепипед</b>	Определение опущено из-за громоздкости выражения.

граф-данные, важным достоинством которого является линейная зависимость времени счета от числа вершин в графе-данных. Такой алгоритм, при увеличении количества объектов на предъявляемом изображении, не ведет к взрывообразному росту объема вычислений.




Рис. 6. Схема формирования иерархии объемлющих характеристик в процессе распознавания прямых параллелепипедов. Объекты первого и второго уровней обработки лежат в картинной плоскости, объекты третьего и четвертого уровней расположены в трехмерном пространстве.

Алгоритм распознавания реализован в виде программы на языке C++ [28]. Исходная конфигурация объектов для распознавания задается в текстовом файле. Этот файл строится специальной программой рендеринга и состоит из наборов по 6 чисел. Каждый набор задает один отрезок: первые 3 числа определяют начало отрезка, последние 3 числа — его направление и протяженность (2 из 6 чисел оказываются одинаковыми для всех отрезков, поскольку все они лежат в картинной плоскости). Эксперименты по распознаванию производились на компьютере с процессором Pentium-IV (2400 МГц, 512 Мб оперативной памяти).




Рис. 7. Результаты компьютерного распознавания параллелепипедов, конфигурация которых показана слева вверху. Жирными линиями показаны отрезки, которые программа выделяет в качестве признаков, позволяющих сформировать перцептивную гипотезу. Пунктирными линиями программа достраивает распознанные параллелепипеды.

На рис. 7, 8 и 9 представлены примеры распознавания трехмерных геометрических объектов. На рис. 9 справа внизу пунктиром показан иллюзорный кубик. Иллюзия возникает потому, что в данной версии модели распознавания отсутствуют обратные связи и ложная перцептивная гипотеза не может быть опровергнута.

Выполнены многочисленные эксперименты по распознаванию трехмерных геометрических объектов. Компьютерные эксперименты показали, что геометрические объекты успешно распознаются во всех случаях, когда их проекции состоят хотя бы из двух граней, и ни одна из вершин не скрыта за другими объектами. Частичная маскировка граней другими объектами не создает препятствий для распознавания. Таким образом углы оказываются ключевыми признаками для идентификации трехмерных геометрических фигур. Этот результат хорошо согласуется с психофизиологическими экспериментами *И. А. Шевелева* с соавторами [50], где показано, что X-




Рис. 8. Пример распознавания трех параллелепипедов. Жирными линиями показаны отрезки, специфическое сочетание которых программа идентифицирует как параллелепипед. Пунктиром показаны линии, достроенные распознающей программой.

образные фигуры и их фрагменты играют ключевую роль при восприятии человеком геометрических объектов.

Опыт успешного компьютерного распознавания трехмерных объектов, а также характер трудностей, возникающих при распознавании (например, возникновение иллюзорных объектов), очень напоминают соответствующий опыт восприятия человеком геометрических фигур. Это обстоятельство позволяет задать вопрос, имеет ли компьютерная процедура (рис. 6) какое-либо сходство с процессом распознавания человеком геометрических объектов? Распознавание геометрического объекта данного уровня является результатом формирования характеристики, объемлющей значимые геометрические объекты нижележащего уровня. В связи с этим интересны экспериментальные данные по возрастному развитию восприятия и способностей детей рисовать геометрические фигуры. Например, дети 4–5 лет рисуют конус в виде рядом расположенных круга и треугольника [51]. Это значит, что нейронные структуры коры, порождающие объемлющие харак-




Рис. 9. Примеры компьютерного распознавания кубиков, показанные жирными линиями. Справа внизу пунктирными линиями показан иллюзорный кубик. Этот кубик построен программой на основе специфического сочетания отрезков, показанных жирными линиями.

теристики плоских фигур — круга и треугольника — уже сформированы у детей к этому возрасту. В компьютерной процедуре распознавания аналогичные функции выполняет второй уровень обработки.

Круг и треугольник представляют собой плоские признаки трехмерного объекта — конуса. Способность формировать объемлющие характеристики трехмерных объектов по плоским изображениям кажется наиболее загадочной. Проблема распознавания трехмерных фигур состоит в выявлении таких специфических пространственных отношений плоских фигур, которые соответствуют трехмерным объектам. Способности детей 4–5 лет распознавать и рисовать трехмерные фигуры возникают в процессах дальнейшего обучения и возрастного развития. Это свидетельствует о формировании, посредством обучения, нейронных структур, порождающих объемлющие характеристики трехмерных объектов. В компьютерной модели распознавания такие функции выполняют третий и четвертый уровни обработки. Таким образом, компьютерная процедура, реализующая иерархию объем-

лющих характеристик, возможно, в какой то мере аналогична процессу распознавания человеком трехмерных объектов. Это предположение требует дальнейшего изучения, что вполне возможно, поскольку, с одной стороны, имеются обширные экспериментальные данные по возрастному развитию восприятия человеком геометрических фигур. С другой стороны, разработана модельная основа для компьютерных экспериментов, правдоподобно имитирующих процессы распознавания трехмерных геометрических объектов.

### **Заключение**

В работе предлагается новый взгляд на организацию процесса восприятия. Вводится понятие объемлющей сенсорной характеристики, которая является ответом данного перцептивного уровня на те признаки или характеристики нижележащего уровня, пространственная организация или специфическая временная последовательность которых составляет адаптивно значимую целостность. Последовательность объемлющих характеристик образует иерархию: от признаков до высших объемлющих характеристик, выражающих целостные образы и сцены. Иерархия объемлющих характеристик — это путь от восприятия физических к формированию семантических характеристик.

Специфические паттерны электрической активности, отображающие объемлющие характеристики, посредством обратных связей передаются с верхних нейронных уровней на нижние. Это формирует каскад переноса возбуждения сверху вниз, стимулирующий те нейронные структуры, сигналы которых соответствуют высшей объемлющей характеристике данного акта восприятия. В каскадной схеме передача возбуждения происходит только на непосредственно нижележащий уровень обработки. Стимуляция нейронных структур, отображающих различные сенсорные характеристики одного перцептивного уровня, позволяет связать их в осмысленное целое.

Стимуляция сверху уменьшает время реакции отобранных нейронов нижележащих уровней до миллисекундного диапазона. В результате нейронные популяции нижележащих уровней, участвующие в данном акте восприятия, на короткое время становятся детекторами совпадений. Иерархически упорядоченный набор нейронных ансамблей из детекторов совпадений формирует быстрый сенсорный путь, единственный и уникальный для каждого акта восприятия.

Иерархия объемлющих сенсорных характеристик и каскадный перенос

специфического возбуждения сверху вниз образуют единый психофизиологический механизм восприятия. Многоуровневый иерархический отбор сенсорных признаков и значимых целостностей обеспечивает передачу в вышестоящие структуры мозга только той информации, которая отвечает потребностям и целям организма. Мозг не фильтрует и не подавляет избыточные сигналы и шумы, он просто их игнорирует.

Гипотеза объемлющих характеристик приводит к концепции восприятия, необходимыми свойствами которой являются иерархичность организации, синхронизация нейронной активности и нисходящая стимуляция. Таким образом, наиболее активно дискутируемые теоретические воззрения на природу восприятия оказываются естественным образом связанными в единой концепции. При этом, сами теоретические представления приобретают иное качество и функциональный смысл. Например, вопреки традиционным представлениям об иерархической организации восприятия как последовательности от простого к сложному, иерархия объемлющих характеристик является последовательностью от сложного к простому. Стимуляция сверху не отбирает определенные объекты из множества возможных. Стимуляция сверху уменьшает время реакции целевых нейронов нижележащих уровней до миллисекундного диапазона. Объемлющая характеристика, посредством стимуляции сверху, отбирает популяции нейронов, которые могут отображать признаки данного объекта по прошлому опыту. Если эти признаки действительно обнаруживаются рецепторами, «специфические ворота» для соответствующего сенсорного возбуждения оказываются открытыми.

В рассматриваемой концепции многие проблемы современных теорий восприятия или не существуют, или имеют ясные перспективы решения. Структура модели восприятия делает невозможным и ненужным существование всезнающего гомункулуса, но обладает столь же широкой универсальностью в отношении объяснения феноменов восприятия. Выясняются когнитивные механизмы, обеспечивающие легкость обучения человека и высших животных новым сенсорным категориям, которое может происходить буквально с первого предъявления. Теоретические следствия модели имеют разносторонний характер и формулируются в конкретной форме, что делает их доступными экспериментальной проверке в лабораторных условиях. Компьютерные эксперименты демонстрируют работоспособность модели и подтверждают широкие возможности дальнейших теоретических и экспериментальных исследований восприятия на новой концептуальной основе.

## Литература

1. Хьюбел Д. Глаз, мозг и зрение. – М.: Мир, 1990. – 240 с.
2. Прибрам К. Языки мозга. – М.: Прогресс, 1975. – 464 с.
3. Солсо Р.Л. Когнитивная психология. – М.: Тривола, 1996. – 598 с.
4. Ghose G. M., Maunsell J. Specialized representations in visual cortex: A role for binding? // *Neuron*. – 1999. – v. 24, No. 1. – pp. 79–85.
5. Hubel D., Wiesel T. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex // *J. Physiol.* – 1962. – v. 160. – pp. 106–154.
6. Игумен Феофан (Крюков). Сенсорная интеграция: иерархичность и синхронизация // *Нейроинформатика-2005*. VIII Всероссийская научно-техническая конференция. Сборник научных трудов. – 2005. т. 2. – Москва: МИФИ, с. 79–92.
7. Stringer S. M., Rolls E. T. Invariant object recognition in the visual system with novel views of 3D objects // *Neural. Comput.* – 2002. – v. 14. – pp. 2585–2596.
8. Treisman A. Solutions to the binding problem: progress through controversy and convergence // *Neuron*. – 1999. – v. 24. – pp. 105–110.
9. Watt R. J., Phillips W. A. The function of dynamic grouping in vision // *Trends Cogn. Sci.* – 2000. – v. 4. – pp. 447–454.
10. Bar M. Top-Down Facilitation of Visual Object Recognition Neurobiology of Attention, L. Itti, G. Rees, and J.K. Tsotsos (Eds.) – Elsevier Academic Press, Amsterdam, 2005. – pp. 140–145.
11. Giesbrecht B., Woldorff M. G., Song A. W., Mangun G. R. Neural mechanisms of top-down control during spatial and feature attention // *Neuroimage*. – 2003, v. 19. – pp. 496–515.
12. Driver J., Eimer M., Macaluso E., van Velsen J. The neurobiology of human spatial attention: modulation, generation and integration // *Functional Neuroimaging of Visual Cognition: Attention and Performance, XX* / Eds: Kanwisher N., Duncan J. – Oxford: Oxford University Press, 2004. – pp. 267–299.
13. Thorpe S. D. Fize D., C. Marlot C. Speed of processing in the human visual system // *Nature*. – 1996, v. 381. – pp. 520–522.
14. Ungerleider L., Haxby J. “What” and “Where” in the human brain // *Curr. Opin. Neurobiol.* – 1994, v. 4. – pp. 157–165.
15. Malsburg C. von der. Binding in models of perception and brain function // *Curr. Opin. Neurobiol.* – 1995, v. 5. – pp. 520–526.
16. Singer W. Neuronal synchrony: A versatile code for the definition of relations? // *Neuron*. – 1999, v. 24. – pp. 49–65.

17. Engel A. K., Roelfsema P. R., Fries P., Brecht M., Singer W. Role of the temporal domain for response selection and perceptual binding // *Cereb. Cortex.* – 1997, v. 7. – pp. 571–582.
18. Singer W., Gray C. M. Visual feature integration and the temporal correlation hypothesis // *Ann. Rev. Neurosci.* – 1995, v. 18. – pp. 555–586.
19. Roelfsema P. R., Engel A. K., König P., Singer W. Visuomotor integration is associated with zero time-lag synchronization among cortical areas // *Nature.* – 1997, v. 385. – pp. 157–161.
20. Schmolesky M. T., Wang Y., Hanes D. P., Thompson K. G., Leutgeb S., Schall J. D., Leventhal A. G. Signal timing across the macaque visual system // *J. Neurophysiol.* – 1998, v. 79. – pp. 3272–3278.
21. Givre S. J., Arezzo J. C., Schroeder C. E. Effects of wavelength on the timing and laminar distribution of illuminance-evoked activity in macaque V1. // *Vis. Neurosci.* – 1995, v. 12. – pp. 229–239.
22. Damasio A. R. The brain binds entities and events by multiregional activation from convergence zones // *Neural Computation.* – 1989, v. 1. – pp. 123–132.
23. Hummel J. E. Complementary solutions to the binding problem in vision: Implications for shape perception and object recognition // *Visual Cogn.* – 2001, v. 8. – pp. 489–517.
24. Zeki S. A. Vision of the brain. – Oxford: Blackwell Scientific Publications, 1993. – 366 pp.
25. Сергин В. Я. Механизмы зрительного восприятия: концепция объемлющих сенсорных характеристик // *Нейроинформатика-2006. VIII Всероссийская научно-техническая конференция. Сборник научных трудов. 2006. т. 3. Москва: МИФИ.* – с. 224–235.
26. Сергин В. Я. Перцептивное связывание сенсорных событий: гипотеза объемлющих характеристик // *Журнал высшей нервной деятельности.* – 2002. т. 52, № 6. – с. 645–655.
27. Sergin A. V., Sergin V. Ya. Mechanisms of Perception: Embedded Sensory Characteristics Model // *Cybernetics and Systems '2004.* – World Scientific Publishing Co., 2004, v. 1. – pp. 216–221.
28. Сергин А. В. Компьютерная модель восприятия: Иерархия объемлющих сенсорных характеристик // *Нейроинформатика-2006. VIII Всероссийская научно-техническая конференция. Сборник научных трудов.* – 2006. т. 1. Москва: МИФИ. – с. 189–195.
29. Ухтомский А. А. Доминанта. – Спб.: Питер, 2002. – 448 с.

30. *Kryukov V. I.* An attention model based on the principle of dominanta // *Neurocomputers and attention. I. Neurobiology, synchronization and chaos* / Eds. *Holden A. V., Kryukov V. I.* – Manchester: Manchester Press, 1991. – pp. 319–351.
31. *Борисюк Г. Н., Борисюк Р. М., Казанович Я. Б., Иваницкий Г. Р.* Модели динамики нейронной активности при обработки информации мозгом — итоги «десятилетия» // *УФН.* – 2002. – т. 172, № 10. – с. 1189–1214.
32. *Borisyuk R. M., Kazanovich Y. B.* Oscillatory neural network model of attention focus formation and control // *Biosystems.* – 2003, v. 71. – p. 29–38.
33. *Игумен Феофан (Крюков).* Модель внимания и памяти, основанная на принципе доминанты и компараторной функции гиппокампа // *ЖВНД.* – 2004. – т. 54, № 1. – с. 10–29.
34. *Hebb D. O.* The Organization of behavior. – New York: Wiley, 1949.
35. *Иваницкий А. М.* Физиология мозга о происхождении субъективного мира человека // *Журн. высш. нерв. деят.* – 1999. – т. 49, № 5. – с. 707–713.
36. *Барабанчиков В. А.* Системогенез чувственного восприятия. – М.: Изд-во «Институт практической психологии», 2000. – 464 с.
37. *Beck J.* Textural segmentation, second-order statistics, and textural elements // *Biological Cybernetics.* – 1983, v. 48. – pp. 125–137.
38. *Sagi D., Julesz B.* “Where” and “what” in vision // *Science.* – 1985, v. 228. – pp. 1217–1219.
39. *Наатанен Р.* Внимание и функции мозга. – М.: МГУ, 1998. – 559 с.
40. *Cotterill R. M. J.* Autism, intelligence and consciousness // *Biologiske Skrifter Danske Videnskabernes Selskab.* – 1994, v. 45. – pp. 1–93.
41. *Leonards U., Singer W., Fahle M.* The influence of temporal phase differences on texture segmentation // *Vision Res.* – 1996, v. 36. – pp. 2689–2697.
42. *Roelfsema P. R., Engel A. K., Konig P., Singer W.* The role of neuronal synchronization in response selection: A biologically plausible theory of structured representations in the visual cortex // *Massachusetts Institute of Technology, Journal of Cognitive Neuroscience.* – 1996. – v. 8, No. 6. – pp. 603–625.
43. *Воронков Г. С.* Механизм решения задач в элементарном сенсорнуме: нейронные механизмы опознания и сенсорного обучения // *Нейрокомпьютеры: разработка и применение.* – 2004, № 2–3. – с. 92–100.
44. *Кропотов Ю. Д.* Система селекции действий мозга как фильтр высокого уровня // *Оптический журнал.* – 1999. – т. 66, № 10. – с. 55–61.
45. *Величковский Б. М.* Современная психология. – М.: МГУ, 1982. – 336 с.

46. *Bonato P., Cataliotti J.* The effects of figure/ground, perceived area, and target saliency on the luminosity threshold // *Perception and Psychophysics*. – 2000, v. 62. – pp. 341–349.
47. *Шифман Х. Р.* Ощущение и восприятие. – С.-Пб.: Питер Принт, 2003. – 924 с.
48. *Трейсман Э.* Объекты и их свойства в зрительном восприятии человека // *В мире науки*. – 1987, № 1. – с. 68–78.
49. *Treisman A.* The binding problem // *Current Opin. in Neurobiol.* – 1996. – v. 6. – pp. 171–178.
50. *Шевелев И. А., Каменкович В. М., Лазарев Н. А., Новикова Р. В., Тихомиров А. С., Шараев Г. А.* Психофизиологическое и нейрофизиологическое исследование опознания неполных изображений // *Сенсорные системы*. – 2003. – т. 17, № 4. – с. 339–346.
51. *Ярошевский М. Г.* Наука о поведении: Русский путь. – Воронеж: Институт практической психологии, 1996.

**Владимир Яковлевич СЕРГИН**, ведущий научный сотрудник Института математических проблем биологии РАН, доктор физико-математических наук, заслуженный деятель науки РФ. Область научных интересов: психофизиологические механизмы и системная организация восприятия, сознания, рассудочного и образного мышления, интуиции. Является автором более 80 научных работ, в том числе 2 монографий и 3 изобретений.

**В. Л. ВВЕДЕНСКИЙ**  
Курчатовский институт,  
Москва  
E-mail: [vvedensky@imp.kiae.ru](mailto:vvedensky@imp.kiae.ru)

## **ПОСТРОЕНИЕ СМЫСЛОВОГО ПРОСТРАНСТВА ЯЗЫКА ЧЕЛОВЕКА**

### **Аннотация**

В работе подробно изложен нетрадиционный подход к проблеме представления человеческого языка в форме, приемлемой для компьютера. В языке человека ключевым, является смысл применяемых слов, но формализация категории смысла считается неосуществимой задачей. И все же мы полагаем, что такая возможность имеется. Смысл выражения — это то, что должен передать переводчик, а не просто заменить слова одного языка на слова другого. В качестве объекта исследования мы взяли множество словарей разных языков, полагая, что содержание словарных статей отражает смысл соответствующих слов. Мы обнаружили, что устройство лексиконов разных языков подчиняется строгим математическим закономерностям, опираясь на которые, можно установить способ представления языка в мозге человека. Рассматривалось множество глаголов европейских языков, и оказалось, что звуковая форма корней этих слов в разных языках позволяет упорядочить их в виде плотноупакованной структуры на двумерной поверхности. Это указывает на способ представления звучания глаголов на коре мозга, где очевидно имеется компактная область, кодирующая звучание. Видимо именно она поражается при инсультах, приводящих к нарушению речи. Если же упорядочить множество глаголов по смыслу, то их также можно распределить на двумерной поверхности, однако они образуют не плотное пятно, а группируются в своеобразную дендритную структуру. Глаголы представлены на двумерной поверхности коры, по крайней мере, в двух областях, строение которых существенно различно. Мы полагаем, что полученные результаты могут быть полезны для разработки систем речевого контакта с компьютером.

**V. L. VVEDENSKY**  
Kurchatov Institute,  
Moscow, Russia  
**E-mail: vvedensky@imp.kiae.ru**

## **CONSTRUCTION OF THE MENTAL SPACE OF THE HUMAN LANGUAGE**

### **Abstract**

An unorthodox approach to the problem of implementation of human language in computer is presented. The meaning of words is the crucial feature of the human language. Formalization of meaning or sense is considered unfeasible, though we believe that this can be done. The main goal for any interpreter is to reproduce the meaning of an utterance, but not to convert the words used into other language. We took dictionaries of many languages as the object for our study since we believe that they reflect the sense of the words included. It turns out that the lexicons of different languages are built in accordance with quite strict mathematical rules, which provide insight into the organization of language in the human brain. We performed a scrutiny of the manifold of verbs of several European languages and did show that the phonetic form of the roots is such that one can organize them into a densely packed two-dimensional array. The phonation of verb roots is probably presented on the cortical surface in such a way. Most probably, just this area is damaged, when the speech is affected as a result of local cerebral hemorrhage. If the meanings of the verbs are taken as a classification factor, these words can also be arranged over the two-dimensional surface, though as a dendrite structure. The verbs seem to be presented in two different areas in the cortex, which have different structures. We believe that these findings can be useful for the design of the computer speech interface.

### **Введение**

Широкое проникновение в современную жизнь компьютерной техники в виде интернета и мобильных телефонов настоятельно требует удобного для широкого круга людей способа управления этими устройствами. Традиционная клавиатура и мышь (или джойстик) неудобны для приборов все уменьшающихся в размерах, особенно для мобильных телефонов или карманных компьютеров. Здесь ограничивающим фактором является размер

пальца и острота зрения. Разумной альтернативой может служить управление голосом в необходимых случаях. Функция голосового набора телефонного номера уже встроена в большинство мобильных телефонов, однако надо заметить, что качество этой функции не вызывает восторга у пользователей. Телефон (по сути дела компьютер) чаще всего «не понимает» что было произнесено, особенно в условиях шума или других разговоров вокруг. Для человека же понять какой номер назван не составляет труда, даже если это жаргонное «две дюжины полста». Похоже у людей имеется какой-то «встроенный» механизм, позволяющий решать задачу распознавания речи с легкостью недостижимой для самых сложных компьютеров [1]. Несмотря на то, что компьютеры достигли уровня позволяющего обыгрывать ведущих гроссмейстеров в шахматы, их способности в распознавании речи не вышли за рамки ясельного возраста у людей, хотя эту задачу стараются решить уже более тридцати лет [2]. Основы применяемых ныне методов распознавания речи изложены в обзоре [3].

Серьезные затруднения на пути создания систем автоматического распознавания речи заставляют пристальнее взглянуть на то, как устроены механизмы, осуществляющие функцию языка в мозге человека [4]. Наиболее характерно, что говоря с человеком, нам важно не распознавание, а понимание речи. То есть следует не просто узнать произнесенные слова (некоторые вообще не нужны для понимания), а определить передаваемый смысл даже очень короткого сообщения. Понятие смысла (Рус — *смысл, значение*; Ger — *Sinn, Bedeutung*; Eng — *sense, meaning*; Fra — *sens*; Gre — *εννοια, νοημα, σημασια*, откуда — семантика) не рассматривается в общепринятых ныне подходах к созданию систем речевого контакта с компьютером. Собственно говоря, не ясно, как его можно ввести в математической форме. В настоящей статье мы и хотим изложить подход к описанию понятия смысла. Исходной точкой является известное требование к любому переводчику, чтобы он переводил смысл высказывания, а не произнесенные слова. Хорошие переводчики с этим справляются, то есть для них смысл — это вполне практическая вещь. Да и обычные люди легко могут сказать, что некоторые слова близки по смыслу, причем одно ближе, а другое дальше. В русском языке изменение приставки в слове может или слабо, или радикально повлиять на смысл слова. Возникает ощущение, что в пространстве слов имеется некоторая метрика, позволяющая описать такое пространство.

Множество слов (тезаурус, лексикон) некоторого языка часто рассматривается как граф, где слова являются узлами, соединенными связями, от-

ражающими семантические отношения [5, 6, 7]. Слова английского языка, в количестве около 100 тысяч, могут быть представлены как абстрактные математические объекты и анализ показывает, что их можно разместить в пространстве невысокой размерности. Такой результат вытекает из рассмотрения множества блужданий по этой сети, которым можно сопоставить речь человека. Любое предложение является траекторией в таком пространстве. Основная масса связей локальна, но встречаются и связи между сильно удаленными объектами во вмещающем пространстве. Наши дальнейшие результаты согласуются с этими утверждениями, но имеют значительно более конкретную форму. Представление в виде графа иногда может быть чрезвычайно неадекватным, характерным примером тому является знаменитая римская дорожная карта *Tabula Peutingeriana*. На ней изображена вся Римская империя от Ирландии до Индии с указанием множества городов и сетью дорог между ними, отмеченными числом дневных переходов. Она в общем-то точна, но очертания морей и суши искажены так, что практически неузнаваемы. Зато ее удалось разместить на свитке длина которого во много раз больше ширины. Его удобно скручивать в рулон. Если же не задаваться такой утилитарной целью, то даже имеющиеся сведения о расстояниях между городами могут дать правильные сведения о строении земли, морей и суши. Данные заключенные в графе могут быть использованы для определения свойств вмещающего его пространства. Так из расписания авиарейсов в большом международном аэропорту, без каких-либо дополнительных данных можно установить, что Земля — это шар. Примерно эту задачу мы и поставили себе, пытаясь из данных собранных в словарях (лексиконах) разных языков определить свойства структур в мозге человека осуществляющих функцию языка.

### **Базовый словарный состав языка**

В своем подходе мы старались использовать те возможности, которые предоставляет учет близости по смыслу различных слов языка. У слова есть как бы две ипостаси: его звучание и его значение, причем и то и другое во многих случаях очень нечетко определено с формальной точки зрения, в частности, при описании фонограмм речи или при выборе конкретного синонима из списка. Это не создает проблем для людей, но пока является почти непреодолимым препятствием для систем автоматического распознавания речи или перевода на другой язык.

Для целей анализа было бы разумно как-то выделить наиболее существенное ядро языка, максимально отражающее его базовые свойства, как с точки зрения звучания, так и по организации смысловых связей. Можно, например, рассматривать наиболее часто встречающиеся в речи или текстах слова, частотное распределение которых следует закону Ципфа [8] (или Зифа, по-американски). Однако оказывается, что большинство часто встречающихся слов выполняют в языке чисто служебные функции (артикли, предлоги и т. п.), тогда как многие редко употребляемые слова, например указывающие на опасность, несомненно очень важны.

Мы полагаем, что для выделения смыслового ядра языка важную роль может сыграть китайская система изображения слов с помощью иероглифов, которые отражают не звучание слов, а их смысловое содержание. Китайцы записывают отдельные слова с помощью одного, двух или трех иероглифов, иногда даже больше. Можно допустить, что многовековая практика использования этой системы привела к тому, что наиболее экономно, то есть используя лишь один символ, изображаются понятия наиболее существенные для языка. Оказывается, что единичных иероглифов, передающих конкретное понятие всего около 1000 [9, 10]. Большинство иероглифов используется только в сочетаниях. Переводы основных иероглифов в значительной степени совпадают со словами, включающими основные корни большинства европейских языков (вероятно и остальных тоже). В европейских языках имеются 1300–1800 слов, которые соответствуют понятиям, описываемым единичными китайскими иероглифами, превышение 1000 объясняется существованием синонимов. Одному иероглифу могут соответствовать несколько переводов на европейский язык, причем обратный перевод на китайский может обозначаться и совсем другим иероглифом. То же самое относится и к переводам основных слов с одного европейского языка на другой. Полученный базовый список слов отражает сильно связанную и взаимозависимую систему понятий. Слова европейских языков богато используют аффиксы (приставки, суффиксы, окончания) или сателлиты для передачи вариантов смысла, однако оказывается, что в базовом списке количества корней и слов не очень отличаются. Похоже на то, что усложнение слов приставками или сателлитами (встать: *get up* — Eng; *stehen Sie auf* — Ger) находит отражение в использовании комбинаций иероглифов.

Интересно сравнить список английских переводов 1000 основных понятий со списком 1000 наиболее часто употребляемых английских слов.

Принципы отбора в эти списки существенно различны, однако имеются примерно 300 общих слов. Это наиболее востребованные базовые слова:

*again, all, and, ask, back, bad, ball, band, bank, bar, be, beat, beauty, bed, bell, best, bind, bird, bite, black, blind, blood, blow (huff), blue, board, boat, bone, book, both, bottom, box, break, bright, broad, brother, burn, buy, call, can, cat, catch, change, circle, climb, close, cloth, cloud, cold, color, come, cook, cool, corner, cost, cover, cow, cry, curve, cut, dark, day, death, deep, dig, divide, do, dog, door, draw, dream, drink, drive, drop, dry, duck, each, early, east, eat, edge, egg, eight, empty, end, every, eye, face, fall, family, far, fast, fat, feed, feel, field, find, fine, fire, fish, five, flow, flower, fly, foot, force, four, fresh, full, get, give, go, gold, good, grab, grass, half, hand, hang, hard, have, he, head, hear, heart, heat, heavy, high, hit, hold, hole, home, horn, horse, i, ice, iron, key, kill, lake, large, late, laugh, lay, learn, leave, left, leg, light (ray), like, line, listen, little, long, look, love, low, main, make, man, may, me, measure, meat, meet, middle, milk, mix, moon, more, mountain, mouth, much, near, neck, new, nine, north, not, nude, number, one, only, pain, paint, pair, pass, pick, piece, plait, play, point, poor, post, pour, power, press, pretty, pull, push, put, quick, rain, read, red, rich, ride, ring, river, road, rock, roll, room, root, rope, round, row, rub, run, rupture, sail, salt, sand, save, saw, say, sea, seize, sell, send, set, seven, sharp, she, sheet, shell, ship, shoe, shore, short, shoulder, side, sign, silver, sing, sit, six, skin, sky, sleep, slip, slow, small, smell, smoke, snow, soft, soon, sound, south, speak, spell, spin, spot, star, steam, steel, step, stick, still, stone, straight, stream, stretch, string, suck, sugar, summer, sweet, take, talk, tall, tear, tell, ten, that, thick, thin, thing, think, this, three, through, throw, tie, time, tire, tone, too, touch, tree, try, tube, turn, two, use, very, view, wake, wall, want, warm, wash, watch, water, wave, weak, well, white, who, will, wind, window, wing, word, write, year, yellow, yes, you.*

Для любого другого языка можно составить список слов, отражающий те же понятия. Их набор дает представление о том ядре языка, изучением которого мы занимаемся.

Наиболее важными для целей смыслопередачи являются корни слов (по крайней мере, в европейских языках и схожих с ними). Корни выделены тем, что осуществляют связь слов с образами-понятиями, поступающими через органы чувств, в то время как аффиксы и служебные слова — это внутренние объекты вербальной системы. Заметим, что в приведенном выше списке из 300 базовых, наиболее часто употребляемых английских слов,

не применяются приставки и сателлиты, такие как *propose*, *report*, *withdraw* или *set up*.

Слово (корень) может быть разбит на фонемы, описывающие произношение, и на основании частоты встречаемости фонем в разных анализируемых списках можно получить важные результаты [11, 12]. Однако, более пристальный анализ показывает, что для описания кодировки набора базовых понятий с помощью корней слов их полезно структурировать несколько иным образом.

### Строение корней слов индоевропейских языков

Разложение на отдельные фонемы отражает звучание слова, однако оно плохо описывает изменчивость слова. Так не очень ясно, какие фонемы нужно использовать в словах *С<sub>о</sub>БАКА* или *САПО<sub>г</sub>*. Во многих случаях возникают вопросы, одна это фонема или две, наиболее характерный пример — латинская *X*. Если же не придерживаться разбиения на единичные фонемы, то подавляющее число индоевропейских корней имеет однотипную структуру. Корень начинается комплексом согласных (или одной), в середине находится комплекс, включающий R, L, V, J в комбинации с гласными (или просто гласная, хотя она может и отсутствовать, например, в чешском языке), и заканчивается опять комплексом согласных. Центральный комплекс обладает повышенной лабильностью, легко изменяясь как внутри языка, так и при переходе к родственному языку: *M(oLo)K{o}* – *M(Le)Ч{ный}* – *M(Le)K{o}* (Pol) – *M(iL)K* (Eng). При этом R, L, V и J могут входить и в «гласные», и в «согласные» комплексы.

Иногда какой-либо компонент этой «троицы» может отсутствовать, например, в английских словах *go-* или *-eat*.

Все корни из базового списка, даже те, которые не следуют доминирующей схеме, могут быть разложены на такие элементы и вероятность их использования в корнях слов может быть определена. Результат для 13 языков (английский, голландский, немецкий, шведский, латышский, французский, итальянский, румынский, греческий, польский, чешский, русский и болгарский) показан на рис. 1 [13]. Обращает на себя внимание поразительное совпадение частот применения фонологических элементов в разных родственных языках, так, что на графиках трудно выделить кривые относящиеся к конкретному языку. Порядок символов свой для каждого языка и может служить компактной, стабильной характеристикой этого

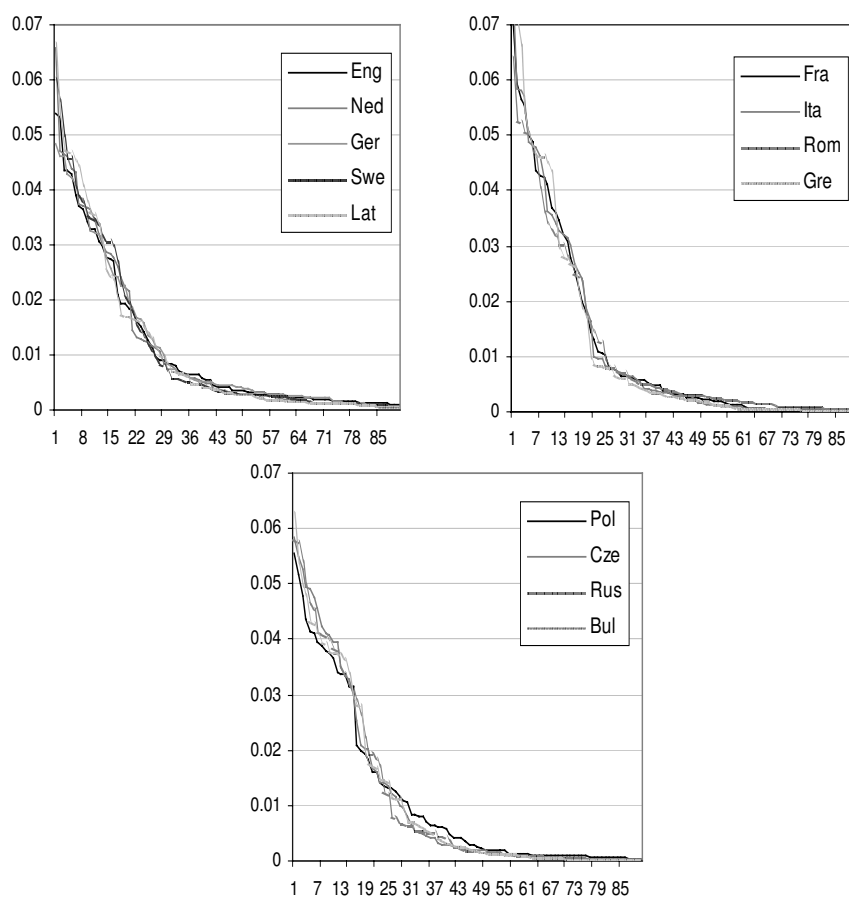


Рис. 1. Вероятность использования фонем и их комбинаций в списке корней слов, описывающих около 1000 основных понятий в разных языках. По горизонтальной оси указан ранг или номер символа в упорядоченном списке. Порядок фонем и их групп в этом списке свой для каждого языка, причем существуют фонемы характерные лишь для одного или нескольких языков. Первые 25 символов для русского языка таковы: К О Т П Е А Р С Л Д Б У В М Н Г И Ч Ст Ш З Х Ж Й Ы. Представлены три группы европейских языков, внутри которых наблюдается высокая степень совпадения данных, так что можно охарактеризовать их особенности.

языка. Фактически это естественный алфавит языка и создается впечатление, что известный нам порядок букв в греческом алфавите (содержащем и гласные, и согласные), лежащем в основе европейских алфавитов, и был в свое время естественным, то есть отражал частоту применения букв при написании основных слов языка. Порядок символов очень устойчив к изменению состава базового списка. Случайный выбор любых 500 слов из полного списка дает ту же последовательность, отклонения начинаются только тогда, когда список становится короче 300 слов. Такое аккуратное совпадение зависимостей для столь, казалось бы, нечеткой системы, каковой представляется человеческий язык, указывает на достаточно строгие математические закономерности, которые формируют лексикон языка. Можно поставить себе задачу установить, какие же причины лежат в основе этих строгих закономерностей.

### Пространство близости языков

Полученные весьма аккуратные результаты для групп европейских языков заставляют обратиться к вопросу о том, как количественно оценить близость разных языков между собой. Это необходимо для того, чтобы использовать данные разных языков для извлечения информации об устройстве кодирующей системы языка человека и выделения универсальных черт, не зависящих от конкретного национального языка. Эта задача рассматривается в исследованиях по глоттохронологии [14, 15], то есть в науке, изучающей процессы эволюции и расхождения языков. Обычно берется некоторый набор слов-понятий, чаще всего так называемый список Сводеша из 200 слов [14], и для любой пары языков определяется количество слов, общность которых узнаваема. Например, сходные (но далеко не тождественные) для большинства европейских языков: Рус — *сидеть*, Eng — *sit*, Ger — *sitzen*, Ned — *zitten*, Swe — *sitta*, Lat — *sēdēt*, Pol — *siedzieć*, Ita — *sedere*, Rom — *sedea*. Эти слова как бы сохранились, после того, как из общего праязыка возникли новые языки. Процент сохранившихся слов в списке считается мерой давности расхождения языков. На основании этих данных удается построить генеалогическое дерево языков [15].

Если применить такую же процедуру для нашего списка базовых слов, который почти в 10 раз больше списка Сводеша, можно существенно улучшить точность определения «взаимных расстояний» между родственными языками. Вот проценты общих слов для некоторых пар языков,

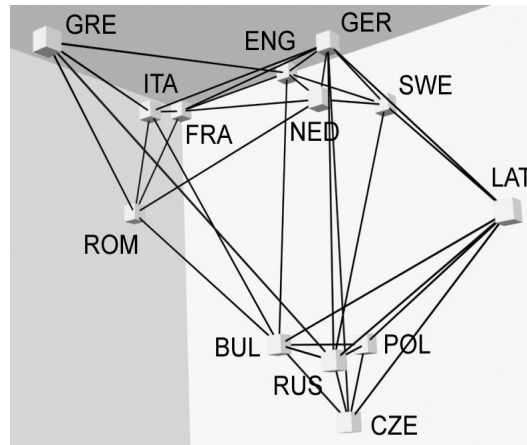


Рис. 2. Трехмерное представление пространства близости для 13 европейских языков. Длина каждой линии соединяющей пару языков пропорциональна логарифму процента общих слов в базовом списке, описывающем 1000 главных понятий. Размер кубика дает представление о точности определения расстояний.

полученные из анализа нашего списка: болгарский/русский 70%, польский/чешский 62%, русский/латышский 30%, латышский/шведский 21%, чешский/немецкий 14%, немецкий/голландский 69%, шведский/английский 47%, английский/французский 45%, французский/итальянский 71%, итальянский /румынский 54%, румынский /болгарский 22% [16]. В качестве меры расстояния между парой языков можно принять величину логарифма процента общих слов в базовом списке из примерно полутора тысяч слов. Если все слова совпадают, то расстояние равно нулю, а если нет общих слов, то языки бесконечно удалены друг от друга. Система взаимных расстояний оказывается самосогласованной и все рассмотренные нами европейские языки могут быть размещены в трехмерном пространстве

Сам факт того, что языки удается распределить в трехмерном пространстве, говорит о многом. Языки не только рассеяны по большим пространствам и головам говорящих на них людей, но могут помещаться и в одной голове полиглота. Эти люди могут часто и легко переходить с одного языка на другой, что требует какой-то перестройки в их мозгу. Похоже, что

для этого достаточно изменения всего трех, может слегка больше, нейронных параметров, определяющих положение конкретного языка в этом «пространстве близости». А уже сохранение общих базовых слов в этих языках является следствием их взаимного расположения в некотором пространстве, формирующем систему языка.

Мы постараемся применить согласованность родственных языков между собой для извлечения сведений об устройстве языка.

### Множество корней глаголов

Попробуем сузить круг рассматриваемых слов, для этого ограничимся только теми словами, которые описывают действия, то есть глаголами русского языка. Из них выделим те, которые обладают высокой стабильностью, то есть такие, которые имеют аналоги в родственных болгарском и польском языках. Эти языки «окружают» русский в пространстве близости, показанном на рис. 2. Различие направлений проявляется в том, что заметная часть корней у русского языка общая с болгарским языком, но не с польским, и наоборот. Оказывается, что общих корней глаголов около 400.

Набор стабильных глагол-образующих корней может быть разложен на начальные, срединные и конечные комплексы, обычно это просто согласная, гласная и опять согласная. Затем сосчитаем количество этих символов в базовых словах. Результат показан на рис. 3. Из вида графика напрашивается схема образования корней показанная на вставке.

Действительно, для наиболее часто встречающегося в первой позиции звука *П* имеются комбинации с наиболее часто применяемыми в конце корня *д*, *н*, отсутствие согласной (–), *т*: *ПАДать*, *ПИНаТЬ*, *ПИ-ть*, *ПЫТать*. В общем, комбинирование согласных в корнях следует этой «треугольной» идеализированной схеме, однако есть важное расхождение. Общее число стабильных корней около 400, а эта схема дает лишь около 200. Величины можно уравнять введением дополнительных «столбцов и строк», что даст большее число пересечений. В русском языке есть такие слова как *КОПать*, *КАПать*, *КУПить* и *КИПеть*, которые могут располагаться на пересечении двух столбцов *К* и двух строк *П*.

И после этой процедуры остаются еще ряд комбинаций отсутствующих и лишних внутри треугольника, а также имеются комбинации из «редких» согласных, располагающиеся вне треугольника.

Эти «дефекты» можно устранить или упорядочить, перемещая их на




Рис. 3. Общее число согласных в стабильных глагол-образующих корнях русского языка в первой и третьей позиции. Порядок первых 17 согласных показан на вставке. Начальные согласные — по горизонтали, согласные в третьей позиции — по вертикали. Серые кружки изображают набор возможных комбинаций дающих распределение соответствующее графику. Это идеализированная ситуация, о реальных комбинациях — в тексте.




Рис. 4. Колончатая система стабильных глагол-образующих корней русского языка. Колонки плотно заполняют пространство ограниченное системой линий, показаны лишь некоторые из слов. Полоски идущие справа налево соответствуют определенной согласной в начале корня, некоторые из них обозначены. Полоски идущие поперек соответствуют заключительным согласным корня.

границы треугольника путем перестановок строк и столбцов.


При этом треугольник (точнее фигура, в которую он превращается) деформируется, а столбцы и строки могут искривляться, сохраняя свою непрерывность. Образуется система скрещенных полос, пересечения которых соответствуют сочетаниям согласных, в корнях стабильных базовых глаголов. Множество корней глаголов может быть сведено в плотноупакованную систему колонок, как это показано на рис. 4 [17].

Оказывается, что начальные и конечные согласные являются хорошими систематизирующими факторами для множества корней и можно думать, что они наиболее важны при построении слов и, вероятно, для их распознавания. Важность согласных была продемонстрирована в экспериментах по чтению искаженного текста [18], обратите внимание на название статьи]. В старых текстах зачастую опускали гласные, без заметного ущерба для чтения. Это характерно и для арабского языка. Эксперименты по распознаванию речи, в которой отдельные фонемы маскировались шумом [19],

показали, что согласные играют главную роль для определения смысла произнесенного слова, тогда как гласные, в значительной степени, несут информацию, позволяющую идентифицировать говорящего и особенности произношения. Наблюдения за двумя пациентами с определенным типом афазии показали, что гласные и согласные по-разному представлены в мозге человека и существенно различные механизмы вовлечены в их обработку [20].

Вид и размер полученной сети корней глаголов (измеренный числом полос) наводит на мысль о связи множества корней с характерными структурами, обнаруженными в коре мозга при изучении зрительной системы обезьян [21], рис. 5. Заметим, что такие структуры выявляются только при функциональных тестах — просто так их не видно на внешне однородной поверхности коры. Обезьяне предъявляют некоторый зрительный стимул и при этом в зрительный нерв впрыскивают радиоактивное вещество, которое связывается лишь в областях коры, связанных с глазом, видящим стимул. Так проявляются чередующиеся полосы доминирования правого и левого глаза. Характерный шаг такой полосатой структуры 0,4 мм — он определяется диаметром колонок, состоящих из групп нейронов и эти «столбики», высотой около 2 мм, ориентированы перпендикулярно поверхности коры больших полушарий мозга. Цепочки колонок образуют полосы, которые плотно заполняют участок коры. Полный размер отдельной «полосатой области» в зрительной системе обезьяны-макака составляет 10–15 мм, то есть число полосок примерно тоже, что и для множества стабильных корней.

У человека и в другой области коры этот размер может быть несколько другим. Аналогичную, но более сложную структуру образуют полосы доминирования ориентации предъявляемого стимула. В качестве стимула обычно используются решетки из черных и белых полос (типа кода на ценнике товара в супермаркете) расположенные вертикально или наклоненные на 30, 60 и 90 градусов. В этом случае области доминирования накладываются друг на друга. Это как раз тот случай, что мы имеем для корней глаголов. Основой для такого «чередующегося» представительства в коре является характер прорастания аксонов от клеток-детекторов ориентации в высшие отделы зрительной коры, где они порождают упорядоченные полосатые узоры. Характер узоров определяется генетическими факторами. В случае человеческой речи детекторы, по-видимому, настроены на отдельные фонемы или группы фонем, они-то попеременно представлены в высших отделах коры.



(a)



(b)

Рис. 5. Полосатые структуры доминирования стимула в зрительной коре обезьяны (из книги *Hubel D. H. Eye, Brain, and Vision*). Светлые и темные полосы на фото **(a)** относятся к областям связанным с правым и левым глазом. Более сложные структуры на фото **(b)** образованы областями доминирования зрительных стимулов ориентированных вертикально и под углом в 30 градусов. Однородно темные области не связаны с доминированием тех или иных детекторов зрительных стимулов.

Придя к такому результату, попробуем расширить область анализа, распространив наш подход на другие языки и сняв ограничение, связанное со стабильностью глагольного корня. Для этого обратимся к английскому языку и выделим корни всех слов, применимых в качестве глаголов. В этом отношении английский язык отличается тем, что многие слова могут применяться в той же самой форме для разных частей речи: *a CUT, to CUT, CUT into pieces*.

Мы проанализировали большинство глаголов английского языка, а также немецкого, французского, итальянского и русского. В качестве исходного набора была взята дюжина наиболее важных и употребительных английских глаголов: *TAKE, GET, SET, GO, PUT, RUN, MAKE, MOVE, HOLD, COME, DO, TURN*. Затем с помощью электронных словарей [22] в полуавтоматическом режиме, они были переведены на дюжину европейских языков, а потом обратно на английский. Это дает существенно более длинный список. За пару шагов количество глаголов достигает 300, и может быть увеличено дальше. Таким образом был составлен список из примерно 2400 корней английских глаголов, и одновременно из 1300–1800 корней немецких, французских, итальянских и русских глаголов. Разница происходит из-за того, что в этих языках многие корни употребляются лишь для существительных, но не для глаголов. Полученный список практически исчерпывает глаголы, включенные в английский словарь, содержащий примерно 50 тысяч слов. Оказалось, что основная масса этих корней может быть сведена в плотноупакованную двумерную структуру, показанную на рис. 6. Такие же двумерные плотноупакованные структуры построены и для немецкого, французского и итальянского языков. Аналогичный вид имеет и множество корней всех русских глаголов, взятых из словаря морфем русского языка [23], согласующийся с картинкой, показанной на рис. 4. Похоже, что стабильные глаголы образуют как бы «скелет» этой системы. Интуитивно чувствуется, что глаголы всех из рассмотренных нами (около 20) европейских языков могут быть сведены в такую плотноупакованную двумерную систему, а скорее всего, это относится и ко всем человеческим языкам. Конкретное построение такой структуры может отличаться, например, для тоновых языков типа китайского, но двумерный характер, по нашему мнению, должен сохраниться. Не оставляет впечатление, что на рис. 6 изображен просто участок коры мозга, заполненный колонками нейронов. Одна колонка — один корень. Где-то рядом должна быть еще одна, предположительно двумерная, существенно меньшая по размеру область, содержащая приставки. Они играют важнейшую роль в процессе глаго-

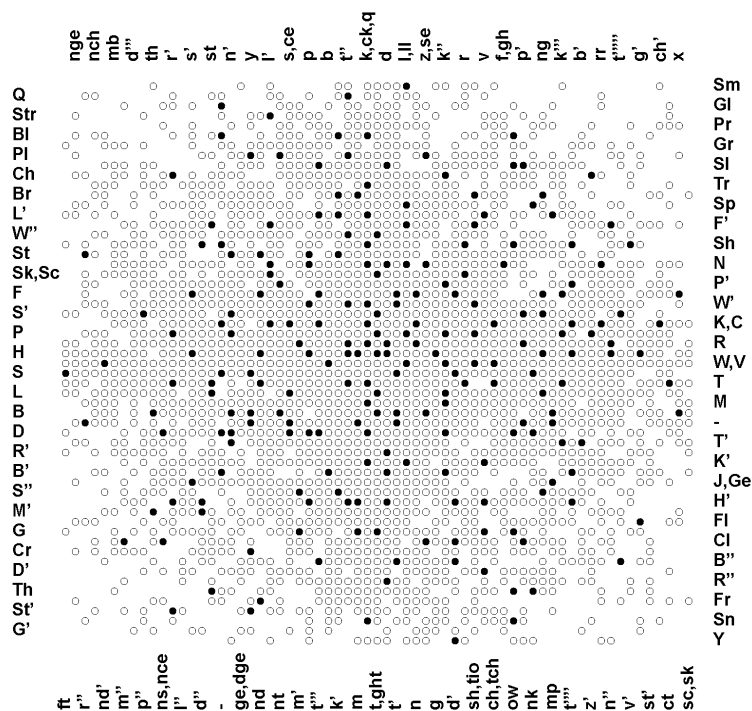


Рис. 6. Множество примерно 2400 английских глаголов и слов, употребляемых в качестве глаголов, представленных в виде точек на двумерной поверхности. Каждый глагол в горизонтальном ряду имеет одну и ту же согласную или комплекс согласных в начале корня. Они обозначены заглавными буквами справа и слева от системы точек. Правая колонка букв соответствует нечетным рядам точек, а левая колонка — четным рядам точек, то есть глаголам. Глаголы упорядочены по тому, как произносятся начальная и конечная согласные, а не как они пишутся. Все точки-глаголы в вертикальных рядах имеют одинаковые согласные или их комплексы в конце корня, они обозначены строчными буквами сверху и снизу попеременно, так же как и для горизонтальных рядов. Одна и та же согласная может соответствовать нескольким строкам или столбцам, например **T** и **T'**, а также от **t** до **t''''**. Отсутствие согласной в некоторой позиции обозначено дефисом (-). Точки, указанные черным цветом, относятся к глаголам, усваиваемым в раннем детстве, ребенком в возрасте примерно двух с половиной лет.

образования и словообразования вообще, по крайней мере, в европейских языках. Последовательная активация отдельных колонок в обеих этих областях должна приводить к восприятию или генерации образа, связанного с действием. Размер этих областей невелик, и даже небольшой инсульт иногда приводит к полному нарушению функции речи, хотя во всем остальном человек вполне нормален. Похоже, именно эта компактная область поражается при локальном нарушении мозгового кровообращения, оставляя в неприкосновенности те области, которые отвечают за смысл произносимых слов. Об этом пойдет речь ниже.

### Усвоение языка детьми

Любой язык может быть впервые усвоен лишь в раннем детском возрасте. Многочисленные случаи воспитания детей среди зверей (так называемые Маугли) говорят о том, что при возвращении в среду людей после некоторого возраста, такие дети почти неспособны научиться человеческому языку. Этот факт может быть сопоставлен со структурой показанной на рис. 6. На этом рисунке черными точками указаны корни глаголов применяемых детьми самого младшего возраста, около 30 месяцев от роду, то есть в самом начале усвоения материнского языка [24]. Видно, что они почти полностью используют пространство, которое в дальнейшем заполняется всеми остальными глаголами. Похоже на то, что в коре младенца уже имеется сформированная, генетически предопределенная область, предрасположенная к восприятию слов-глаголов, причем она заполняется в очень быстром темпе. Где-то к шести годам словарь практически полон. Если это время упустить, то «зарезервированная» область, вероятно, начнет использоваться для других целей, и усвоение языка становится почти невозможным. Подобное явление наблюдается у слепых от рождения, те области мозга, которые у зрячих заняты обработкой зрительной информации, у слепых задействованы для других целей.

Структура, показанная на рис. 6, указывает и на возможный механизм, лежащий в основе усвоения слов языка. У ребенка формируются детекторы согласных и гласных фонем, предположительно в слуховой области коры. Аксоны нейронов от этих детекторов прорастают в другую область коры, где конвергируют на определенных колонках, соответствующих корням, а часто это и есть слова. Детские слова «рассыпаны» по всей этой лексической области. В дальнейшем, терминалы аксонов от детекторов фонем пер-

вых и последних согласных разрастаются во взаимно-перпендикулярных направлениях, образуя пересечения, готовые к восприятию нового слова с такой комбинацией согласных. Подобным образом заполняется вся доступная область, имеющая полосатую (стриарную) структуру. «Полосатые» области в зрительной коре обезьян (рис. 5) имеют определенный, сравнительно небольшой размер, как и описанные здесь «лексические» области у человека. Число корней глаголов ограничено, тогда как другие объекты языка, в особенности имена и различные названия, практически неограничены по числу. Скорее всего, они хранятся в совсем другом месте и в другом виде, на что имеются разнообразные указания, имена, например, легко забываются. Хранение разных объектов языка в разных местах коры вполне согласуется с общими принципами устройства мозга, где имеются и первичная, и вторичная моторные области, и даже области более высоких порядков в разных модальностях.

### Пространство смысловой близости слов

Выше мы рассматривали звуковую форму слов в разных языках и показали, что можно сформулировать математические закономерности, описывающие лексикон. Однако слово имеет как бы две ипостаси — звучание и смысл. Можно надеяться, что и для смысловых отношений между словами удастся найти формальное описание. Для этого также можно воспользоваться достаточно большим набором словарей разных языков [22]. Словарные статьи для глаголов (и для других частей речи тоже) обычно содержат целый набор различных вариантов перевода, хотя в конкретном предложении всегда используется лишь один вариант. Фактически, в словарях мы имеем дело с «рейтинговой оценкой» различных вариантов переводов, проведенной составителями словаря на основании их встречаемости в речи или текстах. Оценки очень размытые и неоднозначные, очень и очень часто, например, русский перевод английского слова не содержит этого английского слова в качестве перевода в русско-английской части словаря. Мы имеем дело с очень нечетким (*fuzzy* — русский перевод *нечеткий*, *размытый*, но и *пушистый*) множеством. Однако это не означает, что нельзя провести достаточно строгий анализ содержимого словарей. При этом будем исходить из того, что, как и положено хорошим переводчикам, составители словарей хотели правильно отразить смысл слова при составлении данной словарной статьи. Для того, чтобы по возможности устранить влия-




Рис. 7. Трехмерное изображение «пространства близости» английских глаголов. Это лишь часть из заметно большего множества. Расстояние между любой парой глаголов пропорционально проценту общих переводов на другие языки в группе из 14 языков.

ние конкретной национальной культуры обратимся к достаточно большому числу словарей разных языков, хотя в силу технических причин придется ограничиться европейскими языками и европейской культурой.

На базе данных содержащихся в словарях можно обратиться к вопросу о формализации близости по смыслу разных слов, для начала глаголов. Рассмотрим два английских глагола *LINK* и *ATTACH*. Мы можем найти такие переводы на 13 европейских языков (голландский, немецкий, шведский, латышский, французский, итальянский, румынский, греческий, албанский, польский, чешский, русский и болгарский), которые составители сочли нужным включить в словари:

*LINK*: *соединявам, сцеплять, смыкать, ενώνω, zusammenkommen, wiązać, vincolare, verklammern, verketten, verflechten, verbinden, uni, schakelen, savienot, saldare, saķēdēt, raccorder, legare, länka ihop, koppeln, kojarzyć, înlănțui, förena, congiungere, bashkoj.*

*LINK/ATTACH: связывать, присоединять, привързвам, συνδέω, unire, saistīt, przyczepić, připojit, lier, lidhem, lega, knüpfen, dołączyć, attacher, anettere, aanslaan.*

*ATTACH: спечелвам, прикреплять, прикладывать, привлічам, назначать, задерживать, συνάπτω, κατάσχω, атроφώ, αποσπώ, získat, vë, vastmaken, vastklampen, saisir, pune, przytwierdzać, przyprawiać, přivázat, připevnit, prinde, přiložit, přilepit, pignorare, piestiprināt, piešķirt, pielikt, ngjis, knyta, joindre, hechten, foga, fixa, fissare, festmachen, fästa, binda, bilägga, bie, befestigen, attaccare, atribui, ataşa, arrêter; apporre, anschließen, anheften, agăţa, adăuga, aanplakken.*

Как видно, есть переводы, отнесенные только к какому-то одному из глаголов, и есть такие, которые, по мнению составителей, одновременно отражают смысл и того и другого. Число общих переводов может быть выбрано в качестве меры близости по смыслу для пары слов. Как и в случае определения меры расстояния между языками, описанном выше, в качестве меры расстояния между словами разумно взять логарифм процента общих переводов для пары слов, например, *LINK* и *ATTACH*. Если все переводы совпадают, то слова тождественны по смыслу, если ни один из языков не находит у себя слова, описывающего и то, и другое слово из рассматриваемой пары, значит эти слова практически бесконечно далеки по смыслу. Наши дальнейшие результаты показывают, что выбор 13 языков близок к минимальному. В этом случае можно устранить языковые вариации и достигнуть приемлемой точности построения пространства близости.

На рис. 7 показан участок пространства близости для 20 английских глаголов — для них достаточно трехмерного пространства [25]. Такие же картинки можно построить для других групп глаголов, близких по числу. Следует отметить, что это распределение не относится исключительно к английскому языку — он чисто технически был выбран в качестве исходного. Любой перевод этих английских слов на другой язык будет помещен в соответствующую точку этого пространства между английскими словами, которые считаются его переводом. Фактически, указанная область изображенного пространства плотно заполнена всеми возможными переводами на 13 выбранных европейских языков, и скорее всего, переводы на любой существующий человеческий язык будут располагаться здесь же. Все это множество слов формирует непрерывную структуру, свойства которой не зависят от конкретного языка. Это своего рода «пространство смысла»,

где можно наблюдать плавное изменение значений слов при движении в разных направлениях по этой структуре. Даже простой взгляд на рис. 7 показывает, что слова не рассыпаны во всех направлениях, а тяготеют к некоторой поверхности в трехмерном пространстве. Для небольших наборов слов даже можно показать, что они расположены на двумерной плоскости [26].

Дальнейшее увеличение числа глаголов и размера рассматриваемой области принятым нами способом становится слишком трудоемким, так как требуется вычислять много расстояний с помощью большого числа словарей и строить когерентную структуру, удовлетворяющую этому набору расстояний. Однако, уловив двумерный характер получаемого распределения, процедуру можно упростить и ускорить. Для глаголов из пары языков можно составить цепочки, демонстрирующие плавное изменение смысла. Например, для английского и русского можно составить такую последовательность: *вычесть* – *subtract* – *отнять* – *deprive* – *отобрать* – *select* – *выбрать* – *choose*. Иногда цепочки ветвятся. Внутри пары языков трудно составить когерентную структуру из таких цепочек, однако если число языков увеличить, появляются стабильные узоры достаточно большого размера. Оказывается, что совместный анализ всего четырех языков: английского, русского, немецкого и французского, позволяет свести в единую систему сотни и тысячи глаголов. Вероятно, так можно упорядочить все глаголы всех языков. Процедура выглядит следующим образом. Для некоторого исходного глагола, например, *собрать* на двумерной поверхности начинают строиться цепочки, путем определения ближайших соседей в других языках. Это будут *gather, collect, assemble* (Eng), *sammeln, lesen* (Ger), *ramasser, recueillir, accumuler* (Fra). Учитываются те переводы, которые будучи переведенными обратно, дают исходный глагол, в том числе перекрестно по языкам. Затем эти слова переводятся обратно на русский язык, что дает целый ряд глаголов отличных от *собрать*. В силу размытости смысловых взаимосвязей, от исходного глагола начинают в разные стороны расходиться не четкие линии, как характерно для математических графов, а размытые дендриты. Рис. 8 дает представление об их виде. Двумерной поверхности хватает, чтобы разместить разрастающуюся систему дендритов, сохраняя достаточно равномерной плотность заполнения пространства словами. Характерной особенностью является то, что эти дендриты могут не только ветвиться, но и через некоторое количество шагов сливаться. Образуется чрезвычайно характерная «сетевая» структура изображенная на рис. 9. Вид ее чрезвычайно «биологичен», а это всего лишь некоторый



Рис. 8. Распределение на двумерной поверхности близких по смыслу глаголов четырех языков: английского, немецкого, французского и русского. Близость определяется наличием перевода в словаре. На этом участке можно проследить плавное изменение значений глаголов вдоль определенных направлений.

способ представления данных, содержащихся в словарях разных языков. Причем от какого-либо конкретного языка эта структура не зависит — словарь этого языка может просто не использоваться при ее построении. Здесь наверняка речь идет о пространстве, формирующем смысловые взаимосвязи между словами как внутри языка, так и между словами разных языков. А вероятно, и слова здесь не при чем, скорее всего подобные структуры существуют и у многих животных, только они не имеют выхода на «озвучивающие» области типа показанной на рис. 6. Люди, имеющие собак не сомневаются что их питомцы имеют представления о понятиях обозначенных на рис. 9, а вот развитой «области озвучивания» у них, скорее всего, попросту нет, как нет зрения у летучих мышей.




Рис. 9. Дендритная структура, получаемая при расширении множества глаголов, показанного на рис. 8. Области обозначенные серым цветом заполнены примерно 2000 глаголов русского, английского, немецкого и французского языков. Точками показаны понятия и соответствующие им слова, входящие в лексикон ребенка в возрасте двух с половиной лет [27]. Объем полной структуры взрослого человека примерно в 10 раз больше показанной на рисунке части.

На этом рисунке точками обозначены те понятия и соответствующие им слова, которые используют дети в самом начале усвоения материн-

ского языка. Как и в случае «пространства звучания» (рис. 6) дети сразу используют все доступное «пространство смысла», которое впоследствии заполняется все новыми понятиями, но они размещаются в «промежутках оставленных детьми».

Интересно, что на коре больших полушарий можно обнаружить вероятный субстрат для «пространства смыслов». На рис. 5 помимо полосатых областей связанных с детекторами зрительной информации, мы видим и равномерно темные участки с дендритной структурой похожей на изображенную на рис. 9. Они, похоже, не связаны напрямую с детекторами и вполне могут использоваться для поддержки функций более высокого порядка, например, для кодировки понятий. Размер полной структуры широких темных полос много больше, чем окружаемые ими области доминирования правого или левого глаза. Если предположить, что именно эти темные полосы являются носителями «пространства понятий», становится понятной существенно большая устойчивость «смысловой» части языка к мозговым инсультам, в сравнении с полными нарушениями речи. Лишь малые области «пространства смыслов» могут быть затронуты небольшим инсультом, что и наблюдается в ряде клинических случаев. Обширные же поражения мозга с необходимостью затронут большой ряд областей, перемешанных с сетевым «пространством понятий», но выполняющих другие функции. Это сильно усложнит клиническую картину и выделение симптомов связанных с поражением именно смысловой части языка.

### Заключение

Проблема представления языка в мозгу человека привлекает большой интерес исследователей и для ее решения применяются наиболее совершенные и сложные методики, такие как многоканальная магнитоэнцефалография МEG или функциональная магниторезонансная визуализация fMRI [28, 29]. Их результаты пока смутно указывают на особенности осуществления функции языка в мозгу человека, но несомненно подход к этой проблеме с разных сторон должен привести к результату. Помимо расширения нашего знания о человеке, понимание того, как устроен человеческий язык, должно содействовать созданию технических устройств, обеспечивающих «дружественный» речевой контакт человека с компьютером. Мы полагаем, что настоящая работа продвигает нас в этом направлении.

### Литература

1. *Lippman R.P.* Speech recognition by machines and humans // *Speech Communication*. – 1997, **22**. – pp. 1–15.
2. *Jelinek F.* Continuous speech recognition by statistical methods // *Proc. IEEE*. – v. 64, pp. 532–536, Apr. 1976.
3. *Rabiner L.R.* A tutorial on hidden Markov models and selected applications in speech recognition // *Proc. IEEE*. – v. 77, No. 2, pp. 257–285, Feb. 1989.
4. *Dusan S., Rabiner L.R.* Can automatic speech recognition learn more from human speech perception? // In: *Trends in Speech Technology*, C. Burileanu (Ed.), Romanian Academic Publisher, pp. 21–36, 2005.
5. *Motter A. E., de Moura A. P. S., Lai Y.-C., Dasgupta G.* Topology of the conceptual network of language // *Phys. Rev.* – **E65**, 065102(R), 2002.
6. *Holanda A. de J., Pisa I. T., Kinouchi O., Martinez A. S., Ruiz E. E. S.* Thesaurus as a complex network // *Physica A*. – **344**, pp. 530–536, 2004.
7. *Sole R. V., Murtra B. C., Valverde S., Steels L.* Language Networks: their structure, function and evolution. – Working Paper № 05–12–042 of Santa Fe Institute, 2005.
8. *Zipf G.K.* Human behavior and the principle of least-effort. – Cambridge, MA: Addison-Wesley, 1949.
9. RichWin Electronic Dictionary, RichWin 97 for Windows Professional Version. Copyright 1997–1998, Alestron Inc.
10. Краткий русско-китайский словарь. – Москва: Государственное издательство иностранных и национальных словарей, 1957.
11. *Введенский В.Л., Коршаков А.В.* Естественно упорядоченный алфавит индоевропейских языков // *Нейроинформатика 2004*, VI Всероссийская научно-техническая конференция. Сборник научных трудов, часть 2. – с. 18–24.
12. *Vvedensky V.L., Korshakov A.V.* Visualization of the basic language thesaurus // Proc. VII International Conf. “*Cognitive Modelling in Linguistics*”, Varna 2004, pp. 308–313.
13. *Введенский В.Л.* Математические закономерности словообразования в европейских языках // *Нейроинформатика 2005*, VII Всероссийская научно-техническая конференция. Сборник научных трудов, 2005, часть 2. – с. 263–270.
14. *Бурлак С.А., Старостин С.А.* Введение в лингвистическую компаративистику. – М.: Эдиториал УРСС, 2001.
15. *Gray R.D., Atkinson Q.D.* Language-tree divergence times support the Anatolian theory of Indo-European origin // *Nature*. – **426**, pp. 435–438, (27 Nov. 2003).

16. *Vvedensky V.L.* Proximity space of the European languages // *Text Processing and Cognitive Technologies*. – v. 11, 2005, pp. 376–378.
17. *Введенский В. Л.* Сеть корней глаголов русского языка. *Нейроинформатика 2006 // Нейроинформатика 2006*, VIII Всероссийская научно-техническая конференция. Сборник научных трудов, 2006, часть 3. – с. 236–243.
18. *Grainger J., Whitney C.* Does the huamn mnid raed wrods as a wlohe? // *Trends in Cognitive Sciences*, 2004, v. 8. – pp. 58–59.
19. *Owren M.J., Cardillo G.C.* The relative roles of vowels and consonants in discriminating talker identity versus word meaning // *The Journal of the Acoustical Society of America*, March 2006, Volume 119, Issue 3, pp. 1727–1739.
20. *Caramazza A., Chalant D., Capasso R., Miceli G.* Separable processing of consonants and vowels // *Nature*. – **403**, pp. 428–430, (2000).
21. *Hubel D.H.* Eye, brain, and vision. – W.H. Freeman & Company, 1995.
22. Foreignword.com. The language site.  
URL: <http://www.foreignword.com>.
23. *Кузнецова А. И., Ефремова Т. Ф.* Словарь морфем русского языка. – М.: Русский язык, 1986.
24. *Dale P.S., Fenson L.* Lexical development norms for young children // *Behavioral Research Methods, Instruments, & Computers*, **28**, 1996, pp. 125–127.
25. *Vvedensky V.L.* Proximity space of verbs // *The Second Biennial Conference on Cognitive Science*. – St.-Petersburg, Vol. 1. – Abstracts pp. 177–178. 2006,
26. *Коршаков А. В.* Процедура построения пространства понятий как часть системы машинного перевода // *Нейроинформатика 2006*, VIII Всероссийская научно-техническая конференция, Сборник научных трудов, часть 3. – стр. 155–162.
27. Тест речевого и коммуникативного развития детей раннего возраста. – The MacArthur Communicative Development Inventory 1993. Адаптирован кафедрой детской речи РГПУ им. А. И. Герцена 2002.
28. *Pulvermuller F.* Brain reflections of words and their meaning // *Trends in Cognitive Science*. – v. 5, No. 12, 2001, pp. 517–524.
29. *Grossman M., Koenig Ph., DeVita Ch., Glosser G., Alsop D., Detre J., Gee J.* The neural basis for Category-Specific Knowledge: An fMRI Study // *Neuroimage*. – 15, pp. 936–948, 2002.

**Виктор Львович ВВЕДЕНСКИЙ**, кандидат физико-математических наук, старший научный сотрудник Института молекулярной физики Российского научного центра «Курчатовский институт». Область научных интересов в настоящее время — исследование основных принципов функционирования языка человека. Автор более 10 публикаций по этой тематике, общее число работ в разных областях физики — более 70.

---

НАУЧНАЯ СЕССИЯ МИФИ–2007

НЕЙРОИНФОРМАТИКА–2007

IX ВСЕРОССИЙСКАЯ  
НАУЧНО-ТЕХНИЧЕСКАЯ  
КОНФЕРЕНЦИЯ

ЛЕКЦИИ  
ПО НЕЙРОИНФОРМАТИКЕ  
Часть 2

Оригинал-макет подготовлен Ю. В. Тюменцевым  
с использованием издательского пакета L<sup>A</sup>T<sub>E</sub>X 2<sub>ε</sub>  
и набора PostScript–шрифтов PSCyr

Подписано в печать 11.11.2006 г. Формат 60 × 84 1/16  
Печ. л. 9,25. Тираж 190 экз. Заказ №

*Московский инженерно-физический институт  
(государственный университет)  
Типография МИФИ  
115409, Москва, Каширское шоссе, 31*