

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ
РОССИЙСКОЙ ФЕДЕРАЦИИ
ФЕДЕРАЛЬНОЕ АГЕНТСТВО ПО АТОМНОЙ ЭНЕРГИИ
РОССИЙСКАЯ АКАДЕМИЯ НАУК
РОССИЙСКАЯ АССОЦИАЦИЯ НЕЙРОИНФОРМАТИКИ
МОСКОВСКИЙ ИНЖЕНЕРНО-ФИЗИЧЕСКИЙ ИНСТИТУТ
(ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ)
НАУЧНО-ИССЛЕДОВАТЕЛЬСКИЙ ИНСТИТУТ
СИСТЕМНЫХ ИССЛЕДОВАНИЙ РАН

НАУЧНАЯ СЕССИЯ МИФИ–2008

НЕЙРОИНФОРМАТИКА–2008

**X ВСЕРОССИЙСКАЯ
НАУЧНО-ТЕХНИЧЕСКАЯ
КОНФЕРЕНЦИЯ**

**ЛЕКЦИИ
ПО НЕЙРОИНФОРМАТИКЕ**

Часть 2

По материалам Школы-семинара
«Современные проблемы нейроинформатики»

Москва 2008

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

НАУЧНАЯ СЕССИЯ МИФИ–2008. X ВСЕРОССИЙСКАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ «НЕЙРОИНФОРМАТИКА–2008»: ЛЕКЦИИ ПО НЕЙРОИНФОРМАТИКЕ. Часть 2. – М.: МИФИ, 2008. – 164 с.

В книге публикуются тексты лекций, прочитанных на Школе-семинаре «Современные проблемы нейроинформатики», проходившей 22–25 января 2008 года в МИФИ в рамках X Всероссийской конференции «Нейроинформатика–2008».

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

Ответственный редактор
Ю. В. Тюменцев, кандидат технических наук

ISBN 978–5–7262–0881–7

© *Московский инженерно-физический институт
(государственный университет), 2008*

Оригинал-макет подготовлен *Ю. В. Тюменцевым*
с использованием издательского пакета $\text{\LaTeX} 2_{\epsilon}$
и набора PostScript–шрифтов *PSCyr*

Подписано в печать 12.11.2007 г. Формат 60 × 84 1/16
Печ. л. 10, 25. Тираж 170 экз. Заказ № 491

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

Содержание

Предисловие	5
<i>Б. В. Крыжановский. О топологии потенциальной поверхности и вероятностях обнаружения локальных минимумов в задачах бинарной оптимизации</i>	12
Введение	13
Обобщенная модель Хопфилда	15
Размер области притяжения	16
Объем памяти обобщенной модели	18
Энергия локального минимума	20
Вероятность обнаружения минимума	22
Форма локального минимума	25
Итерационный алгоритм	28
Обсуждение результатов	30
Литература	34
<i>Я. Б. Казанович. Сегментация изображений с помощью динамических нейронных сетей</i>	37
Введение. Теория временной корреляции	38
Сегментация контурных изображений	43
Модель Ли	44
Модель Чое-Миккулайнена	46
Модель Ю-Жанга	52
Обсуждение	53
Сегментация пиксельных изображений	54
Параллельные процедуры. Модель Опара-Вергеттера	54
Последовательные процедуры. Модели типа LEGION	58
Обсуждение	65
Сегментация и кластеризация	67
Модель Роума-Фригуи	68
 УДК 001(06)+004.032.26 (06) Нейронные сети	 3

Модель Жао-Макау	72
Модель Буманна-Ланге-Рамахера	74
Обсуждение	78
Сегментация и когнитивные функции мозга	78
Сегментация и память	79
Сегментация и внимание	84
Обсуждение	88
Заключение	89
Литература	91

Ю. И. Нечаев. Нейронечеткая система поддержки принятия решений при оценке поведения сложного динамического объекта	97
Введение	98
Стратегии и методы управления	99
Архитектура и принципы функционирования системы	101
Динамическая база знаний	108
Математические модели динамики судна при движении во льдах	113
Контроль скорости судна	113
Контроль прочности судна	115
Алгоритмы функционирования системы в рамках принципа конкуренции	117
Алгоритм на основе стандартной модели	118
Нечеткая модель	125
Нейросетевая модель	131
Результаты моделирования динамики взаимодействия судна с ледовым полем	133
Результаты моделирования на основе традиционной модели	133
Результаты моделирования на основе нечеткой системы	136
Результаты моделирования на основе нейронной сети	138
Нейросетевое моделирование напряженного состояния элементов судового перекрытия	138
Функционирование системы при различных режимах движения	145
Интерфейс оператора	150
Оценка риска принимаемых решений	156
Заключение	159
Литература	160

ПРЕДИСЛОВИЕ

1. В этой книге содержатся тексты ряда лекций, прочитанных на Восьмой Школе-семинаре «Современные проблемы нейроинформатики», проходившей 22–25 января 2008 года в МИФИ в рамках X Всероссийской научно-технической конференции «Нейроинформатика–2008», а также текст одной из лекций (А. А. Фролов, В. Ю. Рощин), представленной на Седьмой Школе-семинаре, и не вошедшей по техническим причинам в состав сборников [10, 11] (она включена в Часть 1).

При отборе и подготовке материалов для лекций авторы и редактор следовали принципам и подходам, сложившимся при проведении семи предыдущих Школ (см. [1–11]). 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 четырех лекций из программы Восьмой Школы-семинара, а также упомянутая выше лекция А. А. Фролова и В. Ю. Рощина из программы Седьмой Школы:

1. В. Л. Дунин-Барковский. О международной инициативе «Десятилетие разума (Decade of the Mind)».
2. К. Кавамура, С. Б. Парин, С. А. Полевая, В. Г. Яхно. Возможность построения симуляторов осознания сенсорных сигналов: Иерархия «распознающих ячеек», нейроархитектура, психофизические данные.
3. А. Ю. Хренников. Психо-роботы.
4. А. А. Фролов, В. Ю. Рощин. Что такое интерфейс мозг-компьютер.
5. С. А. Терехов. Случайные гауссовские процессы в задачах аппроксимации данных.

3. В Части 2 опубликованы еще три доклада из программы Восьмой Школы-семинара:

1. *Б. В. Крыжановский*. О топологии потенциальной поверхности и вероятностях обнаружения локальных минимумов в задачах бинарной оптимизации.
2. *Я. Б. Казанович*. Сегментация изображений с помощью динамических нейронных сетей.
3. *Ю. И. Нечаев*. Нейронечеткая система поддержки принятия решений при оценке поведения сложного динамического объекта.

4. Лекция **В. Л. Дунина-Барковского** «О международной инициативе «Десятилетие разума (Decade of the Mind)» ставит своей целью ознакомить членов российского нейросетевого сообщества с последними инициативами в области понимания механизмов мозга. Речь идет об инициативе «Десятилетие разума», даются краткие сведения об авторах декларации, обсуждаются проблемы, охватываемые инициативой.

5. В лекции **К. Кавамур, С. Б. Парина, С. А. Полевой, В. Г. Яхно** «Возможность построения симуляторов осознания сенсорных сигналов: Иерархия “распознающих ячеек”, нейроархитектура, психофизические данные» рассмотрены варианты базовых моделей нейроноподобных систем для описания динамических процессов обработки сенсорных сигналов. Проведено сопоставление с данными о нейроархитектуре мозга. Рассмотрены некоторые основные динамические процессы в модельных нейроноподобных системах и проведено сопоставление с экспериментальными нейрофизическими данными осознания внешних стимулов и внутренних состояний человека.

6. В лекции **А. Ю. Хренникова** «Психо-роботы» предпринимается попытка геометризации психологии, осуществляемая путем представления ментальных состояний («идей») точками некоторого метрического пространства, именуемого ментальным пространством. Эволюция идей описывается динамическими системами в метрическом ментальном пространстве. Подход, основанный на использовании понятия ментального пространства, применяется для моделирования потоков бессознательной и сознательной информации в человеческом мозге. Строится последовательность моделей, с помощью которых рассматриваются когнитивные системы с нарастающей сложностью психологического поведения, определяемого структурой потоков идей. Поскольку предлагаемые модели фактически относятся к классу моделей искусственного интеллекта (ИИ), они могут быть использованы для создания ИИ-систем, называемых в данной работе

психо-роботами, в которых проявляются важные элементы человеческой психики.

7. Лекция **А. А. Фролов, В. Ю. Рощин** «Что такое интерфейс мозг-компьютер» посвящена рассмотрению и анализу имеющихся данных по проблеме создания и испытания интерфейсов мозг-компьютер (ИМК). ИМК являются новой системой коммуникации человека с машиной, основанной на непосредственном преобразовании намерений человека, отраженных в регистрируемых сигналах мозга, в управляющие команды. С точки зрения потенциально достижимых уровней информационной производительности для разработки ИМК изучаются три основные парадигмы: неинвазивный ИМК, основанный на распознавании ментальных состояний, вызванных воображаемым выполнением движений; неинвазивный ИМК, использующий принцип непрерывного управления; инвазивный ИМК, основанный на двусторонней связи мозг-компьютер посредством имплантируемых электродов и позволяющий полностью инкорпорировать внешние технические устройства во внутреннюю нейронную модель схемы тела и, соответственно, оперировать с ними так же, как и с естественными исполнительными органами.

8. Тематика лекции **С. А. Терехова** «Случайные гауссовские процессы в задачах аппроксимации данных» связана с актуальной задачей аппроксимации данных. Особое внимание уделено гауссовским процессам, моделирующим условную плотность вероятности. Методы описания данных гауссовскими процессами позволяют надежно оценивать неопределенность (риск) прогноза на новых данных. Основное внимание уделено методам приближения данных гауссовскими процессами и тесно связанным с ними оценкам величины риска прогноза, определяемого такими приближениями. Алгоритмы ориентированы на коллекции данных малых и средних размеров (до 10000 примеров) и могут эффективно применяться при планировании экспериментов.

9. В лекции **Б. В. Крыжановского** «О топологии потенциальной поверхности и вероятностях обнаружения локальных минимумов в задачах бинарной оптимизации» обсуждается проблема бинарной оптимизации. На основе анализа обобщенной модели Хопфилда получены выражения, устанавливающие связь между глубиной локального минимума и шириной области притяжения, которую можно выразить в виде «глубже минимум – шире область притяжения – больше вероятность обнаружения в процессе случайного поиска». На основании этого, вероятность нахождения локаль-

ного минимума при случайной инициализации нейронной сети удалось представить как функцию глубины этого минимума. В практических оптимизационных приложениях наличие таких выражений позволит по ряду уже найденных минимумов оценить вероятность нахождения более глубокого минимума и принять решение на остановку программы поиска или ее продолжение.

10. Лекция **Я. Б. Казановича** «Сегментация изображений с помощью динамических нейронных сетей» посвящена рассмотрению различных подходов к построению моделей сегментации изображений на основе использования динамических процессов, колебаний и синхронизации нейронной активности. Приводятся нейробиологические основы моделей, описываются принципы функционирования моделей и результаты их применения. Обсуждаются сравнительные качества моделей и перспективы их улучшения.

11. В лекции **Ю. И. Нечаева** «Нейронечеткая система поддержки принятия решений при оценке поведения сложного динамического объекта» Обсуждается проблема нейронечеткого моделирования при разработке бортовой интеллектуальной системы (ИС) реального времени. В качестве практического приложения рассмотрены особенности взаимодействия судна с ледовым полем различной интенсивности. Определены принципы использования нейронечетких технологий в задачах повышения надежности функционирования ИС. Представлены результаты моделирования динамики взаимодействия на базе различных вычислительных технологий.

* * *

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 [12] в списке литературы в конце предисловия). Эта библиотека, созданная и развиваемая отделением фирмы NEC в США, содержит уже более 900 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 [13], поисковый сервис Google Scholar [14], а также портал научных вычислений [15].

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 [1–11].

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

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

Литература

1. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // III Всероссийская научно-техническая конференция «Нейроинформатика-2001», 23–26 января 2001 г. / Отв. ред. Ю. В. Тюменцев. – М.: Изд-во МИФИ, 2001. – 212 с.
2. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // IV Всероссийская научно-техническая конференция «Нейроинформатика-2002», 23–25 января 2002 г. / Отв. ред. Ю. В. Тюменцев. Часть 1. – М.: Изд-во МИФИ, 2002. – 164 с.

3. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // IV Всероссийская научно-техническая конференция «Нейроинформатика-2002», 23–25 января 2002 г. / Отв. ред. *Ю. В. Тюменцев*. Часть 2. – М.: Изд-во МИФИ, 2002. – 172 с.
4. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // V Всероссийская научно-техническая конференция «Нейроинформатика-2003», 29–31 января 2003 г. / Отв. ред. *Ю. В. Тюменцев*. Часть 1. – М.: Изд-во МИФИ, 2003. – 188 с.
5. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // V Всероссийская научно-техническая конференция «Нейроинформатика-2003», 29–31 января 2003 г. / Отв. ред. *Ю. В. Тюменцев*. Часть 2. – М.: Изд-во МИФИ, 2003. – 180 с.
6. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // VI Всероссийская научно-техническая конференция «Нейроинформатика-2004», 28–30 января 2004 г. / Отв. ред. *Ю. В. Тюменцев*. Часть 1. – М.: Изд-во МИФИ, 2004. – 200 с.
7. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // VI Всероссийская научно-техническая конференция «Нейроинформатика-2004», 28–30 января 2004 г. / Отв. ред. *Ю. В. Тюменцев*. Часть 2. – М.: Изд-во МИФИ, 2004. – 200 с.
8. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // VII Всероссийская научно-техническая конференция «Нейроинформатика-2005», 26–28 января 2005 г. / Отв. ред. *Ю. В. Тюменцев*. – М.: Изд-во МИФИ, 2005. – 216 с.
9. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // VIII Всероссийская научно-техническая конференция «Нейроинформатика-2006», 24–27 января 2006 г. / Отв. ред. *Ю. В. Тюменцев*. – М.: Изд-во МИФИ, 2006. – 244 с.
10. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // IX Всероссийская научно-техническая конференция «Нейроинформатика-2007», 24–26 января 2007 г. / Отв. ред. *Ю. В. Тюменцев*. Часть 1. – М.: Изд-во МИФИ, 2007. – 180 с.
11. Лекции по нейроинформатике: По материалам Школы-семинара «Современные проблемы нейроинформатики» // IX Всероссийская научно-техническая конференция «Нейроинформатика-2007», 24–26 января 2007 г. / Отв. ред. *Ю. В. Тюменцев*. Часть 2. – М.: Изд-во МИФИ, 2007. – 148 с.
12. NEC Research Institute CiteSeer (also known as ResearchIndex) – Scientific Literature Digital Library.
URL: <http://citeseer.ist.psu.edu/cs>

13. The Archive arXiv.org e-Print archive — Physics, Mathematics, Nonlinear Sciences, Computer Science.
URL: <http://arxiv.org/>
14. Google Scholar.
URL: <http://scholar.google.com/>
15. 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

Б. В. КРЫЖАНОВСКИЙ
НИИ системных исследований РАН,
Москва
E-mail: kryzhanov@mail.ru

**О ТОПОЛОГИИ ПОТЕНЦИАЛЬНОЙ ПОВЕРХНОСТИ И
ВЕРоятНОСТЯХ ОБНАРУЖЕНИЯ ЛОКАЛЬНЫХ МИНИМУМОВ
В ЗАДАЧАХ БИНАРНОЙ ОПТИМИЗАЦИИ**

Аннотация

Обсуждается проблема бинарной оптимизации. На основе анализа обобщенной модели Хопфилда получены выражения, устанавливающие связь между глубиной локального минимума и шириной области притяжения, которую можно выразить в виде «глубже минимум – шире область притяжения – больше вероятность обнаружения в процессе случайного поиска». На основании этого, вероятность нахождения локального минимума при случайной инициализации нейронной сети удалось представить как функцию глубины этого минимума. В практических оптимизационных приложениях наличие таких выражений позволит по ряду уже найденных минимумов оценить вероятность нахождения более глубокого минимума и принять решение на остановку программы поиска или ее продолжение. Кроме того, описан итерационный алгоритм, позволяющий представить любую наперед заданную симметричную матрицу в виде взвешенного хеббовского разложения по внешним произведениям конфигурационных векторов. Возможность такого представления говорит о том, что все аналитические выводы, касающиеся ассоциативных нейросетей и оптимизационных алгоритмов, базирующихся на хеббовских матрицах, в равной степени применимы и для любого иного типа матриц. Развитая теория находится в хорошем согласии с результатами эксперимента.

B. V. KRYZHANOVSKY
Institute of Systems Analysis, RAS,
Moscow

E-mail: kryzhanov@mail.ru

**ABOUT POTENTIAL SURFACE TOPOLOGY AND RECOGNITION
PROBABILITIES FOR LOCAL MINIMA IN BINARY OPTIMIZATION
PROBLEMS**

Abstract

A binary optimization problem is discussed in the Lecture. Some expressions are derived basing on the Hopfield model to state an important relationship between a depth of local minimum and a width of attraction region. This relationship can be formulated as “deeper minimum – wider attraction region – greater detection probability during a random search process”. It has turned out to express the detection probability for local minimum as a function of the minimum depth for random initialization of a neural network. Such kind of expressions allow to evaluate the detection probability for deeper minimum in real-world applied optimization problems using a sequence of previous obtained minima in the searching process as well as to decide about shutdown or continuation of the search. An appropriate iteration algorithm is also suggested which makes it possible to represent any prescribed symmetric matrix as a weighted Hebbian expansion by external products of configuration vectors. An existence of this representation indicates that all the analytical conclusions related to associative neural networks and optimization algorithms based on the Hebbian matrices are equally applicable to any kind of matrices. Theoretical results obtained in the Lecture match well with experimental data.

Введение

Обычно нейронная система ассоциативной памяти рассматривается как система, решающая задачи распознавания или восстановления образов. Однако, ее можно рассматривать и как систему, решающую оптимизационную задачу – нейронная сеть в процессе релаксации находит конфигурацию, соответствующую минимуму энергии [1]. Это свойство нейронной сети можно использовать для решения различных NP -полных задач. Стандартный

подход сводится к нахождению такой архитектуры и параметров нейронной сети, при которых ценовая (целевая) функция совпадает с понятием нейросетевой энергии. Успешное применение нейронной сети к задаче коммивояжера [2], инициировало широкие исследования нейросетевых подходов к решению задач теории графов [3], нейросетевой оптимизации обработки изображений [4] и большому ряду других приложений. Эта область теории нейронных сетей активно развивается по настоящее время (см. работы [5–15] и ссылки в них).

Исследования в указанной области объединяет одно — сердцевиной подавляющего большинства нейросетевых оптимизационных алгоритмов является модель Хопфилда [1], а сам процесс оптимизации так или иначе сводится к нахождению в N -мерном конфигурационном пространстве глобального минимума некоего квадратичного функционала (энергии), построенного на заданной $N \times N$ - матрице. Стандартный нейросетевой подход к решению указанной задачи сводится к процедуре случайного поиска оптимального решения: на первом этапе этой процедуры нейронная сеть случайным образом инициализируется, на втором этапе — нейронная сеть релаксирует в одно из возможных стабильных состояний, т. е. оптимизирует величину энергии. Поскольку искомым результатом неизвестен и поиск проводится «вслепую», то нейросеть инициализируется раз за разом, с тем, чтобы найти как можно более глубокий минимум энергии. Несмотря на относительно успешное применение [2] этого подхода, всегда остается открытым вопрос — сколько таких случайных попыток следует сделать и когда проведенный поиск можно считать удачным (исходя из соотношения «затраченное время/полученный результат»). Сказанное справедливо как при спиновой [1–13], так и доменной [14,15] динамиках релаксации.

В работах [16–18] исследовались свойства энергетической поверхности и получены выражения, устанавливающие связь между глубиной локального минимума энергии и шириной области притяжения. На основании этого, вероятность нахождения локального минимума при случайной инициализации нейронной сети удалось представить как функцию глубины этого минимума. Полученные выражения можно сформулировать следующим образом: чем глубже локальный минимум, тем больше радиус его области притяжения и, следовательно, тем больше вероятность его обнаружения в процессе случайного поиска. Это означает, что наиболее глубокий минимум находится с наибольшей вероятностью. В практических приложениях наличие таких выражений позволит по ряду уже найденных минимумов оценить вероятность нахождения более глубокого минимума

и принять решение на остановку программы поиска или ее продолжение. Указанные выше результаты получены на основе анализа обобщенной модели Хопфилда — нейронной сети с хеббовской [26] (корреляционной) матрицей межсвязей. Для такого типа матриц получено прекрасное совпадение теории с экспериментом.

К сожалению, глубокий и последовательный анализ как свойств нейросети, так и возможности применения нейросети для оптимизационных целей, возможен только в случае, когда матрица связей нейронной сети построена по правилу Хебба или, хотя бы по предложенному в [16] обобщенному правилу Хебба. В связи с этим встает вопрос о применимости развитой теории нейросетей, в том числе и обсуждаемых здесь результатов работ [16–18], к случаю, когда матрица синаптических связей задана в произвольном (нехеббовском) виде. Для ответа на этот вопрос в настоящей работе описана нейросетевая итерационная процедура [19–21], позволяющая с заданной точностью представить любую наперед заданную симметричную $N \times N$ -матрицу в виде взвешенного хеббовского разложения по конфигурационным векторам. Тем самым доказывается, что все аналитические выводы, касающиеся нейросетей с обобщенными хеббовскими матрицами и оптимизационных алгоритмов, в равной степени применимы и для любого иного типа матриц. Множественные эксперименты со случайными матрицами, подтверждают развитую в [16–18] теорию.

Обобщенная модель Хопфилда

Рассмотрим модель Хопфилда. В теории нейронных сетей ее принято описывать как одномерную систему из N спинов-нейронов, которые могут ориентироваться вдоль, либо против заданной оси. Состояние такой нейронной сети характеризуется конфигурационным вектором $\mathbf{S} = (s_1, s_2, \dots, s_N)$, где $s_i = \pm 1$, $i \in (1, N)$. Здесь мы будем рассматривать обобщенную модель, архитектура которой задается матрицей межсвязей

$$T_{ij} = \sum_{m=1}^M r_m s_{mi} s_{mj} \quad (1)$$

с нулевой диагональю ($T_{ij} = 0$), организованной по правилу Хебба на M образах — N -мерных бинарных векторах $\mathbf{S}_m = (s_{m1}, s_{m2}, \dots, s_{mN})$. Обобщение состоит в том, что каждый образ \mathbf{S}_m добавляется в матрицу

T_{ij} со своим статвесом r_m . Для упрощения выражений принята нормировка статвесов $\sum r_m^2 = 1$ не нарушающая общности рассмотрения. Это незначительное видоизменение модели оказывается весьма существенным, поскольку, в отличие от стандартной модели, позволяет описывать нейронную сеть с невырожденным спектром минимумов.

Энергия нейросети описывается выражением

$$E = - \sum_{i,j=1}^N s_i T_{ij} s_j, \quad (2)$$

а ее динамика заключается в следующем. Задается начальное состояние сети \mathbf{S} (начальные направления спинов устанавливаются в соответствии со знаками компонент вектора \mathbf{S}). Затем, вычисляется локальное поле $h_i = -\partial E / \partial s_i$, действующее на произвольно выбранный i -й спин со стороны всех остальных спинов системы в момент времени t и определяется энергия спина в этом поле $\varepsilon_i = -s_i h_i$. Если направление спина совпадает с направлением локального поля ($\varepsilon_i < 0$), то его положение энергетически устойчиво и в последующий момент времени состояние спина остается неизменным. В противном случае ($\varepsilon_i > 0$) положение спина неустойчиво и он разворачивается вдоль направления этого поля, переходя в состояние $s_i(t+1) = -s_i(t)$ с энергией $\varepsilon_i(t+1) < 0$. Такая процедура последовательно применяется ко всем спинам нейронной сети. При каждом перевороте спина энергия сети понижается. Это означает, что сеть за конечное число шагов перейдет в стабильное состояние, соответствующее локальному минимуму энергии.

Размер области притяжения

Исследуем при каких условиях присутствующий в матрице (1) образ \mathbf{S}_m будет являться неподвижной точкой [1], в которой энергия сети E достигает своего (локального) минимума E_m . Для получения корректных оценок рассмотрение проведем в асимптотическом пределе $N \rightarrow \infty$. Определим область притяжения образа \mathbf{S}_m как совокупность точек N -мерного пространства, из которых нейронная сеть релаксирует в конфигурацию \mathbf{S}_m и попробуем оценить размер этой области. Пусть начальное состояние сети \mathbf{S} находится в некоторой окрестности образа \mathbf{S}_m . Тогда вероятность того,

что сеть сойдется к точке S_m , опишется выражением:

$$\text{Pr} = 2^{-N}(1 + \text{erf}z)^N. \quad (3)$$

Здесь $\text{erf}z$ — функция ошибок переменной z :

$$z = r_m \frac{\sqrt{N}}{\sqrt{2(1 - r_m^2)}} \left(1 - \frac{2n}{N}\right), \quad (4)$$

где n — хеммингово расстояние между S_m и S . Выражение (3) можно получить методами теоретико-вероятностного подхода, повторив хорошо известные для случая $r_m = 1/\sqrt{M}$, $\forall m \in (1, M)$ выкладки [22].

Из (3) следует, что область притяжения определяется как совокупность близких к S_m точек конфигурационного пространства, для которых справедливо соотношение $n \leq n_m$:

$$n_m = \frac{N}{2} \left(1 - \frac{r_0}{r_m} \sqrt{1 - r_m^2}\right), \quad (5)$$

где

$$r_0 = \sqrt{\frac{2 \ln N}{N}}. \quad (6)$$

Действительно, при $n \leq n_m$ вероятность схождения в точку S_m с ростом N асимптотически стремится к единице; в противном случае ($n > n_m$) имеем $\text{Pr} \rightarrow 0$. Это означает, что величину можно рассматривать как радиус области притяжения локального минимума E_m .

Из (5) следует, что при $r_m \rightarrow r_0$ радиус области притяжения стремится к нулю (рис. 1). Это означает, что образы, прописанные в матрицу межсвязи (1) с статвесом, меньшим r_0 , попросту не образуют локальных минимумов. Локальные минимумы имеются только в точках S_m , образы которых прописаны в матрице межсвязей с относительно большими статвесами $r_m > r_0$. Более того, если статвес одного из образов, например образа S_1 , сделать значительно больше чем у остальных ($r_1 \rightarrow 1$), то область его притяжения ($n_1 \sim N/2$) охватит половину всего N -мерного пространства (остальное полупространство занимает область притяжения его негатива $S_1^* = -S_1$). При этом, сеть будет иметь всего лишь два локальных минимума в точках S_1 и S_1^* , остальные локальные минимумы исчезнут. Этот предельный случай не представляет практического интереса для оптимизационных задач и ниже мы его рассматривать не будем.




Рис. 1. Характерный вид зависимости ширины области притяжения от статвеса образа. Локальный минимум существует только для образов, статвес которых в матрице межсвязей больше r_0 . При $r_m \rightarrow r_0$ размер области притяжения стремится к нулю, т. е. образы со статвесом $r_m < r_0$ не создают локальных минимумов.

Объем памяти обобщенной модели

Из проведенного выше анализа следует, что не все из прописанных в матрице межсвязей образов образуют локальные минимумы и могут распознаваться нейронной сетью. В связи с этим следует дать четкое определение понятия объема нейросетевой памяти \bar{M} . Определим его (объем памяти) как число тех образов, которые образуют локальные минимумы и, следовательно, могут быть восстановлены нейронной сетью без ошибок (абсолютная память согласно определению, введенному в [23,25]).

Очевидно, что объем памяти зависит от того, как сформирована матрица межсвязей и, в частности, от распределения статвесов. Рассмотрим, например, случай, когда статвеса образов случайны и равномерно распределены на отрезке $r_m^2 \in [0, 2/M]$ со средним $\bar{r}_m^2 = 1/M$. В этом случае, вероятность того, что статвес образа удовлетворяет условию $r_m > r_0$, равна

величине $1 - Mr_0^2/2$. Соответственно, объем памяти модели определится выражением:

$$\bar{M} = M \left(1 - \frac{Mr_0^2}{2} \right). \quad (7a)$$

Зависимость объема памяти от числа прописанных в матрице межсвязей образов M , представлена на рис. 2. Как видим, максимальный объем памяти $\bar{M} = N/4 \ln N$ достигается при числе образов $M = N/2 \ln N$. При $M \geq N/\ln N$ объем памяти сети обращается в ноль — нет ни одного образа, образующего локальный минимум.




Рис. 2. Зависимость числа устойчивых точек от числа образов M при разных распределениях статвесов: **a** — распределение статвесов (7a); **b** — распределение (7b); **c** — стандартная модель Хопфилда. Все величины нормированы на величину объема памяти $M_H = N/2 \ln N$ стандартной модели Хопфилда.

В случае, когда статвеса образов случайны и равномерно распределены на отрезке $r_m \in [0, \sqrt{3/M}]$ со средним $\bar{r}_m^2 = 1/M$, зависимость объема памяти от числа образов M определяется следующим выражением:

$$\bar{M} = M \left(1 - r_0 \sqrt{\frac{M}{3}} \right). \quad (7b)$$

Максимальный объем памяти $\overline{M} = 2N/9 \ln N$ в этом случае достигается при числе образов $M = 2N/3 \ln N$, а при $M \geq 3N/2 \ln N$ объем памяти сети обращается в ноль.

В другом предельном случае, когда все статвесы равны друг другу ($r_m = 1/\sqrt{M}$), условие существования локальных минимумов $r_m > r_0$ преобразуется в известное [5] ограничение $M < N/2 \ln N$ на емкость памяти стандартной модели Хопфилда. В этом случае понятие «емкость памяти» совпадает с числом образов M , поскольку либо распознаются все прописанные в матрице межсвязей образы, либо не распознается ни один из них. Соответственно, максимальный объем памяти определяется выражением $\overline{M} = N/2 \ln N$.

В заключение этого раздела отметим, что удаление из матрицы межсвязей образов, прописанных в матрице межсвязей с статвесами, меньшими критического значения ($r_m < r_0$), не влияет на размер объема памяти, но улучшает ее распознающие характеристики — размер областей притяжения оставшихся образов увеличится и, следовательно, сеть сможет распознавать более сильно искаженные образы.

Энергия локального минимума

Из анализа выражения (2) следует, что энергию локального минимума E_m с точностью до незначительной флуктуации порядка

$$\sigma_m = N \sqrt{1 - r_m^2} \quad (8)$$

можно представить в виде

$$E_m = -r_m N^2. \quad (9)$$

Тогда, с учетом соотношения (5) из (9) нетрудно получить выражение

$$E_m = E_0 \frac{1}{\sqrt{\left(1 - \frac{2n_m}{N}\right)^2 + \frac{E_0^2}{N^4}}}, \quad (10)$$

где

$$E_0 = -N \sqrt{2N \ln N}, \quad (11)$$

устанавливающее связь между глубиной локального минимума и шириной его области притяжения. Как видим, чем шире область притяжения, тем




Рис. 3. Зависимость энергии локального минимума от ширины области притяжения.

глубже минимум, и наоборот — чем глубже минимум, тем шире область его притяжения (см. рис. 3).

Введенная здесь величина E_0 характеризует сразу два параметра нейронной сети. Во-первых, ею определяется полуширина лоренцевского контура распределения (10). Во-вторых, из (10) вытекает неравенство $E_m \leq E_0$, т. е. E_0 является верхней границей спектра локальных минимумов. Эти результаты хорошо согласуются с результатами компьютерных экспериментов, в ходе которых проверялось, существует ли в точке S_m локальный минимум или его нет. Результаты одного из экспериментов ($N = 500$, $M = 25$) приведены на рис. 4. Как видим, хорошо прослеживается линейная зависимость энергии локального минимума от величины статвеса образа. Причем, экспериментальные точки, соответствующие локальным минимумам, расположены только в правом нижнем квадранте, где $r_m > r_0$ и $E_m < E_0$. Кроме того, на рис. 4 видно, что в соответствии с (8) флуктуации энергий минимумов с ростом статвеса уменьшаются.

В заключение этого раздела приведем вытекающие из предыдущего анализа полезные соотношения: глубина локального минимума ограниче-




Рис. 4. Зависимость энергии E_m локального минимума от статвеса образа r_m .

на соотношением $-N^2 \leq E_m \leq E_0$; сумма квадратов энергий локальных минимумов удовлетворяет соотношению $\sum E_m^2 \leq N^4$, в котором знак равенства стоит в том случае, когда всем образам соответствуют локальные минимумы.

Вероятность обнаружения минимума

Определим теперь вероятность W нахождения локального минимума E_m при случайном поиске. Искомая вероятность по определению совпадает с вероятностью того, что задавая начальную конфигурацию мы попадаем в область притяжения образа S_m . Следовательно величина $W = W(n_m)$ есть число точек в сфере радиуса n_m , приведенное к общему числу точек в N -мерном пространстве:

$$W = 2^{-N} \sum_{n=1}^{n_m} C_N^n. \quad (12)$$

Выражениями (8) и (12) в неявном виде задается связь между глубиной локального минимума и вероятностью его нахождения. Применяя к биномиальным коэффициентам асимптотическое разложение Стирлинга и заменяя в (12) суммирование интегрированием, можно представить искомую связь как

$$W = W_0 e^{-Nh}, \quad (13)$$

где h — функция Шеннона

$$h = \frac{n_m}{N} \ln \frac{n_m}{N} + \left(1 - \frac{n_m}{N}\right) \ln \left(1 - \frac{n_m}{N}\right) + \ln 2. \quad (14)$$

Здесь W_0 — не существенная для дальнейшего анализа медленная функция от E_m , которую можно получить асимптотической оценкой (12) при условии $n_m \gg 1$, а зависимость $W = W(n_m)$ всецело определяется быстрой экспонентой.

Как следует из (12), вероятность обнаружения локального минимума малой глубины ($E_m \sim E_0$) убывающе мала как $W \sim 2^{-N}$. Заметно отличной от нуля вероятность W становится только в случае достаточно глубоких минимумов $|E_m| \gg |E_0|$, размеры областей притяжения которых сопоставимы с величиной $N/2$. Выражение (13) с учетом (10) в этом случае преобразуется к зависимости $W = W(E_m)$, задаваемой выражением

$$W = W_0 \exp \left[-N E_0^2 \left(\frac{1}{E_m^2} - \frac{1}{E_\infty^2} \right) \right], \quad (15)$$

где

$$E_\infty^2 = \sum_m E_m^2. \quad (16)$$

Здесь мы ввели новую константу E_∞ , хотя в принятой нами нормировке из (9) вытекает $E_\infty = -N^2$ и введение нового обозначения не имеет особого смысла. Однако, для других типов нормировок вполне возможна иная зависимость E_∞ от N , что может привести к недоразумениям.

Как видим, вероятность обнаружения минимума растет с ростом его глубины. Эта зависимость подтверждается результатами экспериментов, проведенных для матриц (1) с малым загрузочным параметром $M/N \leq 0/05$, при котором проведенный выше анализ справедлив. Сплошная кривая на рис. 5 построена по формуле (13), точки — эксперимент. Как видим, хорошее согласие достигается прежде всего для наиболее глубоких локальных минимумов, которые соответствуют записанным в матрице межсвязей

образам S_m (на рисунке — это область энергий $E_m < -0.48N^2$). Экспериментально обнаруженные минимумы малой глубины (точки в области $E_m > -0.44N^2$) — это так называемые «химеры» [1]. В стандартной модели Хопфилда ($r_m \equiv 1/\sqrt{M}$) они появляются при относительно больших нагрузках. В рассматриваемом здесь более общем случае они могут появиться и раньше. Причины их появления хорошо исследованы методами статистической физики в работах [24–25], где показано, что химеры образуются как следствие интерференции минимумов S_m . При малой нагрузке химеры отделены от минимумов S_m энергетической щелью, отчетливо видной на рис. 5. С ростом параметра нагрузки M/N соответствующие химерам минимумы опускаются и, при нагрузке $M/N \sim 0.1$, сравниваются по глубине с локальными минимумами S_m . Более того, при $M/N \geq 0.14$ появляются глубоко расположенные так называемые ложные (spurious) минимумы, образованные из больших фрагментов векторов S_m , а большинство локальных минимумов S_m исчезает. Эта экспериментально наблюдавшаяся картина имеет простое объяснение в рамках проведенного выше анализа: с ростом M уменьшается число образов, удовлетворяющих условию $r_m > r_0$ существования локального минимума.

Несмотря на такую сложную картину энергетической поверхности описываемая выражениями (13)–(15) зависимость «глубже минимум — больше область притяжения — больше вероятность попадания в этот минимум» как правило сохраняется при любых параметрах нагрузки. Отметим, что зависимость (13) выполняется тем лучше, чем глубже описываемый этим выражением минимум. А поскольку для задачи оптимизации важно описать поведение именно наиболее глубоких минимумов, то это позволяет сформулировать эвристический подход для отыскания глобального минимума функционала (2) с произвольной наперед заданной матрицей (не обязательно хеббовской). Состоит он в том, чтобы использовать выражение (13) с неизвестными параметрами W_0 , E_0 и E_∞ . Для этого запускается процедура случайного поиска и находится какое-то число минимумов. По полученным данным определяются характерные для данной матрицы значения E_0 и E_∞ и величина подгоночного параметра W_0 . Подстановка этих величин в (13) позволит оценить вероятность нахождения неизвестного более глубокого минимума E_m (если он существует) и принять решение на остановку программы поиска (если оценка пессимистична) или ее продолжение.

Такой подход опробован на хеббовских матрицах при достаточно больших нагрузочных параметрах ($M/N = 0.2 \div 2$), когда нейросетевая система




Рис. 5. Зависимость вероятности W обнаружения локального минимума от его глубины E_m .

переходит в состояние спинового стекла [23] и применение полученных выше результатов становится не совсем корректным. Результат одного из экспериментов приведен на рис. 6. В ходе эксперимента по обнаруженным минимумам (точки A) были рассчитаны параметры W_0 , E_0 и E_∞ и построена зависимость $W = W(E_m)$ (сплошная кривая). Затем, в результате многократно повторяемой процедуры случайного поиска ($\sim 10^5$ стартов нейронной сети) были установлены другие минимумы (точки B) и точные значения вероятностей попадания в них. Как видим, несмотря на разброс, предсказанные значения по порядку величины хорошо совпадают с реальными значениями вероятностей.

Форма локального минимума

Установленная выше зависимость «глубже минимум – больше область притяжения – больше вероятность попадания в этот минимум» на первый взгляд может показаться достаточно удивительной. Кажется, что она про-




Рис. 6. Сравнение предсказанных вероятностей (сплошная линия) и экспериментально найденных значений (точки, связанные пунктиром).

творечит здравому смыслу, который подсказывает, что могут существовать очень глубокий, но очень узкий минимум, вероятность обнаружения которого очень мала, или наоборот — относительно неглубокий, но очень широкий минимум, вероятность обнаружения которого очень велика. Ниже мы покажем, что такого противоречия нет, поскольку все минимумы имеют строго заданную форму, в которой глубина и ширина (радиус области притяжения) взаимосвязаны так, что ширина минимума растет с ростом его глубины.

Чтобы доказать это утверждение, рассмотрим поведение энергии вблизи некоторой точки S_m , в которой энергия достигает своего локального минимума. Подставляя (1) в (2) для энергии этого локального минимума с точностью до несущественной константы получим:

$$E_m = -r_m N^2 - \sum_{\mu \neq m} r_\mu (S_m S_\mu)^2. \quad (17)$$

Введем понятие n -окрестности точки S_m — это совокупность точек N -

мерного пространства, отстоящих от S_m на расстоянии n , т. е. каждый вектор $S_m^{(n)}$ отличается от S_m на n бит (n перевернутых спинов). Например, 1-окрестность содержит N точек, отличающихся от S_m в одном бите, 2-окрестность содержит $N(N-1)/2$ точек, n -окрестность — C_N^n точек. Рассмотрим одну из точек n -окрестности $S_m^{(n)}$. Для простоты обозначений будем полагать, что векторы $S_m^{(n)}$ и S_m отличаются в первых n битах (первые n спинов в этой точке $S_m^{(n)}$ перевернуты относительно S_m). Тогда энергию сети в этой точке из n -окрестности можно записать в виде:

$$E_m^n = -r_m N^2 \left(1 - \frac{2n}{N}\right)^2 - \sum_{\mu \neq m} r_\mu (S_m S_\mu)^2 + \\ + 4 \sum_{\mu \neq m} \sum_{i=1}^n \sum_{j=n+1}^N r_\mu s_{mi} s_{\mu i} s_{\mu j} s_{mj} \quad (18)$$

или в виде

$$E_m^{(n)} = E_m + \delta E_m(n) + R, \quad (19)$$

где

$$R = 4 \sum_{\mu \neq m} \sum_{i=1}^n \sum_{j=n+1}^N r_\mu s_{mi} s_{\mu i} s_{\mu j} s_{mj}, \quad (20)$$

$$\delta E_m(n) = 4r_m N^2 \frac{n}{N} \left(1 - \frac{n}{N}\right). \quad (21)$$

Величина R незначительно меняется от точки к точке в n -окрестности. Нетрудно заметить, что ее можно описать как нормально распределенную случайную величину с нулевым средним ($\langle R \rangle = 0$) и среднеквадратичным отклонением

$$\sigma_m(n) = 2N \sqrt{\frac{r_m n}{N} \left(1 - \frac{n}{N}\right)}. \quad (22)$$

Соответственно, величина $\delta E_m(n) = \langle E_m^n - E_m \rangle$ есть не что иное, как среднее значение разницы в энергии между точками в n -окрестности $\{S_m^{(n)}\}$ и в минимуме S_m . Именно зависимостью величины $\delta E_m(n)$ от n и задается форма локального минимума. Выражение (21) находится в прекрасном согласии с результатами численного эксперимента. В ходе эксперимента генерировалась случайная матрица, случайно находилась какой либо локальный минимум и затем исследовалось среднее значение энергии вокруг этого минимума. Результаты одного из таких экспериментов приведены на рис. 7.




Рис. 7. Форма локального минимума: среднее значение энергии в n -окрестности локального минимума. Кривая соответствует формуле (21), маркер — экспериментальные точки.

Итерационный алгоритм

Опишем теперь итерационную процедуру, позволяющую с заданной точностью представить любую заданную симметричную матрицу $\hat{\mathbf{T}}$ в виде разложения (1) по неподвижным точкам модели Хопфилда.

Введем обозначение матрицы $\hat{\mathbf{T}}_k$:

$$\hat{\mathbf{T}}_k = \hat{\mathbf{T}} - \sum_{m=1}^k r_m S_m^+ S_m, \quad (23)$$

матричные элементы которой имеют вид:

$$T_{k,ij} = T_{ij} - \sum_{m=1}^k r_m s_{mi} s_{mj},$$

и зададим невязку на k -м шаге итерации в виде:

$$\varepsilon_k = \sum_{i=1}^N \sum_{j=1}^N T_{k,ij}^2, \quad (24)$$

Определим процедуру минимизации невязки таким образом, чтобы с ростом k имело место $\varepsilon_k \rightarrow 0$. Если при некотором числе итераций $k \geq M$ величина невязки станет меньше заданного значения ε_M , то тем самым мы решим поставленную выше задачу: равенство (1) будет выполняться с заданной точностью.

Предлагаемая здесь итерационная процедура сводится к следующему. На k -м шаге итерации генерируем случайный конфигурационный вектор \mathbf{S}_k . С учетом (23) выражение для невязки (24) представим в виде:

$$\varepsilon_k = \sum_{i=1}^N \sum_{j=1}^N (T_{k-1,ij} - r_k s_{ki} s_{kj})^2, \quad (25)$$

или в виде:

$$\varepsilon_k = \varepsilon_{k-1} + 2r_k E_k + r_k^2 N^2, \quad (26)$$

где

$$E_k = - \sum_{i=1}^N \sum_{j=1}^N T_{k-1,ij} s_{ki} s_{kj}. \quad (27)$$

Из (26) следует, что минимум невязки ε_k будет достигнут, если величину статвеса задать в виде:

$$r_k = - \frac{E_k}{N^2}. \quad (28)$$

Тогда минимальное значение невязки примет вид:

$$\varepsilon_k = \varepsilon_{k-1} - r_k^2 N^2. \quad (29)$$

Как видно из (29), величину ε_k можно сделать еще меньше, если увеличить статвес ε_k . Для этого надо запустить стандартную спиновую динамику [2] оптимизации квадратичного функционала E_k , т. е. оптимизировать энергию модели Хопфилда (27), построенной на матрице $\hat{\mathbf{T}}_{k-1}$. При этом вектор \mathbf{S}_k заменяется на вектор \mathbf{S}_k^{onm} , соответствующей экстремуму функционала E_k . В точке \mathbf{S}_k^{onm} , в соответствии с (28), достигается максимальное (по модулю) значение статвеса r_k и минимальное значение невязки ε_k .

Далее, на основе вектора $\mathbf{S}_k = \mathbf{S}_k^{onm}$ и отвечающего ему значения статвеса r_k в соответствии с (23) строим матрицу $\hat{\mathbf{T}}_k = \hat{\mathbf{T}}_{k-1} - r_k \mathbf{S}_k^+ \mathbf{S}_k$ и переходим к следующему шагу итерации.

Покажем, что описанная выше итерационная процедура сходится за конечное число итераций. Для этого, с учетом полученного выше соотношения $E_k = -r_k N^2$ между энергией экстремума и статвесом паттерна, преобразуем (29) к виду:

$$\varepsilon_{k+1} = \varepsilon_k (1 - r_k^2), \quad (30)$$

из которого несложно получить следующее соотношение

$$\varepsilon_{k+1} = \varepsilon_0 \prod_{m=1}^k (1 - r_m^2), \quad (31)$$

где ε_0 — начальное значение невязки, равное сумме квадратов матричных элементов исходной матрицы $\hat{\mathbf{T}}$. Поскольку на статвес паттерна, соответствующего экстремуму функционала энергии, выше получено ограничение

$$r_k^2 \geq \frac{2 \ln N}{N}, \quad (32)$$

то для величины невязки из (30)–(31) вытекает соотношение

$$\varepsilon_k \sim \varepsilon_0 \exp\left(-\frac{2k \ln N}{N}\right), \quad (33)$$

из которого нетрудно оценить число итераций M , обеспечивающих заданную точность разложения (1). Нетрудно заметить, что число итераций конечно. Численные эксперименты подтверждают сказанное (см. рис. 8).

Обсуждение результатов

Проведенный анализ показал, что свойства обобщенной модели описываются двумя критическими параметрами r_0 и E_0 . Первый из них определяет минимальное значение статвеса, при котором образ образует локальный минимум и может быть восстановлен нейронной сетью. Второй — это верхняя граница локальных минимумов энергетической поверхности. Существенно, что величины обоих параметров никак не зависят от числа образов M , на которых построена матрица межсвязей. Существенно

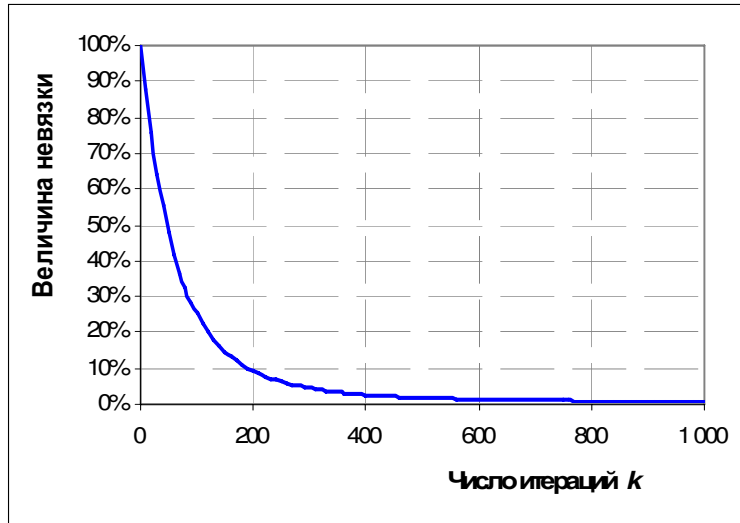


Рис. 8. На рисунке показано как невязка ε_k уменьшается с ростом числа итераций k . Кривая взята из эксперимента, проведенного при условиях: матричные элементы исходной матрицы \mathbf{T} генерировались случайным образом с равномерным распределением на отрезке $[-1, +1]$ и нулевым средним; размерность конфигурационного пространства — $N = 1000$.

и то, что удаление из матрицы межсвязей образов, прописанных в матрице межсвязей с статвесами, меньшими критического значения ($r_m < r_0$), хотя и не влияет на размер объема памяти, однако улучшает ее распознающие характеристики — размер областей притяжения оставшихся образов увеличится и, следовательно, сеть может распознавать более сильно искаженные образы. Вместе с этим, обратим внимание на тот факт, что с ростом размерности сети радиус области притяжения локального минимума уменьшается. Как следует из (5), такое уменьшение имеет место даже в том случае, когда загрузка сети с ростом N логарифмически уменьшается как $M/N = \text{const}/2 \ln N$. Это означает, что с ростом N уменьшается уровень допустимых искажений, при которых сеть способна восстанавливать образы (сеть меньших размеров способна распознавать более сильно искаженные образы).




Рис. 9. Случай хеббовской матрицы с большой загрузкой ($M/N = 1$).
(а) Кривая показывает спектральную плотность минимумов (число минимумов на единичном интервале). В верхней части рисунка представлен сам спектр минимумов — каждая вертикальная черта соответствует минимуму. По оси ординат отложена спектральная плотность в %, по оси абсцисс — энергия в относительных единицах E/N^2 .
(б) Зависимость вероятности нахождения минимума от его глубины. По оси ординат отложена вероятность в %, по оси абсцисс — энергия минимума.

Во избежание недоразумений следует указать на то, что связь между радиусом области притяжения n_m и объемом этой области $W = W(n_m)$ существенно нелинейная (12). Это означает, что даже при очень большом значении радиуса (например $n_m \sim 0.49N$) область притяжения может занимать очень малую часть N -мерного пространства, а доля пространства вне области притяжения (т. е. все точки, отстоящие от минимума на расстоянии от n_m до $0.5N$) с ростом N нарастает экспоненциально и при достаточно больших значениях N стремится к $1/2$.

В заключение сделаем несколько практических замечаний, относящихся к сравнению теории с экспериментом. Во-первых, напомним, что карти-




Рис. 10. Случайная матрица с равномерным распределением матричных элементов. **(а)** Кривая показывает спектральную плотность минимумов (число минимумов на единичном интервале). В верхней части рисунка представлен сам спектр минимумов — каждая вертикальная черта соответствует минимуму. По оси ординат отложена спектральная плотность в %, по оси абсцисс — энергия в относительных единицах. **(б)** Зависимость вероятности нахождения минимума от его глубины. По оси ординат отложена вероятность в %, по оси абсцисс — энергия минимума E/N^2 .

на энергетического ландшафта симметрична относительно изменения знака вектора состояния нейронной сети и, следовательно, каждому локальному минимуму в точке S соответствует точно такой же минимум в точке $S^* = -S$. Поэтому, экспериментально измеренную вероятность нахождения минимума с энергией E следует сравнивать с величиной $W = W(E)$, если только в ходе эксперимента фиксировалась координата минимума, в противном случае — с величиной $2W(E)$.

Итак, получены выражения, устанавливающие связь между глубиной локального минимума и шириной области притяжения, которую можно выразить в виде «глубже минимум — шире область притяжения — больше

вероятность обнаружения в процессе случайного поиска». Тем самым показано, что в процессе случайного поиска с наибольшей вероятностью находится наиболее глубокий минимум. Эти выражения получены на основе анализа обобщенной модели Хопфилда. Однако, показано, что существует итерационный алгоритм, позволяющий за конечное число шагов представить любую наперед заданную симметричную матрицу в виде взвешенного хеббовского разложения (1) по внешним произведениям конфигурационных векторов. Возможность такого представления говорит о том, что все аналитические выводы, касающиеся ассоциативных нейросетей и оптимизационных алгоритмов, базирующихся на хеббовских матрицах, в равной степени применимы и для любого иного типа матриц. Развитая теория находится в хорошем согласии с результатами эксперимента. Действительно, многочисленные минимизационные эксперименты, проведенные на хеббовских матрицах с произвольной загрузкой (как очень малой, так и очень большой), на случайных матрицах с гауссовским или равномерным распределением матричных элементов, показывают, что с практически во всех случаях наибольшей вероятностью находится наиболее глубокий минимум (см. рис. 9 и рис. 10).

Работа выполнена при поддержке РФФИ (проект 06-01-00109).

Литература

1. *Hopfield J. J.* Neural Networks and physical systems with emergent collective computational abilities // *Proc. Nat. Acad. Sci. USA.* – v. 79, pp. 2554–2558 (1982).
2. *Hopfield J. J., Tank D. W.* Neural computation of decisions in optimization problems // *Biological Cybernetics.* – v. 52, pp. 141–152 (1985); *Hopfield J. J., Tank D. W.* Computing with neural circuits: A Model // *Science.* – v. 233, pp. 625–633 (1986).
3. *Fu Y., Anderson P. W.* Application of statistical mechanics to NP-complete problems in combinatorial optimization // *Journal of Physics A.* – v. 19, pp. 1605–1620 (1986).
4. *Poggio T., Girosi F.* Regularization algorithms for learning that are equivalent to multilayer networks // *Science.* – 247, pp. 978–982 (1990).
5. *Smith K. A.* Neural networks for combinatorial optimization: A review of more than a decade of research // *INFORMS Journal on Computing.* – v. 11 (1), pp. 15–34 (1999).
6. *Joya G., Atencia M., Sandoval F.* Hopfield neural networks for optimization: Study of the different dynamics // *Neurocomputing.* – v. 43, pp. 219–237 (2002).
7. *Hartmann A. K., Rieger H.* *New Optimization Algorithms in Physics.* – Wiley-VCH, Berlin, 2004.

8. Tang Huajin, Tan K. C., Yi Zhang. A columnar competitive model for solving combinatorial optimization problems // *IEEE Trans. Neural Networks*. – v. 15, pp. 1568–1574 (2004).
9. Kwok T., Smith K. A. A noisy self-organizing neural network with bifurcation dynamics for combinatorial optimization // *IEEE Trans. Neural Networks*. – v. 15, pp. 84–98 (2004).
10. Salcedo-Sanz S., Santiago-Mozos R., Bousoño-Calzon C. A hybrid Hopfield network-simulated annealing approach for frequency assignment in satellite communications systems // *IEEE Trans. Systems, Man and Cybernetics*. – v. 34, pp. 1108–1116 (2004).
11. Wang L. P., Li S., Tian F. Y., Fu X. J. A noisy chaotic neural network for solving combinatorial optimization problems: Stochastic chaotic simulated annealing // *IEEE Trans. System, Man, Cybern, Part B–Cybernetics*. – v. 34, pp. 2119–2125 (2004).
12. Wang L. P., Li S. A gradual noisy chaotic neural network for solving the broadcast scheduling problem in packet radio networks // *IEEE Trans. Neural Networks*. – vol. 17, pp. 989–1000 (2006).
13. Kryzhanovsky B., Magomedov B. Application of domain neural network to optimization tasks // *Proc. of ICANN'2005*. Warsaw. LNCS 3697, Part II, pp. 397–403 (2005).
14. Kryzhanovsky B., Magomedov B. Domain dynamics in optimization tasks. – *Lecture Notes in Computer Science*. – Springer, Berlin–Heidelberg. ISSN: 0302-9743, Volume 4029 / 2006, pp. 37–45 (2006).
15. Litinskii L. B., Magomedov B. M. Global Minimization of a Quadratic Functional: Neural Networks Approach // *Pattern Recognition and Image Analysis*. – v. 15(1), pp. 80–82 (2005).
16. Крыжановский Б. В., Магомедов Б. М., Микаэлян А. Л. Взаимосвязь глубины локального минимума и вероятности его обнаружения в обобщенной модели Хопфилда // *Доклады АН*. – т. 405, № 3, с. 320–324, 2005.
17. Kryzhanovsky B. V., Magomedov B. M., Fonarev A. B. On the Probability of Finding Local Minima in Optimization Problems // *Proc. of International Joint Conference on Neural Networks IJCNN-2006*, pp. 5888–5892. Vancouver, Canada.
18. Kryzhanovsky B. V., Kryzhanovsky V. M., Mikaelian A. L. Binary optimization: A relation between the depth of a local minimum and the probability of its detection // *4th International Conference on Informatics in Control, Automation and Robotics*. – pp. 5–10. ICINCO 2007, Anger, France.

19. Крыжановский Б. В. Представление наперед заданной матрицы в виде хэббовского разложения по конфигурационным весторам // IX Всероссийская научно-техническая конференция «Нейроинформатика-2007». – М.: МИФИ, т. 1, с. 178–182 (2007).
20. Kryzhanovsky B. V. Expansion of a matrix in terms of external products of configuration vectors // *Optical Memory & Neural Networks*. – vol. 16, No. 4, pp. 187–199, 2007.
21. Крыжановский Б. В. Представление заданной матрицы в виде взвешенного разложения по конфигурационным векторам. // *Многопроцессорные вычислительные и управляющие системы–2007*. Материалы Международной научно-технической конференции. Т. 2. - Таганрог: Изд-во ТТИ ЮФУ, 2007. – с. 9-13.
22. Perez-Vincente C. J. Finite capacity of sparse-coding model // *Europhys. Lett.* – v. 10, pp. 627–631 (1989).
23. McEllice R., Posner E., Rodemich E. R. Capacity of the Hopfield associative memory // *IEEE Trans. on Inf. Theory*. – v. 33, pp. 461–482 (1987).
24. Amit D. J., Gutfreund H., Sompolinsky H. // *Annals of Physics*. – v. 173, pp. 30–67 (1987).
25. Amit D. J., Gutfreund H., Sompolinsky H. Spin-glass models of neural networks // *Physical Review A*. – v. 32, pp. 1007–1018 (1985.)
26. Hebb D. O. *The Organization of Behavior*. – New York: Wiley, 1949.

Борис Владимирович КРЫЖАНОВСКИЙ, директор Центра оптико-нейронных технологий Научно-исследовательского института системных исследований РАН (Москва), член-корреспондент РАН, доктор физико-математических наук, Президент Российской ассоциации нейроинформатики. Область научных интересов: нейронные сети, квантовая механика, нелинейная оптика. Имеет более 80 научных публикаций.

Я. Б. КАЗАНОВИЧ

Институт математических проблем биологии РАН,
г. Пущино, Московская область
E-mail: yakov_k@impb.psn.ru

**СЕГМЕНТАЦИЯ ИЗОБРАЖЕНИЙ С ПОМОЩЬЮ
ДИНАМИЧЕСКИХ НЕЙРОННЫХ СЕТЕЙ**

Аннотация

Рассматриваются различные подходы к построению моделей сегментации изображений на основе использования динамических процессов, колебаний и синхронизации нейронной активности. Приводятся нейробиологические основы моделей, описываются принципы функционирования моделей и результаты их применения. Обсуждаются сравнительные качества моделей и перспективы их улучшения.

Y. B. KAZANOVICH

Institute of Mathematical Problems in Biology,
Russian Academy of Sciences,
Pushchino, The Moscow Region
E-mail: yakov_k@impb.psn.ru

IMAGE SEGMENTATION BY DYNAMICAL NEURAL NETWORKS

Abstract

The lecture presents a review of neural network models for image segmentation that is based on dynamic processes, oscillations, and synchronization of neural activity. Neurobiological principles of the models, the mechanisms of their functioning, and the results of simulations are described. The performance of the models and the perspectives of improving the segmentation quality are discussed.

The mind, meeting place and source of all other symbol systems, surely must possess a mechanism for combining its semantic atoms into molecules and aggregates in a way richer than anything yet contrived on paper or in electronics. Identifying this mechanism is the binding problem.

C. von der Malsburg

Прежде, чем объединиться, надо решительно размежеваться.

В. И. Ленин

Введение. Теория временной корреляции

Разбиение изображений на непересекающиеся фрагменты, соответствующие зрительным объектам и фону, является популярной задачей искусственного интеллекта. На эту тему опубликовано огромное количество работ. Обзоры по данной области исследований можно найти, например, в работах [1–8] (см. также веб-страницы [9–10]). Сегментация считается важным предварительным шагом, существенно облегчающим последующее решение задач анализа зрительных сцен, таких как распознавание образов, запоминание, обнаружение заданных объектов и т. д. Хотя люди используют достаточно единообразные интуитивные стратегии сегментации, дать формальное, универсальное и объективное определение качества сегментации вряд ли возможно. Многочисленные эксперименты показывают, что сегментация зависит от контекста, предшествующего опыта и внутренних установок, которые лежат за пределами самого анализируемого изображения. Все это препятствует формулировке сегментации как чисто оптимизационной задачи.

Компьютерная реализация сегментации опирается в значительной мере на интуицию и здравый смысл. Обычно применяющиеся методы основаны на предположении, что пиксели в сегментированной области должны иметь сходные оптические характеристики по интенсивности, цвету, текстуре, в

то время как разные области хотя бы по одной из этих характеристик различаются. Кроме того, сегментация должна быть устойчива по отношению к шуму и естественной вариации объектов и фона. Предпочтение отдается тем методам, которые легче адаптируются к широкому классу изображений путем соответствующей модификации параметров алгоритма.

В то время как люди в большинстве случаев успешно справляются с задачей сегментации, часто даже не фокусируя на ней внимания, компьютерная сегментация оказалась трудной задачей. В связи с этим у исследователей возникло желание лучше разобраться, как эту задачу решает мозг. Важной особенностью работы мозга является параллельная обработка информации. Это дает надежду на то, что использование биологических методов сегментации окажется не только качественным, но и быстрым.

Встречный интерес к проблеме сегментации возник и у биологов в связи с так называемой проблемой интеграции признаков объектов в цельный образ. По-английски эта проблема называется *the binding problem* — проблема связывания (в дальнейшем термин **байндинг** будет использоваться как синоним интеграции признаков). Дело в том, что признаки, используемые при кодировании информации о зрительных стимулах в первичных зонах зрительной коры, имеют различную природу. Это могут быть геометрические, спектральные или динамические характеристики изображения. Известно, что первичная обработка различных по своей природе признаков идет в специализированных нейронных структурах коры мозга. Только в ассоциативных зонах коры формируется представление о целостных объектах. В связи с этим возникает вопрос: каковы нейронные механизмы, позволяющие сохранить информацию о принадлежности признаков к отдельным объектам, и как осуществляется объединение нужных признаков в цельный образ объекта?

Нетривиальность проблемы байндинга становится очевидной при одновременном предъявлении на изображении нескольких объектов. В этом случае весь набор признаков, извлеченных из изображения, должен быть сегментирован с указанием того, какой признак какому объекту принадлежит, и «метка» принадлежности должна сохраняться на всем пути продвижения зрительной информации по коре. Имеются психологические эксперименты, показывающие, что при недостатке ресурсов (например, нехватке времени) испытуемые могут выполнять группировку признаков по объектам с ошибками. Например, после предъявления изображения, содержащего зеленый треугольник и красный квадрат, испытуемому может показаться, что ему были показаны зеленый квадрат и красный треугольник.

Из сказанного видно, что сегментацию можно рассматривать как частный случай байндинга. В самом деле, если речь идет об изображениях, заданных попиксельно, то достаточно включить в число признаков объектов признаки отдельных пикселей, чтобы метка принадлежности пикселей различным объектам реализовывала сегментацию изображения. Если же изображение задано в виде контуров объектов, тогда для сегментации объектов достаточно, чтобы в число признаков были включены признаки сегментов, составляющих контуры.

Гипотеза о возможном механизме интеграции признаков в мозге была предложена в работе [11]. Основная идея состоит в том, что признаки объекта кодируются синфазной активностью нейронов в различных областях коры мозга. Синфазность служит в качестве метки, помечающей информацию, относящуюся к одному объекту.

Эта гипотеза получила определенное экспериментальное подтверждение [12–13]. В экспериментах на первичных зонах зрительной коры животных была обнаружена как стимулоспецифическая колебательная активность нейронов, так и синфазность этой активности у нейронов, кодирующих один и тот же стимул. В частности, проводились эксперименты на кошках, которым предъявлялась светлая полоска, движущаяся вверх или вниз по темному экрану. Активность на уровне одиночных нейронов (multiunit activity) и нейронных ансамблей (local field potential) регистрировалась в зоне V1 или V2 первичной зрительной коры двумя электродами. Были получены следующие результаты.

1. Нейроны отвечают периодической активностью с частотой в гамма-диапазоне (40–70 Гц) при прохождении полоски через их рецептивное поле.
2. При одновременном пересечении полоской двух рецептивных полей активность соответствующих нейронов синфазна, даже если эти нейроны находятся друг от друга на расстоянии нескольких миллиметров.
3. Если полоску разорвать на две изолированных части, то синхронность ответа падает тем больше, чем больше величина разрыва.
4. Если на экране движутся две полоски в разных направлениях (одна вверх, другая вниз), то синхронизованного ответа не возникает даже в тот момент, когда эти полоски оказываются на одной прямой.

Таким образом, в случае 2 имеет место синхронный ответ на единичный объект, а в случаях 3 и 4 — несинхронный ответ на два разных объекта.

В дальнейшем были проделаны многочисленные эксперименты на разных животных и с многоэлектродной записью активности различных участков мозга, продемонстрировавшие важную роль осцилляторной и синхронной активности в реализации когнитивных функций. Основанная на этих экспериментальных данных теория интеграции признаков получила название теории временной корреляции (temporal correlation theory) [14–15]. Ее частным случаем, когда нейронная активность носит четко выраженный колебательный характер, является теория осцилляторной корреляции (oscillatory correlation theory) [16].

Несмотря на то, что теория временной корреляции (ТВК) является наиболее продвинутой попыткой объяснения интеграции признаков, следует отметить, что данная теория не может считаться общепризнанной, а эксперименты, подкрепляющие ТВК, поставлены при весьма специальных условиях: светлые полосы, движущиеся на однородном темном фоне, лишь очень отдаленно напоминают реальные зрительные сцены. Однако, поскольку принципы ТВК кажутся перспективными для обработки изображений, теоретическое и модельное изучение роли синхронизации нейронной активности в обработке информации пошло намного дальше имеющихся экспериментальных данных. В частности, целью исследований является проверка, каким образом ТВК может быть применена для анализа сложных изображений с нечетко определенными границами между объектами и высоким уровнем шумов. В случае успеха эти результаты могут быть полезны и для нейробиологов, поскольку помогут им в поиске новых экспериментальных фактов для обоснования ТВК. С другой стороны, ТВК может оказаться весьма эффективным инструментом при решении практических задач анализа изображений, поскольку принципы ТВК достаточно просто могут быть воплощены в технических системах с параллельными вычислениями.

Идеология ТВК хорошо сочетается с методами моделирования, опирающимися на осцилляторные нейронные сети [17–18]. Согласно ТВК сегментация должна приводить к синфазной активности нейронов, кодирующих зрительный объект, в то время как активность нейронных ансамблей, кодирующих разные объекты, должна быть некогерентной. Общая идея, присутствующая в большинстве нейросетевых моделей сегментации, состоит в реализации синфазности с помощью локальных латеральных связей (такая организация связей согласуется с архитектурой связей в первичных зонах зрительной коры). Другая идея, являющаяся обобщением имеющихся нейрофизиологических данных, заключается в предположении, что вход-

ное изображение кодируется в нейронной сети таким образом, что соседние элементы сети (нейроны или осциллирующие нейронные ансамбли) имеют тенденцию работать синфазно лишь в том случае, если участки изображения, находящиеся в их рецептивных полях, обладают сходными оптическими характеристиками. Опираясь при построении модели на эти предположения, можно ожидать, что динамика нейронной сети приведет к формированию в сети синфазных кластеров нейронов (при отсутствии синфазности или даже синхронизации между кластерами), таких что соответствующий каждому кластеру сегмент изображения будет иметь сходные (или, по крайней мере, плавно меняющиеся) оптические характеристики.

В последние годы было предложено большое количество моделей сегментации, отличающихся степенью учета биологических данных, классами анализируемых изображений, применяемыми принципами функционирования и результатами применения. Некоторые авторы обращают внимание на контурные изображения, поскольку они более похожи на стимулы, используемые в нейрофизиологических экспериментах. Другие предпочитают полутоновые и цветные изображения в силу их большей практической значимости. В последнем случае рецептивные поля нейронов или нейронных осцилляторов обычно представлены пикселями на изображении, каждый из которых характеризуется интенсивностью серого (для полутоновых изображений) или интенсивностями трех-четырех составляющих спектра (для цветных изображений).

Принятый в данной работе подход к категоризации методов сегментации является компромиссом, старающимся учесть как тип обрабатываемых изображений, так и применяемые вычислительные схемы. Сначала будут рассмотрены модели для сегментации контурных изображений. Затем для изображений, заданных попиксельно, описываются два класса моделей сегментации — с последовательным и параллельным выбором объектов. Результатом работы параллельной процедуры является одновременное существование нескольких синфазных внутри себя нейронных ансамблей, каждый из которых кодирует свой зрительный объект. При использовании последовательной процедуры синфазные ансамбли, кодирующие различные объекты, возникают один за другим, так что в каждый момент времени только один из представленных одновременно в зрительной сцене объектов кодируется когерентной активностью определенного нейронного ансамбля, в то время как активность в остальной части сети отсутствует или подавлена до низкого уровня. Далее будет рассмотрено, как сегментация может сочетаться с методами кластеризации. В следующем разделе описы-

ваются модели сегментации, привлекающие дополнительные когнитивные функции, такие как память и внимание. Заключительный раздел посвящен общему обсуждению существующих моделей сегментации и перспективам их совершенствования.

В то время как данная тематика моделирования весьма популярна в работах западных специалистов, в России она представлена работами лишь одной группы авторов [19–22], разрабатывающих параллельную процедуру сегментации. Эти работы хорошо известны участникам Конференции по нейроинформатике и не будут рассматриваться в данном обзоре. Частично вопросы сегментации изображений уже рассматривались нами в обзоре [23]. По охваченному кругу статей настоящая работа пересечений с этим обзором практически не имеет.

Терминологическое замечание. В работе часто будут использоваться термины **синхронизация, синфазность, когерентность, противофазность**. Под синхронизацией двух сигналов будет пониматься ситуация, когда на кросскорреляционной функции этих сигналов имеется хотя бы один большой пик (в случае периодической активности таких пиков будет несколько). Если основной пик кросскорреляционной функции находится в нуле, будем говорить о синфазной активности. Если речь идет об импульсной активности, синфазность означает, что импульсы в обоих сигналах генерируются одновременно. Когерентность будет использоваться как синоним синфазности. Противофазному режиму соответствует расположение основного пика кросскорреляционной функции в $\pm\pi$. В этом случае моменты максимума одного сигнала соответствуют минимумам другого сигнала. Под нейронным **ансамблем** будем понимать связанное множество синфазно работающих нейронов, представляющих один из объектов на изображении. Аналогичное соглашение имеет место для ансамблей нейронных осцилляторов.

Сегментация контурных изображений

Сегментация контурных изображений является специальным случаем задачи сегментации, когда входное изображение задано в виде набора коротких прямолинейных отрезков, имеющих различную ориентацию и располагающихся в узлах двумерной решетки. Психологические и нейрофизиологические наблюдения показывают, что интеграция признаков в таких изображениях происходит в первичных зонах зрительной коры (стриарная кора) в основном благодаря латеральному взаимодействию нейронов, имеющих

сходные ориентационные предпочтения (т. е. дающих максимальную реакцию на стимулы примерно одной и той же ориентации). Это, впрочем, не исключает определенной роли обратных связей от вышележащих корковых областей (в частности, экстрастриарных). Целью моделирования контурной сегментации является разработка такой биологически правдоподобной нейронной сети, которая бы позволяла осуществить группировку отрезков в контуры при подавлении активности нейронов, вызванной дистракторами (ложными объектами) и шумом. Дополнительно к этому модель должна обладать способностью заполнять пробелы в неполных контурах с тем, чтобы результирующий контур был связанным.

Модель Ли

Модель, описывающая функционирование чувствительных к ориентации нейронов в области V1, была предложена и изучена в серии статей *З. Ли* [24–27]. Эта модель развивает более ранние идеи по сегментации контурных изображений, выдвинутые в работе [28]. Параметры модели (кроме входных сигналов) являются жестко заданными в том смысле, что они не зависят от предъявленного изображения и не меняются в процессе его обработки. Параметры связи между парой нейронов зависят лишь от расстоянии между ними (сила связи убывает с расстоянием) и от разницы в их предпочтительной ориентации. Основное предположение модели состоит в том, что два нейрона связаны наибольшей возбуждающей связью, если их предпочтительные ориентации коллинеарны отрезку, соединяющему центры рецептивных полей этих нейронов. Наоборот, в случае ортогональности этих направлений связь между нейронами максимально ингибирующая. Остальные силы связи имеют промежуточные значения. Таким образом, нейроны, активируемые гладко меняющимся контуром, взаимно увеличивают свою активность, в то время как активность нейронов, активируемых шумом, подавляется. Экспериментальное подтверждение такой схемы взаимодействия содержится в работе [29].

Базовым функциональным элементом модели является осциллятор, формируемый парой из возбуждающего и тормозного нейронов. Динамика осциллятора описывается уравнениями

$$\frac{dx}{dt} = -x - g(y) + J_0 f(x) + I_x,$$

$$\frac{dy}{dt} = -y + f(x) + I_y.$$

Здесь переменные x и y задают мембранные потенциалы возбуждающего и тормозного нейронов, соответственно, f и g — кусочно-линейные сигмоидальные функции с порогом и насыщением, J_0 — сила синаптической связи между возбуждающими клетками, I_x и I_y — входные сигналы. В зависимости от входных сигналов и параметров осциллятор может демонстрировать различные виды динамики, включающие стационарные состояния, регулярные и хаотические колебания.

Возбуждающие нейроны в модели имеют рецептивные поля, чувствительные к ориентации стимула. Другими словами, внешний сигнал, проходящий на нейрон, максимален, если ориентация отрезка на изображении совпадает с предпочтительной ориентацией клетки. Этот сигнал убывает по мере того, как растет рассогласование между этими направлениями. Кроме того, входной сигнал увеличивается в случае отрезка, обладающего большей заметностью (то есть отличающегося по направлению от окружающих его отрезков).

В каждом узле двумерной решетки находится не один осциллятор, а гиперколонка, состоящая из K осцилляторов с предпочтительными ориентациями, равными $\theta = k\pi/K$ ($k = 0, \dots, K - 1$) (при вычислениях использовалось 12 направлений, $K = 12$).

В модели реализована следующая архитектура связей. Внутри гиперколонки имеются связи от каждого тормозного нейрона на все возбуждающие нейроны. Сила связи убывает с ростом $|\Delta\theta|$ (максимальная сила соответствует связи, идущей на возбуждающий нейрон того же осциллятора). Связи между гиперколонками идут от возбуждающего нейрона одной гиперколонки на все возбуждающие и тормозные нейроны соседних гиперколонок. Сила связи убывает по мере возрастания расстояния между узлами решетки. Наиболее важное свойство этих связей состоит в том, что сила связи между возбуждающими нейронами имеет большую величину, если ориентационная предпочтительность нейронов совпадает с ориентацией линии, соединяющей узлы, где расположены эти нейроны. С другой стороны, связь от возбуждающего нейрона к тормозному имеет наибольшую силу, если ориентационная предпочтительность соответствующих осцилляторов ортогональна линии, соединяющей места их расположения.

Дополнительно к описанным входным сигналам на нейроны подаются еще так называемые нормализующие токи, которые предназначены для получения требуемой динамики сети и для управления заметностью конту-

ров. Предполагается, что эти сигналы поступают из более высоких отделов зрительной коры. В частности, подача сильного сигнала на тормозные нейроны осцилляторов, соответствующих некоторому контуру, может привести к тотальному подавлению активности этих осцилляторов. Результатом будет исключение данного контура из процедуры сегментации.

Основные результаты применения модели (аналитические и компьютерные) были получены для простых геометрических форм, таких как прямые линии и круги в присутствии шума, но модель применялась и к небольшому числу фотографических изображений, предварительно преобразованных в векторную форму (рис. 1). При подходящем выборе параметров модель демонстрировала затухающие или устойчивые синхронные колебания для контуров, представленных отрезками с плавно меняющимися направлениями. Степень выраженности контура в выходных сигналах, идущих от возбуждающих нейронов, и степень синхронизации увеличиваются в случае длинных, гладких и замкнутых контуров, что совпадает с данными биологических экспериментов. Например, набору отрезков, ориентированных вдоль контура окружности, соответствует более высокий выходной сигнал по сравнению с ситуацией, когда отрезки расположены на контуре окружности, но ортогональны к нему.

Синхронизация в пределах одного контура имеет место, даже если входные сигналы от отрезков на изображении поступают в модель не одновременно, а с небольшим запаздыванием один после другого. С другой стороны, синхронизация отсутствует, если даже разные контуры пересекаются и все сигналы от изображения приходят одновременно. Последнее вытекает в основном из взаимно подавляющего взаимодействия между осцилляторами в одной гиперколонке.

В работах [25–27] основное внимание уделено текстурам, построенным из отрезков с разным наклоном. Показано, что имеет место увеличение выходных сигналов на границе между двумя текстурами с разными наклонами отрезков (так называемый pop-out границы).

Модель Чое-Миккулайнена

Хотя модель Ли хорошо соответствует ряду экспериментальных данных, она никак не отвечает на вопрос, каким образом в мозгу возникает требуемая для интеграции контуров архитектура связей. Кроме того, модель не объясняет тот факт, что качество выполнения интеграции падает при перемещении объекта от центра к периферии зрительного поля. В статье [30]

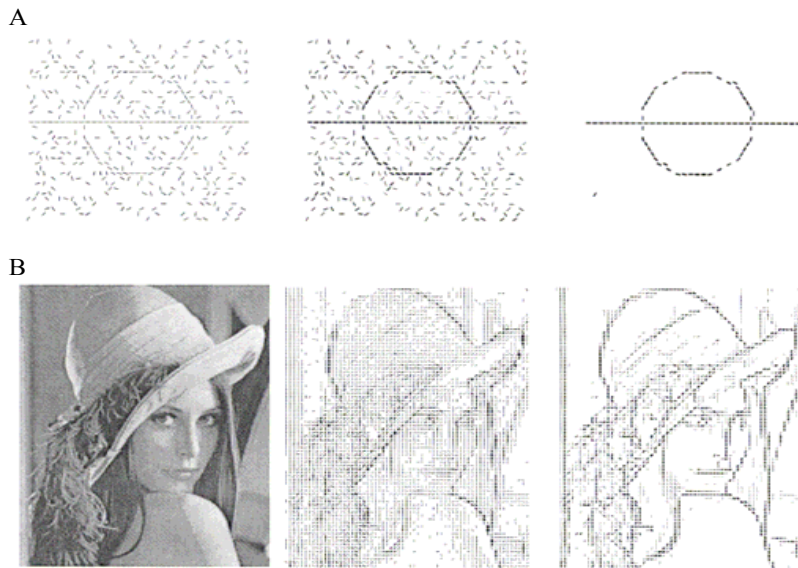


Рис. 1. Примеры обработки контурных изображений моделью Ли. Здесь: **А.** Слева — изображение на входе модели. В центре — активность нейронов на выходе модели. Справа — активность нейронов на выходе модели после обрезания активности на уровне 0,63 от максимальной. **В.** Слева — исходное изображение. В центре — изображение на входе модели. Справа — активность на выходе модели. (Воспроизведено по работе [24]).

предлагается усовершенствованная модель, позволяющая увеличить охват экспериментальных данных на основе зависящей от входных сигналов самоорганизации латеральных связей. Более ранняя версия модели, названная RF-SLISSOM (Receptive Field Spiking Laterally Interconnected Synergetically Self-Organizing Map), была описана в работе [31]. Модель оперирует непосредственно с интенсивностями пикселей без явного использования нейронов с ориентационной селективностью. Никакой заранее заданной упорядоченности при определении величин связей не предполагается. Модель автоматически формирует сильные латеральные связи между нейронами, получающими сигналы от линий со сходной ориентацией.

Базовым элементом модели является интегративно-пороговый импульсный нейрон с уткой Эхорна [32], работающий в дискретном времени. На каждом синапсе нейрона происходит суммирование приходящих импульсов при экспоненциальном затухании постсинаптического потенциала

$$s(t) = x(t) + s(t-1)e^{-\lambda},$$

где $s(t)$ и $s(t-1)$ — постсинаптические потенциалы в моменты времени t и $t-1$; $x(t)$ — амплитуда входного импульса; λ — параметр затухания. Для разных связей величина λ может быть различной. Подбирая подходящие значения для λ , можно превратить нейрон в детектор совпадения (λ велико) или во временной интегратор (λ мало).

Мембранный потенциал нейрона m формируется как результат действия кусочно-линейной сигмообразной функции на взвешенную сумму постсинаптических потенциалов. Нейрон генерирует импульс в момент времени, когда его мембранный потенциал превышает порог. Величина порога складывается из трех компонент. Первая из них является константой (базовый порог). Вторая задает период абсолютной рефрактерности. Третья реализует относительную рефрактерность и представляет собой функцию, экспоненциально убывающую со временем, прошедшим после последней генерации импульса. При постоянном входном сигнале нейрон работает как осциллятор, частота импульсов которого тем выше, чем больше входной сигнал.

Архитектура связей в модели представлена на рис. 2. Нейронная сеть состоит из двух плоских слоев, называемых картами, MAP1 (136×136 нейронов) и MAP2 (54×54 нейронов)¹. Нейроны в обоих слоях с идентичными координатами образуют кортикальную колонку. Нейроны из одной колонки имеют совпадающие рецептивные поля. Каждый нейрон способен формировать как возбуждающие, так и тормозные сигналы. Входными сигналами на нейрон являются: 1) афферентные возбуждающие сигналы от элементов рецептивного поля (пикселей сетчатки), 2) возбуждающие сигналы от соседних нейронов другой карты, 3) латеральные возбуждающие и тормозные сигналы от соседних нейронов своей карты. Внешние сигналы от сетчатки с размерами 46×46 или 72×72 , поступающие на нейроны обеих карт, варьируют в интервале $(0, 1)$. Рецептивное поле нейрона имеет размер 6×6 .

¹Мар по-английски — карта.




Рис. 2. Архитектура связей модели Чое-Миккулайнена. *Односторонние стрелки* — восходящие афферентные связи между слоями. *Двусторонняя стрелка* — связи внутри колонки. Латеральные связи внутри карт: *серый цвет* — возбуждающие и тормозные связи, *белый цвет* — тормозные связи. (Воспроизведено по работе [30]).

Карта MAP1 предназначена для самоорганизации сети и превращения ее в упорядоченную структуру. Нейроны в MAP1 первоначально имеют латеральные возбуждающие связи радиуса 7, порождающие дальний порядок, но этот радиус постепенно сокращается до 3, уточняя локальный порядок. Тормозные связи в MAP1 имеют фиксированный радиус 10.

Карта MAP2 предназначена для реализации сегментации и байндинга. В MAP2 возбуждающие латеральные связи имеют радиус 40, а тормозные связи имеют глобальный характер (все-на-всех). Благодаря тормозным связям тенденция к сегментации элементов сети заложена в самой конструкции модели, а для того, чтобы имело место связывание на основе синфазной активности, необходимо действие возбуждающих связей, соответствующая активность в которых порождается входным изображением.

За исключением латеральных тормозных связей в MAP2 веса всех остальных связей модифицируются в соответствии с правилом Хебба с нормализацией

$$w_{ij}(t) = \frac{w_{ij}(t-1) + \alpha V_i(t)V_j(t)}{\sum_k [w_{kj}(t-1)] + \alpha V_k(t)V_j(t)},$$

где w_{ij} — величина связи от нейрона j к нейрону i ; α — параметр, задающий скорость обучения; V_i и V_j — усредненные (в пределах небольшого временного окна) частоты импульсации нейронов. Нормализация препятствует неограниченному росту величины связи. Скорость обучения зависит от типа связи. Кроме того, различные значения α используются на этапах обучения и тестирования модели. Так, обучение разделено на две стадии с высокими и низкими значениями α . Это позволяет стабилизировать глобальный порядок в картах на финальном этапе обучения. Во время тестирования используются большие значения α для латеральных возбуждающих связей, что способствует надежной синхронизации между нейронами, стимулируемыми одним зрительным объектом.

При обучении (40000 предъявлений различных изображений) в качестве входных изображений использовались объекты (полоски) эллипсоидальной формы, расположенные на белом фоне. Распределение интенсивности внутри каждого эллипса гауссовское (от черного в центре до серого на краях). Соотношение большого и малого радиусов эллипса принималось $a^2 = 15$, $b^2 = 0.6$ на начальном этапе обучения, а в дальнейшем $a^2 = 45$, $b^2 = 0.45$. Каждый такой объект перекрывал несколько рецептивных полей. Объекты располагались в случайных местах зрительного поля

и имели случайную ориентацию. В ходе обучения нейроны постепенно становились чувствительными к определенной ориентации объекта, расположенного в их рецептивном поле. В конце концов в модели возникала глобальная ретинотопическая карта предпочтительных ориентаций, почти идентичная для обоих слоев и сходная с той, которая имеется в зрительной коре. После обучения латеральные связи с низкими значениями весов были удалены. При этом оказалось, что оставшиеся латеральные возбуждающие связи имеют ту же архитектуру, которая была постулирована в модели Ли. Однако следует отметить, что, в отличие от модели Ли, тормозные связи в MAP2 имеют одинаковый вес.

Работоспособность модели тестировалась на изображениях, содержащих набор из 9 коротких эллипсоидальных полосок (соотношение большого и малого радиусов $a^2 = 3.5$, $b^2 = 1.5$) (рис. 3). Размер полоски достаточно мал, чтобы она помещалась в рецептивном поле одного из нейронов. Полоски располагались в различных местах зрительного поля и имели различную ориентацию. На каждом изображении имелись три более или менее коллинеарных полоски (точность выполнения условия коллинеарности была различной для разных изображений) с небольшими пробелами фона между каждой из пар полосок. Предполагалось, что эти полоски образуют участок контура. Остальные 6 полосок имели случайную ориентацию и играли роль шума.



Рис. 3. Примеры изображений, использовавшихся для тестирования модели Чое–Миккулайнена. Полоски, образующие линию, обведены пунктирной линией. (Воспроизведено по работе [30]).

Целью компьютерных экспериментов было проверить, как влияет точность задания коллинеарности контурных полосок на уровень корреляции стимулируемых ими нейронов. Для этого для каждой полоски вычислялась множественная нейронная активность (МНА), определяемая как число импульсов, генерируемых нейронами, расположенными в области, занимае-

мой этой полоской. Было показано, что в случае высокой коллинеарности полосок соответствующая им внеклеточная МНА почти идеально синхронна (синфазна). Синхронизация падает по мере ухудшения коллинеарности полосок, образующих контур. В случае случайной ориентации полосок синхронизация отсутствует.

В других экспериментах была обнаружена высокая корреляция между степенью синхронизации МНА и способностью человека к идентификации соответствующих контуров на изображении. Если изображение содержит два контура с разной ориентацией (каждый из которых представлен тремя коллинеарными полосками), то при предъявлении изображения сначала возникает синхронная (синфазная) активность во всех активируемых нейронах, но позднее формируется два кластера МНА, работающих в противофазе.

Из экспериментальных данных известно, что качество выполнения сегментации контуров различно в центре поля зрения и на периферии, а также в верхней и нижней зрительных полусферах. Для их объяснения были выдвинуты две гипотезы: эти различия могут быть следствием различий в (1) частоте предъявления различных изображений при обучении, (2) типе варибельности обучающей выборки. Эти гипотезы проверялись двояким образом. В первом эксперименте объекты при обучении предъявлялись в одной области в два раза чаще, чем в другой. Во втором эксперименте углы ориентации полосок в обучающей выборке варьировались равномерно и случайно в интервале $[0^0, 10^0]$ в одной области и $[0^0, 25^0]$ в другой. Как можно было ожидать, эксперименты показали, что группировка с помощью синхронизации более надежна там, где имеет место более интенсивное обучение и где разнообразие предъявляемых углов ориентации выше. Последнее особенно значимо для правильной группировки полосок с неидеальной коллинеарностью.

Модель Ю-Жанга

Еще один подход к сегментации контуров предложен в работе [33]. В значительной мере в нем воспроизведены основные черты модели Ли — трехмерная сеть нейронов, чувствительных к ориентации, сгруппированная в гиперколонки, локальные горизонтальные связи и т. д., но в дополнение к зрительным сигналам, поступающим от рецептивного поля, на нейроны приходят сигналы от областей, моделирующих верхние зоны коры. Эти сигналы используются для выбора определенного контура из набора одно-

временно заданных контуров, на которые, кроме того, наложен еще дополнительный шум. Другим отличием данной модели от модели Ли является использование в качестве базовых элементов не формальных осцилляторов, а импульсных нейронов, сходных с теми, что фигурировали в модели Чое-Миккулайнена.

Нейроны получают два сигнала: периодическую (с периодом σ) последовательность импульсов от входного зрительного канала и нисходящие сигналы, кодирующие априорную информацию о выбираемом контуре. Априорная информация задается в виде последовательности кодов. Например, если контур состоит из сегментов (полосок) с ориентациями $0, \pi/4, \pi/2, 3\pi/4, \dots$, то нисходящие импульсы будут посылааться параллельно на все нейроны с предпочтительной ориентацией 0 , затем (после временной задержки σ) импульсы будут посылаяться на все нейроны с предпочтительной ориентацией $\pi/4$, еще позднее — на все нейроны с ориентацией $\pi/2$ и т. д. Таким образом, длина нисходящей импульсной последовательности равна числу отрезков в контуре L , а активность нейронной сети имеет период $L\sigma$.

Идея, положенная в основу функционирования модели, — это детекция временного совпадения импульсов при наличии синаптических задержек. Предполагается, что константа временной задержки при обмене сигналами между нейронами равна σ . Вследствие этого генерируемая нейроном активность будет распространяться на соседние клетки, но только в том случае, если они получают подходящий нисходящий сигнал, то есть если контур данного объекта соответствует контуру, заданному априори. Рассогласование между кодирующей априорной последовательностью и реальной ориентацией контурного сегмента немедленно прервет «рост» контура.

Обсуждение

Подведем итоги данного раздела. Модель Ли отражает анатомические и нейрофизиологические данные о функционировании первичных зон зрительной коры и является хорошей основой для дальнейшего развития моделей сегментации контурных изображений. Усовершенствование модели, предложенное *Й. Чое* и *Р. Миккулайненом* и связанное с автоматическим формированием связей в процессе обучения и функционирования, представляется шагом в перспективном направлении, позволившем включить в модель ряд новых экспериментальных данных. Однако использованные для тестирования модели изображения являются достаточно условными. В

работе не приводится каких-либо результатов сегментирования контуров естественных изображений. Модель Ю-Жанга кажется наиболее спорной, поскольку ее функционирование неустойчиво при наличии шумов и деформаций контуров. Кроме того, представляется правдоподобным, что сегментация контуров может в значительной степени осуществляться автономно первичными зонами зрительной коры без влияния более высоких зон, что противоречит постулатам этой модели. Тем не менее, идея о выборе определенного объекта по информации о его признаках, поступающей сверху вниз, является плодотворной и в несколько других условиях возникает в моделях, которые будут рассмотрены далее (см. раздел «Сегментация и когнитивные функции мозга», с. 78). Отметим, что класс изображений, с которыми работают существующие контурные модели, является сравнительно узким, а успешных результатов по обработке этими методами достаточно сложных естественных изображений пока что нет.

Сегментация пиксельных изображений

В нейросетевых моделях имеется два популярных подхода к решению задачи сегментации изображений путем формирования синфазных нейронных ансамблей, кодирующих разные объекты. В соответствии с первым подходом такие ансамбли формируются одновременно, то есть несколько несинфазных или даже несинхронных между собой ансамблей сосуществуют в одной нейронной сети. При этом когерентность между нейронами одного ансамбля служит меткой, позволяющей реализовать связывание признаков объектов на последующих этапах обработки информации. Согласно второму подходу синфазные ансамбли, кодирующие объекты, возникают последовательно (в детерминированном или случайном порядке), так что в каждый момент времени существует лишь один синхронно работающий ансамбль нейронов с высоким уровнем активности, в то время как активность в других частях нейронной сети временно подавлена до низкого уровня.

Параллельные процедуры. Модель Опара–Вёргёттера

В случае параллельных процедур задача сегментации изолированных объектов, контрастно выделяющихся из фона, представляется достаточно тривиальной. Она решается путем задания локальных синхронизирующих связей

в однослойной сети. Десинхронизация между различными ансамблями наступает за счет действия шумов или за счет дальних десинхронизирующих связей. Конечно, для разработки модели с биологически правдоподобными элементами и с реальными временными характеристиками надо приложить определенные усилия, но принципиальных трудностей на этом пути нет. В связи с этим основное внимание исследователей обращено на работу с реальными изображениями, где объекты могут пересекаться и где нет четкой границы между соседними объектами, а также между объектами и фоном.

Один из наиболее успешных примеров такого рода моделей предложен в работе [34]. Элемент модели описывается дискретной переменной, называемой спином, с конечным числом состояний. Для краткости будем и сами элементы называть спинами. Имеется взаимнооднозначное соответствие между спинами и пикселями изображения. Информация об изображении преобразуется в величины взаимодействия между спинами, зависящие от разности интенсивностей соответствующих пикселей. Динамика модели формулируется в терминах минимизации функции энергии.

Спины расположены в узлах двумерной решетки размером $N = L_x L_y$ с локальными связями между спинами. Каждый спин w может принимать q различных состояний. Номер состояния рассматривается как метка спина. Целью сегментации является такое распределение меток, чтобы разным объектам были присвоены различные метки, а все спины, представляющие один объект, имели одну и ту же метку. Конфигурацией сети называется набор состояний (меток) всех ее спинов $W = \{w_1, \dots, w_N\}$. Глобальная энергия конфигурации W определяется как

$$E(W) = \sum_{i=1}^N (K_i - \sum_{j \in N_i} J_{ij} \delta_{w_i w_j}),$$

где w_i, w_j — метки спинов i и j , соответственно; J_{ij} — сила взаимодействия между спинами i и j ; $\delta_{w_i w_j} = 1$, если $w_i = w_j$, в противном случае $\delta_{w_i w_j} = 0$; N_i — окрестность спина i радиуса Δ ; K_i — величина, описывающая глобальное ингибирование, гарантирующее, что удаленным объектам будут присвоены различные метки:

$$K_i = \frac{\alpha}{N} \sum_{j=1}^N \delta_{w_i w_j},$$

где α — положительный параметр.

Значения J_{ij} задаются таким образом, что позитивная сила связи соответствует пикселям со сходными значениями интенсивности, а отрицательная сила связи соответствует пикселям, интенсивности которых значительно различаются:

$$J_{ij} = 1 - \frac{|g_i - g_j|}{\Theta},$$

где g_i и g_j — интенсивности пикселей, Θ — определенным образом усредненное значение разностей интенсивностей.

Традиционные процедуры спиновой динамики с локальными связями имеют низкую скорость адаптации. Кроме того, необходимо бывает принимать специальные меры (типа имитации отжига) для избегания локальных минимумов. Для преодоления этих трудностей авторы предлагают подход, сочетающий алгоритм с локальным взаимодействием и алгоритм кластеризации.

Начальным состоянием модели является случайное распределение меток спинов. Идентичные спины объединяются в кластеры. Формирование кластера имеет стохастическую природу и зависит от температуры T . Если T высока, средняя величина кластера мала. Если T низка, возможный размер кластера увеличивается. Таким образом, температура является параметром, управляющим числом сегментируемых объектов на изображении. После завершения формирования кластеров начинает работать алгоритм модификации кластеров. Для каждого кластера вычисляется функция энергии, зависящая от окружения этого кластера и температуры. Далее метки всех спинов в кластере одновременно устанавливаются так, чтобы удовлетворять гиббсовскому распределению энергии кластера. В каждый момент времени происходит модификация одного кластера при фиксированных метках соседних кластеров.

Этот алгоритм был назван энергетической модификацией кластеров (ЭМК). Для улучшения работы ЭМК авторы вводят зависящие от величины интенсивности пикселей задержки в передаче сигналов от пикселей к спинам (яркие пиксели обрабатываются раньше, чем темные пиксели) [35]. Это гарантирует одновременную активацию спинов, представляющих пиксели со сходными значениями интенсивности. Предполагается, что сила взаимодействия между спинами равна нулю до того момента, когда они получают внешний сигнал. Таким образом, в рассматриваемой системе происходит преобразование структуры интенсивностей во временную структуру входных данных, что в свою очередь оказывает влияние на ход

вычисления энергии кластеров и, соответственно, на формируемую структуру спиновых меток.

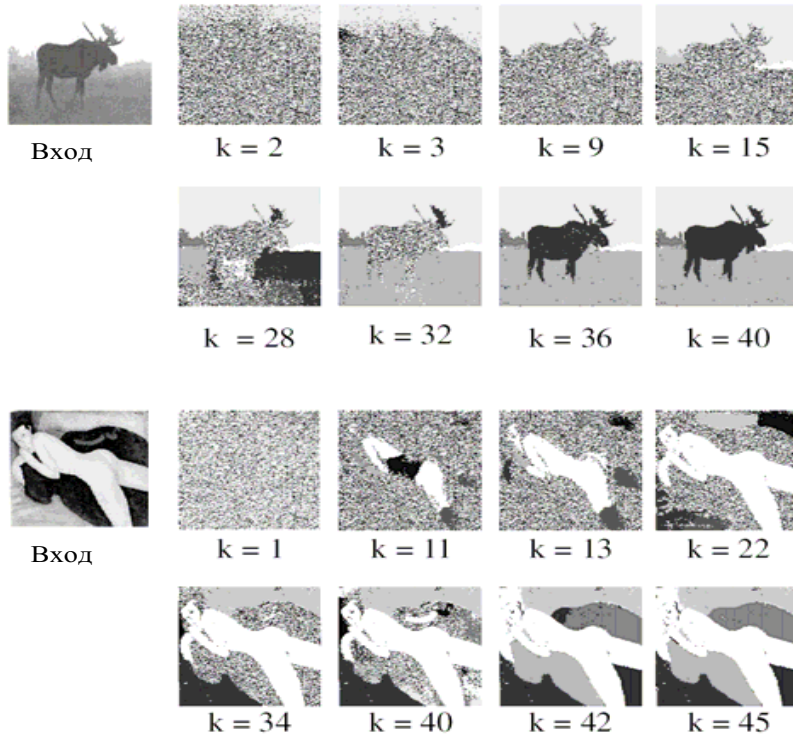


Рис. 4. Результаты сегментации на различных итерациях работы модели Опара–Вёргёттера. Входное изображение 128×128 пикселей. (Воспроизведено по работе [35]).

ЭМК тестировалась на синтетических и реальных изображениях (рис. 4). Было показано, что ее характеристики (быстродействие, качество сегментации, устойчивость к шумам, способность восстанавливать детали изображения) превосходят известные из работ по искусственному интеллекту алгоритмы, использующие локальную информацию, и алгоритмы, основанные на модификации кластеров. В частности, при низкой температуре для сегментации изображения бывает достаточно всего нескольких десятков

итераций ЭМК.

Последовательные процедуры. Модели типа LEGION

В отличие от модели, представленной в разделе «Параллельные процедуры. Модель Опара–Вёртгёттера» (см. с. 54), в которой метки, присваиваемые сегментам изображения, носят формальный характер, в данном разделе мы рассмотрим более традиционный для динамических нейронных сетей подход к сегментации, основанный на колебаниях и синхронизации нейронной активности. Последовательная сегментация в данном случае означает, что в какой-то период времени в модели возникает синхронно работающий ансамбль осцилляторов с высокой активностью, геометрия которого совпадает с геометрией одного из объектов на входном изображении. В следующий период времени в сети возникает другой синхронный ансамбль, соответствующий другому объекту, и т. д. Последовательность, в которой осуществляется сегментация, обычно имеет стохастический характер с большим приоритетом для объектов с определенными геометрическими или спектральными свойствами. Например, объекты выбираются в порядке убывания их площади, причем совсем маленькие объекты игнорируются как шум.

Для реализации конкуренции между нейронными ансамблями, соответствующими сегментируемому объектам, имеется две возможности. Первая — это использовать дальнедействующие тормозные связи. Однако при большом числе элементов в сети это приводит к слишком большому числу связей. Другая возможность — использовать специальный центральный элемент, играющий роль глобального тормозного элемента (global inhibitor), связанного со всеми элементами сети. В этом случае число связей в сети имеет тот же порядок, что и число элементов. Данный принцип реализован в модели, называемой LEGION (Locally Excitable, Globally Inhibitory Oscillator Network) [16, 36–39]. Первоначальный вариант модели был рассчитан на работу с изолированными черными объектами на белом фоне. Позднее авторы вносили в базовую модель различные усовершенствования, позволившие сегментировать достаточно сложные полутоновые изображения.

В сети LEGION осцилляторы расположены в узлах плоской решетки, так что каждый осциллятор ассоциирован с одним пикселем на входном изображении. Между осцилляторами имеются локальные возбуждающие связи, сила которых убывает по мере увеличения расстояния между ос-

цилляторами. С помощью этих связей формируются ансамбли синхронно работающих осцилляторов. В сети имеется также глобальный тормозный элемент (ГТЭ), предназначенный для реализации конкуренции между ансамблями осцилляторов и препятствующий глобальной синхронизации всех элементов сети.

Элементом модели является модифицированный релаксационный осциллятор Ван-дер-Поля, динамика которого описывается следующими уравнениями (для упрощения обозначений индекс, показывающий номер осциллятора, опущен всюду, где это не приводит к недоразумениям)

$$\frac{dx}{dt} = 3x - x^3 + 2 - y + R + S + \rho,$$

$$\frac{dy}{dt} = \varepsilon(\alpha(1 + \tanh(\beta x)) - y).$$

Здесь R — величина, зависящая от внешнего входа (сигнала от пикселя), модулируемого сигналами от соседних осцилляторов, S — интегральный сигнал от соседних осцилляторов и ГТЭ, ρ — гауссовский шум, α, β — положительные параметры, $0 < \varepsilon \ll 1$ — малый параметр, обеспечивающий генерацию релаксационных колебаний.

Активность ГТЭ определяется как

$$\frac{dz}{dt} = \phi(\sigma_\infty - z),$$

где $\sigma_\infty = 1$, если величина x превосходит порог θ_z для хотя бы одного осциллятора, в противном случае $\sigma_\infty = 0$; $\phi \gg \varepsilon$ — параметр.

Рассмотрим изолированный осциллятор без шума при фиксированной величине члена R . Заметим, что x -нульклина — кубическая функция, а y -нульклина — сигмоидальная функция (рис. 5). Если $R > 0$, обе нульклина пересекаются в единственной неустойчивой точке, расположенной в средней части кубической кривой. Это приводит к появлению устойчивого предельного цикла, в котором переменная x принимает то высокие (**активная фаза**), то низкие (**фаза молчания**) значения. Параметры осциллятора выбраны таким образом, что в течение каждой из фаз величина x меняется медленно, а при переходе от одной фазы к другой изменение происходит практически скачком. Если $R \leq 0$, нульклина пересекаются на левой ветви кубической кривой в двух точках, одна из которых устойчивая. В этом случае периодические колебания становятся невозможными. Осциллятор стабилизирует свою активность при низких значениях x .

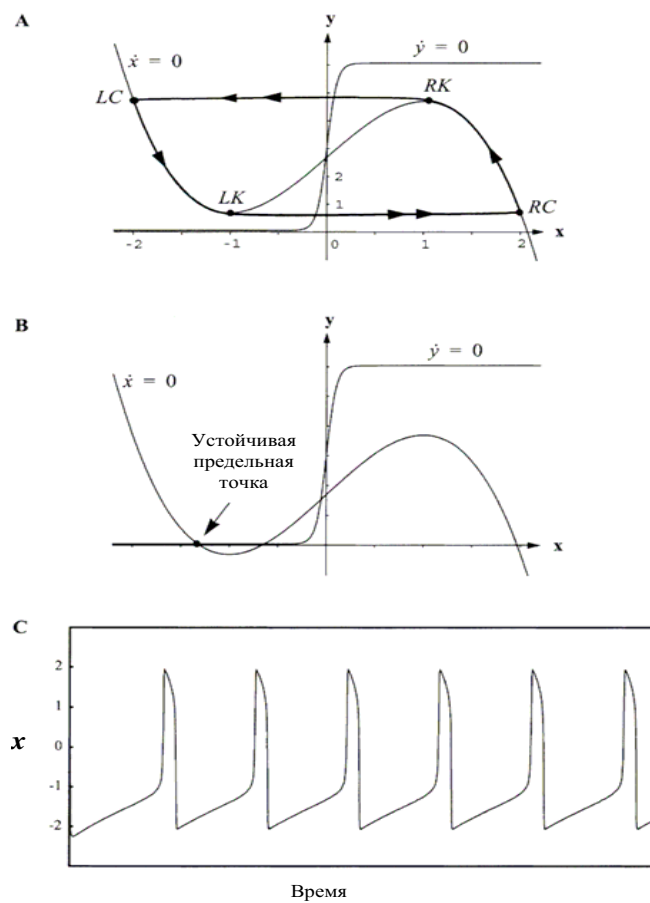


Рис. 5. Фазовый портрет и траектория осциллятора Ванга–Термана. Здесь: **А.** Осцилляторный режим. Кривая $LC - LK - RC - RK$ показывает предельный цикл осциллятора. **В.** Стационарный режим осциллятора. **С.** Траектория переменной x . (Воспроизведено по работе [39]).

Синфазные ансамбли формируются в сети благодаря локальным связям между осцилляторами. Введенный в модель ГТЭ играет роль устройства, определяющего моменты времени, когда ансамбль осцилляторов становится активным или переходит в фазу молчания. Ансамбли конкурируют за влияние, оказываемое на ГТЭ, в то же время стараясь избежать обратного тормозного воздействия. Ансамбль большего размера и с более быстро растущей активностью имеет больший шанс «победить» в этой конкуренции. В течение определенного временного интервала активность этого ансамбля остается высокой, а активность других ансамблей подавляется ГТЭ до уровня молчания. Однако такое состояние системы не длится долго. Благодаря действию ГТЭ, активность во всей сети падает до низкого уровня, вследствие чего активность ГТЭ падает до 0, и далее процесс конкуренции начинается заново с тем, чтобы привести к «победе» другой ансамбль осцилляторов. Параметры взаимодействия осцилляторов с ГТЭ подобраны следующим образом: тот ансамбль, который был активен, подвергается со стороны ГТЭ настолько сильному торможению, что не может участвовать в конкуренции в течение времени, достаточного для последовательной активации остальных ансамблей. Это позволяет системе последовательно активировать различные ансамбли осцилляторов. Стохастический характер порядка выбора объектов обусловлен наличием шума.

Какие именно ансамбли формируются в сети, зависит от задания членов R и S , поэтому основные усилия разработчиков модели были направлены на такое задание этих величин, чтобы адаптировать процесс формирования ансамблей к сегментации реальных изображений в присутствии шума. Численные эксперименты показали, что константные значения R и S (зависящие исключительно от входного изображения) не дают качественной и устойчивой сегментации. В связи с этим как для внешних сигналов, так и для величин связей были использованы адаптируемые переменные. Ключевым в этой связи явилось понятие «лидера», введенное в работе [37]. Лидер — это осциллятор, расположение которого в сети соответствует центру достаточно большой гомогенной области изображения. Фрагмент изображения, порожденный шумом, не содержит лидера. Лидер получает значительное возбуждение от соседних осцилляторов, переходит в активное состояние и становится ядром, из которого начинается формирование связанного ансамбля активных осцилляторов. Активное состояние распространяется по осцилляторам от лидера к границам сегментируемой области, и там распространение останавливается благодаря подобранным величинам связей. Член R ответственен за идентификацию лидеров, а член S

определяет структуру величин связей.

Развитие модели претерпело несколько модификаций, отличающихся тем, как задавались значения R и S . Ниже приводится последний из опубликованных авторами вариантов [39].

Для определения осцилляторов-лидеров вводится бинарная переменная p :

$$p = H(T_p - \sigma_{N_p}),$$

где H — функция Хевисайда

$$H(v) = \begin{cases} 1, & v \geq 0; \\ 0, & v < 0. \end{cases}$$

Здесь T_p — порог, σ_{N_p} — стандартное отклонение, описывающее уровень гомогенности в квадратной окрестности N_p размера $(2\rho + 1) \times (2\rho + 1)$ вокруг данного пикселя (T_p и ρ — фиксированные параметры).

Переменная R определяется как

$$R = Ip,$$

где I — интенсивность пикселя.

Переменная S определяется как

$$S = WH \left(\sum_{k \in N_1} H(x_k) - 0.5 \right) - W_z H(z - \theta_z),$$

где H — функция Хевисайда; W — динамический вес, задающий силу влияния на данный осциллятор его ближайшей окрестности N_1 ; W_z — сила тормозного воздействия на осциллятор; θ_z — порог (W_z и θ_z — фиксированные параметры).

Переменная W — бинарная: $W = 1$, если в текущий момент времени пиксель идентифицируется как лежащий внутри сегментируемой области, $W = 0$, если пиксель идентифицируется как принадлежащий границе. Значение W вычисляется в два этапа. Сначала для каждого пикселя определяются 4 специальные окрестности (одна из них фиксированная, а три других динамические), которые зависят от распределения активных и молчащих осцилляторов в окрестности данного осциллятора. Затем для этих окрестностей вычисляются средние и стандартные отклонения интенсивностей. Значение W вычисляется как функция этих величин. Дополнительно те

же величины используются для вычисления значений непрерывной переменной $u \in (0, 1)$, которая показывает, принадлежит ли данный пиксель внутренней части сегментируемой области или расположен вблизи границы. В свою очередь, u влияет на формирование окрестностей пикселя на следующем шаге итерации.

При фиксированных значениях параметров число сегментов, которые способна сформировать сеть LEGION, не велико. Более или менее надежной работы модели можно добиться при числе сегментируемых объектов, не превышающем 5–7. На самом деле, это число определяется отношением периода колебания в сети (время просмотра всех объектов) ко времени активной фазы для одного объекта. Для увеличения числа сегментируемых объектов авторы рекомендуют применение иерархической модели, состоящей из нескольких сетей LEGION, в которой сначала выполняется грубая сегментация, которая затем делается более детальной путем дальнейшего дробления составных объектов. Предложена также алгоритмическая реализация сети LEGION, в которой ограничения на число сегментируемых объектов сняты.

Многочисленные эксперименты по сегментации изображений с помощью сети LEGION включали в себя искусственные изображения с высоким уровнем шумов, магниторезонансные томограммы мозга, аэрофотоснимки гидрографических объектов и др. Полученные результаты сегментации сравнивались с традиционными методами сегментации, основанными на адаптивных методах и нелинейном сглаживании [40–41]. Было продемонстрировано, что LEGION не уступает в качестве сегментации этим методам, а в ряде случаев дает лучшие результаты. Примеры сегментации с помощью сети LEGION приведены на рис. 6.

Модель сегментации, предложенная в работах [42–43], во многих отношениях сходна с сетью LEGION. В ней также используются принципы локального возбуждающего и глобального тормозного действия на элементы системы. Отличие состоит в том, что в данной модели сегментация объектов и группировка пикселей внутри каждого объекта рассматриваются как относительно независимые операции. В связи с этим, модель соединяет в себе традиционные алгоритмы компьютерного зрения для выполнения сегментации объектов и методы синхронизации колебаний для формирования когерентных нейронных ансамблей, представляющих объекты в сети.

Модель имеет два слоя элементов. Первый слой формируется из неосцилляторных элементов и предназначен для выделения контуров объектов. Второй слой реализует интеграцию пикселей на основе временной корре-




Рис. 6. Сегментация аэрофотоснимков гидрографических объектов моделью Чена–Ванга. Здесь: **A.** Изображение 640×640 пикселей. **B.** Результат сегментации изображения **A.** **C.** Изображение 378×670 пикселей. **D.** Результат сегментации изображения **C.** (Воспроизведено по работе [39]).

ляии. В качестве второго слоя используется упрощенный вариант сети LEGION с постоянными величинами связей между элементами. Информация о контурах, получаемая в первом слое, используется для подавления взаимодействия между ансамблями осцилляторов, представляющих различные объекты с тем, чтобы не допустить глобальную синхронизацию всей сети. Для улучшения и ускорения синхронизации используются как возбуждающие, так и тормозные связи между соседними осцилляторами.

Выходной сигнал ГТЭ описывается выражением

$$z = A \left[\text{sign} \left(\sum_{i=1}^N x_i - \theta \right) + 1 \right],$$

где x_i — состояние возбуждающего элемента i -го осциллятора, θ — порог, A — сила глобального торможения.

Контурные объекты, вычисленные в первом слое, используются как сильные тормозные сигналы, идущие вертикально снизу вверх на осцилляторы второго слоя. Эти сигналы подавляют осцилляторную активность «контурных» осцилляторов, создавая таким образом изолированные (не взаимодействующие друг с другом) ансамбли осцилляторов, соответствующие отдельным объектам на изображении.

В работе [43] было показано, что результаты сегментации существенно зависят от параметров ГТЭ A и θ . Например, высокие значения обеих величин A и θ могут привести к тотальному подавлению активности маленьких по размеру ансамблей осцилляторов, в то время как комбинация высокого значения θ с низким значением A позволяет маленьким ансамблям активироваться одновременно, формируя диффузно распределенный объект. Низкие значения A и θ должны использоваться, если мелкие детали изображения представляют важность, однако в этом случае возникает опасность, что некоторые маленькие ансамбли будут активироваться одновременно с каким-то большим ансамблем.

Используя традиционные алгоритмы выделения контуров, основанные на гауссовских фильтрах, авторы показали, что модель успешно работает на искусственных изображениях с высококонтрастными объектами.

Обсуждение

Вопрос о том, какие механизмы сегментации, последовательные или параллельные, используются мозгом, на экспериментальном уровне не решен. В

связи с этим оба класса моделей имеют право на существование. Вполне возможно, что оба механизма задействованы мозгом. Параллельный соответствует предвнимательной обработке информации, а последовательный имеет место при наличии внимания [44–45]. Если эта гипотеза верна, то параллельные методы должны быть менее точными, но более быстрыми. К сожалению, на уровне имеющихся модельных разработок проверить эту гипотезу не представляется возможным, поскольку существующие модели оперируют разнородными формальными элементами, конструкция которых далека от биологических нейронов.

Модели Опара–Вёргёттера и Ванга с соавторами являются в настоящее время наиболее продвинутыми и успешными в анализе реальных изображений по сравнению с другими моделями в своем классе методов (параллельных или последовательных). Очевидное их отличие состоит в том, что модель Опара–Вёргёттера носит абстрактный характер, для ее нейронной реализации потребуются значительные дополнительные усилия, в то время как LEGION стремится, по возможности, соответствовать нейробиологическим механизмам работы мозга. С точки зрения алгоритмической эффективности основным недостатком модели Опара–Вёргёттера является то, что она рассчитана на класс изображений, в которых каждый индивидуальный объект содержит пиксели со сходными оптическими характеристиками. Это далеко не всегда имеет место в реальности.

Параллельные методы сегментации в традиционном нейронно-сетевом оформлении предлагались в работах [46–47]. Изложение этих работ имеется в обзоре [23]. К сожалению, несмотря на то, что модели Кёнига с соавторами были приближены к биологической реальности и соответствовали ряду экспериментальных данных, авторы ограничились лишь применением их к сегментации простых искусственных изображений. Продолжения эти работы не получили, по всей видимости, из-за громоздкости моделей.

Модель Чена–Ванга была получена в результате многолетних усилий по усовершенствованию принципов функционирования сети LEGION. В ранних вариантах модели взаимодействие между двумя соседними осцилляторами зависело только от значений интенсивности соответствующих пикселей [37]. Однако оказалось, что качество сегментации существенно повышается при непарном локальном взаимодействии осцилляторов [39]. Плата за это — высокая сложность модели и отсутствие биологической аргументации в поддержку ряда используемых механизмов. В частности, модификация силы связей, по-видимому, предполагает наличие быстро модифицирующихся синапсов, существование которых в мозгу до сих пор

остаётся дискуссионным. Проверка соответствия модели временным характеристикам реальных процессов сегментации также не представляется возможной из-за выбранной конструкции осциллятора.

Модификация сети LEGION, предложенная Урсино с соавторами, как будто бы сильно упрощает конструкцию Чена–Ванга. На самом деле, эта модель просто переносит цент тяжести решаемой задачи на процедуру выделения контуров, так что качество работы всей системы радикально зависит от качества реализации этой процедуры. К сожалению, известные методы выделения контуров не являются идеальными. На реальных изображениях получаемые с их помощью контуры могут не быть замкнутыми и иметь неравномерную толщину. Кроме того, они могут порождать ложные контурные фрагменты по всему изображению. Для преодоления этих трудностей требуются достаточно сложные процедуры, что существенно уменьшает привлекательность данного подхода. Однако этот подход может оказаться весьма перспективным, если процедура улучшения и фильтрации «сырых» контуров будет реализована не методами искусственного интеллекта, а на осцилляторных нейронных сетях с использованием тех же механизмов, что и в существующих моделях. Такая задача кажется вполне разрешимой.

Сегментация и кластеризация

Кластеризация — это процедура, позволяющая сгруппировать дискретное множество точек P в многомерном пространстве S в компактные классы (кластеры) на основе определенной в S метрики (расстояния между точками). Термин кластеризация употребляется как синоним классификации без учителя, поскольку предполагается, что задача кластеризации должна решаться без какой-либо априорной информации о принадлежности точек к классам. Задача сегментации может быть сведена к задаче кластеризации следующим образом. Поставим в соответствие каждому пикселю вектор его оптических характеристик (признаков). Тогда, после выбора подходящей метрики в пространстве S таких векторов, проведение их кластеризации даст некоторое решение задачи сегментации. Пиксели, расположенные близко друг к другу и имеющие сходные характеристики, будут иметь приоритет по включению в один и тот же кластер и, следовательно, в один и тот же сегмент изображения. Успешность сегментации будет зависеть как от введенной метрики, так и от алгоритма кластеризации.

Какова связь этих общих соображений с осцилляторными нейронными сетями? Дело в том, что синхронизация колебаний дает удобный способ реализации кластеров. Поставим в соответствие каждой точке P осциллятор и введем в сети из этих осцилляторов взаимодействие таким образом, чтобы осцилляторы, соответствующие близко расположенным точкам в S , были связаны синхронизирующими связями, а осцилляторы, соответствующие удаленным точкам из S , были связаны десинхронизирующими связями. Тогда динамика активности в сети автоматически приведет к формированию синхронных ансамблей осцилляторов, представляющих компактные кластеры точек в S .

Модель Роума-Фригуи

Эти идеи были применены к сегментации изображений в работе [48]. Авторы ее не слишком заботились о биологической правдоподобности модели. Их целью было выяснить, насколько осцилляторные нейронные сети могут быть эффективными при сегментации изображений. В качестве элементов модели были выбраны так называемые фазово-импульсные элементы. Это было обусловлено тем, что сети из таких элементов (pulse-coupled neural networks — PCNN) являются популярным объектом нейросетевого моделирования и уже зарекомендовали себя как эффективное средство при решении задач по анализу изображений [49].

Фазово-импульсный осциллятор описывается уравнением [50]

$$x = f(\phi),$$

где x — состояние осциллятора, ϕ — его текущая фаза колебаний, функция $f : [0, 1] \rightarrow [0, 1]$ — гладкая монотонно-возрастающая, причем $f(0) = 0$ и $f(1) = 1$. Осциллятор генерирует импульс в тот момент, когда достигается состояние $x = 1$. Немедленно после этого фаза обнуляется, $\phi = 0$. При отсутствии входных импульсов фаза меняется как

$$\phi = \omega t,$$

где t — время, прошедшее после последнего импульса, ω — собственная частота осциллятора.

Если в момент t на вход осциллятора приходит импульс с амплитудой ε , фаза осциллятора скачком меняется с $\phi(t)$ на

$$\phi(t^+) = f^{-1}(B(x(t) + \varepsilon)),$$

где $f^{-1}(\cdot)$ — обратная функция и

$$B(x) = \begin{cases} x, & 0 \leq x \leq 1; \\ 0, & x < 0, \\ 1, & x > 1. \end{cases}$$

В соответствии с этими формулами, в момент t состояние осциллятора меняется с $x(t)$ на

$$x(t^+) = B(x(t) + \varepsilon),$$

Функция B используется для ограничения интервала изменения x единичным отрезком $[0, 1]$.

В численных экспериментах использовалась функция f следующего вида:

$$f(\phi) = \frac{1}{b} \ln[1 + \phi(e^b - 1)],$$

где b — постоянный параметр, задающий меру выпуклости функции f . Все собственные частоты одинаковы. Величина амплитуды импульса ε не постоянна, а меняется в зависимости от текущих фаз пары взаимодействующих осцилляторов (см. ниже).

Опишем теперь, как сеть из фазово-импульсных осцилляторов может использоваться для сегментации. Рассмотрим множество точек $P_i \in S$ ($i = 1, \dots, N$). Используя координаты точек и метрику в пространстве S , можно вычислить так называемую реляционную матрицу $R = \{r_{ij}\}$, где r_{ij} удовлетворяет соотношениям

$$r_{ij} \in [0, 1], \quad r_{ii} = 0, \quad r_{ij} = r_{ji}$$

и характеризует относительное несходство между точками P_i и P_j .

После того как каждой точке P_i поставлен в соответствие фазово-импульсный осциллятор, проблема кластеризации сводится к разбиению множества из N осцилляторов на некоторое число ансамблей синфазных осцилляторов. Заметим, что требование отсутствия синфазности между ансамблями осцилляторов не препятствует тому, чтобы эти ансамбли работали синхронно с некоторым сдвигом фаз относительно друг друга. Число ансамблей считается априорно неизвестным. Оно зависит от параметров алгоритма кластеризации.

Для формирования требуемых ансамблей осцилляторов авторами предложен следующий метод задания амплитуд импульсов:

$$\varepsilon_{ij} = \begin{cases} C_E \left[1 - \left(\frac{r_{ij}}{\delta} \right)^2 \right], & r_{ij} \leq \delta, \\ C_I \left[\left(\frac{1 - r_{ij}}{1 - \delta} \right)^2 - 1 \right], & r_{ij} > \delta. \end{cases}$$

В этой формуле C_E — максимальная величина возбуждающей связи, C_I — максимальная величина тормозной связи, $0 < \delta < 1$ — параметр, определяющий степень сходства между осцилляторами, при которой они должны быть включены в один ансамбль. Если $r_{ij} < \delta$, взаимодействие между осцилляторами возбуждающее, в противном случае — тормозное. Чем меньше δ , тем большее число сегментов будет выделено на изображении.

При формировании в сети ансамбля G синфазных осцилляторов необходимо принять специальные меры к тому, чтобы уже достигнутая синфазность сохранялась в будущем. Для этой цели импульсы, приходящие на осцилляторы одного ансамбля, должны быть одинаковой амплитуды. Это достигается пересчетом значений расстояний r_{ij} ($j \in G$) по формуле

$$r_{ij} = \frac{1}{g} \sum_{j \in G} r_{ij},$$

где g — число осцилляторов в G (эта процедура называется усредняющим алгоритмом связывания).

В начальном состоянии фазы осцилляторов имеют случайные значения. В ходе работы модели осцилляторы начинают объединяться в ансамбли с одновременной импульсацией. Осцилляторы, достигнув своей активности, остаются таковыми благодаря идентичным входным сигналам. Постепенно уже сформировавшиеся ансамбли вовлекают в себя другие осцилляторы. Более того, сами ансамбли могут сливаться, образуя ансамбли большего размера. В конце концов в системе формируются устойчивые ансамбли осцилляторов, генерирующие импульсы с фиксированным фазовым сдвигом между ансамблями.

Описанная выше модель была бы вполне работоспособна, если бы не одна проблема — огромный размер реляционной матрицы в случае работы с реальными изображениями. К счастью, имеется эффективный способ радикально уменьшить объем вычислений расстояний. Для этого вводится понятие **прототипа**. Прототипами называются точки из множества

$B = \{b_m\}$ ($m = 1, \dots, M$), $b_m \in S$, $M \ll N$. Первоначально прототипы случайно распределяются в S . Как только некоторый осциллятор генерирует импульс, определяется ближайший к нему прототип b_m , после чего расстояние от данного осциллятора до ансамбля A заменяется на расстояние от b_m до A . Если осциллятор включается в ансамбль B , то b_m берет на себя роль представителя этого ансамбля, то есть, b_m перемещается в центр B и используется в последующих вычислениях расстояний вместо всех индивидуальных элементов B .




Рис. 7. Сегментации изображений моделью Роума–Фригуи. *Левая колонка* — исходные изображения. *Средняя колонка* — сегментация при $\delta = 0.2$. *Правая колонка* — сегментация при $\delta = 0.3$. (Воспроизведено по работе [48]).

Модель применялась к сегментации цветных изображений. Каждый пиксель изображения характеризовался восемью признаками. Помимо двух значений координат пикселя в число признаков были включены интенсивности по трем цветам и три текстурные характеристики окрестности

пикселя [51]. На рис. 7 показаны результаты сегментации для изображений, взятых из базы Corel Image Database. При $\delta = 0.2$ крупные области на изображении разбиваются на небольшие подобласти, не слишком сильно отличающиеся по своим оптическим характеристикам. При $\delta = 0.3$ формируются крупные области, соответствующие основным объектам на изображении.

Модель Жао-Макау

В работах [52–54] разработан сходный подход к сегментации, но на базе более абстрактных элементов, в качестве которых использованы логистические отображения

$$x(t+1) = f(x(t)) = rx(t)(1-x(t)),$$

где $x(t)$ меняется в интервале $(0, 1)$. Известно, что логистическое отображение может порождать различные типы динамики в зависимости от значения параметра r . В частности, для большинства значений r между 3.57 (приблизительно) и 4 логистическое отображение порождает хаотическую динамику [55]. Сети из логистических отображений, называемые глобально взаимодействующими отображениями (Globally Coupled Maps — GCM), уже использовались ранее в задачах кластеризации [56]. Модель Жао-Макау является обобщением этих сетей с дополнительной адаптацией входных данных.

Рассматриваемая модель представляет собой N взаимодействующих хаотических логистических отображений, каждое из которых соответствует некоторому пикселю на изображении. Динамика сети описывается следующими уравнениями:

$$x_i(t+1) = (1-\varepsilon)f(x_i(t)) + \frac{\varepsilon}{M_i(t)} \sum_{j=1}^N z_{ij}(t)f(x_j(t)), \quad i = 1, \dots, N,$$

где z_{ij} — силы взаимодействия, $M_i(t)$ — число пикселей в локальной окрестности $\Delta_i(t)$ пикселя i , ε — параметр ($0 < \varepsilon < 1$).

Величины z_{ij} зависят от признаков пикселей i и j ,

$$z_{ij}(t+1) = \beta z_{ij}(t) + (1-\beta)H(e^{-\alpha|c_i(t)-c_j(t)|} - \theta),$$

где $c_i(t) = (c_{i1}(t), \dots, c_{iK}(t))$ — вектор признаков i -го пикселя, $|\cdot|$ — евклидова норма, α, β — параметры $\alpha > 0, 0 < \beta < 1, H$ — функция Хевисайда, θ — порог. Параметры α и θ задают уровень различий между сегментами изображения: бóльшим значениям этих параметров соответствует большее число кластеров.

Особенностью модели является адаптируемость векторов $c_i(t)$ в ответствии с «силой», действующей на пиксель i со стороны пикселей из $\Delta_i(t)$. Эта сила велика/мала в зависимости от того, имеют ли пиксели сходные/несходные признаки. При работе модели координаты векторов постепенно сдвигаются в направлении действия равнодействующей силы со стороны $\Delta_i(t)$. Благодаря подходящему выбору процедуры адаптации, точки, которые отнесенные к одному кластеру, группируются в нем более тесно, а расстояние между кластерами возрастает.

Процесс кластеризации описывается следующим образом. В исходном состоянии силы взаимодействия ε и $z_{ij}(0)$ устанавливаются на достаточно высокий уровень, чтобы синхронизовать всю сеть. При подаче на вход модели изображения каждая переменная $z_{ij}(t)$ стремится к значению, даваемому функцией Хевисайда. Эта величина определяет окрестность пикселя $\Delta_i(t)$, пиксели которой считаются сходными по своим признакам с пикселем i . Другими словами, взаимодействие между осцилляторами i и j становится максимальным, когда $z_{ij}(t)$ приближается к 1, а при $z_{ij}(t)$, приближающемся к нулю, взаимодействие исчезает. Постепенно все осцилляторы, стимулируемые сходными входными сигналами, формируют синфазный хаотический ансамбль. Осцилляторы, стимулируемые пикселями со значительно различающимися признаками, будут отнесены к разным ансамблям. Преимущества использования хаотической динамики состоит в том, что десинхронизация различных ансамблей осуществляется очень быстро, так как невзаимодействующие хаотические траектории расходятся с экспоненциальной скоростью.

Заметим, что процедура адаптации векторов $c_i(t)$ существенна. Без нее пиксели со сходными признаками могли бы попасть в разные кластеры. Но стоит заметить, что модель не предусматривает обратного влияния синфазности осцилляторов на процесс адаптации. Таким образом, синфазность лишь выявляет структуру кластеров, формируемых благодаря адаптации.

Пример сегментации изображения с помощью модели Жао-Макау приведен на рис. 8.

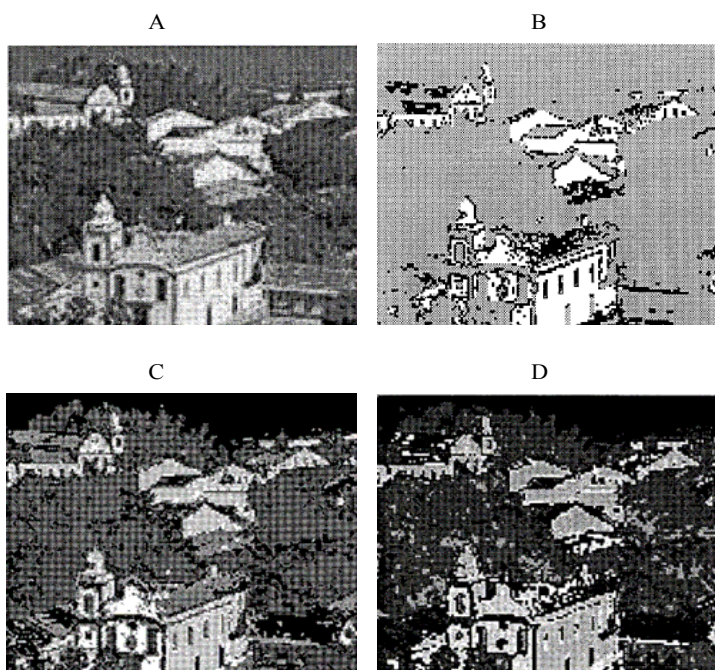


Рис. 8. Пример сегментации изображения моделью Жао–Макау. Здесь: **A.** Исходное изображение 160×120 пикселей. **B.** Сегментация при $\theta = 0.5$. **C.** Сегментация при $\theta = 0.7$. **D.** Сегментация при $\theta = 0.8$. (Воспроизведено по работе [53]).

Модель Буманна-Ланге-Рамахера

В работе [57] предложен еще один вариант сокращения вычислений при сегментации, основанный на том, что элементами, подлежащими сегментации, являются не отдельные пиксели, а квадраты, содержащие сравнительно большое число пикселей. Предположим, что входное изображение разбито на N квадратов одинакового размера. Каждый квадрат i можно характеризовать гистограммой интенсивностей $\mathbf{h}_i = (h_{ij})_{j=1, \dots, M}$ (предполагается, что гистограмма имеет M бинов). Бины гистограммы по определению являются ее признаками. Вероятности признаков определяются

как

$$p(j|i) = \frac{h_{ij}}{n}, \quad j = 1, \dots, M,$$

где n — число пикселей в квадрате. Задача сегментации изображения может быть сформулирована как разбиение множества квадратов на K непересекающихся кластеров (сегментов изображения). Предполагается, что величина K известна априорно. Очевидно, разумная процедура кластеризации квадратов должна принимать во внимание как вероятности признаков, так и пространственное расположение квадратов: близлежащие квадраты с большей вероятностью могут принадлежать одному сегменту, чем удаленные квадраты (последнее условие носит название условия локальной гладкости).

Данный подход к сегментации изображений был реализован в модели из импульсных нейронов. Идея модели состоит в том, что веса связей в нейронной сети адаптируются в процессе ее работы таким образом, что после определенного периода обучения сеть оказывается способной классифицировать квадраты в соответствии с некоторой оптимизационной процедурой

Модель построена из простых импульсных нейронов с постоянным порогом срабатывания. Динамика мембранного потенциала U_i нейрона i задается уравнением

$$\frac{dU_i}{dt} = -\varepsilon U_i + \sum_{k \in \Gamma_i} W_{ki} S_k,$$

где Γ_i — множество пресинаптических нейронов для нейрона i , S_k — текущий выходной сигнал нейрона k , W_{ki} — синаптические веса, ε — параметр затухания мембранного потенциала. В тот момент, когда U_i достигает порога θ , нейрон генерирует импульс длительностью τ , после чего мембранный потенциал немедленно обнуляется.

С каждым квадратом ассоциируется двухслойная сеть с M нейронами во входном слое и K нейронами в выходном. Эта сеть называется блоком. Между слоями блока имеются адаптирующиеся связи, идущие снизу вверх, типа все-на-всех. Кроме того, в выходном слое имеются латеральные тормозные связи типа все-на-всех, реализующие принцип «победитель получает все». Входные нейроны стимулируются сигналами $p(j|i)$ ($j = 1, \dots, M$), так что их импульсная активность пропорциональна указанным вероятностям. Выходные нейроны осуществляют классификацию квадратов. Квадрат i считается принадлежащим k -му сегменту, если k -й

выходной нейрон имеет наибольшую активность (частоту разрядов) в выходном слое данного блока.

Полная сеть модели строится как плоская сеть из блоков с локальным взаимодействием между блоками. Соседство между блоками соответствует соседству между квадратами. Пусть ν_i — выходной нейрон в блоке i , а ν_j — выходной нейрон в блоке j . Если блоки i и j являются соседними (в вычислениях использовались ближайшие 4 соседа) и $\nu_i = \nu_j$, тогда нейроны ν_i и ν_j соединены возбуждающими связями, в противном случае связи между нейронами ν_i и ν_j тормозные. Такая архитектура связей дает некоторое предпочтение отнесению соседних квадратов к одному сегменту, чем повышается гладкость границ сегментируемых областей. Величины связей между блоками фиксированные.

Опишем теперь процедуру обучения (кластеризации). Обозначим $q(j|\nu)$ вероятность признака j при условии, что квадрат принадлежит сегменту ν . Пусть $m_{i\nu} = 1$, если ν — «победивший» сегмент в блоке i , в противном случае $m_{i\nu} = 0$. Величину

$$\bar{h}_{j\nu} = \frac{\sum_i m_{i\nu} p(j|i)}{\sum_i m_{i\nu}}$$

можно рассматривать как текущую оценку $q(j|\nu)$. Принимая это во внимание, процедуру адаптации весов связей можно задать следующей формулой:

$$\frac{dW_{j\nu}^i}{dt} = \alpha (\exp(W_j^{\max} - W_{j\nu}^i) \bar{h}_{j\nu} - 1),$$

где α — скорость обучения ($\alpha \approx 0.01$), W_j^{\max} — параметры. Динамика весов связей дает следующее приближенное выражение

$$W_{j\nu}^i \approx W_j^{\max} + \ln(q(j|\nu)).$$

Величины W_j^{\max} выбираются таким образом, чтобы гарантировать положительность $W_j^{\max} - W_{j\nu}^i$. Можно показать, что такой выбор весов связей дает статистически оптимальную схему классификации.

Модель тестировалась при следующих значениях параметров: $N = 64 \times 64$, $M = 12$, $K = 5$ (в одном примере было $K = 2$). Начальные веса и мембранные потенциалы инициализировались случайным образом.

Обучение начиналось с небольшим запозданием по отношению к моменту старта функционирования модели, чтобы дать модели время на начальную стабилизацию.

Численные эксперименты проводились с искусственными изображениями, содержащими простые геометрические объекты, искусственные текстуры и реальные изображения. Путем регистрации средней активности нейронов в выходном слое было показано, что 1) нейронная активность имеет осцилляционный характер, 2) нейрон «победившего» класса (сегмента) доминирует над другими нейронами в своем блоке, 3) нейроны, кодирующие один и тот же сегмент, работают синфазно, генерация импульсов нейронами, кодирующими разные сегменты, происходит с фазовым сдвигом. В экспериментах наблюдались волны активации, распространяющиеся по сегментируемым областям.

Результаты сегментации текстур оказались неудовлетворительными, что неудивительно — локальные гистограммы не являются информативными для большинства типов текстур (в данном случае габоровские фильтры были бы более подходящим инструментом).



Рис. 9. Пример сегментации изображения моделью Буманна с соавторами. Здесь: **А.** Исходное изображение. **В.** Промежуточные результаты сегментации в момент $t = 5$. **С.** Окончательные результаты сегментации при установлении стационарного состояния сети, $t = 50$. (Воспроизведено по работе [57]).

Пример сегментации реального изображения приведен на рис. 9. На рисунке различные сегменты показаны различными интенсивностями серого цвета.

Обсуждение

Общим недостатком, свойственным всем алгоритмам сегментации, основанным на кластеризации, является то, что эти модели неявно предполагают, что диапазон изменения оптических характеристик в рамках каждого сегментируемого объекта мал по сравнению с различием этих характеристик у разных объектов. Для многих классов изображений это условие не выполняется. В частности, отблески света на поверхности объектов могут существенно повлиять на результат сегментации.

Сравнение моделей Роума–Фригуи и Жао–Макау показало, что последняя из них работает существенно быстрее, требуя для выполнения кластеризации меньше итераций. Это объясняется с одной стороны тем, что синхронизация, обусловленная непрерывным взаимодействием, наступает быстрее, чем при импульсном взаимодействии. С другой стороны, формирование кластеров ускоряется за счет адаптации входной информации (движения кластеризуемых точек). Вычисления показали, что с увеличением объема обрабатываемых данных число итераций, требуемых для получения компактных кластеров, растет медленно.

Существенный недостаток модели Буманна с соавторами состоит в том, что результат сегментации критически зависит от априорно заданного числа сегментов K . В принципе, можно провести кластеризацию для нескольких значений K , а затем выбрать ту из них, которая окажется более удовлетворительной согласно некоторому дополнительному критерию. Но такой метод проб и ошибок, помимо сомнительной биологической правдоподобности, потребует существенно больших затрат времени на вычисления.

Сегментация и когнитивные функции мозга

Рассматривавшиеся выше методы сегментации практически не включали в себя какой-либо априорной информации относительно того, какие именно объекты должны сегментироваться. Правда, в моделях типа LEGION приоритет при сегментации отдается большим по размеру объектам, а небольшие шумовые объекты могут вообще игнорироваться. Но это весь-

ма частный случай общей ситуации, когда априорно заданная информация о свойствах сегментируемых объектов может существенно повысить качество сегментации. Эта информация может быть задана в достаточно полном объеме в заранее сформированной памяти или путем указания специальных характеристик объектов, таких как яркость, наличие определенных признаков и т. д., которыми должны обладать сегментируемые объекты. Первый из этих случаев соответствует сегментации с памятью, а второй — сегментации с вниманием. Подача на сеть, выполняющую сегментацию, дополнительных сигналов от памяти или внимания способствует созданию неравноправных условий конкуренции для ансамблей осцилляторов, представляющих разные объекты. В результате, победить в конкуренции и сохранить высокую активность способны лишь те ансамбли, которые получают дополнительное подкрепление.

Сегментация и память

Выше уже указывалось, что сегментация пересекающихся объектов является одной из важных и трудных задач. Рассмотренные методы ее решения базировались на предположении, что пересекающиеся объекты можно разделить благодаря различию их по яркости или цвету. Но что делать в случае, если эти характеристики у объектов идентичны (по крайней мере, идентичны там, где должна проходить граница между объектами)? Например, как разделить частично наложившиеся друг на друга черный треугольник и черный эллипс? Очевидно, такая задача может быть решена только в том случае, если в памяти системы содержится априорная информация об этих геометрических фигурах.

Одна из моделей байндинга и сегментации с памятью была предложена в работах [58–59] (краткое изложение модели можно найти также в [60]). В этой модели память реализована в виде отдельного центрального модуля, имеющего прямые и обратные связи с модулем, представляющим первичные области новой коры, где реализуется байндинг. Хотя эта модель работает с контурными изображениями, она рассматривается в данном разделе, поскольку основной ее особенностью является наличие памяти. Нет сомнений, что эта модель может быть адаптирована и для работы с пиксельными изображениями.

Элементами сети являются импульсные нейроны с динамическим порогом срабатывания, сходные с традиционными интегративно-пороговыми нейронами с утечкой [32]. Важным свойством этих нейронов является спо-

способность быстро синхронизоваться на временах, соответствующих экспериментальным данным по синхронизации гамма-колебаний. Возбуждающие нейроны в модели обладают относительной рефрактерностью — после генерации импульса порог нейрона мгновенно увеличивается до заданного уровня, а затем экспоненциально падает.

Архитектура модели представлена на рис. 10. Сеть состоит из трех слоев: сетчатки R , первичной зрительной коры P и центральной области зрительной памяти C . Слой R имеет размер 100×100 нейронов, находящихся во взаимно-однозначном соответствии с пикселями на изображении. Слой P состоит из популяции возбуждающих нейронов P (100×100 нейронов) и двух популяций тормозных нейронов P^S и P^T того же размера (в работе [61] сходные результаты были получены для одной тормозной популяции в P). Аналогично, слой C состоит из трех популяций: возбуждающей популяции C (40×40 нейронов), тормозной популяции для разделения объектов C^S (40×40 нейронов), тормозной популяции для последовательной смены объектов C^T (20×20 нейронов).




Рис. 10. Архитектура связей модели Кноблауха–Палма. Здесь: R — сетчатка, P — первичная зрительная кора, C — память. (Воспроизведено по работе [59]).

Поскольку модель ориентирована на работу с контурными изображениями, функционирование слоя P по существу сходно с моделью Ли (см. подраздел «Модель Ли» раздела «Сегментация контурных изображений», с. 44). Отличие данной модели в том, что детекторы направлений расположены не в колонке, как в модели Ли, а на плоскости (детектируемые ориентации ограничены четырьмя направлениями 0^0 , 45^0 , 90^0 , 135^0). Это упрощает архитектуру слоя, но приводит к «рваному» представлению в P непрерывных контуров, активированных в R . Еще одной особенностью

модели является введение шума с пространственной и временной корреляцией. Это сделано для ускорения десинхронизации удаленных друг от друга участков контуров и для нарушения неправдоподобно регулярной (с нейрофизиологической точки зрения) колебательной активности.

Слой памяти S представляет собой вариант ассоциативной памяти Виллшоу [62], реализованной на импульсных нейронах. Слой S связан с R прямыми и обратными связями, настраиваемыми с помощью хеббовского обучения и обеспечивающими гетероассоциативность между представлениями стимула в R и S . Связи $C \rightarrow C$ и $C \rightarrow C^S$ являются хеббовскими, остальные связи в S фиксированные. Популяция C^S используется для реализации конкуренции между ансамблями в S , представляющими различные объекты, предотвращая их одновременную активацию. Популяция C^T предназначена для прерывания текущей активности популяции в S , давая возможность активироваться ансамблю, представляющему другой объект. Кроме того, C^T предотвращает неконтролируемое распространение возбуждения в случае, когда силы, разделяющие ансамбли, недостаточно велики. Рис. 11 показывает, как три тестовых стимула (треугольник, эллипс и квадрат) представляются активностями в слоях R , P и S . Заметим, что в S стимулы представлены бинарными случайными паттернами, которые лишь отдаленно сохраняют форму представления тех же стимулов в R .

Численные расчеты, в которых в качестве входного стимула использовался треугольник, были проведены для сравнения динамики сети в полной модели и в модели, из которой были исключены обратные связи $C \rightarrow P$. В обоих случаях наблюдалась осцилляторная активность в S , но в полной модели частота колебаний в C существенно возросла (с примерно 30 до 50–60 Гц), а колебания в P стали более регулярными и синфазными с колебаниями в C . Активность всего нейронного ансамбля, представляющего стимул в R , была синфазной. Активность отдельных нейронов в общих чертах отражала активность всего ансамбля, но была намного менее регулярной (например, нейрон в S зачастую срабатывал лишь на каждом втором или третьем колебании суммарной активности популяции). Увеличение суммарной импульсной активности сопровождалось возрастанием частоты появления пачек из двух-трех импульсов на уровне одиночных элементов.

Для тестирования способности модели к сегментации на ее вход был подан стимул, представляющий собой суперпозицию из трех объектов: треугольника, квадрата и эллипса (рис. 12). Предварительно эти объекты предъявлялись поодиночке и были запомнены в ассоциативной памяти.

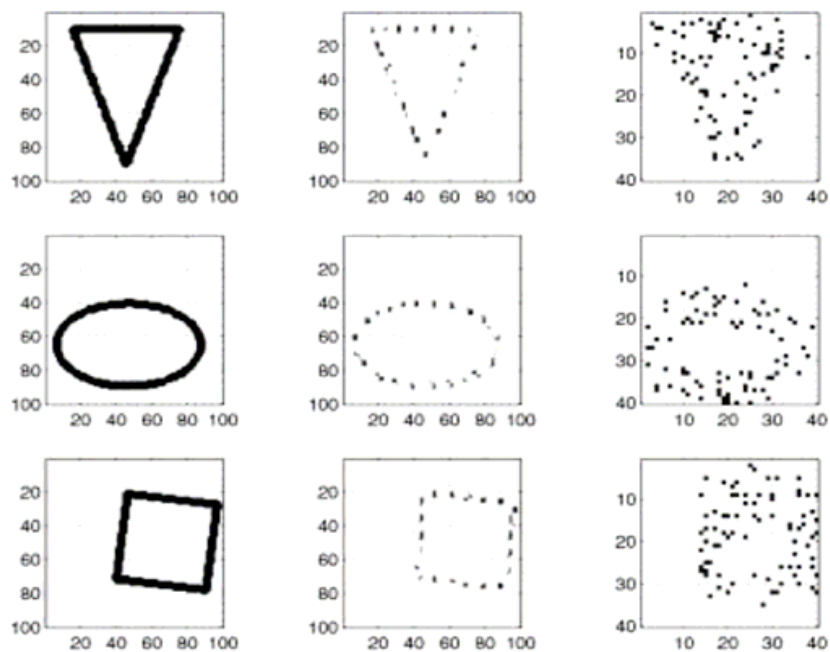


Рис. 11. Представление стимулов в модели Кноблауха–Палма. *Слева* — представление стимулов на сетчатке R. *В центре* — представление стимулов в первичной зрительной коре P. *Справа* — представление стимулов в памяти C. (Воспроизведено по работе [59]).

По сравнению со многими другими моделями сегментации, в которых объекты кодировались синхронными колебаниями со сдвигом фаз между различными ансамблями, в данной модели имела место некоррелированная активность ансамблей, представляющих различные объекты, причем отсутствие корреляции (плоские коррелограммы) наблюдались в обоих слоях P и C. Важность этого факта обусловлена тем, что именно такое отсутствие корреляции наблюдалось в нейрофизиологических экспериментах [14, 63].

Благодаря тормозному действию популяции C^S , в каждый момент времени только один ансамбль в C демонстрирует колебательную активность. Для каждого ансамбля период быстрой осцилляторной активности, длив-

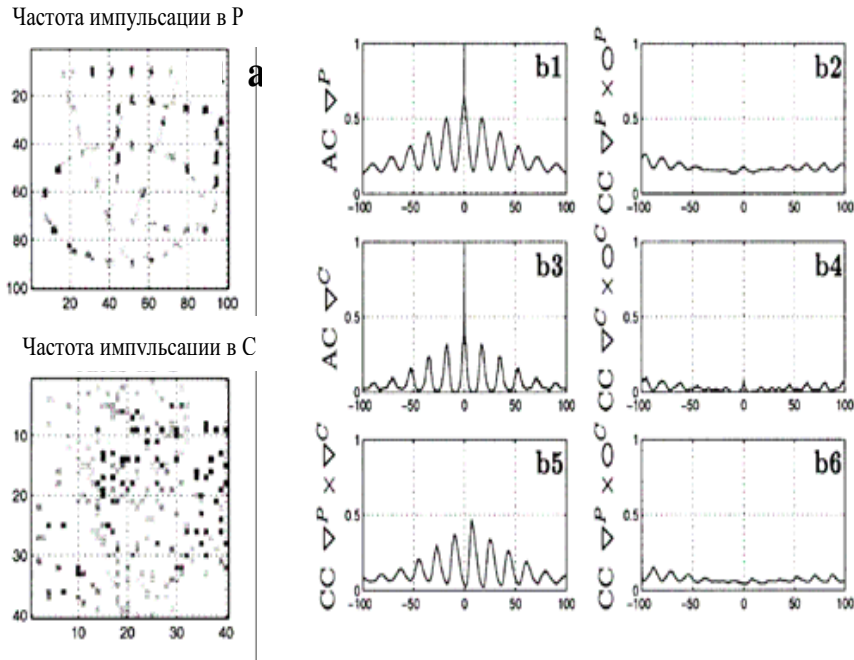


Рис. 12. Функционирование модели Кноблауха–Палма при предъявлении стимула, являющегося суперпозицией трех фигур — треугольника, квадрата и эллипса. Слева (a) — частоты импульсации нейронов в слоях Р и С. Справа (b) — автокоррелограммы (АС) и кросс-коррелограммы (СС) суммарной (по каждой фигуре) активности нейронов. (Воспроизведено по работе [59]).

шийся несколько сотен миллисекунд (эта длительность зависит от параметра, задающего относительную рефрактерность), сменяется более длительным периодом с низкой нерегулярной активностью. Эти две фазы активности перемежаются на всем протяжении функционирования сети. Аналогичный вид имеет активность в R. Последнее является результатом действия обратных связей от C к R.

Исследование коррелограмм активности в R и C показало, что активность в этих слоях синхронизуется в противофазе при реалистичных временных задержках передачи сигналов (около 4–8 мс). Это противоречит как экспериментальным данным, так и теоретическим представлениями ТВК, согласно которым активность нейронов, представляющих один объект, должна быть синфазной. Авторами предложено несколько вариантов модификации модели для преодоления этой трудности [61]. Один из вариантов был исследован более подробно методами имитационного моделирования. Он заключается во введении бимодальных распределений для синаптических задержек между R и C. Одна мода представляла собой короткие задержки (около 0.5 мс), а другая мода порождала задержки, распределенные в широком диапазоне (до 50 мс). В такой модификации модели была продемонстрирована синфазность колебаний в областях R и C.

Сегментация и внимание

Биологические исследования показывают, что обработка зрительной информации у животных и человека не ведется с одинаковой тщательностью по всей зрительной сцене. В большинстве случаев основные усилия сконцентрированы на каких-то специальных областях или объектах зрительного поля. Например, это могут быть области, которые заметно выделяются из своего окружения (по-английски это называется pop-out), и объекты, которые только что появились в сцене или представляют в данный момент особую важность. Остальные детали и объекты зрительной сцены более или менее игнорируются. Механизм, позволяющий мозгу осуществлять такую фильтрацию, называется вниманием. Важно отметить, что фильтрация зрительной информации может выполняться при неподвижных зрачках, то есть за счет внутренних процессов в мозге. Соответствующее этому внимание называется скрытым (в отличие от открытого внимания, сопровождаемого саккадами — движениями зрачков). В описываемых ниже моделях речь всегда идет о скрытом внимании, поэтому термин «скрытое» будет опускаться.

Внимание необходимо вследствие ограниченных возможностей зрительной системы, у которой недостаточно ресурсов для детального и быстрого анализа всей зрительной сцены. Восприятие сложных зрительных сцен требует итеративного взаимодействия между различными уровнями обработки внешних стимулов и памятью. Внимание используется для оптимальной организации этого взаимодействия. В частности, показано, что внимание играет важную роль при байндинге, давая возможность связывать признаки разного типа (включая признаки разной модальности).

Нейрофизиологические и психологические аспекты зрительного внимания являются объектом активного изучения [64]. Известно, что внимание способно модулировать нейронный ответ: активность нейрона возрастает, когда находящийся в его рецептивном поле стимул включен в фокус внимания. Ответ нейронов на стимулы вне фокуса внимания в значительной мере подавляется. Недавние исследования также показали, что функционирование внимания связано с осцилляторной активностью и ее синхронизацией [65–68].

Внимание реализуется разветвленной сетью, в которую включены различные корковые и подкорковые области. Достаточно надежно установлено, что такими областями являются некоторые ядра таламуса, высшие зоны новой коры (височной, теменной и лобной), а также гиппокамп. Не исключено, что эти зоны могут разным образом комбинироваться и координировать свое взаимодействие при различных видах внимания. Психологические исследования показывают, что внимание улучшает качество сегментации изображений. Это порождает надежду на то, что тот же положительный эффект может быть получен при включении внимания в модели сегментации. Общей идеей здесь является соединение принципов синхронизации и модуляции нейронной активности.

Модель сегментации с вниманием предложена в работе [69]. Элементами модели являются импульсные нейроны Экхорна [32]. Как уже отмечалось, сети из таких нейронов с локальными связями способны формировать кластеры синфазных осцилляторов. Подача на вход такой сети изображения, представленного интенсивностями пикселей, приведет к сегментации изображения, при которой в каждый кластер будут включены пиксели с близкими значениями интенсивности.

Новой идеей, реализованной в модели, является использование в качестве входной информации при сегментации не только исходного полутонового изображения, но и нескольких изображений, получаемых из исходного в результате его обработки набором фильтров. Назначение фильтра - вычис-

лить в каждом пикселе изображения значение некоторого признака, ассоциированного с данным фильтром. Полученное в результате фильтрации изображение называется картой признака. В реальных вычислениях использовались три типа фильтров: вейвлеты, морфологические фильтры, характеризующие локальную геометрию изображения, и разностно-гауссовские фильтры (difference-of-Gaussians — DoG фильтры), поскольку эти фильтры уже зарекомендовали себя при анализе различных классов изображений [70–72]. Использование карт признаков позволяет найти на изображении наиболее вероятную область расположения целевых объектов. Благодаря ограничению области, где должна проводиться сегментация, качество сегментации с помощью временной корреляции удастся повысить. На выходе модели сегментируемые объекты представлены нейронными ансамблями с более высоким уровнем активности.

Модель состоит из взаимодействующих модулей: центрального модуля и набора модулей признаков. На вход центрального модуля подаются интенсивности пикселей. На вход модуля признака подаются сигналы от карты этого признака. Нейроны внутри модуля организованы в виде двумерного слоя с локальными связями (в вычислениях связи имели радиус 3).

Сегментация на основе временной корреляции выполняется центральным модулем. Роль, исполняемая модулями признаков, сходна с той, которую играет карта заметности в модели внимания Итти и Коха [73, 74]. Модули признаков подают на центральный модуль дополнительные возбуждающие модулирующие сигналы, цель которых сфокусировать внимание на сегментах изображения, представляющих интерес. В результате активность нейронов, представляющих целевые объекты, оказывается существенно выше активности нейронов, представляющих нецелевые объекты и фон.

В качестве тестовых примеров для проверки качества работы модели использовались маммограммы и инфракрасные изображения ракетных установок. В случае ракетных установок модель позволяла отфильтровать 94% объектов, не являющихся целевыми, при нулевых ошибках распознавания целевых объектов. В случае маммограмм модель позволяла отфильтровать 46% нецелевых объектов при 7% ошибок распознавания целевых объектов. Такого качества сегментации невозможно было бы добиться на основе какого-либо одного метода фильтрации по заданному признаку или их простой логической комбинацией.

Работа [69] была ориентирована главным образом на техническое при-

менение идей ТВК; вероятно, поэтому в ней отсутствует корреляционный анализ режимов синхронизации, возникающих при функционировании модели. В результате остается неясным, имеется ли десинхронизация активности нейронных ансамблей, кодирующих различные объекты на изображении, и если да, то какими механизмами эта десинхронизация обеспечивается.

В работе [75] используются сходные идеи, но при этом проблема синхронизации/десинхронизации исследовалась явно. Интенсивности исходного изображения представлялись во входном слое модели амплитудами осцилляторов ФитцХью–Нагумо. Для реализации десинхронизации был введен специальный «возмущающий» слой, десинхронизирующие сигналы с которого подавались на входной слой. Это давало требуемый эффект десинхронизации, но, к сожалению (как было выяснено кросс-корреляционным анализом), активность пары нейронов, представляющих разные объекты, оказалась сильно коррелированной. Это означает, что данные нейроны генерируют последовательности импульсов, отличающиеся всего лишь сдвигом фаз. Такая активность противоречит имеющимся экспериментальным данным [14, 63].

Модели сегментации [69, 75] основаны на автоматической фокусировке внимания по принципу pop-out. Другой возможный подход к реализации внимания основан на неравноправной конкуренции (biased competition) между нейронными ансамблями, когда вводится дополнительный сигнал, повышающий активность какого-либо ансамбля и тем самым обеспечивающий его «победу» в конкуренции по принципу «победитель получает все». Считается, что такой дополнительный сигнал вырабатывается системой внимания в высоких областях новой коры и затем проектируется в первичные зоны зрительной коры, формируя подходящий фокус внимания.

В уже рассматривавшихся выше работах [60, 61] (см. раздел «Сегментация и память», с. 79) авторы использовали неравноправную конкуренцию для проверки способности своей модели воспроизводить экспериментальные данные по регистрации активности нейронов, стимулируемых комбинациями объектов [76, 77]. Сначала в памяти модели были запомнены два объекта: квадрат и эллипс. Затем на вход модели подавались каждый из этих стимулов по отдельности или их комбинация (сложный стимул). Регистрировалась (в виде постстимульной гистограммы с временным шагом 500 мс) средняя активность нейрона, чувствительного к стимулу «квадрат». В согласии с экспериментальными данными при моделировании были получены следующие результаты:

- 1) при отсутствии внимания ответ нейрона на сложный стимул был меньшим, чем на «свой» стимул (квадрат), и большим, чем на «чужой» стимул (эллипс);
- 2) при наличии внимания ответ нейрона на сложный стимул был таким, как если бы предъявлялся только один объект — тот, на котором было сфокусировано внимание.

Указанные эффекты были более выражены в верхнем слое памяти (слой С), чем в нижнем слое первичной зрительной коры (слой Р).

Механизм, благодаря которому модель правильно воспроизводит экспериментальные данные, связан с участием нейрона, чувствительного к определенному стимулу, в двух режимах байндинга — с высокой и низкой активностью. При предъявлении «своего» стимула нейрон все время находится в состоянии высокой активности. При предъявлении сложного стимула и при отсутствии внимания нейрон примерно половину времени проводит в состоянии высокой активности, а в остальное время находится в состоянии низкой активности. Если же внимание на «своем» стимуле присутствует, нейрон снова возвращается в режим высокой активности в течение всего времени стимуляции.

Обсуждение

Привлечение для сегментации изображений когнитивных функций мозга является перспективным направлением исследований. Экспериментальные данные о том, в какой мере и на каком этапе память и внимание участвуют в реализации сегментации, остаются весьма фрагментарными. По-видимому, простые задачи сегментации могут быть решены автономно на уровне первичных зон зрительной коры, но в более сложных случаях когнитивные функции (память, распознавание, внимание) оказываются необходимыми для успешного решения задачи. При этом когнитивные функции могут участвовать в выполнении сегментации как синхронно с сегментацией, так и итеративно. В последнем случае промежуточные результаты сегментации анализируются на уровне когнитивных функций с привлечением верхних зон коры, а затем полученная таким образом информация используется в первичных зонах зрительной коры для уточнения сегментации.

Выполненные работы показали, что дополнительная информация об объектах, содержащихся в памяти или обладающих специальными свойствами, может существенно повысить качество сегментации, а также дать

объяснение ряду нейрофизиологических данных. Однако в существующих моделях пока что не удалось сочетать хорошее соответствие экспериментальным данным с сегментацией естественных изображений. Для естественных изображений сегментация налагающихся объектов с одинаковыми оптическими характеристиками по-прежнему остается нерешенной задачей. Модель сегментации Кноблауха–Палма в настоящем виде не обладает инвариантностью по отношению к положению запомненных объектов. Поэтому она не способна сочетать сегментацию объекта с его поиском на изображении. Достижение инвариантности при взаимодействии сегментации и памяти - важная задача для будущих исследований.

Заключение

Обзор дает довольно полное представление о моделях сегментации с помощью динамических и осцилляторных нейронных сетей, разработанных в последние 10 лет. Рассмотренные модели показывают, что принципы ТВК являются эффективным средством решения задач сегментации изображений. В существующих моделях удалось воспроизвести ряд экспериментальных данных, а лучшие из разработок продемонстрировали качество сегментации, сравнимое или даже несколько превосходящее системы искусственного интеллекта.

Следует, однако, отметить, что круг воспроизводимых в моделях нейробиологических и психологических данных не слишком широк, а с точки зрения технических приложений существующие системы еще весьма далеки от возможностей сегментации, демонстрируемых человеческим мозгом. Модели используют весьма широкий спектр принципов, что можно считать как достоинством, так и недостатком. Достоинство можно видеть в том, что у экспериментаторов будет больший выбор при планировании и объяснении результатов экспериментов. Недостаток же состоит в том факте, что в данный момент трудно сделать окончательные выводы относительно того, какие из этих принципов действительно реализуются в биологических организмах. Настораживает и тот факт, что стремление получить высокое качество сегментации изображений зачастую сопряжено с игнорированием известных экспериментальных данных.

Очевидно, что существующие модели далеко не используют те возможности, которые предоставляются имеющимися знаниями о функционировании мозга. Попробуем перечислить несколько направлений, в которых

могло бы пойти усовершенствование моделей сегментации.

Практически все модели реализуют байдинг каждого объекта на какой-то одной частоте (например, из гамма-диапазона). Однако иерархическая организация коры мозга и множественность частот, одновременно используемых при обработке зрительной информации, позволяют предположить, что в реализации байдинга может участвовать сразу несколько частот из разных частотных диапазонов. Признаки низкого уровня, возможно, связываются синхронизацией колебаний в диапазоне гамма-ритма, а окончательное связывание признаков в образ сложного объекта происходит при синхронизации на более низкой частоте (например, на частоте тета-ритма).

Хорошо известно, что в мозге приматов зрительная информация после первичных зон зрительной коры разбивается на два потока, один из которых идет в височную кору и отвечает за распознавание и запоминание объектов, а другой идет в теменную кору и отвечает за расположение объектов в пространстве. Эта особенность обработки информации в мозге не нашла отражения в моделях. По-видимому, с этим связаны трудности сопряжения сегментации с другими когнитивными функциями. Взаимодействие различных когнитивных процессов — сегментации, памяти, внимания, распознавания, детекции новизны, в которых задействованы многие структуры мозга, остается за пределами сегодняшних возможностей моделей. Только при создании моделей с широким спектром когнитивных функций можно надеяться получить результаты сегментации, заметно превосходящие системы искусственного интеллекта.

Еще одним резервом улучшения моделей сегментации является использование бинокулярного зрения. Принципы ТВК могут оказаться весьма полезными при интеграции признаков, полученных в разделенных оптических каналах.

С точки зрения решаемых задач, возможно, наиболее перспективными являются задачи по сегментации движущихся изображений. В этой области накоплен большой экспериментальный материал. Практическая важность таких работ также не вызывает сомнений. Небольшое число имеющихся здесь моделей не вышли на уровень работы с достаточно сложными изображениями и не включены в настоящий обзор. Тем не менее, можно ожидать, что задача слежения за объектами в зрительной сцене, включающей множественные целевые объекты, объекты-дистракторы (отвлекающие внимание) и скрывающие экраны, станет важным стимулом для дальнейшего развития и проверки работоспособности моделей сегментации.

Работа выполнена при поддержке Российского фонда фундаментальных исследований (грант 07-01-00218).

Литература

1. *Haralick R. M., Shapiro L. G.* Image segmentation techniques // *Computer Vision, Graphics and Image Processing*, **29**, 100–132, 1985.
2. *Pal N. R., Pal S. K.* A review on image segmentation techniques // *Pattern Recognition*, **26**, 1277–1294, 1993.
3. *Zhu S. C., Yuille Y.* Region competition: Unifying snakes, region growing, and Bayes/MDL for multiband image segmentation // *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **18**, 884–900, 1996.
4. *Zhang A.* A survey on evaluation methods for image segmentation // *Pattern Recognition*, **29**, 1235–1346, 1996.
5. *Li J., Gray R. M.* Image Segmentation and Compression Using Hidden Markov Models (The International Series in Engineering and Computer Science). – Kluwer Academic Publishers, 2000.
6. *Pham D. L., Xu C., Prince J. L.* Current methods in medical image segmentation // *Annual Review of Biomedical Engineering*, **2**, 315–337, 2000.
7. *Shapiro L. G., Stockman G. C.* Computer Vision. – New Jersey, Prentice-Hall, 2001.
8. *Sharon B., Galun M., Sharon D., Bash R., Brandt A.* Hierarchy and adaptivity in segmenting visual scenes // *Nature*, **442**, 810–813, 2006.
9. Wikipedia-Segmentation (image processing)
URL: [http://en.wikipedia.org/wiki/Segmentation_\(image_processing\)](http://en.wikipedia.org/wiki/Segmentation_(image_processing))
10. *Баранова О., Вежневцев А.* Методы сегментации изображений: автоматическая сегментация // *Графика и мультимедиа*,
URL: <http://cgm.graphicon.ru/content/view/147/73/>
11. *Malsburg C. von der.* The correlation theory of brain function // Internal report 81-2, Max-Planck Institute for Biophysical Chemistry, 1981 (reprinted in *Models of Neural Networks*, E. Domany, J.L. van Hemmen, K. Schulten (Eds.)) – Springer, New York, 1994, pp. 95–119.
12. *Gray C. M., Konig P., Engel A. K., Singer W.* Oscillatory responses in cat visual cortex exhibit intercolumnar synchronization which reflects global stimulus properties // *Nature*, **388**, 334–337, 1989.
13. *Eckhorn R., Bauer R., Jordon W., Brosch M., Kruse W., Munk M., Reitboeck H. J.* Coherent oscillations: a mechanism of feature linking in the visual cortex // *Biol. Cybern.*, **60**, 121–130, 1988.

14. *Singer W., Gray C.M.* Visual feature integration and the temporal correlation hypothesis // *Ann. Rev. Neurosci.*, **18**, 555–586, 1995.
15. *Singer W.* Neuronal synchrony: A versatile code for the definition of relations // *Neuron*, **24**, 49–65, 1999.
16. *Wang D.L.* The time dimension for scene analysis // *IEEE Trans. Neural Networks*, **16**, 1401–1426, 2005.
17. *Абарбанель Г.Д.И., Рабинович М.И., Селверстон А., и др.* Синхронизация в нейронных ансамблях // *Успехи физических наук*, **166**, № 4, 363–390, 1996.
18. *Борисюк Г.Н., Борисюк Р.М., Казанович Я.Б., Иваницкий Г.Р.* Моделирование динамики нейронной активности и обработка информации в мозге — итоги «десятилетия» // *Успехи физических наук*, **172**, № 10, 1189–1214, 2002.
19. *Kuzmina M., Manykin E., Surina I.* Oscillatory networks with self-organized dynamical connections for synchronization-based image segmentation // *BioSystems*, **76**, 43–53, 2004.
20. *Кузьмина М.Г., Манькин Э.А., Сурина И.И.* Модель осцилляторной сети, имитирующая основанное на синхронизации функционирование зрительной коры // *Нейроинформатика-2001*. III Всероссийская научно-техническая конференция, т. 1, под ред. *А.А. Ежова*, с. 191–200, Москва, МИФИ, 2001.
21. *Кузьмина М.Г., Манькин Э.А.* Осцилляторная сеть для сегментации изображений: новые разработки // *Нейроинформатика-2004*. VII Всероссийская научно-техническая конференция, т. 1, под ред. *О.А. Мишулиной*, с. 262–268, Москва, МИФИ, 2004.
22. *Гричук С., Кузьмина М.Г., Манькин Э.А.* Селективная сегментация реальных изображений осцилляторно-сетевым методом // *Нейроинформатика-2007*. IX Всероссийская научно-техническая конференция, т. 3, под ред. *О.А. Мишулиной*, с. 235–244, Москва, МИФИ, 2007.
23. *Казанович Я.Б., Шматченко В.В.* Осцилляторные нейросетевые модели сегментации изображений и зрительного внимания // *Нейроинформатика-2004*. VI Всероссийская научно-техническая конференция. *Лекции по нейроинформатике*, т. 1, под ред. *Ю.В. Тюменцева*, с. 72–125, Москва, МИФИ, 2004.
24. *Li Z.* A neural model of contour integration in the primary visual cortex // *Neural Computation*, **10**, 903–940, 1998.
25. *Li Z.* Visual segmentation by contextual influences via intra-cortical interactions in the primary visual cortex // *Network*, **10**, 187–212, 1999.
26. *Li Z.* Pre-attentive segmentation in the primary visual cortex // *Spatial Vision*, **13**, 25–50, 2000.

27. Li Z. Computational design and nonlinear dynamics of a recurrent network model of the primary visual cortex // *Neural Computation*, **13**, 1749–1780, 2001.
28. Yamaguchi Y., Shimizu H. Pattern recognition with feature-ground separation by generation of coherent oscillations // *Neural Networks*, **7**, 49–63, 2004.
29. Kapadia M. K., Ito M., Gilbert C. D., Westheimer G. Improvement in visual sensitivity by changes in local context: parallel studies in human observers and in V1 of alert monkeys // *Neuron*, **15**, 843–856, 1995.
30. Choe Y., Miikkulainen R. Contour integration and segmentation with self-organized lateral connections // *Biol. Cybern.*, **90**, 75–88, 2004.
31. Choe Y., Miikkulainen R. Self-organization and segmentation in a laterally connected orientation map of spiking neurons // *Neurocomputing*, **21**, 139–157, 1998.
32. Eckhorn R., Reitboeck H.J., Amdt M., Dicke P. Feature linking via synchronization among distributed assemblies: Simulation of results for cat visual cortex // *Neural Computation*, **2**, 293–307, 1990.
33. Yu B., Zhang L. Pulse-coupled neural networks for contour and motion matching // *IEEE Trans. Neural Networks*, **15**, 1186–1201, 2004.
34. Opara R., Wörgötter F. A fast and robust cluster update algorithm for image segmentation in spine-lattice models without annealing – Visual latencies revisited // *Neural Computation*, **10**, 1547–1566, 1998.
35. Opara R., Wörgötter F. Using visual latencies to improve image segmentation // *Neural Computation*, **8**, 1493–1520, 1996.
36. Wang D.L., Terman D. Locally excitatory globally inhibitory oscillator network // *IEEE Trans. Neural Networks*, **6**, 283–286, 1995.
37. Wang D.L., Terman D. Image segmentation based on oscillatory correlation // *Neural Computation*, **9**, 805–836, 1997.
38. Chen K., Wang D.L., Liu X. Weight adaptation and oscillatory correlation for image segmentation // *IEEE Trans. Neural Networks*, **11**, 1106–1123, 2000.
39. Chen K., Wang D.L. A dynamically coupled neural oscillator networks for image segmentation // *Neural Networks*, **15**, 423–439, 2002.
40. Caelli T., Bischof W. Machine learning and image interpretation. – Plenum Press, New York, 1997.
41. Weickert J. A review of nonlinear diffusion filtering // In Scale-space theory in computer vision, B. Romany, L. Florack, J. Koenderick, M. Viergever (Eds.), pp. 3–28, Springer, Berlin, 1997.
42. Ursino M., La Cara G.E., Sarti A. Binding and segmentation of multiple objects through neural oscillators inhibited by contour information // *Biol. Cybern.*, **89**, 56–70, 2003.

43. Ursino M., La Cara G.E. Modeling segmentation of a visual scene via neural oscillators: fragmentation, discovery of details and attention // *Network*, **15**, 69–89, 2004.
44. Kazanovich Y., Borisyuk R. Object selection by an oscillatory neural network // *BioSystems*, **67**, 103–111, 2002.
45. Borisyuk R., Kazanovich Y. Oscillatory model of attention-guided object selection and novelty detection // *Neural Networks*, **17**, 899–915, 2004.
46. Schillen T.B., Konig P. Binding by temporal structure in multiple feature domains of an oscillatory neural network // *Biol. Cybern.*, **70**, 397–405, 1994.
47. Verschure P., Konig P. On the role of biophysical properties of cortical neurons in binding and segmentation of visual scenes // *Neural Computation*, **11**, 1113–1138, 1999.
48. Rhouma M.B.H., Frigui H. Self-organization of pulsed-coupled oscillators with application to clustering // *IEEE Trans. Pattern Analysis and Machine Intelligence*, **23**, 180–195, 2001.
49. Lindblad T., Kinsler J.M. Image processing using pulse-coupled neural networks, 2nd ed. – Springer-Verlag, 2005.
50. Mirollo R.E., Strogatz S.H. Synchronization of pulse-coupled biological oscillators // *SIAM J. Applied Mathematics*, **50**, 1645–1662, 1990.
51. Carson C., Belongie S., Greenspan H., Malik J. Blobworld: Image segmentation using expectation-maximization and its application to image querying // *IEEE Trans. Pattern Analysis and Machine Intelligence*, **24**, 1026–1038, 2002.
52. Zhao L., Macau E. A network of dynamically coupled chaotic maps for scene segmentation // *IEEE Trans. on Neural Networks*, **12**, 1375–1385, 2001.
53. Zhao L., Furukawa R.A., de Carvalho A. A network of coupled chaotic maps for adaptive multi-scale image segmentation // *Int. J. Neural Systems*, **13**, 129–137, 2003.
54. Zhao L., de Carvalho A., Li Z. Pixel clustering by adaptive pixel moving and chaotic synchronization // *IEEE Trans. on Neural Networks*, **15**, 1176–1185, 2004.
55. Strogatz S. *Nonlinear Dynamics and Chaos*. – Perseus Publishing, 2000.
56. Kaneko K. Clustering, coding switching, hierarchical ordering, and coding in a network of chaotic elements // *Physica D*, **41**, 137–172, 1990.
57. Buhmann J.M., Lange T., Ramacher U. Image segmentation by networks of spiking neurons // *Neural Computation*, **17**, 1010–1031, 2005.
58. Knoblauch A., Palm G. Pattern separation and synchronization in spiking associative memories and visual areas // *Neural Networks*, **14**, 763–780, 2001.

59. Knoblauch A., Palm G. Scene segmentation by spike synchronization in reciprocally connected visual areas. I. Local effects of cortical feedback // *Biol. Cybern.*, **87**, 151–167, 2002.
60. Palm G., Knoblauch A. Scene segmentation through synchronization // In *Neurobiology of Attention*, L. Itti, G. Rees, and J. K. Tsotsos (Eds.) pp. 618–623. Elsevier, San Diego, CA, 2005.
61. Knoblauch A., Palm G. Scene segmentation by spike synchronization in reciprocally connected visual areas. II. Global assemblies and synchronization on larger space and time scales // *Biol. Cybern.*, **87**, 168–184, 2002.
62. Willshaw D., Buneman O., Longuet-Higgins H. Non-holographic associative memory // *Nature*, **222**, 960–962, 1969.
63. Engel A., Konig P., Singer W. Direct physiological evidence for scene segmentation by temporal coding // *Proc. Natl. Acad. Sci. (USA)*, **88**, 9136–9140, 1991.
64. *Neurobiology of Attention*, G. Itti, G. Rees, J. K. Tsotsos (Eds.) – Amsterdam, Elsevier, 2005.
65. Steinmetz P. N., Roy A., Fitzgerald P., Hsiao S. S., Johnson K. O., Niebur E. Attention modulates synchronized neuronal firing in primate somatosensory cortex // *Nature*, **404**, 187–190, 2000.
66. Fries P., Schroeder J.-H., Roelfsema P. R., Singer W., Engel A. K. Oscillatory neural synchronization in primary visual cortex as a correlate of stimulus selection // *J. Neurosci.*, **22**, 3739–3754, 2002.
67. Fries P., Reynolds J., Rorie A., Desimone R. Modulation of oscillatory neuronal synchronization by selective visual attention // *Science*, **291**, 1560–1563, 2001.
68. Doesburg S. M., Roggeveen A. B., Kitajo K., Ward L. M. Large-scale gamma-band phase synchronization and selective attention // *Cerebral Cortex*, 2007 (in press).
69. Broussard R. P., Rogers S. K., Oxley M. E., Tarr G. L. Physiologically motivated image fusion for object detection using a pulse coupled neural network // *IEEE Trans. Neural Networks*, **10**, 554–563, 1999.
70. Jin Y., Angelini E., Laine A. Wavelets in Medical Image Processing: Denoising, Segmentation, and Registration // In *Handbook of Biomedical Image Analysis*. Vol. 1, Segmentation models, part A (Topics in Biomedical Engineering. International Book Series), J. S. Suri, D. L. Wilson, S. Laxminarayan (Eds.). pp. 305–358. Springer, 2005.
71. Polakowski W., Rogers S., Ruck D., Hoffmeister J., Raines R. Computer aided breast cancer detection and diagnosis of masses using difference of gaussians and derivative-based feature saliency // *IEEE Trans. Med. Imag.*, **16**, 811–819, 1997.

72. Rogers S. K., Colombi J. M., Martin C. E., Gainey J. C., Fielding K. H., Burns T. J., Ruck D. W., Kabrisky M., Oxley M. Neural networks for automatic target recognition // *IEEE Trans. Neural Networks*, **8**, 1153–1184, 1995.
73. Itti L., Koch C. A saliency-based search mechanism for overt and covert shifts of visual attention // *Vision Research*, **40**, 1489–506, 2000.
74. Itti L., Koch C. Computational modeling of visual attention // *Nature Reviews Neuroscience*, **2**, 194–203, 2001.
75. Labbi A., Milanese R., Bosch H. Visual object segmentation using FitzHugh-Nagumo oscillators. Nonlinear Analysis // *Theory, Methods & Applications*, **47**, 5827–5838, 2001.
76. Moran J., Desimone R. Selective attention gates visual processing in the extrastriate cortex // *Science*, **229**, 782–784, 1985.
77. Reynolds J., Desimone R. The role of neural mechanisms of attention in solving the binding problem // *Neuron*, **24**, 19–29, 1999.

Яков Борисович КАЗАНОВИЧ, заведующий Лабораторией нейронных сетей Института математических проблем биологии РАН, кандидат физико-математических наук (Пушино, Московская область). Область научных интересов: нейросетевые модели в нейрофизиологии и психологии, теория динамических систем. Автор (соавтор) более 70 публикаций.

Ю. И. НЕЧАЕВ

Государственный морской технический университет,
Институт высокопроизводительных вычислений
и информационных систем,
г. Санкт-Петербург
E-mail: int@csa.ru

**НЕЙРОНЕЧЕТКАЯ СИСТЕМА ПОДДЕРЖКИ ПРИНЯТИЯ
РЕШЕНИЙ ПРИ ОЦЕНКЕ ПОВЕДЕНИЯ СЛОЖНОГО
ДИНАМИЧЕСКОГО ОБЪЕКТА**

Аннотация

Обсуждается проблема нейронечеткого моделирования при разработке бортовой интеллектуальной системы (ИС) реального времени. В качестве практического приложения рассмотрены особенности взаимодействия судна с ледовым полем различной интенсивности. Определены принципы использования нейронечетких технологий в задачах повышения надежности функционирования ИС. Представлены результаты моделирования динамики взаимодействия на базе различных вычислительных технологий.

Yu. NECHAEV

Saint-Petersburg State Marine Technical University,
Institute for High-Performance Computing and Information Systems,
Saint-Petersburg
E-mail: int@csa.ru

**NEURO-FUZZY DECISION SUPPORT SYSTEM
FOR ESTIMATION
OF COMPLEX DYNAMIC OBJECT BEHAVIOUR**

Abstract

The problem of neuro-fuzzy modeling is discussed by development of onboard real time intelligent system (IS). As a practical application some interaction features of a ship with an ice field of various intensity are considered. Application principles for using of neuro-fuzzy technologies to increase reliability of IS functioning are stated. Modeling results for the dynamics of interaction are submitted based on various computing technologies.

Мои научные полигоны — это прежде всего эксперимент, возможность познать новые физические эффекты и закономерности. Рассматриваемые в настоящей лекции методы и модели, основанные на новых подходах к обработке и интерпретации информации, — это всего лишь инструмент, дополняющий современный арсенал средств моделирования.¹

Введение

Управление судном как сложным многорежимным динамическим объектом (ДО) при эксплуатации в районе Северного шельфа связано с решением сложных задач анализа и интерпретации информации с помощью адаптивных алгоритмов. Реализация этих алгоритмов определила широкое применение методов математического моделирования, построенных на основе классической теории управления, нечетких и нейросетевых структур. Использование методов и средств моделирования при создании бортовых интеллектуальных систем (ИС) новых поколений осуществляется на основе концепции и принципов обработки информации, сформулированных автором во время чтения лекций на конференциях по нейроинформатике (МИФИ-2002, МИФИ-2003). Реализация этого подхода осуществляется в мультипроцессорной вычислительной среде, что позволяет повысить функциональную эффективность, надежность и живучесть ИС. Алгоритмическое и программное обеспечение бортовых ИС разрабатываются на основе достижений вычислительной математики и выступают в роли одного из основных концептуальных элементов управления и принятия решений. Именно этот элемент в условиях непрерывного изменения динамики объекта и внешней среды определяет совершенство ИС [1–51].

Ниже обсуждается подход и технология, обеспечивающая функционирование ИС судов активного ледового плавания для арктического шельфа. Особенности эксплуатации этих судов потребовали корректировки методов построения бортовых ИС на базе эффективного математического аппарата, разработанного на основе принципов обработки информации, изложенных в работах [22, 23]. Интерфейс оператора поддерживается за счет использования простых и наглядных средств поддержки принятия решений по управлению судном в ледовых условиях.

¹Ю. Нечаев. Курс лекций «Нейрокомпьютерные системы».

Стратегии и методы управления

Концепция создания ИС контроля динамики судна при движении во льдах предусматривает реализацию принципов обработки информации с использованием конкурирующих вычислительных технологий. Эти технологии основаны на различных подходах, обеспечивающих принятие решений по управлению судном при сложном нелинейном взаимодействии судна с внешней средой в условиях неопределенности и неполноты исходной информации. Сопоставление результатов анализа ситуации (анализ альтернатив) позволяет определить предпочтительную вычислительную технологию, развивая которую можно повысить качество управления и эффективность функционирования ИС.

Фундаментальные результаты общей теории самоорганизации показывают, что современная наука управления, как и другие науки, начинает переходить на путь естественности, т. е. на новые концептуальные основы. В свойстве самоуправляемости и направленной самоорганизации нелинейных систем проявляется новый взгляд на проблему управления, видна тенденция перехода от классических методов централизованного управления к современным методам синергетики и теории самоуправления [20, 31, 34, 37].

Усложнение задач принятия решений по управлению движением судов и технических средств освоения Северного шельфа сопровождается расширением применений в этой области наряду с классической теорией оптимального управления технологий искусственного интеллекта (ИИ). Этому способствует постоянное совершенствование средств вычислительной техники и разрабатываемого программного обеспечения. Бортовые компьютеры, устанавливаемые на современных морских судах и других транспортных средствах, имеют характеристики, достаточные для развертывания в их памяти весьма оснащенного математического обеспечения, предназначенного для организации движения, навигации и бортовой диагностики [48].

Проектирование систем управления, предназначенных для работы в условиях неопределенности, может основываться на некоторых гарантирующих принципах, ориентированных на наихудшие из возможных условия функционирования системы. Это привело к созданию теории гарантированного или робастного управления. Практика применения этих методов показывает, что в ряде случаев не удается достигнуть ожидаемых показателей эффективности проектируемых систем. Одним из основных слагаемых,

составляющих понятие эффективности, оказывается показатель надежности, понимаемый как способность системы выполнять основную задачу вопреки неблагоприятно складывающимся внешним обстоятельствам, иначе говоря, устойчивость системы к возмущениям. Часто оказывается так, что показатель надежности или устойчивости вступает в противоречие с другими составляющими эффективности в той мере, в какой последние приводят к усложнению проектируемой системы.

Опыт проектирования сложных систем в большой степени связан с использованием теории ИИ. Одним из основных достижений этой теории является возможность проектирования систем, функционирующих в условиях неопределенности. В нестандартных ситуациях, когда система подвергается нерасчетным возмущениям, требования к обработке входной информации существенно меняются — дефицит времени предписывает выделять только ту информацию, которая требуется для выполнения основной задачи и отбрасывать все остальное, что имело смысл в априорных представлениях об эффективности. Такое обращение с информацией оказывается возможным только в случае ее надлежащего структурирования, или оснащения информации семантикой [48].

В реальных задачах, когда появляются отклонения между априорной моделью и действительным описанием управляемого процесса, такой подход может приводить к неудачным результатам. Для устойчивого функционирования система должна быть достаточно *грубой* к возмущениям такого рода, либо управляющая сторона (оператор) должна иметь возможность вмешательства в ход процесса в случае его отклонения от установленного режима. Такое вмешательство может быть обеспечено при наличии двух условий [48]:

- априорно синтезируемые алгоритмы настолько *просты*, что возможна их коррекция в оперативном режиме;
- имеются критерии контроля ситуации, обеспечивающие необходимость такого вмешательства.

Критериальный базис бортовых систем разрабатывается для задач двух разных типов — задач локальной стабилизации, которые обычно используют в задачах синтеза, и задач глобального контроля и управления. Последние связаны с большими отклонениями в управляемой системе и с возможностью выхода фазовой траектории на границу области устойчивости нелинейной системы.

Теория случайных процессов и, в частности, стохастические дифференциальные уравнения предоставляют средства для существенного расширения возможностей синтеза на основе введения более универсального понятия малости возмущений. Считается, что возмущения малы в среднем по ансамблю всех их возможных реализаций. Большие и даже сколь угодно большие величины возмущений не исключаются совсем, а малыми оказываются их вероятности в сравнении с вероятностями появления возмущений с малыми абсолютными величинами. В результате стохастические модели оказываются более адекватным средством синтеза систем управления, чем соответствующие детерминированные. Практическая сторона дела состоит в том, что эти модели позволяют не только осуществить локальную стабилизацию состояния равновесия невозмущенной системы, но и контролировать и прогнозировать такие состояния в системе, в окрестности которых ее движение уже не аппроксимируется линеаризованной системой.

В ряде случаев неопределенность в описании системы может быть охарактеризована с помощью сингулярных возмущений. Получаемые при этом критерии робастности оказываются существенно более простыми, хотя, как правило, приближенными. В пользу сингулярных возмущений говорит еще и то обстоятельство, что именно такие возмущения являются определяющими в системах, содержащих неизвестные малые постоянные времени, быстрые движения, неучтенную динамику и т. п. При этом, пренебрежение такими параметрами, в отличие от регулярного случая, приводит к изменению существенной характеристики задачи — ее размерности.

Таким образом, при рассмотрении задачи контроля ледовой прочности судна целесообразно строить алгоритм управления в рамках принципов обработки информации в мультипроцессорной вычислительной среде при активном сочетании классической теории оптимального управления и новых принципов обработки информации на базе теории нечеткой логики, искусственных нейронных сетей и генетических алгоритмов.

Архитектура и принципы функционирования системы

Мониторинг сложных систем неразрывно связан с обработкой большого объема измерительной информации. При этом в условиях непрерывного процесса взаимодействия ДО с внешней средой часто приходится сталкиваться с недостаточной определенностью наблюдаемых данных, что за-

трудняет интерпретацию результатов их обработки. Решить данную задачу и получить наиболее полную и достоверную информацию о текущем состоянии сложных систем возможно с использованием методов ИИ. Эти методы позволяют преодолеть влияние априорной неопределенности исходных данных на результат принятия окончательного решения и тем самым расширяют классические подходы к обработке измерительной информации [1, 2, 11, 40–42].

Разработка системы интеллектуальной поддержки оператора при принятии решений по контролю динамики судна при движении во льдах предполагает реализацию принципов обработки информации в многопроцессорной вычислительной среде. Помимо этих принципов при синтезе системы реализуется принцип несовместимости, заключающийся в том, что сложность системы и точность ее анализа традиционными математическими методами находятся в состоянии взаимного противоречия [1, 2].

Для повышения эффективности принятия решений в условиях неопределенности и неполноты исходной информации в системах принятия решений используются методы и модели интеллектуального управления. В качестве компонент системы находят применение ИНС, эволюционные алгоритмы и системы, основанные на знаниях. Разработанная на их основе системы нечеткого управления получили широкое распространение при контроле сложных объектов в различных областях технических приложений.

Среди актуальных направлений разработки нечетких систем поддержки принятия решений следует выделить повышение их адаптивности [1, 4, 7, 37]. В работах [7, 37] предложены различные варианты адаптивных нечетких регуляторов, функционирующих в условиях полной априорной неопределенности о структуре и параметрах объекта управления. Однако, в рассматриваемой задаче динамический объект является многорежимным [4, 43], что значительно усложняет задачу контроля динамики судна [28, 42].

Учет особенностей поведения судна в этих условиях реализуется в рамках многоструктурного анализа. При этом структура системы известна и имеются специально разработанные модели обработки измерительной информации, но неизвестны параметры внешней среды и моменты времени, связанные со сменой управляющих структур. Эффективность функционирования такой системы зависит от надежности моделей обработки информации, программно-аппаратной избыточности и времени адаптации.

В бортовых ИС реального времени для обеспечения процесса приня-

тия решений используется сложное преобразование информации (рис. 1), поступающей от датчиков измерительной системы. Для повышения надежности функционирования ИС в условиях неопределенности и неполноты исходной информации в базе знаний предусматривается механизм имитационного моделирования информационных потоков в рамках принципа конкуренции. Этот механизм учитывает специфику исследуемых ситуаций и информацию о динамике судна и внешней среды [22–30].

Технические средства бортовой ИС. Практическая реализация принципов обработки информации в мультипроцессорной вычислительной среде осуществлена на высокопроизводительных вычислительных платформах. Программно-аппаратный комплекс широко использует параллельное программирование и средства визуализации.



Рис. 1. Общая схема функционирования системы контроля прочности

Измерительный блок ИС включает датчики динамических измерений параметров взаимодействия судна и внешней среды, установленные в зоне контакта. Для повышения эффективности функционирования ИС используется дополнительная информация в виде данных метеоразведки, ледовой

разведки и авиатехники. Технические средства ИС реализованы на базе стандартных комплектующих, программно-аппаратных и измерительных средств, пригодных для бортовых систем реального времени.

Особенности функционирования системы. Функционирование ИС реального времени обеспечивается в условиях непрерывного изменения динамики судна и внешней среды. Методологической основой для построения алгоритмических процедур принятия решений в нечетких условиях является концепция оптимальности решения и имеющихся ресурсов (нечеткая цель и ограничения).

При формализации знаний с достаточной для практических целей точностью выделяют определенные промежутки времени, в течение которых состояние системы меняется незначительно (теория нечетких интервалов). Это позволяет принять гипотезу *квазистационарности* [11] и использовать хорошо разработанный аппарат «инженерии знаний». Адекватное отображение информации достигается с помощью *интегрированных моделей* представления знаний, соединяющих возможности схем представления на разных уровнях абстракции. При этом логическая структура определяет модель объекта управления, а продукционная — модель принятия решения [28].

Многорежимный принцип управления. Движение судна, как много-режимной динамической системы, описывается векторным дифференциальным уравнением [4, 43]:

$$x' = A + Bu, \quad (1)$$

где $x = (x_1, \dots, x_n)^T \in X \subset R^n$ — фазовый вектор динамической системы; $u = (u_1, \dots, u_m)^T \in U \subset R^m$ — вектор управляющих воздействий; $k = (k_1, \dots, k_p)^T$ — вектор параметров регулятора. Элементы матриц A и B являются функциями от вектора $\lambda = (\lambda_1, \dots, \lambda_S)^T \in \Lambda \subset R^S$ и времени $t \in [t_0, t_f]$. При этом λ является внешним вектором рассматриваемой динамической системы, а область изменения его значений Λ — внешним множеством.

Принцип многорежимности обеспечивает возможность настройки системы управления на различные режимы движения судна во льдах:

- обычный режим, связанный с преодолением сплошного ледового поля при движении без помощи ледокола;

- режим движения «набегами» в сложных ледовых условиях;
- режим движения в битом льду за ледоколом при различной сплоченности льда;
- режим движения в дрейфующих льдах, связанный со значительными ударными нагрузками.

Задача состоит в том, чтобы наилучшим образом свести движение системы к некоторому заранее предписанному движению с учетом неопределенности в параметрах $\lambda \in \Lambda$. При этом воздействовать на качество регулирования можно путем варьирования значений параметров $k \in K$ регулятора. В сложных ситуациях при достаточно большом внешнем множестве Λ (особенно при движении в торосистых льдах) для различных λ используют разные значения k . Зависимость $k = k(\lambda), \forall \lambda \in \Lambda$ реализуется *модулем коррекции* (корректором), а совокупность из регулятора и корректора образует *контроллер* [4, 43].

Реализация управления в системах контроля скорости судна при движении во льдах связана с решением сложных задач нелинейного преобразования информации при различных режимах движения, определяемых внешними условиями и особенностями взаимодействия судна с ледовым полем различной сплоченности. В этих условиях задача контроля скорости основана на использовании нового подхода к анализу и интерпретации информации [22, 23] и основанного на развитии концепции «мягких вычислений» [51]. Этот подход предусматривает использование теоретических принципов, позволяющих рационально организовать вычислительную технологию обработки данных измерений, а также формализовать поток информации при реализации нечеткого логического вывода в мультипроцессорной вычислительной среде. Реализация этих принципов дает возможность повысить эффективность функционирования ИС при непрерывном изменении динамики объекта и внешней среды. Проверка корректности алгоритмов управления и принятия решений осуществляется на основе общих требований к алгоритмическому обеспечению системы. Применительно к параллельным алгоритмам логического управления понятие корректности связано со специфическими свойствами таких алгоритмов: непротиворечивостью, устойчивостью и самосогласованностью.

Особенности обработки информации. Функционирование бортовых ИС связано с оперативным контролем ситуации и прогнозированием ее

развития в условиях непрерывного изменения динамики судна и внешней среды. Обеспечение контроля осуществляется на основе адаптивных алгоритмов, способных изменять свою структуру при изменении поведения судна на волнении. При синтезе таких алгоритмов используют различные подходы — детерминистский, стохастический и подход на основе принципов самоорганизации. Первые два подхода предполагают наличие в исходных данных полного информационного базиса, т. е. всех определяющих параметров и факторов, которые необходимо учитывать при анализе ситуации.

Принцип нелинейной самоорганизации [1] требует минимального объема априорной информации. Методологической основой этого принципа является допущение о том, что вся информация о структуре и поведении динамической системы содержится в данных измерений и критериальных соотношениях, определяющих выбор структуры модели. Для прогнозирования состояния судна в условиях непрерывного изменения внешней среды необходимо сформулировать математическую модель, содержащую всю необходимую информацию о параметрах и изменении состояния судна в течение заданного интервала времени. Именно поэтому принцип нелинейной самоорганизации наиболее эффективен в задачах контроля и прогнозирования ситуаций, связанных с внезапными (скачкообразными) изменениями в поведении судна. На основании данных прогноза ИС вырабатывает практические рекомендации по управлению судном таким образом, чтобы избежать этой опасности. Реализация принципа нелинейной самоорганизации при разработке базы знаний ИС требует большого объема вычислительных операций, связанных с предварительной оценкой динамики объекта на основе математического моделирования с последующей формулировкой соответствующих критериальных оценок [20, 34].

Поток информации в ИС представляется последовательностью вычислительных процедур. Эти процедуры определяют операции преобразования сигналов от датчиков измерительной системы до их использования при функционировании алгоритмов, построенных на основе стандартных, нечетких и нейросетевых моделей. Типичная форма исследуемого сигнала, характеризующего динамику взаимодействия судна в ледовых условиях, представлена на рис. 2.

Здесь изображена временная последовательность сигналов от датчиков измерительной системы при прохождении судном торосистого ледового поля. На основе этой информации создаются нейросетевые ансамбли и когнитивные образы [10, 28, 42] описывающие реальные динамические кар-




Рис. 2. Пример записи сигналов от датчиков, установленных в зоне контакта

тины и совокупность различных сочетаний параметров торосистого льда. Указанные структуры используются при реализации механизма логического вывода по прецедентам [14, 25, 28].

Анализ альтернатив. Выбор оптимального решения в рамках принципа конкуренции обеспечивается системой поддержки принятия решений. В основу функционирования системы принят метод анализа иерархий [49]. На множестве альтернатив каждому критерию ставится в соответствие лингвистические переменные (ЛП) с заданным терм-множеством. Базовое множество ЛП определяет допустимое множество значений критериев. Для оценки эффективности альтернативы по отдельному критерию вводится ЛП с соответствующим терм-множеством, мощность которого совпадает с мощностью заданного терм-множества. Между двумя ЛП существует причинно-следственная связь, которая представляется в виде нечеткого импликативного отношения:

$$\mu_{R_{ij}}(x_i, y) : X_i \times Y \rightarrow [0, 1], x_i \in X_i, y \in Y, \quad (2)$$

где X_i — базовое множество значений i -го критерия; Y — базовое множество значений оценки эффективности альтернатив.

Исследуемые модели и объекты управления в ИС новых поколений представляют собой класс динамических систем, состояние которых непрерывно изменяется во времени. Особенности поведения ДО в непрерывно изменяющейся среде определяют использование различных подходов к проблеме моделирования, сочетающих традиционные методы и модели анализа и прогноза динамических ситуаций с новым математическим аппаратом, включающим ИНС [5, 38] и генетические алгоритмы (ГА) [28].

Динамическая база знаний

Система управления осуществляет выбор оптимальной скорости судна в зависимости от интенсивности ледовой нагрузки. Процесс управления организуется в рамках концепции «мягких вычислений» [51]. Управляющий алгоритм представляется набором логических правил IF . . . THEN [1, 11, 36]. В качестве исходной информации используются показания датчиков деформаций корпуса, установленных в зоне контакта [42].

Нечеткая формальная система. В бортовых ИС находят применение модели нечеткого вывода, основанные на различных формальных конструкциях, обеспечивающих разрешение нечетких логических правил. При реализации измерительной и экспертной информации в ИС используются правила нечеткого вывода, использующие принцип обобщения Л.Заде [9] для нечеткого вывода, в котором высказывания моделируются нечеткими множествами, позволяющими вывести нечеткое заключение.

Основная проблема реализации нечеткого управления в бортовых ИС заключается в построении функций принадлежности (ФП), особенно в условной части логического правила, содержащего несколько нечетких переменных. Построение ФП осуществляется на основе обработки измерительной и экспертной информации, а также материалов конкретного проекта судна. При этом реализуются два подхода. Первый подход состоит в формализации нечетких знаний в процессе разработки ИС. Он основан на традиционном представлении экспертных знаний и предусматривает построение ФП базовых правил, «зашитых» в программный комплекс. Второй подход реализуется в процессе функционирования ИС и связан с построением текущих значений ФП на основе данных динамических измерений. Алгоритмы и программное обеспечение построения ФП основаны на использовании статистических методов и нейросетевых технологий [22, 28].

Композиционная модель нечеткого вывода описывает связь всех возможных состояний логической системы с управляющими воздействиями и формально записывается в виде (X, R, Y) , где $X = \{x_1, \dots, x_n\}$; $Y = \{y_1, \dots, y_m\}$ — базовые множества, на которых заданы входы A_i и выходы B_i нечеткой системы; R — нечеткое соответствие «вход-выход», которое строится на основе формализации нечетких стратегий. Принятие решений при функционировании нечеткой системы знаний осуществляется на основе модели:

$$\text{if } A_1 \text{ then } B_1, \text{ else if } A_2 \text{ then } B_2, \dots, \text{ else if } A_N \text{ then } B_N. \quad (3)$$

Здесь A_1, \dots, A_N — нечеткие подмножества, определенные на базовом множестве X , а B_1, \dots, B_N — нечеткие подмножества из базового множества Y . Эти нечеткие подмножества задаются функциями принадлежности:

$$\mu_{A_i}(x), \mu_{B_i}(y), (x \in X, y \in Y); \quad (4)$$

$$R = A \times B = \sum_{i=1}^n \sum_{j=1}^m \{\mu_A(x_i) \wedge \mu_B(y_j) \mid (x_i, y_j)\} \quad (5)$$

или

$$\mu_R(x, y) = \mu_A(x) \wedge \mu_B(y) = \min(\mu_A(x), \mu_B(y)) \quad (6)$$

где $\mu_A(x)$, $\mu_B(y)$ — функции принадлежности элементов x, y множеств A и B .

В качестве нечеткой импликации при реализации механизма логического вывода в ИС использованы алгоритмы Мамдани и Сугено [28, 36]. Система реализует выбор оптимальной скорости судна в зависимости от интенсивности ледовой нагрузки. Процесс управления организуется на основе концепции конкуренции с использованием методов классической математики, нечеткой логики и ИНС [42].

В сложных задачах анализа и интерпретации данных динамических измерений используется модель нечеткого логического вывода по прецедентам. Обобщенная модель вывода по прецедентам реализуется в следующем виде [25]:

$$\langle S_{PB}, M(W), M(W, V), M_{FD} \rangle, \quad (7)$$

где S_{PB} — система нейросетевого представления базы прецедентов; $M(W)$ — модели нечеткого вывода по прецедентам; $M(W, V)$ — комплексная модель нечеткого вывода для совокупности исследуемых процессов; M_{FD} — модель анализа альтернатив и формирователя решений.

Адаптивная компонента. При формализации знаний и механизма логического вывода важное значение имеет организация адаптивной компоненты на основе принципов обработки информации в мультипроцессорной вычислительной среде [22, 23]. Одно из направлений ее организации связано с реализацией принципа адаптивного резонанса (Adaptive Resonance Theory — ART), получившего широкое распространение при построении и обучении нейронных сетей [38]. Формируемые на основе этого принципа свойства базы знаний наиболее четко проявляются при обеспечении функционирования ИС в задачах интерпретации экстремальных ситуаций в условиях неопределенности и неполноты исходной информации (рис. 3).



Рис. 3. Адаптивная компонента

Наиболее важной особенностью системы знаний, использующей принципы адаптивного резонанса, являются [26]:

- возможность сохранения *свойства пластичности* при запоминании новой информации в процессе функционирования ИС;
- предотвращение модификации исходной базы знаний за счет формирования новых правил, описывающих возникшую нестандартную ситуацию.

При функционировании ИС происходит накопление новой информации и корректировка базы знаний. Динамическая база знаний совершенствуется и расширяется за счет включения новых моделей. Подобно нейронной сети ART, база знаний имеет внутренний детектор новизны — тест на сравне-

ние предъявленной нестандартной ситуации (нового образа) с содержимым ансамбля логических правил.

При реализации механизма логического вывода новый образ, предъявленный на основе поступившей информации, классифицируется с одновременной уточняющей модификацией процедур, определяющих условную часть логического правила. Такую ситуацию можно интерпретировать как возникновение адаптивного резонанса в динамической базе знаний в ответ на предъявление образа. Если резонанс не возникает в пределах некоторого заданного порогового уровня, то успешным считается тест новизны, и образ (нестандартная ситуация) воспринимается системой как новый.

Модификация логических правил, не испытавших резонанса, при этом не производится. Запомненный образ нестандартной ситуации не будет изменяться, если текущая входная информация не окажется достаточно похожим на него. Таким образом, решается проблема стабильности-пластичности. Новый образ, описывающий нестандартную ситуацию, может порождать создание новых классов таких ситуаций, однако при этом существующая база знаний не разрушается.

Важной особенностью адаптивной компоненты ИС, использующей теорию ART, является реализуемый *шаблон критических черт* информации. Этот шаблон позволяет выделять признаки, предъявленные в некотором образе (нестандартной ситуации), которые являются существенными для системы предварительной обработки информации при реализации механизма логического вывода. Результат распознавания определяется присутствием специфических критических особенностей в нестандартной ситуации.

Задачей адаптивной компоненты является формирование правильной реакции в обоих случаях: «пластичное» решение о появлении нового образа и «стабильное» решение о совпадении со старым образом.

Другой важной особенностью динамической базы знаний, использующей принцип адаптивного резонанса, является *самоадаптация алгоритма поиска* нестандартных ситуаций. Адаптивная компонента использует управляемый алгоритм поиска, основанный на динамической самоорганизации классов прототипов, соответствующих классам векторов в условной части логического правила, путем наращивания структуры, определяющей «действие» в выходной части логического правила.

Если поиск класса, попадающего в «резонанс» с входным вектором по соответствующему критерию сходства не привел к успеху, то создается новый класс (добавляется новая нестандартная ситуация). В противном случае согласно обучающему правилу модифицируется прототип того класса,

который имеет максимальное сходство с входным вектором.

Нейроконтроллер. Реализация принципов обработки информации в мультипроцессорной вычислительной среде [22, 23] осуществляется с использованием многорежимного принципа управления, находящего применение в сложных системах [4, 43]. В этом случае нейроконтроллер представляется кортежем:

$$\Omega = (\Lambda, K, W, V, J), \quad (8)$$

где $\Lambda \subset R^S$ – внешнее множество динамической системы, являющееся областью изменения значений входных векторов нейронной сети; $K \subset R^P$ – область изменения значений искомым коэффициентов регулятора (выходных векторов нейронной сети); $W = \{W_i\}, i = 1, \dots, L + 1$ – набор матриц синаптических весов нейронной сети; L – число «скрытых» слоев в нейронной сети; $V = (v_1, \dots, v_q)^T \in V \subset R^q$ – набор дополнительных изменяемых параметров нейронной сети (параметров в активационных функциях); J – функционал ошибки (рассогласования) между требуемым и реализуемым движением, определяющий характер обучения нейронной сети.

Обеспечение многорежимного контроля динамики судна достигается за счет реализации в системе управления ансамбля нейроконтроллеров (рис. 4).




Рис. 4. Функции, выполняемые ансамблем нейроконтроллеров: $NC - 1, \dots, NC - N$ – ансамбль нейроконтроллеров; $F(\cdot)$ – распределяющая функция; $AS - 1, \dots, AS - N$ – области специализации нейроконтроллеров

Из рис. 4 видно, что ансамбль содержит два вида нейроконтроллеров, каждый из которых имеет свою область специализации AS_i . Первый вид представляет собой нейроконтроллеры NC_i ($i = 1, \dots, N$), формирующие управляющий сигнал. Функция второго вида нейроконтроллера (NC_0) состоит в выработке номера i ($1 \leq i \leq N$) для каждого текущего значения $\lambda \in \Lambda$ в соответствии с зависимостями $F(\lambda)$. Этот номер указывает, какой из нейроконтроллеров NC_i должен осуществлять управление при данном $\lambda \in \Lambda$. Переход от одного нейроконтроллера к другому устанавливаются с помощью распределяющей функции $F(\lambda)$ [4].

Для оценки качества управления, реализуемого нейронной сетью, используется показатель эффективности (критерий оптимальности нейроконтроллера). Этот критерий учитывает наличие у нейроконтроллера варьируемых параметров из областей W и V , а также многорежимность динамической системы.

Математические модели динамики судна при движении во льдах

В основу построения нечетких и нейросетевых моделей динамики судна при движении во льдах положено математическое описание определения необходимой скорости судна исходя из обеспечения прочности на основе рекомендаций работ [12, 33]. Рассмотрим некоторые зависимости, определяющие динамику взаимодействия судна в сплошном и битом льду, а также при работе «набегами» при движении в торосистых льдах.

Контроль скорости судна

Движение судна в сплошном ледовом поле. Этот режим — один из наиболее типичных при движении судна с произвольной скоростью в сплошных льдах [12]:

$$\sigma_{\text{л}} h^2 [A] + h([B] + [C]) + h^{1,86} V^{1,26} k_v + V k_e - P_{ML} = 0, \quad (9)$$

где

$$[A] = \frac{2}{b} \left[0.015 \int_0^{L/2} (0.57(1.6 \cos b + 0.11) \operatorname{tg} \alpha / \sin \beta) dx + 0.11 f_d \int_0^{L/2} \frac{dx}{\sin \beta} \right];$$

$$[B] = 2\rho_0 g \left[0.57 \int_0^{L/2} (y(1.6 \cos \beta + 0.11) \sin \alpha / \sin \beta) dx + 0.5 f_d \int_0^{L/2} \frac{y \cos \alpha}{\sin \beta} dx; \right];$$

$$[C] = 1.2 \frac{B}{2T + B} f_d \rho_0 g B L_c;$$

Здесь $\sigma_{\text{И}} = 6 \cdot 10^5 \text{ Па}$, h — толщина льда; V — скорость судна; $k_v = 150 \cdot 10^3$; $k_e = 61, 5 \cdot 10^3$; P_{ML} — тяга на швартовах; α — угол входа ватерлинии в воду; β — угол наклона борта к вертикали на миделе; $f_d = 0.08$; $\rho_0 = 150 \text{ кг/м}^3$; L_c — длина цилиндрической вставки.

Движение в битом льду. Для оценки сопротивления при движении в битых льдах предложен ряд формул, основанных на обработке результатов натуральных экспериментов и испытаний моделей судов в опытовых бассейнах. Одна из таких формул имеет вид [12]:

$$R = \rho_L (bh)^{1/2} (B/2)^2 [k_1^* (1 + 2f\alpha_H L/B) + k_4^* f\alpha(L/B) s_{\text{сж}}] + \quad (10)$$

$$+ k_2^* \rho_L bh B (f + \alpha_H t g \varphi_{2\Phi}) Fr + k_3^* \rho_L bh L t g^2 \varphi_{2\Phi} Fr^2,$$

b — протяженность мелкобитого льда, м; h — его толщина, м; (α_H — коэффициент полноты носовой ветви КВЛ; α — коэффициент полноты КВЛ; $s_{\text{сж}}$ — сила сжатия льда в баллах; $Fr = V/(gL)^{1/2}$ — число Фруда по длине судна; $k_1^*, k_2^*, k_3^*, k_4^*$ — безразмерные коэффициенты, зависящие от сплоченности и силы тяжести льда [12].

Работа судна «набегами». Наибольший практический интерес при этом режиме представляет оценка действующих усилий на этапе продвижения судна в сплошном льду начиная от момента касания кромки ненарушенного льда. Решение дифференциального уравнения движения с учетом начальных условий ($t = 0, x = 0, x' = v_P$) для случая $[B_5 - C_{13} \exp(-2A_4 x)] > B_5 > 0$ позволяет записать выражения, определяющие время, перемещение, скорость и ускорение на этом участке [12]:

$$t = \frac{1}{(A_4 B_5)^{1/2}} \text{Arth}\{[B_5 - C_{13} \exp(-2A_4 x)]/B_5\}^{1/2} + C_{14}, \quad (11)$$

$$x(t) = -(1/2A_4) \ln\{(B_5/C_{13})[1 - \text{cth}^2[(t - C_{14})(A_4 B_5)^{1/2}]]\},$$

$$x' = (B_5/A_4)^{1/2} \operatorname{cth}[(t - C_{14})(A_4 B_5)^{1/2}],$$

$$x'' = B_5 / \operatorname{sh}^2[(t - C_{14})(A_4 B_5)^{1/2}],$$

где $C_{13} = B_5 - v_P^2 A_4$, $C_{14} = -[1/(A_4 B_5)^{1/2}] \operatorname{Arcth}(v_P^2 A_4 / B_5)^{1/2}$ — постоянные, определяемые с учетом начальных условий.

$$A_4 = (1.4 P_{ML\Pi.X.} + k_3 v_0^2) / (1 + k'_{11}) D v_0^2,$$

$$B_5 = (P_{ML3.X.} - k_4) / (1 + k'_{11}) D,$$

D — водоизмещение судна, $P_{ML\Pi.X.}$ и $P_{ML3.X.}$ — значения тяги гребных винтов на переднем и заднем ходу.

Коэффициент присоединенных масс воды и льда k'_{11} в первом приближении можно принимать, как для чистой воды, по следующей формуле:

$$k'_{11} = k_{11} = [5.91(B/L)^2 + 7.76(B/L) - 0.269] / [48.4 - 6.89(B/T) + (2) + 1.47(B/L)^2 - 0.0475(B/L)^3] + 0.176 a_{11} \delta [1.09 - 0.015(B/L)],$$

где L, B — длина и ширина судна; δ — коэффициент общей полноты; $a_{11} = 0.928$ для ускоренного движения; $a_{11} = 1.176$ для замедленного движения.

Контроль прочности судна

Предварительная оценка величины ледовых нагрузок, действующих на бортовой набор и наружную обшивку корпуса судна, может быть выполнена на основе расчетных моделей, приведенных в работе [33].

Интенсивность расчетной ледовой нагрузки на бортовой набор в зоне контакта определяется по формуле:

$$q_H = 780 k_D k_0 k_V / k_\beta, \quad (13)$$

где $k_D = [D_1 / 10^4 (C_1 + C_2 D_1 / D_2)]^{1/2}$ — коэффициент, учитывающий влияние приведенных масс судна и льдины; $k_0 = (\sigma_C / 400)^{3/5}$ — коэффициент, учитывающий предел прочности льда на смятие; $k_V = (V_s l_1 / 2, 35)^{4/5}$ — коэффициент, учитывающий приведенную скорость судна V_s ;

$$k_\beta = \sin^{3/5} 8^\circ \cos^{2/5} 8^\circ / \sin^{3/5} \beta \cos^{2/5} \beta$$

— коэффициент, учитывающий влияние угла наклона шпангоута к вертикали; D_1 и D_2 — масса судна и льдины; $l_1 = 0.01 \alpha m$; α — угол в градусах

между касательной к ватерлинии в точке удара и диаметральной плоскостью; $m = 1.6 \cos \beta + 0.11$ — коэффициент, определяемый в зависимости от угла β , определяемого как угол между вертикалью и касательной к борту в точке удара.

При учете изгиба ледового поля, расчетная формула для вычисления ледовой нагрузки при ударе принимает вид:

$$(qH)^* = q_H k_1 k_2 k_3, \quad (14)$$

где k_1, k_2, k_3 — коэффициенты, определяемые в зависимости от толщины льда, а также характеристики $(V_0^2 l_1^2 M_1 / C_1 \sigma_c)^{2/5}$ (для k_1), угла β (для k_2) и предела прочности льда на смятие (для k_3).

Ледовую нагрузку для бортового набора в средней части корпуса определяют исходя из условий сжатия судна ледовым полем. Эта нагрузка зависит от угла наклона борта β , толщины льда h , его прочностных характеристик σ_c и σ_p , а также от параметра R , характеризующего конфигурацию кромки льда:

$$q_c = (0.43 / \sin \beta) (\sigma_c \sigma_p^2 h^4 / 2R)^{1/3}. \quad (15)$$

Для судов усиленных ледовых классов расчетное значение предела прочности льда на смятие можно принимать равным $\sigma_c = 200 \text{ т/м}^2$, а расчетное значение предела прочности на изгиб $\sigma_p = 100 \text{ т/м}^2$.

Расчетная нагрузка на обшивку p пропорциональна расчетной нагрузке на бортовой набор q . Это позволяет записать следующие выражения для интенсивности ледовой нагрузки на обшивку корпуса:

- при ударе о плавающую льдину

$$p_H = (p_H)_0 M_1^{2/5} (C_1 + C_2 M_1 / M_2)_0^{2/5} V_S l_1^{4/5} / (M_1)_0^{2/5} (C_1 + C_2 M_1 / M_2)_0^{2/3} (V_S)_0 (l_1)_0^{4/5}; \quad (16)$$

- при ударе о кромку ледового поля

$$p_H = (p_H)_0 L^{6/5} (C_1)_0^{2/5} l_1^{4/5} / L_0^{6/5} (C_1)^{2/5} (l_1)_0^{4/5} = 10^{-2} k \alpha^{4/5} L^{6/5} k'_\beta, \quad (17)$$

где нулевой индекс относится к судну-прототипу, а k'_β — коэффициент, учитывающий влияние угла наклона шпангоутов к вертикали

$$k'_\beta = (1.6 \cos \beta + 0.11)^{4/5} / (C_1)^{2/5} = m^{4/5} / (C_1)^{2/5}; \quad (18)$$

$$m = 1.6 \cos \beta + 0.11; k = (10^2 / 100^{4/5}) (p_H)_0 (C_1)_0^{2/5} / [L_0^{8/9} (l_1)_0]^{4/5}.$$

Алгоритмы функционирования системы в рамках принципа конкуренции

Методологические основы построения алгоритмов функционирования ИС контроля прочности судна при движении во льдах сформулированы на основе теоретических принципов обработки информации в многопроцессорной вычислительной среде, предусматривающих использование интеллектуальной технологии сбора и обработки информации, поступающей с датчиков деформаций корпусных конструкций в зоне контакта. Преобразование информации осуществляется по цепочке «толщина льда–деформации–напряжения– скорость». На основании полученной экспериментальной зависимости контролируется скорость движения судна в ледовом поле. В связи со сложностью решаемой задачи, неточностью и неопределенностью исходной информации, контроль и управление судном производятся с использованием принципа конкуренции, предусматривающего сравнительный анализ данных, полученных на базе различных вычислительных технологий. Первый алгоритм построен с использованием методов традиционной математики, другие — на основе нечетких и нейросетевых моделей [22, 28, 42].

При построении нейросетевых и нечетких моделей использовались данные испытаний, полученные на демонстрационном макете взаимодействия судна с внешней средой, включающим элемент корпусной конструкции с системой нагружения. На основе этой экспериментальной установки отработывалась информационная технология функционирования ИС контроля прочности и вибрации судна. В зависимости от интенсивности внешней нагрузки ИС вырабатывает практические рекомендации по управлению судном в ледовых условиях. Интерфейс «Оператор–ИС» обеспечивает демонстрацию режимов движения судна в ледовом поле в зависимости от характеристик внешней среды [28, 41, 42].

Для проведения экспериментальных исследований динамики взаимодействия судна с ледовым полем на основе формул (9)–(18) были построены вычислительные алгоритмы, функционирующие в рамках принципа конкуренции. На базе этих алгоритмов разработан программный комплекс, позволяющий осуществлять моделирование, обработку и интерпретацию полученных данных при функционировании ИС. Вычислительные процедуры осуществляются в рамках многорежимного принципа контроля и принятия решений по управлению судном в различных условиях эксплуатации [42]. Основная цель использования стандартных, нечетких и нейросетевых

моделей в рассматриваемой проблеме заключается в следующем:

- установление действующих сил, определяющих возникающие деформации и напряжения, связанные со скоростью движения судна;
- обеспечении контроля динамики судна и выбор предпочтительной (безопасной) скорости его движения в рамках принципа конкуренции.

Модель контроля вибрации функционирует параллельно с моделями контроля прочности судна на основе данных измерений вибрации в наиболее неблагоприятных корпусных конструкциях.

Алгоритм на основе стандартной модели

Основной при анализе движения судна в рамках классической теории управления является система уравнений для проекций векторов линейной и угловой скоростей на оси связанной системы координат [12]:

$$(m + \lambda_{11}) \frac{dv_x}{dt} - (m + \lambda_{22}) v_y \omega_z - \lambda_{26} \omega_z^2 = N_X, \quad (19)$$

$$(m + \lambda_{22}) \frac{dv_y}{dt} + (m + \lambda_{11}) v_x \omega_z + \lambda_{26} \frac{d\omega_z}{dt} = N_Y, \quad (20)$$

$$(J_Z + \lambda_{66}) \frac{d\omega_z}{dt} + \lambda_{26} \frac{dv_y}{dt} - (\lambda_{22} - \lambda_{11}) v_x v_y + \lambda_{26} v_x \omega_z = M_z. \quad (21)$$

В случае неустановившегося движения судна вдоль оси :

$$v_x = v, \quad \beta = \omega_z = 0, \quad N_x = P - X - X_1, \quad (22)$$

где P — тяга гребных винтов, X — сопротивление воды движению на прямом курсе, X_t — сопротивление движению со стороны ледового поля. Тогда для скорости судна имеем дифференциальное уравнение [48]:

$$(m + \lambda_{11}) \dot{v} = P - x - x_1, \quad (23)$$

где координату x_1 считаем стационарным случайным процессом с экспоненциально-косинусной корреляционной функцией, т. е. реакцией двумерной системы на векторный белый шум $[v_3, v_4]^T$:

$$\dot{x}_1 = x_2 + b_3 v_3, \quad \dot{x}_2 = -a_1 x_2 - a_2 x_2 + b_4 v_4, \quad a_1, a_2 > 0, \quad (24)$$

а координату тяги P — выходом апериодического звена

$$\dot{P} = -\alpha P + \beta u + \varepsilon v^2, \quad (25)$$

где учитывается только основная инерционность α энергетической установки, а сигналом управления считается вход $u(t)$.

В результате проведенных преобразований получаем следующие уравнения движения судна в горизонтальной плоскости:

$$\dot{v} = a_x, \quad (26)$$

$$\dot{a}_x = -\left(\alpha + \frac{a}{m_1}\right)a_x - \frac{\alpha a}{m_1}v - \frac{\alpha}{m_1}x_1 - \frac{1}{m_1}x_2 + \frac{\beta}{m_1}u + \frac{\varepsilon}{m_1}v_2 - \frac{b_3}{m_1}v_3, \quad (27)$$

$$\dot{x}_1 = x_2 + b_3v_3,$$

$$\dot{x}_2 = -a_1x_1 - a_2x_2 + b_4v_4.$$

Субоптимальное управление имеет следующий вид:

$$u(t) = -B_\xi^T P_*^T \hat{z} - B_\xi^T P_\xi \hat{\xi}. \quad (28)$$

Здесь

$$B_\xi^T P_*^T = \frac{\beta}{m_1} P_{1*} = -\frac{\alpha a}{\beta} \pm \sqrt{\left(\frac{\alpha a}{\beta}\right)^2 + q_z}. \quad (29)$$

Результаты моделирования системы стабилизации скорости приведены на рис. 5. Из этих данных следует, что максимальное отклонение скорости от номинала не превышает 10%. Рис. 5б показывает, как при этом меняется управление. Видно, что управление ограничено на всем интервале: $|u(t)| \leq 0,017$. Из этого рисунка следует, что основной период управления не меньше 6–7 с, что представляется вполне приемлемым в плане реализации. Увеличением коэффициента q_z процесс стабилизации можно улучшить ценой соответствующего увеличения интенсивности управления.

На основе формул (19)–(29) реализуется алгоритм управления судном при движении в сплошном ледовом поле. Дополнительной информацией при реализации алгоритма являются данные, характеризующие прочность судна. Предварительная оценка величины ледовых нагрузок, действующих на бортовой набор и наружную обшивку корпуса судна, может быть выполнена на основе расчетных моделей [33]. Эффективность системы контроля и стабилизации скорости судна при движении во льдах в большой степени




Рис. 5. Осциллограмма скорости в режиме управления (а) и осциллограмма управления (б)

определяется адекватностью моделей возмущений, имитирующих случайные факторы, характеризующие взаимодействие судна со льдом [12, 28, 48].

Номинальное значение скорости зависит от величины сопротивления движению со стороны ледового поля, которое, в свою очередь, определяется сплоченностью и толщиной льда. Рассмотрим имитационные Simulink-модели для толщины льда в ситуациях сплошного, битого льда и торосов.

Сплошное ледовое поле характеризуется толщиной, которая по протяженности и во времени (при движении судна) изменяется как стационарный случайный процесс с непрерывными траекториями. Такая модель может

быть построена в виде стационарного гауссовского процесса. В условиях Simulink-модели это естественным образом реализуется в виде фильтра, формирующего процесс заданной интенсивности из «белого шума». На рис. 6 приведена схема моделирования динамики взаимодействия для процесса, представляющего толщину льда в функции времени, сек. Процесс формируется из «белого шума» с помощью фильтра с передаточной функцией $W_f(s)$. Реализация процесса со средней толщиной льда 1 м приведена на рис. 7б.

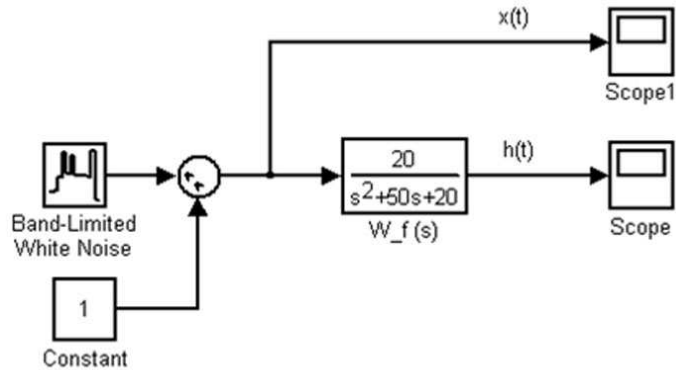


Рис. 6. Схема формирования возмущения для случая сплошного ледового поля

Для имитации возмущений от *битого льда и торосов* моделировались случайные процессы с разрывными траекториями. Моменты разрывов (всплесков) в таких процессах, простейшим из которых является пуассоновский, распределены обычно по экспоненциальному закону. В рассматриваемой задаче может оказаться более приемлемым другое распределение (гамма, Вейбулла и т. д.). В связи с этим, целесообразно в основу имитации положить некоторое универсальное средство, позволяющее в интерактивном режиме корректировать тип и параметры распределения по текущим данным. В системе MATLAB таким средством является функция `randtool`, основное окно которой представлено на рис. 8.

В этом окне развернуто меню с набором из 19 распределений, из которых выбрано экспоненциальное. Здесь также приведена гистограмма распределения с выбранным параметром и при общем числе точек (samples) равном 100. Возможна настройка на любое другое распределение из имею-




Рис. 7. Реализации случайных процессов на схеме рис. 6: а) – "белый шум"; б) – толщина льда, м

щегося списка. Несколько сложнее реализовать кусочный характер воздействий, т. е. чередование промежутков с разным характером толщины льда, в частности, нулевой (свободная вода) и положительной случайной.

Для моделирования таких процессов удобно использовать **Stateflow** — инструмент численного моделирования систем, характеризующихся сложным взаимодействием непрерывной и дискретной компонент (рис. 9).

Имитатор воздействий на судно в условиях битого льда и торосов реализован в виде **Simulink/Stateflow**-модели. Структура и параметры **Stateflow**-блока **Logic** представлены на рис. 10.

Модель такого типа (с именем **BityiLedP.mdl**) (рис. 10), использует пе-

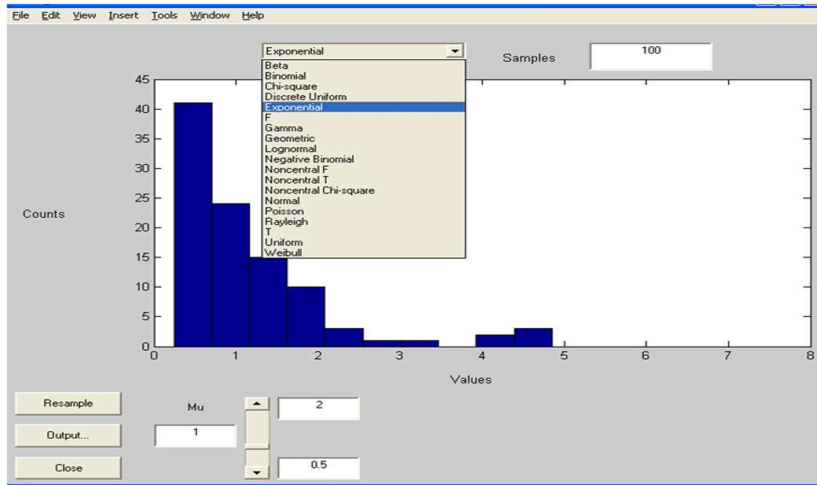


Рис. 8. Окно задания распределений случайных величин

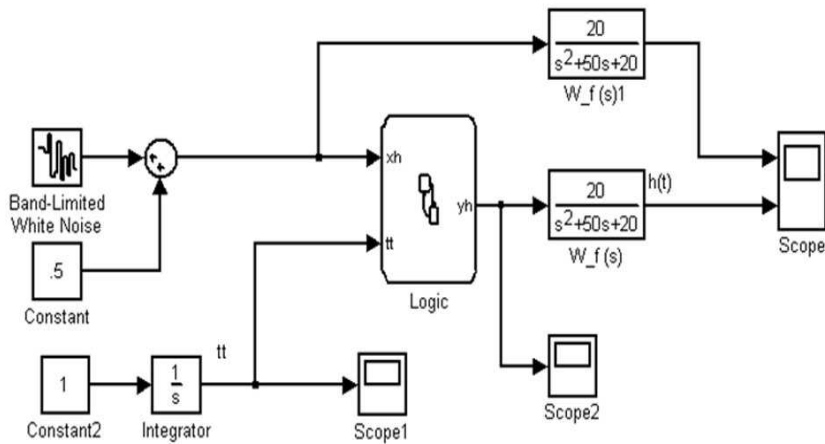


Рис. 9. Simulink/Stateflow-модель имитатора воздействий в случае битого льда (BityiLedP.mdl)

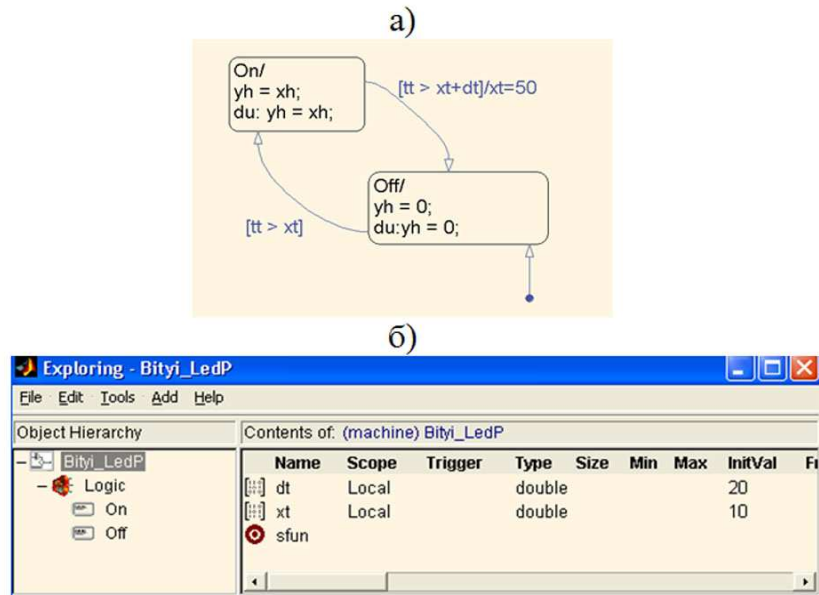


Рис. 10. Структура (а) и параметры (б) Stateflow-блока Logic

ременные: моделирование текущего времени, «белого шума» и толщины льда в функции времени. Логика переключений моделируется Stateflow-блоком Logic. Структура этого блока приведена на рис. 10а, из которого следует, что блок имеет два состояния: **On** — наличие препятствия в виде битого льда или тороса, и **Off** — отсутствие препятствия движению судна («свободная вода»).

Параметры блока, определяющие переключения между состояниями, назначаются в обозревателе (проводнике) формируемой Simulink/Stateflow-модели. Окно обозревателя модели BityiLedP (рис. 10б) имеет вид: правая часть содержит параметры — время до встречи первого препятствия, и протяженность препятствия во времени, а левая иерархию объектов в системе. Результатом работы системы BityiLedP являются осциллограммы, приведенные на рис. 11. Нижняя осциллограмма соответствует условиям битого льда (или торосов). В данном случае параметры блока детерминированные, но использованием randtool легко обеспечиваются любые распределения из

приведенного на рис. 10 перечня.




Рис. 11. Осциллограммы толщины льда в системе *BityiLedP*

Моделирование процессов взаимодействия судна с ледовым полем осуществлялось на основе метода конечных элементов и процедуры **Stateflow** — инструмента численного моделирования систем, характеризующихся сложным взаимодействием непрерывной и дискретной компонент (рис. 12).

Нечеткая модель

Нечеткий алгоритм контроля прочности разработан на основе данных ледового паспорта и системы критериев, реализующих принцип нормального

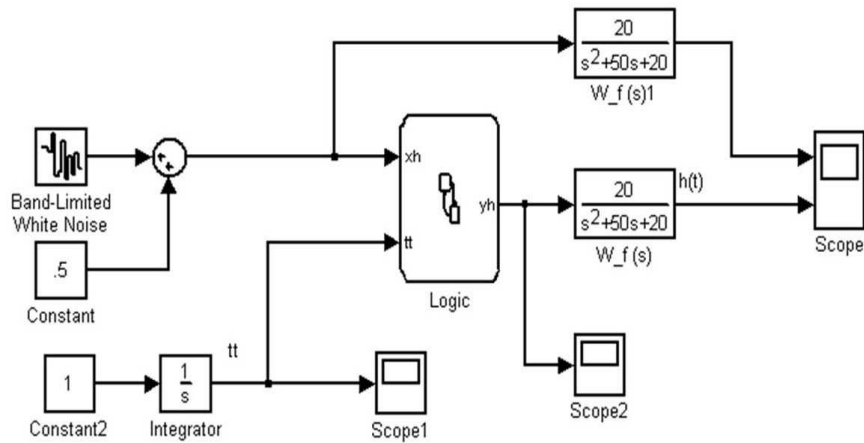


Рис. 12. Simulink/Stateflow-модель имитатора воздействий

функционирования на основе нечеткой аппроксимации данных измерений и математических моделей, построенных на основе формул (9)–(29).

Реализация алгоритма осуществляется с помощью нечетких логических правил **if ... then** [11, 42]. Каждое правило содержит в левой части переменные состояния, а в правой части переменную, характеризующую управление (действие). В качестве исходной (текущей) информации используются данные о толщине ледового поля, устанавливаемые путем обработки результатов измерений деформаций судового корпуса и соответствующих значений действующих напряжений в конструкциях корпуса в зоне контакта (толщина льда) и скорость изменения этой характеристики. Управление в рассматриваемой ситуации принимается в виде изменения (снижения) скорости движения судна.

Для формирования управляющих сигналов используется адаптивная система нечеткого вывода, обеспечивающая формирование продукционных правил и настройку параметров функций принадлежности наблюдаемых и управляемых переменных [26, 42]. Настройка системы производится в режиме обучения, когда управление осуществляет человек-оператор в условиях максимально приближенных к реальным. На основе анализа текущих ситуаций и сопоставления их с действиями оператора система вырабатывает соответствующие правила поведения. Эти правила представляются

матрицей управления и реализуются в режиме реального времени.

В сложных ситуациях, особенно задачах анализа и интерпретации данных динамических измерений при взаимодействии судна с торосистым льдом, используется модель нечеткого логического вывода по прецедентам [29]. Для реализации механизма логического вывода по прецеденту проводилось моделирование ситуаций, связанных с взаимодействием судна с торосами льда различной формы и интенсивности. Анализ результатов моделирования позволил выделить типичные ситуации и сформировать соответствующий ансамбль ситуаций (прецедентов). На основе этой информации можно выделить прецеденты и разработать систему нечетких логических правил, описывающих различные ситуации. Особенность этой задачи состоит в том, что при функционировании механизма логического вывода в реальных условиях эксплуатации база знаний прецедентов постепенно будет накапливать новую информацию, и наряду со статической компонентой (исходная, база знаний) будет формироваться новая динамическая среда (динамическая база знаний). Эту особенность целесообразно предусмотреть при разработке системы нечетких знаний, использующей механизмы адаптации, в частности теорию адаптивного резонанса [5, 38].

Построение функций принадлежности и системы управления ведется на основе теории ИНС. Обучение нейронной сети осуществляется на основе данных динамических измерений с помощью процедуры обратного распространения (Error Back Propagation) [28, 38] или генетического алгоритма [42]. Поток информации при функционировании программного комплекса моделирования динамики судна при движении во льдах представлен на рис. 13.

При функционировании ИС на основе принципа конкуренции [22, 23] осуществляется параллельное выполнение нечетких логических правил. При этом в рассматриваемой задаче наибольшие трудности связаны с автоматическим формированием правил на основе имеющихся событий, описывающих множество результатов их параллельного выполнения. Эффективным способом решения этой проблемы является построение решателя, корректно использующего приведенную классификацию правил, определяющих модель предметной области.

Работа механизма логического вывода (решателя) зависит от характера исследуемой проблемы. В рассматриваемой предметной области пассивные события не учитываются и используются характеристики правил, отражающие особенности процесса взаимодействия судна с ледовым полем и соответствующие показатели, включая прочностные характеристики,




Рис. 13. Преобразование информации при моделировании динамики судна во льдах: MS (Measuring System) — измерительная система; $1, \dots, N$ — Sensors — датчики измерительной системы; DTS (Data Transfer System) — система передачи данных; PB (Processing Block) — блок обработки информации; CS (Control System) — блок управления; ANN (Artificial Neural Network) — искусственная нейронная сеть; GA (Genetic Algorithm) — генетический алгоритм; U (Control) — управление

скорость судна и временные интервалы.

При движении судна в сплошном ледовом поле решатель на первом этапе функционирования ИС доопределяет состояние предметной области, последовательно производя параллельное выполнение логических правил. Левые части этих правил являются подмножеством текущей (все более определенной) ситуации и имеют вероятность выше заданного порога. Затем для текущего доопределенного состояния решатель устанавливает множество потенциально выполнимых логических правил, описывающих активные события [7, 28, 42].

Процедура реализуется путем сопоставления текущей доопределенной ситуации с условными частями содержащихся в модели нечетких правил. При этом определяется их взаимная зависимость и находятся ветви возможного параллельного выполнения правил. При выполнении правил происходит корректировка атрибутов решения (суммарной трудоемкости, общего времени и вероятности), соответствующих выбранной на данной глубине дерева ветви решения. Указанные показатели используются для оценки и сравнения альтернативных решений при реализации принципа конкуренции.

Для работы нечеткой системы были введены следующие значения функций принадлежности:

- толщина льда: границы — $\{0, 0.375, 0.75, 1.125, 1.5\}$, интервалы — $\{NM, NS, Z0, PS, PM\}$;
- изменение толщины льда: границы — $\{-0.06, -0.03, 0, 0.03, 0.06\}$, интервалы — $\{NM, NS, Z0, PS, PM\}$;
- абсолютная величина скорости: границы — $\{12.5, 11.25, 10, 8.75, 7.5, 6.25, 5, 3.75, 2.5\}$, интервалы — $\{NH, HL, NM, NS, Z0, PS, PM, PL, PH\}$.

Изменение толщины льда в программе производится по истечении временного интервала, задавать который можно через интерфейс пользователя от 100 мс до 30000 мс. При каждом новом значении толщины льда отображаются изменения толщины льда, скорости, определенной по нечетким правилам, и скорости, определенной по математической модели. Слева от графиков выводятся численные значения толщины льда, изменения толщины льда и относительной скорости. Кроме того, на матрице управления указывается сработавшее нечеткое правило.

При изменении значения толщины льда производятся следующие действия. Сначала определяются нечеткие множества толщины льда и ее изменения, которые будут участвовать в нечетком выводе. Затем по нечетким правилам определяется нечеткое множество скорости согласно матрице управления. Результаты моделирования отображаются на соответствующих графиках.

Модель взаимодействия судна в ледовом поле, основанная на теории нечеткой логики, представлялась в виде совокупности продукционных правил **if ... then**, описывающих взаимосвязи входных и выходных переменных [28, 42]:

$$R_l[k] : \text{if } (x_1 = A_{1l}^{[k]}, x_2 = A_{2l}^{[k]}, \dots, x_n = A_{nl}^{[k]}), \quad (30)$$

$$\text{then } (y_1 = B_{1l}^{[k]}, y_2 = B_{2l}^{[k]}, \dots, y_m = B_{ml}^{[k]}), \quad l = 1, \dots, N,$$

$$A_{il}^{[k]} \subseteq X_i \subset R, \quad i = 1, \dots, n, \quad A_{il}^{[k]} \in \{A_i^p\}, \quad p = 1, \dots, P,$$

$$B_{jl}^{[k]} \subseteq Y_j \subset R, \quad j = 1, \dots, m, \quad B_{jl}^{[k]} \in \{B_j^q\}, \quad q = 1, \dots, Q,$$

где $k \in \{1, \dots, K\}$ — номер структуры модели; n, m — количество входных и выходных лингвистических переменных $x_l, y_l, l = 1, \dots, n, j =$

$1, \dots, m; N$ — общее число правил в составе нечеткой модели; $A_{il}^{[k]}, B_{jl}^{[k]}$ — нечеткие множества (конкретные лингвистические значения соответствующих входных и выходных переменных в составе l -го правила); $X_i, Y_j (i = 1, \dots, n, j = 1, \dots, m)$ — пространства входных и выходных переменных.

Таким образом, нечеткая модель содержит совокупность терм-множеств лингвистических переменных входа и выхода системы с соответствующими функциями принадлежности [9, 36].

Структура нечеткой модели представлена на рис. 14. Фазификатор (F) преобразует точное множество входных данных $x = (x_1, \dots, x_n)^T$ в нечеткое множество A' , определяемое с помощью значений функции принадлежности $\mu_{A'}(x)$. На выходе блока вывода формируется нечеткое множество на основе расширенного правила **modus ponens** в виде «условие-импликация-вывод». Дефазификатор (DF) решает задачу отображения выходного нечеткого множества $B^{[k]}$ в единственное четкое значение $y \in Y$, которое является выходным сигналом модели. Из множества методов дефазификации в работе использован метод центраида [36].

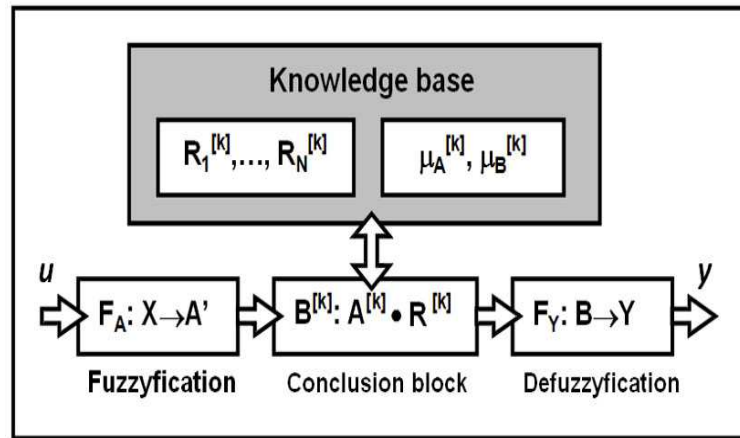


Рис. 14. Схема нечеткой модели

Таким образом, определены исходные данные для решения задачи синтеза нечеткой системы. На основе априорной информации о возможных структурах модели взаимодействия задано нечетких логико-лингвистических моделей с формой логического вывода, представленных в виде нечет-

ких уравнений и матрицы управления. Эти данные использованы в задаче нечеткого моделирования движения судна в ледовых условиях.

Нейросетевая модель

Нейросетевое моделирование в задаче контроля динамики судна рассмотрено не только как конкурирующая вычислительная технология, но и при реализации алгоритма обработки измерительной информации в режиме реального времени. Такой подход особенно эффективен в задачах, где требуется высокая достоверность результата и надежность практических рекомендаций [1, 22–30, 40–42]. В рассматриваемой системе нейронные сети находят следующее применение:

- обработка измерительной информации при функционировании системы оценки динамики судна;
- построение ансамбля нейронных сетей для организации логического вывода по прецеденту.

Общая задача построения нейросетевой модели связана с выбором топологии и обучением сети (рис. 15) и состоит в построении непрерывной зависимости с заданными свойствами по дискретному набору данных.

Формально такая задача сводится к поиску отображения $F : X^n \rightarrow Y^m$, определяемого для каждого дискретного набора данных, как вектора в координатном пространстве размерностью n , равной числу узлов-точек входного набора данных $x \in X^n \subset R^n$, и точку-вектор в m -мерном пространстве параметров модели $y \in Y^m \subset R^m$.

Это отображение удовлетворяет обобщенному критерию качества аппроксимации $E : Y^m \rightarrow R$, который включает в себя требуемую точность аппроксимации $\varepsilon > 0$ (минимизацию ошибки) и дополнительные требования к внешнему виду или поведению модели за пределами области данных [5, 6, 28]. В качестве числовой меры точности нейросетевой модели использована нормированная среднеквадратическая ошибка

$$S_N = \left[\sum_{i=1}^N (y_i - y_i^*)^2 / (N - 1) \right] / (y_{\max}^* - y_{\min}^*), \quad (31)$$

где $(y_{\max}^* - y_{\min}^*)$ — размах наблюдения величины y^* .

Обработка потока информации концентрируется в узлах, каждый из которых имеет свое функциональное назначение.

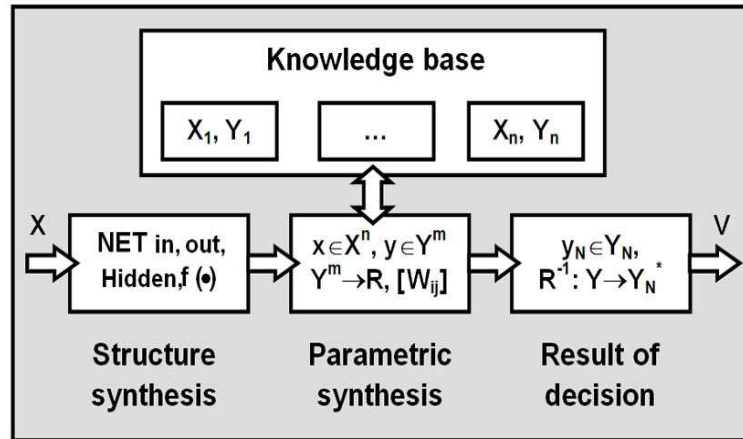


Рис. 15. Схема нейросетевой модели, реализующая оценку динамики взаимодействия в ледовых условиях

Система реализует выбор оптимальной скорости судна в зависимости от интенсивности ледовой нагрузки. Процесс управления организуется на основе концепции нечеткой логики. Алгоритм представляется в виде матриц управления. Элементы матриц соответствует одному из возможных состояний управляющего воздействия Y . Они могут быть сгенерированы при помощи ИНС [22, 28]. Настройка синаптических связей ИНС осуществляется в рамках принципа конкуренции с помощью процедуры обратного распространения ошибки и генетического алгоритма [42].

В качестве иллюстрации на рис. 16 представлен один из вариантов алгоритма контроля скорости, разработанный на основе моделей (9)–(29) и реализуемый в виде матриц управления размерности 5×5 . Схема управляющей базы знаний на основе ИНС имеет четыре управляющих входа $X_1, X_2, dx_1/dt, dx_2/dt$ и один выход Y .

Обучение сети производится на основе функций принадлежности для X_1, X_2, dX_1, dX_2 которые подаются на вход системы, и значениях Y на выходе. В результате использования ГА формируется сложная многомерная поверхность ошибки управления как функция параметров закона управления. ГА находит глобальный минимум этой поверхности. В сложных задачах анализа и интерпретации данных динамических измерений




Рис. 16. ИНС, обеспечивающая управление судном при движении во льдах

используется ансамбли ИНС, анализ которых ведется на основе модели нечеткого логического вывода по прецедентам [25, 42].

Результаты моделирования динамики взаимодействия судна с ледовым полем

Моделирование динамики взаимодействия осуществлено для случаев движения судна в сплошном ледовом поле и при движении в битых льдах. Эксперимент производился в рамках принципа конкуренции для моделей, построенных на основе традиционных, нечетких и нейросетевых моделей.

Результаты моделирования на основе традиционной модели

Результаты моделирования функционирования ИС на базе традиционной модели дополняют материалы, представленные на рис.5–12. Целью анализа является более полное исследование системы в заданных режимах, а также сопряжение алгоритма с программой визуализации.

На основании данных предварительных расчетов по математическим моделям было установлено выражение для безопасной скорости судна в

зависимости от толщины h ледового поля [12]:

$$v_R = v_0[1 - 0.3(h/h^*) - 0.25(h/h^*)^2 - 0.2(h_C/h^*) - 0.2(h_C/h^*)^2], \quad (32)$$

где $v_0 = 5$ м/с — скорость судна в свободной воде; $h^* = 1.5$ — предельное (стандартное) значение толщины льда, м; h_C — толщина снежного покрова, м; $h^{**} = 1.0$ — предельное (стандартное) значение толщины снежного покрова.

Для конкретизации задачи с учетом используемого ледового паспорта будем принимать толщину снежного покрова равной трети h , т. е.

$$v_R = v_0[1 - 0.3(h/h^*) - 0.25(h/h^*)^2 - 0.07(H/h^{**}) - 0.07(h/h^{**})^2] \quad (33)$$

Другой вариант расчета безопасной скорости основывается на обобщенной величине, характеризующей толщину льда

$$h_0 = h + 0.25h^*, \quad (34)$$

для которой математическая модель принимает вид

$$v_R = v_0[1 - 0.36(h/h^*) - 0.20(h/h^*)^2]. \quad (35)$$

Оба способа используются в программе моделирования движения судна в ледовом поле, построенной на основе разработанного подхода и с применением средств MATLAB/Simulink/Stateflow.

В процессе моделирования режим возмущений от ледового поля задается Stateflow-машиной. Судно проходит через ледовое поле на интервале времени $[xt, x + dt] = [10, 40]$, с. Особенности процесса можно установить из приведенных выше диаграмм, т. к. они соответствуют данному фиксированному режиму движения с полным временем наблюдения процесса в течение $t_f = 80$ с. Значение, которое показывает блок Display составляет 4.631, что соответствует падению скорости движения на момент $t = t_f = 80$. При этом следует учесть, что на интервале $[xt, x + dt] = [10, 40]$, судно проходит лед толщиной 1.39 м, что близко к предельному значению и система стабилизации скорости отключена. Осциллограммы процессов во времени приведены на рис. 17. Здесь сплошная кривая характеризует скорость судна $v(t)$, верхняя ступенчатая линия — безопасную скорость $v_R(t)$, нижняя ступенчатая линия — среднюю толщину льда $h(t)$.




Рис. 17. Осциллограммы процесса без стабилизации (а) и со включенной стабилизацией (б)

Главный вопрос, который возникает в связи с этим результатом — это качество стабилизации при прохождении ледового поля, особенно в первые моменты встречи льда (своего рода «пограничный слой» поля, на рис. 17 это интервал между 10 с и 20 с), когда скорость значительно превышает безопасную.

Можно заметить, что существенное повышение качества возможно только при наличии средств прогноза ледовой ситуации по курсу движения судна на сотни метров (или десятки секунд по времени) вперед. Но качество зависит также и от других параметров. Так, в представленных выше на рис. 17 данных постоянная времени энергетической установки судна

$T_m = 0.15$ с. Для $T_m = 0.25$ с результаты приведены на рис. 18. В процессе моделирования также рассмотрены меньшие величины толщины льда и протяженности ледового поля.




Рис. 18. Процесс со включенной стабилизацией для $T_m = 0.25$ с

Результаты моделирования на основе нечеткой системы

Движение судна в сплошном ледовом поле. В начале работы системы вводятся начальная толщина льда и начальная скорость судна. Интервал, через который генерируется новое значение толщины льда, и сплоченности льда (от 10% до 100%, т. е. от 1 до 10 баллов) изменялись в любой момент работы системы.

При моделировании ледового поля в нижней части окна слева отображаются текущие данные и матрица управления, а справа — динамика изменения толщины льда, ее приращения, а также значения скорости, вычисленные по нечетким правилам и по математической модели (рис. 19).

Пунктирная линия в графиках сверху ограничивает предельные значения. Среди текущих данных отображаются средняя относительная и абсо-

лотная скорости судна, а также толщина льда и ее изменение по сравнению с предыдущим значением. На матрице управления отображается действующее на текущем шаге логическое правило, определяющее скорость в зависимости от толщины льда и ее изменения.

В случае приближения графиков к правому краю выделенного поля, они начинают перемещаться влево, при этом всегда отображаются последние значения, помещающиеся на выделенном пространстве (рис. 19). Фрагмент тестирования системы, изображенный на этом рисунке, характеризует ситуацию постепенного уменьшения толщины льда (по сравнению с исходным значением равным 1 м).

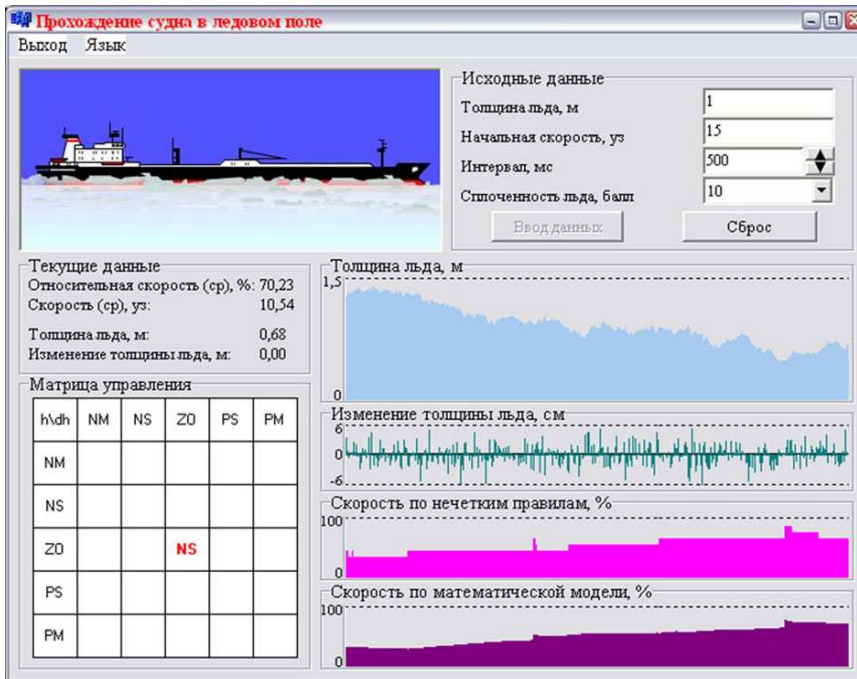


Рис. 19. Результаты моделирования при сплошном ледовом поле и толщине льда 1 м

Движение судна в битых льдах. Моделирование динамики судна при движении в битых льдах осуществлялось для различных значений сплоченности ледового поля. Особенность этой ситуации состоит в том, что в зависимости от сплоченности льда происходит изменение скорости судна. При этом во время прохождения судном участка водной поверхности (без льда) скорость судна начинает увеличиваться.

На рис. 20 представлен фрагмент взаимодействия при сплоченности ледового поля 5 баллов после прохождения судном случайного изменяющегося сплошного ледового поля. Остановка работы программной системы осуществляется с помощью меню «Сброс». После этого меняются исходные данные и запускается система на продолжение моделирования. Выход из системы осуществляется по пункту меню «Выход». С помощью меню «Язык» можно сменить язык представления информации с русского на английский и наоборот.

Результаты моделирования на основе нейронной сети

Динамика нейронечеткого моделирования представлялась в виде совместных динамических картин поведения судна в рассматриваемой ситуации. Для этого экран оператора на рис. 19 и 20 дополнялся принятой конфигурацией нейронной сети, а динамические картины взаимодействия судна с ледовым полем представляли собой кривые изменения скорости судна, определенные на основе стандартной, нечеткой и нейросетевой моделей.

Такая форма отображения результатов моделирования позволяет более наглядно представить поведение судна в сложных ситуациях, особенно при контроле динамических характеристик судна при движении в торосах. Поэтому в реальных условиях эксплуатации форма, изображенная на рис. 21, может быть использована при организации интерфейса «Оператор–ИС».

Нейросетевое моделирование напряженного состояния элементов судового перекрытия

Одной из сложных задач анализа и интерпретации динамики взаимодействия судна с ледовым полем является оценка напряженно-деформируемого состояния корпусных конструкций в зоне контакта. Решение этой задачи при функционировании ИС осуществляется в рамках принципа конкуренции с использованием стандартного алгоритма, построенного на базе ме-

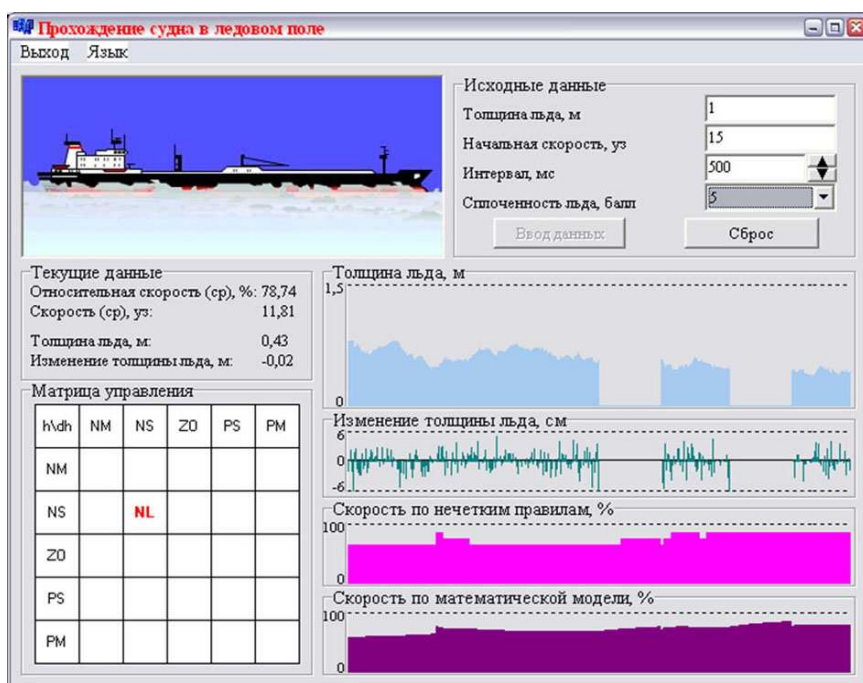


Рис. 20. Результаты моделирования при сплоченности льда 5 баллов и исходной толщине льда 1 м

тогда конечных элементов и ИНС. В этой задаче нейронная сеть играет двойную роль. С одной стороны, она используется как конкурирующая вычислительная технология, с другой — как эффективная процедура, обеспечивающая функционирование программного комплекса в режиме реального времени. Последнее особенно важно в сложных ситуациях, когда применение стандартного алгоритма не может обеспечить быструю обработку информации, поступающей от датчиков измерительной системы.

Экспериментальная проверка эффективности использования ИНС в рамках принципа конкуренции на данном этапе исследования проведена путем обработки и сопоставления экспериментальных данных, полученных в результате физического моделирования динамики взаимодействия на специально разработанном экспериментальном стенде. Фактические данные

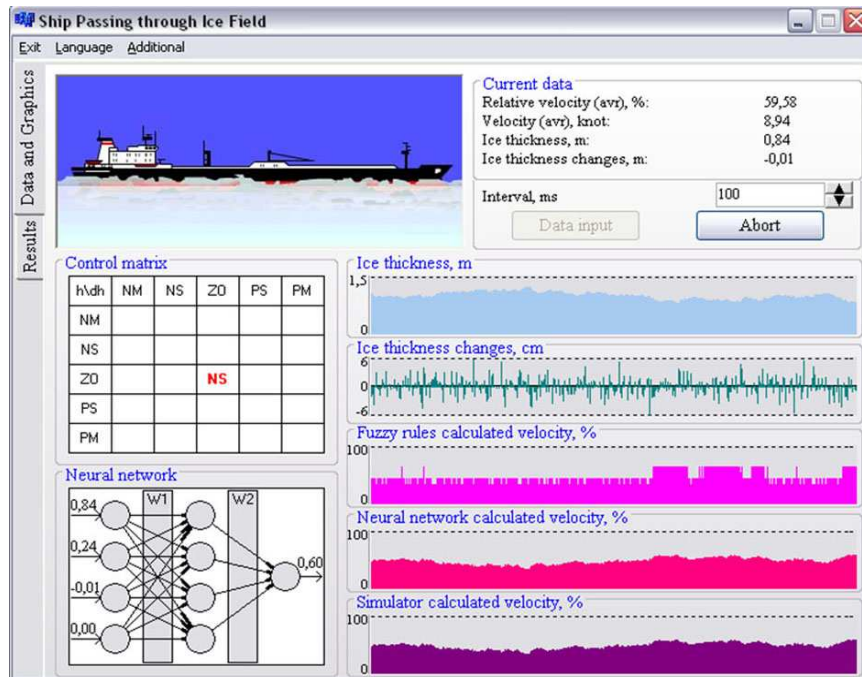


Рис. 21. Графическое окно «Визуализация динамики взаимодействия»

измерений установлены путем тензометрирования характерных элементов корпусных конструкций. Расстановка датчиков принята в соответствии с данными, полученными в процессе решения задачи оптимизации. При дальнейшем использовании ИНС предусматривается применение «быстрых алгоритмов», реализуемых с помощью ядерных нейронных сетей, предложенных А. Ю. Дороговым [6].

В процессе обработки информации были рассмотрены 3 типа эксперимента. Первый тип включал 6 примеров в обучающем множестве, второй (включая тестовый эксперимент) – 24 примера и третий (включая тестовый эксперимент) – 32 примера.

Расчетные данные представлены таблицами входных воздействий (табл. 1) и выходных реакций (табл. 2).

В табл. 1 и 2 использованы следующие обозначения: k – число экспе-

Таблица 1. Входные воздействия на перекрытие

Номер опыта	Точка 1	Точка 2	...	Точка п
1	x_{11}	x_{12}	...	x_{1n}
2	x_{21}	x_{22}	...	x_{2n}
...
k	x_{k1}	x_{k2}	...	x_{kn}

Таблица 2. Выходные реакции, измеренные в процессе эксперимента

Номер опыта	Точка 1	Точка 2	...	Точка m
1	y_{11}	y_{12}	...	y_{1m}
2	y_{21}	y_{22}	...	y_{2m}
...
k	y_{k1}	y_{k2}	...	y_{km}

риментов; n — число точек для входных воздействий; m — число точек для выходных реакций.

Исходная информация представлена в матричной форме:

- для входных воздействий

$$X = \begin{pmatrix} x_1^r \\ x_2^r \\ \vdots \\ x_k^r \end{pmatrix} = (x_1^c, x_2^c, \dots, x_n^c), \quad (36)$$

где x_i^r — i -я строка таблицы входных воздействий, x_j^c — j -й столбец таблицы входных воздействий;

- для выходных реакций

$$Y = \begin{pmatrix} y_1^r \\ y_2^r \\ \vdots \\ y_k^r \end{pmatrix} = (y_1^c, y_2^c, \dots, y_n^c), \quad (37)$$

где y_i^r — i -я строка таблицы выходных реакций, y_j^c — j -й столбец таблицы выходных реакций.

Для аппроксимации исходных данных используется линейная модель:

$$y_i^r = x_i^r W, \quad (38)$$

где W — матрица размером $n \times m$, элементы которой необходимо определить.

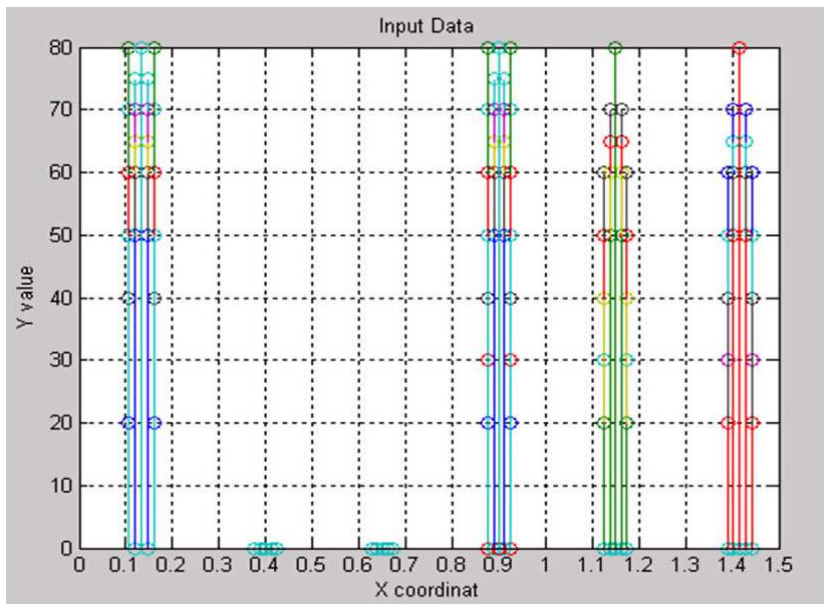


Рис. 22. Обучающее множество (входы)

В качестве нейросетевой модели рассматривалась однослойная нейронная сеть с линейными функциями активации. Матричная форма модели имеет вид:

$$W = \begin{pmatrix} w_1^r \\ w_2^r \\ \vdots \\ w_n^r \end{pmatrix} = (w_1^c, w_2^c, \dots, w_m^c), \quad (39)$$

где w_i^r — i -я строка матрицы, w_j^c — j -й столбец матрицы W .

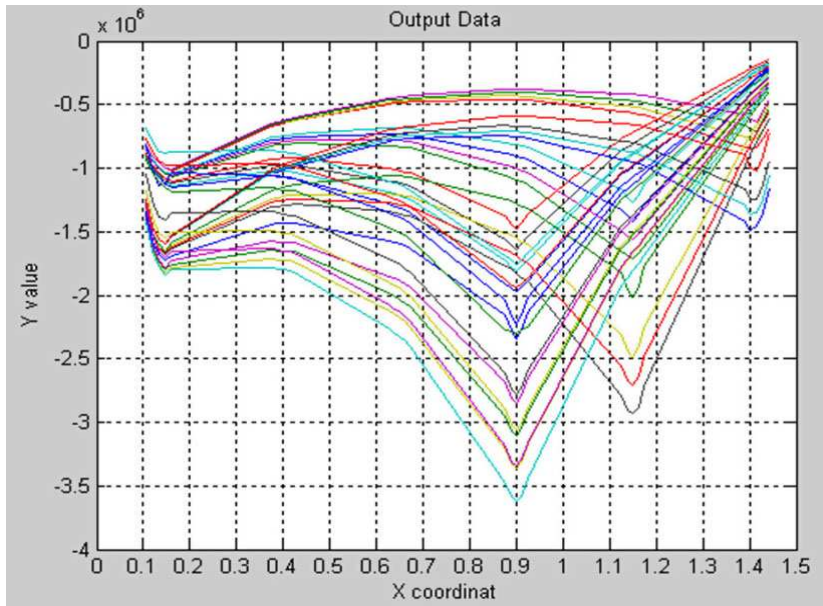


Рис. 23. Обучающее множество (выходы)

При настройке параметров модели достаточно рассмотреть выбор элементов одного столбца матрицы W .

Вектор-строка ошибки для одной контрольной точки по всем экспериментам имеет вид:

$$e = (y_i^c - Xw_i^c)^T. \quad (40)$$

Длина вектора равна числу экспериментов.

Критерий настройки нейронной сети: необходимо выбрать значения w_i^c так, чтобы минимизировать среднеквадратичную ошибку $J = e \cdot e^T$.

Процедура минимизации ошибки:

$$\begin{aligned} \frac{dJ}{d(w_i^c)^T} &= \frac{dJ}{de} \frac{de}{d(w_i^c)^T} = -2(y_i^c - Xw_i^c)^T \frac{d((w_i^c)^T X^T)}{d(w_i^c)^T} = \\ &= -2(y_i^c - Xw_i^c)^T X = 0, \\ (y_i^c)^T X - (w_i^c)^T X^T X &= 0, \end{aligned} \quad (41)$$

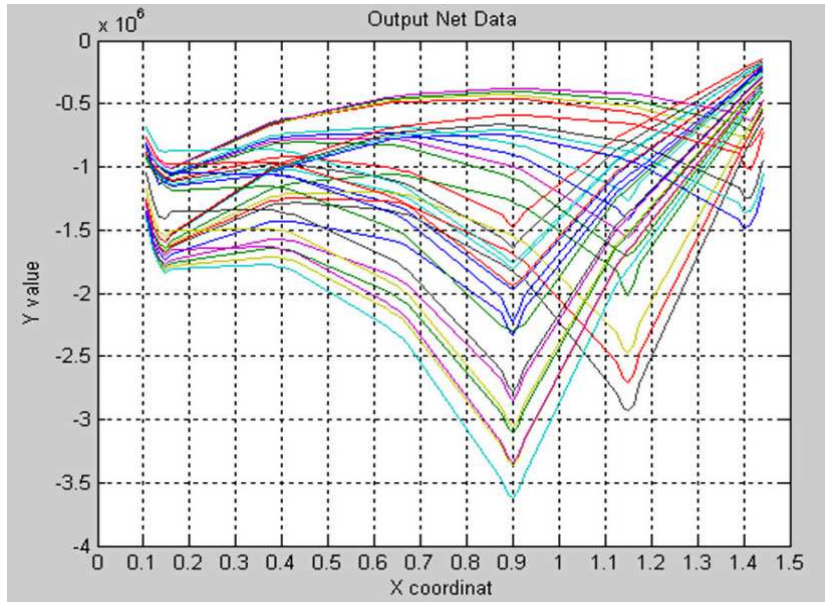


Рис. 24. Результаты нейросетевого моделирования

$$(w_i^c)^T = (y_i^c)^T X (X^T X)^{-1}.$$

Аналогично определяются все остальные столбцы матрицы W .

Для каждого вида выходной реакции строится своя нейросетевая модель. Для адекватной модели число экспериментов должно быть $k \geq \min(n, m)$. Если данное условие не выполнено, то настройка возможна, но построенная модель будет покрывать только множество воздействий, которые являются линейными комбинациями строк таблицы X . В качестве требования к экспериментальным данным принимается условие, что вектора-строки таблицы X должны быть линейно независимыми.

Фрагмент MATLAB-программы:

```
$X$=InputData(:,2);
% продольная координата балки;
$P$=InputData(:,3:8);
% входное множество примеров $T$=InputData(:,9:end);
```

```
\% выходное множество примеров net=newlind(P,T);  
\% инициализация и настройка сети Y=sim(net,P);  
\% эмуляция сети.
```

Проведенные эксперименты показали, что для надежной работы нейронной сети размер обучающей выборки должен быть не менее, чем число контрольных точек (30). Во втором эксперименте размер обучающей выборки был равен 24. Поэтому для получения надежных данных эксперименты по построению нейросетевой модели были продолжены. Третья серия экспериментов была проведена на примерах с большим размером обучающей выборки (32 примера). С целью сокращения иллюстративного материала на рис. 22–24 представлены выборочные результаты экспериментов 3-й серии.

Результаты эмуляции обучающего множества обученной нейронной сетью приведены на рис. 24.

Как видно из рис. 24, разработанная нейронная сеть хорошо воспроизводит данные тестовой выборки. Таким образом, при достаточном количестве обучающих примеров, сеть обеспечивает решение задачи моделирования рассматриваемого динамического объекта.

Функционирование системы при различных режимах движения

Рассмотрим построение системы контроля прочности и вибрации судна, обеспечивающей реализацию механизма принятия решений в ледовых условиях. В зависимости от особенностей взаимодействия судна с ледовым полем, определяемых выделенными режимами движения, используются различные структуры системы.

Наиболее простая структура реализована на базе нечеткой модели с коррекцией правил. Эта структура изображена на рис. 25 и представляет собой двухуровневую систему. Она включает в себя блоки предварительной обработки информации (вычислительный блок, блок анализа ситуации методом конечных элементов и блок сравнения) и блок адаптации на основе матрицы нечетких логических правил и нейросетевых моделей.

Функционирование системы контроля, изображенной на рис. 25, состоит в следующем. Поток информации, непрерывно поступающий с датчиков измерительной системы, обрабатывается на участках квазистационарности

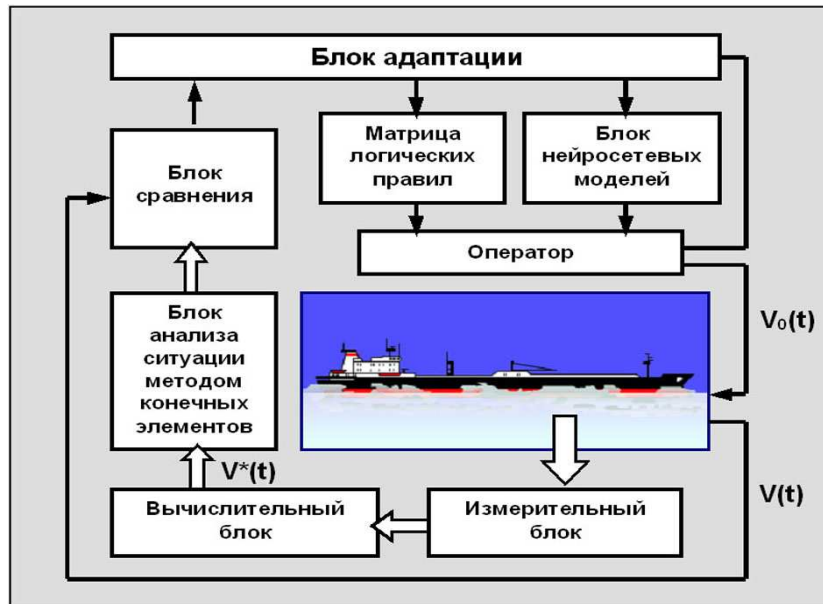


Рис. 25. Система контроля динамики судна, реализующая принцип конкуренции

в режиме реального времени. Вычислительные процедуры осуществляются на основе принципов обработки информации в многопроцессорной вычислительной среде. Блок анализа ситуации преобразует непрерывные сигналы с датчиков в цифровые коды и обеспечивает процедуры предварительной обработки данных для дальнейшего использования при построении нечетких и нейросетевых алгоритмов. Одновременно методом конечных элементов устанавливается картина напряженно-деформируемого состояния корпусных конструкций в зоне контакта. На основе полученных данных с использованием критериальной базы осуществляется оценка прочности и вибрации судна в рассматриваемой ситуации. Помимо этого вычислительный комплекс ИС позволяет определить внешние нагрузки на корпусные конструкции и установить соответствующее расчетное значение скорости судна и толщину ледового поля [42].

Блок сравнения обеспечивает анализ результатов оценки скорости суд-

на и данных измерения ее фактического значения в момент получения информации о динамике взаимодействия судна с ледовым полем. Принцип работы этого блока заключается в следующем. На основании анализа текущего значения вектора ошибки $[\varepsilon, d\varepsilon/dt]$, $\varepsilon = V(t) - V^*(t)$, (где $V(t)$ — фактическое значение скорости судна, $V^*(t)$ — значение, являющееся выходом вычислительного блока) блок адаптации формирует управляющие воздействия, изменяющие правые части матрицы лингвистических правил. Преобразование информации в этой матрице ведется на основе принципа адаптивного резонанса, позволяющего обеспечить «настройку» логической системы на поток информации, представленный в виде входного вектора наблюдений. Одновременно с этим в блоке нейросетевых моделей выбирается подходящая модель и осуществляется ее обучение. В качестве моделей обучения используются метод обратного распространения ошибки и генетический алгоритм. На экране схемы рис. 2 представлена динамическая картина взаимодействия для заданного режима движения.

Таким образом, механизм преобразования информации в блоке адаптации сводится к установлению желаемой реакции системы на основе матрицы логических правил. Нулевые элементы этой матрицы соответствуют состояниям $[\varepsilon, d\varepsilon/dt]$ (ε — нечеткое значение ошибки управления), для которых не требуется коррекция. Ненулевые элементы свидетельствуют о необходимости коррекции правил, которая реализуется на основе принципа адаптивного резонанса [26, 38]. Процедура адаптации заключается в корректировке некоторого правила из матрицы нечетких логических правил. Адаптация этих правил при выполнении гипотезы квазистационарности заключается в выборе подходящей модели из ансамбля матриц логических правил (или ансамбля, соответствующих различным режимам движения судна. Матрицы логических правил в этом случае могут быть построены с учетом различных параметров взаимодействия, определяющих динамику судна в ледовых условиях. С другой стороны, на основе обученной нейросетевой модели устанавливается свое значение скорости, соответствующее вектору входных данных. Окончательный выбор скорости судна осуществляется на основе методов анализа альтернатив в нечеткой среде. Процедура такого анализа разработана с использованием метода анализа иерархий [49].

Расширенная структура нечеткой многорежимной системы принятия решений по управлению судном в сложной ледовой обстановке представлена на рис. 26. Как видно из этого рисунка, блок анализа ситуации методом конечных элементов и блок сравнения здесь сохранены. Но вместо

матрицы логических правил используется специально разработанный блок таких матриц, каждая из которых соответствует определенному режиму движения судна. Кроме того, система обработки информации дополняется блоком коррекции, обеспечивающим «подстройку» логических правил с использованием методов идентификации, нечеткой адаптивной модели и нейросетевых ансамблей.

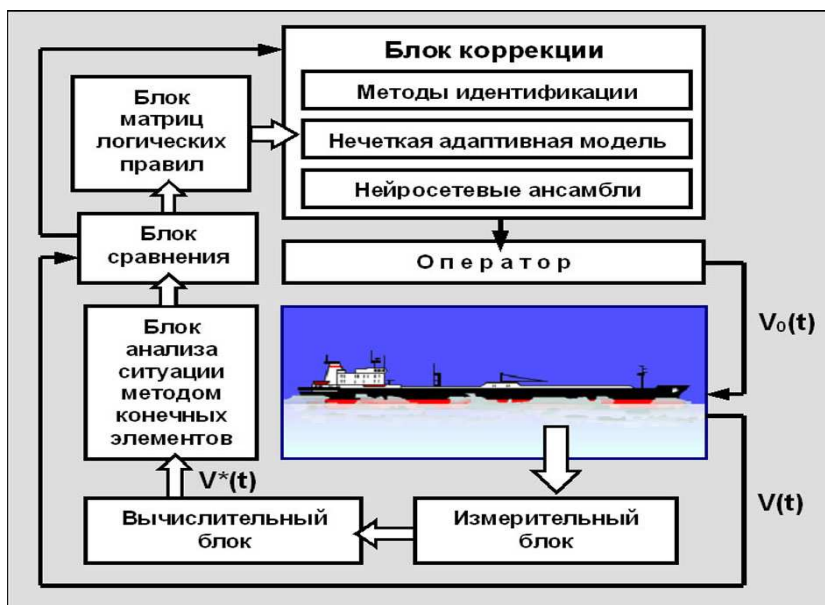


Рис. 26. Система контроля динамики судна активного ледового плавания при движении в торосах

Функционирование блока коррекции осуществляется на основе моделей логического вывода в рамках принципа конкуренции. При этом блок идентификации использует традиционные методы идентификации текущей ситуации, а нечеткая адаптивная модель построена на основе принципа адаптивного резонанса [26, 38]. Нейросетевые ансамбли аппроксимируют динамику взаимодействия судна с торосами различной формы и интенсивности. Результатом работы блока коррекции является выбор предпочтительной вычислительной технологии для обеспечения безопасности судна

при движении в сложных условиях эксплуатации, особенно в торосистых льдах. Блок коррекции подавляет сигнал с i -го нечеткого логического правила $R_i, i = 1, \dots, N$, которое не соответствует текущим параметрам взаимодействия и предлагает решение по выбору текущей скорости на основе анализа альтернатив.

Алгоритм функционирования нечеткой адаптивной модели состоит в виде последовательности шагов, определяющих процедуры анализа входного образа с помощью модели нечеткого вывода, предложенной Сугено [8]. Если процедуры, реализуемые алгоритмом идентификации не приводят к желаемому результату, то осуществляется модификация логического правила, имеющего наибольшее «сходство» с исходной информацией, поступившей на вход нечеткой системы. Эта процедура реализуется путем перестройки исходных значений функций принадлежности с учетом непрерывного изменения динамики объекта и внешней среды.

Таким образом, осуществляется динамическая самоорганизация нечеткой системы знаний за счет «наращивания» новых и модификации наиболее «схожих» правил. Рассмотренная нечеткая система эффективна при достаточно сильной неопределенности, когда не полностью известно число возможных структур модели взаимодействия. В этом случае накапливаемая информация при функционировании системы позволяет увеличивать число нечетких логических правил. В особо сложных ситуациях, когда система испытывает затруднения, осуществляется логический вывод по прецеденту с соответствующей реализацией динамической картины взаимодействия (рис. 27) [28, 42].

В отдельных случаях, когда информация о возможных структурах модели объекта представлена конечным множеством моделей взаимодействия, целесообразно использовать нечеткую логическую управляющую систему с неявной адаптацией. Такая система может быть построена после накопления достаточных данных натурных измерений на основе решения задачи идентификации текущей модели взаимодействия.

Таким образом, основная идея использования новых принципов обработки информации в интеллектуальных системах мониторинга прочности и вибрации судна состоит в рациональной организации вычислительной технологии. Включение в информационный базис нечетких и нейросетевых моделей позволяет расширить функциональные возможности системы и повысить надежность принимаемых решений в сложных ледовых условиях. Матрицы нечетких логических моделей способны адаптироваться к изменяющимся внешним условиям, а нейросетевые ансамбли — распозна-

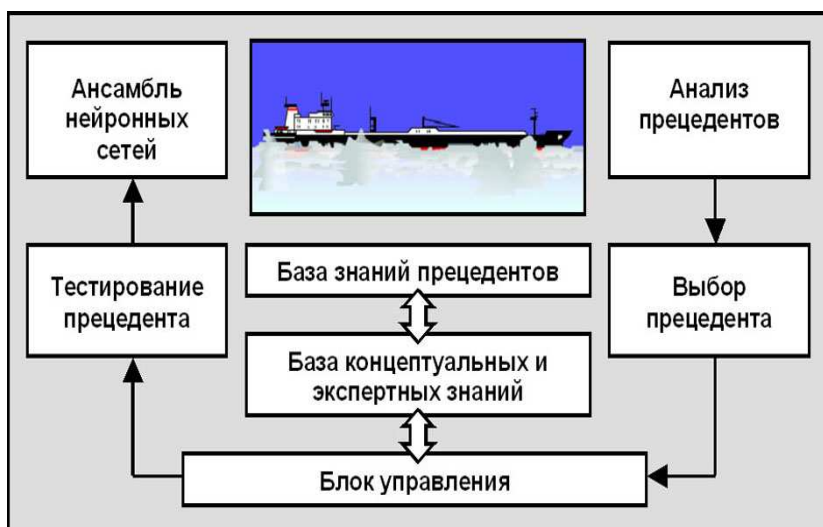


Рис. 27. Структура функционирования блока коррекции с использованием ансамбля нейронных сетей

вать «шаблоны» (причинно-следственные отношения) каждого контролируемого процесса. Такой непрерывный процесс самообучения позволяет накапливать информацию о динамике взаимодействия и предсказывать отклонения параметров от режимных (допустимых) значений.

Интерфейс оператора

Главной особенностью ИС, как системы нового поколения, является реализация в ней базовых принципов и процедур, делающих естественным процесс общения оператора с ИС. Рассматриваемая многорежимная система обработки информации в рамках принципа конкуренции предлагает оператору различные решения по выбору скорости судна в зависимости от динамики его взаимодействия с ледовым полем в конкретной ситуации. Окончательное решение выбирает оператор на базе рекомендаций ИС. Важным принципом организации интерфейса также является возможность функционирования в условиях неопределенности и неполноты исходной

информации. Интеллектуальная поддержка оператора определяется в соответствии с качеством управления, которое может быть обеспечено на основе вырабатываемой информации. Критерии безопасности представленной на экране монитора информации определяются по степени опасности ситуации в соответствии с нормативными показателями и документами, принятыми в отечественной и международной практике.

Оператор несет главную ответственность за управление судном на основе практических рекомендаций, вырабатываемых ИС в нормальных условиях эксплуатации. В сложных (нештатных и экстремальных) ситуациях требуется «подстройка» системы, а иногда и переход на соответствующие стратегии, обеспечивающие принятие решений по управлению судном на основе принципа конкуренции (анализ альтернатив ведется с использованием классической математики, нечеткой логики и теории нейронных сетей). В этих ситуациях выводимая на экран информация должна обеспечить действия оператора, связанные с быстрым и наиболее эффективным реагированием на возникающие события.

Разработка интерфейса выполнена с учетом наиболее полного представления информации о функционировании ИС на основе алгоритмов классического и нейронечеткого управления в рамках принципа конкуренции (рис.28). Главной особенностью разрабатываемой ИС, как системы нового поколения, является реализация в ней базовых принципов и процедур, делающих *естественным* процесс общения оператора с ИС [28, 42].

Взаимодействие оператора с бортовой ИС в соответствии с критериями эффективности может быть изображено тремя вложенными друг в друга с общим центром кругами Эйлера (рис. 29), который использовал их для наглядной иллюстрации операций над множествами.

В задаче контроля динамики судна с ледовых условиях три концентрично вложенных круга Эйлера определяют информационные границы для оператора по способам формирования управляющих решений. Эти границы зависят от особенностей возникающих ситуаций и могут характеризоваться на основе интерпретации, данной в работе [16, 32].

В задаче контроля динамики судна с ледовых условиях три концентрично вложенных круга Эйлера определяют информационные границы для оператора по способам формирования управляющих решений. Эти границы зависят от особенностей возникающих ситуаций и могут характеризоваться на основе интерпретации, данной в работе [32]. В первом (внутреннем) круге Эйлера управляющие воздействия автоматически формируются на основе формализованных знаний экспертов о взаимодействии



Рис. 28. Интерфейс «Оператор–ИС»: ДС — динамическая сцена

судна с ледовым полем (*алгоритмический контур программного управления*). Во втором круге Эйлера управляющие воздействия вырабатываются в автоматизированном режиме (автоматическом поле параметрической настройки системы) с использованием формализованных знаний экспертов и обобщенного опыта управления (*алгоритмический контур адаптивного управления*). Во внешнем круге Эйлера управляющие воздействия формируются при информационной и интеллектуальной поддержке ИС (*алгоритмический контур самообучения системы*). Расширение области круга обеспечивается повышением уровня формализации управления при анализе и прогнозе динамики взаимодействия судна с ледовым полем.

Сложность и неопределенность ситуаций при движении судна в ледовом поле требует особого внимания к построению системы принятия решений по управлению судном в сложной гидрометеорологической обстановке.




Рис. 29. Круги Эйлера, определяющие информационные границы при функционировании системы поддержки принятия решений

При реализации интерфейса «Оператор–ИС» предусмотрены следующие варианты решения [42]:

- анализ и прогноз ситуации;
- визуализация динамики взаимодействия;
- оперативное управление.

Графическое окно интерфейса «Анализ и прогноз ситуации» *Analysis–Forecast* (рис. 30) содержит три области: область исходных данных — *Input Data*, область дерева модели — *Domain* и окно просмотра — *Results*. Область исходных данных содержит обработанные данные динамических измерений и материалы прогноза береговых метеорологических станций. Область дерева модели включает следующие закладки: *Physics* — задание условий задачи, *Model* — выбор модели (классическая, нечеткая, нейросетевая); *Simulation* — работа с моделью. Окно просмотра *Results* содержит результаты анализа (выбор предпочтительной вычислительной технологии) с указанием соответствующей кривой изменения скорости в зависимости от толщины льда и выводы *Conclusion* (практические рекомендации по выбору скорости судна).

Графическое окно «Визуализация динамики взаимодействия» *Visualization* (см. рис. 21) содержит результаты моделирования динамики взаимо-

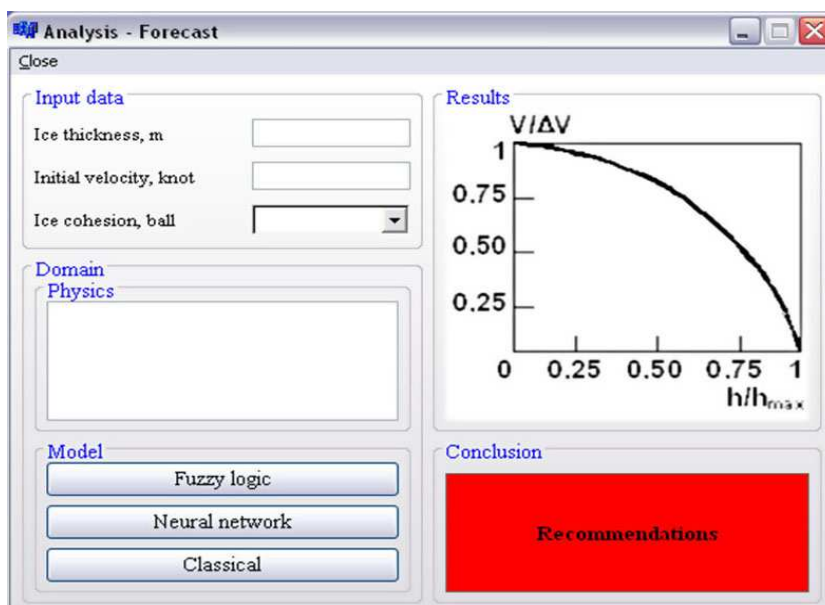


Рис. 30. Графическое окно «Анализ и прогноз ситуации»: в окне «Results» показана прогнозируемая кривая падения скорости в зависимости от относительной толщины льда

действия на основе принципа конкуренции с выводом на экран соответствующей динамической картины. Окно содержит входную (Input Data) и текущую (Current Data) информацию о характеристиках ледового поля и скорости судна. Модель этого окна наиболее подробно разработана с учетом динамических картин изменения толщины льда Ice thickness, Change of ice thickness и скорости судна Velocity, определенных по классическому Classic, нечеткому Fuzzy и нейросетевому Neural Network алгоритмам.

Графическое окно «Оперативное управление» Running Control (рис. 31) — наиболее ответственная модель интеллектуальной поддержки оператора в бортовых системах реального времени. Реализация этой модели основана на использовании когнитивной парадигмы. Главный принцип реализации когнитивной парадигмы — быстрая и надежная реакция оператора на представленную информацию в виде разнообразных способов отображе-

ния результатов функционирования системы в сложных ледовых условиях: движение в сплошном ледовом поле, в битом льду и в торосах.

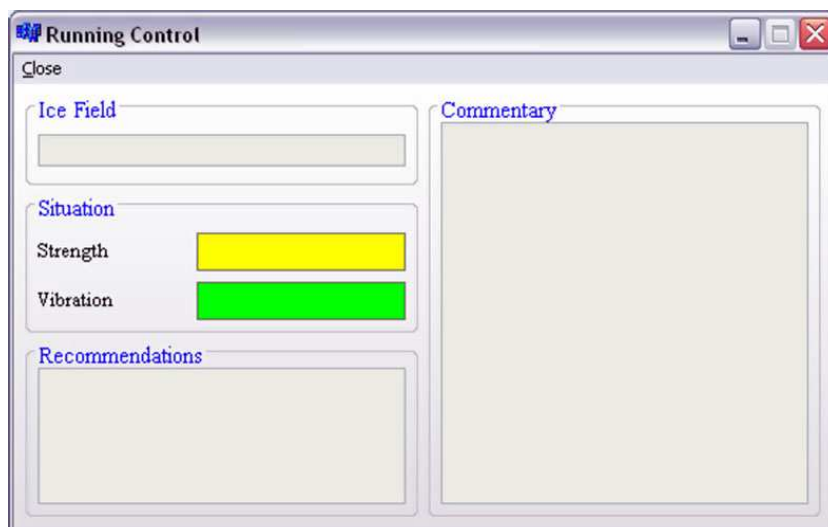


Рис. 31. Графическое окно «Оперативный контроль»

Окно отличается простотой отображения информации и содержит три закладки: характеристику ледового поля **Ice Field**, оценку ситуации **Situation** и практические рекомендации **Recommendation**. В окне **Ice Field** приводятся текущие данные об особенностях ледовой обстановки (сплошное поле, битый лед, торосы). В окне **Situation** дается оценка прочности **Strength** и вибрации **Vibration** судна. Причем, если эти характеристики удовлетворительны, то текущие значения выводятся на *зеленом поле*. Если эти характеристики приближаются к предельным значениям, то используется *желтое поле* (настораживающий цвет). В случае нарушения критериев данные выводятся на *красном поле* (угрожающий цвет). Окно **Recommendation** содержит предложения по изменению скорости **Velocity**, исходя из условий безопасности судна в текущей ситуации. Если оператора кроме текущих данных ледовой обстановки интересуют материалы прогноза береговых служб метеоразведки, ледовой разведки и авиаподдержки, то на экран **Commentary** выводится соответствующая информация.

Оценка риска принимаемых решений

При оценке риска принимаемых решений используются различные методы и модели. Среди них можно выделить два подхода, представляющих наибольший практический интерес в рассматриваемой проблемной области. Первый подход базируется на теории катастроф в гомеостатических системах. Научные основы этого направления изложены в работе [20]. Второй подход — теория катастроф в системах с конечным множеством дискретных состояний [17] состоит в использовании теории и методов анализа сценариев рискованных ситуаций. В практических задачах наибольшее развитие получило именно это направление — исследование сценариев риска очень малой вероятности, характеризуемого большим ущербом.

Расчетные схемы оценки риска определяются особенностью рассматриваемой задачи. В общем виде такую оценку можно представить как последовательность этапов [13]:

- *Предварительный этап.* Анализ причин, факторов и основных сценариев развития ситуации; определение видов ущербов, ранжирование возможности и тяжести их последствий.
- *Расчетный этап.* Имитационное моделирование различных сценариев, анализ результатов и оценка риска совместно с данными экспертного опроса.
- *Заключительный этап.* Анализ оценки риска на основе всей доступной информации — результатов имитационного моделирования и данных экспертной информации с использованием детерминированных, вероятностных или нечетких моделей.

Основная цель анализа и оценки риска заключается в предоставлении информации об уровне безопасности исследуемой ситуации лицу, принимающему решения. Использование данных моделирования различных сценариев в рассматриваемой ситуации совместно с результатами экспертного опроса в задачах оценки риска дает возможность определения уровня безопасности рассматриваемого динамического объекта, информация о котором может быть выражена скорее качественными, чем количественными категориями.

Особенности оценки риска. Термин «риск» часто имеет различные трактовки. В задачах принятия решений понятие риска отражает неуверенность эксперта в том, что произойдет ли данное (нежелательное) событие

и возникнет ли данное неблагоприятное состояние системы [13]. При количественной оценке риск R определяется на основе сочетаний величины события A (последствия события) и величины его наступления P , т. е. $R = A \cdot P$. Обобщая эту формулу на непрерывный случай, получаем

$$R(x) = \int_{A_{\min}}^{A_{\max}} A(x)P(x)dx, \quad (42)$$

где $P(x)$ — некоторая вероятностная мера на σ -алгебре пространства событий $[A_{\min}, A_{\max}]$.

Для получения полной картины изменения риска производится всесторонний анализ решений, связанных с риском. Анализ рисков позволяет построить *матрицу риска* [46], общий вид которой для морских катастроф представлен на рис. 32.




Рис. 32. Матрица риска

Такая интерпретация риска представляет собой зависимость частоты возникновения опасностей P от уровня последствий A . При построении матрицы риска устанавливается обобщенный уровень риска R как произведение вероятности возникновения опасности P на последствие A от воздействия указанной опасности на исследуемое событие или проектируемый ДО.

Таблица 3. Шкала определения вероятности P

Уровень последствий, C	1	2	3	4	5
Частота возникновения опасности P , %	0-20	21-40	41-60	61-80	81-100

При оценке опасности риска морских катастроф выделяют ситуации, связанные с нарушением технического состояния корпуса, машин, механизмов и систем ДО, а также ситуации, возникающие вследствие нарушения технологии перевозки грузов. Вероятность P в этом случае определяется по 5-балльной шкале (табл. 3).

Анализ матрицы риска позволяет выделить следующие уровни риска: незначительный риск, практически допустимый риск и недопустимый риск. Формализованная оценка безопасности ДО предполагает использование процедур управления риском в ситуациях, которые отнесены к недопустимому риску. Решение проблемы обеспечения достаточной надежности и безопасности ДО при сохранении приемлемого риска ведется на всех стадиях жизненного цикла, включая этапы проектирования, строительства, эксплуатации, ремонта и модернизации.

В задачах принятия решений в качестве одной из альтернатив рассматривается ситуация назначения стратегий действия по критерию минимального риска или ущерба. При оценке рисков потерь наибольшую сложность представляет задача вычисления достоверных рисков. Это объясняется тем, что ситуации, связанные с риском, имеют большую неопределенность. Значения рисков не могут быть вычислены достоверно, так как для этого приходится использовать неустойчивые статистики. Кроме того, мера риска часто определяется как очень малая вероятность, что приводит к недостоверным результатам. Использование идеи доверительных интервалов не снимает остроты проблемы этой достоверности. В связи с этим актуально развитие направления, связанного с оценкой риска принятия решений в нечеткой среде.

Принятие решений в условиях риска. При оценке риска в системах интеллектуальной поддержки принятия решений обычно статистические характеристики отсутствуют и известны лишь границы неопределенности.

Математическая модель принятия решений в условиях неопределенно-

сти образует упорядоченный набор [8]:

$$\langle X, Y, f(x, y) \rangle. \quad (43)$$

Здесь X — множество альтернатив; Y — множество неопределенностей; $f(x, y)$ — критериальная функция.

Альтернатива $x \in X \subset R^n$ выбирается с целью достижения возможно большего значения критерия (исхода) $f(x, y)$ при реализации любой неопределенности $y \in Y \subset R^m$ в предположении известных множеств X и Y и скалярной функции (критерия) $f(x, y)$, определенной на прямом произведении $X \times Y$.

Особенность задачи (43) состоит в том, что при выборе решений известны лишь границы изменения неопределенности y , т. е. только само множество Y , а какие-либо статистические данные о возможной реализации y отсутствуют. Задача (43) позволяет построить функцию риска

$$\Phi(x, y) = \max_{z \in X} [f(z, y) - f(x, y)], \quad (44)$$

которая рассматривается в качестве дополнительного критерия. В результате приходим к двухкритериальной задаче оценки риска в условиях неопределенности:

$$\langle X, Y, \{f(x, y), \Phi(x, y)\} \rangle. \quad (45)$$

В задаче (45) оператор стремится выбрать именно ту альтернативу $x \in X$, при которой можно добиться одновременно возможно большего исхода $f(x, y)$ и возможно меньшего риска $\Phi(x, y)$ с учетом реализации любой неопределенности $y \in Y$.

Заключение

Таким образом, новая парадигма мониторинга прочности и вибрации судов активного ледового плавания, реализуемая системой интеллектуальной поддержки, имеет следующие преимущества:

1. Расширение традиционных подходов к обработке информации, дополнение их новыми методами, моделями и алгоритмами поддержки принятия решений по управлению судном в сложной гидрометеорологической обстановке.

2. Учет неопределенности и неполноты исходной информации при интерпретации и выборе сложных решений по управлению судном как многорежимной динамической системой.
3. Развитие внутреннего потенциала теории управления и принятия решений на основе принципа конкуренции, позволяющего на базе анализа альтернатив выбирать предпочтительную вычислительную технологию с использованием методов классической математики, нечетких и нейросетевых моделей.

Предлагаемая технология обработки информации в интеллектуальных системах новых поколений принципиально отличается от существующих традиционных подходов к построению систем мониторинга прочности и вибрации судна. Существенно расширяя функциональные возможности системы и повышая эффективность решения поставленных задач, разработанный подход позволяет обеспечить новое качество — способность предсказания и предвидения критических и аварийных ситуаций при эксплуатации судов активного ледового плавания.

Таким образом особенность разработанного подхода состоит в организации ИС нового поколения, осуществляющей преобразование потока информации в сложных ситуациях, определяющих динамику нелинейного взаимодействия судна с внешней средой в условиях неопределенности и неполноты исходной информации. Ведущая роль в механизме преобразования информации принадлежит «нелинейной динамике» и связана с понятием «синергетика». Синергетический подход радикально изменил понимание отношений между порядком и хаосом, между энтропией и информацией. Высокая сложность реализуемых структур и процессов имеет ключевое значение в задачах моделирования поведения судна в сложной ледовой обстановке. Их неустойчивость, нестабильность, стохастичность обусловили ориентацию новой научной парадигмы обработки информации в рамках принципа конкуренции. В рамках этой парадигмы изучаются изменения в самой структуре модели взаимодействия, а не в условиях ее неизменной структуры.

Литература

1. Александров В. Л., Матлах А. П., Нечаев Ю. И., Поляков В. И. Интеллектуальные системы новых поколений // *Морской вестник*. – 2002. №2, с. 53–57.

2. Александров В. Л., Матлах А. П., Нечаев Ю. И., Поляков В. И., Родионов А. А. Нейросетевые модели в задачах прочности корабля: концепции и приложения. // *Морской вестник*. – №4(8), 2003. – с. 83–89.
3. Арнольд В. И. Теория катастроф. – М.: Наука, 1990.
4. Брусков В. С., Тюменцев Ю. В. Синтез оптимального ансамбля нейроконтроллеров для многорежимного летательного аппарата // *Тр. 5-й Всероссийской конференции «Нейроинформатика-1999»*. – М.: МИФИ. 1999. Часть 2, с. 190–201.
5. Галушкин А. И. Теория нейронных сетей. – М.ИПРЖР, 2000.
6. Дорогов А. Ю. Быстрые нейронные сети. – Санкт-Петербург. Изд-во Госуниверситета, 2002.
7. Елисеев А. В. Идентификация нечеткой модели в задаче синтеза регулятора // *Автоматизация и современные технологии*. 2005. №11, с. 3–12.
8. Жуковская Л. В., Миркин Е. А. Новый подход к оценке эффективности управленческих решений в условиях риска в АСУ // *Автоматика и телемеханика*. – №4, 2004. – с. 166–172.
9. Заде Л. Понятие лингвистической переменной и его применение к принятию приближенных решений. – М.: Мир, 1976.
10. Зенкин А. А. Когнитивная компьютерная графика. – М.: Наука, 1991.
11. Интеллектуальные системы в морских исследованиях и технологиях / Под ред. Ю. И. Нечаева. – Санкт-Петербург. ГМТУ, 2001.
12. Ионов Б. П., Грамузов Е. М. Ледовая ходкость судов. – Санкт-Петербург. Судостроение, 2001.
13. Костерев В. В., Аверкин А. Н. Формальное описание риска в нечетких системах // *Труды Международной конференции по мягким вычислениям и измерениям SCM-2001*. – Т.1. Санкт-Петербург, 2001 – с. 170–173.
14. Котенко И. В. Модели вывода по прецедентам для реализации интеллектуальных систем // *Труды 5-й Национальной конференции по искусственному интеллекту с международным участием*. – Пушкино. 1998. Т.1, с. 270–277.
15. Красовский А. А., Наумов А. И. Аналитическая теория самоорганизующихся систем управления с высоким уровнем искусственного интеллекта // *Известия РАН. Теория и системы управления*. – 2001. №1. – с. 69–75.
16. Кузичева З. А. Эйлер и Ламберг — трактовка логики // *Материалы международной конференции «Эйлер и наука»*. Российская Академия Наук. Санкт-Петербург, 2007. – с. 147–151.
17. Куклев Е. А. Модели рисков катастроф как маловероятных событий в системах с дискретным состоянием // *Труды Всероссийской научной конференции «Управление и информационные технологии УИТ-2003»*. – 2003, Т. 2 – с. 158–163.

18. Кукушкин Ю. А., Богомолов А. В., Ушаков И. Б. Математическое обеспечение оценивания состояния материальных систем // *Информационные технологии* №7 (Приложение). 2004. – с. 1–31.
19. Макаренко Н. Г. Реконструкция динамических систем по хаотическим временным рядам // *Нелинейные волны*. Нижний Новгород. – 2005. – с. 398–410.
20. Малинецкий Г. Г., Кульба В. В., Косяченко С. А., Шнирман М. Г. и др. Управление риском. Риск. Устойчивое развитие. Синергетика. – М.: Наука. 2000.
21. Назаров А. В., Якимов В. Л. Прогноз параметров технического состояния много-режимных объектов // *Применение нейрокомпьютеров в ракетно-космической технике*. Книга 21. – М.: Радиотехника, 2006. – с. 64–68.
22. Нечаев Ю. И. Нейросетевые технологии в интеллектуальных системах реального времени // Тр. 4-й Всероссийской конференции «Нейроинформатика–2002». *Лекции по нейроинформатике*. Часть 1. – М.: МИФИ, 2002. с. 114–163.
23. Нечаев Ю. И. Математическое моделирование в бортовых интеллектуальных системах реального времени // Тр. 5-й Всероссийской конференции «Нейроинформатика–2003». *Лекции по нейроинформатике*. Часть 2. – М.: МИФИ, 2003. с. 119–179.
24. Нечаев Ю. И. Принципы использования нейронных сетей в бортовых интеллектуальных системах // *Нейрокомпьютеры: разработка, применение*. 2004, №7–8. – с. 49–56.
25. Нечаев Ю. И., Тихонов Д. Г. Нейропрогноз на основе логического вывода по прецедентам // Тр. 7-й Всероссийской научно-технической конференции «Нейроинформатика–2005». Часть 2. – М.: МИФИ, 2005. – с. 197–204.
26. Нечаев Ю. И., Петров О. Н. Система поддержки принятия решений на основе нечетких знаний о динамике судна в экстремальных ситуациях // *Сборник докладов Международной конференции по мягким вычислениям и измерениям SSM-2005*. т. 2. – Санкт-Петербург, 2005. – с. 66–69.
27. Нечаев Ю. И. Нейроаппроксимация и нейропрогноз при контроле динамики сложного объекта // *Нейрокомпьютеры: разработка, применение*. – 2005, №10–11. – с. 22–31.
28. Нечаев Ю. И. Методологические основы построения системы нейро-нечеткого управления при движении судна во льдах // *Нейрокомпьютеры: разработка, применение*. – 2006, №6. – с. 31–42.
29. Нечаев Ю. И. Нейросетевые ансамбли при интерпретации экстремальных ситуаций в бортовых интеллектуальных системах // *Нейрокомпьютеры: разработка, применение*. – 2006, №6. 2006. – с. 60–69.

30. *Нечаев Ю. И.* Концептуальные основы создания бортовых интеллектуальных систем // *Информационно-измерительные и управляющие системы. Бортовые интеллектуальные системы.* – 2006, №9. – с. 4–8.
31. Новые концепции общей теории управления: Сб. научных тр. / Под ред. *А. А. Красовского.* – Москва-Таганрог, 1995.
32. *Парфенова М. Я., Колганов С. К., Парфенов И. И., Иванов В. И.* Человеческий фактор в интеллектуальных информационных технологиях для профилактики, предупреждения и устранения аварийных ситуаций // *Информационные технологии.* – 2005, №5. – с. 21–29.
33. *Попов Ю. Н., Фаддеев О. В., Хейсин Л. Е., Яковлев А. А.* Прочность судов, плавающих во льдах. – Л.: Судостроение, 1967.
34. Синергетическая парадигма. Многообразие поисков и подходов. – М.: Прогресс-Традиция, 2000.
35. *Сингеру Омату, Марзуки Халид, Рубия Юсоф.* Нейроуправление и его приложения. – М.: ИПРЖР, 2000.
36. *Терано Т., Асаи К., Сугено М.* Прикладные нечеткие системы. – М.: Мир, 1993.
37. *Терехов В. А., Ефимов Д. В., Тюкин И. Ю., Антонов В. Н.* Нейросетевые системы управления. – Санкт-Петербург: СПбГУ, 1999.
38. *Уоссермен Ф.* Нейрокомпьютерная техника. – М.: Мир, 1992.
39. *Чуи К.* Введение в вейвлеты. – М.: Мир, 2001.
40. *Alexandrov V.L., Matlakh A.P., Nechaev Yu. I., Polyakov V.I.* Ships safety navigation in conditions of the Arctic shelf // *Proceedings of 2nd International Maritime Conference on DESIGN FOR SAFETY, Osaka Colloquium 2004, SAKAI, JAPAN.* – pp. 231–237.
41. *Alexandrov V.L., Matlakh A.P., Nechaev Yu. I., Polyakov V.I.* Intelligence system for ship Dynamics monitoring in extreme situations // *Proc. of International conference on marine research and transportation ICMRT-05. Naples, Italy. 2005.* – pp. 55–63.
42. *Alexandrov V.L., Matlakh A.P., Nechaev Yu. I., Polyakov V.I.* Strength and vibration multimode control for ship, moving the ice condition // *Proc. of the 10th International symposium on Practical Design of ships and other floating structures PRADS-2007. Houston. Texas. USA, 2007, Vol. 2.* – pp. 1295–1302.
43. *Brusov V.S., Tiumentsev Yu. V.* High performance aircraft flight control based on artificial neural networks // *Proc. Of the RRDPAE-96. Warsaw, 1997.* – pp. 97–100.

44. *Dubois D., Prade H., Grabish M.* Graduate rules and the approximation of control laws // *Theoretical Aspects of Fuzzy Control* / Ed. *H. T. Nguyen*. – John Willey & Sons. Inc., 1995.
45. *De Keyser R. M. C., Van De Velde Ph. G. A., Dumartier F. A. O.* A comparative study of self-adaptive long range predictive control methods // *Automatica*. – 1988. Vol. 24. – pp. 49–163.
46. *Egorov G. V.* Risk theory based minimization of transport fleet influence on the environment // *Proceedings of Second International Conference of Navy and Shipbuilding Nowadays NSN-2001*. St.-Petersburg. KSRI, 2001. – pp. 190–197.
47. *Kosko B., Dickerson J. A.* Function Approximation with additive fuzzy systems // *Theoretical Aspects of fuzzy control* / Ed. *N. T. Nguyen*. – John Willey & Sons. Inc., 1995.
48. *Nechaev Yu. I., Dubovik S. A.* Control of ship movement in the ice field: approach on basis of the optimal control theory // *Proceeding of international conference "HYDRONAV'05"*. Gdansk-Ostroda. Poland, 2005.
49. *Saaty T.* Mathematical models of arma control and disarmament. – J. Wiley & Sons. Inc., 1968.
50. *Takens F.* Lectures notes in mathematics. Vol. 898. – N.Y. Springer, 1981. – pp. 366–381.
51. *Zadeh L.* Fuzzy logic, neural networks and soft computing // *Commutation on the ASM-1994*. Vol. 37, No. 3. – pp. 77–84.

Юрий Иванович НЕЧАЕВ, профессор кафедры вычислительной техники и информационных технологий Санкт-Петербургского государственного морского технического университета, заведующий отделом систем поддержки принятия решений Института высокопроизводительных вычислений и информационных систем, заслуженный деятель науки РФ, академик РАЕН, доктор технических наук, профессор.