

РОССИЙСКАЯ АКАДЕМИЯ НАУК
МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РОССИЙСКОЙ ФЕДЕРАЦИИ
ГОСУДАРСТВЕННАЯ КОРПОРАЦИЯ ПО АТОМНОЙ ЭНЕРГИИ «РОСАТОМ»
РОССИЙСКАЯ АССОЦИАЦИЯ НЕЙРОИНФОРМАТИКИ
НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ЯДЕРНЫЙ УНИВЕРСИТЕТ «МИФИ»
НАУЧНО-ИССЛЕДОВАТЕЛЬСКИЙ ИНСТИТУТ СИСТЕМНЫХ ИССЛЕДОВАНИЙ РАН

НЕЙРОИНФОРМАТИКА-2015

ХVII ВСЕРОССИЙСКАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ с международным участием

СБОРНИК НАУЧНЫХ ТРУДОВ

ЧАСТЬ 1

- **НЕЙРОННЫЕ СЕТИ И КОГНИТИВНЫЕ НАУКИ**
- **ТЕОРИЯ НЕЙРОННЫХ СЕТЕЙ**
- **НЕЙРОСЕТЕВЫЕ СИСТЕМЫ ОБРАБОТКИ ДАННЫХ,
РАСПОЗНАВАНИЯ ОБРАЗОВ И УПРАВЛЕНИЯ**

МОСКВА

УДК 001(06)+004.032.26(06)
ББК 72Я5+32.818Я5
М 82

**XVII ВСЕРОССИЙСКАЯ НАУЧНО-ТЕХНИЧЕСКАЯ КОНФЕРЕНЦИЯ
"НЕЙРОИНФОРМАТИКА-2015": Сборник научных трудов.** В 3-х частях.
Ч. 1. М.: НИЯУ МИФИ, 2015. – 244 с.

Сборник научных трудов содержит доклады, включенные в программу XVII ВСЕРОССИЙСКОЙ НАУЧНО-ТЕХНИЧЕСКОЙ КОНФЕРЕНЦИИ «НЕЙРОИНФОРМАТИКА-2015», проходившей в г. Москве 19–23 января 2015 г. Тематика конференции охватывает широкий круг вопросов: методические вопросы нейроинформатики, теория нейронных сетей, нейробиология, модели адаптивного поведения и когнитивные исследования, нейронные сети для управления, обработки изображений, временных рядов и другие приложения нейроинформатики.

В первую часть включены доклады, посвященные когнитивным исследованиям и моделированию в нейробиологии, теоретическим исследованиям искусственных нейронных сетей, а также их применению в задачах управления и прогнозирования.

Ответственный редактор *А.Г. Трофимов*

Статьи получены до 25 октября 2014 года.

Материалы издаются в авторской редакции.

ISBN 978-5-7262-2043-7

© Национальный исследовательский
ядерный университет «МИФИ», 2015

Оригинал-макет подготовлен *Е.Н. Кочубей*

Подписано в печать 20.11.2014. Формат 60×84 1/16.
Печ. л. 15,25. Тираж 150 экз. Заказ № 182.

*Национальный исследовательский ядерный университет «МИФИ»
Типография НИЯУ МИФИ
115409, Москва, Каширское ш., 31*

ОРГАНИЗАТОРЫ КОНФЕРЕНЦИИ

- Российская академия наук
- Министерство образования и науки Российской Федерации
- Государственная корпорация по атомной энергии «Росатом»
- Российская ассоциация нейроинформатики
- Национальный исследовательский ядерный университет «МИФИ» (НИЯУ МИФИ)
- Научно-исследовательский институт системных исследований РАН (НИИСИ РАН)
- Московский авиационный институт (национальный исследовательский университет), МАИ
- Государственный научный центр РФ Троицкий институт инновационных и термоядерных исследований (ГНЦ РФ ТРИНИТИ)

ОРГАНИЗАЦИОННЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель – Президент НИЯУ МИФИ Оныкий Б. Н. (НИЯУ МИФИ)
Зам. председателя – Проректор НИЯУ МИФИ Петровский А. Н. (НИЯУ МИФИ)
Сопредседатель – Мишулина О. А. (НИЯУ МИФИ)
Сопредседатель – Тюменцев Ю. В. (МАИ)
Акад. РАН Бетелин В. Б. – НИИСИ РАН, Москва
Акад. РАН Евтушенко Ю. Г. – ВЦ РАН, Москва
Загребаяев А. М. – НИЯУ МИФИ
Трофимов А. Г. – НИЯУ МИФИ
Ушаков В. Л. – НИЦ «Курчатовский институт», Москва
Бесчастный П.П. – НИЯУ МИФИ
Хапалов В. И. – НИЯУ МИФИ
Ученый секретарь – Бесхлебнова Г. А. (НИИСИ РАН, Москва)

ПРОГРАММНЫЙ КОМИТЕТ КОНФЕРЕНЦИИ

Председатель – чл.-корр. РАН Крыжановский Б. В. (НИИСИ РАН, Москва)
Зам. председателя – Дунин-Барковский В. Л. (НИИСИ РАН, Москва)
Зам. председателя – Редько В. Г. (НИИСИ РАН, Москва)
Чл.-корр. РАН Анохин К. В. – НИЦ «Курчатовский институт», Москва
Чл.-корр. РАН Балабан П. М. – Институт высшей нервной деятельности
и нейрофизиологии РАН (ИВНД и НФ РАН), Москва
Бурцев М. С. – НИЦ «Курчатовский институт», Москва
Введенский В. Л. – НИЦ «Курчатовский институт», Москва
Чл.-корр. РАН Величковский Б. М. – НИЦ «Курчатовский институт», Москва
Головко В. А. – Брестский государственный технический университет, Республика
Беларусь
Доленко С. А. – НИИ ядерной физики им. Д.В. Скобельцына МГУ
Ежов А. А. – ГНЦ РФ ТРИНИТИ, Москва
Жданов А. А. – Институт точной механики и вычислительной техники
им. С.А. Лебедева РАН, Москва
Чл.-корр. РАН Иваницкий А. М. – ИВНД и НФ РАН, Москва
Каганов Ю. Т. – МГТУ им. Н. Э. Баумана
Казанович Я. Б. – Институт математических проблем биологии РАН, Пущино, Моск. обл.
Литинский Л. Б. – НИИСИ РАН, Москва
Макаренко Н. Г. – Главная астрономическая обсерватория РАН, Санкт-Петербург
Максимов В. В. – Институт проблем передачи информации им. А.А. Харкевича РАН,
Москва
Мишулина О. А. – НИЯУ МИФИ
Нечаев Ю. И. – Научно-исследовательский институт экспериментальной медицины
РАМН, Санкт-Петербург
Прохоров Д. В. – Toyota Research Institute, USA
Чл.-корр. РАН Рудаков К. В. – Вычислительный центр им. А.А. Дородницына РАН,
Москва
Самарин А. И. – НИИ нейрокибернетики им. А.Б. Когана, Ростов-на-Дону
Терехов С. А. – ООО «Нейрок Техсофт», Москва
Трофимов А. Г. – НИЯУ МИФИ
Тюменцев Ю. В. – МАИ
Ушаков В. Л. – НИЦ «Курчатовский институт», Москва
Чижов А. В. – Физико-технический институт им. А.Ф. Иоффе РАН, Санкт-Петербург
Фролов А. А. – ИВНД и НФ РАН, Москва
Шумский С.А. – Физический институт им. П.Н. Лебедева РАН, Москва
Яхно В. Г. – Институт прикладной физики РАН, Нижний Новгород

СПИСОК РЕЦЕНЗЕНТОВ

1. Бесхлебнова Г. А. – *Научно-исследовательский институт системных исследований РАН, Москва*
2. Бурцев М. С. – *Национальный исследовательский центр «Курчатовский институт», Москва*
3. Васильков В. А. – *НИИ нейрокибернетики им. А.Б. Когана Южного федерального университета, Ростов-на-Дону*
4. Витяев Е. Е. – *Новосибирский государственный университет*
5. Доленко С. А. – *НИИ ядерной физики им. Д.В. Скобельцына МГУ им. М.В. Ломоносова, Москва*
6. Дунин-Барковский В. Л. – *Научно-исследовательский институт системных исследований РАН, Москва*
7. Ежов А. А. – *Государственный научный центр Российской Федерации Троицкий институт инновационных и термоядерных исследований (ГНЦ РФ ТРИНИТИ)*
8. Каганов Ю. Т. – *Московский государственный технический университет им. Н.Э. Баумана*
9. Казанович Я. Б. – *Институт математических проблем биологии РАН, Пущино, Московская обл.*
10. Карандашев Я. М. – *Научно-исследовательский институт системных исследований РАН, Москва*
11. Киселев И. И. – *Научно-исследовательский институт системных исследований РАН, Москва*
12. Котов В. Б. – *Научно-исследовательский институт системных исследований РАН, Москва*
13. Кошур В. Д. – *Сибирский федеральный университет, Красноярск*
14. Крыжановский В. М. – *Научно-исследовательский институт системных исследований РАН, Москва*
15. Литинский Л. Б. – *Научно-исследовательский институт системных исследований РАН, Москва*
16. Макаренко Н. Г. – *Главная астрономическая обсерватория РАН, Санкт-Петербург*
17. Мальсагов М. Ю. – *Научно-исследовательский институт системных исследований РАН, Москва*
18. Мишулина О. А. – *Национальный исследовательский ядерный университет «МИФИ», Москва*

19. Парин С. Б. – *Нижегородский государственный университет им. Н.И. Лобачевского*
20. Полевая С. А. – *Нижегородская государственная медицинская академия*
21. Ратушняк А. С. – *Конструкторско-технологический институт вычислительной техники СО РАН, Новосибирск*
22. Редько В. Г. – *Научно-исследовательский институт системных исследований РАН, Москва*
23. Смирнитская И. А. – *Научно-исследовательский институт системных исследований РАН, Москва*
24. Соловьева К. П. – *Научно-исследовательский институт системных исследований РАН, Москва*
25. Станкевич Л. А. – *Санкт-Петербургский государственный политехнический университет*
26. Тарков М. С. – *Институт физики полупроводников им. А.В. Ржанова СО РАН, Новосибирск*
27. Терехов С. А. – *ЗАО «Связной Логистика», Москва*
28. Трофимов А. Г. – *Национальный исследовательский ядерный университет «МИФИ», Москва*
29. Тюменцев Ю. В. – *Московский авиационный институт (национальный исследовательский университет)*
30. Ушаков В. Л. – *Национальный исследовательский центр «Курчатовский институт», Москва*
31. Чижов А. В. – *Физико-технический институт им. А.Ф. Иоффе РАН, Санкт-Петербург*
32. Шакиров В. В. – *Научно-исследовательский институт системных исследований РАН, Москва*
33. Шапошников Д. Г. – *НИИ нейрокибернетики им. А.Б. Когана Южного федерального университета, Ростов-на-Дону*
34. Шумский С. А. – *Физический институт им. П.Н. Лебедева РАН, Москва*

Уважаемые коллеги!

Конференция НЕЙРОИНФОРМАТИКА вновь собирает исследователей, работающих по актуальным направлениям теории и приложений искусственных нейронных сетей. Как и на предыдущих наших собраниях, в этом году на конференции НЕЙРОИНФОРМАТИКА-2015 представлены доклады по проблемам теории нейронных сетей, нейробиологии, моделям адаптивного поведения, нейросетевому моделированию объектов и систем, обработке статистических данных, временных рядов и изображений и многим другим прикладным задачам нейроинформатики.

Более 200 российских ученых и наших зарубежных коллег направили в оргкомитет конференции результаты своих исследований.

По сложившейся традиции конференцию открывают приглашенные доклады. В рамках школы-семинара участники конференции прослушают лекции известных специалистов по актуальным проблемам нейроинформатики. На рабочем совещании участники конференции обсудят теоретические модели в нейробиологии. Особое внимание уделяется работам студентов, аспирантов и молодых специалистов, которые примут участие в творческом конкурсе.

За прошедшие годы российская конференция НЕЙРОИНФОРМАТИКА сложилась как представительный и многоплановый по тематике научный форум. В его работе принимают участие и известные ученые, и молодые специалисты, аспиранты и студенты. Желаем всем участникам конференции плодотворной работы, активного сотрудничества и новых творческих идей.

Оргкомитет

СОДЕРЖАНИЕ

Пленарные доклады

ГОРБАНЬ А.Н., МИРКЕС Е.М., ЗИНОВЬЕВ А.Ю.

Робастные топологические грамматики для нейронных сетей,
обучающихся без учителя 12

STOOR R.

The cochlea – a prototypical ancient neural network with a critical
architecture 13

TSODYKS M.

Understanding the capacity of information retrieval from long-term
memory 13

TIMOFEEVA YU., MICHIELETTO D., Y LU, COOMBES S.

Dendrites, neurons and resonances 14

АНОХИН К.В.

Когнитом: гиперсетевая модель мозга 14

САМСОНОВИЧ А. В.

Функциональные возможности биологически инспирированных
когнитивных архитектур 16

ОСИПОВ Г. С.

Нейрофизиологические и психологические основания знаковой
картины мира 17

КУЗНЕЦОВ О. П., ЖИЛЯКОВА Л. Ю.

Сложные сети и когнитивные науки 18

Стендовая сессия 1

НЕЙРОННЫЕ СЕТИ И КОГНИТИВНЫЕ НАУКИ

РЕБРУН И. А., СИДОРОВ К. В., ТЕРЕХИН С. А.,

ФИЛАТОВА Н. Н., ШЕМАЕВ П. Д.

Биотехническая система для исследования когнитивной
деятельности в различных эмоциональных состояниях
испытуемого 19

КОРОЛЕВА М. Е., БАХЧИНА А. В., УШАКОВА И. Л.,

НЕКРАСОВА М. М., КРУПА В. В., ПАРИН С. Б.

Вегетативное обеспечение некоторых форм социального
взаимодействия 29

КОРЯГИН Е. В., МЕДЯНСКИЙ И. А., ШИРКИН А. Е. Разработка модели ассоциативной памяти робота AP-600 для задачи кластеризации и обобщения данных	38
---	----

Секция 1

НЕЙРОННЫЕ СЕТИ И КОГНИТИВНЫЕ НАУКИ

РАДЧЕНКО Г. С., ПАРИН С. Б., ПОЛЕВАЯ С. А., КОРСАКОВА-КРЕЙН М. Н., ФЕДОТЧЕВ А. И. Влияние характеристик тональной модуляции музыкальных фрагментов на показатели ЭЭГ	47
БОЖОКИН С. В., СУСЛОВА И. Б. Нестационарная корреляция ансамбля вспышек ЭЭГ: вейвлет анализ	55
ТРОФИМОВ А. Г., КОЛОДКИН И. В., УШАКОВ В. Л., ВЕЛИЧКОВСКИЙ Б. М. Агломеративный метод выделения микросостояний ЭЭГ, связанных с характеристиками бегущих волн	66
ТРОФИМОВ А. Г., ИВАНИЦКИЙ И. И., ВЕЛИЧКОВСКИЙ Б. М. Жадный алгоритм построения комитета классификаторов сигналов ЭЭГ	78
АТАНОВ М. С., ИВАНИЦКИЙ Г. А. Оптимизация алгоритма распознавания типа текущей мыслительной деятельности на основе данных ЭЭГ	88
ТАРОТИН И. В., ИВАНИЦКИЙ Г. А. Построение модели мониторинга мыслительной деятельности в пространстве психологических характеристик	97
ВВЕДЕНСКИЙ В. Л. Как усреднять магнитные сигналы мозга	106

Секция 2

ТЕОРИЯ НЕЙРОННЫХ СЕТЕЙ

ПРОСТОВ Ю. С., ТЮМЕНЦЕВ Ю. В. Исследование нейросетевой модели на базе гистерезисного микроансамбля	116
---	-----

ТАРКОВ М. С.

Отображение матрицы весовых коэффициентов слоя нейронной
сети на мемристорный кроссбар 126

КУКИН К. А., СБОЕВ А. Г., СОБИНОВ А. Р.

Сравнение методов обучения спайковых нейронных сетей
на основе различных нейросимуляторов 134

Стендовая сессия 2

НЕЙРОСЕТЕВЫЕ СИСТЕМЫ ОБРАБОТКИ ДАННЫХ, РАСПОЗНАВАНИЯ ОБРАЗОВ И УПРАВЛЕНИЯ

СОЛОВЬЕВ А. М.

Искусственная нейронная сеть с гистерезисными свойствами
в задаче стабилизации обратного гибкого маятника с наличием
люфта в основании его крепления 144

ГОРБАТКОВ С. А., БЕЛОЛИПЦЕВ И. И., ФАРХИЕВА С. А.

Итерационный метод построения нейросетевой динамической
модели прогнозирования банкротств 154

ИВАНОВ Е. О., ЗАМЯТИН Н. В.

Нейронная сеть Хопфилда для управления группой
объектов (насосов) 164

ГАБДРАХМАНОВА Н. Т.

Нейросетевые модели для решения управленческих задач
на магистральном нефтепроводе 172

ШЕПЕЛЕВ И. Е., НАДТОКА И. И., ВЯЛКОВА С. А.,

ГУБСКИЙ С. О.

Определение оптимальных метапараметров для нейросетевого
краткосрочного прогнозирования электропотребления
крупного города 182

ИСАЕВ И. В., ДОЛЕНКО С. А., ОБОРНЕВ И. Е., ОБОРНЕВ Е. А.,

ШИМЕЛЕВИЧ М. И.

Повышение точности нейросетевого решения
многопараметрических обратных задач при группировке
определяемых параметров: проверка на модельных данных 191

БУРАКОВ М. В.

Разработка нейроэмулятора для нелинейного динамического
объекта 202

АБАТУРОВ В. С., ДОРОГОВ А. Ю.

Сервис-ориентированная инфраструктура аналитической
платформы для встраиваемых интеллектуальных подсистем 211

ТАРКОВ М. С., ОСИПОВ М. И.

Слежение за объектами байесовской сетью 221

ОРЕХОВА Е. Е., АБРАМОВ А. А., АНДРЕЕВ В. В.,
АНДРЕЕВА О. В.

Создание информационной системы на основе искусственных
нейронных сетей для определения предела выносливости
металлов под воздействием внешних факторов 231

Именной указатель авторов 242

Пленарные доклады

А.Н. ГОРБАНЬ¹, Е.М. МИРКЕС¹, А.Ю. ЗИНОВЬЕВ²

¹Университет Лестера, Великобритания

²Институт Кюри, Париж, Франция

РОБАСТНЫЕ ТОПОЛОГИЧЕСКИЕ ГРАММАТИКИ ДЛЯ НЕЙРОННЫХ СЕТЕЙ, ОБУЧАЮЩИХСЯ БЕЗ УЧИТЕЛЯ

Мы разработали систему робастных алгоритмов для нейронных сетей, обучающихся без учителя. Эти алгоритмы позволяют ассимилировать данные сложной топологии и аппроксимировать данные дендритами и кубическими комплексами. Мы разработали способы измерения сложности аппроксиматоров и методы отыскания баланса между сложностью и точностью аппроксимации.

Ключевые слова: *топологическая грамматика, ассимиляция данных, робастная статистика, обучение без учителя.*

A.N. GORBAN¹, E.M. MIRKES¹, A.YU. ZINOVYEV²

¹University of Leicester, Leicester, UK

²Institut Curie, Paris, France

ROBUST TOPOLOGICAL GRAMMARS FOR UNSUPERVISED NEURAL NETWORKS

We develop a family of robust algorithms for unsupervised learning. These algorithms aim to assimilate datasets of complex topologies and to approximate data by dendrite and cubic complexes. We develop the measure of the approximator complexity and find the balance between accuracy and complexity and to define the optimal approximations.

Keywords: *topological grammar, data assimilation, robust statistics, unsupervised learning.*

R. STOOP

Institute of Neuroinformatics and of Physics, UZH and ETHZ of Zurich,
Switzerland

THE COCHLEA – A PROTOTYPICAL ANCIENT NEURAL NETWORK WITH A CRITICAL ARCHITECTURE

Using a biophysically close implementation of the mammalian hearing sensor, we have recently shown that the pitch we perceive for complex sounds is of purely physical, in contrast to a cortical, origin. From the physical principles that guided the evolution of our hearing sensor, we infer the nature of pitch as the embracing description of the emergent complexity from the interaction of the nonlinear amplifiers present in the sensor, and use it to purposefully tune the sensor towards the perception of sounds we want to listen to. We then show that the network of the amplifiers resident in the hearing sensor is critical, and observe how this changes, as we listen to a target sound.

Keywords: *cochlea, neural networks, neural avalanches, building principles of constrained neural networks.*

M. TSODYKS

Department of Neurobiology Weizmann Institute of Science Rehovot, Israel

UNDERSTANDING THE CAPACITY OF INFORMATION RETRIEVAL FROM LONG-TERM MEMORY

Human memory stores vast amounts of information. Yet retrieving this information is challenging when specific cues are lacking. Classical experiments on free recall of lists of randomly assembled words indicate non-trivial scaling laws for the number of recalled words for lists of increasing length. The fundamental factors that control retrieval capacity are not clear. Here we propose a simple associative model of retrieval where each recalled item triggers the recall of the next item based on the similarity between their long-term neuronal representations. The model predicts retrieval capacity laws that are compatible with the psychological literature.

Keywords: *information retrieval, long-term memory, associative model.*

YU. TIMOFEEVA¹, D. MICHIELETTO¹, Y LU¹, S. COOMBES²

¹University of Warwick

²University of Nottingham, Great Britain

DENDRITES, NEURONS AND RESONANCES

Gap junctions, also referred to as electrical synapses, are expressed along the entire central nervous system and are important in mediating various brain rhythms in both normal and pathological states. These connections can form between the dendritic trees of individual cells. To obtain insight into the modulatory role of gap junctions in tuning networks of resonant dendritic trees, I will present two methods for calculating the response function of a network of gap-junction coupled neurons. These methods will then be used to construct compact closed form solutions for a two-cell network of spatially extended neurons which will allow the study of the role of location and strength of the gap junction on network dynamics.

Keywords: *resonant dendritic trees, network dynamics, electrical synapses.*

К.В. АНОХИН

НИИ Курчатовский институт, Институт нормальной физиологии
им. П.К. Анохина, Москва

КОГНИТОМ: ГИПЕРСЕТЕВАЯ МОДЕЛЬ МОЗГА

Несмотря на впечатляющие успехи нейронауки, природа высших функций мозга все еще ускользает от нашего удовлетворительного понимания. Эта ситуация, известная как «провал в объяснении» (explanatory gap), требует поиска новых объяснительных моделей и принципов. В настоящем докладе будет предложена модель организации мозга как когнитивной гиперсети – К-сети. Вершинами К-сети (когнитома), являются КОГи (когнитивные группы), представляющие собой подмножества вершин нижележащей N-сети (коннектома), объединенные единым когнитивным опытом. Ребра между к-вершинами в когнитоме формируются как совокупности ребер между образующими их подмножествами n-вершин в коннектоме. В понятиях алгебраической топологии КОГ представляет собой реляционный симплекс или гиперсимплекс, основанием которого служит симплекс из вершин опорной N-сети, одновременно выступающий

вершиной с новым качеством в К-сети более высокого уровня. Формализм гиперсетей обобщает сети и гиперграфы, давая аппарат, необходимый для отображения феноменов эмерджентности в многоуровневых системах, и позволяя моделировать гораздо более сложные структуры, чем сети и гиперграфы. В докладе будут рассмотрены некоторые нетривиальные следствия двусторонних отношений N- и К-сетей, лежащие в основе гиперсетевой теории мозга (ГСТМ).

Keywords: *сложные сети, гиперграфы, гиперсимплексы, гиперсети, когнитивные группы, коннектом, когнитом.*

K.V. ANOKHIN

National Research Centre «Kurchatov Institute», Institute of Normal Physiology. P.K. Anokhin, Moscow

THE COGNITOME: A HYPERNETWORK BRAIN MODEL

Despite impressive advances in neuroscience, the nature of the higher brain functions still eludes satisfactory understanding. This situation, known as «explanatory gap», calls for new explanatory models and principles. This report will suggest a model of the brain as the cognitive hypernetwork – K-network. The vertices of the K-network (cognitome) are COGs (GOgnitive Groups) - subsets of vertices from the underlying N-network (connectome) associated by a common cognitive experience. Edges between k-vertices in the cognitome are formed by the sum of edges between subsets of corresponding n-vertices in connectome. In terms of algebraic topology COG is a relational simplex or hypersimplex. Its base is the simplex from vertices of the underlying N-network and its apex is the vertex possessing a new quality at the higher-level K-network. Hypernetworks generalize networks and hypergraphs, provide formalism for description of emergent phenomena in the multi-level systems, and allow modeling much more complex structures than networks and hypergraphs. The report presents some non-trivial bipartite relations between N- and K-networks that form a background for the hypernetwork brain theory (HNBT).

Keywords: *complex networks, hypergraph, hypersimplex, hypernetwork, cognitive group, connectome, cognitome.*

А.В. САМСОНОВИЧ

Университет Джорджа Мэйсона, Фэйрфакс, Вирджиния, США

ФУНКЦИОНАЛЬНЫЕ ВОЗМОЖНОСТИ БИОЛОГИЧЕСКИ ИНСПИРИРОВАННЫХ КОГНИТИВНЫХ АРХИТЕКТУР

Основные функциональные аспекты мышления человека можно описать на вычислительном уровне и воспроизвести в машине на принципах не требующих детального моделирования нейронов и структур мозга. Это прежде всего основные принципы восприятия и осмысления информации, принятия и исполнения решений, сформулированные на языке символьных моделей типа когнитивных архитектур. Ключевыми же являются принципы социально-эмоционального интеллекта, нарративного интеллекта, мета-мышления, автономного выбора целей, семантического картирования, человекоподобной обучаемости и креативности. Создание в машине аналога человеческого субъекта на этих принципах и признание его людьми на уровне равного человеку персонажа приведет к технологическому прорыву, который окажет влияние на все сферы жизни человека.

Ключевые слова: *когнитивные архитектуры; нарративный интеллект; социально-эмоциональное мышление.*

A.V. SAMSONOVICH

Krasnow Institute for Advanced Study, George Mason University,
Fairfax VA, USA

FUNCTIONAL CAPABILITIES OF BIOLOGICALLY INSPIRED COGNITIVE ARCHITECTURES

General functional aspects of human cognition can be described at a computational level and replicated in a machine based on principles that do not require detailed modeling of neurons and brain structures. These are, primarily, basic principles of perception, reasoning, decision making and action control, formulated in terms of symbolic models like cognitive architectures. The key principles are those that support social-emotional intelligence, narrative intelligence, metareasoning, autonomous goal reasoning, semantic mapping, human-level teachability and creativity. Creation of a machine analog of the human mind based on these principles and its acceptance as a human-equivalent character

will lead to a technological breakthrough with an impact on all aspects of human life.

Keywords: *cognitive architectures, narrative intelligence, social-emotional cognition.*

Г.С. ОСИПОВ

Институт системного анализа РАН, Москва

НЕЙРОФИЗИОЛОГИЧЕСКИЕ И ПСИХОЛОГИЧЕСКИЕ ОСНОВАНИЯ ЗНАКОВОЙ КАРТИНЫ МИРА

Рассматривается модель картины мира субъекта деятельности, которая, с одной стороны, опирается на данные нейрофизиологических исследований, с другой – на известные психологические феномены. Рассматриваются процессы формирования образов, значений и личностных смыслов, операции обобщения, агглютинации, интроспекции. Строятся модели таких функций сознания как целеполагание и синтез поведения, объясняется существование различных типов картин мира субъектов поведения.

Ключевые слова: *субъект, образ, сознание, картины мира.*

G.S. OSIPOV

Institute for Systems Analysis of Russian Academy of Sciences (ISA RAS),
Moscow, Russia

NEUROPHYSIOLOGICAL AND PSYCHOLOGICAL FOUNDATION OF THE SYMBOLIC PICTURE OF THE WORLD

A model of the world picture of the active subject is considered. The model is based on data of neurophysiological studies and on the well-known psychological phenomena. The processes of the formation of patterns, patterns significance and personal meaning as well as the operations of generalization, agglutination, and introspection are considered. Models of such functions of consciousness as goal setting and synthesis of behavior are designed. The existence of different types of world pictures generated by active subjects is explained.

Keywords: *subject, consciousness, picture of the world.*

О.П. КУЗНЕЦОВ, Л.Ю. ЖИЛЯКОВА

Институт проблем управления им. В.А.Трапезникова РАН, Москва

СЛОЖНЫЕ СЕТИ И КОГНИТИВНЫЕ НАУКИ

Сложные сети – это сети с большим числом узлов и связей между ними. Примеры: Интернет, социальные сети, сети авиалиний, нервные сети головного мозга. В докладе излагаются основные понятия теории сложных сетей, описываются важные классы сложных сетей: безмасштабные сети и сети тесного мира. Рассматриваются процессы распространения активности в сетях. Отмечается важная роль теории сложных сетей в исследованиях нервных сетей головного мозга.

Ключевые слова: *сложные сети, коэффициент кластеризации, сети тесного мира, безмасштабные сети, динамические процессы, коннектом.*

O.P. KUZNETSOV, L.YU. ZHILYAKOVA

Institute of Control Sciences of Russian Academy of Sciences

COMPLEX NETWORKS AND COGNITIVE SCIENCES

Complex networks are networks with a large number of nodes and connections between them. Examples: Internet, social networks, networks of airlines, nervous networks of a brain. In the report the basic concepts of the theory of complex networks are stated, important classes of complex networks (scale-free networks and small-world networks) are described. Processes of activity propagation in networks are considered. The important role of the theory of complex networks in researches of brain networks is noted.

Keywords: *complex networks, clustering coefficient, small-world networks, scale-free networks, dynamical processes, connectom.*

Стендовая сессия 1

Нейронные сети и когнитивные науки

**И.А. РЕБРУН, К.В.СИДОРОВ, С.А. ТЕРЕХИН,
Н.Н. ФИЛАТОВА, П.Д. ШЕМАЕВ**

Тверской государственный технический университет
nfilatova99@mail.ru

БИОТЕХНИЧЕСКАЯ СИСТЕМА ДЛЯ ИССЛЕДОВАНИЯ КОГНИТИВНОЙ ДЕЯТЕЛЬНОСТИ В РАЗЛИЧНЫХ ЭМОЦИОНАЛЬНЫХ СОСТОЯНИЯХ ИСПЫТУЕМОГО

В докладе предлагается биотехническая система для исследования электрической активности мозга при выполнении ограниченного набора заданий в условиях и при отсутствии внешних эмоциональных стимулов. Методика исследования основана на объективном подтверждении изменения эмоционального состояния испытуемого по результатам мониторинга ЭЭГ. Рассмотрен процесс построения испытуемым лингвистических шкал для оценки размеров и цвета двумерных объектов простой формы.

Ключевые слова: *электроэнцефалограмма, биотехническая система, эмоция, аттрактор, лингвистическая шкала.*

**I.A. REBRUN, K.V.SIDOROV, S.A.TEREKHIN,
N.N. FILATOVA, P.D. SHEMAYEV**

Tver State Technical University
nfilatova99@mail.ru

BIOTECHNICAL SYSTEM FOR RESEARCH OF COGNITIVE ACTIVITY IN VARIOUS EMOTIONAL CONDITIONS OF THE EXAMINEE

The biotechnical system for research of electric activity of a brain when performing a limited set of tasks in conditions and in the absence of external emotional incentives is offered. The technique of research is based on objective confirmation of change of an emotional condition of the examinee by results of mon-

itoring of EEG. A process of creation of linguistic scales for an assessment of the sizes and color of two-dimensional objects of a simple form is considered.

Keywords: *electroencephalogram, biotechnical system, emotion, attractor, linguistic scale.*

Введение

В последние годы активно исследуется возможность внедрения в обучающие комплексы, компьютерные тренажеры [1] и другие человеко-машинные системы средств, предназначенных для мониторинга психофизиологического состояния оператора и формирования объективной оценки состояния человека. Особый интерес представляет определение характеристик, позволяющих описать эмоциональное состояние и выявить степень его влияния на производимую агентом деятельность, в частности на процедуры качественной оценки метрических или иных характеристик объектов. Для проведения таких исследований необходимо создание специализированной биотехнической системы, позволяющей использовать различные каналы предъявления стимулов и обрабатывать результаты с использованием общего математического аппарата.

Архитектура биотехнической системы

Биотехническая система EEG/S (electroencephalogram / speech signal) предназначена для исследования особенностей обработки информации в процессе выполнения заданий, связанных с оценкой качественных характеристик или вычислениями. Ее отличительной особенностью является возможность выполнения когнитивных экспериментов с испытуемым, эмоциональное состояние которого может изменяться под действием внешних стимулов, что позволяет моделировать условия различных ситуаций для принятия решений. Основное внимание при создании EEG/S уделялось вопросам формирования внешних эмоционально значимых воздействий, для восприятия которых испытуемый использует один или несколько каналов. Регистрация откликов осуществляется параллельно по двум каналам (с использованием сигналов электрической активности мозга и речевого тракта). Идея построения такой системы рассматривалась в работе [2] при создании методики формирования базы образцов эмоциональной речи. Биотехническая система (БТС) позволяет пользователю выбирать канал предъявления (V_h) / восприятия (V_{OS}) стимула для формирования у испытуемого соответствующего эмоционального состояния. Вариация V_h позволяет использовать в качестве каналов V_{OS} зрительный,

акустический, тактильный или обонятельный анализаторы, что позволяет создавать сложные интегральные стимулы и соответствующие реакции испытуемых. В состав системы входят энцефалограф «Энцефалан-131-03» и несколько вариантов каналов предъявления стимулов (рис. 1).




Рис. 1. Блок-схема биотехнической системы мониторинга эмоций:
 1 – блок управления; 2, 9 – БД видео и аудиостимулов; 3, 10 – блоки предъявления видео и аудиостимулов; 4 – микрофон; 5 – блок регистрации, первичной обработки и визуализации речевого сигнала; 6 – блок сегментации речевого сигнала; 7 – объект; 8 – оператор; 11 – компьютерный энцефалограф; 12, 13 – БД ЭЭГ, БД речевых сигналов; 14 – блок визуализации результатов; 15 – БД правил классификации (распознавания эмоций); 16 – блок мониторинга состояния испытуемого; 17 – блок определения векторов аттрактора; 18 – блок определения информативных интервалов спектральной плотности мощности; 19 – блок формирования признаков пространств; U – выбор режима работы системы (U1 – режим работы с видеостимулами; U2 – режим работы с аудиостимулами; U4 – режим регистрации электроэнцефалограмм)

Особенности методики регистрации эмоционального состояния испытуемого в БТС EEG/S

БТС EEG/S позволяет проводить эксперименты, связанные с выполнением испытуемым ограниченного набора заданий в условиях и при отсутствии внешних эмоциональных стимулов. В основу методики положено допущение, что после снятия внешнего, эмоционально значимого стимула, эмоция, которую ощущает испытуемый, не меняет знак в течение все-

го времени (T) выполнения задания. Тогда образцы ЭЭГ ($A(t < T)$) можно рассматривать как паттерны временных рядов, содержащих информацию о влиянии эмоциональной реакции на процесс решения. Реализация этого допущения осуществляется путем:

- ограничения объема отдельного задания (обычно время выполнения не превышает 10 – 15 с);
- специального сценария, предусматривающего чередование заданий и стимульного материала, вызывающего положительные или отрицательные эмоции.

Визуальный контроль за сигналами ЭЭГ позволяет оператору наблюдать возникающие различия в электрической активности головного мозга при восприятии стимулов разных видов. В ситуациях, когда в ЭЭГ оператор наблюдает факты значимого изменения электрической активности головного мозга объекта, происходит предъявление слайда с заданием. Обработанные речевые сигналы (с ответами) и ЭЭГ поступают в блок формирования признаков пространств, в котором формируются две гетерогенные векторные модели. Блок мониторинга эмоций осуществляет распознавание эмоционального состояния объекта по речевому сигналу или ЭЭГ.

Для количественной оценки эмоционального состояния испытуемого на основе анализа записей биомедицинских сигналов применяются методы нелинейной динамики, в частности m -мерные реконструкции аттрактора исходной динамической системы. Для построения аттракторов использован алгоритм из работы [3].

Применение аттракторов для обработки результатов экспериментов с системой EEG/S позволило перейти к многомерному представлению каждого отдельного сигнала (рис. 2 и 3).

Как показали исследования [4,5] при смене знака эмоционального состояния испытуемого наблюдаются изменения во временных диаграммах биомедицинских сигналов и в графиках соответствующих аттракторов. Приведенные на рис. 4 примеры наглядно иллюстрируют изменения проекций аттрактора, построенных по одному отведению ЭЭГ, при изменении эмоционального состояния испытуемого. Аналогичные результаты получаются по речевым образцам.

Для количественной оценки характеристик проекций аттрактора его площадь покрывается равномерной, ортогональной сеткой. Используются три типа признаков [2,4,5]: размеры проекции аттрактора, максимальная плотность точек проекции аттрактора, число ячеек с нулевым значением плотности точек аттрактора.




Рис. 2. Фрагмент ЭЭГ с произвольно выделенными точками $X(i)$ и $X(i+\tau)$




Рис. 3. Аттрактор, восстановленный по сигналу X : выделена одна точка аттрактора с координатами $(X(i), X(i+\tau))$

Основные правила оценки этих признаков описаны в работах [5,6]. Для классификации векторных моделей сигналов созданы две автономные нейросетевые иерархические структуры, каждая из которых поддерживает правила классификации эмоциональных реакций объекта [7,8]. Учитывая субъективность эмоциональных реакций при построении правил использовался аппарат нечеткой логики, что позволяет в ходе анализа образца ЭЭГ или речи рассчитывать степень его соответствия каждому классу. В итоговом заключении указывается класс, степень соответствия которому оказалась максимальной [8].




Рис. 4. Изменение характеристик аттракторов ЭЭГ сигнала при нейтральном состоянии (а), при отрицательных (б) и положительных(в) эмоциях

Рассмотренные средства позволяют получать объективные оценки знака эмоций, испытываемых участником эксперимента, практически сразу после завершения предъявления эмоционально значимого стимула и не приводят к дополнительным нагрузкам на испытуемого.

Методика проведения экспериментов по построению модели шкал

Система EEG/S предназначена для изучения особенности когнитивной деятельности испытуемого в условиях сложных или нечетко определенных ситуаций, которые могут возникать в управлении, проектировании, диагностике.

Одной из самых распространенных задач, решаемых операторами автоматизированных систем управления, является задача сравнения на множестве $\{A_i\}$ альтернатив и выбора одной, субъективно наилучшей A . Однако в практической деятельности мы постоянно сталкиваемся с ситуацией, когда множество $\{A_i\}$ существует только в воображении лица, принимающего решение (ЛПР). Наиболее часто это возникает в задачах оценки A_i по качественной шкале [9]. Этот вид когнитивных задач предполагает существование в памяти агента множества образов $\{x_i\}$, которые

определяют некоторые реперные точки на лингвистической шкале оценки свойства (L). Каждый такой образ $\forall x_i \in X$ можно рассматривать с одной стороны как одноточечное множество $1/l_i$, а с другой – как элемент нечеткого множества L с функцией принадлежности $0 < \mu_L(l_i) < 1$. Если образы упорядочены по условию:

$$\mu_L(l_{i+1}) > \mu_L(l_i), \quad i = 2, \dots, n-1, \quad \mu_L(l_1) = 0, \quad \mu_L(l_n) = 1,$$

то можно построить новую функцию принадлежности $\mu_L(i)$, которая будет использоваться в качестве ограничений при определении смысла единственной нечеткой переменной L , определяющей некоторое свойство объекта.

Задачи оценки таких характеристик, как размер, цвет, возникают постоянно, и человек их решает, опираясь на собственную коллекцию запомненных образов, которые и выступают в качестве $\{x_i\}$. Качество решения таких задач, т.е. близость оценок по шкале L к некоторым эталонам, которые закрепляются общепринятыми представлениями в данном сообществе, зависит от уровня знаний субъекта и от его способностей в реализации ряда когнитивных операций: вспоминания эталона, мысленного сравнения образца и эталона и др. Если коллекцию эталонных образов рассматривать, как элемент личного опыта, то тогда для оценки влияния некоторого фактора $X1$ (эмоциональный стимул) на решение когнитивных задач, связанных с оценкой качественных характеристик, необходимо создать ситуацию, при которой все испытуемые будут обладать примерно одинаковым множеством $\{x_i\}$.

К проведению экспериментов были привлечены 11 мужчин в возрасте от 18 до 27 лет. Испытуемые решали два типа задач: оценки размеров квадратов черного цвета, и определения цветовых оттенков затонированных квадратов одинакового размера. На экране монитора предъявлялся набор объектов, различающихся одной характеристикой (например, размером, R). Для каждого эталонного образа $x(R_i)$ было сформулировано единственное высказывание с качественной оценкой отличительного свойства (R). Упорядоченные эталоны $\{x(R_i)\}$ позволяли построить одну функцию принадлежности, для оценки свойства (R). Например, при решении задач с оценкой размеров квадрата использованы семь эталонов: $R_1 := (\text{точно не большой квадрат, } 4 \text{ см})$, $R_2 := (\text{совсем не большой квадрат, } 5 \text{ см})$ и т.д. до $R_k := (\text{точно большой квадрат, } 10 \text{ см})$. Для определения цветовых оттенков объектов использованы 5 эталонов, параметры которых задавались с учетом настроек модели цветов RGB (табл. 1).

В течение 15–20 с испытуемый знакомился с набором эталонных образов, которые иллюстрировали качественную шкалу для оценки размера

или цвета. Далее эталоны убирались и испытуемому в случайном порядке предъявлялись задания (от 20 до 40 заданий), заключающиеся в оценке единичных образов по качественной шкале. Каждый образ выводился на экран монитора на белом фоне на расстоянии одного метра от испытуемого t раз.

Таблица 1

Лингвистическая шкала	Точно не X	Не очень X	Более или менее X	Примерно X	Точно X
Ранг эталона	1	2	3	4	5
Параметры эталона X	15	75	135	195	255

Эксперименты проводились в условиях нейтрального состояния испытуемого и после восприятия серии эмоционально значимых видео или аудио стимулов. Для удобства обработки результатов упорядоченным эталонам поставлена в соответствие последовательность целых чисел: $i = 1, \dots, 7$. Тогда при использовании формулы “сигмоида 2” (из библиотеки MatLab) и эталонных образов получим расчетную $\mu_R(i)$. По результатам работы каждого испытуемого можно построить аналогичную функцию, отражающую его субъективные оценки свойства R . Для этого используется правило:

$$\mu_R^j(z) = \mu_R(i), \quad \tilde{R} = \sum_{i=1}^k \mu_i / i, \quad \tilde{R}_{is} = \sum_{z=1}^k \mu_z / z,$$

где z – средняя оценка i -го образа j -ым испытуемым на множестве из t однотипных заданий, $\tilde{R}$ – нечеткое множество, построенное на базовой шкале эталонов (i), $\tilde{R}_{is}$ – нечеткое множество, построенное на базовой шкале j -го испытуемого (z).

На рис. 5 приведен фрагмент построения функции принадлежности испытуемого $\mu_R^j(z)$ по результатам оценки размеров черного квадрата. Видно, что завышение оценки размера i -го эталона эквивалентно снижению значения функции принадлежности, а занижение оценки свойства R эквивалентно увеличению значения $\mu_R(i)$. Функции принадлежности, построенные по результатам экспериментов, отличаются от эталонной функции на участке $0 < \mu_R(i) < 1$.

Проведенные эксперименты показали, что даже незначительные эмоциональные изменения, вызванные внешними стимулами и объективно

подтверждаемые изменениями в характеристиках аттракторов биоэлектрических сигналов, приводят к изменениям в шкалах для оценки качественных признаков (рис. 6).




Рис. 5. Изменение функции принадлежности нечеткого множества «большой квадрат» при завышении и при занижении оценок размеров эталонов

Следует отметить, что если в нейтральном состоянии у испытуемого проявляется тенденция к завышению или занижению оценок, то она сохраняется и при небольших эмоциональных изменениях его состояния. Проведенные эксперименты не только подтверждают вывод об увеличении нечеткости в оценках размеров и цвета в условиях наличия внешнего эмоционального стимула и использования в качестве эталона образа из памяти, но и иллюстрируют эффективность интегрирования методик исследования когнитивной деятельности и эмоциональных реакций.

Заключение

Созданная биотехническая система EEG/S позволяет расширить методики исследования когнитивной деятельности в условиях внешних эмоциональных стимулов, степень влияния которых на испытуемого можно объективно оценить путем определения специальных признаков аттракторов, восстановленных по сигналам ЭЭГ.

Работа выполнена при частичной финансовой поддержке РФФИ (проект № 14-01-00719).




Рис. 6. Влияние эмоций:
 а – видео стимулы на оценку синего цвета;
 б – аудио стимулы на оценку зеленого цвета

Список литературы

1. Проектирование тренажерных комплексов для технического образования Филатова Н.Н. Монография / Н.Н. Филатова, О.Л. Ахремчик, Н.И. Вавилова; Федер. агентство по образованию. Тверь: Тв.ГТУ, 2005.
2. Филатова Н.Н., Сидоров К.В. Модель интерпретации эмоций в речи // Труды Конгресса по интеллектуальным системам и информационным технологиям «IS&IT'13». Научное издание в 4 томах. М.: Физматлит, 2013. Т. 1. С. 98–105.
3. Practical Implementation of Nonlinear Time Series Methods. In: The TISEAN package / R. Hegger, H. Kantz, T. Schreiber // CHAOS, 1999. V. 9. № 2. P. 413–435.
4. Сидоров К.В., Филатова Н.Н. Анализ признаков эмоционально окрашенной речи // Вестник Тверского государственного технического университета, 2012. № 20. С. 26–31.

5. Модель интерпретации знака эмоций по естественной речи Сидоров К.В., Филатова Н.Н. // Известия Южного федерального университета. Технические науки, 2012. № 9. С. 39.
6. Филатова Н.Н., Сидоров К.В., Ханеев Д.М. Применение нейроподобной иерархической структуры // XVI Всероссийская научно-техническая конференция «НЕЙРОИНФОРМАТИКА-2014» с международным участием: Сборник научных трудов в 3-х частях. Ч. 2. М.: НИЯУ МИФИ, 2014. С. 291–300.
7. Ханеев Д.М., Филатова Н.Н. Пирамидальная сеть для классификации объектов, представленных нечеткими признаками // Известия Южного федерального университета. Технические науки, 2012. № 9 (134). С. 45–49.
8. Филатова Н.Н., Ханеев Д.М., Сидоров К.В. Интерпретатор сигналов на основе нейроподобной иерархической структуры // Программные продукты и системы, 2014. № 1 (105). С. 92–97.
9. Виноградов Г.П. Методы и алгоритмы принятия решений в автоматизированных системах управления производствами с непрерывной технологией на основе субъективных представлений. Тверь: ТвГТУ, 2013.

**М.Е. КОРОЛЕВА¹, А.В. БАХЧИНА¹, И.Л. УШАКОВА¹,
М.М. НЕКРАСОВА², В.В. КРУПА³, С.Б. ПАРИН^{1,2}**

¹Нижегородский государственный университет им. Н.И. Лобачевского

²Нижегородская государственная медицинская академия

Министерства здравоохранения РФ

³Нижегородский государственный технический университет им. Р.Е. Алексеева
marijakoroleva@yandex.ru

ВЕГЕТАТИВНОЕ ОБЕСПЕЧЕНИЕ НЕКОТОРЫХ ФОРМ СОЦИАЛЬНОГО ВЗАИМОДЕЙСТВИЯ¹

В работе рассматривается проблема связи функционального состояния человека и социальных условий, в которых он находится. Мы рассматриваем такие специфические формы социального взаимодействия как публичное выступление, где исследуется влияние наличия аудитории слушателей на сердечный ритм говорящего, и езда курсанта автошколы с инструктором при обучении вождению.

Было показано, что контекст естественного публичного выступления для большинства испытуемых является фактором, провоцирующим стресс-активацию организма. Промежуточные результаты исследования

¹ Работа выполнена при частичной поддержке гранта РГНФ № 14-16-52005_а(р).

процесса обучения вождению показали наличие значимых положительных корреляций параметров сердечного ритма у двух из трех исследуемых пар в процессе первого практического занятия. В последующих практических занятиях эта связь теряется.

Ключевые слова: *социальное взаимодействие, функциональное состояние, публичное выступление, обучение вождению.*

**M.E. KOROLEVA¹, A.V. BAKHCHINA¹, I.L. USHAKOVA¹,
M.M. NEKRASOVA², V.V. KRUPA³, S.B. PARIN^{1,2}**

¹N.I. Lobachevsky State University of Nizhni Novgorod

²Nizhny Novgorod State Medical Academy

³R.E. Alekseev Nizhny Novgorod State Technical University
marijacoroleva@yandex.ru

AUTONOMIC REGULATION OF SOME FORM OF SOCIAL INTERACTION

The problem of the relationship of human functional state and its social conditions is considered. We consider the specific forms of social interaction: public performance and a student of driving school with instructor during driving instruction. It was shown that the context of public speaking is a stress factor for speakers. We also found a significant positive relationship between the parameters of heart rate of teacher and student at the first practical driving lesson.

Keywords: *social interaction, functional state, public speaking, driving instruction.*

Введение

Своим исследованием мы решаем проблему взаимосвязи социального контекста и функционального состояния человека. Существуют противоречивые наблюдения и результаты исследований влияния присутствия других людей на трудоспособность [1], сердечный ритм [2], принятие решений [1, 3]. Однако пока четких закономерностей выявить не удалось. Отчасти данная проблема осложняется наличием большого спектра видов социального взаимодействия со своими особыми характеристиками, дополнительными факторами, влияющими на участников взаимодействия.

В своей работе мы проанализировали некоторые формы социального взаимодействия, а именно процесс публичного выступления и процесс

взаимодействия курсанта со своим инструктором во время практических занятий обучения вождению.

Данные формы взаимодействия являются сложными, в них имеют место различные факторы, которые могут повлиять на функциональное состояние человека: эмоциональные, когнитивные, физические нагрузки, непредсказуемость развития события и др. Однако, социальное присутствие и взаимодействие является одной из ключевых характеристик исследуемых контекстов.

Социальное взаимодействие. Социальное присутствие

Общение – это сложный процесс, имеющий три стороны:

- общение как процесс передачи информации между людьми;
- общение как обмен восприятиями; формирование образа другого человека, и образа себя в глазах другого человека;
- общение как взаимодействие двух и более субъектов, реализуемое определенными средствами, детерминированное конкретными целями.

То есть в процессе общения участники не только обмениваются информацией, но и взаимно влияют друг на друга, изменяют систему представлений и восприятие мира [4].

Для того, чтобы произошло взаимодействие, зачастую хватает одного только присутствия других людей.

Эффект влияния присутствия на состояние человека был замечен довольно давно. Еще в конце 19 века Норман Трипплетт заметил и описал феномен социальной фасилитации – присутствие других облегчает действия одного, способствует им. Активность индивида повышается в условиях ее осуществления в окружении других людей по сравнению с обычным уровнем этой же активности при индивидуальном осуществлении. Чаще всего социальная фасилитация обнаруживается в ситуации соревнования с другими [3].

В ряде других экспериментов было показано наличие противоположного эффекта – сдерживания, торможения действий индивида под влиянием присутствия других, что получило название эффекта социальной ингибиции. Это снижение производительности деятельности, ее скорости и качества, когда она совершается в присутствии других людей, может проявляться даже тогда, когда другие присутствуют не реально, а лишь в воображении [1].

Рассуждая над причинами таких противоречивых результатов, социальный психолог Роберт Зайонц пришел к выводу, что возбуждение всегда усиливает доминирующую реакцию; повышенное возбуждение улуч-

шает выполнение простых задач, для которых наиболее вероятной («доминирующей») реакцией является правильное решение. Когда люди возбуждены, то они быстрее разгадывают простые анаграммы. В сложных задачах, где правильный ответ не напрашивается сам собой, возбуждение приводит к ошибкам. Возбужденные люди обычно хуже решают сложные анаграммы [3].

Исследуя влияние эффекта скученности (т.е. большого скопления людей на небольшом пространстве), Гари Эванс, Динеш Нагар и Джанак Панди выявили, что скученность усиливает возбужденность [3].

Из многочисленных экспериментов было выявлено, что факт присутствия других вызывает в человеке возбуждение и напряжение (социальное возбуждение по Майерсу), которое может по-разному влиять на поведение человека.

Н.Н. Данилова, описывая психофизиологические исследования социального взаимодействия, вводит термин «социальное присутствие», то есть присутствие наблюдателей. Изучение влияния социального присутствия на функциональное состояние человека показывает, что результат существенно зависит от характеристик наблюдателя; снижение уровня симпатической активации в присутствии наблюдателя возникает лишь в том случае, если он хорошо знаком с испытуемым, имеет ранг того же уровня и при этом ситуация не требует оценки деятельности испытуемого [2].

Таким образом, можно говорить о взаимосвязи и взаимовлиянии функционального состояния человека и социального взаимодействия, однако, каких-то определенных четких закономерностей пока не выявлено.

Публичное выступление как особая форма социального взаимодействия

Публичное выступление (ПВ) – особая форма деятельности в условиях непосредственного общения с аудиторией [5].

С точки зрения социальной коммуникации публичное выступление определяется как передача сообщения от коммуникатора к реципиенту (аудитории слушателей). Сообщение состоит из текста, передаваемого оратором, и мотивов самого выступающего [6].

Контекст публичного выступления является особой формой социального взаимодействия за счет специфичности его характеристик.

Понимая публичное выступление как специфическую социальную ситуацию, М. Аргайл выделяет следующие его характеристики:

- особая цель выступающего – донести художественное или информационное содержание до зрителя;

- особый репертуар деятельности – включенность паравербальных (тембр голоса, скорость, громкость) и невербальных (мимика, пантомимика и т. д.) выразительных компонентов;
- особые правила взаимодействия со зрителями;
- наличие зрителей;
- проблемные области ситуации – волнение выступающего, влияние зрителей [4].

Публичное выступление – это живое действие говорящего или играющего человека, которое осуществляется в контакте с тем или иным сообществом, с группой людей. ПВ осуществляется в рамках соотношения между активным модератором и определенной воспринимающей человеческой средой. При этом выступающее лицо берет на себя особую роль. Оно сознательно стремится воздействовать на среду, в том числе намеренно передавать информацию, знания, оказывать эмоциональное влияние, побуждать к определенному действию. Публичное выступление представляет собой некоторым образом подготовленный и спланированный контакт с группой внимающих людей.

Вегетативное обеспечение процесса общения в условиях публичного выступления

Вегетативное обеспечение деятельности – это способность вегетативной нервной системы к долговременному поддержанию вегетативной реактивности на определенном уровне, обеспечивающем эффективную реализацию актуальной функции [7].

Предыдущие исследования в данной области показали психологические изменения, вызванные публичным выступлением: социальное возбуждение, боязнь оценки, сценическое волнение, повышенная ответственность [5], а также продемонстрировали физиологические изменения: повышение артериального давления и частоты сердечных сокращений, повышение уровня адреналина и кортизола [8–11]. Результаты современных исследований [9–11] свидетельствуют, что публичное выступление – это фактор, вызывающий в организме человека стресс – системную неспецифическую защитную реакцию на повреждение или его угрозу [12]. Она запускается в том случае, если у организма нет модели реагирования, специфичной для успешной адаптации в данном контексте.

Контекст публичного выступления сложен. В нем можно выделить следующие составляющие, которые влияют на функциональное состояние выступающего: устная речь, воспроизведение информации по памяти,

наличие слушателей. Поэтому мы поставили перед собой две основные цели:

- определение непрерывных психофизиологических изменений функциональной системы у лиц, выступающих перед аудиторией;
- выявление степени влияния различных компонентов контекста публичного выступления на функциональное состояние выступающего.

Методы, используемые в работе:

Компьютерная кампиметрия – измерение дифференциальных порогов цветоразличения [13];

Компьютерная латерометрия – измерение пространственных характеристик пространственного слуха, функциональной межполушарной асимметрии[13];

Беспроводная кардиоинтервалография – мониторинг показателей вегетативной регуляции, уровня адаптационных ресурсов организма [14].

Было проведено две серии экспериментов:

1 – в контексте естественной деятельности (студенты во время представления исследовательских работ на защитах и конференциях, 25 человек в возрасте от 13 до 25 лет);

2 – в контексте публичного выступления, смоделированного в лаборатории, при зачитывании выданного текста и рассказе его по памяти (16 студентов в возрасте от 17 до 19 лет).

Результаты

Контекст публичного выступления приводит к значимому снижению коэффициента межполушарной асимметрии ($p=0,025$). Это является маркером стрессогенности изучаемого контекста [13].

У 73% испытуемых, непосредственно выступающих на публике, наблюдается снижение общей мощности сердечного ритма при одновременном повышении индекса вегетативного баланса. Сопоставляя данные результаты с исследованиями сердечного ритма в оптимальных и экстремальных условиях [11], можно сказать, что данная динамика характерна для стресса.

В условиях моделирования исследуемого контекста динамика параметров сердечного ритма, характерная для стресса, наблюдается, но не является доминирующей (15,6%). То есть результаты лабораторного эксперимента не воспроизводят результаты измерений, проводимых в контексте естественной деятельности.

Во второй серии экспериментов была выявлена доминирующая динамика во всех контекстах: снижение общей мощности и снижение индекса вегетативного баланса. Причем, наиболее часто (75% испытуемых) данная динамика встречается в 3 контексте (рассказ по памяти).

Таким образом, динамическим показателем стресса, вызванного публичным выступлением, является снижение значения общей мощности variability сердечного ритма на фоне увеличения индекса вегетативного баланса.

Воспроизведение эксперимента в лаборатории не отражает результатов, полученных в естественной деятельности.

Переход от одних когнитивных функций к другим (от чтения к рассказу по памяти одного и того же текста) ведет к изменению режимов вегетативной регуляции сердца.

Психологические и психофизиологические особенности взаимодействия в системе учитель-ученик в процессе практического обучения вождению

Одним из наших дальнейших направлений для исследования является изучения психологических и психофизиологических изменений в процессе взаимодействия «учитель-ученик».

Особым видом социального взаимодействия, опосредованного ситуацией повышенной опасности, является общение курсанта автошколы с инструктором в процессе практического занятия на проезжей части, когда ученик ведет автотранспортное средство самостоятельно, под контролем учителя. В этом случае на функциональное состояние курсанта действуют такие факторы как постоянно меняющаяся дорожная обстановка, непредсказуемость поведения соседей по вождению, отсутствие автоматического навыка вождения автомобилем, присутствие другого человека в салоне автомобиля, который оценивает правильность действий, выполняемых курсантом [15].

В ходе нашего предварительного исследования было проанализировано три пары «курсант-инструктор» в ходе практических уроков вождению.

Цель этого исследования: проследить изменение параметров сердечного ритма и уровня эмоциональной дезадаптации у курсантов и инструкторов в процессе освоения навыков вождения, выявить наличие/отсутствие согласованности данных изменений у ученика и учителя.

Методы исследования:

Проективно-вербальная методика *Уровень эмоциональной дезадаптации* – оценка текущего эмоционального состояния испытуемых;

Беспроводная кардиоинтервалография – мониторинг показателей вегетативной регуляции, уровня адаптационных ресурсов организма [14].

Измерения проходили во время первой поездки курсанта с инструктором, в середине обучения и во время последней поездки с инструктором.

В результате исследования уровня эмоциональной дезадаптации мы наблюдаем следующие тенденции:

У двух из трех курсантов наблюдается более высокий уровень эмоциональной дезадаптации перед первой поездкой относительно последующих; у одного наблюдается более высокий уровень эмоциональной дезадаптации перед последней поездкой относительно предыдущих.

В процессе взаимодействия с инструктором и езды по проезжей части мы наблюдаем изменение уровня эмоциональной дезадаптации.

У первого курсанта – снижение после 1 и 2 поездок (у его инструктора та же тенденция); у второго курсанта – снижение после первой поездки (интересно отметить, что у его инструктора после этой поездки наблюдается большое увеличение уровня эмоциональной дезадаптации), а затем увеличение после последующих занятий; у третьего курсанта наблюдается возрастание уровня эмоциональной дезадаптации после первых двух поездок (при снижении уровня эмоциональной дезадаптации у его инструктора), а после последней поездки эмоциональное состояние улучшается и у курсанта, и у его инструктора. Однако каких-то четких закономерностей проследить пока невозможно, так как количество испытуемых еще очень мало.

Анализируя динамику параметров сердечного ритма, мы обращали внимание на наличие показателей стресс-активации организма [11].

У первой пары курсант-инструктор наблюдается синхронное снижение количества ситуаций, приводящих организм в стресс-активацию.

У курсантов из второй и третьей пар вторая поездка оказалась особо стрессогенной (13 и 8 стресс-активаций соответственно), однако у их инструкторов мы такой стрессогенности не наблюдаем.

Результаты корреляционного анализа параметров сердечного ритма курсанта и инструктора показали значимые положительные корреляции частоты сердечного ритма, общей мощности спектра вариабельности, индекса вегетативного баланса у двух из трех исследуемых пар в процессе первого практического занятия. В последующих практических занятиях эта связь теряется.

Выводы

Нами были проанализированы такие специфические формы социального взаимодействия как публичное выступление и езда курсанта автошколы с инструктором при обучении вождению.

Было показано, что контекст естественного публичного выступления для большинства испытуемых является фактором, провоцирующим стресс-активацию организма. Воспроизведение эксперимента в лаборатории не отражает результатов, полученных в естественной деятельности. Переход от одних когнитивных функций к другим (от чтения к рассказу по памяти одного и того же текста) ведет к изменению режимов вегетативной регуляции сердца.

Промежуточные результаты исследования процесса обучения вождению показали наличие значимых положительных корреляций параметров сердечного ритма у двух из трех исследуемых пар в процессе первого практического занятия. В последующих практических занятиях эта связь теряется.

Список литературы

1. Андреева Г.М. Психология социального познания. – 2-е изд. М.: Аспект-Пресс, 2000.
2. Данилова Н.Н. Психофизиология. М.: Аспект-Пресс, 2010.
3. Майерс Д.Д. Социальная психология. СПб.: Питер, 2010.
4. Аргайл М. Основные характеристики ситуации // Психология социальных ситуаций /Сост. и общ. ред. Н.В. Гришина. СПб.: Питер, 2001. С. 178-197.
5. Юрченко О.В. Способы психологической саморегуляции функциональных состояний профессионала в процессе и реализации публичного выступления. Диссертация ... кандидата психологических наук : 19.00.03 [Электронный ресурс ФБ ННГУ] М.; 2007.
6. Харащ А.У. Смысловая структура публичного выступления (об объекте смыслового восприятия)//Вопросы психологии, 1078. № 4.
7. Вегетативные расстройства. Клиника, диагностика, лечение. / Под ред. А.М. Вейна. М., 2003.
8. Allen A.P., Kennedy P.J., Cryan J.F., Dinan T.G., Clarke G. Biological and psychological markers of stress in humans: Focus on the Trier Social Stress Test // Neuroscience and Biobehavioral Reviews 38, 2014. P. 94–124.
9. Lewinski M., Biau S., Erber R., Ille N., Aurich J., Faure J.-M., Mustl E, Aurich C. Cortisol release, heart rate and heart rate variability in the horse and its rider: Differ-

ent responses to training and performance // The Veterinary Journal 197, 2013. P. 229-232.

10. Zanstra Y.J., Johnston D.W. Cardiovascular reactivity in real life settings: Measurement, mechanisms and meaning // NIH Public Access Author Manuscript UK, 2011.

11. Бахчина А.В., Парин С.Б., Шишалов И.С., Кожевников В.В., Некрасова М.М., Котикова Д.С., Елизарьева Н.В., Полевая С.А. Динамика ритма сердца в стрессогенных информационных контекстах. // Нелинейная динамика в когнитивных исследованиях. Тезисы докладов. Н. Новгород, 2013. С. 9-12.

12. Селье Г. Очерки об адапционном синдроме / Пер. с англ. М.: Медицина, 1960.

13. Полевая С.А. Интегративные принципы кодирования и распознавания сенсорной информации. Особенности осознания световых и звуковых сигналов в стрессовой ситуации // Вестник Новосибирского государственного университета, 2008. Т. 2. Вып. 2. С. 106-117.

14. Полевая С.А., Рунова Е.В., Некрасова М.М., Федотова Е.В., Бахчина А.В., Ковальчук А.В., Шишалов И.С., Парин С.Б. Телеметрические и информационные технологии в диагностике функционального состояния спортсменов // Клиническая медицина, 2012. Вып. 4. С. 94-98.

15. Романов А.Н. Автотранспортная психология: Учеб. пособие для студ. высш. учеб. заведений. М.: ИЦ «Академия», 2002.

Е.В. КОРЯГИН, И.А. МЕДЯНСКИЙ, А.Е. ШИРКИН

Балтийский федеральный университет им. И. Канта, Калининград
koryagin.evgeniy@gmail.com

РАЗРАБОТКА МОДЕЛИ АССОЦИАТИВНОЙ ПАМЯТИ РОБОТА АР-600 ДЛЯ ЗАДАЧИ КЛАСТЕРИЗАЦИИ И ОБОБЩЕНИЯ ДАННЫХ

Проведен анализ существующих моделей ассоциативной памяти, проанализировано их соответствие критериям применения в роботах. Представлена модель модернизированной самоорганизующейся растущей нейронной сети, способной выполнять задачу моделирования ассоциативной памяти в роботах.

Ключевые слова: *ассоциативная память, система управления в роботах.*

E.V. KORYAGIN, I.A. MEDYANSKIY, A.E. SHIRKIN

Immanuel Kant Baltic Federal University, Kaliningrad
koryagin.evgeniy@gmail.com

DEVELOPMENT OF ASSOCIATIVE MEMORY MODEL FOR ROBOT AR-600 FOR CLUSTERIZATION AND GENERALIZATION TASKS

Several neural network models are considered for associative memory reconstruction perspective. Effectiveness and eligibility of existing methods is analyzed. Modified self-organizing incremental neural network model is presented as a main method for associative memory modeling of any kind input data. Perspectives of further work are described.

Keywords: *associative memory, self-organizing incremental neural network, noise robustness, unsupervised learning, clusterization, control.*

Введение

Данная работа является развитием исследований [1 – 4]. Перед авторами стоит задача разработки интеллектуальной системы управления антропоморфным роботом AR-600. Среди требований, предъявляемых к системе управления, важными являются возможность связывания разнородных данных и запоминание временных последовательностей. Ядром такой системы должна стать модель ассоциативной памяти. Авторами были определены основные требования к такой модели, исходя из задачи применения ее в робототехнике. В данной работе представлен анализ известных моделей ассоциативной памяти и предложен вариант доработки лучшей из рассмотренных моделей.

С учетом того, что системе управления необходимо обрабатывать разнородные данные с подсистем робота (это системы технического зрения, системы компьютерного слуха, системы энкодеров и тактильных датчиков и др.), были сформулированы следующие критерии для ассоциативной памяти:

1. Необходимо, чтобы ассоциативная память могла работать не только с двоичными числами, но и с действительными.
2. Ассоциативная память должна обладать свойством синаптической пластичности, т.е. память должна накапливать новые ассоциации без разрушения старых. При этом не должна теряться способность к обучению.

3. Ассоциативная память должна уметь связывать последовательные события (события, связанные временем). Также она должна уметь связывать и статические во времени образы.

4. Ассоциативная память должна уметь реализовывать ассоциативные связи один к одному, один ко многим, многие ко многим.

5. Ассоциативная память должна быть устойчивой к шуму.

6. Ассоциативная память должна уметь ассоциировать непохожие образы.

На основе данных критериев был проведён анализ уже существующих моделей ассоциативной памяти, выявлены их достоинства и недостатки.

Анализ известных моделей ассоциативной памяти

Были проанализированы известные алгоритмы нейросетевой ассоциативной памяти, в том числе нейронные сети Хопфилда [5, 6] и Кохонена [7]. Также были проанализированы более свежие схемы ассоциативной памяти, рассмотренные ниже.

Двунаправленная ассоциативная память (ДАП)

Принцип действия. Идея двунаправленной памяти базируется на адаптивно-резонансной теории Стефана Гроссберга и автоассоциативной памяти Хопфилда [5].

В отличие от сети Хопфилда, ДАП выполняет задачу гетероассоциативной памяти, т.е. запоминаются ассоциации между парами образов. Также входной образ может быть ассоциирован не с коррелирующим с ним образом. Этого можно достичь, если выходной вектор формируется на другом наборе нейронов [4].

Преимущества:

- Простая реализация.
- Быстрая сходимость к точке устойчивости и восстановление ассоциативных пар.
- Весовые коэффициенты синапсов считаются только один раз – при инициализации.
- Совместимость с аналоговыми схемами и оптическими системами.

Недостатки:

- ДАП унаследовала недостаток сети Хопфилда в низкой емкости.
- Если сеть сильно перегружена, то будут возникать неточности в распознавании ассоциативных пар.

- Нет возможности самоорганизации (невозможно обработать данные с разными размерностями).
- Обработывает только бинарные данные.

Нейронный газ

Принцип действия. Данная нейронная сеть основана на идее когнитивных карт. При этом используется реорганизация сети с изменением свойств входного вектора данных. Модификацией этой идеи является отсутствие заранее заданной топологии сети, которая строится в ходе работы сети, подстраиваясь под обучающие данные, что позволяет интерполировать ассоциативную память и решать задач оптимизации [1].

Преимущества:

- Особый вид топологии сети позволяет сети максимально хорошо подстраиваться под свойства и особенности входных данных.
- Сеть является растущей и самоорганизующейся, что уникально подходит под задачи робототехники при реализации ассоциативной памяти.
- Нейронный газ способен получать данные разных размерностей.

Недостатки:

- Неспособность отслеживать временные последовательности с быстро меняющимися характеристиками. Это приводит к тому, что уже созданные топологические структуры оказываются фиктивными и не используются в дальнейшем.
- Не строит ассоциации многие ко многим.

Общая ассоциативная память (ОАП)

Этот тип ассоциативной памяти создан группой японских и китайских учёных в 2010 году [2, 4].

Принцип действия. Данная модель ассоциативной памяти состоит из трёх слоёв (рис. 1): входного слоя, слоя памяти и ассоциативного слоя. Первый слой (нижний на рис. 1) отвечает за входные и выходные векторы, второй (средний) хранит входные векторы, классифицируя их с помощью нейронной сети SOINN [3], третий слой создаёт ассоциации между классами из второго слоя.

Изначально данные поступают на входной слой. Они обрабатываются вторым слоем, где SOINN классифицирует их, при этом, если входные данные поступили в течение небольшого промежутка времени, на уровне третьего слоя между нейронами-представителями этих данных образуется

ассоциативная связь. Ассоциативная связь усиливается, если возбуждение тех же нейронов-представителей повторяется. Со временем же связь между этими нейронами ослабевает. В любой момент функционирования ОАП можно узнать по определённым данным, какие выходные данные ассоциируются с этими входными. На вход специальной функции нахождения ассоциативной связи подаются входные данные. Они кластеризуются, находится их нейрон-представитель, далее находятся связанные с ним сильной ассоциативной связью нейроны-представители. Затем возвращаются типичные выходные данные, ассоциирующиеся с данным входом.




Рис. 1. Слои общей ассоциативной памяти (ОАП)

Достоинства:

- Возможность обучения без какого-либо априорного знания о предметной области.
- Синаптическая пластичность.
- Работает с небинарными входными данными.
- Способна ассоциировать последовательность событий.
- Способна ассоциировать один образ ко многим, многие ко многим.
- Устойчива к шуму в данных.
- Более быстрое обучение, чем в рекуррентных нейронных сетях.

Недостатки:

- Результат обучения зависит от того, в какой последовательности поданы входные векторы.
- Менее эффективна при решении узкоспециализированных задач.

Результаты сравнения моделей

Результаты проведенного анализа представлены в табл. 1. ОАП удовлетворяет основным требованиям, выдвигаемым к модели ассоциативной памяти, что делает её лучшей для решения поставленной задачи – служить основой для интеллектуальной системы робота.

Таблица 1

Сравнение известных моделей ассоциативной памяти

	ОАП	ДАП	Сеть Хопфилда	Сеть Элмана	Сеть Кохонена
Работа с не двоичными данными	+	-	-	+	+
Синаптическая пластичность	+	-	-	-	-
Ассоциация последовательных событий	+	-	-	+	-
Ассоц. один ко многим, многие ко многим	+	-	-	+	-
Устойчивость к шуму	+	+	+	+	+
Гетеро-ассоциативность	+	+	-	+	+
Конкурентное обучение	+	-	-	-	+
Слои	3	2	2	2-3	2

Проблема кластеризации данных

Второй слой общей ассоциативной памяти решает задачу кластеризации данных без изначального знания об их природе, характере и предметной области. Разработчики ОАП используют для этого сеть SOINN. Нами были проанализированы и другие методы кластеризации данных, в том числе и модифицированные алгоритмы SOINN – ESOINN (Enhanced SOINN [3]).

Основная проблема задачи кластеризации в работе заключается в том, что нет чёткого определения, что же такое “кластер” применительно к нашим задачам. Такое определение появляется лишь в конкретных предметных областях.

В табл. 2 приведен сравнительный анализ наиболее известных алгоритмов кластеризации. Помимо упомянутых SOINN и ESOINN указаны также алгоритмы иерархической кластеризации, EM-алгоритмы и метод k средних [8,9]. Под сложностью подразумевается формула зависимости

количества операций от количества входных данных, где N – количество входных элементов, K – количество кластеров [9]. При этом были использованы наиболее распространенные для данной задачи критерии сравнения. Среди рассмотренных моделей SOINN и ESOINN лучше всего подходят для второго слоя ОАП. Об этом же пишут авторы ОАП в своих работах.

Таблица 2

Сравнение основных алгоритмов кластеризации

	SOINN	ESOINN	Иерархическая кластеризация	Метод k средних	ЕМ-алгоритм
Количество классов	Неограниченно	Неограниченно	Ограничено	Ограничено	Ограничено
Обучение без учителя	+	+	+	+	+
Инкрементное обучение	+	+	+	-	-
Устойчивость к шумам	+	+	-	+	+
Абстрагирование от предметной области	+	+	-	-	+
Обработка данных низкой и высокой плотности	-	+	+	+	+
Хранение двоичной и недвоичной информации	+	+	-	-	-
Сложность	N^2	N^2	N^3	$KN^{(1-1/K)}$	N^3

Описание предлагаемой модели ассоциативной памяти робота AP-600

Предлагается следующая модель ассоциативной памяти для робота. В её основе будет лежать трёхслойная общая ассоциативная память (ОАП), где первый слой будет исполнять роль входного слоя, второй будет кластеризовать элементы входного слоя, т.е. он будет состоять из нейронов-представителей первого слоя, обобщающих элементы первого слоя. Эту задачу во втором слое будет выполнять ESOINN, так как она лучше всего справляется с задачей кластеризации данных. Третий слой или слой ассоциаций будет для каждого набора нейронов второго слоя иметь нейрона-представителя, который будет связан с другими нейронами –

представителями других наборов нейронов второго слоя, именно эти связи и образуют ассоциативные связи.

Применим эту модель к системе управления роботом. Первый слой ОАП будет получать сигналы от разнообразных анализаторов антропоморфного робота AP-600, имеющегося в наличии Лаборатории интеллектуальной робототехники БФУ им. И. Канта. Сначала планируется этот метод в подсистемах технического зрения и распознавания речи. Второй слой будет обобщать полученные сигналы от каждого анализатора, объединяя разные сигналы одного объекта в один кластер. Третий слой будет связывать объекты из второго слоя ассоциативной связью при одновременной или близкой по времени активации нейронов этого слоя. Таким образом, «услышав» слово мяч и «увидев» его зрительный образ, робот свяжет эти два понятия ассоциативной связью.

Реализация описанной выше модели в виде подсистемы робота AP-600 ведется с использованием языка C++. Текущая версия алгоритма сети ESOINN доступна по ссылке [10]. Модуль ассоциативной памяти будет встроен в виде отдельного узла в инфраструктуру Robot Operating System [11], которая поддерживается роботом AP-600.

Заключение

В работе были проанализированы известные модели ассоциативной памяти, выбрана лучшая модель для использования в качестве ассоциативной памяти робота. Также проведён анализ слабых мест этой модели и найден способ её улучшить. Для робота AP-600 предложена модель ассоциативной памяти. В настоящее время ведется практическая реализация модели.

Список литературы

1. Fritzke B. A Growing Neural Gas Network Learns Topologies // Advances in Neural Information Processing Systems, 1995. V. 7. P. 625-632.
2. Furao S. An Algorithm for Incremental Unsupervised Learning and Topology Representation, Ph.D Thesis, Tokyo Institute of Technology, 2006.
3. Furao S., Ogura T. and Hasegawa O. An enhanced self-organizing incremental neural network for online unsupervised learning // Neural Networks, 2007. V. 20. No.8. P. 893-903.
4. Furao S, Ouyang Q., Kasai W., Hasegawa O. A General Associative Memory Based on Self-organizing Incremental Neural Network // Neurocomputing, 2013. V. 104. P. 57-71.

5. Storkey A.J., Valabregue R. The basins of attraction of a new Hopfield learning rule // *Neural Networks*, 1999. V. 12. No. 6. P. 869-876.
6. Hopfield J.J. Neural networks and physical systems with emergent collective computational abilities // *Proceedings of National Academy of Sciences*, 1982. V. 79. No. 8. P. 2554-2558.
7. Kohonen T. *Self-Organization and Associative Memory*, Berlin: Springer, 1984.
8. Estivill-Castro V. Why so many clustering algorithms – A Position Paper // *ACM SIGKDD Explorations Newsletter*, 2002. V. 4. P. 65–75.
9. Rand W. M. Objective criteria for the evaluation of clustering methods // *Journal of the American Statistical Association (American Statistical Association)*. 1976. V. 66. P. 846–850.
10. ESOINN abstract library for any sizes of input data, url: <https://github.com/VincentLaw/ESOINNlib> (дата обращения: 29.09.2014).
11. Quigley M., Conley K., Gerkey, B., Faust J., Foote T., Leibs J., Wheeler R., Ng A. ROS: an open-source Robot Operating System, ICRA Workshop on Open Source Software, 6 pages, url: <http://www.robotics.stanford.edu/~ang/papers/icraoss09-ROS.pdf> (retrieved 3 April 2010).

Секция 1

Нейронные сети и когнитивные науки

**Г.С. РАДЧЕНКО¹, С.Б.ПАРИН¹, С.А. ПОЛЕВАЯ²,
М.Н. КОРСАКОВА-КРЕЙН³, А.И. ФЕДОТЧЕВ⁴**

¹Нижегородский государственный университет им. Н.И. Лобачевского

²Нижегородская государственная медицинская академия
Министерства здравоохранения РФ

³Touro College and University System, New York

⁴Институт биофизики клетки РАН, Пущино, Московская обл.
radchenko.grigoriy@mail.ru

ВЛИЯНИЕ ХАРАКТЕРИСТИК ТОНАЛЬНОЙ МОДУЛЯЦИИ МУЗЫКАЛЬНЫХ ФРАГМЕНТОВ НА ПОКАЗАТЕЛИ ЭЭГ¹

В работе исследовано влияние ладового условия модуляции музыкальных фрагментов и ее расстояния на характеристики электроэнцефалограммы. Были выявлены различия мажорных и минорных ладовых условий в зависимости от расстояния модуляции. Были обнаружены достоверные различия общей мощности в зависимости от степени модуляции для стимулов с однородными ладовыми условиями мажор-мажор и минор-минор.

Ключевые слова: *музыка, электроэнцефалограмма, тональная модуляция, тональное расстояние, ладовое условие.*

**G.S. RADCHENKO¹, S.B. PARIN¹, S.A. POLEVAYA²,
M.N. KORSAKOVA-KREYN³, A.I. FEDOTCHEV⁴**

¹N.I. Lobachevsky State University of Nizhni Novgorod

²Nizhny Novgorod State Medical Academy

³Touro College and University System, New York

⁴Institute of Cell Biophysics, Pushchino, Moscow region
radchenko.grigoriy@mail.ru

INFLUENCE OF CHARACTERISTICS OF TONAL MODULATION OF MUSICAL FRAGMENTS ON EEG

We investigate how conditions of modal modulation of musical fragments and distance of modulation influence on EEG characteristics. We found that

¹Работа выполнена при поддержке РГНФ проект 14-36-01024.

differences between major and minor mode conditions depend on the distance of modulation. We found significant differences in the total power that depend on the degree of modulation for stimuli with same mode condition major-major and minor-minor.

Keywords: *music, EEG, tonal modulation, tonal distance, mode condition.*

Введение

Музыка все больше применяется как средство терапии и коррекции состояний человека и реабилитации в различных областях психофизиологии, медицины и психологии. В связи с этим необходимо изучение влияния базовых элементов музыки на функциональное состояние человека. Достаточной большой пласт исследований в последнее время направлен на изучение особенностей восприятия музыки при различных акустических условиях [1], при этом игнорируется информационная составляющая восприятия музыки, которая связана, прежде всего, с восприятием движения в мелодическом пространстве. Тональная модуляция представляет собой смену тонального центра в рамках одной музыкальной композиции [2]. Этот прием является одним из главных структурных компонентов музыки и одним из ключевых средств выразительности в Европейской музыкальной культуре. В данной работе изучено влияние тональной модуляции на характеристики электроэнцефалограммы.

Процедура эксперимента

В исследовании приняли участие 15 студентов факультета социальных наук ННГУ им. Лобачевского обоего пола (5 мужчин и 10 женщин), в возрасте от 17 до 28 лет (средний возраст – $20,7 \pm 3,4$). Опыт игры на музыкальных инструментах и занятий вокалом имели 12 добровольцев (средняя продолжительность – $4 \pm 3,2$ года), ни один из них не являлся профессиональным музыкантом. Все участники эксперимента были правшами. Перед участием в эксперименте каждый испытуемый ознакомился и подписал форму добровольного информированного согласия на участие. Эксперимент был организован и проводился в соответствии с этическими нормами, установленными Хельсинской декларацией 1964 года.

Испытуемым предлагалось прослушать набор из 48 аудиостимулов. Стимулы были подготовлены следующим образом. Специально для этого эксперимента были написаны 12 коротких музыкальных фраз, по одной

фразе для каждой из 12 степеней модуляции, включая не-модулирующее условие, чтобы обеспечить базовые данные для сравнения с теми модуляциями, в которых происходил переход на другой тональный центр и в другой лад. Начала и окончания этих 12 основных фраз были модифицированы так, что получились четыре варианта модуляций для той же самой ступени: из мажора в мажор (М-М), из мажора в минор (М-м), из минора в мажор (м-М) и из минора в минор (м-м). Таким образом, были получены все возможные ладовые версии для каждой из 12 возможных степеней модуляции

Каждая музыкальная фраза состояла из 8 аккордов. Первые три-пять аккордов устанавливали начальную тональность, и следующие за ними переходные аккорды совершали модуляцию в заключительную тональность посредством обычной каденции доминанта-тоники. Музыкальные фразы были похожи по темпу, стилю, громкости, тембру и фактуре. Стилистическое единообразие предотвращало интеракцию между ладом и фактурой [3; 4]. Фразы отличались по степени модуляции, по ритму и проходящим нотам (для плавности модуляции). Выбор начальной тональности в каждом музыкальном стимуле был произвольным. В зависимости от степени модуляции, некоторые из фраз потребовали меньшее количество переходных аккордов, чем другие. Все модуляции были плавными и не содержали каких-либо неожиданных сопоставлений между аккордами. Каждая музыкальная фраза составляла по продолжительности 11 секунд и включала небольшое замедление в конце для более естественного звучания. Последний аккорд продолжался 3 с, чтобы подчеркнуть заключительную тональность.

Для анализа стимулы были сгруппированы по следующим критериям.

1. Ладовое условие модуляции:

- a. из мажора в мажор (М-М),
- b. из мажора в минор (М-м),
- c. из минора в мажор (м-М),
- d. из минора в минор (м-м).

2. Тональное расстояние:

I. Близкие модуляции:

- a) 0, 5, 7 ступень для модуляции из мажора в мажор и из минора в минор;
- b) 0, 2, 4, 5, 9 ступени для модуляции из мажора в минор;
- c) 0, 3, 7, 8 ступени для модуляции из минора в мажор

II. Дальние модуляции:

- d) 1, 2, 3, 6, 9, 10, 11 ступени для модуляции из мажора в мажор;
- e) 1, 6, 8, 10, 11 ступени для модуляции из мажора в минор;

- ф) 1, 2, 6, 9, 10, 11 ступени для модуляции из минора в мажор;
- г) 1, 3, 4, 6, 8, 9, 10, 11 ступени для модуляции из минора в минор.

Тональное расстояние определялось по количеству тонов, заменяемых в гамме начальной тональности во время перехода в заключительную тональность, и по взаимоотношениям начального и заключительного тонических трезвучий.

Запись электроэнцефалограммы осуществлялась при помощи электроэнцефалографа-анализатора ЭЭГА-21\26 «Энцефалан-131-03» (модификация 10) и комплекта ЭЭГ электродов КЭ-ЭЭГ-10\20 (тип 19-3) компании Медиком-МТД (Таганрог, Россия). Схема монтажа отведений – BaseMonopolar, использовались следующие параметры фильтрации исходного сигнала: верхняя полоса пропускания – 70 Гц, нижняя полоса пропускания – 0,5 Гц, режекция сетевой наводки на частоте – 50 Гц, частота дискретизации – 250 Гц. Регистрация ЭЭГ осуществлялась по семи отведениям (Т3,С3,Сz,С4,Т4,Р3,Рz,Р4), уровень подэлектродного сопротивления на момент начала записи составлял не более 10 кОм.

Для анализа ЭЭГ использовалось программное обеспечение «Энцефалан-ЭЭГА». Вычислялся спектр мощности для следующих частотных диапазонов: тета (4–8 Гц), альфа (8–12 Гц), бета1 (13–24 Гц) и бета2 (25–35 Гц). Для спектрального анализа использовались данные ЭЭГ за 10 с до предъявления аудиофрагмента, 10 с во время предъявления аудиофрагмента и 10 секунд после предъявления аудиофрагмента, для статистической обработки использовались абсолютные значения мощностей (мкВ^2 – площадь под соответствующим участком спектрограммы по выбранным частотным диапазонам) и относительные значения мощностей (% – отношение площади под соответствующим участком спектрограммы к суммарной площади по выбранным частотным диапазонам, умноженное на 100 %). Для абсолютных значений мощностей применялась процедура нормализации (z-шкала).

Схема эксперимента включала в себя следующие этапы:

1. Инструктаж испытуемого и выполнение тестового прослушивания стимула и заполнения анкеты;
2. Регистрация исходного фона ЭЭГ (продолжительность – 3 минуты);
3. Экспериментальная серия (испытуемому в случайном порядке предъявлялся набор из 48 стимулов, после каждого стимула предлагалось заполнить анкету семантического дифференциала);
4. Регистрация конечного фона ЭЭГ (продолжительность – 3 минуты).

Статистическая обработка велась при помощи программ Microsoft Excel 2010 и Statistica 10. Вычислялись t -критерии Стьюдента для зависимых и независимых выборок.

Результаты исследования

При сравнении относительных значений мощностей мажорных (ММ) и минорных (мм) ладовых условий с фоном до стимуляции и с фоном после стимуляции были получены следующие результаты (табл. 1).

Для мажорных ладовых условий (ММ) при прослушивании музыкальных фраз по сравнению с фоном до прослушивания отмечается более высокий уровень мощностей в альфа диапазоне и более низкий уровень в бета1 и бета2 диапазонах, по сравнению с фоном после прослушивания отмечается более низкий уровень мощностей в тета и бета2 диапазонах и более высокий в альфа и бета1 диапазонах частот.

Таблица 1

Относительные значения мощностей ритмов ЭЭГ для мажорных (ММ) и минорных (мм) ладовых условий до, во время и после прослушивания стимулов

Экспериментальный контекст	Ритмы ЭЭГ %							
	Мажорное ладовое условие				Минорное ладовое условие			
	Тета	Альфа	Бета1	Бета 2	Тета	Альфа	Бета1	Бета2
До прослушивания	19,9 ² ±11,7	44,3 ² ±21,4	23,7 ±11,1	11,9 ² ±9,7	19,7 ² ±11,8	45,1 ² ±21,9	23,4 ² ±11,6	11,6 ² ±9,3
Во время прослушивания	19,6 ² ±10,6	47,8 ^{1,2} ±21,8	21,7 ^{1,2} ±10,9	10,6 ^{1,2} ±9,1	20,4 ² ±11,2	46,2 ² ±22	22,1 ^{1,2} ±11,3	11,1 ² ±9,7
После прослушивания	36,6 ±10,7	23,4 ±9,0	23,7 ±6,8	16,1 ±9,3	36,1 ±10,6	23,7 ±8,6	24,2 ±6,9	15,8 ±8,4

Примечание. Цифрами обозначены достоверные отличия ($p < 0,05$ по критерию Стьюдента) в сравнении: 1 – с фоном до прослушивания; 2 – с фоном после прослушивания.

Сравнение фоновых записей до начала прослушивания с фоновыми записями после прослушивания стимулов с мажорным ладовым условием

показало более высокий уровень мощностей в альфа диапазоне и более низкий уровень мощностей в тета и бета2 диапазонах для фона до прослушивания стимула.

Для минорных ладовых условий (мм) при прослушивании музыкальных фраз по сравнению с фоном до прослушивания отмечается более низкий уровень мощностей бета1 диапазоне, по сравнению с фоном после прослушивания отмечается более низкий уровень мощностей в тета, бета1 и бета2 диапазонах и более высокий в альфа. Сравнение фоновых записей до начала прослушивания с фоновыми записями после прослушивания стимулов с минорным ладовым условием показало более высокий уровень мощностей в альфа диапазоне и более низкий уровень мощностей в тета, бета1 и бета2 диапазонах для фона до прослушивания стимула.




Рис. 1. Относительные значения мощностей для мажорных (ММ) и минорных (мм) ладовых условий при близких (а) и дальних (б) модуляциях. Звездочками обозначены достоверные различия ($p < 0,05$ по t -критерию Стьюдента)

При сравнении относительных значений мощностей для стимулов с мажорными (ММ) и минорными (мм) ладовыми условиями при близких и дальних модуляциях были выявлены следующие отличия. Для близких модуляций был выявлен достоверно более высокий уровень мощности в альфа диапазоне и достоверно более низкий уровень мощности в бета2 диапазоне для стимулов с минорными ладовыми условиями (рис. 1, а). Для стимулов с дальними модуляциями был отмечен достоверно более высокий уровень тета активности и достоверно более низкий уровень альфа активности для стимулов с минорными ладовыми условиями (рис. 1, б).

Был проведен анализ изменений общей мощности в зависимости от ступени модуляции для стимулов с однородными ладовыми условиями мажор-мажор и минор-минор (табл. 2).

Таблица 2

Нормализованные значения мощностей ЭЭГ в височных, центральных и теменных отведениях (z-шкала) для мажорных (ММ) и минорных (мм) ладовых условий в зависимости от ступеней модуляции

№ ступени	Мощности ЭЭГ (z-шкала)					
	ММ			мм		
	Тем.	Цен.	Вис.	Тем.	Цен.	Вис.
0	0,56±0,16	0,18±0,16	-0,74±0,16	0,55±0,17	0,30±0,17*	-0,85±0,17
1	0,60±0,14	0,27±0,14	-0,87±0,14	0,51±0,17	0,36±0,17	-0,87±0,17
2	0,70±0,13	0,30±0,13	-1,00±0,13	0,63±0,15	0,28±0,15	-0,91±0,15
3	0,53±0,17*	0,24±0,17	-0,77±0,17*	0,62±0,17	0,29±0,17	-0,91±0,17
4	0,53±0,17	0,28±0,17	-0,82±0,17	0,61±0,14*	0,28±0,14	-0,89±0,14*
5	0,60±0,16	0,26±0,16	-0,87±0,16	0,62±0,17	0,17±0,17	-0,79±0,17
6	0,66±0,15	0,25±0,15*	-0,91±0,15	0,56±0,14	0,36±0,14	-0,93±0,14
7	0,60±0,15*	0,27±0,15	-0,87±0,15	0,66±0,15	0,20±0,15*	-0,87±0,15
8	0,56±0,17	0,30±0,17	-0,86±0,17	0,51±0,17	0,36±0,17	-0,87±0,17
9	0,71±0,14	0,25±0,14	-0,96±0,14	0,53±0,17	0,24±0,17	-0,77±0,17
10	0,67±0,13*	0,27±0,13	-0,94±0,13*	0,61±0,17	0,25±0,17	-0,85±0,17
11	0,58±0,16	0,26±0,16	-0,83±0,16*	0,56±0,19	0,23±0,19	-0,79±0,19

*Достоверно различающиеся уровни мощностей ($p < 0,05$ по t -критерию Стьюдента).

Достоверно больший уровень мощности для минорного ладового условия был выявлен для 1 ступени модуляции в центральных и височных

отведениях, для 4 ступени модуляции в теменных и височных отведениях и для 7 ступени в центральных отведениях. Достоверно больший уровень мощности для мажорного ладового условия был обнаружен для 3 ступени в теменных и височных отведениях, для 6 ступени в центральном отведении, для 7 ступени в теменных отведениях, для 10 ступени в теменных и височных отведениях и для 11 ступени в височных отведениях. При других ступенях влияние ладового условия на пространственное распределение активности не наблюдалось.

Заключение

Прослушивание музыкальных фрагментов с мажорными ладовыми условиями (ММ) вызывает повышение мощности в альфа диапазоне и снижение мощностей в бета1 и бета2 диапазонах. Прослушивание музыкальных фрагментов с минорными ладовыми условиями (мм) вызывает снижением мощности в бета1 диапазоне. Это может говорить о повышении синхронизации корковых структур в ответ на прослушивание музыкальных фрагментов, что свидетельствует о снижении уровня напряжения и служит подтверждением полезного эффекта прослушивания музыки.

Изменения общей мощности спектра ЭЭГ во время прослушивания стимулов с мажорными (ММ) и минорными (мм) ладовыми условиями в наибольшей степени проявляются в височных зонах, а в наименьшей – в центральных. Мощность спектра ЭЭГ в височных зонах при минорной модуляции значительно ниже, чем при мажорной для 1 и 4 ступеней модуляции. Для 3, 10 и 11 ступеней наблюдается обратная ситуация: мажорные стимулы вызывают в височной зоне большую активацию. Изменения для 3 и 4 ступеней могут быть связаны с тем, что особенностью данных ступеней модуляции является присутствие характерных для противоположных тональностей переходных аккордов и последующий возврат в начальную тональность. Изменения для ступеней 1 и 11 могут быть связаны с характерным для них движением мелодического контура в обеих модуляциях (на полтона вверх для 1 ступени и на полтона вниз для 11 ступени). Изменения для 10 ступени могут быть связаны с понижением основного тона, которое характерно для данной ступени.

Были выявлены различия мажорных и минорных ладовых условий в зависимости от расстояния модуляции. Показано, что при близких модуляциях характерен больший уровень мощности в альфа диапазоне и меньший уровень мощности в бета2 диапазоне для фрагментов с минорными ладовыми условиями (мм). При дальних модуляциях для фрагментов с мажорными ладовыми условиями характерен более высокий уровень

мощности в альфа диапазоне и более низкий уровень мощности в тета диапазоне. Это может свидетельствовать о том, что при близком расстоянии модуляции минорные ладовые условия в большей степени способствуют синхронизации корковых структур и снижению уровня напряжения; в то время как при дальних модуляциях подобный эффект можно наблюдать уже для мажорных ладовых условий. Этот факт может быть крайне полезен для дальнейшего изучения эффектов от прослушивания музыки и для ее использования в средствах коррекции функциональных состояний организма. Дальнейшие исследования будут направлены на проверку этого эффекта в контексте прослушивания подготовленных музыкальных фрагментов со схожим набором параметров и отрывков из реальных музыкальных произведений.

Список литературы

1. Федотчев, А.И., Радченко, Г.С. Музыкальная терапия и "музыка мозга": состояние, проблемы и перспективы исследований // Успехи физиологических наук, 2013. Т. 44. № 4. С. 34-50.
2. Korsakova-Kreyn, M.N.; Dowling, W.J. Emotional processing in music: Study in affective responses to tonal modulation in controlled harmonic progressions and real music. // Psychomusicology: Music, Mind and Brain, Mar 2014. V. 24(1). P. 4-20.
3. Kastner, M.P., Crowder, R.G. Perception of the Major/Minor Distinction: IV. Emotional Connotations in Young Children// Music Perception: An Interdisciplinary Journal, Winter 1990. V. 8. No. 2. P. 189-201.
4. Webster, G.D., Weir, C.G. Emotional responses to music: Interactive effects of mode, texture, and tempo. // Motivation and Emotion, 2005. V. 29(1). P. 19-39.

С.В. БОЖОКИН, И.Б. СУСЛОВА

Санкт-Петербургский государственный политехнический университет
bsvjob@mail.ru, ibsus@mail.ru

НЕСТАЦИОНАРНАЯ КОРРЕЛЯЦИЯ АНСАМБЛЯ ВСПЫШЕК ЭЭГ: ВЕЙВЛЕТ-АНАЛИЗ

Построены модели вспышек активности ЭЭГ в виде суперпозиции элементарных нестационарных сигналов. С помощью непрерывного вейвлет-преобразования и спектральных интегралов рассчитаны новые количественные параметры, характеризующие изменение во времени спектральных свойств каждой отдельной вспышки мозговой активности и ансамбля вспышек. Решена задача о нестационарной корреляции различных

каналов ЭЭГ. Обсуждается применение методики для анализа нестационарной ЭЭГ во время функциональных проб.

Ключевые слова: классификация всплесков активности мозга, динамика корреляции различных каналов ЭЭГ.

S.V. BOZHOKIN, I.B. SUSLOVA

Saint-Petersburg State Polytechnic University

bsvjob@mail.ru, ibsus@mail.ru

NON-STATIONARY CORRELATION OF EEG BURSTS ENSEMBLE: WAVELET ANALYSIS

We modeled EEG activity bursts as a superposition of elementary non-stationary signals. Using the technique of continuous wavelet transform and spectral integrals analysis, we calculated a set of new quantitative parameters characterizing the time variation of spectral properties for each brain activity burst and for the ensemble of bursts. The problem of non-stationary correlation of different EEG channels has been solved. The application of the approach for the analysis of non-stationary EEG during functional tests has been discussed.

Keywords: *classification of brain activity bursts, dynamics of different EEG channels correlation.*

Введение

Сигнал электроэнцефалограммы (ЭЭГ), представляющий собой электрическую активность огромного количества нейронов, часто характеризуется изменениями уровня фоновой активности в различных частотных диапазонах $\mu = \{\delta, \theta, \alpha, \beta, \gamma\}$, где δ – ритм (0,5–4 Hz), θ – ритм (4–7,5 Hz), α – ритм (7,5–14 Hz), β – ритм (14–30 Hz), γ – ритм (30–80 Hz) [1-3]. Всплески ЭЭГ, проявляющиеся в появлении и исчезновении паттернов активности в различных отведениях головного мозга, часто связывают с полиморфной, очаговой или диффузной активностью мозга. Паттерны активности ЭЭГ могут быть выражены как отдельными спайками, острыми волнами, так и различными их сочетаниями (комплекс спайк-волна, острая волна-медленная волна, пик-волновые разряды (spike wave discharge, SWD), K-комплекс и т.д.). Большое внимание исследователей приковано к индивидуальным особенностям осцилляторных паттернов альфа ритмов

ЭЭГ [4]. Основной чертой альфа-активности является ее веретенообразность (SS – sleep spindle), отражающая динамику организации активности нейронных ансамблей [5]. Считается, что паттерны ЭЭГ связаны с состояниями человека (сон, бодрствование, неврологические патологии), с действием нейротропных лекарственных препаратов, а также с когнитивными процессами.

Значительный вклад в изучение ЭЭГ был сделан методом сегментного анализа [6], однако гипотеза квазистационарности исключает из рассмотрения существенные подробности процесса перестройки ритмов. Быстрое (оконное) преобразование Фурье, с помощью которых вычисляется когерентность [7], характеризующая синхронизацию различных каналов ЭЭГ, также имеет ряд существенных ограничений, связанных с подбором окна. Методы нелинейной динамики [8] дают скорее качественную оценку сложности нестационарного процесса. Одним из наиболее эффективных инструментов изучения нестационарной ЭЭГ является непрерывное вейвлет-преобразование (CWT) [9-10].

Цель настоящей работы состоит в нахождении количественных параметров, описывающих динамику возникновения и исчезновения всплесков активности различных каналов ЭЭГ, возникающих в спектральных диапазонах $\mu = \{\delta, \theta, \alpha, \beta, \gamma\}$. Математические модели ЭЭГ, разработанные авторами в работе [11], и анализируемые с помощью CWT, будут применены к реальным сигналам ЭЭГ. Вычисленные количественные параметры, описывающие амплитудно-частотных характеристики каждой вспышки, а также всего ансамбля всплесков, позволят определить динамику развития во времени корреляций различных каналов ЭЭГ.

Математическая модель вспышечной активности ЭЭГ

Рассмотрим сигнал ЭЭГ $Z_A(t)$ (рис. 1), зависящий от времени t , в состоянии покоя для центрального затылочного отведения головного мозга O_z , который характеризуется веретенообразным альфа ритмом.

Представим сигнал $Z_B(t)$, описывающий модель вспышечной активности ЭЭГ, в виде суммы N_F простейших нестационарных сигналов

$$Z_B(t) = \sum_{L=0}^{N_F-1} z_L(t - t_L). \quad (1)$$

Каждый сигнал $z_L(t - t_L)$, где $L = 0, 1, 2, \dots, N_F - 1$, центрирован в точке $t = t_L$ и представляет собой произведение гауссовой огибающей на осциллирующую функцию [11]

$$z_L(t-t_L) = \frac{b_L}{2\tau_L\sqrt{\pi}} \exp\left(-\frac{(t-t_L)^2}{4\tau_L^2}\right) \cos(2\pi f_L(t-t_L) + \alpha_L). \quad (2)$$




Рис. 1. Сигнал ЭЭГ $Z_A(t)$ (в μV) в зависимости от времени t (в s)

В качестве примера сигнала $Z_B(t)$, состоящего из $N_F = 5$ элементарных всплесков, рассмотрим следующие ненулевые значения параметров: отдельный спайк ($t_0 = 2,5 \text{ s}$, $b_0 = 3,2\sqrt{\pi}$, $\tau_0 = 0,02 \text{ s}$); комплекс спайк ($t_1 = 4,25 \text{ s}$, $b_1 = 3,0\sqrt{\pi}$, $\tau_1 = 0,02 \text{ s}$) и медленная волна д-ритма с частотой $f_2 = 2 \text{ Hz}$, (центр волны находится при $t_2 = 4,25 \text{ s}$, $b_2 = 30\sqrt{\pi}$, $\tau_2 = 0,25 \text{ s}$); два спайка разной полярности ($t_3 = 7,4 \text{ s}$, $b_3 = 2,8\sqrt{\pi}$, $\tau_3 = 0,02 \text{ s}$) и ($t_4 = 7,6 \text{ s}$, $b_4 = -2,8\sqrt{\pi}$, $\tau_4 = 0,02 \text{ s}$).




Рис. 2. Суммарный сигнал $Z_C(t) = Z_A(t) + Z_B(t)$ в зависимости от времени t, s

Рассмотрим теперь суммарный сигнал ЭЭГ $Z_c(t) = Z_A(t) + Z_B(t)$ (рис. 2), представляющий собой сумму сигнала ЭЭГ покоя $Z_A(t)$ (см. рис. 1) и модельного сигнала вспыхечной активности $Z_B(t)$.

Непрерывное вейвлет-преобразование (CWT)

Непрерывное вейвлет-преобразование (CWT) $V(v, t)$ произвольного сигнала ЭЭГ $Z(t)$, явный вид материнского вейвлета Морле, а также спектральные интегралы $E_\mu(t)$ в различных частотных диапазонах μ приведены в работах [11-15]. Вспышкой ЭЭГ активности в μ диапазоне частот, где $\mu = \{\delta, \theta, \alpha, \beta, \gamma\}$, назовем появление и исчезновение группы волн, отличных от фоновой активности ЭЭГ по частоте, форме и амплитуде. Для каждой вспышки существует время начала вспышки t_B и время ее окончания t_E . Продолжительность вспышки $[t_B, t_E]$ автоматически определяется из условия того, что значение спектрального интеграла $E_\mu(t)$ превосходит 5 % от максимального значения $E_{\max}$, вычисленного для всех времен наблюдения ЭЭГ в диапазоне частот μ . Для каждого момента времени t , удовлетворяющего условию $t_B < t < t_E$, определяется локальная частота $F_\mu(t)$, которая для диапазона частот μ соответствует максимальному значению $|V(v, t)|^2$.

Рассмотрим ЭЭГ активность в диапазоне альфа ритма $\mu = \alpha$, где диапазон $\alpha = [7, 5; 14 \text{ Hz}]$, и введем систему количественных параметров, описывающих основные характеристики таких вспышек. Устанавливая уровень отсечки в 5%, мы видим, что весь интервал наблюдения спектрального интеграла $E_\alpha(t)$ по времени t разбивается на отдельные вспышки с номером $J = 0, 1, 2, 3, \dots, N_F - 1$, где N_F – суммарное количество вспышек в исследуемом сигнале. Каждая вспышка характеризуется своей продолжительностью $\tau(J) = t_E(J) - t_B(J)$ и положением центра вспышки $t_c(J) = t_B(J) + [t_E(J) - t_B(J)] / 2$. Усредняя величину $F_\mu(t)$ по промежутку времени J -вспышки, получаем среднее значение локальной частоты J -вспышки – $F_\mu(J)$. Стандартным способом вычисляется среднеквадратичное отклонение частоты вспышки $\Delta F(J)$, характеризующее разброс значений частоты $F_\mu(t)$ относительно среднего значения $F_\mu(J)$. Массив вычисленных значений $\tau(J)$, $F_\mu(J)$ и $t_c(J)$ описывает изменения параметров вспышек во время всей записи ЭЭГ. Для ансамбля вспышек, суще-

ствующих на всем интервале измерения сигнала ЭЭГ, можно вычислить: среднюю продолжительность вспышки $\langle \tau \rangle$, среднюю частоту вспышек $\langle F \rangle$, среднеквадратичное отклонение времени вспышек $\langle \Delta \tau \rangle$, среднеквадратичное отклонение частоты $\langle \Delta F \rangle$, относительную продолжительность всех вспышек PF (Part of Flash) по отношению ко всему интервалу наблюдения T .

Расчет параметров вспышек ЭЭГ

Выполним с помощью CWT количественный анализ веретенообразной активности сигнала $Z_A(t)$ (см. рис. 1). Для такого сигнала на рис. 3 построен график $|V(v, t)|^2$ в зависимости от частоты v , Hz, и от времени t , s. Анализ этого графика показывает наличие нескольких вспышек, частоты которых расположены в диапазоне альфа ритма $\alpha = [7,5-14 \text{ Hz}]$.




Рис. 3. Величина $|V(v, t)|^2$ в зависимости от частоты v , Hz, и от времени t , s, для сигнала $Z_A(t)$ (см. рис. 1)

Поведение нормированного на максимум спектрального интеграла $E_\alpha(t)/E_{\alpha\max}$ (рис. 4) позволяет вычислять характерные времена возникновения и исчезновения частот в диапазоне альфа ритма.

Поведение локальной частоты вспышки $F_\alpha(t)$ приведено на рис. 5, причем границы вспышек ($N_F = 8$) отмечены нулевыми значениями $F_\alpha(t)$.




Рис. 4. Зависимость $E_{\alpha}(t) / E_{\alpha \max}$ от времени t, s , для сигнала $Z_A(t)$




Рис. 5. Зависимость локальной частоты $F_{\alpha}(t)$, Hz, в зависимости от времени t, s , для сигнала ЭЭГ покоя $Z_A(t)$ (см. рис. 1)

Вычисленные параметры индивидуальных всплесков сигнала $Z_A(t)$ ($N_F = 8$) позволяют определить статистические характеристики всего ансамбля всплесков сигнала $Z_A(t)$: $\langle \tau \rangle = 0,83 s$, $\langle \Delta \tau \rangle = 0,66 s$, $\langle F \rangle = 10,38 \text{ Hz}$, $\langle \Delta F \rangle = 3,77 \text{ Hz}$, $PF = 0,7$. Все приведенные расчеты количественных параметров, как для индивидуальных всплесков, так и для ансамбля всплесков, могут быть выполнены для всех сигналов ЭЭГ $Z_B(t)$ и $Z_C(t)$ в различных спектральных диапазонах $\mu = \{\delta, \theta, \alpha, \beta\}$.

Рассмотрим поведение нормированного спектрального интеграла $E_{\alpha}(t) / E_{\alpha \max}$ для суммарного сигнала $Z_C(t) = Z_A(t) + Z_B(t)$ (рис. 6).




Рис. 6. Зависимость $E_{\alpha}(t) / E_{\alpha \max}$ для суммарного сигнала $Z_C(t)$

Зависимость от времени спектрального интеграла на рис. 6 для суммарного сигнала $Z_C(t)$ отличается от аналогичного графика на рис. 4 для $Z_A(t)$ в окрестностях моментов времени t_0 , t_1 , t_3 и t_4 , где были искусственно помещены спайки малой продолжительности. Дельта волна с частотой $f_2 = 2$ Hz, центрированная в точке $t_2 = 4,75$ s, не влияет на спектральный интеграл $E_{\alpha}(t)$ суммарного сигнала $Z_C(t)$ в диапазоне α -ритма.

Динамика корреляций всплеск

Известно, что различные отделы коры головного мозга могут демонстрировать синхронную активность как в норме (во время когнитивной деятельности), так и при различных патологиях (болезнь Паркинсона, эпилептические припадки). Большинство методов, применяемых для вычисления такой статической корреляции, используют длительный интервал времени, примерно равный нескольким секундам [7]. Динамика возникновения и распада нейронных ансамблей требует разработки метода динамической корреляции, зависящей от текущего времени. В качестве исследуемого спектрального диапазона μ рассмотрим α -ритм, а в качестве двух каналов с номерами i и j рассмотрим, соответственно, сигналы $i = Z_A(t)$ и $j = Z_C(t)$. Спектральный интеграл в диапазоне α - ритма для i канала мы обозначим $E_{\alpha}(i, t)$, а для j канала этот спектральный интеграл

равен $E_\alpha(j, t)$. Динамика возникновения и затухания корреляций во времени для нестационарных сигналов i и j каналов в диапазоне α -ритма, может быть подсчитана с помощью коэффициента корреляции Пирсона

$$R_{ij}(\alpha, t) = \frac{\langle E_\alpha(i, t)E_\alpha(j, t) \rangle - \langle E_\alpha(i, t) \rangle \langle E_\alpha(j, t) \rangle}{\sqrt{[\langle E_\alpha^2(i, t) \rangle - \langle E_\alpha(i, t) \rangle^2][\langle E_\alpha^2(j, t) \rangle - \langle E_\alpha(j, t) \rangle^2]}}. \quad (3)$$

Для усреднений по времени $\langle \dots \rangle$ в формуле (3) используется окно, центр которого соответствует моменту времени t . Ширина окна T_α , определяется исходя из соотношения $T_\alpha = n / F_\alpha(\text{min})$, где безразмерный параметр $n = 6$ определяет ширину окна, а $F_\alpha(\text{min}) = 7,5 \text{ Hz}$.




Рис. 7. Зависимость величины $R_{ij}(\alpha, t)$ от времени t, s для спектральных интегралов $E_\alpha(i, t)$ и $E_\alpha(j, t)$ каналов $i = Z_A(t)$ и $j = Z_C(t)$

На начальном участке записи $t < 2 \text{ s}$ коэффициент корреляции равен $R_{ij}(\alpha, t) = 1$. Это является следствием того, что на этом участке каналы i и j полностью тождественны и спектральные интегралы $E_\alpha(i, t)$ и $E_\alpha(j, t)$ одинаковы. В момент времени $t_0 = 2,5 \text{ s}$ на записи j существует единичный спайк активности ЭЭГ. Это приводит к тому, что в канале j в этот момент времени существует максимум спектрального интеграла $E_\alpha(j, t)$, отличающийся от подобного максимума для канала $E_\alpha(i, t)$. Следова-

тельно, в окрестности момента времени $t_0 = 2,5$ s коэффициент корреляции $R_{ij}(\alpha, t)$ уменьшается. Подобное рассогласование каналов, приводящее к уменьшению $R_{ij}(\alpha, t)$, наблюдается также в окрестности момента времени $t_1 = 4,25$ s. В этот момент времени на записи канала j существует одиночный пик и последующая волна тета-активности. Аналогично, в окрестности моментов времени $t_3 = 7,4$ s и $t_4 = 7,6$ s, где на записи j существуют два кратковременных спайка разной полярности, также происходит уменьшение $R_{ij}(\alpha, t)$.

Выводы

Нестационарный сигнал ЭЭГ фиксированного отведения головного мозга представляется в виде последовательности всплесков в спектральных диапазонах $\mu = \{\delta, \theta, \alpha, \beta, \gamma\}$. Методика использует непрерывное вейвлетное преобразование $V(v, t)$, которое позволяет точно определять изменение спектрального состава сигнала ЭЭГ во времени и применять технику спектральных интегралов $E_\mu(t)$. Для каждой всплески реализована процедура автоматического вычисления: локальной частоты $F_\mu(t)$, момента времени начала всплески $t_B(J)$ и ее конца $t_E(J)$, продолжительности всплески $\tau(J)$, центра локализации всплески $t_C(J)$ и средней частоты всплески $F_\mu(J)$. Вычислены статистические характеристики всего ансамбля всплесков.

Получен коэффициент корреляции Пирсона $R_{ij}(\mu, t)$, зависящий от времени и показывающий процессы согласования и рассогласования сигналов ЭЭГ в диапазоне μ ритма для различных отведений i и j головного мозга. Введенные количественные параметры всплесков активности ЭЭГ и их корреляций позволяют провести классификацию как нормальных, так и аномальных паттернов ЭЭГ. Данный метод можно использовать для выявления индивидуальной вариативности ЭЭГ активности; для исследования синхронных состояний различных отделов головного мозга и когерентной активности, связанной как с когнитивными процессами, так и с различными неврологическими заболеваниями. Предлагаемый метод можно применить во время функциональных проб (фотостимуляция, гипервентиляция, психоэмоциональные пробы), чтобы диагностировать появление и исчезновение различных частот в сигнале ЭЭГ. Модель всплесочной активности может использоваться для тестирования качества процессов обучения нейронных сетей.

Работа выполнена при финансовой поддержке РФФИ (15-02-04675) и Государственного задания № 3.1446.2014/К.

Список литературы

1. Гнездицкий В.В. Обратная задача ЭЭГ и клиническая электроэнцефалография. М.: МЕДпресс-информ. 2004.
2. Зенков Л.Р. Клиническая электроэнцефалография с элементами эпилептологии. М.: МЕДПрессинформ, 2012.
3. Кропотов Ю.Д. Количественная ЭЭГ, когнитивные вызванные потенциалы мозга человека и нейротерапия. Донецк, 2010.
4. Bazanova O. Comments for Current Interpretation EEG Alpha Activity// Journal of Behavioral and Brain Science 2012. V. 2. P. 239-248.
5. Sitnikova E. Thalamo-cortical mechanisms of sleep spindles and spike-wave discharges in rat model of absence epilepsy (a review) // Epilepsy Res. 2010. V. 89(1). P. 17-26.
6. Fingelkurts A.I.A., Fingelkurts A.N., Krause C.M., Kaplan A.Y. Systematic rules underlining spectral pattern variability: experimental results and a review of the evidence// Int. J. Neuroscience, 2003. V. 113 (10). P 1447-1473.
7. Kulaichev A.P., The informativeness of coherence analysis in EEG studies// Neuroscience and behavioral physiology, 2011. V. 41(3). P. 321-328.
8. Martis R.J., Acharya U.R., Tan J.H., Petznick A., Tong L., Chua C.K., Ng E.Y.K., Application of intrinsic time scale decomposition (ITD) to EEG signals for automated seizure prediction// Int. J. Neur. Syst., 2013. V. 23. P. 1350023.
9. Короновский А.А., Макаров В.А., Павлов А.Н., Ситникова Е.Ю., Храмов А.Е. Вейвлет в нейродинамике и нейрофизиологии. М.: Физматлит. 2013.
10. Rosso O.A., Martin M.T., Plastino A., Evidence of self-organization in brain electrical activity using wavelet-based informational tools// Physica A. 2005. V. 347. P. 444-464.
11. Божокин С.В., Сулова И.Б., Вейвлет-анализ математической модели всплеск электроэнцефалограммы мозга// Нейроинформатика-2014. XVI – Всероссийская научно-техническая конференция. М.: НИЯУ МИФИ, 2014. Ч.2. С.51-66.
12. Божокин С.В., Суворов Н.Б. Вейвлет-анализ переходных процессов электроэнцефалограммы при фотостимуляции // Биомедицинская радиоэлектроника, 2008. № 3. С. 21-25.
13. Божокин С.В., Вейвлет анализ динамики усвоения и забывания ритмов фотостимуляции для нестационарной электроэнцефалограммы // Журнал технической физики, 2010. Т. 80(9). С. 16-24.
14. Суворов Н.Б., Божокин С.В., Полонский Ю.З., Электрофизиологические корреляты умственной деятельности человека. Вейвлет–анализ // Информационно-управляющие системы. 2012. № 3. С. 71-76.
15. Bozhokin S.V., Suslova I.B., Wavelet Analysis of Non-Stationary Signals in Medical Cyber-Physical Systems (MCPS) // Lecture Notes of Computer Science. LNCS. 2014. V. 8638. P. 467-480.

**А.Г. ТРОФИМОВ¹, И.В. КОЛОДКИН¹, В.Л. УШАКОВ²,
Б.М. ВЕЛИЧКОВСКИЙ²**

¹Национальный исследовательский ядерный университет «МИФИ», Москва

²Национальный исследовательский центр «Курчатовский институт», Москва
atrofimov@list.ru

АГЛОМЕРАТИВНЫЙ МЕТОД ВЫДЕЛЕНИЯ МИКРОСОСТОЯНИЙ ЭЭГ, СВЯЗАННЫХ С ХАРАКТЕРИСТИКАМИ БЕГУЩИХ ВОЛН*

Предложен метод выделения микросостояний головного мозга по данным электроэнцефалографии (ЭЭГ) на основе характеристик бегущих волн. Для оценки степени выраженности бегущих волн введены показатели синхронности и когерентности. В результате экспериментальных исследований на реальных данных ЭЭГ показано, что предложенный метод не уступает по качеству традиционным методам сегментации ЭЭГ и отражает новую сегментационную структуру ЭЭГ.

Ключевые слова: *бегущая волна, сегментация, фазовая синхронность, когерентность, микросостояния ЭЭГ, агломеративная кластеризация.*

**A.G. TROFIMOV¹, I.V. KOLODKIN¹, V.L. USHAKOV²,
B.M. VELICHKOVSKI²**

¹National Research Nuclear University (MEPhI), Moscow

²National Research Centre "Kurchatov Institute", Moscow
atrofimov@list.ru

AGGLOMERATIVE METHOD FOR ISOLATING MICROSTATES EEG RELATED TO THE CHARACTERISTICS OF THE TRAVELING WAVE

We propose a method for the isolation of microstates of the brain according to electroencephalography (EEG) based on the characteristics of traveling waves. To assess the severity of the traveling waves introduced indicators syn-

* Исследование выполнено за счет гранта Российского научного фонда (проект № 14-28-00234).

chrony and coherence. Experimental studies on real EEG data show that the proposed method is highly competitive with traditional methods of segmenting EEG and reflects the new structure of the EEG segmentation.

Keywords: *travelling-wave, segmentation, phase-locking, coherence, eeg microstates, electroencephalogram, agglomerative clustering.*

Введение

Сигнал ЭЭГ, записанный как в состоянии покоя, так и при когнитивных нагрузках испытуемого, является принципиально нестационарным [1]. Задача описания сигнала ЭЭГ как последовательности сменяющих друг друга квазистационарных участков, обладающих схожими характеристиками (сегментов), является одной из ключевых задач при обработке ЭЭГ [2].

Сигнал ЭЭГ представляет собой многомерный временной ряд, имеющий пространственно-временную структуру, т.е. временной ряд, характеризующийся в каждый момент времени вектором наблюдений, каждое из которых соответствует некоторой точке пространства (расположению электрода). В настоящей работе предложено проводить выделение микросостояний (сегментацию) такого ряда на основе характеристик, учитывающих его распределённую природу.

Выделенные микросостояния не только позволяют представить сигнал ЭЭГ в более компактной форме, но и лучше понять его природу. Анализ характеристик микросостояний, их продолжительностей, последовательностей смены одних микросостояний другими может предоставить исследователю важную информацию и служить основой для решения других задач обработки ЭЭГ, в частности, классификации, моделирования и совместного анализа ЭЭГ и фМРТ.

Выделение сегментов ЭЭГ, как правило, предполагает следующую последовательность действий [3].

- 1) предобработка исходных сигналов;
- 2) построение пространства признаков для сегментации;
- 3) поиск кластеров в выделенном пространстве признаков.

В настоящей работе предложен подход к выделению характеристик сигналов, основанный на анализе бегущих волн [4].

Бегущая волна – это волновое движение, при котором поверхность равных фаз (фазовые волновые фронты) перемещается с конечной скоростью, постоянной в случае однородных сред [4].

Постановка задачи

Рассматривается многомерный сигнал ЭЭГ $X = (x(1), \dots, x(T))$, характеризующийся в каждый момент времени t вектором наблюдений $x(t) = (x_1(t), \dots, x_L(t))$, $t = \overline{1, T}$, где T – число временных отсчётов, L – число каналов электроэнцефалографа. Каждому наблюдению $x_i(t)$ соответствуют координаты $P_i = (\xi_i, \eta_i)$, $i = \overline{1, L}$, электрода в проекции на некоторую плоскость. Ряд X получен в результате дискретизации непрерывного сигнала ЭЭГ с постоянной частотой дискретизации f_s .

Ставится задача выделения микросостояний $S_1, \dots, S_K$ временного ряда X и отнесения вектора наблюдений $x(t)$ в каждый момент времени t , $t = \overline{1, T}$, одному из выделенных микросостояний. Микросостоянием будем считать область в некотором пространстве признаков, характеризующих временной ряд X в каждый момент времени t , $t = \overline{1, T}$. Формально задача выделения микросостояний $S_1, \dots, S_K$ – это задача нахождения оператора F , сопоставляющего временному ряду X в каждый момент времени t номер $k(t)$ микросостояния:

$$k(t) = F[X, t], \quad t = \overline{1, T}, \quad k(t) \in \{1, \dots, K\},$$

где K – число микросостояний. Отметим, что число микросостояний временного ряда, как правило, априорно неизвестно.

Введённое понятие микросостояния требует определения пространства признаков, в котором будут выделяться эти микросостояния.

Обозначим через ϕ оператор, сопоставляющий временному ряду X в каждый момент времени t некоторый вектор характерных признаков $y(t) = (y_1(t), \dots, y_M(t))$:

$$y(t) = \phi[X, t], \quad t = \overline{1, T}, \quad y(t) \in \mathbb{R}^M.$$

В частном случае значение оператора ϕ в момент времени t может зависеть не от всего временного ряда X , а от его фрагмента во временном окне с центром в t и шириной τ :

$$y(t) = \phi[x(t-\tau), \dots, x(t+\tau)], \quad t = \overline{\tau+1, T-\tau}, \quad y(t) \in \mathbb{R}^M. \quad (1)$$

В настоящей работе предлагается каждое микросостояние S_i представить как элемент иерархической структуры и охарактеризовать соответствующим эталоном $w_i = (w_{1i}, \dots, w_{Mi})$ в пространстве характерных признаков y , $i = \overline{1, K}$. Таким образом, задача выделения микросостояний состоит

в определении их эталонных представителей для разного числа микросостояний и формировании иерархической структуры. Как только эталонные представители $w_1, \dots, w_K$ найдены, принадлежность вектора значений временного ряда X тому или иному микросостоянию в момент времени t может быть определена по критерию близости соответствующего вектора характерных признаков $y(t)$ к эталонному представителю микросостояния:

$$x(t) \in \Omega_k \Leftrightarrow \rho(y(t), w_k) = \min_{i=1, K} \rho(y(t), w_i), \quad t = \overline{1, T}, \quad (2)$$

где $\rho(x, y)$ – расстояние (в частности, евклидово) между векторами x и y .

Характеристики бегущей волны

Предположим, что от точки P_i в направлении точки P_j распространяется монохроматическая бегущая волна частоты ω . Выберем точку P_i в качестве начала координат, а ось координат зададим в направлении точки P_j . Тогда возмущения среды $z_i(t)$ и $z_j(t)$ в точках P_i и P_j соответственно, создаваемые рассматриваемой бегущей волной в момент времени t , будут описываться выражениями:

$$z_i(t) = z(0, t) = A_i(\omega, t) \sin(-\omega t + \varphi_0),$$

$$z_j(t) = z(r_{ij}, t) = A_j(\omega, t) \sin(kr_{ij} - \omega t + \varphi_0),$$

где $r_{ij} = \rho(P_i, P_j)$ – расстояние между точками P_i и P_j , $A_i(\omega, t)$ и $A_j(\omega, t)$ – амплитуды волны частоты ω в точках P_i и P_j соответственно.

Для однородной стационарной среды волновое число k не зависит ни от времени, ни от пространственной координаты. Разность фазы $\Delta\varphi_{ij}$ волны в один и тот же момент времени в точках P_i и P_j постоянна и равна:

$$\Delta\varphi_{ij} = kr_{ij}. \quad (3)$$

Условие (3) является необходимым, но не достаточным условием наличия бегущей монохроматической волны между точками P_i и P_j , поскольку постоянство разности фаз между точками P_i и P_j может наблюдаться и при распространении двух независимых бегущих волн, проходящих через эти точки в различных направлениях.

Для проверки необходимого условия наличия бегущей волны частоты ω используем статистические характеристики выборки разностей фаз в каждый момент времени $t \in [t_1; t_2]$, рассмотренные в [3].

1. Показатель синхронности:

$$\gamma_{ij}(\omega, t_1, t_2) = \frac{1}{t_2 - t_1 + 1} \sqrt{\left(\sum_{t=t_1}^{t_2} \cos \Delta\varphi_{ij}(\omega, t) \right)^2 + \left(\sum_{t=t_1}^{t_2} \sin \Delta\varphi_{ij}(\omega, t) \right)^2}. \quad (4)$$

Возможные значения показателя (4) лежат в отрезке от 0 до 1.

Показатель (4) характеризует только степень разброса разностей фаз $\Delta\varphi_{ij}(\omega, t_1), \dots, \Delta\varphi_{ij}(\omega, t_2)$ волны на частоте ω (*phase-locking value*), оцениваемых с помощью преобразования Фурье, в точках P_i и P_j , при этом никак не учитывает амплитуды волны $A_i(\omega, t)$ и $A_j(\omega, t)$, $t = t_1, t_2$. Синхронность амплитуд $A_i(\omega, t)$ и $A_j(\omega, t)$ не является необходимым условием наличия бегущей волны между точками P_i и P_j , однако может говорить о согласованности изменения энергии волны в этих точках.

2. Показатель когерентности:

$$\Gamma_{ij}(\omega, t_1, t_2) = \frac{\left| \left\langle X_i(\omega) X_j^*(\omega) \right\rangle_{t=t_1}^{t_2} \right|}{\sqrt{\left\langle X_i(\omega) X_i^*(\omega) \right\rangle_{t=t_1}^{t_2} \left\langle X_j(\omega) X_j^*(\omega) \right\rangle_{t=t_1}^{t_2}}}, \quad (5)$$

где $X_i(\omega)$ – спектр временного ряда $\{x_i(t), t = \overline{1, T}\}$, а символ $*$ означает комплексное сопряжение.

Возможные значения когерентности лежат в отрезке от 0 до 1, причём равенство когерентности единице является критерием выполнения условия (3) и согласованности изменения амплитуд бегущей волны в точках P_i и P_j на интервале времени $[t_1; t_2]$.

Группировка характеристик бегущих волн

Введённые показатели (4) и (5) выраженности бегущей волны могут быть рассчитаны для любой пары электродов с координатами P_i и P_j , $i = \overline{1, L}$, $j = \overline{1, L}$. В настоящей работе предложено рассчитывать эти показатели лишь для соседних точек. Пару соседних электродов определим как пару электродов, ячейки Вороного для которых имеют общее ребро [3].

Пусть $\gamma_r\left(\omega, t - \frac{\Delta t}{2}, t + \frac{\Delta t}{2}\right)$ – значение показателя (4), рассчитанное для r -й пары соседних точек, $r = \overline{1, R}$, Δt – фиксированная ширина временного окна.

При фиксированном значении частоты ω совокупность значений показателя (4), рассчитанных для каждой пары соседних электродов можно рассматривать как вектор характерных признаков $y(t|\omega)_\gamma$, описывающих временной ряд X в момент времени t , $t = \overline{1, T}$, (см. (1)):

$$y(t|\omega)_\gamma = \left(\gamma_1 \left(\omega, t - \frac{\Delta t}{2}, t + \frac{\Delta t}{2} \right), \dots, \gamma_R \left(\omega, t - \frac{\Delta t}{2}, t + \frac{\Delta t}{2} \right) \right). \quad (6)$$

Аналогично определяем вектор $y(t|\omega)_\Gamma$ характерных признаков, составленный из значений показателя (5).

Для сокращения размерности векторов $y(t|\omega)_\gamma$ и $y(t|\omega)_\Gamma$ может быть проведена пространственная группировка пар соседних электродов [3]. Разобьём множество всех электродов на некоторые подмножества $\Omega_1, \dots, \Omega_Q$. Каждое подмножество Ω_q , $q = \overline{1, Q}$, характеризуем значением показателя (4) или (5), усреднённым по всем парам соседних электродов из этого множества.

Вектор характерных признаков $\tilde{y}(t|\omega)_\gamma$, описывающих временной ряд X в момент времени t , $t = \overline{1, T}$, составляем из рассчитанных средних значений:

$$\tilde{y}(t|\omega)_\gamma = \left(\bar{\gamma}_1 \left(\omega, t - \frac{\Delta t}{2}, t + \frac{\Delta t}{2} \right), \dots, \bar{\gamma}_Q \left(\omega, t - \frac{\Delta t}{2}, t + \frac{\Delta t}{2} \right) \right). \quad (7)$$

Аналогично определяем вектор $\tilde{y}(t|\omega)_\Gamma$.

Микросостояниями $S_1, \dots, S_K$ временного ряда X являются непересекающиеся области в пространстве предложенных характерных признаков. Для их выделения используем алгоритм агломеративной иерархической кластеризации [5]. Отличие от прочих алгоритмов заключается в построении не одного разбиения данных на непересекающиеся кластеры, а системы вложенных разбиений, в которых объекты объединяются во все более крупные кластеры. Результат агломеративной кластеризации обычно представляется в виде таксономического дерева – дендрограммы [5].

Экспериментальные исследования

Экспериментальные исследования предложенных алгоритмов сегментации проводились на данных электроэнцефалографии головного мозга (ЭЭГ), записанных в НБИКС-центре НИЦ «Курчатовский институт». Запись проводилась в состоянии покоя испытуемого в течение нескольких минут, число каналов электроэнцефалографа $L = 62$, расположение каналов соответствует стандартной схеме «10-20», частота дискретизации $f_s = 5000$ Гц. Для проведения исследований выбран промежуток записи длиной 10 с ($T = 50000$).

Для расчёта спектров сигналов ЭЭГ использовано дискретное оконное преобразование Фурье. На основе результатов спектрального разложения вычислены показатели выраженности бегущей волны в соответствии с формулами (4) и (5) для всех пар соседних электродов и на всех частотах ω от 5 до 30 Гц с шагом 1 Гц. Ширина окна $t_2 - t_1$ изменялась в зависимости от анализируемой частоты ω : $t_2 - t_1 = f_s / \omega$.

На рис. 1 приведены диаграммы значений показателей (4) и (5) выраженности бегущей волны на частоте $\omega = 6$ Гц для всех пар соседних электродов. Из диаграмм видно, что выделяются группы пар электродов со схожей динамикой выраженности бегущей волны, при этом картина выраженности бегущей волны у обоих показателей схожа, незначительная разница проявляется в крутизне межсинхронных переходов.




Рис. 1. Значения показателей синхронности γ_{ij} (а) и когерентности Γ_{ij} (б) бегущих волн на частоте 6 Гц для всех пар соседних электродов

В зависимости от частоты ω , разбиения множества пар электродов на группы и числа кластеров K , представление исходного временного ряда как последовательности номеров микросостояний будет получаться различным. Для оценки качества формируемых микросостояний используем следующие показатели: индекс Дэвиса–Болдина DB [6], средневзвешенная продолжительность микросостояний $\overline{\Delta t}$, среднеквадратичное отклонение продолжительности микросостояний $\tilde{\sigma}$.

Показатель DB используется для сравнения качества сегментации в исследуемом пространстве признаков при различном числе микросостояний (чем меньше индекс DB , тем более чётко выражены кластеры). Малые значения показателя $\overline{\Delta t}$ означают частую смену микросостояний, что может говорить о чрезмерной детализации сегментов. Высокие значения показателя $\tilde{\sigma}$ говорят о сильной вариабельности продолжительностей микросостояний.

На рис. 2 представлены значения показателей качества, рассчитанные для различных пространств признаков и различного числа микросостояний K . Из графиков видно, что оптимальная кластеризация по DB -критерию (минимальное значение DB -индекса) наблюдается в пространстве амплитуд гармоник на частотах примерно 10-11 Гц (частота альфа-ритма) при $K = 2, 3, 4$.

При кластеризации в пространствах признаков, связанных с показателями синхронности и когерентности, полученная картина принципиально отличается: оптимальная кластеризация по DB -критерию наблюдается в пространстве амплитуд частот примерно 24-26 Гц (частоты бета-ритма) при числе кластеров $K = 2, 3, 4$ и в пространстве амплитуд частот 27 Гц и 30 Гц при числе кластеров $K = 5, \dots, 8$. Отметим, что картины для показателей синхронности и когерентности качественно схожи.

На рис. 3 приведены графики последовательности смены номеров микросостояний, выделенных в различных пространствах признаков.

Из графиков на рис. 3 видны принципиальные различия последовательностей смены микросостояний, выделенных в различных пространствах признаков.

На рис. 4 приведена дендрограмма микросостояний в пространстве группированных на $Q = 4$ области показателей синхронности (7), графики последовательностей их смены и эталонные представители на различных уровнях иерархии кластеров. Из графиков видно, какие именно микросостояния агломерируются при повышении уровня иерархии.




Рис. 2. Показатели качества сегментации DB , $\overline{\Delta t}$ и $\tilde{\sigma}$ в различных пространствах признаков. По оси абсцисс отложено число микросостояний K , по оси ординат – анализируемая частота бегущей волны ω




Рис. 3. Графики последовательностей смены номеров микросостояний для сегментации на $K = 5$ микросостояний

в пространствах признаков: амплитуд исходного сигнала (EEG); амплитуд гармоник частоты 30 Гц (Spectr); показателей

на частоте 30 Гц синхронности при группировке на $Q = 4$ области (Phase-locking); $Q = 4$ области показателей когерентности (Coherence)




Рис. 4. Дендрограмма микросостояний в пространстве группированных на $Q = 4$ области показателей синхронности, графики последовательностей их смены и эталонные представители на различных уровнях иерархии

Заключение

В работе предложен метод сегментации сигналов ЭЭГ на основе характеристик бегущих волн. Для оценки степени выраженности бегущих волн использованы показатели синхронности и когерентности. В результате экспериментальных исследований на реальных данных ЭЭГ установлено, что свойства микросостояний, связанных с характеристиками бегущих волн, принципиально отличаются от свойств микросостояний, выделенных в пространствах исходных амплитуд ЭЭГ и их спектральных характеристик.

Список литературы

1. Kaplan A.Y. et al. Nonstationary nature of the brain activity as revealed by EEG/MEG: methodological, practical and conceptual challenges //Signal processing. 2005. Т. 85. №. 11. С. 2190-2212.
2. Lehmann D. et al. Brain electric microstates and momentary conscious mind states as building blocks of spontaneous thinking: I. Visual imagery and abstract thoughts //International Journal of Psychophysiology, 1998. Т. 29. №. 1. С. 1-11.
3. Трофимов А.Г., Колодкин И.В., Ушаков В.Л., Величковский Б.М. Метод сегментации пространственно-распределенных временных рядов на основе бегущих волн // Наука и образование. №10, 2014 [Электр. журн. <http://technomag.bmstu.ru/doc/728495.html>]
4. Sandstede B. Stability of travelling waves //Handbook of dynamical systems, 2002. Т. 2. С. 983-1055.
5. Hastie T. et al. The elements of statistical learning. New York : Springer, 2009. Т. 2. №. 1.
6. Maulik U., Bandyopadhyay S. Performance evaluation of some clustering algorithms and validity indices //Pattern Analysis and Machine Intelligence, IEEE Transactions on, 2002. Т. 24. №. 12. С. 1650-1654.

**А.Г. ТРОФИМОВ¹, И.И. ИВАНИЦКИЙ¹,
Б.М. ВЕЛИЧКОВСКИЙ^{1,2}**

¹Национальный исследовательский ядерный университет «МИФИ»

²Национальный исследовательский центр «Курчатовский институт», Москва
atrofimov@list.ru

ЖАДНЫЙ АЛГОРИТМ ПОСТРОЕНИЯ КОМИТЕТА КЛАССИФИКАТОРОВ СИГНАЛОВ ЭЭГ*

Предложен жадный алгоритм построения комитета классификаторов сигналов электроэнцефалографии (ЭЭГ), работающих в простейших одномерных пространствах признаков. Показано, что точность комитета классификаторов превысила точность лучшего из слабых классификаторов более чем в 3,8 раз.

Ключевые слова: *комитет, бинарная классификация, пороговый классификатор, интерфейс «мозг-компьютер», многомерный временной ряд.*

A.G. TROFIMOV¹, I.I. IVANITSKIY¹, B.M. VELICHKOVSKIY^{1,2}

¹National Research Nuclear University (MEPhI), Moscow

²National Research Centre "Kurchatov Institute", Moscow
atrofimov@list.ru

GREEDY ALGORITHM OF COMPOSITION COMMITTEE OF CLASSIFIERS EEG SIGNALS

We propose the greedy algorithm of composition committee of classifiers EEG signals, which work on the simplest one-dimensional feature space. It is shown that the accuracy of classification of committee exceeded the accuracy of the best of the weak classifiers more than eight times.

Keywords: *brain-computer interface, machine learning, boosting, classification.*

Введение

Задача классификации сигналов ЭЭГ является ключевой в интерфейсах «мозг-компьютер» (ИМК). От точности её решения напрямую зависит

* Исследование выполнено в рамках работ по гранту Российского научного фонда № 14-28-00234 (НИЦ «Курчатовский институт»).

качество разрабатываемого интерфейса [1]. Построение классификатора сигналов ЭЭГ в ИМК, как правило, предполагает выполнение следующих этапов [1,2].

1. Предобработка сигналов. На этом шаге осуществляется фильтрация ЭЭГ от шумов, устранение артефактов, отбор каналов или другие операции, позволяющие на ранних этапах отсеять неинформативные данные.

2. Выделение характерных признаков ЭЭГ. Целью этого этапа является переход от исходного пространства динамических данных ЭЭГ к пространству многомерных статических данных. Как только такой переход сделан, задача классификации ЭЭГ сводится к известной задаче классификации многомерных данных.

3. Классификация в пространстве характерных признаков ЭЭГ. На этом этапе могут использоваться классические алгоритмы классификации многомерных статических данных, например, метод дискриминантных функций, нейросетевой аппарат и др.

Методы предобработки ЭЭГ и методы классификации статистических данных известны и хорошо изучены. Наибольшую сложность представляет задача выделения характерных признаков ЭЭГ. Для её решения может быть предложено множество способов. В большинстве случаев априорно неизвестно, какой из них лучше, также неизвестно, окажутся ли данные разных классов хорошо разделимыми в построенном пространстве признаков. Одним из возможных подходов к решению этой задачи является перебор множества способов построения пространств признаков и выбор того пространства, в котором данные разделимы наилучшим образом. Недостатком такого подхода является необходимость определения класса функциональных преобразований, сопоставляющих сигналу ЭЭГ вектор характерных признаков. Этот класс функциональных преобразований задаётся исследователем, исходя из его интуиции, при его неудачном выборе задача классификации может не иметь удовлетворяющего по точности решения.

Простейшим из способов формирования вектора характерных признаков является конкатенация всех наблюдаемых значений ЭЭГ (по всем каналам и всем моментам времени) в единый вектор характерных признаков. Недостатками данного подхода являются высокая размерность получаемого пространства признаков, зависимость размерности вектора от числа временных отсчётов и частоты дискретизации, высокая чувствительность к шумам. Использование спектральных характеристик ЭЭГ не всегда позволяет разделить сигналы, относящиеся к разным ментальным состояниям [3].

В настоящей работе предложен подход к решению задачи классификации ЭЭГ, основанный на использовании комитета классификаторов, работающих в простейших пространствах характерных признаков. Таким образом, вместо поиска подходящего функционального преобразования, сопоставляющего сигналу ЭЭГ вектор характерных признаков, предложено строить множество простых классификаторов, возможно, не обладающих требуемой точностью классификации, работая по-отдельности, из которых будет формироваться комитет. Предложенный подход реализует идею *бустинга* [4].

Постановка задачи

Рассматривается множество сигналов ЭЭГ с одинаковым числом временных отсчётов T , разделённое на два класса. Далее сигналы из одного класса будем называть целевыми, а из другого – нецелевыми. Пусть все сигналы дискретизованы с одинаковой частотой f_s .

Множества целевых и нецелевых сигналов обозначим

$$\Omega_+ = \{X_1^+, X_2^+, \dots, X_{N_+}^+\} \text{ и } \Omega_- = \{X_1^-, X_2^-, \dots, X_{N_-}^-\}$$

соответственно, где $X_i^+ = \{x_i^+(t), t = \overline{1, T}\}$, $i = \overline{1, N_+}$, $X_i^- = \{x_i^-(t), t = \overline{1, T}\}$, $i = \overline{1, N_-}$, – временные ряды, $x_i^+(t) = (x_{i1}^+(t), \dots, x_{iL}^+(t))$, $i = \overline{1, N_+}$, и $x_i^-(t) = (x_{i1}^-(t), \dots, x_{iL}^-(t))$, $i = \overline{1, N_-}$, – векторы значений сигналов X_i^+ и X_i^- соответственно в момент времени t , $t = \overline{1, T}$, N_+ и N_- – число целевых и нецелевых временных рядов соответственно, L – размерность векторного временного ряда (число каналов).

Под бинарным классификатором H будем понимать оператор, осуществляющий отображение многомерного временного ряда X на множество $\{0, 1\}$, где 0 и 1 означают метки нецелевого и целевого класса соответственно: $c = H[X]$, где $c \in \{0, 1\}$.

Обозначим через ϕ оператор, сопоставляющий векторному временно-му ряду X некоторый вектор характерных признаков $y = (y_1, \dots, y_M)$ размерности M : $y = \phi[X]$. Классификатор в пространстве признаков y обозначим через C : $c = C(y)$.

Пусть y_i^+ , $i = \overline{1, N_+}$, и y_i^- , $i = \overline{1, N_-}$, – результаты действия оператора ϕ на сигналы X_i^+ и X_i^- соответственно: $y_i^+ = \phi(X_i^+)$, $y_i^- = \phi(X_i^-)$, а c_i^+ ,

$i = \overline{1, N_+}$, и c_i^- , $i = \overline{1, N_-}$, – результаты классификации векторов признаков y_i^+ и y_i^- с помощью классификатора C : $c_i^+ = C(y_i^+)$, $c_i^- = C(y_i^-)$.

Для оценки качества классификации могут быть предложены следующие показатели:

1) средневзвешенная вероятность ошибок 1-го и 2-го родов:

$$\varepsilon = \kappa\alpha + (1 - \kappa)\beta, \quad (8)$$

где $0 \leq \kappa \leq 1$ – весовой коэффициент, $\alpha = \frac{\sum_{i=1}^{N_-} c_i^-}{N_-}$ – вероятность ошибки

1-го рода (*False Positive Rate, FPR*), $\beta = 1 - \frac{\sum_{i=1}^{N_+} c_i^+}{N_+}$ – вероятность ошибки

2-го рода (*False Negative Rate, FNR*);

2) доля ошибочно распознанных примеров:

$$\gamma = 1 - \frac{\sum_{i=1}^{N_+} c_i^+ + \sum_{i=1}^{N_-} (1 - c_i^-)}{N_+ + N_-}. \quad (9)$$

Выбор конкретного показателя связан с требованиями, предъявляемыми к классификации и, как правило, определяется особенностями рассматриваемой проблемной области. Далее будем обозначать показатель качества классификации через I , понимая под этим один из показателей (8) или (9). Критерием построения классификатора является минимум показателя I .

Пусть построено множество классификаторов $H_1, \dots, H_R$, каждый из которых представлен парой отображений: $y_r = \varphi_r[X]$ и $c_r = C_r[y_r]$, $r = \overline{1, R}$, $c_r \in \{0, 1\}$, где R – число построенных классификаторов.

В качестве решающего правила комитета будем использовать взвешенное голосование. Выход каждого из R классификаторов умножается на соответствующий весовой коэффициент w_r , $r = \overline{1, R}$, $w_r \geq 0$, значение $w_r = 0$ означает, что r -й классификатор не включен в комитет, $w_r > 0$ – вес классификатора в комитете:

$$\Phi(c_1, \dots, c_R, w_1, \dots, w_R) = \begin{cases} 1, & \text{если } \sum_{r=1}^R w_r c_r > \frac{1}{2} \sum_{r=1}^R w_r, \\ 0, & \text{иначе.} \end{cases} \quad (10)$$

Построение множества слабых классификаторов

В качестве скалярного признака y_r для r -го классификатора, $r = \overline{1, R}$, используем средние значения уровней ЭЭГ в фиксированном временном промежутке $[t_r - \Delta\tau/2; t_r + \Delta\tau/2]$ на фиксированном канале p_r , где $t_r \in \{1 + \Delta\tau/2, \dots, T - \Delta\tau/2\}$, $\Delta\tau$ – фиксированная ширина временного окна:

$$y_r = \varphi_r[X] = \frac{1}{\Delta\tau + 1} \sum_{\tau=t_r-\Delta\tau/2}^{t_r+\Delta\tau/2} x_{p_r}(\tau), \quad r = \overline{1, R}. \quad (11)$$

Для классификации одномерных характерных признаков используем пороговый бинарный классификатор. Задача построения порогового бинарного классификатора (оператора C) состоит в нахождении оптимального порога y_0 , разделяющего данные двух классов.

Работа порогового бинарного классификатора C описывается следующей моделью:

$$C(y, y_0, s) = \begin{cases} 1, & \text{если } (y - y_0)s > 0, \\ 0, & \text{иначе,} \end{cases}$$

где y_0 – порог, $s \in \{-1, 1\}$ – индикатор. Значение $s = -1$ означает, что классификатор относит к целевому классу данные, расположенные слева от порога, значение $s = 1$ – справа.

Порог y_{0r} для каждого классификатора определяется методом сканирования. В качестве критерия точности работы слабых классификаторов используем показатель I ((8) или (9)).

Алгоритм построения комитета классификаторов

Алгоритм построения комитета классификаторов включает следующие этапы.

1. В начале работы алгоритма полагаем множество S номеров решающих классификаторов пустым: $S := \emptyset$.

2. Из множества классификаторов C_r , $r = \overline{1, R}$, выбираем *базовый* классификатор. В настоящей работе в качестве базового классификатора выбирается классификатор с наименьшим выбранным показателем качества классификации, т.е. классификатор C_{r^*} такой, что $r^* = \arg \min_{r=1, R} I(C_r)$. Для

найденного классификатора изменяем значение $w_{r^*} := 1$ и добавляем r^* в множество номеров решающих классификаторов комитета: $S := S \cup r^*$.

3. Для комитета классификаторов проверяем один (или несколько) из критериев останова:

– $I(S) \leq I_0$, где $I(S)$ – показатель точности комитета с множеством S номеров решающих классификаторов на обучающей/тестовой выборке, I_0 – требуемая точность классификации;

– $|S| \geq R_0$, где R_0 – максимальное число классификаторов в комитете (в частности, $R_0 = R$);

– $\Delta I \leq \Delta I_0$, где ΔI – изменение показателя точности комитета на текущей итерации по сравнению с предыдущей, ΔI_0 – заданная константа (это условие не проверяется на первой итерации);

– начало процесса переобучения, характеризующегося увеличением ошибки классификации на тестовой выборке.

Если критерий останова выполнен, то конец.

4. Перебираем все возможные пары классификаторов $\{C_{r_1}, C_{r_2}\}$ из всех имеющихся слабых классификаторов (как включённых, так и не включённых в комитет) с целью выбора одной для включения в комитет. В комитет добавляем ту пару классификаторов, для которой комитет (из $|S| + 2$ классификаторов) имеет минимум выбранного показателя качества классификации $I((8)$ или $(9))$: $(r_1^*, r_2^*) = \arg \min_{\substack{r_1, r_2 = 1, \dots, R, \\ r_1 \neq r_2}} I(S \cup r_1 \cup r_2)$. Для найденной

оптимальной пары классификаторов $\{C_{r_1^*}, C_{r_2^*}\}$ полагаем $w_{r_1^*} := w_{r_1^*} + 1$, $w_{r_2^*} := w_{r_2^*} + 1$ и $S := S \cup \{r_1^*, r_2^*\}$. Нечётный суммарный вес всех классификаторов-членов комитета позволит избежать ситуации равенства голосов.

5. Переходим к п. 3.

Как при выборе базового классификатора комитета, так и при добавлении на каждой итерации пары классификаторов в комитет используется критерий минимума локальной ошибки классификации на текущей итерации алгоритма. Отметим, что такой жадный выбор решающих классификаторов на каждой итерации в общем случае может не приводить к глобально оптимальному решению [5,6].

Экспериментальные исследования

Экспериментальные исследования алгоритма построения комитета классификаторов проводились на сигналах электроэнцефалограмм (ЭЭГ), полученных в лаборатории нейроэргономики и интерфейсов мозг-компьютер НБИКС-центра НИЦ «Курчатовский институт» в ИМК-

эксперименте по подаче экстренной команды роботу [7]. Целевые сигналы ЭЭГ соответствуют сосредоточению внимания испытуемого на внешнем стимуле (предъявление изображения на экране монитора), нецелевые сигналы записаны в состоянии чтения текста нейтрального содержания.

Все сигналы ЭЭГ были оцифрованы с частотой дискретизации $f_s = 500$ Гц и очищены от артефактов. Запись каждого сигнала ЭЭГ велась по $L = 58$ каналам, расположенным по стандартной схеме «10-10», в течение одной секунды ($T = 500$). Сигналы были разбиты на обучающую и тестовую выборки, объёмы которых соответственно равны $N^{train} = 1161$ ($N_+^{train} = 359$, $N_-^{train} = 802$), $N^{test} = 289$ ($N_+^{test} = 89$, $N_-^{test} = 200$).

Каждый слабый классификатор C_r работает в одномерном пространстве признаков (11), характеризуемым номером канала p_r и временным сдвигом t_r . Ширину временного окна $\Delta\tau$ полагаем фиксированной и равной 25 отсчетам (50 мс). Слабые классификаторы построены для всех каналов $p_r \in \{1, \dots, L\}$ и временных сдвигов t_r с шагом 25 отсчетов (50 мс). Общее число слабых классификаторов $R = 58 \cdot 20 = 1160$.

Минимальное среднее арифметическое вероятностей ошибок 1-го и 2-го рода (при $\kappa = 0,5$) наблюдается для классификатора с параметрами $p_r = 31$ (канал F8), $t_r = 6$ (275 мс): на обучающей выборке $\epsilon^{обуч} \approx 0,33$, на тестовой выборке $\epsilon^{тест} \approx 0,33$. Минимальная доля ошибочно распознанных примеров наблюдается для классификатора с параметрами $p_r = 13$ (канал Pz), $t_r = 6$ (275 мс): на обучающей выборке $\gamma^{обуч} \approx 0,27$, на тестовой выборке $\gamma^{тест} \approx 0,27$.

На рис. 1 приведены гистограммы распределения классификаторов по показателям точности на обучающей и тестовой выборках. Из рис. 1, а и в видно, что распределение имеет выраженную правую асимметрию на данных обучающей выборки, в то время как распределение классификаторов по точности на тестовой выборке (рис. 1, б и г) практически симметрично.

Этот факт говорит о возможном переобучении некоторой доли слабых классификаторов.

Как только выбран базовый классификатор, далее на каждой итерации алгоритма добавляем пару слабых классификаторов в комитет, максимально уменьшающих значение используемого критерия ϵ или γ . Для оценки обобщающих способностей используем 5-кратную (5-fold) кросс-валидацию (имеющиеся экспериментальные данные были разделены случайным образом на 5 равных подвыборок, тестирование проводилось на каждой из подвыборок при обучении на остальных подвыборках).





Рис. 1. Гистограммы распределения слабых классификаторов по показателям качества классификации:

a – по показателю ϵ на обучающей выборке; *б* – по показателю ϵ на тестовой выборке; *в* – по показателю γ на обучающей выборке; *г* – по показателю γ на тестовой выборке


На рис. 2 приведены графики зависимостей средних значений показателей ϵ или γ точности комитета от числа решающих классификаторов в нём (усреднение проводилось по 5 значениям показателей точности, рассчитанным при кросс-валидации).

Как видно из рис. 2, *a*, жадный комитет, оптимизирующий значение ϵ , практически не склонен к переобучению, в то же время начиная с $K \approx 30$ точность на тестовой выборке практически перестаёт изменяться. Наилучшее значение средней вероятности ошибок I и II рода на тестовой выборке $\epsilon^{тест} \approx 0,09$ достигается при $K = 73$ слабых классификаторов в комитете. Наиболее сильное улучшение критерия качества классификации как на обучающей, так и на тестовой выборках наблюдается на первых шагах алгоритма – при добавлении классификаторов в комитеты, состоящие не более чем из 15 слабых классификаторов.

При использовании жадного алгоритма построения комитета классификаторов с критерием точности γ , как видно из рис. 2, б, улучшения точности практически не наблюдается.



а



б

Рис. 2. Графики зависимостей показателей ϵ (а) и γ (б) качества классификации комитета от числа классификаторов-членов комитета. Высота столбиков равна среднему значению показателя точности при кросс-валидации, длина штрихов — среднему квадратичному отклонению

Результаты классификации сигналов ЭЭГ на обучающей и тестовой выборках с помощью комитета классификаторов и их сравнение с результатами работы лучшего слабого классификатора приведены в табл. 1.

Таблица 1

Результаты работы комитета классификаторов

Критерий I	Базовый классификатор		Комитет классификаторов	
	Ср. знач. $I_{\text{обуч}} / I_{\text{тест}}$	С. к. о. $I_{\text{обуч}} / I_{\text{тест}}$	Ср. знач. $I_{\text{обуч}} / I_{\text{тест}}$	С. к. о. $I_{\text{обуч}} / I_{\text{тест}}$
ϵ	0,3294/0,3349	0,0085/0,0337	0,0373/0,0891	0,0057/0,0171
γ	0,2653/0,2699	0,025/0,025	0,2462/0,2588	0,0018/0,0108

Из таблицы, содержащей результаты работы комитета классификаторов, видно, что жадный комитет улучшил значение показателя точности классификации почти в 4 раза по сравнению с лучшим слабым классификатором при использовании критерия ϵ (для тестовой выборки) и практически не улучшил показатель точности при использовании критерия γ . Полученная точность около 92 % сравнима с точностью существующих ИМК на вызванных потенциалах, работающих с одиночными стимулами [8].

Заключение

В работе предложен жадный алгоритм построения комитета бинарных классификаторов временных рядов. Каждый из слабых классификаторов – кандидатов на включение в комитет – работал в своём пространстве признаков. В качестве таких признаков выбраны средние значения уровней на разных каналах многомерного временного ряда в скользящих временных окнах. В качестве решающего правила комитета использовано взвешенное голосование.

В результате экспериментальных исследований на реальных данных ЭЭГ установлено, что среднее арифметическое вероятностей ошибок 1-го и 2-го рода построенного комитета классификаторов оказалось лучше, чем значение этого показателя для лучшего из слабых классификаторов, в $\epsilon_0/\epsilon \approx 8,8$ раз на обучающей выборке и $\epsilon_0/\epsilon \approx 3,8$ на тестовой выборке.

Список литературы

1. Vallabhaneni A., Wang T., He B. Brain—computer interface //Neural Engineering. Springer US, 2005. С. 85-121.
2. Трофимов А.Г., Скругин В.И. Метод выделения динамических паттернов в задаче классификации многомерных временных рядов // Информационные технологии, 2011. № 4. С. 65-71.
3. Lotte F. et al. A review of classification algorithms for EEG-based brain-computer interfaces //Journal of neural engineering, 2007. Т. 4.

4. Bauer E., Kohavi R. An empirical comparison of voting classification algorithms: Bagging, boosting, and variants //Machine learning, 1999. Т. 36. №. 1–2. С. 105-139.

5. Manner S., Meir R., Zhang T. Greedy algorithms for classification—consistency, convergence rates, and adaptivity //The Journal of Machine Learning Research., 2003. Т. 4. С. 713-741.

6. Friedman J. H. Greedy function approximation: a gradient boosting machine //Annals of Statistics, 2001. С. 1189-1232.

7. Fedorova A.A. et al. A fast “single-stimulus” brain switch // 6th Int. BCI Conf. 2014. September 16-19, Graz, Austria (in press).

8. Martinovic I. et al. On the Feasibility of Side-Channel Attacks with Brain-Computer Interfaces //USENIX Security Symposium, 2012. С. 143-158.

М.С. АТАНОВ, Г.А. ИВАНИЦКИЙ

Институт высшей нервной деятельности и нейрофизиологии РАН, Москва
mikhail.atanov@phystech.edu

ОПТИМИЗАЦИЯ АЛГОРИТМА РАСПОЗНАВАНИЯ ТИПА ТЕКУЩЕЙ МЫСЛИТЕЛЬНОЙ ДЕЯТЕЛЬНОСТИ НА ОСНОВЕ ДАННЫХ ЭЭГ

В данной работе решается задача улучшения функционирования интерфейса мозг-компьютер, направленного на обучение решению предлагаемых задач методом биологической обратной связи. Основным моментом является применение метода независимых компонент к электроэнцефалографии (ЭЭГ). Также производится попытка физиологической интерпретации полученных компонент с целью нахождения общих между разными людьми процессов, составляющих мышление.

Ключевые слова: *перцептрон, ЭЭГ, метод независимых компонент, интерфейс мозг-компьютер.*

M.S. ATANOV, G.A. IVANITSKY

Institute of Higher Nervous Activity and Neurophysiology of RAS, Moscow
mikhail.atanov@phystech.edu

OPTIMIZATION OF CURRENT TYPE OF COGNITIVE ACTIVITY RECOGNITION BASED ON EEG DATA

The problem of improving the performance of the BCI, designed for learning the subjects to solve cognitive tasks utilizing biofeedback learning, is con-

sidered in the paper. The main point is the application of ICA method to EEG data. Moreover, an attempt was made to interpret the resulting components from the physiological point of view to find the processes, forming the thinking, common for different subjects.

Keywords: *perceptron, EEG, Independent Component Analysis, brain-computer interface.*

Введение

Решение проблемы высокоточного распознавания коротких отрезков ЭЭГ необходимо для должного функционирования интерфейсов мозг-компьютер. В настоящее время научными коллективами применяются разнообразные математические конструкции, позволяющие достигать точности на уровне 95 %, однако интерпретация результата обучения соответствующего классификатора зачастую оказывается сильно затруднена или вовсе невозможна ввиду сложности комбинаций методов или их внутренних ограничений. В данной работе задача повышения точности классификации решается сравнительно простыми, но эффективными методами с ограничением на возможность последующей интерпретации, что даёт не только практический эффект увеличения качества функционирования интерфейса, но и фундаментальное знание о процессах, происходящих в мозге при осуществлении определённого рода деятельности.

В предыдущих исследованиях лаборатории высшей нервной деятельности человека неоднократно была подтверждена стабильность спектра ЭЭГ при осуществлении мыслительной деятельности. Испытуемым предлагались задачи двух типов: вербально-логические (решить анаграмму) и пространственно-образные (собрать квадрат из двух частей). В качестве третьего состояния (покоя) были взяты межстимульные интервалы. Усреднённые отдельно по трём состояниям периодограммы оказались стабильны в течение длительного времени [1]. Более того, была подтверждена приемлемая точность распознавания текущего состояния по единичной периодограмме с использованием перцептрона (в данной работе – без скрытых слоёв).

Сигнал ЭЭГ состоит из суперпозиции сигналов некоторого количества источников, и некоторые из этих источников являются представлениями элементарных базисных психологических процессов, из которых состоит мыслительная деятельность. Переход из пространства каналов ЭЭГ в пространство источников должен, в таком случае, повышать эффективность распознавания, поскольку использованы для классификации будут «причинные» процессы, а не их «следствие» в виде смеси, каковой является

ЭЭГ. Преобразованием «размешивания» в данной работе является метод независимых компонент (МНК). Метод применяется к данным ЭЭГ практически сразу после его изобретения [2] и набрал большую популярность, несмотря на то, что одним из базовых предположений метода является статистическая независимость сигналов искомым источников, которое, по большому счёту, неверно в некоторых случаях [3].

Преобразование к компонентам является умножением квадратной матрицы размешивания на матрицу данных ЭЭГ (столбцы — дискретные временные отсчёты, строки — каналы). Матрица весов является невырожденной по построению, следовательно, она обратима, и обратная матрица называется матрицей смешивания. Каждый их столбцов этой матрицы описывает представленность соответствующей компоненты в каналах ЭЭГ. Далее эти столбцы будут называться картами компонент, поскольку столбцы можно изобразить в виде топографических карт присутствия компоненты в разных областях мозга. В данной работе использовался алгоритм FastICA [4] реализации МНК.

Применение МНК в интерфейсах мозг-компьютер направлено в основном на очистку сигналов ЭЭГ от морганий и движений глаз, поскольку они изолируются в отдельных компонентах [2]. Работы, в которых практикуется переход из базиса каналов ЭЭГ в базис независимых компонент и последующая обработка именно сигналов компонент, чрезвычайно редки [5, 6] и, как и большинство интерфейсов, в качестве стимулов используют реальное или воображаемое движение кистей рук. Использование же в данной работе сложных когнитивных заданий приближает условия исследования к реальным, так как заранее неизвестны области интереса, и решение предлагаемых задач вовлекает многие элементарные составляющие мышления. Отсюда следует актуальность решения поставленной задачи.

Данная работа является развитием исследований [1, 7-9] и инспирирована по большей части работой [10].

Постановка задачи и описание алгоритма

Задача состоит в оптимизации алгоритма распознавания типа текущей мыслительной деятельности на основе данных ЭЭГ и физиологической интерпретации полученных результатов.

Здесь и далее под эффективностью метода подразумевается влияние на точность классификации (процент правильных классификаций, ППР), усреднённой по многократным кросс-валидациям. Процедура состояла в следующем [1]. Вначале запись ЭЭГ фильтруется прямоугольным поло-

совым фильтром 5-20 Гц. Далее она очищается от глазодвигательных наводок методом линейной регрессии отдельно по каждому каналу ЭЭГ на 2 канала электроокулограммы. Затем запись разрезается на промежутки (реализации), отвечающие решению одной задачи или межстимульному интервалу. После этого вычисляется преобразование Фурье отдельно каждой реализации и рассчитывается квадрат его модуля в диапазоне 5-20 Гц (периодограммы). На полученном пуле проводится 50 2-fold кросс-валидаций со случайными разбиениями пула на 2 выборки. Отдельно была исследована дисперсия ППР при разном числе кросс-валидаций, и число 50 явилось оптимальным между длительностью расчетов и дисперсией получаемого результата.

При выработке дальнейших методических шагов мы исходили из следующих соображений. Первым делом необходимо проверить эффективность простого перехода из базиса каналов ЭЭГ в базис независимых компонент. Предполагается, что эффективность будет значимой, поскольку специфические и фоновые постоянные процессы выделятся в отдельные компоненты. Также есть смысл провести анализ случайности полученного результата: данные ЭЭГ преобразуются произвольными матрицами и определяется, насколько преобразование к независимым компонентам и преобразование единичной матрицей лучше среднего случайного преобразования (в единицах стандартных отклонений).

Затем следует удостовериться в постоянстве базиса независимых компонент. Для этого нужно рассчитать компоненты по удалённым во времени записям ЭЭГ и провести их сравнение. Стоит отметить, что независимые компоненты на выходе метода их расчёта получаются в произвольном порядке. То есть для соотнесения компонент, полученных по разным записям, следует разработать способ их сортировки. Методы, найденные в литературе [11, 12], основанные на корреляциях карт компонент, не оптимальны, поскольку, например, корреляции между картами разных компонент из одного набора (рассчитанных по одной записи ЭЭГ) нередко достигают значения 0,8. В рамках нашей исследовательской парадигмы «одинаковые» компоненты должны иметь близкие спектры, рассчитанные отдельно по трём когнитивным состояниям (решение вербальной, пространственной задачи и отдых). Соответственно, к корреляции карт необходимо добавить корреляции спектров состояний. Итоговым критерием стало среднеквадратичное значение четырёх корреляций: карт и спектров в трёх состояниях. Альтернативной проверкой постоянства базиса независимых компонент может служить сравнение точности классификатора при переходе к компонентам с помощью матрицы размешивания, рассчитанной по всем данным и, например, по первой половине данных.

После выяснения постоянства компонент возможно проверить, какие из них являются важными, то есть объясняют большую часть дисперсии периодограмм в разных состояниях. Возможно несколько способов поиска, например: 1) последовательно определять неважные компоненты, исключение которых даёт значимый прирост точности распознавания; 2) провести полный перебор всех наборов компонент; 3) определить оптимальный набор из небольшого числа компонент (2-4), и затем последовательно присоединять к набору те компоненты, с которыми точность распознавания максимальна. В работе [10] был использован третий метод, как наиболее соответствующий парадигме эксперимента. Также была показана зависимость точности распознавания от количества компонент в наборе: выпуклая вверх кривая с достаточно протяжённым плато. Второй же метод слишком затратен по времени. В данной работе был использован первый метод.

Необходимо также проверить, насколько приемлем переход к независимым компонентам для режима реального времени. Для этого, опять же, можно рассмотреть две записи ЭЭГ. Матрица размешивания вычисляется по первой записи либо по всей записи. Если разложение на компоненты второй записи в обоих указанных случаях практически одинаково, то метод можно применять в реальном времени, используя предварительно вычисленную матрицу размешивания.

По нахождению оптимальных наборов компонент для нескольких испытуемых производится их интерпретация. Соотнести компоненты разных людей представляется более трудной задачей, поскольку спектры их компонент, как и спектры ЭЭГ имеют крайне малое сходство, что видно невооружённым глазом (рис. 1, 2).

Однако существуют как минимум 2 компоненты, обнаруженные почти у всех (9 из 10) испытуемых – они имеют пик спектра в районе 11 Гц и карты с максимумами в центральных отведениях ЭЭГ С3 (для первой компоненты) и С4 (для второй). В работе [13] было показано, что эти 11-герцовые колебания связаны с подавлением движения, задействованным в процессе решения пространственных задач. Активность пространственного мышления в процессе решения вербально-логических задач априори не определена. Ответ зависит от стратегии решения: одни испытуемые при решении анаграммы буквально переставляют местами буквы и визуально оценивают получающиеся псевдослова, другие же используют фонетику, то есть представляют, как звучит слово, не произнося его вслух. Если во втором случае происходит перестановка не букв, но звуков, то пространственное мышление, естественно, менее задействовано. Выходит, важ-

ность компонент, обнаруженных у различных людей, может отличаться ввиду разной стратегии решения.




Рис. 1. Спектры ЭЭГ в трёх состояниях (чёрный – геометрическая задача, темно-серый – анаграмма, светло-серый – межстимул) для двух испытуемых




Рис. 2. Спектры независимых компонент в трёх состояниях для двух испытуемых

Можно провести исследование весов, полученных в ходе обучения перцептрона: по ним определяются важные для классификации частотные диапазоны для каждой отдельной компоненты или канала ЭЭГ. Однако

это рассмотрение вышло за рамки исследования по причине неинвариантности относительно испытуемых интерпретации исключённых компонент.

Результаты и обсуждение

Таблица 1

Эффективность МНК

Испытуемый №	1	2	3	4	5	6	7	8	9	10	сред	остаток
ППР ЭЭГ	87,5	76,1	81,8	93,7	80,1	87,9	85,0	81,0	90,4	86,1	85,0	15,0
ППР МНК	91,4	75,6	86,1	94,5	92,8	92,0	95,1	85,9	92,2	88,0	89,4	10,6
Среднее	84,4	71,7	81,6	89,8	80,4	88,6	82,5	79,8	87,8	85,3	83,2	
Ст. откл.	2,0	2,3	1,4	2,5	2,4	1,2	1,7	1,7	1,8	1,2	1,8	
Откл. ЭЭГ	1,5	1,9	0,2	1,6	-0,1	-0,7	1,4	0,7	1,4	0,7	0,9	
Откл. МНК	3,5	1,7	3,2	1,9	5,2	2,9	7,2	3,6	2,4	2,3	3,4	

Переход к независимым компонентам уменьшил процент неправильных классификаций на ~30 %.

ППР по компонентам лежит в среднем на 2,5 ст. отклонений правее ППР по ЭЭГ, то есть переход к размешанным независимым компонентам от каналов ЭЭГ неслучайно и довольно значимо повышает ППР.

Таблица 2

Постоянство компонент

Испытуемый №	1	2	3	4	5	6	7	8	9	10	сред
ППР МНК 1	90,3	80,5	88,1	91,7	91,5	92,5	88,3	80,2	88,6	86,6	87,8
ППР МНК ½	92,8	66,3	89,4	95,8	90,2	91,6	90,0	81,3	89,5	86,6	87,3

Отличия ППР при преобразовании данных ЭЭГ матрицей размешивания, рассчитанной по всем данным и по первой половине данных, в пределах погрешности не отличаются. Поэтому метод может применяться в реальном времени.

Соотнесение компонент по описанному выше критерию сходства также даёт основания судить о постоянстве компонент: у всех испытуемых как минимум половина компонент имеет значения показателя сходства большие, чем максимальные значения этого показателя при сравнении компонент из одного набора.

Поскольку практически невозможно провести исследование на одном испытуемом в абсолютно равных условиях, данный результат может считаться удовлетворительным. Стоит также заметить, что по спектрам исходной ЭЭГ видно, что в разное время наиболее variabelен спектр в состоянии покоя, но не во время решения задач. Из этого факта можно

предположить, что именно компоненты, наиболее интенсивные в меж-стимульном интервале, являются наименее постоянными, хотя это отдельно не исследовалось.

Таблица 3

Оптимальный набор компонент

Испытуемый №	1	2	3	4	5	6	7	8	9	10	сред	остаток
ЭЭГ	89,9	73,3	82,8	92,0	78,2	88,9	88,7	76,9	91,1	88,9	85,1	14,9
ЭЭГ опт.	91,5	77,7	87,4	93,6	92,5	92,6	89,2	79,5	92,1	90,3	88,6	11,4
МНК	90,3	80,5	88,1	91,7	91,5	92,5	88,3	80,2	88,6	86,6	87,8	12,2
МНК опт.	95,2	89,1	93,7	92,8	95,0	92,6	92,0	95,5	95,4	90,9	93,2	6,8

Исключение некоторых компонент значительно более эффективно, чем исключение некоторых каналов ЭЭГ. Данное наблюдение явно свидетельствует о разделении важной и неважной информации в разные компоненты.

При переходе от ранее использовавшегося метода классификации (строка «ЭЭГ») к новому (строка «МНК опт.») процент ошибок классификатора упал более чем в 2 раза до 7%. Применяя новый алгоритм классификации в составе вышеупомянутого интерфейса мозг-компьютер, предъявление сигнала обратной связи будет производиться в более подходящие моменты, и, вследствие этого, эффективность обучения (испытуемых) решению задач (интерфейсом) должна увеличиться.

При интерпретации оптимальных наборов компонент оказалось, что компоненты, представляющие центральные 11-Герцовые ритмы, неважны для классификации в половине случаев. Возможно, более инвариантные результаты могут быть получены при изменении алгоритма включения/исключения компонент из рассмотрения, поскольку в данном варианте «нейтрально важные» компоненты могут входить в оптимальный набор.

Выводы

Переход от базиса каналов ЭЭГ к базису независимых компонент неслучайно и значимо повышает точность классификатора при определении типа решаемой задачи по данным ЭЭГ. Важная и неважная для классификации информация при этом концентрируется в разных компонентах и исключение неважных компонент приводит к ещё большему увеличению точности классификации. Совместное применение МНК и исключения компонент приводит к уменьшению процента ложных ответов классификатора более чем в 2 раза.

Компоненты сохраняют своё присутствие на исследуемых временных диапазонах, откуда следует, что описанная методика может применяться в реальном времени.

Список литературы

1. Иваницкий Г.А., Наумов Р.А., Иваницкий А.М. Технология определения типа совершаемой в уме мыслительной операции по рисунку электроэнцефалограммы //Технологии живых систем, 2007. Т. 4. №. 5-6. С. 20-29.
2. Makeig S. et al. Evolving signal processing for brain-computer interfaces //Proceedings of the IEEE, 2012. Т. 100. №. Special Centennial Issue. С. 1567-1584.
3. Makeig S. et al. Independent component analysis of electroencephalographic data //Advances in neural information processing systems, 1996. С. 145-151.
4. Hyvarinen A. Fast and robust fixed-point algorithms for independent component analysis //Neural Networks, IEEE Transactions on, 1999. Т. 10. №. 3. С. 626-634.
5. Navarro I., Sepulveda F., Hubais B. A comparison of time, frequency and ICA based features and five classifiers for wrist movement classification in EEG signals //Engineering in Medicine and Biology Society, 2005. IEEE-EMBS, 2005. 27th Annual International Conference of the IEEE, 2005. С. 2118-2121.
6. Erfanian A., Erfani A. ICA-based classification scheme for EEG-based brain-computer interface: the role of mental practice and concentration skills //Engineering in Medicine and Biology Society, 2004. IEMBS'04. 26th Annual International Conference of the IEEE. IEEE, 2004. Т. 1. С. 235-238.
7. Иваницкий Г.А. и др. Как определить, чем занят мозг, по его электрическим потенциалам? Устойчивые паттерны ЭЭГ при выполнении когнитивных заданий //Вопросы искусственного интеллекта, 2008. Т. 1. №. 1. С. 93-102.
8. Иваницкий Г.А. и др. Паттерны нейронной активности как отражение информационных процессов в мозге.//Тезисы докладов Всероссийской конференции «Нелинейная динамика в когнитивных исследованиях», 2009. С. 62.
9. Атанов М.С. Влияние обратной связи по частотному спектру ЭЭГ на когнитивную деятельность в парадигме интерфейса мозг-компьютер //Сборник тезисов XXII Съезда Физиологического общества им. И.П. Павлова. М., 2013. С. 38
10. Frolov A. et al. Sources of EEG activity most relevant to performance of brain-computer interface based on motor imagery //Neural Network World, 2012. Т. 22. №. 1. С. 21.
11. Delorme A. et al. Independent EEG sources are dipolar //PloS one, 2012. Т. 7. № 2. С. E30135.
12. Grandchamp R. et al. Stability of ICA decomposition across within-subject EEG datasets //Engineering in Medicine and Biology Society (EMBS), 2012 Annual International Conference of the IEEE. IEEE, 2012. С. 6735-6739.
13. Таротин И.В., Иваницкий Г.А. Ритмы ЭЭГ, связанные с движением и пространственным мышлением: гомологичны ли они? // Журнал высшей нервной деятельности им. И.П. Павлова, 2014. Т. 64. № 6. С. 1-12.

И.В. ТАРОТИН, Г.А. ИВАНИЦКИЙ

Институт высшей нервной деятельности и нейрофизиологии РАН, Москва
ilya_tarotin@mail.ru

ПОСТРОЕНИЕ МОДЕЛИ МОНИТОРИНГА МЫСЛИ- ТЕЛЬНОЙ ДЕЯТЕЛЬНОСТИ В ПРОСТРАНСТВЕ ПСИХО- ЛОГИЧЕСКИХ ХАРАКТЕРИСТИК

В работе описан новый метод визуализации мыслительного процесса в когнитивном пространстве в реальном времени. Его основная идея заключается в быстром распознавании типов мышления по спектрам электроэнцефалограммы (ЭЭГ) с использованием искусственной нейронной сети – перцептрона. Построение когнитивного пространства основано на одном из методов многомерного шкалирования – алгоритме Сэммона. Разработанная технология будет применена в дальнейшем для исследования процессов мышления в ходе сложной когнитивной деятельности.

Ключевые слова: *ЭЭГ, когнитивное пространство, перцептрон, классификация сигналов.*

I.V. TAROTIN, G.A. IVANITSKY

Institute of Higher Nervous Activity and Neurophysiology of RAS, Moscow
ilya_tarotin@mail.ru

A MODEL FOR COGNITIVE ACTIVITY MONITORING IN A SPACE OF PSYCHOLOGICAL FEATURES

New method of mental activity real-time visualization in the cognitive space was presented. Its main idea is to quickly identify types of thinking using EEG spectra with the help of artificial neural network (perceptron). Cognitive space construction is based on one of the multidimensional scaling methods (Sammon mapping). The developed technology will be applied in future to study thought processes during complex cognitive activity.

Keywords: *EEG, cognitive space, perceptron, signal classification.*

Введение

Процедуры шкалирования психических явлений проводятся в психологии не один десяток лет, но всегда были основаны на преобразованиях либо результатов опроса испытуемых (субъективное психологическое

шкалирование), либо результатов психофизических (т.е. поведенческих) экспериментов (объективное психологическое шкалирование). В результате таких процедур были получены так называемые когнитивные пространства.

Подход психологического шкалирования основан на предположении о том, что суждения о сходстве или различии между психическими явлениями связаны с положением точек, их отображающих, в пространстве. Чем более сходны между собой психические явления, тем ближе друг к другу в пространстве расположены представляющие их точки, и наоборот.

Субъективное пространство ощущений тщательно изучалось в психофизике и получило название сенсорного пространства [1-5]. Шкалирование на основе опросов проводилось, например, в [6]. В работах [7-8] когнитивное пространство было впервые получено на основе многомерного шкалирования данных электрической активности мозга человека.

Из современных работ по картированию состояний психики следует отметить работу, выполненную с использованием фМРТ [9]. В этой работе проведено картирование зон активации мозга при просмотре видеоклипов. Характерные зоны активации, соответствующие разным категориям видеоряда (например, люди, животные, ведра и т.д.), выделены с помощью последовательности статистических процедур. Затем зоны корковой активации были поставлены в соответствие семантическому дереву, что позволило откартировать на коре больших полушарий мозга семантические понятия.

Настоящая работа является продолжением исследований Г.А. Иваницкого и А.О. Роик [7-8, 10]. Исследования Г.А. Иваницкого посвящены распознаванию типов мышления по ЭЭГ в режиме off-line, то есть с помощью обработки сигнала ЭЭГ после проведения экспериментов. А.О. Роик была проведена работа по построению пространства психологических характеристик – когнитивного пространства, в котором когнитивные состояния, соответствующие решению разных типов задач, отображены на плоскость. Настоящее исследование объединяет два вышеописанных подхода, что позволяет, опираясь на поступающие в реальном времени данные ЭЭГ, отслеживать ход мыслительной деятельности человека.

Итак, целью работы является создание новой технологии визуализации мыслительного процесса на основе анализа электрической активности головного мозга в реальном времени.

Описание алгоритма

Процесс обработки поступающей ЭЭГ можно разделить на три этапа:

- 1) обучение классификатора – перцептрона – по спектрам мощности ЭЭГ;
- 2) построение когнитивного пространства с помощью картирования Сэммона;
- 3) определение положения рабочей точки – текущего когнитивного состояния испытуемого – в реальном времени.

Традиционно в лаборатории ВНД человека производилось распознавание типа решаемых испытуемыми задач по спектрам мощности ЭЭГ [11-12]. В одном из вариантов исследования испытуемым предлагалось для решения 8 типов заданий, по 4 пространственно-образных и вербально-логических, причем уровень пространственности и вербальности разнился, что было показано путем опроса испытуемых. Во время решения задач у испытуемых записывалась ЭЭГ. Всего каждому испытуемому в два этапа предъявлялось по 60 задач каждого типа, то есть всего 480 задач, по 240 за этап. Испытуемый принимал участие в двух этапах исследования, длительностью около полутора часов каждый, которые проводились в разные дни в одинаковых условиях. Предъявлялись пространственно-образные задания следующих видов (рис. 1).




Рис. 1. Примеры задач, предъявляемых испытуемым

1. «Дорожная развязка». В этом задании на экране предъявляется схема обычной дорожной развязки. На ней указаны 4 точки О, А, В, С. Необходимо найти единственно возможный вариант движения из точки О в одну из точек А, В, С согласно указанным на рисунке стрелкам разрешенного направления движения. Данная задача являлась наиболее пространственной как по опросу испытуемых, так и по расположению в когнитивном пространстве (построенному на основе данных ЭЭГ).

2. «Сложная фигура». Необходимо в уме собрать одну из фигур, предъявленных в нижней части экрана, из элементов, представленных в верхней части экрана.

3. «Сечение куба». На экране предъявляется куб с тремя точками на его ребрах. Необходимо в уме построить сечение куба плоскостью, проходящей через указанные три точки, и сопоставить полученную фигуру с одной из предъявленных в нижней части экрана.

4. «Вращение фигур». В этом задании необходимо подобрать к верхней фигуре одну из фигур в нижней части экрана, так чтобы они вместе образовали квадрат. Задача, имеющая наименьший уровень пространственности из всех представленных пространственных задач.

Вербально-логические задания были следующих видов (см. рис. 1):

1. «Петя и Вася». В этом задании требовалось решить логическую задачу. Предъявлялось высказывание, на которое требовалось ответить однозначно либо «да», либо «нет». Наиболее вербальная задача.

2. «Рита и Таня». Отличие этого задания от предыдущего заключается в использовании других имен и ранжировки не по возрасту, а по высоте. Принципиально, данное задание в точности аналогично предыдущему.

3. «Сложное слово». Предъявлялась следующая последовательность символов: последовательность букв, являющаяся началом первого слова; открывающаяся круглая скобка; звездочки в количестве равном числу букв, которые требуется найти; закрывающаяся круглая скобка; последовательность букв, составляющая конец второго слова. Необходимо вместо звездочек подставить буквы, дающие конец первого слова и начало второго слова.

4. «Анаграмма». На экране предъявлялось существительное из 5 или 6 букв, которые были перемешаны в случайном порядке. Испытуемому необходимо было угадать исходное слово.

Задания предъявлялись с помощью программы Presentation – среды разработки сценариев предъявления стимулов. Задания всех видов предъявляли в случайной последовательности. Примеры заданий представлены на рис. 1. В правом верхнем углу для каждой задачи указан символ, которым обозначается соответствующее когнитивное состояние на карте когнитивного пространства.

После прохождения испытуемым первого этапа эксперимента производилось обучение перцептрона, представляющего собой искусственную нейронную сеть без скрытых слоев, подробно описанную в [13] под названием ассоциатор паттернов (Pattern Associator). Обучение проводилось по единичным, соответствующим одиночным четырехсекундным отрезкам ЭЭГ, Фурье-спектрам на всех парах из 8 типов задач с помощью

дельта-правила. Длина окна Фурье преобразования была равна 4,096 с, соответственно, шаг по частоте в спектре был равен 0,244 Гц.

Таким образом, получалось 28 обученных классификаторов. Далее, для построения когнитивного пространства на вход каждого классификатора подавались спектры ЭЭГ заданий, предъявляемых на втором этапе эксперимента. По выходным данным этой процедуры вычислялись проценты правильного распознавания (ППР) для каждой пары задач, которые (за вычетом значения 0,4) играли роль расстояний в методе картирования Сэммона. Этот метод состоит в отображении многомерного пространства расстояний в пространство меньшей размерности (в нашем случае – на плоскость). Для этого производилась минимизация функции ошибки Сэммона E , которая зависит от разности расстояний: заданного (ППР) и варьируемого евклидова расстояния на плоскости. Минимизация производилась методом градиентного спуска с уменьшающимся шагом и задавалась антиградиентом. Таким образом, алгоритм Сэммона подразумевает наилучшее сохранение расстояний между точками при переходе к плоскостной проекции.

$$E = \frac{1}{\sum_{i < j} D_{ij}^*} \cdot \sum_{i < j} \frac{(D_{ij} - D_{ij}^*)^2}{D_{ij}^*}. \quad (1)$$

Здесь D^* – заданные расстояния (в нашем случае – проценты правильного распознавания), D – варьируемые евклидовы расстояния в двумерном пространстве.

Пример когнитивного пространства для одного из испытуемых можно увидеть на рис. 2. Уровень пространственности и вербальности когнитивного состояния и, соответственно, типа задачи, изменяется в соответствии с формой и величиной значка на плоскости: пространственные задания изображены в форме кругов, а вербальные – в форме ромбов, причем размер фигуры определяет степень пространственности или вербальности задания. То есть наибольший круг соответствует наиболее пространственной задаче, наибольший ромб – наиболее вербальной, а между ними находятся промежуточные значения в порядке убывания признака. Так, «дорожная развязка» является наиболее пространственной задачей и изображена большим кругом, а «Петя и Вася» – наиболее вербальной и изображена большим ромбом.

Далее, в виде перемещающейся рабочей точки был реализован алгоритм слежения за ходом мыслительной деятельности. Для этого был разработан следующий новый метод быстрого распознавания между 8-ю типами задач.




Рис. 2. Пример когнитивного пространства для одного из испытуемых

На вход каждого из 28 классификаторов, предварительно обученных так, как описано выше, подавался спектр мощности текущего 4-секундного отрезка ЭЭГ. Длина окна преобразования Фурье при классификации оставалась равной аналогичной величине при обучении, то есть 4,096 с. В результате мы получали 28 чисел со значениями от 0 до 1, с помощью которых мы могли расположить рабочую точку в когнитивном пространстве. Это было сделано следующим образом.

Вначале находились координаты 28-ми «промежуточных» точек (для каждой пары состояний) – число на выходе каждого классификатора делит пропорционально длину отрезка, соединяющего два состояния (рис. 3). Если, например, число на выходе одного из классификаторов равно 0,5, то координаты искомой точки находятся в середине отрезка, соединяющего пару когнитивных состояний, по которым обучен данный классификатор, а если число равно 0, то местонахождение точки совпадает с местонахождением первого состояния. Процесс нахождения точки показан на рис. 3, где число на выходе классификатора для данной пары равно 0,2.

Следующим шагом было определение «стороны» пространства, куда должна быть помещена рабочая точка в текущий момент, то есть вид задач, к которому принадлежит подающаяся на вход текущая задача: пространственный или вербальный. Это производилось с помощью подсчета количества «пространственных» и «вербальных» ответов 16-ти классификаторов между заданиями разного вида. Выбиралась та сторона, к которой было отнесено большее число «промежуточных» точек. Так, если для одного из испытуемых 10 из 16 точек, определенных между парами задач

разных видов, находятся ближе к пространственному состоянию, а 6 – к вербальному, то выбиралась пространственная сторона, на которой и было сосредоточено дальнейшее внимание. В качестве примера, точка на рис. 3 отнесена к пространственному виду.




Рис. 3. Иллюстрация расположения «промежуточной» точки

После определения стороны, выделялись для дальнейшего рассмотрения «промежуточные» точки, вычисленные только между парами данной стороны – всего 6 точек. Точно так же, как при определении стороны плоскости, из выделенных четырех состояний одного вида с использованием «промежуточных» точек было определено наиболее подходящее состояние, т.е. по входящему четырехсекундному отрезку спектра ЭЭГ определялся наиболее вероятный тип решаемой задачи.

Оставалось определить расположение рабочей точки, учитывая, что используемые нами классификаторы не дают строго определенных ответов – на выходе мы получали не строго 0 или 1, но и числа, лежащие в этом отрезке. Координаты рабочей точки были найдены с помощью определения взвешенного среднего шести координат промежуточных точек выделенной стороны: большие веса (равные 2) были отнесены к точкам, определенным между парами задач, включающими ранее выделенное наиболее вероятное состояние (всего 3 пары), а меньшие веса (равные 0,1) – к остальным точкам (2).

$$\mathbf{x}^* = \frac{2 \cdot \sum_{k=1}^3 \mathbf{x}_k + 0,1 \cdot \sum_{k=4}^6 \mathbf{x}_k}{6}. \quad (2)$$

Здесь $\mathbf{x}^*$ – координаты располагаемой в когнитивном пространстве рабочей точки, конечный результат алгоритма, $\mathbf{x}_k$ – координаты промежуточных точек.

Вышеописанный алгоритм был применен к последовательным 4-секундным отрезкам, поступающим на вход классифицирующей системы каждую секунду с перекрытием в 3 секунды (рис. 4). Рабочей точке также было придано свойство инерции, то есть её текущее местоположение учитывало 2 предшествующих. Это было сделано для того, чтобы сгладить её движение по когнитивному пространству.




Рис. 4. Перекрывающиеся эпохи ЭЭГ

В реальной анимированной картине в когнитивном пространстве отображается только одна движущаяся рабочая точка, а на рис. 5 она обозначена крестиком в 4-х положениях при поступлении на вход разных типов задач. В данном примере рабочая точка движется от положения 1 в положение 4, по пути проходя через промежуточные положения 1 и 2. Траектории движения рабочей точки на рисунке 5 обозначены стрелками.

Таким образом, раз в секунду происходило перемещение рабочей точки, что дало возможность в реальном времени наблюдать за ходом мыслительной деятельности. А это, в свою очередь, открывает новое поле для исследования процессов мышления.




Рис. 5. Рабочая точка в когнитивном пространстве

Выводы и дальнейшие планы

Предложен и реализован алгоритм мониторинга мыслительной деятельности в пространстве психологических характеристик. В основе алгоритма лежит использование искусственной нейронной сети для классификации типов мышления по спектрам мощности ЭЭГ.

Разработан новый метод быстрой классификации восьми типов заданий, необходимый для работы системы в реальном времени, а также предложена методика визуализации текущего состояния испытуемого в когнитивном пространстве. Получена анимированная картина движения рабочей точки в когнитивном пространстве по 4-секундным отрезкам спектров мощности ЭЭГ с шагом 1 с.

Реализованная технология будет использована в дальнейших исследованиях. Во-первых, в сотрудничестве с Московским авиационным технологическим институтом (МАТИ) планируется исследовать совмещенную операторскую деятельность. Цель предстоящего исследования – поиск физиологического объяснения разной способности пилотов к эффективному совмещению разнохарактерной деятельности, а также возможностей для повышения ее эффективности. Во-вторых, разработанная система может послужить инструментом повышения эффективности когнитивной деятельности с помощью оптимизации процесса решения заданий, а также помочь снизить негативное влияние человеческого фактора в операторской деятельности.

Список литературы

1. Бардин К.В. Проблема порогов чувствительности и психофизические методы // М.: Наука, 1976.
2. Измайлов Ч.А., Соколов Е.Н., Черноризов А.М. Психофизиология цветового зрения // М.: Изд-во МГУ, 1989.
3. Измайлов Ч.А. Сферическая модель цветоразличения // М.: Изд-во МГУ, 1980.
4. Забродин Ю.М., Лебедев А.Н. // Психифизиология и психофизика. М.: Наука, 1977.
5. Ломов Б.Ф. О взаимосвязи психологии и физиологии в исследовании восприятия // Физиология человека. 1977. Т.3. № 6. С. 951-960.
6. Терехина А.Ю. Многомерное шкалирование в психологии // Психол. журн. Т. 4. № 1. С. 77-88.
7. Roik A.O., Ivanitskii G.A. A Neurophysiological Model of the Cognitive Space // Neuroscience and Behavioral Physiology, 2013. Vol. 43. No. 2. p. 193-199.
8. Roik A. O., Ivanitskii G.A., Ivanitskii A.M. The Human Cognitive Space: Coincidence of Models Constructed on the Basis of Analysis of Brain Rhythms and Psychometric Measurements // Neuroscience and Behavioral Physiology, 2014. V. 44. No. 6. P. 692-701.
9. Huth A.G., Nishimoto S., Vu A.T., Gallant J.L. A Continuous Semantic Space Describes the Representation of Thousands of Object and Action Categories across the Human Brain // Neuron, 2012. V. 76. No. 6. P. 1210-1222.
10. Иваницкий Г.А., Наумов Р.А., Роик А.О., Иваницкий А.М. Как определить, чем занят мозг, по его электрическим потенциалам? Устойчивые паттерны ЭЭГ при выполнении когнитивных заданий // Вопросы искусственного интеллекта, 2008. Т. 1. № 1. С. 93-102.
11. Иваницкий Г.А., Наумов Р.А. Иваницкий А.М. Технология определения типа совершаемой в уме мысленной операции по рисунку электроэнцефалограммы // Технологии живых систем, 2007. Т. 4, № 5-6, С. 20-28.

12. Naumov R.A., Ivanitsky G.A., Ivanitsky A.M. The recognition of mental activity type with EEG during spatial and verbal tasks solving. // International Journal of Psychophysiology, 2008. V. 69. No 3. P. 180.

13. Rumelhart D.E., McClelland J.L., and the PDP research group. Parallel distributed processing // Cambridge, Mass.: MIT Press, 1986.

В.Л. ВВЕДЕНСКИЙ

Национальный исследовательский центр «Курчатовский институт», Москва
victorlvo@yandex.ru

КАК УСРЕДНЯТЬ МАГНИТНЫЕ СИГНАЛЫ МОЗГА

При анализе магнитных сигналов мозга в период, предшествующий спонтанному движению пальца руки, выявлены пики треугольной формы, четко увязанные по времени с моментом движения, происходящего на 700 мсек позже пика. Амплитуда пика сильно меняется от движения к движению, что позволяет выделить группы событий, в которых мозг ведет себя по-разному при планировании и осуществлении одного и того же действия. Разделение на группы выявляет и другие процессы, в мозге идущие в период подготовки движения.

Ключевые слова: *магнитоэнцефалография, произвольное движение, усреднение сигналов.*

V.L. VVEDENSKY

National Research Centre "Kurchatov Institute", Moscow
victorlvo@yandex.ru

AVERAGING OF THE BRAIN MAGNETIC SIGNALS

We observe in MEG records triangular peaks, which precede for about 700 ms the instant of the self-paced finger movement. Amplitude of the peak varies considerably from trial to trial. This makes possible separation of trials into groups, where the brain behaves differently during planning and execution of the same action. Separation into groups reveals other processes, active in the cortex before voluntary movement.

Keywords: *MEG, voluntary movement, averaging of MEG signals.*

Введение

Уже в течение ряда лет в Центре нейрокогнитивных исследований Московского городского психолого-педагогического университета (МГППУ) под руководством проф. Т.А. Строгановой ведутся измерения магнитных сигналов мозга для решения различных задач в области медицины и исследования человека. Применяется 306-канальный нейромагнитометр Elekta Neuromag MEG system в магнитно-экранированной комнате. Качество сигналов, получаемых с помощью этого прибора, очень высокое, даже в сравнении с однотипными нейромагнитометрами, работающими в других лабораториях мира. Богатый накопленный материал показывает, что возможности этого прибора выходят за рамки методик, разработанных для проведения нейрофизиологических экспериментов с использованием других типов измерительных приборов. Сравнение данных магнитных измерений (MEG) с результатами, полученными при похожих измерениях на электроэнцефалографах (EEG) или магнитно-резонансных томографах (fMRT) показывает, что МЭГ демонстрирует куда более высокую четкость и разнообразие пространственно-временной структуры сигналов [1, 2]. При оценке различных методик проведения нейрофизиологических измерений следует иметь в виду, что практически всегда применяется многократное повторение (сто и более раз) одного и того же либо внешнего стимула, либо стереотипного действия самого испытуемого. Результатом эксперимента становится сигнал (или сигналы), получаемый усреднением всего множества реакций мозга на отдельные одинаковые события. Свойства этого усредненного сигнала и изучаются, главным образом анализируются изменения некоторых его составляющих при варьировании условий проведения эксперимента.

В основе такого подхода лежит не всегда обоснованное предположение, что реакция мозга на стимул одинакова при каждом из однотипных событий, причем генерируемый сигнал существенно слабее, чем разнообразные шумы, не имеющие отношения к исследуемому процессу. Неявно присутствует и другое предположение, что “мешающие” сигналы имеют чисто шумовую природу, и при большом числе усреднений просто взаимно компенсируются, а не порождают сигнал с какими-либо странными свойствами. Несмотря на зыбкость такого разложения на строго повторяющийся исследуемый сигнал и математически стабильный шум, этот подход является стандартно рекомендуемым для всех исследований, использующих ЭЭГ [3]. Такой же методике следуют и в экспериментах, использующих функциональную магнитную томографию (fMRT). Измерения магнитной активности мозга с помощью МЭГ поставили под сомне-

ние безусловную применимость традиционного метода простого усреднения (“догма ЭЭГ”) для извлечения сигналов мозга человека из записей МЭГ [4]. Невозможно рассматривать текущую активность мозга, вроде и не имеющую отношения к изучаемому процессу, как математически чистый шум. Поведение множества нейронов мозга в период, предшествующий внешнему стимулу или собственному действию, заметно влияет на вид сигнала, порождаемого исследуемым участком коры при конкретном событии. Кроме того, изучаемый сигнал совсем не обязательно мал, в отдельных событиях он доминирует в общей активности коры [1, 2]. Стандартный электрод ЭЭГ, закрепленный на поверхности головы, чувствителен к активности больших участков коры мозга и не может выделить тонкие различия между сигналами, получаемыми в каждом отдельном событии. Достаточно острая направленность и избирательность магнитного датчика наоборот, позволяет детально анализировать различия в поведении нейронных ансамблей на небольших участках коры в каждом отдельном событии. Это позволяет изучать процессы в мозге, используя информацию, содержащуюся в полном наборе данных накопленных в ряду событий, а не только работать со средними значениями этих сигналов.

В этой работе мы рассматриваем поведение магнитных сигналов мозга в течение секунды, предшествующей поднятию пальца руки по желанию испытуемого. Известны два типа сигналов, которые характеризуют подготовку мозга к выполнению действия. Это электрический потенциал или магнитное поле готовности (*Bereitschaft potential*) [5], плавно возрастающие в течение секунды до начала движения. Часто наблюдается и предшествующая повышенная активность в альфа и бета диапазонах частот (около 10 и 20 Гц), которая подавляется перед выполнением действия [6]. Нашей целью было обнаружение сигналов с другим поведением. Анализировалось каждое отдельное событие в предшествующий движению период времени.

Эксперимент

Измерения были проведены проф. Т.А. Строгановой и А.О. Прокофьевым с помощью 306-канального нейромагнитометра Elekta Neuromag MEG system. В экспериментах приняли участие 8 испытуемых обоего пола в возрасте 20-30 лет. Сидя в экранированной комнате, испытуемые раз в две-три секунды по своему желанию резко поднимали вверх указательный палец правой руки, лежащей на подушечке как на мышке компьютера. Нейромагнитометр в виде шлема регистрировал 204 градиента магнитного поля в 102 точках вокруг головы. На всех сенсорах определялся

временной ход сигнала, причем особое внимание уделялось промежутку времени в 1 с, предшествующему моменту быстрой фазы движения пальца. Этот момент с высокой точностью определялся по пику ускорения акселерометра прикрепленного к пальцу. Усреднение проводилось для сигнала, измеренного в полосе частот 0,1–300 Гц. Широкая полоса использовалась для того, чтобы не вносить искажений в форму получаемых сигналов – особенно нас интересовали пики треугольной формы, которые регулярно наблюдаются при разных типах нейромагнитных измерений. Ими часто пренебрегают, полагая, что это следствие внешних помех. Просматривая записи, мы выбирали такие, где имелись острые треугольные пики в период времени предшествующий движению пальца. Наличие коррелированного сигнала заостренной формы на паре сенсоров и отсутствие его на остальных указывает на то, что этот сигнал порожден активностью части мозга, лежащей под сенсорами, принимающими сигнал, а источник пика находится практически сразу под костью черепа между этими соседними сенсорами.

Результаты

У четырех испытуемых наблюдались четкие пики на паре соседних сенсоров, причем в других местах их не было видно. У одного из них такая пара обнаружена и в правом, и в левом полушариях. Пример записи показан на рис. 1. Само наблюдение заостренной формы сигнала на кривых, полученных усреднением по более чем ста событиям, причем в период, когда никакого движения еще не было, указывает на чрезвычайно жесткую привязку процесса, отраженного в этом МЭГ-пике, с моментом движения, которое произойдет существенно позже (на 700 мс). Это значит, что движению пальца предшествует измеримый управляющий импульс в коре, запускающий цепь событий строго определенной длительности, причем точное «время задержки» настроено на активную фазу движения, а не на подготовительную активацию мышц. Чтобы детально разобраться в течении процесса, мы анализировали по отдельности каждое из событий. Интересующий нас сигнал, показанный в окошке на рис. 1, имеет характерную форму и представляет собой многомерный вектор.

Для каждого из событий можно определить проекцию реально измеренного сигнала в этот промежуток времени на вектор среднего сигнала. Это дает для каждого события амплитуду составляющей, конгруэнтной среднему сигналу. Результат показан на верхнем графике рис. 1.




Рис. 1. Внизу – магнитные сигналы на двух соседних сенсорах 28 и 69 за секунду до и после быстрого движения пальца руки по желанию испытуемого. Показаны сигналы, усредненные по 147 событиям, вертикальный масштаб 4 фТ/см. Окошками выделены характерные треугольные пики, генерируемые мозгом задолго до самого движения. Положение сенсоров показано на схеме, крестик обозначает вертекс, нос слева. Пунктиром обозначено примерное положение центральной борозды, где расположена сенсомоторная кора. На верхнем графике точки соответствуют отдельным событиям. Для каждого вычислена амплитуда составляющей имеющей форму пика, показанного в окошке. По одной оси отложена амплитуда на сенсоре 69, по другой – на сенсоре 28. Линия тренда показывает, что амплитуда пиков меняется на соседних сенсорах согласованно. Множество событий разбито на три группы: высокая амплитуда – кружки вверх, область промежуточных значений – треугольники вокруг средней белой точки, и кружки вниз, в области отрицательных значений

Мы обнаруживаем, что при некоторых движениях пальца амплитуда пика может многократно превышать среднее значение, причем может иметь и обратный знак. Это представляется странным, поэтому мы постарались установить причину столь высоких амплитуд. Для этого все множество событий было разбито на три группы: с высокой амплитудой пика,

с близкой к среднему значению амплитудой и с отрицательной амплитудой (см. рис. 1). Для каждой из групп можно определить средний сигнал, результат показан на рис. 2.




Рис. 2. Усредненные сигналы на сенсоре 69 для разных групп событий показанных на рис. 1. Движение происходит в момент, обозначенный вертикальной линией. Ave147 – сигнал, усредненный по всем событиям. Mid75 – сигнал, усредненный по 75 событиям, когда амплитуда пика, показанного в малом окне, близка к среднему значению. Видно, что он незначительно отличается от Ave147. Сигнал High36 получен усреднением по 36 событиям, когда амплитуда пика высока. Оказывается, что в этом случае усреднение дает пуг колебаний характерной формы, показанный в большом окне. Сигнал Low36 получен усреднением по событиям с отрицательной амплитудой и является практически инверсией сигнала High36. В результирующем сигнале Ave147 составляющие High36 и Low36 хорошо компенсируют друг друга

Оказывается, что усреднение 75 сигналов с небольшой амплитудой пика дает результат, практически идентичный усреднению по всем 147 событиям. Однако группа из 36 событий с высокой амплитудой при ус-

реднении вскрывает существование характерного цуга колебаний, почти идеально синхронизированного с уединенным пиком, наблюдаемым на Ave147. Если просматривать индивидуальные записи магнитометра, то сигнал такой формы виден даже при отдельном движении пальца.

У трех других испытуемых тоже регистрировались пики на паре сенсоров примерно за 700 мсек до поднятия пальца, только вид выявленного цуга колебаний был свой для каждого из них. Встречались веретенообразные последовательности из пяти треугольных пиков, четко привязанные по фазе к уединенному пику, аналогичному наблюдаемому на Ave147. Для одного испытуемого расстояние между пиками составляло 92 мс, для другого – 54 мс. Это соответственно альфа и бета диапазоны. У двоих наблюдался медленно меняющийся сигнал с ростом амплитуды перед моментом пика и с последующим падением, общей длительностью около 400 мс.

Сейчас мы не можем утверждать, что у других испытуемых это явление отсутствует, так как есть много причин, по которым такие сигналы у них было трудно обнаружить. Они могли быть слабыми, их источники могли находиться на участках коры не дающих магнитного поля, и их можно было пропустить при анализе, если пик регистрировался только на одном сенсоре. Однако сам факт наблюдения сразу двух процессов (уединенного пика и цуга колебаний или медленной волны), четко увязанных по времени с осуществляемым заметно позднее движением, указывает на несомненную важность наблюдения этих сигналов предвосхищающих действие. Характерные пики МЭГ, предшествующие произвольным движениям глаз человека – саккадам, наблюдались ранее [7], однако существенно менее четко, чем в этой работе. Несомненно, что подготовка и осуществление движения глаз и пальцев происходят по-разному, что мы и наблюдаем, но у этих процессов много общего.

Обсуждение результатов

Интерес к изучению процессов в мозге человека, которые формируют произвольное движение, стимулируется разработкой интерфейсов мозг-компьютер для целей протезирования и управления внешними устройствами. Достаточно четкие сигналы от мозга могут быть получены с помощью кортикографии [8, 9] и МЭГ [10], однако до сих пор ясной картины процессов предшествующих движению нет. Вероятной причиной отсутствия модели явления может быть то, что к исполняемому движению ведет отнюдь не единственная цепь (или сеть) процессов в коре мозга. В

зависимости от текущего состояния может реализовываться несколько разных последовательностей срабатывания групп нейронов в коре [11, 12], причем все они будут приводить к одному результату. Именно это и наблюдается в настоящей работе – характерный четкий цуг колебаний альфа или бета диапазонов частот присутствует только в некоторых (примерно четверть) из событий. В остальных случаях имеется другая комбинация процессов. Важно то, что выявленные пики и цуги колебаний имеют характерный вид и могут распознаваться в потоке энцефалограммы в реальном масштабе времени. Такие колебания, появляющиеся и исчезающие в период времени, предшествующий движению, вероятно и являются сигналами, которые уже применяются для интерфейсов мозг-компьютер, разрабатываемых опытным путем. В разных событиях эти четкие сигналы различны, – поэтому проблему пытаются решить, классифицируя такие сигналы. Наиболее аккуратное управление внешним устройством – рукой робота, достигается использованием многих электродов введенных сразу в несколько областей мозга обезьяны [13]. Авторы утверждают, что подготовка и исполнение движения ведется в ансамбле нейронных сетей, «рассыпанных» по лобным и височным отделам мозга обезьяны. Похоже, именно это наблюдается в наших экспериментах, которые проводятся с людьми и в условиях высокого комфорта для испытуемых. Как и в работах [11, 12], мы видим, что имеется целый набор сценариев с разной последовательностью активации участков мозга и с разными временными ходами отдельных процессов, причем каждый сценарий заканчивается одним и тем же результатом – движением пальца. Вряд ли детали подобного «нестабильного» процесса у человека можно увидеть сейчас каким-либо другим экспериментальным методом, кроме МЭГ высокого качества. Столь сильная вариабельность сигналов обычно трактуется как шум, от которого нужно тщательно избавиться, но такой подход грозит «выплеснуть и ребенка».

Важным наблюдением является то, что в период подготовки произвольного движения среди других сигналов наблюдаются острые уединенные пики, четко увязанные по времени с движением, которое произойдет существенно позже. Такие явления лучше всего претендуют на роль синхронизаторов разных других процессов, подготавливающих движение по желанию человека. Мы видим, что у разных испытуемых такие «выстрелы» происходят у каждого в своем месте, или даже в нескольких местах. Отметим, что и в других наших экспериментах подобные острые треугольные пики встречаются часто. Можно полагать, что они играют существенно роль в организации сложных действий организма, когда не-

обходима точная временная привязка активности многих областей в коре мозга, вовлеченных в единый процесс. Острые пики могут лучше и быстрее выполнять синхронизацию, чем фазовые соотношения между разными ритмическими процессами.

Заключение

Магнитная энцефалография высокого качества позволяет аккуратно выделять различные составляющие цепи нейронных процессов в мозге человека, подготавливающей определенное действие. С помощью МЭГ удастся установить, что имеется несколько вариантов таких последовательностей, ведущих к одной и той же цели. Этот результат позволяет по-иному взглянуть на то множество сигналов мозга, которое обычно трактуется как шум, а реально дает ценную информацию о процессах управления в нервной системе. Использование МЭГ может существенно продвинуть вперед разработку эффективных вариантов интерфейса мозг-компьютер.

Автор глубоко признателен Т.А. Строгановой и А.О. Прокофьеву за высокое качество проведенных измерений, находящихся на высшем мировом уровне.

Список литературы

1. Введенский В.Л. Высокая четкость магнитных сигналов коры головного мозга человека // Нейроинформатика-2014: XVI Всероссийская научно-техническая конференция. Лекции по Нейроинформатике. М.: НИЯУ МИФИ, 2014.
2. Vvedensky V.L. Individual trial-to-trial variability of different components of neuromagnetic signals associated with self-paced finger movements // Neuroscience Letters, 2014. V. 569:94-8.
3. Picton T.W., Bentin S., Berg P., Donchin E., Hillyard S.A., Johnson R., Miller G.A., Ritter W., Ruchkin D.S., Rugg M.D., Taylor M.J. Guidelines for using human event-related potentials to study cognition: recording standards and publication criteria // Psychophysiology, 2000. 37:127-152.
4. Gross J.J., Baillet S.S., Barnes G.R., Henson R.N., Hillebrand A., Jensen O., Jerbi K., Litvak V., Maess B., Oostenveld R., Parkkonen L., Taylor J.R., van Wassenhove V., Wibral M., Schoffelen J.M. Good practice for conducting and reporting MEG research // Neuroimage, 2013. 65:349-63.
5. Shibasaki H. and Hallett M., What is the Bereitschaftspotential? // Clinical Neurophysiology, 2006. V. 117. No. 11. 2341–2356.

6. Pfurtscheller G., da Silva F.H.L. Event-related EEG/MEG synchronization and desynchronization: basic principles // *Clinical Neurophysiology*, 1999. V. 110. No.11, 1842–1857.
7. Ioannides A.A., Fenwick P.B.C., Liu L. Widely distributed magnetoencephalography spikes related to the planning and execution of human saccades // *J. Neurosci*, 2005. 25 (35) 7950-7967.
8. Wang Z., Gunduz A., Brunner P., Ritaccio A. L., Ji Q., Schalk G. Decoding onset and direction of movements using electrocorticographic (ECoG) signals in humans // *Frontiers in Neuroengineering*, 2012. V. 5, article 15.
9. Ryun S., Kim J.S., Lee S.H., Jeong S, Kim S.-P. and Chung C.K. Movement type prediction before its onset using signals from prefrontal area: An electrocorticography study // *BioMed Research International*, Volume 2014, Article ID 783203, 9 pages, <http://dx.doi.org/10.1155/2014/783203>.
10. Buch E., Weber C., Cohen L.G., Braun C., Dimyan M.A., Ard T., Mellinger J., Caria A., Soekadar S., Fourkas A., Birbaumer N. Think to move: a neuromagnetic brain-computer interface (BCI) system for chronic stroke // *Stroke*, 2008. 39:910-917.
11. Liu L., Ioannides A.A. A correlation study of averaged and single trials MEG signals: the average describes multiple histories each in a different set of single trials // *Brain Topogr.* 1996. V. 8. P. 385–396.
12. Laskaris N.A., Liu L.C., Ioannides A.A. Single-trial variability in early visual neuromagnetic responses: an explorative study based on the regional activation contributing to the N70m peak // *NeuroImage*, 2003. V. 20, 765–783.
13. Carmena J.M., Lebedev M.A., Crist R.E., O'Doherty J.E., Santucci D.M., et al. (2003) Learning to Control a Brain–Machine Interface for Reaching and Grasping by Primates // *PLoS Biol* 1(2): e42. doi:10.1371/journal.pbio.0000042

Секция 2

Теория нейронных сетей

Ю.С. ПРОСТОВ, Ю.В. ТЮМЕНЦЕВ

Московский авиационный институт
(национальный исследовательский университет)
prostov.yury@yandex.ru, yutium@gmail.com

ИССЛЕДОВАНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ НА БАЗЕ ГИСТЕРЕЗИСНОГО МИКРОАНСАМБЛЯ

Предложена модель нейронного ансамбля, состоящего из частотных нейронов со сложной активационной функцией. Показано, что в таком объединении возникает качественно новое свойство: наличие трёх устойчивых состояний работы (неактивного, полуактивного и активного) с эффектом гистерезиса. Демонстрируется возможность применения ансамбля как распознающего элемента нейронной сети. Проанализирована возможность применения полученных свойств в дальнейших разработках.

Ключевые слова: *эмерджентность, гистерезис, динамическая система, нейросетевое моделирование, адаптивность.*

YU.S. PROSTOV, YU.V. TIUMENTSEV

Moscow Aviation Institute (National Research University)
prostov.yury@yandex.ru, yutium@gmail.com

A STUDY OF NEURAL NETWORK MODEL COMPOSED OF HYSTERESIS MICRO-ENSEMBLES

A model of the neural ensemble consisting of firing-rate neurons with a complex activation function was proposed. It is shown that in such ensemble a new feature emerges, namely existence of three stable states of the model (inactive, half-active and active states) with hysteresis transitions. We demonstrate that the proposed ensemble can be used as a pattern recognition structural element of artificial neural networks. In addition, further usage possibilities are analyzed for the obtained properties of the ensemble.

Keywords: *emergence, hysteresis, dynamic system, artificial neural network, adaptive recognition.*

Введение

В число наиболее актуальных проблем, стоящих сегодня перед научно-техническим сообществом, входит совершенствование интеллектуальных систем управления и поддержки принятия решений. Один из многообещающих подходов к созданию таких систем основан на использовании искусственных нейронных сетей (НС).

Универсальность НС позволяет решать такие важные задачи как распознавание и классификация образов, идентификация систем, аппроксимация функций, прогнозирование процессов и многие другие [1]. Одна из проблем, связанных с реализацией перспективных интеллектуальных систем состоит в том, что требуется обеспечить их адаптивность, т.е. способность оперативно подстраиваться при работе в условиях многочисленных неопределенностей. Существующие НС в своем большинстве не обладают требуемым уровнем адаптивности.

С точки зрения придания НС свойств адаптивности, актуальной является как проблема поиска новых нейросетевых архитектур, так и альтернатив классической модели формального нейрона как композиции сумматора (или другого отображения векторного входа в скалярный выход) и функции активации. В этом направлении интересные результаты были получены при исследовании осцилляторных НС [2] и моделей нейронов, обладающих гистерезисными свойствами [3].

Целью данной работы является исследование свойств так называемого микроансамбля – объединения нейронов, основанных на предложенной в работе [4] модели. Особенностью такого объединения является возникновение режима с тремя устойчивыми состояниями (неактивным, полуживым и активным) и эффекта гистерезиса [5]. В результате такой микроансамбля можно рассматривать как атомарную единицу обработки информации, и в дальнейшем он может быть применён для реализации адаптивной НС [6].

Модель нейрона

В основе рассматриваемой модели лежит идея, высказанная в работе [4], в которой исследуется проблема создания биологически правдоподобной искусственной НС. В настоящей работе требование биологического правдоподобия не выдвигается, а вместо этого, акцент был сделан на потенциальной прикладной значимости получаемой НС. Это позволило упростить модель нейрона, во-первых, отказавшись от некоторых биологически обоснованных переменных, и, во-вторых, заменив оригинальную

Integrate-And-Fire модель её частотным вариантом (*Firing-Rate* моделью), в котором используется зависимость частоты генерации нейроном спайков (далее, частота) от возбуждения. При этом полезные для нашей задачи свойства, которые будут обсуждаться далее, были сохранены. В результате формальное описание модели нейрона приобретает следующий вид:

$$\left\{ \begin{array}{l} \frac{dU_i^{Total}}{dt} = \sum_j v_j \cdot w_{ji} - \mu \cdot U_i^{Total}, \\ P_i = P^0 + \Pi(\langle v_i \rangle), \\ U_i = \frac{U_i^{Total} - P_i}{Q}, \\ v_i = f(U_i), \end{array} \right. \quad (1)$$

где w_{ji} – вес связи от j -го к i -му нейрону, $v_i \in [0;1]$ – частота i -го нейрона, U_i^{Total} и U_i – полный и действительный потенциалы i -го нейрона, P_i – порог i -го нейрона, Q – управляющий параметр сети. Константа μ характеризует скорость убывания полного потенциала. Константа P^0 определяет базовую величину порога, а функция Π – динамическую составляющую, которая зависит от средней частоты нейрона.

Функция активации f (рис. 1) отражает зависимость частоты нейрона от его текущего состояния следующим образом:

$$f(U) = \begin{cases} 1 + \frac{0,35}{U - 2,46} & , \text{ если } U \geq 2,6; \\ 5,2 + 0,23 \cdot \ln\left(\frac{2,6}{U} - 1\right) & , \text{ если } 0 \leq U \leq 2,6; \\ 0 & , \text{ если } U < 0. \end{cases} \quad (2)$$

Модель микроансамбля

Анализ рис. 1 и выражений (1) и (2) показывает, что у такого нейрона может быть только одна точка устойчивого равновесия, положение которой прямо пропорционально зависит от полного потенциала. Однако если рассмотреть ансамбль таких нейронов, то возникает эффект эмерджентности – возникают качественно новые свойства, которыми не обладает отдельно взятый нейрон.




Рис. 1. Вид функции f_v отражающей зависимость частоты нейрона v от действительного потенциала U

Данный вопрос в некоторой степени уже рассматривался в работе [7]. Однако в этой работе используется ещё более упрощённая модель нейрона, а ансамбль исследуется как детектор синхронной активности своих элементов без рассмотрения свойств адаптивности. В противоположность этому, как уже отмечалось выше, наша цель заключается в конструировании и исследовании ансамбля с учётом перспективы реализации адаптивной НС.

Рассмотрим свойства микроансамбля, определив его как множество A_k , состоящее из n нейронов, в котором каждый элемент не имеет замкнутых на себя связей и соединён со всеми другими нейронами одинаковыми связями с весом ω , т.е.: $\forall i \ w_{ii} = 0$ и $\forall i, j \in A_k \ w_{ij} = \omega$, если $i \neq j$.

Для упрощения дальнейшего анализа предположим, что все нейроны микроансамбля A_k имеют топологически и количественно одинаковые внешние связи. Тогда каждый из них будет получать одинаковое внешнее (относительно микроансамбля) возбуждение $G_k = \sum_{j \notin A_k} v_j w_{jk}$, где $j \notin A_k$.

В результате все нейроны микроансамбля A_k будут эквивалентны и для каждого из них справедливо выражение, полученное на основе дифференциального уравнения системы (1):

$$\frac{dU_k^{Total}}{dt} = v_k \cdot V_k + G_k - \mu \cdot U_k^{Total}, \quad (3)$$

где $V_k = (n-1) \cdot \omega$ – возбуждение, получаемое от других нейронов микроансамбля A_k .

Приравнивая правую часть (3) к нулю и используя последние три уравнения из системы (1), мы получим решение в виде следующего равенства:

$$G_k = \mu \cdot (S(v_k) \cdot Q + P_k) - v_k \cdot V_k, \quad (4)$$

где S – функция, обратная f .

На рис. 2 это решение отображено графически с использованием следующих значений параметров: $G_k = 0,5$, $\mu = 0,75$, $P_k = P^0 = 1,01$, $V_k = (n-1) \cdot \omega = 24 \cdot 0,25 = 6$, $Q = \{0,25; 1; 4\}$.

Анализ полученного решения показывает, что для микроансамбля характерно наличие трёх режимов работы, определяемых значениями параметров G_k и Q (рис. 3). В первом, бистабильном режиме (область А), система обладает двумя устойчивыми частотами работы нейронов (кривая a на рис. 2). В двух других режимах существует только одна устойчивая частота, но для одного (область Б) её значение лежит в низкочастотной области, а для другого (область В) – в высокочастотной.




Рис. 2. Графическое решение системы, описывающей упрощённую модель микроансамбля, относительно параметра G при $Q = 1$ (а), $Q = 4$ (б), $Q = 0,25$ (в)

Для дальнейшего анализа введём величину G^* (см. рис. 2 и 3), которая определяет границу между бистабильным и высокочастотным режимом. Далее можно ввести пограничную частоту v^* , которая соответствует величине G^* . Тогда мы можем определить три состояния микроансамбля: неактивное ($v_k = 0$), полуактивное ($0 < v_k < v^*$) и активное ($v_k > v^*$). На практике пограничная частота лежит в пределах 0,2-0,25, а частота полуактивного состояния обычно меньше частоты активного в 6-9 раз.




Рис. 3. Бифуркационная диаграмма относительно параметров G и Q :
 А – область с двумя устойчивыми состояниями; Б – область с одним устойчивым состоянием (полуактивным); В – область с одним устойчивым состоянием (активным)

Наибольший интерес представляет бистабильный режим, так как с ним связаны два полезных свойства, вытекающих из гистерезисной природы полученного решения. Первое свойство состоит том, что состояние микроансамбля сохраняется при переходе в бистабильный режим из любого другого. Второе свойство вытекает из применения первого к бифуркационной диаграмме (рис. 3) и заключается в том, что микроансамбль способен находиться в активном состоянии даже при $G_k = 0$.

Для того чтобы обеспечить переход микроансамбля в неактивное состояние, в системе (1) используется динамическая составляющая порога (функции Π), которая зависит от средней частоты работы ансамбля. В зависимости от вида используемой функции можно контролировать время и условия нахождения микроансамбля в полуактивном и активном состояниях.

Реакция микроансамбля на стимул

Такая модель микроансамбля на практике приводят к тому, что при предъявлении внешнего стимула (паттерна) возникнет возбуждение G_k , которое равно скалярному произведению вектора весовых коэффициентов (эталона) и паттерна. Если эти векторы будут достаточно близки для того, чтобы преодолеть порог G^* , то микроансамбль перейдёт в активное состояние, что соответствует факту распознавания эталона. В противном случае, произойдёт переход в полуактивное состояние, которое можно понимать как состояние неопределённости.

При этом мы можем контролировать через параметр Q степень близости внешнего стимула и эталона, необходимую для активации микроансамбля. Как видно из рис. 3, изменение его значения вызывает повышение или понижение величины порога внешнего возбуждения. Это может быть полезно, например, при появлении шума или неполноты в данных, когда различия с эталонами достаточно велики, чтобы все микроансамбли нейронной сети оставались в состоянии неопределённости. В этом случае мы можем понижать значение Q , пока один из микроансамблей не распознает образ или же мы не достигнем минимально допустимого с точки зрения качества значения параметра.

Важным свойством микроансамбля также является пост-стимульная активность – продолжение работы в активном состоянии после исчезновения внешнего возбуждения, которая возможна при условии $Q < Q^*$ (см. рис. 3). Это свойство позволяет говорить о возможности формирования контекста в нейронной сети, так как данная временная активность служит дополнительным источником информации для создания и использования ассоциативных связей между микроансамблями. В случаях же, когда необходимо сбросить контекст, т.е. прекратить пост-стимульную активность, достаточно увеличить значение параметра Q так, чтобы нарушить условия существования данного эффекта.

Динамика микроансамбля

Для проверки обоснованности выводов было проведено численное моделирование работы микроансамбля, результаты которого приведены на рис. 4. Были использованы следующие параметры модели: $\mu = 0,75$, $P^0 = 1,01$, $V_k = (n-1) \cdot \omega = 10 \cdot 0,60 = 6$. При этом каждый нейрон имел одинаковые фиксированные внешние связи с источником бинарного входного сигнала, а для вычисления динамической составляющей порога использовалась функция $P(x) = 4 \cdot x^3$.

В результате, когда в момент времени t_1 на вход был подан паттерн, отличающийся от эталона на 25 %, микроансамбль перешёл в полуактивный режим работы. Когда же был использован эталонный паттерн (отсечка t_2), микроансамбль стал активным и находился в таком состоянии даже после исчезновения входного сигнала (отсечка t_3). Однако наличие динамического порога привело к тому, что в момент времени t_4 микроансамбль стал неактивным, т.е. произошло так называемое самозапирание.




Рис. 4. Результат моделирования динамики ансамбля

В момент времени t_5 на вход вновь был подан паттерн, отличный от эталона на 25 %, что опять привело к полуактивации. Однако в этот раз постепенно уменьшался параметр Q , что привело к снижению необходимого порога активации, и как результат, к переходу микроансамбля в активный режим (отсечка t_6).

После исчезновения входного сигнала микроансамбль снова остался в активном состоянии. Однако на этот раз была применена техника сброса контекста, т.е. был увеличен параметр Q . В результате в момент времени t_7 микроансамбль перешёл в неактивное состояние.

Полученное поведение подтверждает полученные ранее предположения о динамике функционирования микроансамбля.

Также стоит вспомнить, что микроансамбль является объединением нейронов. В момент времени t_8 на вход был снова подан эталонный паттерн, что привело к активации микроансамбля, а в момент t_9 была смоделирована ситуация, когда на часть из них (50%) подавалось отрицательное возбуждение (торможение), которое не позволяло им находиться в высокочастотном режиме. Это привело к тому, что все нейроны ансамбля через короткое время перешли в полуактивное состояние, несмотря на наличие эталонного паттерна. Это демонстрирует один из возможных механизмов конкуренции между микроансамблями, когда их элементы образуют между собой тормозные связи.

Тестовый пример

Для демонстрации практической применимости предлагаемого подхода была рассмотрена довольно распространённая в области анализа независимых компонент задача «Földiák bars» [8], в которой входные данные представляют собой бинарные изображения размером 8 на 8 пикселей. В качестве образов, которые необходимо научиться распознавать, выступают 8 горизонтальных и 8 вертикальных линий, которые подаются на вход нейронной сети независимо друг от друга с вероятностью 1/8 (рис. 5).




Рис. 5. Примеры входных изображений тестовой задачи

Для решения данной задачи была реализована однослойная нейронная сеть, составленная из 16-и упрощённых микроансамблей с использованием следующих значений параметров: $\mu = 0,75$, $P^0 = 1,01$, $n = 10$, $\omega = 0,25$, $Q = 1$. Кроме возбуждающих связей w^+ , соединяющих вход сети с нейронами микроансамблей, также были использованы латеральные тормозные w^- связи, соединяющие нейроны разных ансамблей по принципу «каждый с каждым».

Для обучения как возбуждающих, так и тормозных связей использовался один из вариантов STDP-правила [9], применимый для *Firing-Rate* нейронов:

$$\begin{cases} \Delta w_{ji}^{+/-} = v_j \cdot v_i \cdot \left(\frac{A_E}{\tau_E^{-1} + v_i} + \frac{A_I}{\tau_I^{-1} + v_i} \right), \\ w_{ji}^+ = w_{ji}^+ + \alpha \cdot \Delta w_{ji}^+, \\ w_{ji}^- = w_{ji}^- + \beta \cdot \Delta w_{ji}^- \end{cases} \quad (5)$$

где $A_E = 1,01$, $\tau_E = 5$, $A_I = -0,58$, $\tau_I = 38$, $\alpha = 0,001$, $\beta = 0,01$, а на значения весов наложены дополнительные ограничения: $w_{ji}^+ = 0$, когда $w_{ji}^+ < 0$ или $i = j$, и $w_{ji}^- = 0$, когда $w_{ji}^- > 0$ или $i = j$. Кроме того, после каждого изменения весов производилась их нормализация, так чтобы $\sum_j w_{ji}^{+/-} = w_{total}^{+/-} \forall i$, где $w_{total}^+ = 2,7$ и $w_{total}^- = 5,4$.

Во время обучения нейронной сети на вход подавались в случайном порядке предварительно сгенерированные изображения, подобные тем, что изображены на рис. 5. Так как модель микроансамбля представляет собой динамическую систему, каждый последующий входной паттерн демонстрировался сети определённый промежуток времени (50 итераций), для того чтобы их состояние стабилизировалось. Общая продолжительность обучения в каждом тесте составляла порядка 25000 итераций.

В результате после обучения описанным способом наличие или отсутствие выученного микроансамблем образа во входном изображении можно установить по среднему значению частоты работы его нейронов: если оно лежит в высокочастотной области, то образ присутствует, иначе – отсутствует. Это демонстрирует рис. 6: каждый из показанных микроансамблей становится активным только в случае присутствия на входе сети выученного ими образа.




Рис. 6. Динамика микроансамблей в процессе распознавания входных паттернов

Выводы

Предложена модель нейронного микроансамбля, обладающего тремя устойчивыми состояниями (неактивным, полуактивным и активным) и эффектом гистерезиса. В результате анализа этой модели показано наличие у неё полезных свойств, которые могут быть использованы для выявления временных связей между образами, а также для повышения робастности нейронной сети к шумам и неполноте данных.

На основе описанного микроансамбля построен пример нейронной сети, подтверждающий работоспособность предлагаемого подхода. Однако в рамках данного примера остался не использованным ряд полезных свойств микроансамбля. Реализация нейронных сетей, использующих эти свойства, является предметом дальнейших исследований.

Список литературы

1. Хайкин С. Нейронные сети: полный курс. – 2-е изд. / Пер. с англ. М.: ИД «Вильямс», 2008.
2. Борисюк Р.М., Чик Д., Казанович Я.Б. Осцилляторная модель зрительного внимания // Нейроинформатика-2010. XII Всероссийская научно-техническая конференция. Сборник научных трудов, Ч. 2. М.: МИФИ. 2010. С. 19–28.
3. Соловьёв А.М., Семёнов М.Е. Искусственные нейронные сети с гистерезисной функцией активации // Нейроинформатика-2014. XVI Всероссийская научно-техническая конференция. Сборник научных трудов, Ч. 1. М.: МИФИ. 2010. С. 19–28.
4. Емельянов-Ярославский Л.Б. Интеллектуальная квазибиологическая система (Индуктивный автомат). М.: Наука. 1990.
5. Красносельский М.А., Покровский А.В. Системы с гистерезисом. М.: Наука. 1983.
6. Простов Ю.С., Тюменцев Ю.В. Мультимодальная ассоциативная нейронная сеть с контекстно-зависимой адаптацией // Авиация и Космонавтика-2013. 12-я Международная конференция. Тезисы докладов. СПб.: Мастерская печати, 2013. С. 618–619.
7. Pchelkin A. Inductive automaton: optimal spike frequency. In Scientific Proceedings of Riga Technical University: Computer Science. Information Technology and Management Science, RTU, Riga, 2003. V. 5.
8. Földiák P. Forming sparse representations by local anti-Hebbian learning // Biological Cybernetics. 1990. Vol. 64. No. 2. P. 165–170.
9. Izhikevich E., Desai N. Relating STDP to BCM // Neural Computations. 2003. V. 15. No. 7. P. 1511–1523.

М.С. ТАРКОВ

Институт физики полупроводников им. А.В. Ржанова СО РАН, Новосибирск
tarkov@isp.nsc.ru

**ОТОБРАЖЕНИЕ МАТРИЦЫ
ВЕСОВЫХ КОЭФФИЦИЕНТОВ СЛОЯ НЕЙРОННОЙ СЕТИ
НА МЕМРИСТОРНЫЙ КРОССБАР**

Рассмотрены вопросы программирования мемристорной матрицы (кроссбара). Получена оценка длительности импульса напряжения для задания требуемого значения сопротивления мемристора исходя из начального значения этого сопротивления. Предложен алгоритм отображения матрицы весовых коэффициентов слоя нейронов на мемристорный кроссбар с учетом заданных граничных значений проводимости мемри-

сторов. Полученные результаты могут быть использованы как при математическом моделировании, так и при физической реализации нейронных сетей с межнейронными связями на мемристорах.

Ключевые слова: *мемристор, сопротивление мемристора, кроссбар, нейронная сеть, матрица весовых коэффициентов.*

M.S. TARKOV

Rzhanov Institute of Semiconductor Physics, Siberian Branch of Russian Academy
of Sciences, Novosibirsk
tarkov@isp.nsc.ru

MAPPING OF NEURAL NETWORK WEIGHTING COEFFICIENTS MATRIX ONTO MEMRISTOR CROSSBAR

The problems of programming for memristor matrix (crossbar) are considered. An estimate for the voltage pulse duration is evaluated to set the required memristor resistance value, basing on the initial resistance value. An algorithm is proposed for mapping neurons layer weighting coefficients matrix onto memristor crossbar with the given memristors conductivity value boundaries. The results can be used both in mathematical modeling, and in the physical realization of neural networks with interneuronal memristor connections.

Keywords: *memristor, memristance, crossbar, neural network, weighting coefficients matrix.*

Введение

Искусственная нейронная сеть обычно использует матрицу весовых коэффициентов для представления множества синапсов слоя нейронов. Соответственно, вычисление активации слоя нейронов можно рассматривать как умножение этой матрицы весов на вектор входных сигналов слоя. Аппаратная реализация нейронной сети требует много памяти для хранения матрицы весов слоя нейронов и является дорогостоящей.

Решение этой проблемы упрощается при использовании в качестве ячейки памяти устройства, называемого мемристором. Мемристор был предсказан теоретически в 1971 году Леоном Чуа [1]. Первую физическую реализацию мемристора продемонстрировала в 2008 году лаборатория фирмы Hewlett Packard в виде тонкопленочной структуры TiO_2 [2]. В России первый мемристор на основе TiO_2 получен в 2012 году в Тюменском

государственном университете [3]. Мемристор имеет много достоинств, таких как энергонезависимость хранения информации, малое потребление энергии, высокая плотность интеграции и замечательная масштабируемость. Уникальная способность сохранять следы возбуждения устройства делает его идеальным кандидатом для реализации синапсов в электронных нейронных сетях [4].

Мемристор

Мемристор ведет себя подобно синапсу: он «запоминает» полный электрический заряд, прошедший через него [5]. Память, основанная на мемристорах, может достигать очень высокой степени интеграции 100 Gbits/cm², в несколько раз более высокой, чем на основе технологии флэш-памяти [6]. Эти уникальные свойства делают мемристор многообещающим устройством для создания массово-параллельных нейроморфных систем [7-9].

Сопротивление мемристора (memristance) (рис. 1) может быть представлено [10] как

$$M(p) = p \cdot R_{on} + (1 - p) \cdot R_{off}, \quad (1)$$

где $0 \leq p \leq 1$ – положение фронта примеси относительно полной толщины h пленки TiO₂, R_{on} – минимальное сопротивление мемристора, R_{off} – максимальное сопротивление мемристора.




Рис. 1. Структура мемристора (D – зона низкого сопротивления, U – зона высокого сопротивления)

Когда на мемристор подается напряжение V выше некоторого порога V_{th} , его сопротивление уменьшается за счет расширения примесной зоны D , имеющей низкое сопротивление, и сокращения зоны U чистого окисла, имеющей высокое сопротивление. Соответственно, сопротивление

мемристора возрастает при подаче напряжения V ниже $-V_{th}$ за счет сокращения зоны D и расширения зоны U . После отключения напряжения текущее сопротивление мемристора сохраняется.

Скорость движения фронта примеси при $V(t) > V_{th}$ (сопротивление мемристора убывает) определяется уравнением

$$\frac{dp}{dt} = \mu_v \cdot \frac{R_{on}}{h^2} \cdot \frac{V(t) - V_{th}}{M(p)}, \quad (2)$$

а при $V(t) < -V_{th}$ – уравнением

$$\frac{dp}{dt} = \mu_v \cdot \frac{R_{on}}{h^2} \cdot \frac{V(t) + V_{th}}{M(p)}. \quad (3)$$

Здесь μ_v – подвижность примеси, h – полная толщина пленки мемристора, $V(t)$ – текущее значения напряжения на мемристоре, V_{th} – пороговое значение напряжения.

Настройка мемристора на требуемый уровень сопротивления M_d зависит от соотношения между M_d и начальным значением M_0 сопротивления мемристора. Настройка осуществляется путем подачи на мемристор в течение отрезка времени τ постоянного напряжения $V > V_{th}$ при $M_0 > M_d$ или напряжения $V < -V_{th}$ при $M_0 < M_d$. Решая совместно уравнения (1) и (2) или (1) и (3), получаем требуемое значение времени

$$\tau = \begin{cases} \frac{M_0^2 - M_d^2}{2k(V - V_{th})}, & V > V_{th}, \\ \frac{M_0^2 - M_d^2}{2k(V + V_{th})}, & V < -V_{th}, \end{cases} \quad (4)$$

где $k = \mu_v \frac{R_{off}}{h^2} (R_{off} - R_{on})$.

Мемристорный кроссбар

На рис. 2 представлен слой нейронов (нейроны обозначены треугольниками) с матрицей весовых коэффициентов на мемристорах, называемой мемристорным кроссбаром, который является типичной структурой мемристорной памяти. Он содержит мемристор на каждом пересечении горизонтальных и вертикальных проводников. Мемристорный кроссбар интересен для реализации матриц соединений в нейронных сетях, поскольку он может обеспечить большое число сигнальных связей и вычислить взвешенную комбинацию входных сигналов. На горизонтальные шины

кроссбара подаются компоненты вектора входных сигналов слоя. Каждая вертикальная шина кроссбара позволяет вычислить активацию для одного из нейронов слоя.




Рис. 2. Слой нейронов с матрицей весов на мемристорах

3. Отображение матрицы весов на мемристорный кроссбар

Интервал изменения весовых коэффициентов конкретной матрицы весов может существенно отличаться от интервала изменения проводимости мемристоров кроссбара. В частности, веса могут иметь разные знаки, в то время как мемристоры кроссбара имеют проводимости одного знака. В работах [11, 12] делается попытка учесть разные знаки весов путем использования двух кроссбаров с разной полярностью используемого напряжения. В работе [13] используется один кроссбар и рассчитывается смещение для обеспечения задания весовых коэффициентов разной полярности. В то же время в этих работах не учитываются ограничения на интервал изменения проводимости мемристоров. Между тем для разных материалов эти интервалы могут сильно различаться. Так, например, в работе [12] используются мемристоры на TiO_2 с параметрами

$$G_{\text{off}} = \frac{1}{R_{\text{off}}} = 5 \cdot 10^{-5} \text{ Ом}^{-1}, \quad G_{\text{on}} = \frac{1}{R_{\text{on}}} = 5 \cdot 10^{-4} \text{ Ом}^{-1}, \quad G_{\text{on}} / G_{\text{off}} \approx 10, \text{ а в рабо-}$$

тах [14, 15] – мемристоры на Ag/a-Si с параметрами $G_{\text{off}} \approx 4 \cdot 10^{-12} \text{ Ом}^{-1}$,

$G_{on} \approx 4 \cdot 10^{-6} \text{ Ом}^{-1}$, $G_{on} / G_{off} \approx 10^6$. Ниже предложен алгоритм, который решает эту проблему.

Пусть требуется вычислить произведение

$$y = w \cdot x, \quad (5)$$

где w – матрица весовых коэффициентов, x – вектор входных сигналов слоя нейронов.

Пусть элементы матрицы весовых коэффициентов удовлетворяют ограничениям

$$w_{\min} \leq w_{ij} \leq w_{\max}, i, j = 1, \dots, n,$$

а проводимость мемристора

$$G_{off} \leq G_m \leq G_{on}.$$

Отображение весовых коэффициентов w_{ij} , $i = 1, \dots, M$, $j = 1, \dots, N$ в проводимости мемристоров задается формулой

$$G_{ij} = \frac{w_{ij} - w_{\min}}{w_{\max} - w_{\min}} (G_{on} - G_{off}) + G_{off}. \quad (6)$$

Задав проводимости мемристоров кроссбара в соответствии с выражением (6), вычисляем на кроссбаре произведение

$$y' = Gx, \quad (7)$$

где G – матрица проводимостей кроссбара.

Из (5)-(7) получаем

$$y = \frac{w_{\max} - w_{\min}}{G_{on} - G_{off}} Gx + \frac{G_{on} w_{\min} - G_{off} w_{\max}}{G_{on} - G_{off}} \sum_{i=1}^N x_i. \quad (8)$$

Итак, из (6)-(8) мы получили следующий алгоритм вычисления произведения (5) на мемристормом кроссбаре:

1. Вычислить величины

$$\Delta_w = \frac{w_{\max} - w_{\min}}{G_{on} - G_{off}}, \quad \Delta_{wG} = \frac{G_{on} w_{\min} - G_{off} w_{\max}}{G_{on} - G_{off}}.$$

2. Вычислить сумму $s = \sum_{i=1}^N x_i$.

3. Вычислить элементы матрицы G по формуле

$$G_{ij} = \frac{w_{ij} - w_{\min}}{\Delta_w} + G_{off}.$$

4. Вычислить $y' = Gx$ на мемристормом кроссбаре.

5. Вычислить результат по формуле $y = \Delta_w \cdot y' + \Delta_{wG} \cdot s$.

В вышеприведенном алгоритме величины G , Δ_w , Δ_{wG} могут быть рассчитаны до начала функционирования нейронной сети. Далее операция $y = wx$ может выполняться многократно согласно схеме рис. 3.




Рис. 3. Схема вычисления $y = wx$ с использованием мемристорного кроссбара

Масштабирование матрицы весов относится к методу обучения нейронной сети *ex situ*, когда все обучение реализуется программно на традиционном компьютере. По окончании обучения вычисленные веса пересчитываются в проводимости мемристоров кроссбаров в соответствии с вышеприведенным алгоритмом. Установка требуемых значений проводимости мемристоров кроссбара может быть реализована путем подачи на мемристор импульса постоянного напряжения заданной величины и заданной длительности (см. формулу (4)).

Заключение

Мемристор (резистор с памятью) представляет собой перспективный элемент для аппаратной реализации синапсов. В данной работе рассмотрены вопросы программирования мемристорных матриц (мемристорных кроссбаров). Получена оценка длительности импульса для задания требуемого значения сопротивления мемристора, исходя из начального значения этого сопротивления. Предложен алгоритм отображения матрицы весовых коэффициентов слоя нейронов на мемристорный кроссбар с учетом заданных граничных значений проводимости мемристоров. Полученные результаты могут быть использованы как при математическом моделировании, так и при физической реализации нейронных сетей с межнейронными связями на мемристорах.

Список литературы

1. Chua L. Memristor – the missing circuit element // IEEE Transactions on Circuit Theory, 1971. V.18. P. 507-519.
2. Strukov D.B., Snider G.S., Stewart D.R., Williams R.S. The missing memristor found // Nature, 2008. V. 453. P.80-83.
3. Мемристор – шаг к искусственному интеллекту. новые разработки ученых ТюмГУ, 26.04.2012. URL: <http://www.utmn.ru/n6468> (доступ 03.10.2014)
4. Pershin Y., Di Ventra M. Experimental demonstration of associative memory with memristive neural networks // Neural Networks, 2010. V. 23. №. 7. P.881-886.
5. Chua L. Resistance switching memories are memristors // Applied Physics A: Materials Science & Processing, 2011. V.102, №. 4. P. 765-783.
6. Ho Y., Huang G.M., Li P. NonVatile memristor memory: device characteristics and design applications // Int. Conf. on Computer-Aided Design (ICCAD), 2009. P. 485-490.
7. Jo S.H., Chang T., Ebong I., Bhadviya B.B., Mazumder P., Lu W. Nanoscale memristor device as synapse in neuromorphic systems // Nanoleters, 2010. V.10, № 4. P. 1297-1301.
8. Kavehei O. Memristive devices and circuits for computing, memory, and neuromorphic applications. PhD thesis. The University of Adelaide, Australia, 2011.
9. Lehtonen E. Memristive computing. University of Turku, Finland, 2012.
10. Wu Q., Liu B., Chen Y., Li H., Chen Q., Qiu Q. Bio-Inspired Computing with Resistive Memories – Models, Architectures and Applications // Proc. of 2014 IEEE International Symposium on Circuits and Systems (ISCAS). P.834-837.
11. Hu M., Li H., Wu Q., Rose G.S. Hardware Realization of BSB Recall Function Using Memristor Crossbar Arrays // DAC 2012, June 3-7, 2012, San Francisco, California, USA. P. 498-503.
12. Alibart F., Zamanidoost E., Strukov D.B. Pattern classification by memristive crossbar circuits using ex situ and in situ training // Nature Communications, 2013. P.1-7.
13. Truong S.N., Min K.-S. New Memristor-Based Crossbar Array Architecture with 50-% Area Reduction and 48-% Power Saving for Matrix-Vector Multiplication of Analog Neuromorphic Computing // Journal of Semiconductor Technology and Science, 2014. V.14. № 3. P. 356-363.
14. Lu W., Kim K.-H., Chang T., Gaba S. Two-Terminal Resistive Switches (Memristors) for Memory and Logic Applications // Proceedings of the 16th Asia and South Pacific Design Automation Conference (ASPDAC '11), 2011. P. 217-223.
15. Taha T.M., Hasan R., Yakopcic C., McLean M.R. Exploring the Design Space of Specialized Multicore Neural Processors // Proc. of Int. Joint Conf. on Neural Networks. Dallas, USA, 2013. P. 2633-2640.

К.А. КУКИН¹, А.Г. СБОЕВ¹, А.Р. СОБИНОВ²

¹Национальный исследовательский центр «Курчатовский институт», Москва

²Московский физико-технический институт (государственный университет)
kukin.konstantin@gmail.com

СРАВНЕНИЕ МЕТОДОВ ОБУЧЕНИЯ СПАЙКОВЫХ НЕЙРОННЫХ СЕТЕЙ НА ОСНОВЕ РАЗЛИЧНЫХ НЕЙРОСИМУЛЯТОРОВ

В работе на основе трех различных нейросимуляторов спайковых нейронных сетей NEST, CSIM, HEM исследуется влияние на процесс обучения следующих факторов: правил долговременной пластичности STDP, правил «спаривания» пресинаптических и постсинаптических спайков (spike pairing scheme) и форм постсинаптических токов нейронов. Также оценивается влияние типа входного сигнала на обучаемость спайковой нейронной сети. Показано, что указанные выше факторы оказывают воздействие как на процесс, так и на результат обучения.

Ключевые слова: *спайковые нейронные сети, методы обучения, нейросимуляторы.*

K.A. KUKIN¹, A.G. SBOEV¹, A.R. SOBINOV²

¹National Research Centre "Kurchatov Institute", Moscow

²The Moscow Institute of Physics and Technology (State University)
kukin.konstantin@gmail.com

COMPARISON OF LEARNING METHODS FOR SPIKING NEURAL NETWORKS USING VARIOUS NEUROSTIMULATORS

An investigation of different factors influence on the learning process were performed using three spiking neural network simulators (NEST, CSIM, HEM). Such factors were analyzed as choice of spike pairing scheme, shapes of postsynaptic currents and choice of input type signal for learning. It is shown these factors influence both learning process and learning result.

Keywords: *spiking neural network, learning methods, neurosimulators.*

Введение

В последнее время отмечен неуклонный рост интереса к спайковым нейронным сетям. С одной стороны, это вызвано развитием техники эксперимента *in vitro*, что позволило изучать нейронные культуры на мульти-электродных матрицах. С другой стороны, развивается направление математического моделирования спайковых нейронных сетей на нейросимуляторах. Вместе с тем методы обучения спайковых нейронных сетей остаются плохо изученными, что делает исследование таких методов актуальной задачей.

Модели спайковых нейронных сетей, как более реалистичные, считаются новым поколением нейронных сетей по отношению к формальным моделям нейронных сетей со статическими элементами [1]. В спайковых нейронных сетях нейрон и синапс являются динамическими объектами, их свойства зависят от времени. Информационное богатство биологически подобных нейронов, синапсов и пластичностей потенциально увеличивает ассоциативные способности спайковых сетей.

Особый интерес представляют попытки использования спайковых нейронных сетей совместно с методами их обучения для решения практических задач: извлечения коррелированных по времени признаков с видеосенсоров [2], монофонического разделения источников звука [3], кластеризации изображений [4] и других подобных задач. Однако, вопросы обучения этих сетей, выделения эффективных обучающих алгоритмов путем сопоставления биологически мотивированных моделей обучения и построенных на основе информационных подходов остаются открытыми, что делает предмет исследования этой работы актуальным как с теоретической точки зрения, так и с практической.

Цель работы заключается в исследовании подходов обучения для разных симуляторов: NEST, CSIM, HEM. В работе изучается влияние на обучение трех типов частотных сигналов (пуассоновского, нормального, равномерного), долговременной пластичности *spike-timing-dependent plasticity* (STDP), формы постсинаптического тока, механизма учета пар спайков в STDP (*spike pairing scheme*). Проведены эксперименты по обучению на основе указанных выше изучаемых факторов и выявлены наиболее пригодные для обучения подходы.

Материалы и методы

Можно выделить три составных элемента спайковой нейронной сети: нейрон, синапс, механизм обучения STDP.

Уравнение динамики мембранного потенциала нейрона leaky integrate-and-fire имеет вид:

$$\frac{dv}{dt} = \frac{v_{resting} - v}{\tau_m} + \frac{I_{syn}(t)}{C_m} + \frac{I_e}{C_m}. \quad (1)$$

Здесь v , C_m – мембранный потенциал, электрическая емкость. Когда v достигает порога v_{th} , происходит генерация импульса (спайка), в течение времени рефрактерности τ_{ref} после спайка значение мембранного потенциала имеет постоянное значение v_{reset} . В отсутствие синаптического тока потенциал на мембране релаксирует к потенциалу $v_{resting}$ за характерное время τ_m . $I_{syn}(t)$ – синаптический ток, I_e – фоновый постоянный стимулирующий ток.

Значения параметров модели нейрона представлены в табл. 1.

Модель синапса выражается уравнениями (5-6) синаптического тока $I_{syn}(t)$, который входит в уравнение нейрона (1). Составляющими частями модели синапса являются:

- модель синаптической пластичности (кратковременная и долговременная, которая определяет динамику синаптического веса в зависимости от активности пресинаптических и постсинаптических нейронов);
- форма постсинаптического сигнала.

Таблица 1

Параметры модели нейрона

Обозначение	Значение	Обозначение	Значение
V	$V(t = 0)$ $= V_{resting}$	I_e	13,5 нА
$V_{resting}$	0 мВ	V_{th}	см. эксперименты
τ_m	30 мс	τ_{ref}	3 мс
C_m	30 нФ	V_{reset}	14,2 мВ

Используется модель кратковременной пластичности Мааса–Маркрама [5], описанная ниже:

$$\begin{cases} u_1 = U, \\ R_1 = 1, \\ u_k = U + u_{k-1}(1 - U)e^{-\frac{\Delta_{k-1}}{F}}, \\ R_k = 1 + (R_{k-1} - u_{k-1}R_{k-1} - 1)e^{-\frac{\Delta_{k-1}}{D}}. \end{cases} \quad (2)$$

Здесь R_k – доля доступных синаптических ресурсов; u_k – доля из доступных ресурсов, которая задействуется при пресинаптическом спайке; F – временная константа восстановления после фасилитации; U – используемая часть синаптических ресурсов для одного спайка; D – временная константа восстановления после депрессии; $\Delta_1, \Delta_2, \dots, \Delta_{k-1}$ – межспайковые интервалы.

Значение параметров модели кратковременной пластичности представлены в табл. 2.

Таблица 2

Параметры модели кратковременной пластичности

Обозначение	Значение
u_k	$u_k(t = 0) = U$
R_k	$R_k(t = 0) = 1$
U	$N^1(0,5; 0,05)$ для возбуждающих $N(0,25; 0,025)$ для тормозящих
D	$N(1100; 110)$ мс для возбуждающих $N(700; 70)$ мс для тормозящих
F	$N(50; 5)$ мс для возбуждающих $N(20; 2)$ мс для тормозящих

Изменение веса записывается через формулу

¹ Обозначение $N(\mu; \sigma)$ означает, что рассматриваемый параметр распределен по нормальному закону распределения с математическим ожиданием μ и стандартным отклонением σ .

$$\Delta w = \begin{cases} w_- e^{-\frac{t_{pre}-t_{post}}{\tau_-}}, & t_{pre} - t_{post} > 0, \\ w_+ e^{-\frac{t_{post}-t_{pre}}{\tau_+}}, & t_{pre} - t_{post} < 0, \end{cases} \quad (3)$$

где t_{pre} – момент испускания спайка пресинаптическим нейроном, t_{post} – момент испускания спайка постсинаптическим нейроном, w_- – коэффициент, отражающий уменьшение веса, w_+ – коэффициент, отражающий увеличение веса, τ_- – характерное время влияния пресинаптического спайка, τ_+ – характерное время влияния постсинаптического спайка.

Если полученное значение веса меньше (больше) минимально (максимально) допустимого W_{min} (W_{max}), то w присваивается значение W_{min} (W_{max}).

В симуляторе НЕМ используется такая же долговременная пластичность (3). На основе анализа исходного кода было выявлено, что в CSIM используется следующая модель STDP:

$$\Delta w = \begin{cases} w_- e^{-\frac{t_{pre}-t_{post}}{\tau_-}}, & t_{pre} - t_{post} > 0 \text{ и } (t_{pre} - t_{post}) \in [T_{min}, T_{max}] \\ 0, & t_{pre} - t_{post} > 0 \text{ и } (t_{pre} - t_{post}) \notin [T_{min}, T_{max}] \\ w_+ e^{-\frac{t_{post}-t_{pre}}{\tau_+}}, & t_{pre} - t_{post} < 0 \text{ и } (t_{post} - t_{pre}) \in [T_{min}, T_{max}] \\ 0, & t_{pre} - t_{post} < 0 \text{ и } (t_{post} - t_{pre}) \notin [T_{min}, T_{max}]. \end{cases} \quad (4)$$

Здесь $T_{min} = 2$ мс, $T_{max} = 60$ мс. Значения параметров модели долговременной пластичности представлены в табл. 3.

Таблица 3

Параметры модели долговременной пластичности

Обозначение	Значение	Обозначение	Значение
w_+	0,3	τ_-	20 мс
w_-	-0,3105	W_{min}	0
τ_+	20 мс	W_{max}	$N^1(54; 10,8; 21,6; 86,4)$

¹ Обозначение $N(\mu; \sigma; a; b)$ означает, что рассматриваемый параметр распределен по нормальному закону распределения с математическим ожиданием μ и стандартным отклонением σ и ограничен интервалом $[a, b]$. В симуляторах NEST и CSIM при реализации случайного значения меньше a (больше b) выбирается $a(b)$; в симуляторе НЕМ в аналогичном случае реализуется новое случайное значение, пока оно не попадет в интервал.

Известно, что существуют различные схемы учета спайков (spike pairing schemes) [7], представленные на рис. 1.

В NEST и НЕМ используется схема “А”, подобную информацию для CSIM найти не удалось.

В работе используется две формы постсинаптического сигнала: экспоненциальная и в виде α -функции. Синапс используется с кратковременной и долговременной пластичностями, описанными выше. Уравнение экспоненциальной формы постсинаптического сигнала:

$$I_{syn}(t) = \sum_{j \in S} \sum_{t_{sp}} w_j(t_{sp}) u_j(t_{sp}) R_j(t_{sp}) \frac{q_j}{\tau_j} e^{-\frac{t-t_{sp}-t_d}{\tau_j}} H(t - t_{sp} - t_d). \quad (5)$$

Здесь S -множество синапсов, входящих в данный нейрон; w_j – синаптический вес j -го синапса; t_{sp} – время возникновения спайка на пресинаптическом нейроне; t_d – задержка на распространение спайка от нейрона к нейрону (в NEST 0.1 мс, в НЕМ и CSIM – 0 мс); τ_j – характерное время убывания синаптического тока j -го синапса; q_j – заряд, который добавляется к постсинаптическому нейрону при испускании спайка пресинаптическим нейроном; соответственно. $H(t)$ – функция Хевисайда. u_j, R_j задаются уравнением (2). Величина q_j для возбуждающих (тормозящих) синапсов составляет 3 пКл (6 пКл). Значение τ_j для возбуждающих (тормозящих) синапсов составляет 3 мс (6 мс).

Уравнение формы постсинаптического сигнала в виде α -функции

$$\begin{cases} I_{syn}(t) = \sum_{j \in S} \sum_{t_{sp}} w_j(t_{sp}) u_j(t_{sp}) R_j(t_{sp}) \frac{q_j}{\tau_j} \alpha_j(t - t_{sp} - t_d), \\ \alpha_j(t) = \frac{t}{\tau_j} e^{-\frac{t}{\tau_j}} H(t). \end{cases} \quad (6)$$

В работе использовались три нейросимулятора: NEST [8], CSIM [9], НЕМ [10].

NEST является симулятором для больших гетерогенных сетей. NEST хорошо подходит для моделей, которые фокусируются на динамике, размере и структуре нейронных систем, а не на морфологических или биоло-




Рис 1. Примеры spike pairing schemes (рисунок взят из [7])

гических свойствах отдельного нейрона. Использует возможность параллелизма на основе MPI и OpenMP. Исходная версия NEST была доработана для возможности использования других механизмов обучения.

CSIM является инструментом для моделирования гетерогенных сетей, состоящих из различных моделей нейронов и синапсов.

HEM – открытый программный пакет, написанный на Python и C++. Он позволяет моделировать гетерогенные спайковые нейронные сети с полным функциональным контролем симуляции.

Описание методики эксперимента

Методика эксперимента впервые описана в статье [11]. Целью данного эксперимента являлось изучение общей сходимости процесса обучения. Сходимость оценивалась двумя способами: по сходимости к целевым синаптическим весам и по корреляции выходных сигналов.

Нейронная сеть состоит из одного нейрона, к которому подсоединяются 100 синапсов: 90 возбуждающих, 10 тормозящих. Возбуждающие синапсы описываются уравнениями кратковременной пластичности (2) и долговременной пластичности (уравнением (3) для NEST, HEM и уравнением (4) для CSIM), тормозящие синапсы моделируются уравнением (2). Нейрон моделируется уравнением (1).

Рассмотрим этапы эксперимента.

1. *Этап выбора максимальных значений весов возбуждающих синапсов.* Для каждого возбуждающего синапса генерируются вектор максимальных значений весов $\vec{W}_{max}$ из их нормального распределения со средним значением 54 и стандартным отклонением $sd = 10,8$, ограниченных в пределах $54 \pm 3sd$. Значения весов меньше чем 21,6 (больше 86,4) заменяются на 21,6(86,4) (см. табл. 3).

2. *Этап выбора целевых весов возбуждающих синапсов.* Случайным образом выбирается одна половина из множества возбуждающих синапсов, и целевые веса для этой половины полагаются равными максимальным значениям весов, полученных по результатам этапа 1. У оставшейся половины возбуждающих синапсов значения целевых весов устанавливаются равными нулю. К полученному вектору целевых весов $\vec{W}_{target}$ должны сходиться веса в результате обучения. Веса у тормозящих синапсов полагаются равными -54, и они остаются постоянными на каждом этапе эксперимента.

3. *Этап генерации входного сигнала.* Для трех возможных типов сигналов (пуассоновского, с нормальным распределением межспайкового

интервала, равномерного) генерируются независимая последовательность сигналов $S_{in}^i (i = 1, 2, \dots, 100)$ для каждого из 100 входов. Для каждого эксперимента используется последовательность сигналов только одного типа. Последовательности $\vec{S}_{in}$ генерируются с частотой 20 Гц в течение 3000 с. В дальнейшем полученные последовательности используются в процессе обучения.

4. *Этап настройки параметра порогового значения потенциала.* При заданном входном сигнале $\vec{S}_{in}$ для генерации выходного сигнала частотой 25 Гц подбирается необходимое значение порогового потенциала нейрона v_{th} .

5. *Этап получения подкрепляющего сигнала.* На этом этапе получают выходной сигнал при входном сигнале $\vec{S}_{in}$ и целевых весах $\vec{W}_{target}$. В дальнейшем этот сигнал используется как подкрепляющий в процессе обучения. Полученная последовательность подкрепляющих сигналов $\vec{S}_+$ далее используется в процессе обучения в форме импульсов тока 1 мкА прямоугольного вида длительностью 0,2 мс. Изменение весов с помощью механизма STDP на этом этапе отключено.

6. *Этап обучения.* Случайным образом выбираются начальные значения весов возбуждающих синапсов на основе гамма распределения со средним значением 9 и стандартным отклонением 6,3. В процессе обучения подается входной сигнал $\vec{S}_{in}$ и подкрепляющий сигнал $\vec{S}_+$. Процесс обучения происходит 3000 с.

В табл. 4 представлены значения порогового потенциала нейрона, полученного из условия, что при входном сигнале с частотой 20 Гц получается выходной сигнал с частотой 25 Гц (для CSIM и NEST). Для симулятора НЕМ входная частота была 10 Гц, выходная – 25 Гц.

Таблица 4

Значение подобранного порога нейрона (мВ) на этапе 4

Симулятор	NEST		HEM	CSIM
Форма постсинаптического тока	exp ¹	α	exp	exp
Тип входного сигнала				
Пуассоновский	15,7	15,6	17,5	-
Нормальный	15,9	15,8	18,7	-
Равномерный	15,7	15,7	17,5	15,1

¹ exp, α означают форму постсинаптического тока, описанную в уравнениях (5), (6) соответственно.

Для оценки сходимости весов к целевым весам был введен параметр $\beta(t)$:

$$\beta(t) = \frac{\sum_{i=1}^{90} |w_i(t) - w_i^{target}|}{\sum_{i=1}^{90} w_i^{target}}, \quad (7)$$

где $\vec{W}(t)$ – вектор значений возбуждающих весов в момент времени t . Суммирование происходит только по весам возбуждающих синапсов, так как только они изменяются в процессе обучения.

Результаты

Как показывают результаты численных экспериментов на симуляторах NEST и NEM с исходными настройками и параметрами, указанными в разделах “Материалы и методы” и “Описание методики эксперимента”, обучения в этом случае не происходит, веса не сходятся к целевым, а параметр $\beta(t)$ стремится к 1.

Симулятор CSIM продемонстрировал наличие обучения, параметр сходимости β после обучения равняется 0,03 (табл. 5).

Замена правила STDP с (3) на (4) в симуляторе NEM при неизменной схеме учета спайков “А” также приводит к наличию обучения при частоте входного сигнала 10 Гц (табл. 5) на этапе 3.

В NEST зафиксировано обучение при замене правила STDP на (4) и изменении схемы учета спайков с “А” на “С” (рис 1). Результаты экспериментов показали, что обучение достигается не при всех формах постсинаптического тока и типах входных сигналов (табл. 5). При нормальном входном сигнале в сочетании с синаптическим током в виде α -функции обучение не происходит, веса расходятся.

Таблица 5

Значение параметра $\beta(t)$ после обучения

Тип входного сигнала	Симулятор			
	NEST		NEM (при частоте $\dot{S}_{in}$ 10 Гц)	CSIM
	exp	α		
Пуассоновский	0,1	0,2	0,38	нет данных
Нормальный	0,3	расх.	0,1	нет данных
Равномерный	0,1	0,2	0,41	0,03

Кроме того, проводилась оценка сходимости между получаемыми и целевыми выходными сигналами на основе расчета коэффициента корреляции между ними. Для этого сгенерированы новые последовательности

сигналов продолжительностью по 100 секунд для трех типов сигналов. При расчете корреляции двух сигналов спайки преобразовывались фильтром Гаусса со стандартным отклонением 5 мс. В симуляторе NEST для экспоненциальной формы постсинаптического тока получены значения корреляций приблизительно 0,8 для всех трех типов входных сигналов.

Заключение

В работе проведены исследования механизмов обучения STDP спайковых нейронных сетей с помощью трех разных симуляторов. Продемонстрирована важность выбора правил STDP, схем учета спайков (spike pairing schemes), форм входных сигналов и форм постсинаптических токов для функционирования механизмов обучения. На основе расчетных экспериментов подобрано пригодное для обучения сочетание указанных выше факторов, которое может быть использовано на практике.

Список литературы

1. Maass W. Networks of spiking neurons: the third generation of neural network models // Neural Networks, 1997. 10(9). P. 1659–1671, 1997.
2. Bichler O., Querlioz D., Thorpe S.J., Bourgoin J.-P., and Gamrat C. Extraction of temporally correlated features from dynamic vision sensors with spike-timing-dependent plasticity // Neural Networks, 2012. V. 32, P. 339–348.
3. Pichevar R., Rouat J. Monophonic sound source separation with an unsupervised network of spiking neurons // Neurocomputing, 2007. V.71. P. 109–120.
4. Chandhok C., Chaturvedi S. Adaptation of Spiking Neural Networks for Image Clustering // International Journal of Video & Image Processing and Network Security IJVIPNS-IJENS V: 12 No: 2003.
5. Maass W., & Markram H. Synapses as dynamic memory buffers // Neural Networks, 2002, V.15. P. 155–161.
6. Morrison A., Aertsen A., Diesmann M. Spike-timing-dependent plasticity in balanced random networks // Neural Comput 19(6):1437–67, 2007.
7. Morrison A., Diesmann M., and Gerstner W. Phenomenological models of synaptic plasticity based on spike timing. Biological Cybernetics, 98(6):459–78, 2008.
8. Gewaltig M.-O. & Diesmann M. NEST (Neural Simulation Tool) // Scholarpedia 2(4):1430, 2007.
9. <http://www.lsm.tugraz.at/csim/>
10. <https://github.com/nishbo/hem>
11. Legenstein R., Naeger C., Maass W. What Can a Neuron Learn with Spike-Timing-Dependent Plasticity? // Neural Computation 17: P. 2337–2382, 2005.

Стендовая сессия 2

Нейросетевые системы обработки данных, распознавания образов и управления

А.М. СОЛОВЬЕВ

Воронежский государственный университет
darkzite@yandex.ru

ИСКУССТВЕННАЯ НЕЙРОННАЯ СЕТЬ С ГИСТЕРЕЗИСНЫМИ СВОЙСТВАМИ В ЗАДАЧЕ СТАБИЛИЗАЦИИ ОБРАТНОГО ГИБКОГО МАЯТНИКА С НАЛИЧИЕМ ЛЮФТА В ОСНОВАНИИ ЕГО КРЕПЛЕНИЯ

Разработаны принципы построения искусственной нейронной сети с гистерезисной функцией активации нейронов на основе S -преобразователя. Рассмотрена физическая модель обратного гибкого маятника с наличием люфта в основании его крепления. Решена задача стабилизации такого маятника в окрестности вертикального положения при помощи двухслойной искусственной нейронной сети с гистерезисными свойствами.

Ключевые слова: *искусственная нейронная сеть, S -преобразователь, гистерезисная функция активации, обратный гибкий маятник.*

A.M. SOLOVYEV

Voronezh State University, Russia
darkzite@yandex.ru

STABILIZATION OF FLEXIBLE INVERTED PENDULUM WITH PRESENCE OF BACKLASH IN THE BASIS BY MEANS OF ARTIFICIAL NEURAL NETWORK WITH HYSTERESIS PROPERTIES

Construction principles of artificial neural networks with hysteresis activation function based on the S -operator are developed. The physical model of the flexible inverted pendulum with presence of backlash in the basis of its mount-

ing is considered. The problem of the pendulum stabilization in the vicinity of the vertical position is solved using two-layer artificial neural network with hysteresis properties.

Keywords: *artificial neural network, hysteresis, S-operator, hysteresis activation function, flexible inverted pendulum.*

Введение

Искусственные нейронные сети (ИНС) способны решать широкий круг задач: классификации образов, идентификации, прогнозирования, оптимизации, управления сложными объектами, распознавания текстов, фильтрации спама и др. Эффективность работы ИНС зависит от многих факторов, таких как архитектура сети, методы ее реализации, алгоритмы обучения, а так же свойства, заимствованные от биологических нейронов головного мозга человека. Так, заимствованная пластичность позволяет построить самообучающуюся ИНС. Так же, не менее важным свойством биологических нейронов является кратковременная память. С точки зрения построения ИНС, данное свойство может быть заимствовано путем использования в нейронах сети гистерезисных функций активации (ГФА). Гистерезисная функция активации рассматривалась в работах [1-3].

Стабилизация обратного или перевернутого маятник является классической проблемой теории управления и широко используется в качестве эталона для тестирования алгоритмов управления (ПИД-регуляторов, нейросетей, нечеткого управления и т. д.).

Первое теоретическое исследование обратного маятника было проведено Стефенсоном в работе [4], а первые эксперименты по стабилизации обратного маятника с помощью колебаний подвеса были сделаны П.Л. Капицей и описаны в его работе [5].

Задача стабилизации обратного маятника имеет большую историю исследований и кажется достаточно изученной, однако большая часть этих исследований рассматривают упрощенную модель, не в полной мере соответствующую реальной механической системе подобного вида. Так, учитывая наличие обыкновенного люфта в подвесе (например, вследствие износа деталей или же будучи введенным намеренно, как в рулевом управлении автомобиля), а также рассматривая случай гибкого стержня, можно добиться большего приближения модели к реальной механической системе, однако задача стабилизации такой системы становится более сложной.

В данной работе будет рассматриваться задача стабилизации в вертикальном положении обратного маятника, представляющего собой гибкий стержень, одним концом шарнирно закрепленный на цилиндре, движение которого вызывается горизонтальным перемещением поршня.

S-преобразователь

Особенностью рассматриваемой в данной работе ИНС является наличие гистерезиса в функции активации нейронов сети. Для построения модели такой ИНС наиболее подходящим является использование преобразователей гистерезисной природы. Следуя классическим схемам М.А. Красносельского и А.В. Покровского [6], гистерезисные операторы трактуются как преобразователи, определенные на пространстве непрерывных функций, динамика которых описывается соотношениями: вход-состояние и состояние-выход.

Рассмотрим в качестве модели гистерезиса в функции активации нейронов сети *S*-преобразователь. Построим ГФА на основе входо-выходных соответствий, формализуемых дифференциальным уравнением

$$\frac{dx}{dt} = f(u, x), \quad (1)$$

где $u = u(t)$ – вход, а $x = x(t)$ – выход ($t \geq 0$).

Линии уровня правой части этого дифференциального уравнения приведены на рис. 1 (кривая Γ).




Рис. 1. Линии уровня $f(u, x) = 0$

В дальнейшем будем считать, что правая часть уравнения (1) определяется соотношением

$$f(u, x) = u - x^3 + 3x. \quad (2)$$

У кривой Γ одна общая точка с прямой $u = u_0$, если $u_0 < \beta$ или $u_0 > \alpha$, и три общие точки, если $\beta < u_0 < \alpha$. Кривая Γ делит плоскость на две части. Пусть в верхней части функция $f(x, u)$ принимает отрицательные значения, а в нижней – положительные. Изучим уравнение (1) с медленным управлением $u = u(t)$.

Если $u(t) \equiv u_0$, то уравнение (1) описывает движение точки по вертикальной прямой $u = u_0$; направление движения на одной из таких прямых показано на рис. 1 стрелками. Точки пересечения прямой $u = u_0$ и кривой Γ будут состояниями равновесия; штриховой линией показана часть кривой Γ , состоящая из неустойчивых точек равновесия, а сплошной линией – из асимптотически устойчивых; эта сплошная линия состоит из графиков Γ_1 и Γ_2 некоторых функций $\gamma_1(u)$ и $\gamma_2(u)$.

Указанной информации достаточно, чтобы описать качественное поведение решений $x(t)$ уравнения (1) при медленно меняющемся управлении $u(t)$ ($t \geq t_0$). После короткого промежутка времени (которым можно пренебречь) точка $\{u(t), x(t)\}$ попадает в столь малую окрестность либо точки $\{u(t), \gamma_1[u(t)]\}$, либо точки $\{u(t), \gamma_2[u(t)]\}$, что ее можно считать совпадающей либо с $\{u(t), \gamma_1[u(t)]\}$, либо с $\{u(t), \gamma_2[u(t)]\}$. Пусть для определения $u(t_1) < \alpha$ и $x(t_1) \approx \gamma_1[u(t_1)]$; тогда при дальнейших значениях $t \in (t_1, t_2)$ при которых $u(t) < \alpha$, точка $\{u(t), x(t)\}$ не выходит из малой окрестности кривой Γ_1 , можно считать выполненным равенство $x(t) = \gamma_1[u(t)]$. Если $u(t_2) = \alpha$ и $u(t)$ в точке t_2 растет, то за короткое время (т.е. за такой промежуток времени, на котором $u(t)$ мало меняется) точка $\{u(t), x(t)\}$ попадает уже в малую окрестность кривой Γ_2 , можно считать выполненным равенство $x(t) = \gamma_2[u(t)]$. Продолжая эти рассуждения, мы приходим к описанию решения $x(t)$, которое совпадает с описанием (при помощи принципа отсутствия лишних переключений) неидеального реле с пороговыми значениями α и β , если Γ_1 совпадает с полупрямой $x = 0$ ($u < \alpha$), а Γ_2 – с полупрямой $x = 1$ ($u > \beta$). Близкие источники возникновения релейных нелинейностей часто возникают в теории дифференциальных уравнений с малыми параметрами, теории катастроф и т.п.

Рассмотрим в качестве примера численное решение данного дифференциального уравнения при входном воздействии

$$u(t) = 16 \cdot \sin(t), \quad x\left(-\frac{\pi}{2}\right) = -2,9.$$

Результаты показаны на рис. 2.




Рис. 2. Решение дифференциального уравнения как функция $x(u)$

Двухслойная нейронная сеть с гистерезисом

В качестве примера многослойной ИНС с ГФА рассмотрим двухслойную нейронную сеть. Архитектура такой сети приведена на рис. 3.




Рис. 3. Архитектура двухслойной ИНС с ГФА

Обучение ИНС будем проводить с помощью процедуры обратного распространения ошибки. Таким образом, рассматриваемую ИНС можно классифицировать как сеть обратного распространения.

На рис. 3 обозначены:

Y^m – вектор входных значений;

W^{mn} – матрица весовых коэффициентов скрытого слоя;

U^n – вектор воздействий скрытого слоя;

Q^n – выходной вектор скрытого слоя;

V^{np} – матрица весовых коэффициентов выходного слоя;

E^p – вектор воздействий выходного слоя;

X^p – целевой вектор;

$G = f(U, X, \dot{X}, t)$ – функция активации.

Количество нейронов n в скрытом слое должно быть 30–50 % от числа m . Это число определяется экспериментальным путем. При слишком большом n может наблюдаться эффект переобучения сети, что отрицательно повлияет на способность сети к обобщению. При слишком малом n ИНС может потерять способность к обучению.

Для индексов примем следующие обозначения: входы нумеруются индексом $i = \overline{1, m}$, элементы скрытого слоя индексом $j = \overline{1, n}$, а выходы соответственно индексом $k = \overline{1, p}$. Индексом l будем обозначать номер итерации работы ИНС.

Прямой проход через сеть осуществляется следующим образом:

$$U^n = Y^m \cdot W^{mn}, \quad (3)$$

$$Q^n = G(U^n), \quad (4)$$

$$E^p = Q^n \cdot V^{np}, \quad (5)$$

$$X^p = G(E^p). \quad (6)$$

Обратный гибкий маятник

Рассмотрим модель стабилизации обратного маятника в вертикальном положении, представляющего собой гибкий стержень, одним концом шарнирно закрепленный на цилиндре, движение которого вызывается горизонтальным перемещением поршня (рис. 4). На рисунке: (x, y) – инерциальная система отсчета гибкого стержня массой m , длиной l и плотностью ρ , где ось Ox совпадает с касательной к профилю стержня в точке его крепления; θ – угол наклона системы координат стержня, I – осевой момент инерции сечения стержня; $(X, \bar{x})$ – система координат рас-

считаемой механической системы, M – масса цилиндра с раствором L , F – сила, приложенная к поршню массой m_p , трактуемая как управление.




Рис. 4. Модель гибкого маятника

Физическая модель похожей механической системы рассматривалась в работе [7]. Исследованию динамики обратного гибкого маятника посвящены работы [8-11].

Целью данной работы является изучение возможной стабилизации обратного гибкого маятника в окрестности вертикального положения при условии наличия люфта в опоре стержня с помощью ИНС с ГФА.

Физическая модель маятника

Рассмотрим физическую модель маятника, приведенную на рис. 4. Выход преобразователя-люфта в управлении маятником описывается следующим соотношением:

$$X(t) = \Gamma[X_0, L] \cdot Y(t) = \begin{cases} 0, & |Y(t) - X_0| \leq \frac{L}{2}, \\ Y(t) - \frac{L}{2}, & Y(t) - X_0 > \frac{L}{2}, \\ Y(t) + \frac{L}{2}, & Y(t) - X_0 < -\frac{L}{2}, \end{cases} \quad (7)$$

которое иллюстрирует рис. 5, где $X(t)$ – перемещение центра цилиндра, $Y(t)$ – перемещение поршня в горизонтальной плоскости.




Рис. 5. Динамика входно-выходных соответствий люфта

Сила, приложенная к опоре стержня, находится из следующего соотношения:

$$f(t) = \Gamma[X(0,t), Y(t), L, F_0] \cdot F = \begin{cases} 0, & |X(0,t) - Y(t)| \leq L, \\ F & |X(0,t) - Y(t)| > L, \end{cases} \quad (8)$$

где L – величина раствора цилиндра, F – сила, трактуемая как управление и приложенная к поршню.

Уравнение движения поршня:

$$m_p \cdot \ddot{Y}(t) = F. \quad (9)$$

Таким образом, система уравнений, описывающая динамику обратного гибкого маятника с наличием люфта в основании, будет иметь следующий вид:

$$\begin{cases} \ddot{X} + \frac{EI}{\rho} X'''' = gX'(0,t), \\ M\ddot{X}(0,t) + mgX'(0,t) + ELX'''(0,t) = f(t), \\ (M+m)\ddot{X}(0,t) + mL\ddot{X}'(0,t) = f(t), \\ g(M+m)X(0,t) - \frac{MEI}{\rho} X''' = \int_0^l f(t) dx, \\ f(t) = \Gamma[X(0,t), Y(t), L, F_0] \cdot F, \\ m_p \cdot \ddot{Y}(t) = F. \end{cases} \quad (10)$$

Для решения задачи стабилизации представленного маятника используем двухслойную ИНС с ГФА, на вход которой подаются величины отклонений от вертикального положения точек профиля стержня, а выходом является сила F , трактуемая как управление.

Обучение такой ИНС будем производить адаптивно, применяя метод контролируемого возмущения [12].

Практическая реализация

Выполним моделирование поведения обратного гибкого маятника с люфтом в случае его стабилизации с помощью классической двухслойной ИНС и ИНС с ГФА.

Параметры исследуемой механической системы и начальные условия:

$$\begin{aligned} m &= 1 \text{ кг}, & M &= 10 \text{ кг}, & l &= 1 \text{ м}, \\ \rho &= 0,5, & E &= 10, & I &= 4, \\ \theta_0 &= 0,06^\circ. \end{aligned}$$

Параметры ИНС:

- количество входов (точек профиля стержня) – 10;
- количество нейронов в скрытом слое – 4;
- количество выходных нейронов (управление F) – 1.

В качестве классической ИНС будем использовать двухслойный персептрон с сигмоидальной функцией активации нейронов.

Фазовая траектория исследуемой механической системы, представляющая собой зависимость интегрального угла отклонения стержня от его интегральной угловой скорости, показана на рис. 6.




Рис. 6. Фазовая траектория системы при управлении с помощью классической ИНС (слева) и ИНС с ГФА (справа)

Здесь

$$e_1 = \int_0^l X' dl, \quad e_2 = \int_0^l \dot{X}' dl.$$

Как видно из результатов моделирования, ИНС с ГФА обладает большей эффективностью по сравнению с классической ИНС в задаче стабилизации обратного гибкого маятника с наличием люфта в основании его крепления.

Заключение

Были предложены принципы построения искусственной нейронной сети с гистерезисной функцией активации нейронов на основе S-преобразователя. Рассмотрена физическая модель обратного гибкого маятника с наличием люфта в основании стержня. Решена задача стабилизации такого маятника в окрестности вертикального положения при помощи двухслойной искусственной нейронной сети с гистерезисными свойствами.

Результаты моделирования показали, что ИНС с ГФА обладает большей эффективностью по сравнению с классической ИНС в задаче стабилизации обратного гибкого маятника с наличием люфта в основании его крепления.

Список литературы

1. Соловьев А.М., Семенов М.Е., Мишин М.Ю., Кабулова Е.Г. Искусственные нейронные сети с гистерезисной функцией активации // Теория и техника радиосвязи, 2013. № 2. С. 102-110.
2. Семенов М.Е., Соловьев А.М., Матвеев М.Г., Канищева О.И. Искусственные нейронные сети с гистерезисной функцией активации на основе преобразователя Прейсаха // Вестник ВГУ, Серия «Системный анализ и информационные технологии», 2013. №2. С. 171.
3. Guangpu Xia, Zheng Tang and Yong Li. Hopfield Neural Network with Hysteresis for Maximum Cut Problem // Neural Information Processing - Letters and Reviews., 2004. V. 4. No. 2.
4. Stephenson A. On an induced stability.// Phil. Mag., 1908. 15, 233.
5. Капица П.Л. Маятник с вибрирующим подвесом // УФН, 1951. № 44. С. 7–20.
6. Красносельский М.А. Системы с гистерезисом // М.А. Красносельский, А.В. Покровский. М.: Наука, 1983.
7. Chao Xu, Xin Yu. Mathematical model of elastic inverted pendulum control system. Journal of Control Theory and Applications 3 (2004) 281-282.
8. Elmer P. Dadios, Patrick S. Fernandez, and David J. Williams. Genetic Algorithm on Line Controller for the Flexible Inverted Pendulum Problem // Journal of Advanced Computational Intelligence and Intelligent Informatics, 2006. V.10. № 2.

9. Tang Jiali, Ren Gexue. Modeling and Simulation of a Flexible Inverted Pendulum System // Tsinghua Science and Technology, 2009. V. 14. № S2.

10. Zheng-Hua Luo, Bao-Zhu Guo. Shear Force Feedback Control of a Single-Link Flexible Robot with a Revolute Joint // IEEE Transaction On Automatic Control, 1997. V. 42. № 1.

11. Mohsen Dadfarnia, Nader Jalili, Bin Xian, Darren M. Dawson. A Lyapunov-Based Piezoelectric Controller for Flexible Cartesian Robot Manipulators // J. of Dynamic Systems, Measurement, and Control, 2004. V. 126 / 347.

12. Дзюба Д.А., Чернодуб А.Н. Применение метода контролируемого возмущения для модификации нейроконтроллеров в реальном времени // Математичні машини і системи, 2011. №1.

С.А. ГОРБАТКОВ, И.И. БЕЛОЛИПЦЕВ, С.А. ФАРХИЕВА

Финансовый университет при Правительстве Российской Федерации,
Уфимский филиал
sgorbatkov@mail.ru, red7315@gmail.com, ok-xi@yandex.ru

ИТЕРАЦИОННЫЙ МЕТОД ПОСТРОЕНИЯ НЕЙРОСЕТЕВОЙ ДИНАМИЧЕСКОЙ МОДЕЛИ ПРОГНОЗИРОВАНИЯ БАНКРОТСТВ

Предложен нейросетевой гибридный метод оценки вероятности развивающегося процесса банкротства предприятий. Метод ориентирован на применение в сложных условиях моделирования: неполноты данных и сильного их зашумления.

Ключевые слова: *диагностика банкротств, неполные данные, нейросеть, динамическая модель, риск, логистический метод.*

S.A. GORBATKOW, I.I. BELOLIPTSEV, S.A. FARKHIEVA

Financial University under the Government of the Russian Federation,
Ufa Branch, Russia
sgorbatkov@mail.ru, red7315@gmail.com, ok-xi@yandex.ru

ITERATIVE METHOD FOR CONSTRUCTING OF NEURAL NETWORK DYNAMIC MODEL FOR BANKRUPTCIES FORECASTING

We propose a neural network iterative hybrid method for estimating the probability of developing in time the risk of bankruptcy of enterprises in diffi-

cult conditions modeling: the incompleteness of the data and their strong noising. Computational experiments have confirmed the effectiveness of the basic idea of the hybrid neural network method for constructing a dynamic model with continuous time. The method can be used in a wide range of applications: evaluation of the borrower's creditworthiness, assessment of investment objects and others.

Keywords: *bankruptcies forecasting, data incompleteness, neural network, dynamic model, borrower's creditworthiness, assessment of investment objects.*

Введение

Математические модели оценки вероятности риска банкротств в настоящее время актуальны в связи со многими приложениями в реальном и финансовом секторах экономики. К ним относятся задачи оценки банкротств корпораций; оценки финансово-экономической состоятельности контрагентов в сделках; оценки инвестиционной привлекательности предприятий; обеспечения экономической безопасности предприятий (постоянный мониторинг их финансового состояния); оценки банком кредитоспособности заемщиков; при выработке управленческих решений по налоговому регулированию (управлению) на местном уровне и во многих других экономических приложениях.

Методы моделирования оценки риска банкротств развивались, начиная с пионерских работ Альтмана (1968г.) [1] и его последователей, где использовались различные версии линейного метода множественного дискриминантного анализа (MDA). Эти методы оказались практически неприменимыми для российских предприятий по трем причинам: 1) различия в законодательстве (инвестиции на Западе более защищены законодательством, чем в России); 2) различия в стандартах бухгалтерской отчетности; 3) отсутствие глубокой адаптации моделей банкротств для различных стран и отраслей экономики.

По этим причинами в России были предприняты многочисленные попытки совершенствования MDA – линейных моделей, а также появившихся в 1980 г. логистических моделей банкротств [2]. Но это принципиально не улучшило прогностическую силу моделей банкротств, поскольку оставались три существенных недостатка: отсутствие учета нелинейной связи моделируемого показателя Y с вектором $\vec{x}$ экономических показателей (факторов) анализируемого объекта и окружающей среды

$$\hat{Y} = \varphi(\vec{x}), \quad \vec{x} = (x_1, x_2, \dots, x_j, \dots, x_n), \quad (1)$$

где $\varphi(\cdot)$ – нелинейная функция; обеспечение приемлемого качества модели в указанных выше сложных условиях моделирования; отсутствие динамических прогнозных моделей банкротств с непрерывным временем для неполных данных, когда в некоторых временных срезах наблюдений нет информации об индикаторах риска банкротства $\hat{Y}$ в (1). Последнее является специфической особенностью рассматриваемого класса задач, поскольку вероятность риска банкротства $P = 1$ связана с решением арбитражного суда и поэтому определена только для последнего временного среза данных.

В данной работе для логистической модели банкротств вида

$$P_{gN} = 1 / \left[1 + \exp(-\hat{Y}_g(\vec{x}_{gN})) \right] \in [0; 1] \quad (2)$$

предлагается гибридный нейросетевой итерационный метод восстановления динамических данных. В (2) введены обозначения: P_{gN} – вероятность риска банкротства g -го экономического объекта, например предприятия, в N -ом наблюдении.

Идея предлагаемого метода базируется на свойстве нейросетей хорошо восстанавливать сложные функциональные зависимости, скрытые в данных, и состоит в следующем. Будем считать, что нелинейная функциональная связь (1) между $\hat{Y}$ и вектором $\vec{x}$ в последнем временном срезе $t = N$ приблизительно сохраняется и в других временных срезах $\{t_k\}$, $k \neq N$. При таком допущении эндогенная переменная y_{gk} , $k = 1, 2, \dots, N-1$ может быть восстановлена поочередно в каждом временном срезе подстановкой вектора $\vec{x}_{gk}$ в нейросетевую модель вида (4). После этого данные становятся полными (комплектными), несущими в себе динамическую информацию через функции $\vec{x}_g(t_k)$ и $y_g(t_k)$, где временной аргумент t_k , $k = 1, 2, \dots, N-1$ является дискретным.

Естественно, допущение о сохранении нелинейной зависимости $\hat{Y}_g(\vec{x}_{gN})$ во всех временных срезах вызывает определенную погрешность в оценке динамики риска банкротства, поэтому для уменьшения этой погрешности вводится специальный итерационный процесс исправления функции $\hat{Y}_g(\vec{x}_g(t))$, в итоге которой мы получим динамическую модель оценки риска банкротства с непрерывным временем $t \in [0; T]$, что и является целью исследования в работе.

Постановка задачи

Пусть известны неполные данные $D' \subset D$, где термин «неполноты» понимается в смысле отсутствия наблюдаемых значений эндогенной переменной $\{y_{kg}\}$ в части временных срезов для некоторых предприятий. Здесь D гипотетически полные данные.

Требуется построить логистическую динамическую нейросетевую модель оценки вероятности риска банкротства вида

$$P(t) = 1 / \left[1 + \exp(-\hat{Y}(\bar{x}(t), t)) \right], \quad (3)$$

где показатель экспоненты $\hat{Y}(\bar{x}(t), t)$ восстанавливается по неполным данным D' с помощью нейросетевого отображения вида

$$\hat{Y}(\bar{x}, t) = F(\bar{x}, W, t). \quad (4)$$

Здесь оператор нейросетевого отображения

$$F: \bar{x} \in R^{(n)} \rightarrow \hat{Y} \in R^{(1)}, \quad (5)$$

где $R^{(n)}$, $R^{(1)}$ – пространства действительных чисел размерности n и 1; W – матрица параметров (синаптических весов) нейросети.

Поскольку требуемая нейросетевая модель (3) имеет четко выраженную прикладную направленность, то постановку задачи приблизим к реальным сложным условиям моделирования:

- 1) кроме неполноты данных и возникающей при этом неопределенности в оценке динамической ситуации риска банкротства, будем считать, что данные $D' \subset D$ сильно зашумлены (вплоть до сознательного искажения части данных, что имеет место в бухгалтерской отчетности);
- 2) априорный вид закона распределения шумов неизвестен;
- 3) количество наблюдений в выделенном кластере предприятий ограничено несколькими сотнями.

В литературе такие сложные условия моделирования относят классу задач с триадой «НЕ-факторов» (неполнота, неопределенность, неточность данных).

Описание алгоритма предлагаемого гибридного метода

Алгоритм метода содержит два итерационных цикла:

- внутренних итераций с индексом k , $k = 1, 2, \dots, N - 1$, целью которых является восстановление эндогенной переменной $\{y_{gt_k}\}$ во временных срезах $\{t_k\}$;

- внешних итераций с индексом $s = 1, 2, \dots$, целью которых является введение в нейросетевую модель вида (4) информации о времени и, соответственно, получение нейросетевой динамической модели с непрерывным временем.

Опишем алгоритм предлагаемого итерационного метода по шагам.

Шаг 1 ($k = 1; s = 1$). Используя данные последнего временного среза ($t_k = N$), где известны вектор факторов $\vec{x}_{gN}$ и метки «банкрот» ($P_{gN} = 1$), «небанкрот» ($P_{gN} = 0$) для всех объектов $g \in [1, G]$ и, соответственно, значения аргумента экспоненты $\vec{Y}_{gN} = -7$ и $\vec{Y}_{gN} = 7$ в (2), строим статическую нейросетевую модель (СНСМ).

Применим для построения квазистатической модели (КСНСМ) модифицированный метод вложенных математических моделей (МВММ) подробно описанный в [3, 4, 5], который обеспечивает регуляризацию СНСМ на основе байесовского подхода. Процедуры, входящие в МВММ, по сути являются процедурами предрегуляризации исходных «сырых» данных, сформированных по стандартным данным бухгалтерской отчетности.

В итоге шага 1 для фиксированного времени $t_k = N$ в последнем временном срезе мы получаем **статическую** логистическую нейросетевую модель оценки риска банкротства (СЛНСМ) (2):

$$\hat{Y}(\vec{x}) = F(\vec{x}, W), \quad (6)$$

где $F(\cdot)$ – оператор нейросетевого отображения.

Шаг 2 ($k = 0, 1, 2, \dots, N-1; s = 1$). Далее будем восстанавливать эндогенную переменную $\{y_{gk}\}$ в каждом временном срезе во внутреннем итерационном цикле ($k = 0, 1, 2, \dots, N-1$), используя статическую нейросетевую модель (2), (6), полученную на шаге 1, для каждого g -го предприятия. Итогом этой процедуры является множество вероятностей риска банкротства во временных срезах:

$$P_g [\hat{Y}_g(\vec{x}(t_k))] = 1 / [1 + \exp(-\hat{Y}_g(\vec{x}(t_k)))] ; \quad k = 1, 2, \dots, N-1 ; \quad (7)$$

$$\{P_g(t_k)\}_{k=1}^{k=N} = P_{gt_1}, P_{gt_2}, \dots, P_{gt_N} ; \quad g = \text{var} . \quad (8)$$

Замечание 1. Модель (4), (6), (7), (8) – это уже квазистатическая нейросетевая модель оценки риска банкротства с логистической трансформацией вероятности (ЛКСНСМ) и дискретным временем $\{t_k\}$. Здесь уже можно приближенно оценивать стадии развивающегося процесса бан-

кротства по вероятностям во временных срезах. Однако, динамическая информация в моменты времени между срезами отсутствует.

На языке функционального анализа модель (2), (5), (7), (8) представляет собой композицию двух нелинейных операторов:

$$\vec{x} \in R^{(n)} \xrightarrow{\Phi} P(t_k) \in M^{(N)}; \quad \Phi = A \circ F; \quad k = \overline{1, N-1}, \quad (9)$$

где F – оператор нейросетевого отображения вида (4)-(5); A – оператор логистической трансформации вероятности вида (7); $M^{(N)}$ – конечномерное пространство дискретных функций размерности N .

Шаг 3. ($k=1, 2, \dots, N-1$; $s=2$). На шаге 3 мы переходим к внешним итерациям введения в динамическую модель непрерывного времени $t \in [0; T]$. Для этого в каждой кластерной НСМ в состав вектора факторов $\vec{x}$ введем в качестве независимого нового фактора – время t :

$$\vec{x}^* = (x_1, x_2, \dots, x_j, \dots, x_n, x_{n+1} \equiv t). \quad (10)$$

Используя восстановленные данные, т.е. кортежи

$$\langle y_{gk}, \vec{x}_{gk}^*, t_k \rangle, \quad k = 1, 2, \dots, N-1, N, \quad (11)$$

обучаем заново и тестируем нейросеть:

$$\hat{Y}(\vec{x}(t), t) = F(\vec{x}(t), t, W), \quad (12)$$

где в нейросетевой модели время t входит явно и является непрерывным. Значит модель (3), (16), (12) можно в полной мере считать динамической, поскольку при обучении НСМ учитывается, что нелинейная зависимость (3) «плывет» во времени. Причем можно получить информацию о вероятности риска банкротства, как во временных срезах, так и в любой точке между ними. Следовательно, появляется возможность уточнения восстанавливаемых значений эндогенных переменных в кортежах:

$$y_{gk}^{(2)} = F(\vec{x}(t), t_k, W^{(1)}), \quad k = 1, 2, \dots, N-1, \quad (13)$$

где синаптические веса $W^{(1)}$ берутся из предыдущего шага внешних итераций ($s = 1$).

Шаг 4. ($k = 1, 2, \dots, N-1$; $s = 3$). Заново обучаем ДНСМ с учетом новых восстановленных данных, т.е. реализуем шаги 2, 3 и т.д. Критерий сходимости внешнего итерационного процесса по индексу s восстановления эндогенных переменных $\hat{y}_{gk}$ и уточнения ДНСМ выбираем в виде:

$$J = \max_g \left[\max_k \left| \hat{y}_{gk}^{(s)} - \hat{y}_{gk}^{(s-1)} / \hat{y}_{gk}^{(s)} \right| \right] \leq \xi; \quad g = \overline{1, G}; \quad k = \overline{1, N-1}; \quad s = 3, 4, \dots \quad (14)$$

Замечание 2. Вычислительный процесс построения ДНСМ является довольно трудоемким, поскольку восстанавливать приходится эндогенные переменные $\{y_{gk}^{(s)}\}$ на шагах 3,4,... для всех предприятий, входящих в кластер m и во всех временных срезах. Это естественная плата за переход от квазистатической нейросетевой модели к динамической для данного сектора экономики и данного региона (страны). Зато последующее использование на практике ДНСМ довольно просто – оно сводится к подстановке на входе обученной и верифицированной нейросети, единой для всего кластера модели вектора $\vec{x}(t)$ факторов для анализируемого g -го объекта в интересующий момент времени t .

Замечание 3. Основная ценность модели банкротства, получаемой с помощью ДНСМ – это возможность получения качественного прогноза банкротства с информацией о стадиях его развития.

3. Модификация динамического нейросетевого метода оценки риска банкротства (МДНСМ)

На практике встречаются экономические объекты с большой инерцией. В таких объектах при исследовании динамики риска банкротства важно учесть «медленное время» с помощью лаговых переменных разного типа. Авторы предлагают, ввести в состав вектора факторов $\vec{x}^*$ также лаговые переменные вида:

$$z_{1t} = P_{t-1}; z_{2t} = P_{t-2}; z_{3t} = P_{t-1}/P_{t-2}. \quad (15)$$

Эффективность такого приема можно оценить только путем вычислительных экспериментов по критерию скорости сходимости итерационного процесса (14).

4. Количественные оценки построения динамической модели банкротств

Использовали реальные данные для строительных организаций из [5].

Шаг 1 (итерация 0). Обучался байесовский ансамбль из 10 сетей на выборке из 136 наблюдений для $t = 5$ (последний временной срез). Результаты тестирования сетей различной структуры приведены в табл. 1.

После фильтрации на байесовском ансамбле, обученным сетям были предъявлены данные за предшествующие 4 года. Получены усредненные оценки величины Y для всех временных срезов $t = 1, 2, 3, 4$. Использовался критерий фильтрации из [5]:

$$K_{Hk} = N_{Hk}^* r_1 - N_{Hk}^1 r_2 - N_{Hk}^2 r_3, \quad (16)$$

где N_{Hk}^* – количество верно идентифицированных предприятий для данной зафиксированной байесовской мета-гипотезы N_k с номером k ; N_{Hk}^1 , N_{Hk}^2 – количество ошибок первого и второго рода соответственно при идентификации; r_1 , r_2 , r_3 – удельные веса показателей в (6), характеризующие их предпочтения, т.е. коэффициенты Фишберна [6]:

$$r_i = (2(n-i+1))/((n+1)n); \quad (17)$$

n – количество ранжируемых показателей, входящих в критерий (6). Формулу (7) можно использовать в случае, если множество показателей N_{Hk}^* , N_{Hk}^1 , N_{Hk}^2 упорядочено в порядке убывания их предпочтения.

Таблица 1

**Результаты тестирования нейросетей,
обучавшихся на данных за последний год ($t = 5$)**

№ сети	Доля верно распознанных предприятий	Всего ошибок идентифика- ции	Число ошибок 1-го рода	Число ошибок 2-го рода	K_{H_k}
HCM1	65,85%	14	5	9	10,33
HCM2	80,49%	8	5	3	14,33
HCM3	80,49%	8	3	5	14,66
HCM4	78,05%	9	5	4	13,66
HCM5	78,05%	9	5	4	13,66
HCM6	85,37%	6	3	3	16,00
HCM7	75,61%	10	6	4	12,83
HCM8	82,93%	7	3	4	15,33
HCM9	80,49%	8	3	5	14,66
HCM10	78,05%	9	3	6	14,00
Среднее на от- фильтрованном ансамбле	85,37%	6	3	3	16,00

Шаг 2 (итерация 1). В общую выборку был добавлен фактор времени (относительное время). Данные были разбиты на обучающее и тестовое множество следующим образом: 610 наблюдений в обучающем множестве и 70 – в тестовом. На этих данных был переобучен ансамбль нейросе-

тей (оптимальное количество нейронов в скрытых слоях подбиралось заново). Результаты тестирования показаны в табл. 2.

Таблица 2

**Результаты тестирования байесовского ансамбля нейросетей,
обучавшихся на данных за все 5 лет**

№ сети	Доля верно распозна- нных пред- приятий	Всего ошиб- бок	Число ошибок 1-го рода	Число ошибок 2-го рода	Критерий K_{H_k}	Средняя на отфилт- рованном ансамбле ошибка обобщения $\bar{\delta}$
HCM1	84,29%	11	5	6	26,83	163%
HCM2	85,71%	10	1	9	28,16	173%
HCM3	84,29%	11	6	5	26,66	170%
HCM4	88,57%	8	4	4	29	172%
HCM5	85,71%	10	1	9	28,16	177%
HCM6	71,43%	20	0	20	21,66	171%
HCM7	87,14	9	4	5	28,33	179%
HCM8	80,0%	14	3	11	25,16	191%
HCM9	81,43%	13	6	7	25,33	174%
HCM10	85,71%	10	3	7	27,83	178%
Среднее на отфилтрово- ванном ан- самбле	87,14%	9	3	6	28,5	

Критерий фильтрации $K_{H_k} > 26$. Отфильтрованным сетям (№ 1, 2, 3, 4, 5, 7, 10) были предъявлены данные и получены значения $\hat{Y}$.

Дополнительно для каждой нейросети была рассчитана средняя относительная погрешность аппроксимации по формуле

$$\bar{\delta} = \sum_{i=1}^{N_{learn}} \left| [(y_i - \hat{y}_i) / y_i] \right| \cdot 100\% / N_{learn}, \quad (18)$$

где N_{learn} – количество наблюдений в обучающем множестве.

Шаг 3 (итерация 2). В данных значения Y (показатель экспоненты) были заменены на значения $\hat{Y}$, полученные на предыдущей итерации. Цикл обучения повторяется заново. Результаты представлены в табл. 3.

Таблица 3

**Результаты тестирования байесовского ансамбля нейросетей,
обучавшихся на данных за все 5 лет (итерация $s = 2$)**

№ сети	Доля верно распозна- нных пред- приятий	Всего ошибок	Количе- ство ошибок 1-го рода	Количе- ство ошибок 2-го рода	K_{H_k}	$\bar{\delta}$
HCM1	85,71%	10	1	9	28,16	68.37%
HCM2	85,71%	10	1	9	28,16	65.98%
HCM3	85,71%	10	1	9	28,16	78.92%
HCM4	85,71%	10	1	9	28,16	69.61%
HCM5	85,71%	10	1	9	28,16	66.38%
HCM7	85,71%	10	1	9	28,16	70.84%
HCM10	87,14%	9	1	8	28,83	70.03%
Среднее на отфильтро- ванном ансамбле	85,91%	10	1	9	28	

Результат: практически все сети (кроме № 10) показали один и тот же результат. При этом ошибки идентификации наблюдаются в одних и тех же точках тестового множества. Этот результат можно объяснить тем, что при переходе к следующей итерации нейросетевое отображение «сжимает» невязку для $\hat{y}$, т.е. отображение (3) является сжимающим [7]. Относительная погрешность также уменьшилась примерно в 2,5 раза.

Таким образом, вычислительные эксперименты подтвердили эффективность основной идеи разработки гибридного нейросетевого метода построения динамической модели банкротств с непрерывным временем, т.е. идеи восстановления непрерывной динамической зависимости вероятности риска банкротств предприятий по неполным данным.

Выводы

1. Разработан и апробирован метод построения динамических моделей банкротств при неполных данных, который может быть использован в широком спектре динамических прикладных задач.
2. Разработанные инструментарии и методы, по мнению авторов, выходят за рамки рассмотренных выше во Введении задач и при адаптации к соответствующей постановке задачи могут быть использованы в

других динамических задачах с неполными данными при моделировании экономических объектов.

Список литературы

1. Altman E.I. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. // Journal of Finance, 1968. V. 23. № 9. P. 589-609.
2. Ohlson J.A. Financial Ratios and the Probabilistic Prediction of Bankruptcy. // Journal of Accounting Research, 1980. № 18(1). P. 109-113.
3. Горбатков С.А., Полупанов Д.В., Макеева Е.Ю., Бирюков А.Н. Методологические основы разработки нейросетевых моделей экономических объектов в условиях неопределенности :Монография / Под ред. С.А.Горбаткова. М.: Издательский дом «Экономическая газета», 2012.
4. Горбатков С.А., Белолипецв И.И., Фархиева С.А. Приближенный метод байесовской регуляризации и двухступенчатая оценка адекватности гибридной нейросетевой модели налогового контроля // Научная сессия НИЯУ МИФИ – 2011: XIII Всероссийская научно-техническая конференция "Нейроинформатика-2011":Сб. научных трудов. М.: МИФИ, 2011. С. 144-154.
5. Горбатков С.А., Белолипецв И.И., Макеева Е.Ю. Выбор системы экономических показателей для диагностики и прогнозирования банкротств на основе байесовского подхода и интеллектуальных информационных технологий // Вестник Финансового университета при Правительстве РФ, 2013. №4(76). С. 50-62.
6. Недосекин А.О. Комплексная оценка риска банкротства корпораций на основе нечетких описаний // http://sedok.narod.ru/sc_group.html
7. Тихонов А.Н., Арсенин В.Я. Методы решения некорректных задач. М.: Наука; Физмалит, 1986.

Е.О. ИВАНОВ, Н.В. ЗАМЯТИН

Томский государственный университет систем управления и радиоэлектроники
egor.o.ivanov@yandex.ru

**НЕЙРОННАЯ СЕТЬ ХОПФИЛДА ДЛЯ УПРАВЛЕНИЯ
ГРУППОЙ ОБЪЕКТОВ (НАСОСОВ)**

Приводится постановка многокритериальной задачи оптимизации управления группой объектов (насосов) и ее приведение к динамике работы нейронной сети Хопфилда. Описывается применение полученной сети для решения реальной задачи оптимизации, проводится анализ ее работы и сравнение полученных результатов с данными других алгоритмов.

Ключевые слова: *управление группой объектов, сеть Хопфилда, многокритериальная оптимизация.*

E.O. IVANOV, N.V. ZAMYATIN

Tomsk Institute of Radio Electronics and Electronic Techniques, Russia
egor.o.ivanov@ya.ru

A HOPFIELD NETWORK FOR THE CONTROL A GROUP OF OBJECTS (PUMPS)

A statement of multi-objective optimization problem for control of pumps group is given. The problem is reduced to the Hopfield network dynamics. Application of the obtained network to real optimization problem is considered. The results of simulation are analyzed and compared with those of other algorithms.

Keywords: *control a group of objects, Hopfield network, multi-objective optimization.*

Введение

Задача управления группой объектов является глобальной проблемой, актуальной как для живой природы, так и для многих технических областей. Фактически, задача группового управления (или взаимодействия) возникает при совместном решении некоторой задачи группой любых объектов различной природы, например колонией муравьев или пчел, бригадой строителей, группой автономных мобильных роботов [1].

Во многих промышленных областях существуют задачи группового управления множеством одновременно работающих устройств, установок: например, задача управления насосами скважин, добывающих или подающих воду в единую систему водопотребления. Сложность данной проблемы обусловлена высоким уровнем взаимного влияния такого оборудования и относительно большой размерностью задачи (десятки, иногда сотни объектов).

В общем случае задача управления группой объектов разбивается на ряд подзадач, среди которых можно выделить следующие [1]:

- определение состава группы (кластера), способной эффективно решить целевую задачу;
- распределение функций между объектами для оптимального (или близкого к нему) решения целевой задачи;

- реализация функций отдельными объектами для достижения конечной цели.

Среди известных подходов к решению задачи управления группой объектов можно выделить два противоположных: централизованный (задача решается одним центральным устройством управления) и децентрализованный (решение осуществляется распределенной системой). Децентрализованный подход находит свое применение в задачах управления автономными роботами [1]. Это связано с тем, что они могут обладать достаточной интеллектуальностью и работать в условиях неопределенности. Последнее, как правило, неверно для оборудования предприятий, поэтому здесь целесообразней использовать централизованный подход.

Постановка задачи

Группа множества объектов в виде вододобывающих насосов работает на заполнение резервуара. Каждый насос характеризуется подачей (количеством перекачиваемой воды) Q_i (м³/ч) и потребляемой мощностью N_i (кВт), соответствующей подаче. В общем случае, каждый насос может характеризоваться разными значениями подачи и мощности, поэтому будет различно и значение удельной стоимости перекачки единицы воды, определяемой как $c_i = N_i/Q_i$.

Обычно насосы вводятся в избыточном количестве, так как некоторые из них могут простаивать по причине необходимого ремонта или обслуживания, а также следовать определенным технологическим режимам (бездействие после определенного времени работы, и, наоборот, нежелательность длительного простоя). Избыточность характеризуется тем, что все включенные насосы могут обладать суммарной подачей Q_{Σ} большей, чем реальная потребность.

Известно, что суммарное количество воды Q_z необходимо подать в течение следующего часа (способ его определения описан в [2]). Для простоты будем рассматривать дискретную задачу, то есть каждый насос может находиться в одном из двух состояний – включен или выключен. Затем задачу можно расширить для непрерывного случая, то есть использования частотного управления электродвигателями насосов. Таким образом, перед нами возникает задача распределения суммарной нагрузки между насосами, т.е. определения, какие насосы следует включить, а какие выключить. Введем в задачу минимизацию удельной стоимости при выполнении требований в обеспечении количества подаваемой воды. Задача

оптимизации определяется в условиях минимизации суммарной удельной стоимости перекачки единицы воды всеми включенными насосами.

Обозначим $x_i \in \{0,1\}$ – состояние насоса в текущий момент времени, где 1 соответствует состоянию «включен», а 0 – «выключен», общее количество насосов обозначим n . Таким образом, при $x_i = 0$ выключенный насос не будет увеличивать суммарную удельную стоимость, а включенный ($x_i = 1$) – будет на величину c_i . Тогда решением задачи будет поиск вектора состояний всех насосов $\mathbf{X}$, который будет минимизировать их суммарную удельную стоимость

$$Z_1 = \sum_i x_i c_i \rightarrow \min, \quad (1)$$

при удовлетворении требований в количестве воды, представленных в качестве минимального отклонения от суммарной необходимой подачи Q_z :

$$Z_2 = (\sum_i x_i Q_i - Q_z)^2 \rightarrow \min. \quad (2)$$

Нейронная сеть Хопфилда с дискретными состояниями

Нейронная сеть Хопфилда представляет собой неориентированный граф с множеством из n вершин (нейронов) и множеством ребер без петель и кратных ребер [3].

Каждому нейрону сети соответствуют два числа x_i – состояние нейрона и u_i – пороговое значение нейрона. Каждому ребру сети (i, j) поставлено в соответствие число w_{ij} – вес (сила) синаптической связи между нейронами i и j . Отсутствие петель и кратных ребер выражается в выполнении: $w_{ij} = w_{ji}$ и $w_{ii} = 0$. Отсутствие связи элемента с самим собой избавляет его от постоянного обратного воздействия на значение собственного состояния [3,4].

Симметричность связей нейронов сети и отсутствие связи элемента с самим собой позволяет утверждать об устойчивости такой сети. Нейрон принимает одно из дискретных состояний $x_i \in \{-1,1\}$. Во многих практических задачах имеет смысл рассматривать булевы состояния $x_i \in \{0,1\}$. Введем матричные $\mathbf{W}$ и векторные $\mathbf{U}, \mathbf{X}$ обозначения для связей и состояний сети. В каждый момент времени $t=1,2,3,\dots$ сеть характеризуется

вектором состояний $\mathbf{X}(t)$. В начальный момент времени сеть находится в состоянии $\mathbf{X}(0)$.

Динамика работы дискретной сети задается в виде [3]

$$x_i(t+1) = \text{sign}(\sum_j^n w_{ij} x_j(t) - u_i). \quad (3)$$

Далее, в целях избавления от громоздкости во всех последующих формулах будем опускать аргумент времени t в тех случаях, когда он равен текущему, в частности: $x_i = x_i(t)$.

Из соображений устойчивости сети будем использовать асинхронную динамику работы, а точнее, наиболее простой ее вариант: случайным образом выбирается и активизируется один из нейронов i . Если общее возбуждение нейрона превышает его порог u_i , то нейрон принимает состояние 1, иначе – состояние -1 . При этом состояние остальных нейронов сети на данном шаге остается неизменным.

Нейросетевая постановка задачи

Предварительно проведем нормировку параметров всех существующих насосов Q_i , Q_Z и c_i , что преобразует их в безразмерные величины, сделав возможным их совместное использование

$$Q_i = \frac{Q_i}{\max_i(Q_i)}, \quad Q_Z = \frac{Q_Z}{\max_i(Q_i)}, \quad c_i = \frac{c_i}{\max_i(c_i)}.$$

Представим задачу в терминах нейронной сети Хопфилда с бинарными состояниями нейронов $x_i \in \{0, 1\}$. Функция энергии $E = E(t)$ дискретной сети с дискретным временем имеет вид

$$E = \alpha (\sum_i x_i Q_i - Q_Z)^2 + \beta \sum_i x_i c_i, \quad (4)$$

где α и β – неотрицательные вещественные константы, определяющие вклад каждого из критериев оптимальности в энергию сети.

Согласно [3], уравнение динамики сети

$$x_i(t+1) = \text{sign} \left[-\frac{\Delta E_i(t)}{\Delta x_i} \right]. \quad (5)$$

Обозначим

$$S = S(t) = \left(\sum_i^n x_i Q_i - Q_z \right)^2 = \left(\sum_i^m x_i Q_i \right)^2,$$

где $m = n + 1$, $x_m = -1$, $Q_m = Q_z$.

Воспользовавшись формулой квадрата суммы и выполнив обратные преобразования, получим

$$S = \sum_i^n (Q_i x_i)^2 + (-Q_z)^2 + 2 \sum_{i=1}^{n-1} \sum_{j=i}^n Q_i x_i Q_j x_j - 2 Q_z \sum_i^n Q_i x_i.$$

Отсюда

$$x_i(t+1) = \text{sign} \left[-2\alpha Q_i^2 x_i - 2\alpha \sum_{j \neq i} Q_j x_j Q_i + 2\alpha Q_z Q_i - \beta c_i \right].$$

Сопоставив с динамикой сети Хопфилда в разрезе весов и порогов сети (5), получим

$$w_{ij} = -2\alpha Q_i^2 \delta_{ij} - 2\alpha Q_j Q_i (1 - \delta_{ij}), \quad (6)$$

$$u_i = -2\alpha Q_z Q_i + \beta c_i, \quad (7)$$

где δ_{ij} – символ Кронекера.

Моделирование

Рассмотрим в качестве задачи для моделирования группу из 18-ти насосов (реальные данные), параметры которых представлены в табл. 1.

Согласно формулам (6, 7) определим в нейронной сети Хопфилда, имеющей 18 нейронов, соответствующие веса и пороги. В качестве начального состояния сети взят вектор, состоящий из всех 1, что соответствует включению всех насосов. Для сети выбран асинхронный режим работы, нейрон для начальной активации выбирается случайным образом. По условию задачи получение ее решения необходимо выполнять ежедневно, следовательно, в процессе моделирования оценивается не скорость получения решения, а его качество. В качестве критериев качества будем использовать обеспечение необходимого количества воды и экономии электроэнергии.

Для подтверждения целесообразности применения нейронной сети, сравним алгоритм на основе сети Хопфилда с двумя простейшими алгоритмами.

Первый – включение насосов в порядке возрастания их мощностей N_i , до тех пор, пока не возникнет приближение к желаемой суммарной подаче. Второй – включение насосов в порядке возрастания удельной стоимости добычи одного кубического метра воды c_j .

Таблица 1

**Параметры насосов
(объем перекачки и потребляемая
мощность)**

№ насоса	Параметры насоса		
	Q_{is} м ³ /ч	N_{is} кВт	c_{is} нормир.
1	16	11	0,688
2	16	16	1,000
3	25	16	0,640
4	25	13	0,520
5	25	22	0,880
6	40	20	0,500
7	40	25	0,625
8	40	30	0,750
9	65	45	0,692
10	120	45	0,375
11	160	90	0,563
12	140	90	0,643
13	16	11	0,688
14	16	16	1,000
15	25	16	0,640
16	25	13	0,520
17	25	22	0,880
18	40	20	0,500

В обоих случаях решение о включении следующего насоса определяется величиной абсолютного отклонения имеющейся подачи всех включенных насосов от желаемой суммарной подачи.

Согласно табл. 1, суммарная подача всех включенных насосов равна 859 м³/час, поэтому моделирование выполняется следующим образом: запускаются три представленных выше алгоритма 860 раз каждый, задавая требуемую подачу в пределах от 10 до 860 с шагом 10, повторяя каждый шаг 10 раз. Наиболее вероятно, что в реальных условиях требуемая величина суммарной подачи не будет колебаться в столь больших пределах, а будет занимать определенную область в ее не крайних значениях, однако и экстремальные величины подачи представляют интерес для моделирования.

Модель Хопфилда запускалась на вычисления с коэффициентами $\alpha = 1,0$ и $\beta = 0,24$, которые были подобраны экспериментально с расчетом на мини-

мальное расхождение в количестве воды. Увеличение значения коэффициента β приводит к тому, что сеть Хопфилда больше ориентируется на минимизацию выражения (1), чем (2). Значения главной диагонали матрицы весов $\mathbf{W}$ сети Хопфилда при проведении эксперимента были обнулены для повышения устойчивости работы сети [3,4].

Проведем анализ результатов моделирования (табл. 2) различных подходов на одинаковых данных.

В первой строке таблицы представлены результаты для сети Хопфилда при $\alpha = 1,0$ и $\beta = 0,24$, во второй и третьей – результаты работы простейших алгоритмов по минимальной мощности и удельной стоимости соответственно. Первые три столбца показывают количество решений, когда суммарная подача включенных согласно найденному решению насосов меньше запрашиваемой, превышает ее или в точности совпадает.

Таблица 2

Сравнение алгоритмов

Алгоритм	Суммарная подача			Сумма N	Сумма Q	Сред- нее
	Мень- ше	Больше	Совпа- дает			
Хопфилд	451	332	77	206820	374680	0,552
Минимизация N_i	440	420	0	234160	375610	0,623
Минимизация c_i	360	420	80	199190	376910	0,528

Отметим, что требование целочисленности вектора-решения $\mathbf{X}$, вообще, не позволяет всегда получать точное решение. Сеть Хопфилда при указанных коэффициентах выдает решения с меньшей суммарной подачей. Алгоритм же поиска по минимальной мощности вообще не предложил ни одного точного решения в силу своей примитивности. В четвертом столбце представлена суммарная мощность, потребленная всеми включенными насосами за все время моделирования. В пятом столбце находится суммарное значение подачи каждого из алгоритмов. Согласно условиям моделирования, суммарная необходимая подача всех насосов составляет 374100 м^3 . Из результатов моделирования следует, что сеть Хопфилда сгенерировала наиболее близкое к лучшему значение. Последний столбец показывает среднюю удельную стоимость каждого кубического метра воды. Здесь сеть Хопфилда показала приемлемые, но не лучшие результаты. Но вместе с тем сеть Хопфилда оставляет много места для маневра: подбирая значения коэффициентов, можно регулировать «вес» каждого из критериев оптимальности.

Заключение

Таким образом, представленная дискретная сеть Хопфилда, решающая задачу оптимизации работы группы насосов, показала хорошие результаты моделирования. Как видим, сеть Хопфилда способна одновременно решать основные сформулированные задачи управления группой объектов, а именно: определение состава группы, распределение функций между объектами и их реализация. Дальнейшие усилия авторы планируют направить на решение непрерывной задачи управления группой насосов.

Список литературы

1. Каляев И.А., Капустян С.Г., Гайдук А.Р. Самоорганизующиеся распределенные системы управления группами интеллектуальных роботов, построенные на основе сетевой модели // Управление большими системами, 2010. № 30.1. С. 605–639.
2. Замятин Н.В., Иванов Е.О., Латровкин В.В. Прогноз расхода ресурсов на примере водозабора второго подъема // Автоматизация в промышленности, 2014. № 3. С.50–53.
3. Меламед И.И. Нейронные сети и комбинаторная оптимизация // Автоматика и телемеханика, 1994. № 4. С. 3–40.
4. R. Rojas. Neural Networks: A Systematic Introduction. Berlin, New-York: Springer-Verlag, 1996.

Н.Т. ГАБДРАХМАНОВА

Российский университет дружбы народов, Москва
gabd-nelli@yandex.ru

**НЕЙРОСЕТЕВЫЕ МОДЕЛИ ДЛЯ РЕШЕНИЯ
УПРАВЛЕНЧЕСКИХ ЗАДАЧ НА МАГИСТРАЛЬНОМ
НЕФТЕПРОВОДЕ**

В статье излагаются основные принципы и результаты построения идентификационной модели расхода электроэнергии на перекачку нефти. Построенная нейросетевая модель апробирована на одном из линейных участков магистрального нефтепровода. Модель может быть использована при планировании расхода электроэнергии на перекачку нефти. Рассмотрены несколько отдельных задач, которые могут быть решены с помощью построенной нейросетевой модели.

Ключевые слова: *нейронная сеть, прогноз, магистральный нефтепровод.*

N.T. GABDRAKHMANOVA

Peoples' Friendship University of Russia, Moscow, Russia
gabd-nelli@yandex.ru

**NEURAL NETWORK MODELS FOR MANAGEMENT TASKS
ON THE MAIN OIL PIPELINE**

Basic principles and results of constructing identification model of electricity consumption for oil transit are set out. Constructed neural network model is

tested on one of the linear sections of the main oil pipeline. The model can be used for planning of electricity consumption for oil transit. Several separate tasks that can be solved by proposed neural network model, are considered.

Keywords: *neural network, electricity consumption, oil pipeline.*

Введение

Актуальность решения задачи построения математической модели планирования расхода электроэнергии в трубопроводном транспорте нефти определяется следующим. Транспорт нефти и газа сопряжен со значительными затратами электроэнергии. Стохастический характер этих процессов приводит к тому, что в большинстве случаев наблюдаются отклонения фактического расхода электроэнергии от запланированных значений. Это в свою очередь инициирует процесс применения штрафных санкций к предприятиям по транспорту нефти. С другой стороны, широкое использование вычислительной техники, автоматизация и телемеханизация объектов нефтепроводных систем позволяет не только управлять ими, но и сохранять в памяти историю изменения их состояния. В настоящее время собранная статистическая информация используется при выборе управленческих решений, однако методы обработки этой информации основаны главным образом на детерминированных операциях и не удовлетворяют возросшему требованию к точности.

Проблема оптимизации перекачки нефти по магистральному нефтепроводу отражена в весьма обширной литературе по методам технико-экономических расчётов [1]. Наибольшее число публикаций по применению информационных технологий для оптимизации перекачки нефти связано с использованием методов последовательного анализа вариантов, таких как динамическое программирование; вероятностные автоматы; генетический алгоритм. В настоящее время эти работы не нашли широкого практического применения. Предложенная постановка задачи отличается от постановок задач, встречающихся в литературе. Задача не является в прямом смысле задачей календарного планирования, так как планируется не объём перекачки, а режим работы системы.

Постановка задачи

Задан нефтепровод, схема которого представлена на рис. 1. При этом считается, что перекачка нефти от резервуарного парка линейной производственно-диспетчерской станции (ЛПДС) «А» до резервуарного парка

конечного пункта (ЛПДС «С») является законченным технологическим процессом. В этих условиях расход электроэнергии определяется для нефтепровода в целом с учетом всех объектов и фиксируется ежечасно для каждого насоса. В блоке качества нефти (НПС «В»), расположенном на участке технологического трубопровода между резервуарным парком и подпорной нефтенасосной ЛПДС «А», ведется измерение мгновенных реологических свойств нефти. На конечном пункте предусмотрена система измерения количества нефти, перекачиваемой по нефтепроводу.




Рис. 1. Схематическое изображение нефтепровода

Необходимо по имеющимся данным за N прошлых периодов составить прогнозный план ежесуточного расхода электроэнергии на T шагов вперед, обеспечивающий перекачку по нефтепроводу нефти заданного объема. Прогноз необходимо осуществить с заданной точностью: относительная погрешность вычислений не должна превышать 3 %.

Для решения прогнозной задачи разработаны модель идентификации и модели для прогноза временных рядов. Модель идентификации построена для расчёта расхода электроэнергии по известным данным характеристик нефти и нефтепровода. Прогнозные модели построены для временных рядов входных переменных модели идентификации.

Модель идентификации

Модель идентификации строится с помощью нейронных сетей по данным, зафиксированным операторами магистрального нефтепровода. Множество зафиксированных данных является результатом измерений. Измерительные устройства имеют свои ошибки измерения. На измерительные устройства действуют шумы, обусловленные окружающей средой. Поскольку состояние среды априори неизвестно, то входные сигналы естественно рассматривать как случайные функции.

Постановка задачи. Пусть система описывается p -мерным вектором $\mathbf{X} = \{X_1, \dots, X_p\}$, состоящим из набора независимых переменных, и скаляром Y , представляющим зависимую переменную. Существует N реализаций вектора $\mathbf{X}$, обозначаемых $\{\mathbf{x}(t)\}$, $t=1, \dots, N$. Соответствующее им множество реализаций скаляра Y обозначим $\{y(t)\}$, $t=1, \dots, N$. Эти реализации в совокупности составляют некоторую выборку.

Математическая модель функциональной взаимосвязи между $\mathbf{X}$ и Y неизвестна:

$$Y(\mathbf{X}) = f(\mathbf{X}) + \xi, \quad (1)$$

где $f(\cdot)$ – некоторая детерминированная функция векторного аргумента; ξ – ожидаемая ошибка, представляющая наше незнание зависимости между $\mathbf{X}$ и Y . ξ – случайная величина с нормальным законом распределения и нулевым математическим ожиданием. Необходимо по данным выборки найти функцию $F(\cdot)$, близкую к $f(\cdot)$ по критерию

$$\|F(\mathbf{x}) - f(\mathbf{x})\| \rightarrow \min \quad (2)$$

по всем точкам $\mathbf{x}$ из области определения D и удовлетворяющую критерию пригодности модели, установленную заказчиком.

Статистическая модель, описанная выражением (1), называется регрессионной [2]. В качестве оценки (2) используем среднеквадратическую ошибку на множестве экспериментальных точек:

$$E = \frac{1}{2N} \sum_{i=1}^N (y_i - F(\mathbf{x}_i))^2 \rightarrow \min.$$

Переменные моделирования. Результат построения модели идентификации полностью зависит от выбора входных и выходных переменных. Проблема выбора переменных моделирования решалась поэтапно при участии экспертов с использованием методов математической статистики и принятых методик [3]. В задаче результирующая (выходная) переменная $y(t)$ – расход электроэнергии на перекачку нефти за период t , (кВт*сут). Компоненты входного вектора $\mathbf{X}$ (компоненты вектора состояния):

$x_1(t) = V_{\text{тов}}(t)/V_{\text{pn}}$, где $V_{\text{тов}}$ – объём перекачиваемой нефти за период t , V_{pn} – объём резервуарного парка;

$x_2(t)$ – производительность режима перекачки в момент $(t-1)$;

$x_3(t)$ – разность геодезических отметок конца и начала трубы для рассматриваемого линейного участка;

$x_4(t)$ – вязкость нефти;

$x_5(t)$ – плотность нефти;

$x_6(t)$ – температура;

$x_7(t)$ – объём перекачиваемой нефти за период t и др.

При выборе архитектуры нейросети проведены многочисленные численные эксперименты. Наилучшие результаты были получены при использовании многослойного персептрона (MLP) [4] и быстрых нейронных сетей (БНС) [5]. Опыт нейросетевого моделирования объектов различного типа показывает, что при использовании многослойного персептрона наилучшее число скрытых слоёв равно двум. Для решения задачи аппроксимации выбрана следующая структура нейронной сети (НС): тип НС – многослойный персептрон; число скрытых слоёв – 2; алгоритм обучения НС – backpropagation; функция активации нейронов скрытого слоя – нечётная сигмоидальная функция; функция активации нейронов выходного слоя – линейная функция. С помощью многослойного персептрона было получено решение задачи с требуемой точностью.

Эксперименты, проведённые с быстрыми нейронными сетями, показали, что для решения данной задачи они наиболее пригодны. Быстрые нейронные сети [5] являются разновидностью многослойных нейронных сетей прямого распространения. БНС сопоставимы с обычными нейронными сетями примерно в том же отношении как алгоритмы быстрого преобразования Фурье (БПФ) с прямым дискретным преобразованием Фурье. Высокая вычислительная эффективность БНС достигается за счет разумных ограничений на структурную организацию нейронной сети [5]. Ниже приведены основные результаты нейросетевого моделирования, полученные с помощью быстрых нейронных сетей.

Результаты моделирования

Основные результаты построения модели идентификации. В табл. 1 приведен фрагмент вычислений на тестовом множестве. В таблице $y(t)$ – табличное значение расхода электроэнергии, $\tilde{y}(t)$ – модельное значение, t – номер точки, $h_t(\%)$ – относительная погрешность вычисления (в процентах), $h(t) = \frac{(y(t) - \tilde{y}(t))}{y(t)} \cdot 100$. Все значения в таблице нормированы.

Недостатком модели, при использовании её для прогноза, является то, что точность вычисления высока только в том случае, если погрешность входных данных нейросетевой модели невелика. Входные переменные построенной модели делятся на две группы. К первой относятся переменные, которые известны с достаточной точностью, например, $x_3(t)$ – разность геодезических отметок конца и начала трубы для рассматриваемого линейного участка. Ко второй группе относятся переменные, изменяющиеся во времени. Например, на вязкость и плотность перекачиваемой нефти влияет температура атмосферы.

Таблица 1

**Результаты вычислений модели идентификации
на тестовом множестве**

t	$y(t)$	$\tilde{y}(t)$	$h_k(\%)$
1	1,3072	1,2890	1%
2	-1,2855	-1,3173	2%
3	-1,2974	-1,2594	3%
4	-1,3038	-1,3050	0%
5	0,3475	0,3509	1%
6	1,2919	1,2666	2%
7	-1,2745	1,2604	1%

На рис. 2 показана динамика изменения значений вязкости. По оси ординат отложены значения вязкости, по оси абсцисс номер точки наблюдения. Точки наблюдения взяты за период три года. На графике верхние пики соответствуют зимнему периоду, нижние точки – летнему (колебания вязкости при постоянной температуре были незначительны). Следовательно, даже при условии известности характеристик перекачиваемой нефти на заданный период, необходимо учитывать изменение температуры воздуха на прогнозный период.




Рис. 2. Динамика изменения вязкости за период наблюдения

При использовании идентификационной модели с целью прогноза расхода электроэнергии необходимо разработать прогнозные модели временных рядов входных переменных. Для решаемой задачи построены модели временных рядов реологических свойств. В табл. 2 приведён фрагмент нормированных исходных данных реологических свойств нефти.

Значения плотности и вязкости приведены при указанной температуре измерения.

Таблица 2

**Фрагмент нормированных исходных данных
реологических свойств нефти**

Измерение		Температура	Вязкость	Плотность		
Начало	Конец					
дата	время				дата	время
31.01.09	0:00	31.01.09	8:00	-1,2	0,3	-0,9
31.01.09	8:00	31.01.09	16:00	-1,2	1,1	-0,4
31.01.09	16:00	01.02.09	0:00	-1,2	1,1	-0,5
01.02.09	0:00	01.02.09	8:00	-1,2	0,5	-1,4
01.02.09	8:00	01.02.09	16:00	-1,1	0,2	-0,8
01.02.09	16:00	02.02.09	0:00	-1,1	0,2	-0,5
02.02.09	0:00	02.02.09	8:00	-1,0	0,7	0,7
02.02.09	8:00	02.02.09	16:00	-1,0	0,8	1,0

В настоящее время плановая производительность трубопровода рассчитывается, исходя из планового на расчётный период объёма перекачки, плотности нефти и плановой продолжительности работы нефтепровода [3]. Кинематическая вязкость ($\text{м}^2/\text{с}$) и плотность ($\text{кг}/\text{м}^3$) для средней температуры нефти определяются опытным путём или рассчитываются по формулам. Средняя температура нефти рассчитывается по имеющимся данным температур аналогичного периода предыдущих 2–3-х лет. Проведённые автором исследования временных рядов температуры атмосферы, плотности и вязкости нефти показали, что данные ряды имеют фрактальную структуру. С математической точки зрения фрактальный объект обладает дробной размерностью. Другое важное свойство, которым обладают почти все фракталы – свойство самоподобия (масштабная инвариантность). При построении прогнозных моделей таких временных рядов предлагается использовать методы нелинейной динамики [6]. Автором построены две параллельные модели временных рядов, одна модель построена с использованием методов нелинейной динамики и с помощью нейросети, вторая модель – авторегрессионная $AR(1,1,0)$, построена с помощью методов математической статистики и пакета STATISTICA 6.0.

Приведём основные результаты моделирования.

Вычислены основные статистические характеристики показателей реологических свойств. Коэффициент выборочной корреляции между температурой и вязкостью равен $r = -0,66251$; между температурой и плотностью $r = -0,72369$; между плотностью и вязкостью $r = 0,591$. Для изучения наличия самоподобия в изучаемом процессе вычислен параметр Херста H (при помощи пакета Fraktan 4.4). Известно, что непрерывный стохастический процесс считается самоподобным, если $0,5 \leq H \leq 1$. Для вязкости нефти: показатель Херста H равен $0,8857$, фрактальная размерность равна: $Fr = 2 - H = 1,11$. Корреляционная размерность равна $C = 3$.

Таким образом, результаты вычислений автокорреляционной функции и показателей Херста свидетельствуют о самоподобном характере временных рядов. Полученный результат подтверждается и тем, что реологические свойства имеют высокий коэффициент корреляции с температурой. Известно, что именно исследования временных рядов температуры привели к открытию свойства самоподобности в аналогичных процессах. Полученные вычисления говорят о том, что при построении прогнозной модели можно использовать методы нелинейной динамики [6]. Результаты исследования временных рядов использовались в дальнейшем при выборе структуры НС модели.

Модель временного ряда можно записать в виде «отображения с запаздыванием»: $x(t) = F(x(t-1), \dots, x(t-p))$. Основная проблема реконструкции временных рядов состоит в выборе размерности входного вектора, т.е. числа p и в выборе структуры модели. Для решения этой задачи использованы методы нелинейной динамики, значение p выбрано по формуле [6]: $p = [2C] + 1$, где C – корреляционная размерность, $[.]$ – целая часть числа. Модели построены с помощью нейросети типа многослойный персептрон.

По тем же данным временного ряда построена авторегрессионная модель АРИМА: тип $AR(1,1,0)$. Для сравнения пригодности моделей решать задачи построения прогноза, модели протестированы на данных, не использованных при построении. Результаты вычислений на тестовом множестве приведены в табл. 3. В таблице в колонке x_4 – табличное значение вязкости (нормированное); x_4 (НС) – модельное значение НС; x_4 (АР) – модельное значение авторегрессионной модели; $\delta(НС)$, $\delta(АР)$ – относительные погрешности вычислений соответствующих моделей. Из таблицы видно, что НС, построенная с использованием методов нелинейной динамики, наиболее пригодна для решения задачи.

Дальнейшие исследования показали, что построенная идентификационная модель может быть использована для решения ряда других управленческих решений. Например, связанных с проектированием новых ли-

нейных участков нефтепровода или с изменением расположения скважины (следовательно, с изменением реологических свойств нефти). Ниже приведены результаты решения ещё одной задачи.

Таблица 3

Результаты вычислений прогнозных моделей

t	x_4	x_4 (НС)	x_4 (АР)	δ (НС)	δ (АР)
1	1,567795	1,195732	0,568278	0,237316	0,63753
2	0,775841	0,711248	0,514213	0,083255	0,337219
3	0,973888	0,518332	0,460679	0,46777	0,526969
4	0,228026	0,203455	0,330279	0,107755	-0,44843
5	-0,05393	-0,05905	0,300781	-0,09505	6,577455
6	0,304118	0,254958	0,272857	0,161648	0,102792
7	0,302165	0,32974	0,229784	-0,09126	0,239541
8	-0,29979	-0,27459	0,208906	0,084056	1,696843
9	-0,5337	-0,43585	0,156233	0,183338	1,292737




Рис. 3. График зафисимости расхода электроэнергии от вязкости

Пусть для принятия управленческих решений требуется оценить влияние реологических свойств, например, вязкости перекачиваемой нефти на расход электроэнергии. Предлагается следующий алгоритм. Нужно создать массив входных данных так, чтобы данные столбца, соответствующие вязкости, изменялись от минимального значения вязкости до максимального значения с некоторым постоянным шагом (но оставались в допустимой области решения задачи), а всем остальным входным величинам

нам присвоить постоянные значения, например, равные среднему значению на некотором интервале. Сформированный массив подается на вход нейросети, затем вычисляется соответствующий расход электроэнергии.

Результаты вычислений приведены на рис. 3. На графике по оси абсцисс отложены значения вязкости, по оси ординат значения расхода электроэнергии.

Заключение

Полученные результаты свидетельствуют о том, что для решения задачи можно использовать нейросетевые технологии. Построенные модели по данным одного линейного участка апробированы на данных аналогичного линейного участка трубопровода. Расчёты показали, что точность прогноза для другого линейного участка также удовлетворяет требованиям прогноза. Данный факт свидетельствует о возможности типизации моделей и о возможности использования моделей при проектировании магистрального нефтепровода. Разработанные математические модели позволят автоматизировать процесс планирования расхода электроэнергии, что повысит эффективность обслуживания магистрального нефтепровода. Приведённые примеры использования идентификационной модели позволяют предполагать, что нейросетевые модели могут эффективно дополнить дорогостоящие диагностики технического состояния нефтепровода.

Предлагаемые подходы решения задач управления магистральными нефтепроводами существенно отличаются от действующих в настоящее время методов. По приведённым в статье результатам, можно говорить об эффективности предлагаемых методов. В настоящее время исследования в этом направлении продолжаются.

Список литературы

1. Новоселов В.Ф., Левин В.С. Управление магистральными нефтепроводами при неполной информации. //Трубопроводный транспорт нефти: Сборник научных трудов. Уфа: ВНИИСПТнефть, 1981. С.105-109.
2. Айвазян С.А. Методы эконометрики: Учебник. М.: ИНФРА-М, 2010.
3. Регламент разработки технологических карт, расчета режимов работы магистральных нефтепроводов ОАО «АК «Транснефть». М., 2008.
4. Хайкин С. Нейронные сети: полный курс. – 2-е изд.: Пер. с англ. М. Издательский дом «Вильямс», 2006.
5. Дорогов А.Ю., Алексеев А.А. Структурные модели быстрых нейронных сетей. В сб. «Интеллектуальные системы» // Труды II-го Международного симпозиума/ Под ред. К.А. Пупкова. Т. 2. М.: ПАИМС, 1996. С.138-143.
6. Малинецкий Г.Г., Потапов А.Б., Подлазов А.В. Нелинейная динамика: Подходы, результаты, надежды. М.: Книжный дом «ЛИБРИКОМ», 2011.

**И.Е. ШЕПЕЛЕВ¹, И.И. НАДТОКА², С.А. ВЯЛКОВА²,
С.О. ГУБСКИЙ²**

¹НИИ нейрокибернетики им. А.Б. Когана Южного федерального университета,
Ростов-на-Дону

²Южно-Российский государственный политехнический университет
(Новочеркасский политехнический институт) имени М.И. Платова
shepelev@krinc.ru

ОПРЕДЕЛЕНИЕ ОПТИМАЛЬНЫХ МЕТАПАРАМЕТРОВ ДЛЯ НЕЙРОСЕТЕВОГО КРАТКОСРОЧНОГО ПРОГНОЗИРОВАНИЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ КРУПНОГО ГОРОДА

В работе рассматривается определение оптимальных метапараметров настройки нейронной сети для краткосрочного прогнозирования электропотребления на примере города Москва в весенне-летний период. Такими метапараметрами являются длина линии задержки на входе нейронной сети, размер её скрытого слоя, глубина обучающей выборки, радиус обучающей окрестности, набор информативных входных переменных и коэффициент регуляризации нейронной сети. Построение прогноза ведется на основе многослойного персептрона.

Ключевые слова: *многослойный персептрон, краткосрочное прогнозирование электропотребления, метапараметры.*

**I.E. SHEPELEV¹, I.I. NADTOKA², S.A. VYALKOVA²,
S.O. GUBSKY²**

¹A.B. Kogan Research Institute for Neurocybernetics, Southern Federal University,
Rostov-on-Don, Russia

²Platov South-Russian State Polytechnic University (Novocherkassk Polytechnic
Institute), Russia
shepelev@krinc.ru

OPTIMAL METAPARAMETERS IDENTIFICATION FOR NEURAL NETWORK SHORT- TERM FORECASTING OF ELECTRICITY CONSUMPTION OF A LARGE CITY

We consider the problem of optimal metaparameters identification for neural network, which is designed for short-term forecasting of electricity con-

sumption by the example of Moscow in the spring and summer season. These are the following metaparameters: length of the delay line at the input of the neural network, the size of its hidden layer, the depth of the training sample, the radius of the training surroundings, set of significant inputs and neural network regularization coefficient. Construction of the forecast is based on a multi-layer perceptron.

Keywords: *multilayer perceptron, short-term forecasting, electricity consumption, metaparameters identification.*

Введение

Прогнозирование электропотребления является одной из основных задач при планировании баланса электроэнергии региональными диспетчерскими управлениями [1]. Повышенные требования к точности прогноза потребления электрической энергии обусловлены технологическими и экономическими причинами. Отклонение прогноза от фактического электропотребления с одной стороны ведет к недостатку электроэнергии для потребителей, с другой стороны – экономически нецелесообразным покупкам электроэнергии. Наиболее востребованным для планирования баланса электроэнергии является краткосрочное прогнозирование, которое заключается в получении почасовых значений электропотребления в диапазоне от одних суток до двух недель вперед [2].

Потребление электрической энергии E представляется временным рядом $(E_1, \dots, E_i, \dots, E_n)$ значений потребляемой мощности, выражаемой в кило- или мегаваттах. Прогноз на один шаг вперед

$$fE_{i+1} = f(E_i, E_{i-1}, \dots, E_{i-d-1}, T, DW, \dots),$$

где f – функция прогноза, в общем случае строится как зависимость от d предыдущих значений временного ряда электропотребления $E_i, E_{i-1}, \dots, E_{i-d-1}$, а также погодных и календарных факторов, таких как температура воздуха T , день недели DW и других. Прогноз на один шаг вперед является основой для проведения последующего анализа способов прогнозирования на несколько шагов вперед.

В настоящей работе проводится определение оптимальных метопараметров для построения прогноза электропотребления города Москва на одни сутки вперед в весенне-летний период. В качестве основного вычислительного алгоритма использовался многослойный персептрон. Основным методом тестирования являлась скользящая оценка для временных

рядов с фиксированной длиной [3]. В вычислительных экспериментах определялись оптимальные значения следующих метапараметров: длина линии задержки на входе нейронной сети, количество нейронов в скрытом слое, глубина обучающей выборки, радиус обучающей окрестности, набор информативных входных переменных и коэффициент регуляризации нейронной сети. На этапе обучения модели прогноза и тестирования в качестве температуры воздуха использовались её фактические значения.

Экспериментальные данные

Данные для вычислительных экспериментов взяты за период с 01.01.2010 по 12.06.2014 и представляют собой временной ряд, составленный из суточных профилей (24-компонентный вектор) почасового электропотребления E (рис. 1), суточных профилей среднечасовой температуры окружающего воздуха T , значений длины световой части суток DL , а также календарных данных – день недели DW и тип дня DT в различных представлениях. Такими представлениями были: кодирование каждого дня одним из двух значений (праздничный и непраздничный), одним из трех значений (праздничный, послепраздничный и непраздничный), одним из четырех значений (предпраздничный, праздничный, послепраздничный и непраздничный).




Рис.1. Почасовой суточный профиль электропотребления в г. Москва за 22 мая 2014 года

Во всех экспериментах тестовую выборку составляли 23 последних суток временного ряда, что соответствовало датам с 21.05.2014 по 12.06.2014. Предварительная обучающая выборка формировалась по пра-

вилам проведения процедуры скользящей оценки, т.е. включала все предшествующие текущему тестовому примеру экземпляры данных общего временного ряда. Окончательная обучающая выборка определялась варьируемыми в вычислительных экспериментах параметрами глубины обучающей выборки и радиуса обучающей окрестности. Размеры окончательной обучающей выборки составляли минимально 20 примеров, максимум – 810 примеров.

Вычислительные эксперименты

Нейронная сеть. Построение модели прогноза проводилось на основе многослойного персептрона, обучаемого алгоритмом L-BFGS [4]. Алгоритм использует информацию о первых производных функции оценки по весовым коэффициентам нейронной сети, которые вычисляются стандартным нейросетевым методом обратного распространения ошибки [5], для того чтобы вычислить производные второго порядка, что делает настройку весовых коэффициентов максимально эффективной. Алгоритм применим для нейронных сетей с большим количеством весов, что справедливо для нашего случая. В вычислительных экспериментах число весовых коэффициентов нейросети составляло ~200–5500.

Априорно была выбрана нейронная сеть с одним скрытым слоем и 24 выходами для единовременного прогнозирования полного почасового суточного профиля электропотребления.

Размеры входного и скрытого слоев. Размеры входного слоя зависели от выбранной длины линии задержки на входе нейросети для временного ряда суточных профилей электропотребления и количества учитываемых погодных и календарных факторов. Длина линии задержки в экспериментах варьировалась от нуля до 4. Ноль соответствовал случаю отсутствия на входе нейросети данных электропотребления, поэтому, для того чтобы учитывался линейный тренд в данных, который можно видеть на графике суммарных суточных данных электропотребления за несколько лет (рис. 2), на вход подавался порядковый номер примера в общей выборке данных. В остальных случаях наличие на входе нейросети предшествующих, относительно прогнозируемых, данных электропотребления отражало авторегрессионный характер модели прогноза.

Длина линии задержки входного слоя и размер скрытого слоя определялись методом бинарного поиска. Варианты учитываемых погодных и календарных факторов перечислены в предыдущем разделе. Поиск набора информативных факторов проводился методом перебора. Среднечасовые значения температуры окружающего воздуха за сутки являлись обяза-

тельными переменными на входе нейросети из-за очевидной жесткой зависимости электропотребления от температуры воздуха, что демонстрируется на рис.3 для рассматриваемой задачи.




Рис. 2. График суммарных суточных данных электропотребления за период с 01.01.2010 по 12.06.2014, демонстрирующий линейный тренд из-за постоянного прироста электропотребления




Рис. 3. Нелинейная зависимость электропотребления от температуры воздуха. График построен по почасовым данным электропотребления и температуры для г. Москва за период с 01.03.2013 по 01.03.2014

Скольльзящая оценка. Для оценки точности прогноза вычислялась усредненная по 23 тестовым суткам среднесуточная относительная ошибка *MAPE* в процентах

$$MAPE = \frac{|FE - E|}{E} 100 \ \%.$$

Тестирование проводилось методом скользящей оценки. Процедура единичной скользящей оценки тестовой выборки состояла из 23 итераций, каждая из которых включала извлечение очередного одного тестового экземпляра из общей выборки данных и назначения в качестве предварительной обучающей выборки всех экземпляров данных временного ряда, предшествующих тестовому.

Глубина обучающей выборки и радиус обучающей окрестности. Формирование окончательной обучающей выборки было одним из предметов вычислительных экспериментов по поиску оптимальной глубины обучающей выборки и оптимального радиуса обучающей окрестности, определяемой относительно числа и месяца текущего тестового экземпляра данных. Определение оптимальной глубины обучающей выборки обусловлено, с одной стороны, необходимостью иметь достаточный для отражения функциональной зависимости объем обучающих данных, а с другой – необходимостью минимизации влияния изменчивого характера данных в долговременной перспективе, измеряемой годами. Аналогичной цели служит определение оптимального радиуса обучающей окрестности с той разницей, что ограничение сверху обусловлено необходимостью минимизации влияния изменчивого характера данных в силу сезонности погодных явлений. В вычислительных экспериментах глубина обучающей выборки варьировалась в диапазоне от года до 4,5 лет, радиус обучающей окрестности – от 10 до 90 дней в сторону предшествующих и последующих примеров временного ряда относительно числа и месяца текущего тестового экземпляра данных. Определение оптимальных значений глубины обучающей выборки и радиуса обучающей окрестности проводилось методом перебора с шагом полгода для первого параметра, шагом 10 или 15 дней для второго.

Регуляризация. Простое сравнение указанных выше количества обучающих примеров и весовых коэффициентов нейронной сети позволяет предположить высокую вероятность переобучения нейронной сети в результате работы алгоритма настройки её весовых коэффициентов [6]. Наибольший вклад в перепараметризацию нейронной сети внес наш выбор построения прогноза электропотребления для полного 24-часового суточного профиля электропотребления, поэтому единичное увеличение

количества скрытых нейронов ведет почти к 50-кратному увеличению числа весовых коэффициентов (минимально на входе нейросети всегда 24-компонентный вектор электропотребления или температуры, на выходе – 24-компонентный вектор электропотребления). Из двух методов предотвращения переобучения нейросети – 1) раннего останова процесса обучения и 2) регуляризации весовых коэффициентов – мы выбрали второй, который состоит в добавлении дополнительного термина в функцию оценки:

$$C(w) = \frac{1}{2} \sum_{k,n} (y_{k,n}^{out} - y_{k,n}^d)^2 + \frac{1}{2} \lambda \sum_i w_i^2,$$

где k – индекс нейрона выходного слоя, n – индекс обрабатываемого сего примера обучающих данных, $y_{k,n}^{out}$ – фактическое выходное значение сети k -го выходного нейрона для n -го примера, $y_{k,n}^d$ – требуемое выходное значение (обучающий сигнал) k -го выходного нейрона для n -го примера, i – индекс весового коэффициента w нейронной сети, λ – коэффициент регуляризации. Метод регуляризации хорошо подходит для решаемой в настоящей работе задачи определения глубины обучающих данных и радиуса обучающей окрестности, т.к. не требует выделения из обучающих данных некоторого объема для валидационной выборки, как это происходит для метода раннего останова. Определение оптимального значения коэффициента регуляризации проводилось методом перебора в диапазоне абсолютных значений от 10^{-4} до 10^9 шагом 1 по шкале десятичного логарифма.

Результаты

На начальном этапе вычислительных экспериментов определялась длина линии задержки для временного ряда электропотребления на входе нейросети и количество нейронов в её скрытом слое посредством бинарного поиска в двумерном пространстве искомого параметров. Оптимальными оказались единичная длина линии задержки на входе, т.е. использование значений почасового электропотребления за одни, предшествующие прогнозным, сутки, и 30 нейронов в скрытом слое.

На следующем этапе осуществлялся поиск оптимальных значений четырех метапараметров: глубины обучающей выборки, радиуса обучающей окрестности, набора информативных входных переменных и коэффициента регуляризации. Была применена скользящая оценка по тестовому множеству с полным или частичным перебором по указанным в предыдущем разделе диапазонам значений для каждого из четырех метапа-

раметров. На практике удобным оказался метод поиска лучшего значения тестовой средней относительной ошибки с помощью двумерной решетки, образованной значениями первых двух метапараметров. Сначала выбирался тестируемый набор входных переменных, затем инициализировалось очередное значение коэффициента регуляризации и получали значения средней относительной ошибки на двумерной решетке. Срез результатов вычислительных экспериментов для фиксированных найденных лучших значений параметров глубины обучающей выборки (3 года), радиуса обучающей окрестности (75 дней) и коэффициента регуляризации (10^7) и разных наборов входных переменных представлен в табл. 1.

Таблица 1

Результаты вычислительных экспериментов для разных наборов входных переменных и оптимальных метапараметров глубины обучающей выборки (3 года), радиуса обучающей окрестности (75 дней) и коэффициента регуляризации (10^7)

Входные данные	T_{24} DW_1 ND	E_{24} T_{24}	E_{24} T_{24} DW_1	E_{24} T_{24} DW_2	E_{24} T_{24} DW_1 DT ₁	E_{24} T_{27}
Средняя относительная ошибка, %	4,4	2,3	1,7	1,9	1,5	2,1
Входные данные	E_{24} T_{27} DW_1	E_{24} T_{27} DW_2	E_{24} T_{27} DW_1 DT ₁	E_{24} T_{27} DW_7	E_{24} T_{27} DW_7 DT₄	E_{24} T_{27} DW_1 DT ₁ DL
Средняя относительная ошибка, %	1.4	1.8	1.4	1.5	1.1	1.5

Примечание. Наилучший набор входных переменных выделен полужирным шрифтом; E обозначает электропотребление, T – температура воздуха, DW – день недели, DT – тип дня, DL – длина световой части суток, ND – порядковый номер примера в общей выборке данных; индексы обозначают количество компонент соответствующего вектора, для номинальных переменных, таких как день недели и тип дня, они обозначают также тип кодирования: 1 обозначает кодирование градуальными вещественными значениями однокомпонентного вектора, 2 – циклическое кодирование двухкомпонентным вектором [7], 4 – позиционное кодирование четырехкомпонентным вектором, 7 – позиционное кодирование семикомпонентным вектором.

Приведенные результаты усреднены по 3 повторным экспериментам. Наилучший набор входных переменных состоял из 24-компонентного вектора электропотребления за предшествующие прогнозируемым сутки, 27-компонентного вектора температуры, который включал 24 значения среднечасовой температуры на прогнозируемые сутки и дополнительно температуру за последние 3 часа предшествующих суток, и дня недели и типа дня, которые кодировались позиционным методом, поэтому представляли собой вектора с 7 и 4 компонентами соответственно. Среди разных представлений типа дня наилучшим было кодирование каждого суток четырьмя значениями: предпраздничный, праздничный, послепраздничный и непраздничный.

Заключение

В работе предложена методика поиска и найдены оптимальные значения метапараметров настройки многослойного персептрона для прогнозирования электропотребления на одни сутки вперед для города Москва в весенне-летний период. Такими метапараметрами были длина линии задержки для временного ряда электропотребления на входе нейронной сети, размер её скрытого слоя, глубина обучающей выборки, радиус обучающей окрестности, набор информативных входных переменных и коэффициент регуляризации нейронной сети. Основным методом поиска оптимальных значений метапараметров был комбинированный подход полного или частичного перебора со скользящей оценкой на тестовом множестве. Особенностью нейросетевой модели была тенденция к значительному переобучению, что потребовало большой величины коэффициента регуляризации. В нейросетевой модели с оптимальными метапараметрами на один обучающий пример приходится примерно 6 весовых коэффициентов. Тем не менее, на тестовой выборке итоговый разброс значений средней относительной ошибки в повторных экспериментах не превосходил $\pm 0,1\%$ при средней относительной ошибке $1,1\%$.

Список литературы

1. Надтока И.И., Губский С.О., Шепелев И.Е. Нейросетевая модель прогнозирования электропотребления с учетом освещенности на территориях операционных зон региональных диспетчерских управлений.// Изв. вузов. Электромеханика. 2012. № 2. С.18-21.
2. Tao Hong. Short Term Electric Load Forecasting. PhD dissertation, North Carolina State University, 2010.

3. Воронцов К.В. Скользящий контроль [Электронный ресурс]. 2014. Режим доступа: <http://www.machinelearning.ru/wiki/index.php?title=CV>.
4. Гилл Ф., Мюррей У., Райт М. Практическая оптимизация. /Пер. с англ. М.: Мир, 1985.
5. Хайкин С. Нейронные сети: полный курс. 2-е изд. М.: ИД «Вильямс», 2006.
6. Hippert H.S., Bunn D.W. and Souza R.C. Large neural networks for electricity load forecasting: Are they overfitted? //International Journal of Forecasting, 2005. V. 21, issue 3. P. 425-434.
7. Осовский С. Нейронные сети для обработки информации. /Пер. И.Д. Рудинского. М.: Финансы и статистика, 2004.

**И.В. ИСАЕВ¹, С.А. ДОЛЕНКО¹, И.Е. ОБОРНЕВ²,
Е.А. ОБОРНЕВ², М.И. ШИМЕЛЕВИЧ²**

¹НИИ ядерной физики имени Д.В. Скобельцына МГУ им. М.В. Ломоносова,
Москва

²Российский государственный геологоразведочный университет
им. С.Орджоникидзе, Москва
isaev_igor@mail.ru, dolenko@srd.sinp.msu.ru

ПОВЫШЕНИЕ ТОЧНОСТИ НЕЙРОСЕТЕВОГО РЕШЕНИЯ МНОГОПАРАМЕТРИЧЕСКИХ ОБРАТНЫХ ЗАДАЧ ПРИ ГРУППИРОВКЕ ОПРЕДЕЛЯЕМЫХ ПАРАМЕТРОВ: ПРОВЕРКА НА МОДЕЛЬНЫХ ДАННЫХ*

При решении многопараметрических обратных задач (ОЗ) задача обычно решается отдельно для каждого параметра. В предыдущих работах было показано, что объединение параметров в группы с одновременным определением значений всех параметров группы в ряде случаев позволяет повысить точность решения при решении многопараметрической ОЗ электроразведки. В данной работе была проведена проверка наблюдаемого эффекта на модельных данных, заданных явным образом.

Ключевые слова: *нейронные сети, обратные задачи высокой размерности, групповое определение параметров, электроразведка.*

* Исследование выполнено за счет гранта Российского научного фонда (проект №14-11-00579).

**I.V. ISAEV¹, S.A. DOLENKO¹, I.E. OBORNEV²,
E.A. OBORNEV², M.I. SHIMELEVICH²**

¹Skobeltsyn Institute of Nuclear Physics, Lomonosov Moscow State University, Russia

²Russian State Geological Prospecting University n. a. Sergo Ordzhonikidze, Moscow, Russia

isaev_igor@mail.ru, dolenko@srd.sinp.msu.ru

IMPROVING THE ACCURACY OF NEURAL NETWORK SOLUTION OF MULTI-PARAMETER INVERSE PROBLEMS BY GROUP DETERMINATION OF PARAMETERS: VERIFICATION ON MODEL DATA

When solving multi-parameter inverse problems (IP), the problem is usually solved separately for each parameter. In previous studies it was shown that aggregation of parameters into groups with simultaneous values determination of all the parameters of the group in some cases allows improving the accuracy of the solution for solving multi-parameter IP of electrical prospecting. In this study, the observed effect was verified on model data defined explicitly.

Keywords: *neural networks, inverse problem of high dimensionality, group determination of parameters, electrical prospecting.*

Введение

При нейросетевом решении многопараметрических обратных задач возможны несколько подходов:

1. Решение отдельной ОЗ с одним выходом с построением отдельной НС для каждого из определяемых параметров (*автономное определение*). Этот подход наиболее универсален и применяется чаще всего.

2. Решение одной ОЗ с *одновременным определением* всех искоемых параметров, что соответствует построению одной НС с числом выходов N_O , равным полному количеству определяемых параметров. Эффективность такого подхода достаточно быстро деградирует с увеличением N_O .

3. Объединение параметров в группы с одновременным определением параметров (и построением одной НС) внутри каждой группы (*групповое определение*). Способ объединения в группы диктуется при этом физическим смыслом определяемых параметров и их известными взаимосвязями.

4. *Поэтапное определение* параметров. В рамках этого подхода на первом этапе определяются независимо друг от друга или одновременно те параметры, для которых эту задачу удаётся решить с приемлемой точностью. На последующих этапах значения этих параметров, полученные при применении НС первого этапа, подаются на вход НС вместе со значениями входных признаков. Этот подход исследовался в работе [1], где было зафиксировано повышение качества решения.

Понижение размерности задачи по входу при автономном определении параметров достигается путем отбора наиболее существенных входных признаков. Отметим, что при правильном осуществлении отбора вычислительная стоимость нейросетевого решения снижается, а качество решения ОЗ повышается [2]. При групповом определении на входы каждой НС подаются все входные признаки, существенные хотя бы для одного из определяемых параметров.

Рассмотрение группового определения параметров было начато авторами ранее [3]. Целью настоящего исследования являлось выяснение того, чем обусловлен наблюдаемый положительный эффект группового определения параметров при решении ОЗ. Определяется ли он свойствами конкретной задачи или является фундаментальным свойством нейронных сетей как метода решения ОЗ?

Обратная задача магнитотеллурического зондирования

Рассмотрим коротко обратную задачу электроразведки в постановке ОЗ магнитотеллурического зондирования (МТЗ), для которой были получены первые результаты по групповому определению параметров.

ОЗ МТЗ представляет собой построение распределения электропроводности в толще Земли по измеренным на ее поверхности компонентам электромагнитного поля. Соответствующая этой ОЗ прямая задача состоит в следующем. Рассматриваются плоские волны, падающие перпендикулярно поверхности Земли. Электромагнитное поле в двумерной задаче разделяется на две независимые моды [4, с. 185].

В случае E -моды электромагнитное поле содержит только компоненты E_x , H_y , H_z (рис. 1).

Компонента E_x вычисляется методом конечных разностей из уравнения Гельмгольца, где проводимость σ входит в коэффициент k :

$$\Delta E_x + k^2 E_x = 0,$$

$$k^2 = i\omega\mu_0\sigma.$$

Здесь ω – круговая частота поля, μ_0 – магнитная проницаемость вакуума.

Компоненты H_y и H_z вычисляются по формулам:

$$H_y = -\frac{1}{i\omega\mu_0} \frac{\partial E_x}{\partial z}, \quad H_z = -\frac{1}{i\omega\mu_0} \frac{\partial E_x}{\partial y}.$$




Рис. 1. Двумерная геологическая модель, применяемая для решения прямой задачи электроразведки

Для случая H -моды и соответствующих ей компонент поля H_x , E_y и E_z вычисления проводятся аналогично.

Таким образом, обратная задача электроразведки является коэффициентной обратной задачей для уравнения Гельмгольца. Она некорректна, нелинейна, многопараметрическая, высокой размерности [5].

Для нее не известны ни аналитическое, ни прямое численное решения.

Традиционным методом решения таких задач является метод минимизации невязки [6, с. 218], основанный на многократном решении прямой задачи. Это определяет недостатки, присущие данному методу: высокая вычислительная стоимость, низкая скорость работы, необходимость задания первого приближения; при использовании этого метода велика роль эксперта. Одним из методов, лишенных многих недостатков, присущих традиционным методам решения ОЗ МТЗ, является использование НС. В данной работе рассматривается способ использования НС, представляющий собой непосредственное решение сетью искомой задачи, когда на входы НС подаются значения компонент полей, а на выходах формируются оценки одного или нескольких параметров, описывающих распределение электропроводности.

Описанный массив данных использовался для решения ОЗ – определения значений электропроводности ($N_O = 336$ параметров, см. рис. 2) по значениям полей ($N_I = 4$ компоненты поля $\times 13$ частот $\times 126$ пикетов = 6552 входных признака).

Решение данной ОЗ сопряжено со значительными трудностями, связанными с большой размерностью входных и выходных данных.

Результаты нейросетевого решения ОЗ МТЗ

Исследовалось решение задачи для параметров, помеченных на рис. 2. Использовались сети с количеством выходов $S_g = 1, 2, 3, 4, 5, 7, 9, 11$ и 13 , соответствующим числу группируемых параметров. Желаемыми выходами являлись значения электропроводности блоков с номерами 17, 50, ..., 302, 323 из столбца №16 (см. рис. 2). Для каждой сети использовались данные соответствующего количества соседних по вертикали блоков, со сдвигом рассматриваемой группы по вертикали. Например, результат решения ОЗ для центрального блока № 5 0 был получен с помощью сетей, одновременно решавших задачу для следующих комбинаций блоков: только 50; (17, 50); (50,83); (17,50,83); (50,83,116); (17,50,83,116); (50,83,116,149) и т.д.

Таким образом, возникала возможность исследовать зависимость качества решения как от размера вертикальной группы, так и от её положения по вертикали в пределах разреза. Отметим, что в этом случае объединяемые в группы блоки имели значительное количество общих существенных входных признаков.

Качество решения задачи оценивалось по величине коэффициента множественной детерминации R^2 . Напомним, что для модели, в точности описывающей выборку, $R^2 = 1$, а для модели, ответ которой для любого примера равен среднему значению по выборке, $R^2 = 0$.

На рис. 3 и 4 приведены результаты НС решения ОЗ МТЗ с групповым определением параметров. Обратим внимание на следующее:

1) для верхнего блока № 17 качество группового решения ОЗ возрастает по сравнению с качеством автономного определения при включении в группу до 4 выходных признаков. Однако наилучший результат достигается при размере группы $S_g = 2$;

2) для блока № 50, качество решения задачи для которого в режиме автономного определения является наилучшим (см. рис. 3), переход к групповому определению всегда ухудшает результат.

3) Для более глубоко лежащих блоков ситуация зависит от положения "окна" группировки параметров. При смещении окна вверх (к параметрам, лучше определяемым в автономном режиме) переход к групповому режиму улучшает результат, при смещении вниз – как правило, ухудшает.

В целом можно сделать следующий вывод: улучшение качества решения для некоторого параметра при переходе к групповому определению (см. рис. 4) чаще всего может достигаться в тех случаях, когда одновременно с ним будут определяться параметры, качество определения которых в автономном режиме лучше, чем у данного (см. рис. 3). Этот же фактор влияет на оптимальное количество группируемых параметров.




Рис. 3. Зависимость качества решения ОЗ МТЗ (R^2) от номера блока (см. рис. 2) и способа определения параметра

Наблюдаемый эффект можно объяснить влиянием следующих факторов. С одной стороны, добавление новых признаков несет новую информацию об объекте, и если нейронная сеть в состоянии ее использовать, то качество решения повышается. С другой стороны, происходит ухудшение соотношения количества входных признаков и количества примеров, и это приводит к ухудшению качества решения.

Кроме того, существует отдельный эффект группового определения.

Итоговый результат зависит от соотношения этих эффектов.

Для того чтобы подтвердить существование эффекта группового определения, мы рассмотрим простую задачу, в которой отсутствуют первые два фактора.




Рис. 4. Зависимость качества решения ОЗ МТЗ (R^2) от размера S_g и положения окна группировки для разных блоков

Проверка эффекта группового определения на модельных данных, заданных явным образом

Рассмотрим модельную обратную задачу (рис. 5) с пятью входными признаками x_i , каждый из которых зависит от всех пяти определяемых параметров y_j .

Зададим обратную задачу при помощи простой полиномиальной модели с коэффициентами a_{ij} , b_{ij} , c_{ijk} , d_{ij} , e_i :

$$x_i \sim \sum_{j=1}^5 a_{ij} \cdot y_j^3 + \sum_{j=1}^5 b_{ij} \cdot y_j^2 + \\ + \sum_{j=1}^4 \sum_{k=j+1}^5 c_{ijk} \cdot y_j \cdot y_k + \sum_{j=1}^5 d_{ij} \cdot y_j + e_i.$$




Рис. 5. Схема рассматриваемой модельной обратной задачи

Монотонное убывание точности (рис. 6) обеспечим при помощи зависимости коэффициентов от условного расстояния от входов до выходов (см. рис. 5). В нашей работе они обратно пропорциональны квадрату расстояния:

$$a_{ij} \sim b_{ij} \sim d_{ij} \sim \frac{1}{i^2 + j^2}, \quad c_{ijk} \sim \frac{a_{ij} + a_{ik}}{2}, \quad e_i \sim \sum_{j=1}^5 a_{ij}.$$

Значения параметров y_i изменяются в диапазоне от 0 до 1 случайным образом.




Рис. 6. Зависимость качества решения модельной ОЗ (R^2) от номера блока (см. рис. 5) и способа определения параметра

На рис. 6 и 7 приведены результаты нейросетевого решения модельной ОЗ с групповым определением параметров. Для самого верхнего блока, который автономно определяется лучше всех, групповое определение ухудшает качество решения. Для остальных блоков картина аналогична

ранее упомянутым результатам. Группировка со смещением вверх улучшает результат, со смещением вниз – ухудшает.




Рис. 7. Зависимость качества решения ОЗ (R^2) от размера S_g и положения окна группировки для разных блоков

Объяснение наблюдаемых эффектов особенностями обучения персептрона при группировке определяемых параметров, приведённое в [3], таким образом, было дополнительно подтверждено. Можно утверждать, что наблюдаемый эффект группового определения параметров связан не со свойствами конкретной задачи, а со свойствами многослойного персептрона как алгоритма обработки данных.

Заключение

Основные результаты наших исследований следующие:

- подтверждено существование положительного эффекта группового определения параметров для нейросетевого решения многопараметрических обратных задач;
- показано, что этот эффект связан с фундаментальными свойствами нейронных сетей, а не со свойствами данных. Поэтому этот метод может быть использован при решении и других многопараметрических обратных задач.

Авторы выражают благодарность А.Г. Гужва, разработавшему программное обеспечение, на котором была выполнена данная работа.

Список литературы

1. Доленко С.А., Исаев И.В., Оборнев Е.А. Персианцев И.Г., Шимелевич М.И. Исследование эффективности поэтапного определения параметров при нейросетевом решении обратной задачи электроразведки. // Нейроинформатика-2013. XV Всероссийская научно-техническая конференция. Сборник научных трудов. Ч.2, М.: НИЯУ МИФИ, 2013. С. 215–225.
2. Dolenko, S., Guzhva, A., Osborne, E., Persiantsev, I., Shimelevich, M. Comparison of Adaptive Algorithms for Significant Feature Selection in Neural Network Based Solution of the Inverse Problem of Electrical Prospecting. // Lecture Notes in Computer Science, 2009. V. 5769. P. 397-405.
3. Dolenko S., Isaev I., Osborne E., Persiantsev I., Shimelevich M. Study of Influence of Parameter Grouping on the Error of Neural Network Solution of the Inverse Problem of Electrical Prospecting. // Communications in Computer and Information Science (CCIS), 2013. V. 383. P. 81-90.
4. Жданов М.С. Электроразведка. М.: Недра, 1986.
5. Бердичевский М.Н., Дмитриев В.И. Обратные задачи магнитотеллурики в современной постановке. // Физика Земли, 2004. № 4. С. 12-29.
6. Дмитриев В.И. Обратные задачи геофизики. М.: МАКС Пресс, 2012.

М.В. БУРАКОВ

Санкт-Петербургский государственный университет аэрокосмического
приборостроения
bmv@sknt.ru

РАЗРАБОТКА НЕЙРОЭМУЛЯТОРА ДЛЯ НЕЛИНЕЙНОГО ДИНАМИЧЕСКОГО ОБЪЕКТА

Рассматривается задача синтеза нейроэмулятора для класса нелинейных динамических объектов, которые допускают описание с помощью модели Гаммерштейна с заранее неизвестными параметрами. Для обучения нейроэмулятора используется генетический алгоритм. Качество работы нейроэмулятора проверяется путем моделирования в пакете *MatLab Simulink*.

Ключевые слова: *нейроэмулятор, нелинейный динамический объект, генетический алгоритм.*

M.V. BURAKOV

Saint Petersburg State University of Aerospace Instrumentation, Russia
bmv@sknt.ru

DESIGN OF NEURO-EMULATOR FOR NONLINEAR DYNAMIC PLANT

In this paper, we consider the problem of synthesis a neuro-emulator for a class of nonlinear dynamical plants which can be described by the Hammerstein model with unknown parameters. Learning of neuro-emulator used genetic algorithm. The quality of the neuro-emulator is checked by modeling in MatLab Simulink package.

Keywords: *neuro-emulator, nonlinear dynamic plant, genetic algorithm.*

Введение

Задача построения нейросетевой модели динамического объекта (нейроэмулятора) допускает различные постановки в зависимости от уровня неопределенности о структуре и параметрах объекта управления. В любом случае имеется выборка входов и выходов объекта на интервале времени, достаточном для выявления его динамических свойств.

При конструировании нейроэмуляторов традиционно используются нейронные сети (НС) прямого распространения [1, 2], хотя здесь возможно и использование НС других типов, например, нечетких НС [3] или сетей Хопфилда [4]. НС прямого распространения являются статическими, и для внесения динамики в их поведение применяется простой прием – на вход сети подаются не только текущие, но и задержанные значения входа и выхода. Количество задержанных сигналов и величина задержки зависят от конкретного объекта (рис. 1).

Для линейного динамического объекта задача синтеза нейроэмулятора не вызывает затруднений, она легко может быть решена с помощью метода обратного распространения ошибки и его модификаций на базе НС прямого распространения с линейными активационными функциями.

Для нелинейных динамических объектов также возможно использование метода обратного распространения ошибки, однако здесь значительно усложняется структура НС, которая должна содержать большое количество нейронов с нелинейными функциями активации [5].




Рис. 1. Общая схема обучения нейроэмулятора

Необходимо также заметить, что алгоритм обратного распространения ошибки корректирует веса межнейронных связей, параметры нелинейных активационных (обычно – гиперболический тангенс *tansig*) при этом не меняются. Желаемое поведение достигается при взвешенном суммировании выходов этих нейронов, т.е. при наращивании количества слоев НС. Одновременная коррекция и весов НС, и параметров активационных функций нейронов возможна при использовании эволюционных методов

оптимизации, таких как генетический алгоритм (ГА). Но и в этом случае для эффективного решения задачи конструирования нейроэмулятора необходимо максимально упростить структуру НС, потому что при большой длине хромосом нельзя гарантировать нахождение приемлемого решения за допустимое время поиска.

Упрощение структуры НС возможно при учете существующих априорных сведений об объекте управления. Ниже рассматривается вариант представления структуры нейроэмулятора для широкого класса нелинейных динамических объектов, позволяющий упростить задачу обучения НС.

Модель Гаммерштейна для описания нелинейных объектов

Математическое описание многих промышленных объектов (электрических, электромеханических, гидравлических и т.д.) с одним входом и одним выходом можно представить в виде так называемой модели Гаммерштейна, содержащей последовательно включенные линейную динамическую часть и статическое нелинейное звено (рис. 2).




Рис. 2. Модель Гаммерштейна

Некоторые типовые нелинейности показаны на рис. 3.




Рис. 3. Типовые нелинейности:

a – насыщение (*saturation*); b – зона нечувствительности (*dead zone*)

Нелинейность типа «насыщение» вводится в модель для учета ограничений уровней переменных при исследовании поведения систем управления в режимах больших отклонений от положения равновесия, а также для описания максимальных уровней управляющего сигнала.

Нелинейный элемент типа «зона нечувствительности» учитывает реальные свойства датчиков, исполнительных механизмов и других устройств при малых входных сигналах.

Важное значение имеют также нелинейности типа «сухое трение», «вязкое трение», гистерезис и некоторые другие. Для описания нелинейностей можно использовать аналитическое, табличное, а также нейросетевое представление.

Линейная часть обычно описывается с помощью передаточной функции (ПФ). Поскольку измерения входа и выхода системы рассматриваются в дискретные моменты времени, используется дискретное представление ПФ в виде:

$$W(z) = \frac{Y(z)}{X(z)} = \frac{b_0 + b_1 z^{-1} + \dots + b_m z^{-m}}{a_0 + a_1 z^{-1} + \dots + a_n z^{-n}},$$

где оператор z^{-1} означает задержку на один такт.

Этой формуле соответствует структура, показанная на рис. 4.




Рис. 4. Графическое представление дискретной ПФ

Структура рис. 4 очевидным образом напоминает искусственный нейрон с линейной активационной функцией, а нелинейности, показанные на рис. 3, являются, по существу, нелинейными активационными функциями. Таким образом, модель Гаммерштейна допускает нейросетевое представление.

Постановка задачи и предлагаемые подходы к решению

В теории автоматического управления обычно рассматривается задача параметрической идентификации динамического объекта. Структура модели полагается известной, обычно она задана в виде дифференциального уравнения заданного порядка. Нейронная сеть является, как правило, «черным ящиком». Поэтому задача построения нейросетевого эмулятора относится к задачам непараметрической идентификации.

Методы и идеи классической теории автоматического управления могут эффективно взаимодействовать с нейросетевыми моделями. Так, например, в [6] рассмотрен вариант реализации нелинейного ПИД-регулятора на базе НС. В данной работе исследуется простой вариант реализации нейроэмулятора, основанный на предположении, что объект может быть описан структурой из последовательно соединенных линейной части и статической нелинейности. В такой постановке НС превращается в «серый ящик», обучение которого упрощается.

Многие реальные динамические объекты описываются с помощью ПФ 2-го порядка – аperiodических и колебательных звеньев. Согласно рис. 4 таким объектам будет соответствовать НС, показанная на рис. 5, содержащая всего четыре настраиваемых коэффициента.

При описании нелинейности F будем считать, что сигнал на входе нелинейности нормированный, а сама нелинейность симметрична. Тогда при выборе, например, 4-х точек для аппроксимации получаем зависимость, показанную на рис. 6.

Координаты точек перегиба нелинейности по оси ординат a_i первоначально получают случайные значения, которые уточняются в процессе обучения.

Таким образом, в соответствии с рис. 5 и 6 при обучении требуется определить 8 параметров нейроэмулятора – 4 веса НС и 4 параметра нелинейности.

При использовании для обучения ГА [7] решение задачи будет кодироваться хромосомой длиной 8 битов, каждый из которых представляет собой действительное число:

$$[w_1 \ w_2 \ w_3 \ w_4 \ a_1 \ a_2 \ a_3 \ a_4].$$




Рис. 5. Структура нейроэмулятора




Рис. 6. Аппроксимация нелинейности

Количество точек для аппроксимации нелинейности может быть выбрано и большим, это повышает точность представления, но увеличивает сложность задачи оптимизации.

Для объектов, имеющих порядок выше 2-го, увеличится и количество задержек на входе нейроэмулятора, соответственно вызывая рост длины хромосомы.

Результаты моделирования

Моделирование выполнялось средствами пакета *MatLab/Simulink* с расширениями *Neural Net toolbox* и *Genetic Algorithm and Direct search toolbox*.

Была рассмотрена задача синтеза нейроэмулятора для динамического объекта 2-го порядка с нелинейностями типа *dead zone* или *saturation*.

Схема моделирования представлена на рис. 7.

На первом этапе были исследованы возможности линейной НС, обучаемой с помощью алгоритма обратного распространения ошибки. На входе системы подавалась тестирующая последовательность импульсов со случайной амплитудой.




Рис. 7. Блок-схема синтеза нейроэмулятора в MatLab/Simulink

Результат обучения показан на рис. 8 (а – входной сигнал, б – выход объекта, в – выход нейроэмулятора). Ошибка выхода нейроэмулятора оказывается значительной и не устраняется при увеличении количества слоев или нейронов НС. На рис. 9 показана работа нелинейного эмулятора.




Рис. 8. Работа линейного эмулятора при нелинейности *dead zone*




Рис. 9. Работа нелинейного эмулятора при нелинейности *dead zone*

Сравнение рис. 8 и 9 показывает, что нелинейный эмулятор, настроенный с помощью ГА по восьми параметрам, обеспечивает намного меньшую ошибку выхода.

На рис. 10 приведен результат настройки нейроэмулятора для объекта 2-го порядка с нелинейностью типа *saturation*. Выход нейроэмулятора также обеспечивает достаточно малую ошибку.




Рис. 10. Работа нелинейного эмулятора при нелинейности *saturation*

Выводы

Рассмотренный подход к проектированию нейроэмулятора нелинейного динамического объекта позволяет сократить количество настраиваемых параметров. Он может быть использован для широкого класса реальных односвязных объектов, поведение которых приближенно соответствует модели Гаммерштейна, содержащей линейную часть и статическую нелинейность.

Приведенные примеры моделирования показывают, что нейроэмулятор обеспечивает удовлетворительное качество работы для ряда типовых нелинейностей. Дальнейшие исследования могут быть направлены на реализацию нейроэмуляторов для объектов с нелинейностями динамического типа.

Список литературы

1. Narendra K., Parthasarathy K. Identification and control of dynamical systems using neural network // IEEE Transaction on neural network, 1990. No 1. P. 4 -27.
2. Kuschewski J.G., Hui S., Zak S.H., Application of Feedforward Neural Networks to Dynamical System Identification and Control, IEEE Transactions on Control Systems Technology, 1993. V. 1. P 37-49.
3. Lee C.H., Teng C.C. Identification and control of dynamic systems using recurrent fuzzy neural networks // IEEE Transaction on fuzzy systems, 2000. V. 8. No. 4. P. 349 – 366.
4. Atencia M., Joya G., Sandoval F. Hopfield neural networks for parametric identification of dynamical systems // Neural Processing Letters, 2005. 21. P. 143–152.
5. Осовский С. Нейронные сети для обработки информации. М.: Финансы и статистика, 2002.
6. Бураков М.В. Нейросетевая реализация ПИД-регулятора // XVI Всероссийская НТК "Нейроинформатика-2014" с международным участием: Сборник научных трудов. В 3-х частях. Ч. 3. М.: НИЯУ МИФИ, 2014. С.117-125.
7. Бураков М.В. Нейронные сети и нейроконтроллеры // СПб: ГУАП, 2013.

В.С. АБАТУРОВ, А.Ю. ДОРОГОВ

Санкт-Петербургский государственный электротехнический университет «ЛЭТИ»
vasilianich@yandex.ru

**СЕРВИС-ОРИЕНТИРОВАННАЯ ИНФРАСТРУКТУРА
АНАЛИТИЧЕСКОЙ ПЛАТФОРМЫ ДЛЯ ВСТРАИВАЕМЫХ
ИНТЕЛЛЕКТУАЛЬНЫХ ПОДСИСТЕМ**

В настоящей работе рассматривается инфраструктура сервис-ориентированной аналитической платформы для встраиваемых интеллектуальных приложений на основе СУБД PostgreSQL. Предложена архитектура аналитической платформы, подчиненной требованиям стандартов SQL/MM и PMML. Описан унифицированный интерфейс управления аналитической платформой. Показана схема формирования основных фаз извлечения знаний: фазы обучения, фазы тестирования и прикладной фазы. Представлена даталогическая модель аналитической платформы.

Ключевые слова: аналитическая платформа, извлечение знаний, унифицированный интерфейс, аналитическая инфраструктура.

V.S. ABATUROV, A.YU. DOROGOV

Saint Petersburg Electrotechnical University "LETI", Russia
vasilianich@yandex.ru

THE SERVICE-ORIENTED ANALYTICAL PLATFORM INFRASTRUCTURE FOR EMBEDDED INTELLIGENT SUBSYSTEMS

The service-oriented analytical platform infrastructure for embedded intelligent subsystem based on DBMS PostgreSQL is considered. The architecture of analytical platform that satisfies requirements of SQL/MM and PMML is proposed. The unified management interface for analytical platform is described. The diagram of main knowledge extraction phases (training, testing and application phases) is shown. The logical data model of analytical platform infrastructure is shown. The advantages of analytical platform are presented.

Keywords: *analytical platform, knowledge extraction, unified management interface, analytical infrastructure.*

Введение

Современные системы управления технологическими процессами требуют обработки и анализа больших объемов информации. Данная проблема давно стала критической в областях, непосредственно связанных с аналитической обработкой данных (Data Mining, искусственный интеллект, системы поддержки принятия решений, техническое зрение, мультимедиа технологии, и др.). В настоящее время рынок аналитических систем экспоненциально развивается. В этом процессе принимают участие такие крупные зарубежные компании как: IBM Cognos, MicroStrategy, Oracle, SAS, Microsoft, а также российские фирмы BaseGroup Labs, «Прогноз» [1].

Тенденция последних лет в развитии аналитических систем заключается в интеграции средств аналитической обработки, алгоритмов извлечения знаний, управления метаданными и визуализации результатов на одной программной аналитической платформе. Реализация технологии промышленной аналитической платформы для встраиваемых приложений связана с решением ряда принципиальных вопросов, к которым относятся: выбор архитектуры, системных интерфейсов, обеспечение сервисных возможностей, безопасности, надежности и высокого быстродействия. С внедрением аналитических вычислений в промышленные системы акцен-

ты применения все более смещаются к безлюдным технологиям, в которых потребителями аналитических сервисов являются другие вычислительные задачи. В этих условиях использование универсальных средств взаимодействия между разнородными задачами и системами выходит на первый план. В промышленных системах обмен поддерживается не только на уровне данных, но и на уровне моделей алгоритмов обработки данных. Поэтому вопросы стандартизации модельного представления алгоритмов представляются не менее важными.

Архитектура аналитической платформы

В настоящей работе рассматривается промышленная аналитическая платформа для встраиваемых приложений, построенная на базе СУБД *PostgreSQL* [2]. На рис. 1 представлена архитектура аналитической платформы.




Рис. 1. Архитектура аналитической платформы

Рассматриваемая аналитическая платформа состоит из аналитической СУБД и вспомогательных внешних вычислительных модулей. Взаимодействие аналитической платформы с приложениями осуществляется с помощью трех независимых интерфейсов:

- *SQL/MM* – расширение языка SQL [3] для управления процессами извлечения знаний;
- *SOAP* – протокол коммуникаций [4] между интернет-приложениями;
- *DDS* – открытый стандарт [5] распределенного сервиса для систем реального времени.

В качестве аналитической СУБД выступает PostgreSQL. PostgreSQL позволяет создавать новые пользовательские типы данных и хранимые процедуры для выполнения процессов извлечения знаний в соответствии со стандартом SQL/MM.

Внешние вычислительные модули, по сути, представляют собой динамически подгружаемые библиотеки, написанные на объектно-ориентированном языке C++ и языке R (функциональный язык программирования для статистической обработки данных). К внешним вычислительным модулям относятся:

- *модули анализа данных* – библиотеки, предназначенные для сложных статистических вычислений и процедур анализа данных, разработанные с применением языка R;
- *модуль XSLT трансформаций* – библиотека, предназначенная для проведения XSLT трансформаций, лежащих в основе большинства функций SQL/MM;
- *модуль валидации XML* – библиотека, предназначенная для проверки значений SQL/MM типов, аналитических ресурсов и различных других XML структур посредством XSD схем;
- *парсер SOAP и DDS* – библиотека, формирующая SQL/MM сценарии на основе SOAP и DDS сообщений и формирующая ответные сообщения на основе результатов работы аналитической платформы.

Взаимодействие аналитической СУБД и внешних модулей организовано посредством стандартного интерфейса PostgreSQL для хранимых процедур, написанных на C++, а также с помощью модуля *PL/R*, позволяющего реализовать хранимые процедуры на языке R.

Аналитическая СУБД содержит хранилища, предназначенные для размещения анализируемых данных (*обучающих данных, данных тестирования и прикладных данных*) и результатов использования моделей знаний (*результаты тестирования и результаты применения*).

Важным аспектом промышленных аналитических платформ является возможность централизованного хранения и использования аналитической инфраструктуры. Системное хранилище, поддерживающее инфраструктуру аналитической подсистемы, в дальнейшем будем называть *репозиторием*. Репозиторий представляет собой хранилище аналитических сервисов и ресурсов. Хранилище сервисов содержит описание всех алгоритмов, имеющихся в аналитической платформе и всех валидационных схем, необходимых для корректной работы процедур SQL/MM и процедур, связанных с контролем целостности аналитических ресурсов.

Хранилище ресурсов содержит результаты выполнения различных фаз и этапов работы аналитической платформы. К ресурсам относятся:

- *настройки* – XML описание параметров, предназначенных для вычислительных модулей (результат этапа настройки алгоритма),
- *задачи* – XML описание, содержащее всю необходимую информацию для запуска этапа непосредственного извлечения знаний,
- *модель PMML* – XML описание готовой модели знаний [6].

Стандарт PMML играет ключевую роль в данной архитектуре. Данный стандарт применяется не только для представления и хранения моделей знаний, но и для создания интерфейса сообщений с аналитической платформой через каналы удаленного доступа (SOAP и DDS).

Выполнение процессов извлечения знаний происходит посредством *аналитического обработчика сценариев*. Обработчик сценариев реализован на основе обработчика запросов SQL СУБД PostgreSQL. Обработчик сценариев позволяет не только осуществлять вызовы аналитических процедур и процедур репозитория, но и предоставляет доступ к данным и ресурсам аналитической платформы. Унифицированный доступ осуществляется благодаря стандарту SQL/MM, являющемуся надстройкой над языком запросов SQL. Кроме того, обработчик сценариев оснащен механизмами контроля целостности аналитических ресурсов. Данные механизмы реализованы посредством триггерных функций PostgreSQL.

На случай некорректного использования аналитической платформы предусмотрены *исключения (Exceptions)*, вызывающие прерывание выполнения сценария и откат к предшествующему состоянию. Коды и сообщения исключающих ситуаций позволяют выявить причину некорректного использования сценария.

Предложенная архитектура позволяет с помощью хранимых процедур СУБД PostgreSQL выполнять классические этапы извлечения знаний, включающие: обучающую фазу, фазу тестирования и фазу применения. На рис. 2 представлена схема формирования основных фаз извлечения знаний:

- *фаза обучения* – фаза интеллектуального анализа данных, на которой строится вычислительная модель PMML;
- *фаза тестирования* – этап, на котором осуществляется проверка качества предсказания на основе построенной модели;
- *прикладная фаза* – этап, на котором строка оперативных данных оценивается на основе обученной модели.




Рис. 2. Фазы извлечения знаний

Инфраструктура аналитической платформы

Стандарт SQL/MM акцентирует внимание на концепции и отдельных алгоритмах извлечения знаний, но не определяет архитектуру аналитической платформы в целом. Тем не менее, предполагается, что для хранения задач, моделей и настроек алгоритмов должны быть определены специальные таблицы в аналитической базе данных. Совокупность системных таблиц, предназначенных для управления алгоритмами, образует инфраструктуру аналитической подсистемы. Инфраструктура должна обеспечивать:

- доступ и управление аналитическими ресурсами платформы (задачами, вычислительными моделями и настройками);
- спецификацию о реализованном наборе сервисов (описание алгоритмов);

- спецификации о допустимых настройках для реализованного набора алгоритмов;
- спецификацию по моделям представления знаний;
- спецификации интерфейсных функций стандарта SQL-MM для реализованного набора алгоритмов;
- поддержку целостности ресурсов и сервисов.

Репозиторий представляет собой системное хранилище, поддерживающее инфраструктуру аналитической подсистемы. Цель создания репозитория – обеспечить программный доступ к сервисам и ресурсам встраиваемой аналитической подсистемы. На рис. 3 представлена даталогическая модель репозитория. Репозиторий состоит из хранилища аналитических ресурсов и сервисов.




Рис. 3. Даталогическая модель репозитория

Хранилище сервисов представляет собой множество таблиц, предназначенных для описания алгоритмов извлечения знаний, описания схем различных типов SQL/MM, хранения базовых валидационных схем и системных файлов трансформаций. В целом, хранилище сервисов предназначено для повышения качества и эффективности работы аналитической подсистемы. Данное хранилище упрощает работу пользователя и делает

прозрачным выполнение процессов извлечения знаний. Названия таблиц хранилища сервисов начинаются с префикса «*RP_*».

На рис. 3 видно, что компонент аналитических ресурсов состоит из пяти таблиц.

Таблица *RP_ALGORITHMS* предназначена для хранения описания алгоритмов аналитической подсистемы. Данная таблица содержит поля идентификации (*id*, *name*), обеспечивающие уникальность алгоритмов, схемы настроек входных и выходных настроек алгоритма, описание методов алгоритма. Таблица *RP_ALGORITHMS* обеспечивает сохранение ресурсов только тех алгоритмов, которые определены в ней.

Таблица *RP_SYSTEM* предназначена для хранения базовых схем, необходимых для работы аналитической платформы. Данная таблица содержит следующие базовые схемы:

- схема представления PMML (*pmml-4-1.xsd*), предназначенная для валидации моделей знаний и используемая в качестве базовой для построения других системных схем;
- схема представления настроек моделей знаний PMML (*pmm_task.xsd*) – базовая для схем настроек моделей знаний;
- схема определения методов SQL-MM (*SQL_MM.xsd*) – предназначена для валидации описаний SQL-MM методов.
- схемы сообщений DDS и SOAP (*DDS_Message.xsd*, *SOAP_Message.xsd*) – предназначены для валидации сообщений, передаваемых с помощью интерфейсов DDS и SOAP.

Таблица *RP_XSLT* предназначена для хранения системных стилей и файлов трансформации, используемых для реализации функционала SQL/MM.

Таблица *RP_SQL_MM_Types* предназначена для хранения названий абстрактных типов SQL/MM, к которым относятся модели (*Model*), задачи обучения (*BldTask*), тестовые задачи (*TestTask*), прикладные задачи (*AplyTask*). Записи данной таблицы обеспечивают наличие уникальных (неповторяющихся) схем, описывающих внутреннюю структуру SQL/MM типов.

Таблица *RP_SQL_MM_Schema* предназначена для непосредственного хранения схем различных типов SQL/MM. Комбинация уникальных ссылок на идентификаторы алгоритмов в таблице *RP_ALGORITHMS* и идентификаторы типов в таблице *RP_SQL_MM_Types* гарантирует, например, что в хранилище сервисов будет одна и только одна схема задачи обучения для алгоритма классификации, разумеется, если в хранилище сервисов объявлен только один алгоритм классификации. В противном случае, для корректной работы аналитической платформы необходимо опреде-

лить валидационные схемы SQL/MM типов для каждого алгоритма классификации.

Хранилище ресурсов представляет собой множество связанных таблиц, предназначенных для хранения результатов полученных в процессе извлечения знаний (настройки моделей, настройки алгоритмов, задачи, модели PMML). Названия таблиц аналитических ресурсов начинаются с префикса «AR_». На рис. 3 видно, что хранилище аналитических ресурсов состоит из шести таблиц.

Таблица *AR_outSettings* предназначена для хранения настроек выходных моделей PMML. Таблица *AR_inSettings* предназначена для хранения настроек алгоритмов извлечения знаний. Таблица *AR_testTask*, *AR_aplyTask*, *AR_bldTask*, предназначена для хранения задач обучения, тестирования и применения соответственно. Таблица *AR_model* предназначена для хранения моделей PMML. Ввиду необходимости увеличения производительности и особенностей реализаций некоторых аналитических алгоритмов в таблице моделей предусмотрено сохранение не только PMML модели, но и ее бинарного представления (*binary*).

Для сохранения целостности ресурсов аналитической платформы и обеспечения валидности обновлений и вставок новых ресурсных в репозитории предусмотрен специальный защитный механизм, основанный на применении триггеров СУБД PostgreSQL. Триггеры представляют собой автоматические хранимые процедуры, которые срабатывают в момент вставки изменения или удаления объектов хранилища ресурсов. Данный защитный механизм не позволит, например, удалить или изменить модель знаний, которая используется в какой-либо прикладной или тестовой задаче.

Технические характеристики аналитической платформы

Поскольку в качестве аналитической СУБД была выбрана СУБД PostgreSQL, аналитическая платформа, реализованная в соответствии с предложенной архитектурой, будет иметь следующие тактико-технические характеристики:

- обработка масштабных массивов разнородной информации (до 32 ТВ);
- расширяемость и масштабируемость аналитики;
- многоплатформенность;
- контроль целостности данных;
- интерфейсы доступа к языкам программирования высокого уровня;
- триггеры и правила для управления процессами;

- система управления правами доступа и авторизации;
- параллельная обработка пользовательских сессий;
- шифрование трафика.

Выводы

Преимуществами аналитической платформы, встроенной в базу данных, является высокая гибкость применения алгоритмов извлечения знаний, а также простые возможности их расширения и масштабирования. Предложенная архитектура аналитической платформы извлечения знаний, основанной на СУБД PostgreSQL, позволяет эффективно организовать процессы аналитики и извлечения знаний в различных предметных областях промышленных применений.

Реализация аналитической платформы в рамках базы данных позволяет использовать сценарные методы обработки данных для построения каскадных алгоритмов произвольной сложности. Кроме того, встроенный сервис базы данных обеспечивает, надежность, безопасность, масштабируемость и расширяемость аналитической подсистемы, что имеет принципиальное значение для систем промышленного использования. Предложенная архитектура репозитория расширяет стандарт SQL/MM в части организации инфраструктуры аналитической подсистемы. Стандарт предполагает использование объектно-ориентированных баз данных. Далеко не все базы данных в полной мере удовлетворяют требованиям стандарта SQL/MM, поэтому можно ожидать реализацию только некоторого диалекта стандарта. СУБД PostgreSQL не является строго объектно-ориентированной, но ее возможности достаточно полно покрывают требования стандарта.

Список литературы

1. Data Mining Community. Top Resource. [Электронный ресурс]. – Режим доступа: <http://www.kdnuggets.com>. Дата последнего доступа: 28.01.14.
2. PostgreSQL [Электронный ресурс]. – Режим доступа: <http://www.postgresql.org/>. Дата последнего доступа: 28.01.14.
3. ISO/IEC 13249-6-2006, SQL/MM Part 6.
4. Simple Object Access Protocol, SOAP 1.2 Messaging Framework (Second Edition). [Электронный ресурс]. – Режим доступа: <http://www.w3.org/TR/soap12-part1/> Дата последнего доступа: 28.01.14.
5. OpenDDS Version 3.0 Supported by Object Computing, Inc. (OCI). [Электронный ресурс]. – Режим доступа: <http://www.opendds.org/>; <http://www.ocிweb.com/> Дата последнего доступа: 28.01.14.
6. PMML Version 4.1, 2012, Data Mining Group (DMG) <http://www.dmg.org/>

М.С. ТАРКОВ¹, М.И. ОСИПОВ²

¹Институт физики полупроводников им. А.В. Ржанова СО РАН, Новосибирск

²Новосибирский государственный университет
tarkov@isp.nsc.ru, inq1201@mail.ru

СЛЕЖЕНИЕ ЗА ОБЪЕКТАМИ БАЙЕСОВСКОЙ СЕТЬЮ

Предложен алгоритм слежения за объектами в видеопотоке, основанный на использовании иерархической байесовской сети. Особенностью предложенного алгоритма является использование в нем многомерного шкалирования, что позволило существенно сократить время обучения сети. Алгоритм устойчив к временным исчезновениям отслеживаемого объекта, способен следить за несколькими объектами на сложном фоне и хорошо распараллеливается.

Ключевые слова: *слежение за объектом, иерархические байесовские сети, многомерное шкалирование.*

M.S. TARKOV¹, M.I. OSIPOV²

¹Rzhanov Institute of Semiconductor Physics, Siberian Branch of Russian Academy of Sciences, Novosibirsk, Russia

²Novosibirsk State University, Russia
tarkov@isp.nsc.ru, inq1201@mail.ru

OBJECT TRACKING BY BAYESIAN NETWORK

We propose an algorithm for tracking objects in a video stream. The algorithm is based on the use of hierarchical Bayesian network. A feature of the proposed algorithm is the use of multidimensional scaling which significantly shortens the network learning time. Algorithm is robust to the temporary tracked object disappearance. It can keep track of multiple objects on a complex background and can be well parallelized.

Keywords: *object tracking, hierarchical Bayesian network, multidimensional scaling.*

Введение

Дан видеопоток – последовательность кадров, на которых запечатлен объект. Также дано множество изображений объекта в различных ракур-

сах, это множество играет роль обучающих данных. Требуется, используя обучающие данные, решить задачу слежения за объектом, то есть определить местоположение объекта относительно текущего кадра либо, если объект в кадре не присутствует, сделать заключение о его отсутствии.

При рассмотрении задачи слежения за объектами в видеопотоке приходится сталкиваться с проблемой качественного анализа изображений объектов. Эти изображения могут кардинально отличаться друг от друга и представлять собой сложное сочетание более мелких и простых объектов, что крайне осложняет анализ в целом. Для успешного решения задачи слежения осуществляется обучение системы слежения на основе априорных данных. При этом простое сравнение объекта на анализируемом изображении с эталонами крайне неэффективно ввиду огромного количества вариантов визуального представления объекта в различных ракурсах.

Для решения вышеуказанных проблем можно использовать результаты исследований биологами механизма распознавания и запоминания в человеческом мозге. Исследования показали, что за эти процессы отвечает неокортекс – участок мозга, составляющий основную часть его коры. Оказалось [1], что для запоминания используется многослойная сеть нейронов, каждый из слоев которой отвечает за восприятие объектов определенной сложности, то есть при работе с визуальными данными используется иерархический принцип. Таким образом, как полагают биологи, человеческий мозг решает проблему хранения большого количества образов.

В работах [2, 3] иерархический подход реализован вероятностной сетью Байеса, которая помогает устанавливать причинно-следственные связи, и эта особенность используется для установления смысловой связи между образом и его фрагментами. Количество уровней иерархии, сложность объектов, на которые разбивается изображение, и множество других параметров определяют эффективность работы сети. Целью работы является поиск оптимальных вариантов структуры таких сетей для задачи слежения за объектом в видеопотоке.

Байесовские сети

Байесовские сети (БС) являются мощным инструментом интеллектуального анализа данных. БС – это математическая модель, по сути своей представляющая направленный ациклический граф, вершинами которого являются некоторые высказывания, а дугами – причинно-следственные связи между ними. Функционирование БС происходит в рамках следующих предположений [4]:

1) Каждая вершина представляет собой событие, описываемое случайной величиной, которая может иметь несколько состояний.

2) Веса связей между вершинами определяются таблицей условных вероятностей или функцией условных вероятностей.

3) Вероятности состояний вершин, не имеющих входящие дуги, являются безусловными.

Другими словами, в БС вершины представляют собой случайные переменные, а дуги – вероятностные зависимости, которые определяются через таблицы условных вероятностей.

Одной из основных концепций при использовании БС является разбиение плотности распределения множества случайных величин на произведение более простых плотностей (меньшего числа случайных величин). Базовыми являются случаи с двумя и тремя узлами с различными причинно-следственными отношениями [4]:

1. Случай независимых переменных x и y :

$$p(x, y) = p(x)p(y) .$$

2. Явная зависимость y от x :

$$p(x, y) = p(x)p(y | x) .$$

3. Зависимость y и z от x :

$$p(x, y, z) = p(x)p(y | x)p(z | x) .$$

4. Зависимость z от x и y :

$$p(x, y, z) = p(x)p(y)p(z | x, y) .$$

Если группы узлов БС условно объединить в слои, в пределах каждого из которых узлы будут соответствовать высказываниям одного типа, и при этом типы высказываний в слоях будут образовывать некоторую иерархию, то мы получим иерархическую БС [3]. Такая сеть способна реализовать логический вывод. На основе перечисленных типов отношений можно построить БС с произвольным количеством слоев.

Вершинам БС можно сопоставить классы изображений. Главное, чтобы у связей между ними была причинно-следственная природа. В случае изображений такой связью может быть отношение вложенности, то есть вершины-родители соответствуют фрагментам изображений класса, которому соответствует дочерняя вершина. Нас интересует вероятность принадлежности изображения классу, соответствующему дочерней вершине, при условии, что какие-то фрагменты (вершины-родители) обнаружены на этом изображении, а какие-то нет. Определив такие связи между слоями БС, мы сможем использовать эту модель для качественного анализа изображений.

Если на представителе класса изображений, который соответствует вершине БС, изображены конкретные однотипные объекты, например автомобили, дома или деревья, то значение вероятности в этом узле будет соответствовать вероятности нахождения на входном изображении объекта из класса, которому эта вершина сопоставлена. Таким образом, БС не только ответит на вопрос о том, какой класс изображений перед нами, она ещё и обоснует свой ответ тем, что согласно значениям в узлах на изображении находятся определенные типы объектов.

Для определения связей в БС необходима статистическая выборка изображений, которым сопоставлены узлы сети, и информация о вложении классов друг в друга. Иерархическая БС, используемая для решения поставленной задачи, состоит из трех слоев (рис. 1):

1) на первом слое расположены узлы $c_1, \dots, c_L$, которым соответствуют элементарные фрагменты изображений следующего слоя размером от 10×10 до 30×30 пикселей;

2) второй слой состоит из узлов $obj_1, \dots, obj_M$, соответствующих изображениям простых объектов, например, частей тела человека;

3) на третьем слое расположены узлы, соответствующие типам отслеживаемых объектов. Значения в этих узлах – это вероятности, с которыми сеть относит входное изображение к соответствующему типу.




Рис. 1. Структура байесовской сети

Третий слой может содержать один и более узлов. Задачи, при решении которых в третьем узле располагается более одного узла, являются задачами слежения за несколькими объектами (multitracking) [3]. В данной работе отслеживаемый объект один и, соответственно, один узел в третьем слое.

Процесс обучения включает в себя анализ обучающих данных, определяющий количество узлов во втором и первом слоях, и связи между слоями. Кроме того, в результате обучения определяются значения условных вероятностей, которые, по сути, являются весами связей.

Алгоритм решения задачи слежения за объектом с использованием трехслойной байесовской сети

Топология трехслойной сети определяется в процессе обучения, на начальном этапе о ней известно (см. рис. 1), что:

- узлы 1-го слоя являются маргинальными, то есть их вероятности мы рассматриваем как безусловные;
- число узлов третьего слоя равно числу отслеживаемых объектов, в рассматриваемом случае – один узел;
- каждый узел является родителем всех узлов следующего слоя (если таковой имеется).

Функционирование сети в режиме распознавания объектов происходит, начиная с первого слоя. При обучении сети весовые коэффициенты вычисляются в направлении от третьего слоя к первому (на рис. 1 снизу вверх).

Из набора обучающих изображений T размера K на первом этапе необходимо извлечь отдельные объекты. Извлечение может проводиться автоматически при помощи кластеризации. Однако полностью автоматизировать этот этап удастся не всегда.

После извлечения объектов обучающие данные представляются множеством пар $s_i = (id_i, t)$, где id_i – идентификатор объекта, который может представлять собой как число, так и осмысленное наименование объекта (рука, голова и т.д.), а t – целое число, задающее тип объекта (в нашем случае $t = 1$). Присвоить идентификатор извлеченному объекту автоматически не всегда возможно, иногда необходимо указывать идентификаторы объектов вручную. Это может оказаться трудоемким процессом, но следствием будет уменьшение ошибки классификации.

После того, как множество $T' = \{s_i \mid i = 1, \dots, K, s_i = (id_i, 1)\}$ определено, формируются множества $obj_i, i=1, \dots, M$, где M – количество различных идентификаторов извлеченных объектов. Данные множества определяют следующим образом:

$$obj_i = \{s \mid id = id_i\}, i = 1, \dots, M.$$

Иными словами, сформированы группы объектов с одинаковыми идентификаторами. Таким образом, во втором слое каждый узел представляет множество объектов obj_i . Следовательно, количество узлов во втором слое будет равно количеству различных идентификаторов извлеченных объектов.

Веса связей определяются выражением

$$p(obj_i | T) = \frac{|obj_i|}{|T|}, i = 1, \dots, M.$$

Они равны вероятностям обнаружения соответствующих объектов при условии, что перед нами изображение отслеживаемого объекта.

Также необходимо вычислить безусловные вероятности для каждого класса объектов, их значения получаются с помощью выражения

$$p(obj_i | T) = \frac{|obj_i|}{\sum_{j=1}^M |obj_j|}, i = 1, \dots, M.$$

Далее из изображений объектов извлекаются фрагменты размером от 10x10 до 30x30 пикселей. Изображения, являющиеся центрами кластеров объектов, разбиваются на фрагменты, после чего все фрагменты также кластеризуются, например, методом k -средних. Выбранную для кластеризации метрику обозначим $d(x, y)$. Центры кластеров фрагментов образуют словарь CB . Число узлов в первом слое равно мощности словаря L . После формирования словаря мы представляем имеющиеся классы объектов в виде множеств

$$obj_k = \{\tilde{c}_i | i = 1, \dots, L_k, \tilde{c}_i = (c_i, m_i)\}, k = 1, \dots, M.$$

где c_i – центр кластера, в котором находится извлеченный фрагмент, $m_i = 1, \dots, M$ – номер класса, из которого извлечен фрагмент. После формирования множеств obj_i определим группу множеств C_i следующим образом:

$$C_i = \{\tilde{c} | c = c_i\}, i = 1, \dots, L.$$

Множества C_i – это кластеры фрагментов. Узлы первого слоя соответствуют этим кластерам. Веса связей между первым и вторым слоями вычисляются по формуле

$$p(C_i | obj_j) = \frac{|\{\tilde{c} \in C_i | m = j\}|}{|obj_j|}, i = 1, \dots, L, j = 1, \dots, M.$$

Эти веса равны вероятности $p(C_i | obj_j)$ обнаружения i -го фрагмента при условии, что на изображении обнаружен j -й класс объектов.

Алгоритм обработки кадра видеопотока имеет следующий вид. Дан очередной кадр видеопотока. Изображение необходимо разбить на элементарные фрагменты, размер которых совпадает с фрагментами, представленными узлами 1-го слоя построенной БС. Далее осуществляется обход изображения окном, размер которого близок размеру искомого объекта.

Фрагменты, попавшие в окно, образуют одно из тестовых множеств. После обхода мы получаем набор множеств $C_{test}^i = \{c_{test}^{i1}, \dots, c_{test}^{iN_i}\}, i = 1, \dots, n$, которые сопоставляются со словарем. Каждый элемент множеств C_{test}^i заменяется на ближайший по метрике d элемент словаря. Элементы, которые находятся слишком далеко от всех элементов словаря, будут удалены из рассматриваемого множества. В итоге получим множества $\tilde{C}_{test}^i \subseteq CB, i = 1, \dots, n$, каждое из них соответствует конкретной области в кадре. Для оценки вероятности нахождения объекта в рассматриваемой области необходимо подать соответствующее множество на вход БС.

Рассмотрим процесс работы сети на некотором наборе входных данных $\tilde{C}_{test}^I$. Значения вероятностей в узлах первого слоя задаются выражением

$$p(c_i) = \begin{cases} 1, & \text{если } c_i \in \tilde{C}_{test}^I, \\ 0, & \text{иначе,} \end{cases} \quad i = 1, \dots, L.$$

Вероятности для второго слоя определяются выражением

$$p(obj_i | c_1, \dots, c_L) = \frac{p(obj_i, c_1, \dots, c_L)}{p(c_1, \dots, c_L)} = \frac{B_i \prod_{j=1}^L p(c_j | obj_i)}{\prod_{j=1}^L p(c_j)},$$

где $B_i = p(obj_i)$ определяется в ходе обучения.

Совместная вероятность для узла третьего слоя и связанных с ним узлов второго слоя имеет вид

$$p(T, obj_1, \dots, obj_M) = p(T) \prod_{j=1}^M p(obj_j | T) = \prod_{j=1}^M p(obj_j | T).$$

Здесь $p(T)$ – безусловная вероятность обнаружения соответствующего типа объектов, в нашем случае равна единице. В узле третьего слоя вычисляется вероятность

$$p(T | obj_1, \dots, obj_M) = \frac{p(T, obj_1, \dots, obj_M)}{p(obj_1, \dots, obj_M)} = \frac{\prod_{j=1}^M p(obj_j | T)}{\prod_{j=1}^M p(obj_j | c_1, \dots, c_L)}$$

обнаружения отслеживаемого объекта в рассматриваемой области.

Когда все входные наборы обработаны сетью, необходимо выбрать набор с максимальной вероятностью (блок MAX на рис. 2). Далее нужно сравнить максимальное значение с заранее заданным порогом (Threshold). Если оно выше указанного порога, то область, которой соответствует набор с максимальной вероятностью, считается областью нахождения отслеживаемого объекта в кадре, иначе алгоритм делает вывод об отсутствии отслеживаемого объекта в рассматриваемом кадре. Вышеупомянутый порог подбирается эмпирически либо из соображений, связанных со спецификой решаемой задачи.

3. Решение задачи слежения за объектом

Дана видеозапись движения человека в офисном помещении (см. рис. 2). Также даны изображения отслеживаемого человека для обучения системы. Необходимо определить местоположение человека в текущем кадре видеопотока. Если отслеживаемый объект в кадре не обнаружен, сообщить об этом. Для сокращения объема вычислений все манипуляции проводятся с монохромными изображениями. Размер кадра составляет 352x228 пикселей.




Рис. 2. Схема алгоритма обработки кадра

Задача решается трехслойной БС (см. рис. 1). Для снижения времени вычислений производится понижение размерности данных методом многомерного шкалирования [5, 6], который отображает точки изучаемых объектов в новое пространство более низкой размерности. В рассматриваемом случае точки отображаются на плоскость. При этом точки образа

объекта располагаются так, чтобы попарные расстояния между ними в новом пространстве как можно меньше отличались от измеренных попарных мер близости анализируемых объектов в исходном пространстве. В качестве меры близости изображений используется евклидово расстояние. Данный подход позволяет обрабатывать кадры независимо друг от друга. Для оценки качества работы алгоритма использовалось сравнение полученных алгоритмом координат объекта и координат, вычисленных по результатам работы алгоритма слежения из библиотеки OpenCV [7].

В табл. 1 представлены времена обучения на процессоре с тактовой частотой 2,1 ГГц с использованием многомерного шкалирования и без него при различных объемах обучающей выборки. Использование понижения размерности данных при обучении путем многомерного шкалирования дало ускорение обучения на два порядка. Это принципиальный момент, так как системы слежения должны иметь возможность периодически переобучаться для повышения эффективности. Время обработки кадра обученной БС составляет 0,2 с.

Таблица 1

Время обучения БС (в секундах)

Объем обучающих данных (в кадрах)	5	7	12
Время обучения без шкалирования	335	714	2657
Время обучения со шкалированием	4,47	7,69	22,8




Рис. 3. Оценка среднего отклонения при различных методах обучения

На рис. 3 показано влияние понижения размерности на качество слежения при различном объеме обучающих данных. Величина отклонения выражена в процентах от полусуммы ширины и высоты отслеживаемого

объекта. Использование многомерного шкалирования ведет к незначительному (2-3%) увеличению среднего отклонения от отслеживаемого центра объекта. При регулировке частоты выборки кадров для экономии вычислительных ресурсов (брать каждый пятый кадр) среднее отклонение увеличивается меньше, чем на 3%. Таким образом, есть возможность значительно уменьшить объем вычислений при потере точности, допустимой в решении конкретной задачи.

Независимость обработки кадров друг от друга дает устойчивость алгоритма к временным исчезновениям отслеживаемого объекта из кадра. Такая ситуация, например, может возникнуть, когда искомый объект временно закрыт другим объектом. Предложенный алгоритм обладает хорошей распараллеливаемостью и после некоторых преобразований может быть использован для слежения за несколькими объектами.

Заключение

Предложен и исследован алгоритм слежения за объектом в видеопотоке, основанный на использовании иерархической байесовской сети (БС). Особенностью предложенного алгоритма является использование в нем многомерного шкалирования, что позволило существенно сократить время обучения сети.

Алгоритм имеет следующие достоинства:

- Возможность слежения на сложном фоне за несколькими объектами (multi-tracking).
- При рассмотрении очередного кадра не нужна информация о предыдущем кадре.
- Алгоритм устойчив к временным исчезновениям отслеживаемого объекта из кадра.
- Хорошая распараллеливаемость.

Ценой преимуществ алгоритма является его сложность и необходимость обучения БС. Однако способность БС осуществлять интеллектуальный анализ данных делает их незаменимыми при решении широкого спектра задач.

Список литературы

1. Хокинс Д., Блейкли С. Об интеллекте. М.: ИД «Вильямс», 2007.
2. Nieto M., Unzueta L., Barandiarán J., Cortés A., Otaegui O., Sánchez P. J. Vehicle tracking and classification in challenging scenarios via slice sampling // EURASIP J. Adv. Sig. Proc., 2011. V. 95. P. 1-17.

3. Nillius P., Sullivan J., Carlsson S. Multi-Target Tracking – Linking Identities using Bayesian Network Inference // IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2006. V. 2. P. 2187-2194.

4. Тулупьев А.Л., Николенко С.И., Сироткин А.В. Байесовские сети. Логико-вероятностный подход. М.: Наука, 2006.

5. Толстова Ю.Н. Основы многомерного шкалирования. М.: КДУ, 2006.

6. Тарков М.С., Чиглинцев Е.А., Понижение размерности пространства данных в задаче диагностирования заболеваний щитовидной железы // Труды XIV Всероссийской научно-технической конференции «НЕЙРОИНФОРМАТИКА-2012». Ч. 1. М.: МИФИ, 2012. С. 142-150.

7. Bradski G., Kaehler A. Learning OpenCV. O'Reilly Media, Inc., USA, 2008.

**Е.Е. ОРЕХОВА, А.А. АБРАМОВ, В.В. АНДРЕЕВ,
О.В. АНДРЕЕВА**

Институт ядерной энергетики и технической физики Нижегородского
государственного технического университета им. Р.Е. Алексеева,
Нижний Новгород
Katrin_orehova@rambler.ru

**СОЗДАНИЕ ИНФОРМАЦИОННОЙ СИСТЕМЫ
НА ОСНОВЕ ИСКУССТВЕННЫХ
НЕЙРОННЫХ СЕТЕЙ ИНС
ДЛЯ ОПРЕДЕЛЕНИЯ ПРЕДЕЛА ВЫНОСЛИВОСТИ
МЕТАЛЛОВ ПОД ВОЗДЕЙСТВИЕМ ВНЕШНИХ ФАКТОРОВ**

Данная статья посвящена проблеме определения параметров усталости металлов. Как известно, в основном параметры усталости металлов определяются экспериментально. Но проведение экспериментов затратно по времени и финансово, а существующая экспериментальная база не охватывает все материалы и условия эксплуатации материала в промышленности. В связи с чем были предприняты попытки создания ускоренного метода определения параметров усталости металлов, с использованием искусственных нейронных сетей (ИНС).

Ключевые слова: *усталость металлов, обобщенный анализ, нейронные сети.*

Е.Е. OREKHOVA, А.А. ABRAMOV, V.V. ANDREEV,

O.V. ANDREEVA

Nizhny Novgorod State Technical University named after R.E. Alekseev, Russia
Katrin_orehova@rambler.ru

THE CREATION OF AN INFORMATION SYSTEM BASED ON ARTIFICIAL NEURAL NETWORKS TO DETERMINE THE ENDURANCE LIMIT OF METALS UNDER THE INFLUENCE OF EXTERNAL FACTORS

This article is devoted to the problem of determining the parameters of the fatigue of metals. As is known, basically the parameters of the fatigue of metals are determined experimentally. But experiments require long time and essential expenses. In addition, the existing experimental database does not cover all materials and their operating conditions in industry. Therefore, attempts have been made to create a rapid method of determining the parameters of the fatigue of metals, using artificial neural networks.

Keywords: *metal fatigue, generalized analysis, neural network.*

Введение

С середины XIX века было установлено, что прочность деталей существенно снижается в результате периодического (циклического) изменения нагрузки. Если на металл действуют знакопеременные нагрузки, то он ведет себя по-иному, чем при действии только растягивающих или только сжимающих сил. Особенности и закономерности этого явления до конца еще не раскрыты. Существующие теории не позволяют с гарантированной точностью предсказывать характеристики сопротивления усталости материалов в реальных конструкциях.

Общепринято усталостное разрушение характеризовать как процесс постепенного накопления повреждений в материале под воздействием циклических нагрузок, приводящий к образованию в нем трещины усталости и ее развитию, заканчивающемуся разрушением. Говорят, что металл «устает» от знакопеременных нагрузок.

Методы определения предела выносливости предусматривают проведение длительных испытаний. При испытании с частотой нагружения несколько тысяч циклов в минуту время построения одной кривой усталости измеряется неделями. Поэтому понятно стремление к разработке экспе-

риментально-аналитических методов для ускоренного нахождения пределов выносливости.

Все ускоренные методы пригодны лишь для ориентировочных оценок. Тем не менее, их разработка и накопление соответствующих экспериментальных данных необходимы и практически полезны. Основное преимущество методов ускоренного построения заключается в их оперативности и резком уменьшении количества необходимых для испытания образцов.

Для применения существующего метода прогноза положения кривой усталости в многоцикловой области, при представлении ее в логарифмических координатах, необходимо знать три параметра: σ_R – предел выносливости; N_G – число циклов нагружения; $\operatorname{tg} \alpha_w$ – тангенс угла наклона левой ветви кривой усталости к оси числа циклов нагружения [1].

Но не для всех сочетаний факторов имеются экспериментальные данные и, следовательно, данные для применения вышеуказанного метода оценки.

Постановка задачи

Данная работа посвящена разработке метода приблизительной оценки усталости металлов, исходными данными для которого является исключительно совокупность известных данных: материал, форма, условия нагрузки и т.д.

Решение поставленной задачи

Для реализации данного метода предполагается использовать искусственные нейронные сети (ИНС). Суть метода в том, что входными данными для ИНС являются известные данные об исследуемой детали (материал, форма, схема нагружения, и т.д.). Выходные данные – значения приведенных параметров σ_R и N_G , $\operatorname{tg} \alpha_w$. На рис. 1 представлена схема исходных данных для тренировки ИНС.

Зная три вышеуказанных параметра, можно определить положение точки перегиба в традиционных координатах с помощью обратной трансформации [1]. Схема трансформации полученных приведенных параметров в традиционные параметры усталости представлена на рис. 2.

Помимо конструкторских (расчетных) работ существуют исследовательские работы, когда необходимо изучить поведение материалов в различных условиях и подобрать оптимальное сочетание факторов.

Исходные данные




Рис. 1. Схема исходных данных для тренировки ИНС

АЛГОРИТМ УСКОРЕННОГО ПРОГНОЗА С ИСПОЛЬЗОВАНИЕМ ОБОБЩЕННОЙ ЗАВИСИМОСТИ




Рис. 2. Схема обратной трансформации приведенных параметров для получения традиционных значений усталости металла

Известно, что в трехмерной области обобщенная (усредненная) зависимость усталости металлов представляет собой кривую. Каждая точка этой кривой – это конкретная точка перегиба в традиционных координатах. Проекция данной линии на координатные плоскости так же представляют собой кривые. Если рассматривать конкретный параметр или их совокупность (материал, форму и т.д.), положение кривой в пространстве изменится. На рис. 3 представлено влияние уточняющих факторов (в данном случае, уточнение марки стали) на положение обобщенной кривой.




Рис. 3. Влияние уточнения марки стали на изменение положения обобщенной кривой

Исследуя семейство представляющих интерес кривых, можно подобрать оптимальное сочетание факторов для исследуемой задачи. Для решения подобных задач предполагается с помощью ИНС вычислять коэффициенты кривых – проекций на координатные плоскости и воссоздавать по этим проекциям положение кривой в пространстве для дальнейшего их исследования и выбора наиболее оптимального варианта. Схема создания ИНС для данной задачи представлена на рис. 4.

В настоящее время созданы ИНС для определения приведенного предела долговечности $N_{\text{прив}}$, приведенного предела усталости $\sigma_{\text{прив}}$ и приведенного тангенса угла наклона tg_прив . В качестве входных параметров в данном случае брались индекс марки стали, индекс схемы нагружения и

нагрузка (МПа). В дальнейшем планируется ввести учет других влияющих факторов (температура, обработка, среда и т.д.).

Для решения поставленных задач были рассмотрены сети типа многослойный персептрон (МСП), так как эти сети лучше других типов сетей прогнозируют значения в области, в которой не проходило обучение, что немаловажно при получении результатов в неисследованной ранее области. При исследовании конфигурации ИНС было рассмотрено несколько различных функций активации: тангенсальная, логистическая, экспоненциальная. Также варьировалось количество нейронов в промежуточном слое.

Обучающая выборка




Рис. 4. Схема задания обучающей выборки для определения коэффициентов кривых усталости металлов

Полученные результаты

Для ИНС, определяющей значения приведенных параметров, обучающая выборка представляет собой совокупность значений марки стали, соответствующих схем нагружения и нагрузок. Всего 1179 наборов.

На нижеследующих рисунках представлены результаты прогнозирования ИНС значений σ_R и $N_{G_i} \operatorname{tg} \alpha_w$.

Также построена ИНС, определяющая коэффициенты уравнений кривых – проекций на координатные плоскости, позволяющие воссоздать положение кривой в пространстве. В качестве входных параметров для создания данной ИНС была взята марка материала (индекс). Выходные параметры – коэффициенты кривых. С помощью полученной ИНС можно воссоздать только усредненную кривую. В дальнейшем предполагается создать ИНС, учитывающие другие факторы, кроме материала.

Для ИНС, определяющей коэффициенты кривых – проекций, обучающая выборка представляла собой совокупность индексов марки стали и искомым коэффициентов.

В результате были смоделированы ИНС, определяющие значения интересующих величин с погрешностью, не превышающей 15 %.




Рис. 5. Результаты определения ИНС значений $\sigma_{\text{прив}}$




Рис. 6. Результаты определения ИНС значений $\text{tg}_{\text{прив}}$




Рис. 7. Результаты определения ИНС значений $N_{\text{прив}}$




Рис. 8. Результаты определения ИНС значений коэффициента A




Рис. 9. Результаты определения ИНС значений коэффициента В




Рис. 10. Результаты определения ИНС значений коэффициента С




Рис. 11. Результаты определения ИНС значений коэффициента D





Рис. 12. Результаты определения ИНС значений коэффициента E

Рис. 13 Результаты определения ИНС значений коэффициента F



Заключение

Существует обобщенная зависимость параметров усталости металлов. [1]. В данной работе предприняты попытки получения значений параметров усталости металлов по совокупности известных данных (форма, материал, обработка, нагрузка и т.д., или только часть из них). Кроме того, установлено, что при уточнении влияющих факторов, положение обобщенной кривой в пространстве изменяется, соответственно, изменяются и проекции пространственной кривой на координатные плоскости, изменяются и уравнения спроецированных кривых. В данной работе предприняты попытки получения ИНС для определения коэффициентов вышеупомянутых кривых, что дает возможность в короткие сроки подобрать оптимальные параметры для рассматриваемой задачи.

Для решения поставленных задач были выбраны сети типа многослойный персептрон. Число промежуточных слоев варьировалось от 1 до 2.

В настоящее время созданы ИНС, определяющие параметры усталости по марке стали и схеме нагружения. Точность полученных ИНС – в пределах 20 %. Также созданы ИНС для определения коэффициентов проекций кривых по известным маркам стали. Наилучшие ИНС прогнозировали значения коэффициентов в пределах от 2 до 15 %.

Список литературы

1. Андреев В.В. Предел выносливости металлов на обобщенной зависимости приведенных параметров сопротивления усталости: Монография. Н.Новгород: Нижегород. ГТУ, 2003.
2. Гухман А.А., Зайцев А.А. Обобщенный анализ. М.: Факториал, 1998.

ИМЕННОЙ УКАЗАТЕЛЬ АВТОРОВ

– А –	Иванов Е. О. 164 Исаев И. В. 191	Соловьев А. М. 144 Суслова И. Б. 55
Абатуров В. С. 211 Абрамов А. А. 231 Андреев В. В. 231 Андреева О. В. 231 Анохин К.В. 14, 15 Атанов М. С. 88	– К – Колодкин И. В. 66 Королева М. Е. 29 Корсакова-Крейн М. Н. 46 Корягин Е. В. 38 Крупа В. В. 29 Кузнецов О. П. 18 Кукин К. А. 134	– Т – Тарков М. С. 126, 221 Таротин И. В. 97 Терехин С. А. 19 Трофимов А. Г. 66, 78 Тюменцев Ю. В. 116
– Б –		– У –
Бахчина А. В. 29 Белолипцев И. И. 154 Божокин С. В. 55 Бураков М. В. 202	– М –	Ушаков В. Л. 66 Ушакова И. Л. 29
– В –	Медянский И. А. 38 Миркес Е.М. 12	– Ф –
Введенский В. Л. 106 Величковский Б. М. 66, 78 Вялкова С. А. 182	– Н – Надтока И. И. 182 Некрасова М. М. 29	Фархиева С. А. 154 Федотчев А. И. 46 Филатова Н. Н. 19
– Г –	– О –	– Ш –
Габдрахманова Н. Т. 172 Горбань А.Н. 12 Горбатков С. А. 154 Губский С. О. 182	Оборнев Е. А. 191 Оборнев И. Е. 191 Орехова Е. Е. 231 Осипов Г. С. 17 Осипов М. И. 221	Шемаев П. Д. 19 Шепелев И. Е. 182 Шимелевич М. И. 185 Ширкин А. Е. 38
– Д –	– П –	– С –
Доленко С. А. 191 Дорогов А. Ю. 211	Парин С. Б. 29, 47 Полевая С. А. 47 Простов Ю. С. 116	Coombes S. 14
– Ж –	– Р –	– М –
Жилякова Л. Ю. 18	Радченко Г. С. 47 Ребрун И. А. 19	Michieletto D., 14
– З –	– С –	– S –
Замятин Н. В. 164 Зиновьев А.Ю. 12	Самсонович А. В. 16 Сбоев А. Г. 134 Сидоров К. В. 19 Собинов А. Р. 134	Stoop R. 13
– И –		– Т –
Иваницкий Г. А. 88, 97 Иваницкий И. И. 78		Timofeeva Yu. 14 Tsodyks M. 13
		– Y –
		Y Lu 14