

Нейроинформатика, её приложения и анализ данных

XXIV Всероссийский семинар

**Красноярск
2016**

Министерство образования и науки РФ
Сибирское отделение РАН
Российская ассоциация нейроинформатики
Институт вычислительного моделирования СО РАН

НЕЙРОИНФОРМАТИКА, ЕЁ ПРИЛОЖЕНИЯ И АНАЛИЗ ДАННЫХ

МАТЕРИАЛЫ
ДВАДЦАТЬ ЧЕТВЕРТОГО ВСЕРОССИЙСКОГО СЕМИНАРА
30 сентября – 2 октября 2016 года

Красноярск 2016

УДК 007.52 (042.3)

Н 43

Нейроинформатика, её приложения и анализ данных: Материалы XXIV Всероссийского семинара, 30 сентября – 2 октября 2016 г. / Под ред. А.Н.Горбаня, отв. за вып. М.Ю. Сенашова; – Красноярск: Институт вычислительного моделирования СО РАН, 2016. – 101 с.

В сборнике представлены материалы XXIV Всероссийского семинара «Нейроинформатика, её приложения и анализ данных», проходившей в городе Красноярске 30 сентября – 2 октября 2016 г.

Основной задачей конференции является всесторонний и высоко квалифицированный обмен новейшими достижениями в различных областях нейроинформатики (как теории нейросетей, так и в области различных практических приложений), а также в области нелинейного статистического анализа многомерных данных, обладающих нетривиальными структурами.

Большое внимание уделено анализу областей применимости и точности методов обработки многомерных данных, анализу устойчивости различных новых (нелинейных) методов кластеризации, разбор большого числа конкретных случаев, иллюстрирующих эти проблемы и достижения.

Материалы предназначены для научных работников, преподавателей, студентов и аспирантов соответствующих специальностей.

Редакционная коллегия:

Горбань Александр Николаевич – ответственный редактор

Сенашова Мария Юрьевна – ответственный за выпуск

© ИВМ СО РАН, 2016

© Коллектив авторов, 2016

ISBN 978-5-906455-09-3



9 785906 455093

РАЗРАБОТКА ГИБРИДНОЙ МОДЕЛИ С НЕЙРОСЕТЕВЫМИ КОМПОНЕНТАМИ ДЛЯ РЕШЕНИЯ ЗАДАЧИ КОМПЛЕКСНОЙ ОЦЕНКИ ДЕЯТЕЛЬНОСТИ АВТОСЕРВИСНОГО ПРЕДПРИЯТИЯ

Д.Д.Барышев, М.Н. Коршикова, О.И.Пятковский

Алтайский государственный технический университет им. И. И. Ползунова
пр. Ленина 46, кафедра ИСЭ, т. 8(3852) 29-08-70, denis.baryshev@bk.ru

На сегодняшний день успешно функционируют и развиваются автосервисные предприятия разных форм собственности, видов деятельности и форм обслуживания – фирменные центры по техническому обслуживанию и ремонту, дилерские центры, частные независимые СТО и гаражные мастерские. В сложившейся ситуации количественного удовлетворения спроса на услуги автосервисных предприятий, их качество становится весомым аргументом в обеспечении конкурентоспособности. Перед руководителями автосервисного предприятия стоит сложная задача – адекватно современным условиям оценить качество услуг по техническому обслуживанию и ремонту автомобилей и выявить резервы для его повышения.

Для оценки деятельности автосервисного предприятия была разработана модель комплексной оценки эффективности функционирования автосервисного предприятия, представленная на Рис. 1 и 2, а также методика оценки, которая представлена на Рис. 3. Различной штриховкой показаны типы решателей.



Рис.1. Модель комплексной оценки деятельности автосервисного предприятия

Создание модели комплексной оценки эффективности функционирования автосервисного предприятия проводилось по этапам проектирования экспертных систем, в результате была получена гибридная модель, состоящая из 63-х входных, 4-х интегральных и 32-х промежуточных показателей. В качестве решателей узлов в ней используются: нейронные сети, экспертные оценки, аналитические формулы.




Рис.2. Модель комплексной оценки деятельности автосервисного предприятия, блок «финансовое состояние»

В группу экспертов вошли ведущие специалисты ООО «Триал», занимающиеся проблемами автоматизации и управления автосервисных предприятий. Для определения состава экспертной группы была разработана анкета для расчета компетентности мнения каждого эксперта. Экспертами было определено, что деятельность автосервисного предприятия зависит от: - кадрового потенциала; - финансового состояния; - спроса; - конкурентоспособности. При определении предварительного подхода к решению проблемы экспертами были рассмотрены различные методы решения задач управления организацией, поскольку задача оценки деятельности, принадлежит классу управленческих задач. За основу была взята гибридная экспертная система. Сочетая различные методы, она позволяет добиться существенно лучших результатов при решении задач оценки, чем другие системы.

Узел	Тип решателя	Описание
Финансовое состояние		
2.1 Коэффициенты рентабельности	Формула	$K_{пр} = \frac{\text{Прибыль от продаж}}{\text{Выручка от реализации}} \cdot 100\%$
2.1.1 Прибыль от продаж	Исходные данные	Документ «Отчет о прибыли и убытках» Код 2200
2.1.1.2 Выручка от реализации	Исходные данные	Документ «Отчет о прибыли и убытках» Код 2110
2.1.2 Коэффициент рентабельности собственного капитала	Формула	$K_{СК} = \frac{\text{Чистая прибыль}}{\text{Собственный капитал}} \cdot 100\%$
2.1.2.1 Чистая прибыль	Исходные данные	Документ «Отчет о прибыли и убытках» Код 2400
2.1.2.2 Собственный капитал	Исходные данные	Документ «Бухгалтерский баланс» Код 1300
2.1.3 Коэффициент рентабельности оборотных активов	Формула	$RCA = \frac{\text{Чистая прибыль}}{\text{Текущие активы}} \cdot 100\%$
2.1.3.1 Чистая прибыль	Исходные данные	Документ «Отчет о прибыли и убытках» Код 2400
2.1.3.2 Текущие активы	Исходные данные	Документ «Бухгалтерский баланс» Код 1200
2.1.4 Коэффициент рентабельности внеоборотных активов	Формула	$RFA = \frac{\text{Чистая прибыль}}{\text{Долгосрочные активы}} \cdot 100\%$
2.1.4.1 Чистая прибыль	Исходные данные	Документ «Отчет о прибыли и убытках» Код 2400
2.1.4.2 Долгосрочные активы	Исходные данные	Документ «Бухгалтерский баланс» Код 1400
2.1.5 Коэффициент рентабельности инвестиций	Формула	$K_{инв} = \frac{\text{Чистая прибыль}}{\text{Собственный капитал}} \cdot 100\%$
2.1.5.1 Чистая прибыль	Исходные данные	Документ «Отчет о прибыли и убытках» Код 2400
2.1.5.2 Собственный капитал	Исходные данные	Документ «Бухгалтерский баланс» Код 1300
2.1.5.3 Долгосрочные активы	Исходные данные	Документ «Бухгалтерский баланс» Код 1400
2.2 Коэффициенты ликвидности	Формула	
2.2.1 Коэффициент абсолютной ликвидности	Формула	$K_{абс} = \frac{\text{Денежные средства}}{\text{Текущие обязательства}}$
2.2.1.1 Денежные средства	Исходные данные	Документ «Бухгалтерский баланс» Код 1100
2.2.1.2 Краткосрочные финансовые вложения	Исходные данные	Документ «Бухгалтерский баланс» Код 1110
2.2.1.3 Текущие обязательства	Исходные данные	Документ «Бухгалтерский баланс» Код 1200
2.2.2 Коэффициент срочной ликвидности	Формула	$K_{ср} = \frac{\text{Денежные средства} + \text{Краткосрочные финансовые вложения}}{\text{Текущие обязательства}}$
2.2.2.1 Денежные средства	Исходные данные	Документ «Бухгалтерский баланс» Код 1100
2.2.2.2 Краткосрочные финансовые вложения	Исходные данные	Документ «Бухгалтерский баланс» Код 1110
2.2.2.3 Краткосрочная дебиторская задолженность	Исходные данные	Документ «Бухгалтерский баланс» Код 1210
2.2.2.4 Текущие пассивы	Исходные данные	Документ «Бухгалтерский баланс» Код 1200
2.2.3 Коэффициент текущей ликвидности	Формула	$K_{текущ} = \frac{\text{Текущие активы}}{\text{Текущие пассивы}}$
2.2.3.1 Текущие активы	Исходные данные	Документ «Бухгалтерский баланс» Код 1200
2.2.3.2 Текущие пассивы	Исходные данные	Документ «Бухгалтерский баланс» Код 1200
2.2.4 Чистый оборотный капитал	Формула	$ЧОК = \text{Текущие активы} - \text{Текущие пассивы}$
2.2.4.1 Текущие активы	Исходные данные	Документ «Бухгалтерский баланс» Код 1200
2.2.4.2 Текущие пассивы	Исходные данные	Документ «Бухгалтерский баланс» Код 1200
2.3 Коэффициенты деловой активности	Формула	
2.3.1 Коэффициент оборачиваемости рабочего капитала	Формула	$K_{ок} = \frac{\text{Выручка}}{\text{Чистый оборотный капитал}}$
2.3.1.1 Выручка	Исходные данные	Документ «Отчет о прибыли и убытках» Код 2110
2.3.1.2 Чистый оборотный капитал	Исходные данные	Документ «Бухгалтерский баланс» Код 1200
2.3.2 Коэффициент оборачиваемости основных средств	Формула	$K_{ос} = \frac{\text{Выручка}}{\text{Среднегодовая дебиторская задолженность}}$
2.3.2.1 Выручка	Исходные данные	Документ «Отчет о прибыли и убытках» Код 2110
2.3.2.2 Среднегодовая дебиторская задолженность	Исходные данные	Документ «Бухгалтерский баланс» Код 1400
2.3.3 Коэффициент оборачиваемости запасов	Формула	$K_{оз} = \frac{\text{Выручка}}{\text{Среднегодовая дебиторская задолженность}}$
2.3.3.1 Выручка	Исходные данные	Документ «Отчет о прибыли и убытках» Код 2110
2.3.3.2 Среднегодовая дебиторская задолженность	Исходные данные	Документ «Бухгалтерский баланс» Код 1400
2.3.4 Коэффициент оборачиваемости дебиторской задолженности	Формула	$K_{дз} = \frac{\text{Выручка}}{\text{Среднегодовая дебиторская задолженность}}$
2.3.4.1 Выручка	Исходные данные	Документ «Отчет о прибыли и убытках» Код 2110
2.3.4.2 Среднегодовая дебиторская задолженность	Исходные данные	Документ «Бухгалтерский баланс» Код 1400
2.3.5 Коэффициент оборачиваемости кредиторской задолженности	Формула	$K_{кз} = \frac{\text{Выручка}}{\text{Среднегодовая дебиторская задолженность}}$
2.3.5.1 Выручка	Исходные данные	Документ «Отчет о прибыли и убытках» Код 2110
2.3.5.2 Среднегодовая дебиторская задолженность	Исходные данные	Документ «Бухгалтерский баланс» Код 1400
2.3.5.3 Среднегодовая кредиторская задолженность	Исходные данные	Документ «Бухгалтерский баланс» Код 1500
2.4 Коэффициенты (показатели) финансовой устойчивости	Формула	
2.4.1 Коэффициент финансовой независимости	Формула	$EQ TA = \frac{\text{Собственный капитал}}{\text{Суммарный актив}}$
2.4.1.1 Собственный капитал	Исходные данные	Документ «Бухгалтерский баланс» Код 1300
2.4.1.2 Суммарный актив	Исходные данные	Документ «Бухгалтерский баланс» Код 1600
2.4.2 Коэффициент соотношения к суммарным активам	Формула	$TD TA = \frac{\text{Долгосрочные обязательства} + \text{Текущие обязательства}}{\text{Суммарный актив}}$
2.4.2.1 Долгосрочные обязательства	Исходные данные	Документ «Бухгалтерский баланс» Код 1400
2.4.2.2 Текущие обязательства	Исходные данные	Документ «Бухгалтерский баланс» Код 1500
2.4.2.3 Суммарный актив	Исходные данные	Документ «Бухгалтерский баланс» Код 1600
2.4.3 Коэффициент соотношения к внеоборотным активам	Формула	$LD TA = \frac{\text{Долгосрочные обязательства}}{\text{Суммарный актив}}$
2.4.3.1 Долгосрочные обязательства	Исходные данные	Документ «Бухгалтерский баланс» Код 1400
2.4.3.2 Суммарный актив	Исходные данные	Документ «Бухгалтерский баланс» Код 1600
2.4.4 Коэффициент покрытия процентов	Формула	$K_{пп} = \frac{\text{Прибыль до налогов и процентов по кредитам}}{\text{Проценты по кредитам}}$
2.4.4.1 Прибыль до налогов и процентов по кредитам	Исходные данные	Документ «Отчет о прибыли и убытках» Код 2400
2.4.4.2 Проценты по кредитам	Исходные данные	Документ «Бухгалтерский баланс» Код 1700
3 Спрос	Исходные данные	
3.1 Количество первичных обращений	Исходные данные	Документ «Заявки»
3.2 Количество повторных обращений	Исходные данные	Документ «Заявки»
3.3 Количество положительных отзывов	Исходные данные	Документ «Отзывы клиентов»
3.4 Количество отрицательных отзывов	Исходные данные	Документ «Отзывы клиентов»
4 Конкурентоспособность	Исходные данные	
4.1 Ассортимент	Исходные данные	Документ «Анкета эксперта»
4.2 Диверсификация	Исходные данные	Документ «Анкета эксперта»
4.3 Ориентация на различные рынки	Исходные данные	Документ «Анкета эксперта»
4.4 Новые технологии	Исходные данные	Документ «Анкета эксперта»
4.5 Ценовая политика	Исходные данные	Документ «Анкета эксперта»
4.6 Надежность	Исходные данные	Документ «Анкета эксперта»
4.7 Доступность	Исходные данные	Документ «Анкета эксперта»
4.8 Выполнение обязательств	Исходные данные	Документ «Анкета эксперта»
4.9 Ценовой уровень зад. частей и мате	Исходные данные	Документ «Анкета эксперта»
4.10 Ценовой уровень обслуживания	Исходные данные	Документ «Анкета эксперта»
4.11 Скидки	Исходные данные	Документ «Анкета эксперта»
4.12 Качество оказанных услуг	Исходные данные	Документ «Анкета эксперта»
5 Обслуживание	Исходные данные	
5.1 Время ожидания	Исходные данные	Документ «Анкета эксперта»

Рис.3. Методика оценки деятельности автосервисного предприятия

Одним из вариантов решения неформализованных задач оценки являются многослойные нейронные сети. Рассмотрим структуру нейронной сети на примере Модели оценки конкурентоспособности. При построении и эксплуатации нейросетевой модели в составе информационной системы выделяют следующие этапы:

1.Изучение, анализ объекта исследования и постановка задачи.

Постановка задачи – оценка конкурентоспособности автосервисных предприятий и её влияние на комплексную оценку эффективности функционирования автосервисного предприятия.

2.Сбор и загрузка исходных данных в информационную базу.

Задачник для обучения сети формировался методом экспертных оценок, т.е. выходные параметры задачника определялись группой квалифицированных экспертов. После были проведены в несколько этапов по методу Дельфи и выявлены основные факторы, влияющие на конкурентоспособность, и определены выходные параметры.

3.Предобработка исходных данных. При помощи программы Нейро-Аналитик был произведен предварительный анализ задачника по средствам заполнения пропусков в данных и исключения аномальных наблюдений (Рис. 4).




Рис.4. Результаты предварительного анализа выборки с помощью программы Нейро-Аналитик

Количество пропусков и аномалий считается системой автоматически и выдается пользователю при каждом заполнении. После предобработки данных, пропусков и аномалий в задачнике не обнаружено.

4. Формирование задачника. Важный вопрос в формировании задачника - разделение всех доступных данных на обучающую и тестовую выборки таким образом, чтобы обеспечить их независимость и представительность. Задачник был разделен на обучающую выборку (в составе 115 объектов) и тестовую выборку (в составе 10 объектов).

5. Выбор структуры и параметров модели нейросети. Для настройки структуры сети в программе Нейро-Аналитик было выбрано ручное создание структуры сети и ее обучение. Такой метод позволит подобрать оптимальную структуру сети с достаточным количеством слоев и нейронов на них. Вначале выбирается самая простая структура (1 слой, 1 нейрон), а затем если сеть не может обучиться, пробуем обучать сеть с увеличенным числом нейронов и слоев, при этом максимальное количество слоев 7, а максимальное количество нейронов на слое 10 (Рис. 5).




Рис.5. Настройка структуры сети с помощью программы Нейро-Аналитик

6. Настройка (обучение) сети. При оценке планировки сеть была обучена по 3 алгоритмам, доступным в программе Нейро-Аналитик: постраничный, плавающий шаг и kPartan (Рис. 6).




Рис.6. Примеры обучения сети с помощью программы Нейро-Аналитик

7. Тестирование.

8. Оценка полученной модели.

Для оценки качества полученной модели используется оценка работы нейросети на тестовой выборке, или ошибка обобщения. Наиболее распространенным методом оценки моделей является метод перекрестного оценивания. Проанализировав полученные результаты можно сделать вывод, что модель вполне приемлема для оценки объекта, обладает достаточной адекватностью и может использоваться в действии.

Схема взаимодействия компонентов информационно-аналитической системы представлена на рисунке 7.




Рис.7. Схема взаимодействия информационно-аналитической системы

Происходит формирование и ведение единой информационной базы – справочников и документов. Производится интеграция с web-сервисами АИС «Бизнес Аналитик». Произведена настройка созданной методики в АИС «Бизнес Аналитик», настроены решатели узлов.

Расчет по методике на тестовых данных представлен на Рис. 8.

Наименование	Значение
РЕЗУЛЬТАТ ОЦЕНКИ	
Комплексная оценка деятельности автосервисного предприятия...	4.11 (10)
Кадровый потенциал	6.14 (10)
Квалификация	6.11 (10)
Средний стаж	14,5
Доля сотрудников, повышавших свою квалификацию...	0,25
Доля сотрудников с высшим образованием	0,5
Экспертная оценка (независимое тестирование)	6,25
Текущее кадров	6.1 (10)
Среднесписочная численность	4,37 (10)
Финансовое состояние	2.50 (10)
Коэффициенты рентабельности	плохо
Коэффициенты ликвидности	плохо
Коэффициенты ледовой активности	хорошо

Рис.8. Расчет по методике на тестовых данных

На Рис. 9 представлен пример работы с системой. ООО «Триал» имеет дилерские договоры с компаниями IVECO и ISUZU, каждая из которых имеет свое СТО и нормативную базу. На слайде представлены результаты комплексной оценки эффективности функционирования автосервисных предприятий (по 10-бальной шкале).




Рис.9. Результаты оценки автосервисных фирм

На Рис. 10 представлены результаты оценки ООО «Триал ISUZU» в разные временные периоды.



Рис.10. Результаты оценки ООО «Триал ISUZU» в разные периоды

Предложенная методика оценка может стать отличным инструментом для руководителя автосервисного предприятия, принимающего решения на стратегическом и тактическом уровнях управления. Полученные от информационно-аналитической системы отчеты помогут выявить резервы для повышения услуг по техническому обслуживанию и ремонту автомобилей.

СПИСОК ЛИТЕРАТУРЫ

1. Пятковский О.И. Интеллектуальные компоненты автоматизированных систем управления предприятием. Монография – г. Барнаул: АлтГТУ. – 1999.-351 с.
2. Нейроинформатика / А.Н. Горбань, В.Л. Дунин-Барковский, А.Н.Кирдин, Е.М. Миркес, А.Ю. Новоходько, Д.А. Россиев, С.А. Терехов, М.Ю.Сенашова, В.Г. Царегородцев. – Новосибирск: Наука, Сибирская издательская фирма РАН, 2006, - 296 с.

ИССЛЕДОВАНИЕ ПРОЦЕССОВ САМОРЕГУЛЯЦИИ ОРГАНИЗМА ТЕПЛОВИЗИОННЫМ МЕТОДОМ

Н.М. Богатов, А.Н. Богатова, С.А. Сухих

Кубанский государственный университет, bogatov@phys.kubsu.ru

Организм человека является открытой энергетической системой, которая вступает во взаимодействие с внешней средой. Агрессивное воздействие внешней среды проявляется в возрастании психофизиологических, информационных нагрузок при адаптации к современным социально-экономическим условиям и техногенным факторам, разрушающим экологию и биосферу. Следствием этого является повышение биоэнергетических затрат организма, приводящее к истощению его ресурсов, появлению хронической усталости, хронического стресса, различных психологических и соматических расстройств. Саморегуляция является важнейшим фактором достижения физиологической, психологической и социальной адаптации. Саморегуляция реализуется как на уровне отдельных функциональных систем организма, так и посредством их взаимодействия [1], в котором важнейшую роль играют нейрогуморальные реакции. Способность индивидуума к саморегуляции посредством управления психоэнергетическим потенциалом является индивидуальной характеристикой человека.

Процессы терморегуляции организма управляются нейрогуморальными реакциями. В работах [2, 3] показано, что напряжение функциональных систем стрессированных биологических объектов проявляется в индивидуальных закономерностях изменения их теплового поля. Изучение коррекции состояния организма и сохранение функционального состояния здоровья в результате саморегуляции является актуальной задачей нейрофизиологии и психологии.

Цель работы – объективная регистрация тепловизионным методом результатов процесса саморегуляции как энергоинформационного обмена в организме.

В процессе эксперимента достигалось воздействие сознания субъекта на энергоинформационный обмен в организме. Информационное воздействие на орган или энергетический центр происходило во внутреннем пространстве субъекта. В эксперименте участвовали респонденты в возрасте 21 – 23 года в количестве 50 человек. Участники эксперимента не обладали специальной подготовкой по управлению сознанием.

Методика исследования включала три этапа: 1 – определение начального функционального и психоэмоционального состояния испытуемых, 2 – методически организованный сеанс саморегуляции, 3 – определение функционального и психоэмоционального состояния испытуемых после сеанса саморегуляции.

На первом и третьем этапах функциональное состояние организма испытуемых оценивалось методами функциональной диагностики, основанными на измерении электрических потенциалов (программно-аппаратные комплексы SilverStep и ROFES, тест-ручка по Фолю), регистрации теплового излучения поверхности тела (тепловизор testo 885-2). Комплекс SilverStep, используя анализ вариабельности сердечного ритма, оценивает состояние регуляторных систем организма, в частности комплексный показатель здоровья, адаптацию, вегетативное равновесие нервной системы, спектрограмму ритмов головного мозга, нейрогуморальную регуляцию, психоэмоциональное состояние. ROFES, анализируя сигналы биологически активной точке MC-7, оценивает общее состояние организма и функциональное состояние 17-ти органов и систем, а также психоэмоциональное состояние. Программная интерпретация результатов исследований, формируемая этими комплексами, не всегда совпадает. Этот факт требует дальнейшего изучения, поэтому более подробно рассмотрим результаты

тепловизионных исследований, как метода непосредственного наблюдения за изменением состояния объекта.

Внутренняя терморегуляция организма реализуется посредством метаболического термогенеза, тока крови, мышечного тонуса кожи, ритма дыхания, частоты сердечных сокращений, выделения пота и контролируется центральной нервной, в частности гипоталамусом, и эндокринной системами. Тепловые и холодовые рецепторы расположены в трех областях тела: в гипоталамусе, грудном отделе спинного мозга и коже [4]. Процессы внутренней терморегуляции и теплообмен с окружающей средой формируют тепловое поле организма.

Симпатическая часть вегетативной нервной системы участвует в формировании как температуры, так и электропроводности кожи. Изменение состояния внутренних органов отражается на электрических характеристиках кожи вследствие висцерокожного симпатического рефлекса [5]. Существует корреляция между изменением электропроводности в репрезентативных акупунктурных точках и состоянием энергетических меридианов, отражающих функциональное состояние соответствующих им внутренних органов и систем организма.

Длительность сеансов саморегуляции составляла $20 \div 30$ минут. Использовались различные психотехники. Продемонстрируем результаты на примере техники «дыхание через биологически активную точку С-7 на левом запястье». Седативная точка С-7 – одна из основополагающих точек меридиана сердца С [6], расположена у лучевого края сухожилия локтевого сгибателя запястья.

Термограммы регистрировались с помощью тепловизора testo 885-2, имеющего матричный детектор 320×240 пикселей, температурную чувствительность $< 0,03$ К. Исследования проводились в закрытом помещении при температуре 22°C , влияние посторонних источников тепла исключалось. Повышение разрешающей способности термограмм достигнуто с помощью псевдоцветовой палитры компьютерной программы [7].

На рис.1 и рис.2 представлены термограммы одного из испытуемых, соответственно, до сеанса саморегуляции и после выполнения упражнения «дыхание через биологически активную точку С-7». Радиационная температура в точке С-7 после сеанса саморегуляции увеличилась на $\Delta t_{\text{С}7} = 1,4^\circ\text{C}$, увеличилась также максимальная температура руки на $0,6^\circ\text{C}$, середины ладони на $0,4^\circ\text{C}$, кончика среднего пальца на $1,8^\circ\text{C}$ (рис. 1).




Рис.1. Термограммы руки: А – до сеанса саморегуляции; Б – после сеанса саморегуляции.

Измерялась разность потенциалов φ между электродами, один из которых испытуемый держал в правой руке, а другой контактировал с точкой С-7. После сеанса саморегуляции электрический потенциал того же испытуемого в точке С-7 увеличился на $\Delta\varphi_{\text{С}7} = 15$ мкВ.

На термограммах рис. 2 отображена радиационная температура лица до сеанса саморегуляции и после выполнения упражнения «дыхание через биологически активную точку С-7». Максимальная радиационная температура лица после сеанса саморегуляции уменьшилась на $\Delta t_f = 0,19^\circ\text{C}$.




Рис.2. Термограммы лица: А – до сеанса саморегуляции; Б – после сеанса саморегуляции.

Параметры распределения теплового поля в правой и левой части лица на термограммах рис. 2 приведены в таблице 1. Разность между средними значениями температуры в правой и левой части лица до сеанса саморегуляции $0,21^\circ\text{C}$, после сеанса $0,14^\circ\text{C}$. Разность между коэффициентами стандартного отклонения температуры в левой и правой части лица до сеанса саморегуляции $0,08^\circ\text{C}$, после сеанса $0,01^\circ\text{C}$. Эти данные свидетельствуют о выравнивании симметрии распределения теплового поля лица относительно вертикальной оси.

Таблица 1

Параметры распределения теплового поля лица

Область	$t_{\text{идея}}$, $^\circ\text{C}$	$t_{\text{лев}}$, $^\circ\text{C}$	$t_{\text{нод}}$, $^\circ\text{C}$	Станд. откл. , $^\circ\text{C}$
Рис. 2А прав.	35,3	30,93	33,77	0,92
Рис. 2А лев.	35,28	30,53	33,56	1
Рис. 2Б прав.	35,11	30,9	33,6	0,8
Рис. 2Б лев.	35	30,2	33,46	0,81

Выравнивание симметрии термограммы лица относительно вертикальной оси – один из характерных результатов саморегуляции. В таблице 2 приведены данные того же испытуемого после следующего сеанса саморегуляции «дыхание в мозг».

Таблица 2

Параметры распределения теплового поля лица

Область	$t_{\text{идея}}$, $^\circ\text{C}$	$t_{\text{лев}}$, $^\circ\text{C}$	$t_{\text{нод}}$, $^\circ\text{C}$	Станд. откл. , $^\circ\text{C}$
Правая	35,9	32,37	34,35	0,77
Левая	35,67	31,67	34,26	0,78

Разность между средними значениями температуры в правой и левой части лица составила 0,09 °С, а разность между коэффициентами стандартного отклонения в левой и правой части 0,01 °С. Приток крови при выполнении упражнения «дыхание в мозг» привел к увеличению максимальной температуры лица на 0,79 °С по сравнению с предыдущим состоянием.

Таким образом, тепловизионный метод является средством объективного контроля результатов энергоинформационного обмена в организме. Тепловое поле поверхности тела отражает индивидуальные особенности организма. Изменение параметров теплового поля в результате сеансов саморегуляции имеет индивидуальные отличия, связанные с физиологическим и психологическим состоянием человека.

Использованные методики саморегуляции приводят к положительному изменению функциональных и психоэмоциональных состояний испытуемых. Согласно показаниям программно-аппаратного комплекса SilverStep у испытуемого в результате сеанса саморегуляции «дыхание в мозг» комплексный показатель здоровья увеличился на 2%, показатели вегетативной регуляции на 8%, нейрогуморальной регуляции на 1%, психоэмоционального состояния на 3%, индексы напряженности и вегетативного равновесия пришли в диапазон нормальных значений.

Положительные изменения функционального и психоэмоционального состояния характеризуются накопительным эффектом, так что возможно их закрепление в процессе последующих сеансов саморегуляции. Результативность сеансов зависит от способности испытуемых к концентрации во внутреннем пространстве, их физиологических и психологических особенностей.

В Кубанском государственном университете проводится эксперимент по использованию техник саморегуляции для сохранения функционального здоровья студентов.

Список литературы

1. Анохин П.К. Очерки по физиологии функциональных систем / П.К.Анохин. — М.: Медицина, 1975. — 448 с.
2. Андросова Т.В. Исследование реакций терморегуляторной системы белых лабораторных мышей в процессе продолжительного стресса / Т.В. Андросова, Н.М. Богатов, Л.Р. Григорьян и др. // Биотехносфера. — 2011. — Т.13. — № 1. — С.16 – 19.
3. Андросова Т.В. Исследование закономерностей температурной регуляции в процессе продолжительного стресса / Т.В. Андросова, Н.М. Богатов, Л.Р. Григорьян и др. // В: Нейроинформатика, её приложения и анализ данных: Материалы XIX Всероссийского семинара, 1 – 3 октября 2011 г. Красноярск. — Красноярск: Сибирский федеральный университет. — 2011. — С. 20 – 24.
4. Иванов К.П. Основы энергетики организма: Теоретические и практические аспекты. Т. 1. Общая энергетика, теплообмен и терморегуляция / К.П.Иванов. — Л.: Наука, 1990. — 307 с.
5. Электропунктурная диагностика по методу И. Накатани. Министерство здравоохранения РФ. Методические рекомендации № 2002/34 / Н.А.Гаврилова, С.В.Коновалов, К.А.Резаев и др. — МЗ РФ: Москва, 2002. — 24 с.
6. Гаваа Лувсан. Очерки методов восточной рефлексотерапии / Лувсан Гаваа. — Новосибирск: Наука (сибирское отделение), 1980. — 279 с.
7. Богатов Н.М. Программа спектрального анализа термограмм / Н.М.Богатов, Л.Р.Григорьян // Федеральная служба по интеллектуальной собственности, патентам и товарным знакам РФ. Свидетельство об официальной регистрации программы для ЭВМ №2006612378. Зарегистрировано: 6.07.2006 г.

МОДЕЛЬ НЕЙРОМОРФНОЙ СИСТЕМЫ УПРАВЛЕНИЯ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ СО СТРУКТУРНОЙ АДАПТАЦИЕЙ

А.В. Бахшиев, Ф.В. Гунделах

Центральный научно-исследовательский и опытно-конструкторский институт
робототехники и технической кибернетики (ЦНИИ РТК), alexab@rtc.ru

Введение

В настоящее время существует множество слабо формализуемых задач, плохо решаемых существующими методами. Одним из общих подходов, в решении такого рода задач – являются искусственные нейронные сети. Однако искусственные нейронные сети, включая активно развивающиеся в настоящее время архитектуры сетей глубокого обучения [1], в практическом применении используются для решения некоторой частной задачи. Они решают ее часто лучше, чем другие подходы, но остается проблема их обобщения. Иными словами, они работают в некотором заданном контексте, и при смене контекста, необходимо строить и обучать новую сеть.

Так, решение с помощью нейронной сети только одной частной задачи, например, распознавания образов, в момент перехода от нейросетевого представления к ограниченному набору классов резко сужает большое количество различных контекстов, в которых может использоваться формируемая НС информация, к одному контексту, ограниченному набором распознаваемых классов для конкретной решаемой задачи.

Если в качестве примера рассматривать роль искусственных нейронных сетей в задачах управления поведением роботов, то они применяются в двух аспектах:

1) Для решения локальных задач, обнаружение и распознавание целевых объектов, идентификация объекта управления, адаптивная регуляция и др. Т.е. решаются отдельные этапы целевой задачи робота;

2) Выбранная архитектура ИНС обучается на множестве примеров решать целевую задачу робота.

В первом случае архитектура выбранной нейронной сети обобщает пространство входных параметров, обычно высокой размерности, в малое пространство решения локальной задачи. При этом мы получаем эффективное решение каждой локальной задачи, однако гибкость системы управления поведением робота в целом оказывается ограниченной, поскольку строится из модулей, решающих задачу в ограниченном контексте.

Во втором случае, потенциальная гибкость системы управления определяется архитектурой нейронной сети, однако в настоящее время не существует архитектур ИНС, эффективно решающих сколь-нибудь сложные задачи управления поведением робота.

Одной из причин этих проблем является отсутствие в существующих архитектурах искусственных нейронных сетей возможности структурной самоорганизации (в смысле изменения архитектуры) во время функционирования, которая является одним из важных свойств биологических нейронных структур. При этом можно выделить три стадии изменения структуры биологических нейронных сетей:

1) Эволюционная. На этой стадии сформировался общий вид архитектуры нервной системы и нейронные сети, обеспечивающие процессы жизнедеятельности. В теории искусственных нейронных сетей – этой стадии можно поставить в соответствие выбор разработчиком архитектуры ИНС, числа слоев, нейронов в скрытом слое, и т.п. А также средства глобальной оптимизации, например, генетические алгоритмы [2].

2) Первичное развитие нервной системы после рождения. На этой стадии формируются детальная архитектура зрительной и моторной коры и высших уровней, в

соответствии с сенсорной информацией и спектром доступных движений.

3) Постоянное накопление опыта в структуре связей нейронов. Происходит в течении всего времени функционирования организма.

Пункты 2 и 3 в искусственных нейронных сетях реализуются путем алгоритмов обучения, настраивающих веса связей между заданным количеством нейронов для достижения наилучшей обобщающей/прогнозирующей способности на обучающей выборке.

Важным практическим отличием биологических нейронных сетей, является их способность проводить настройку (обучение) онлайн, т.е. без этапа предварительного обучения. Эта особенность позволяет адаптироваться к изменяющимся условиям в процессе функционирования, причем адаптация может даже приводить к смене архитектуры нейронной сети (например, реализация более сложного анализа данных со слухового анализатора на зрительной коре в случае необратимого повреждения зрения). Также известно, что при приблизительно постоянном числе нейронов в мозгу, количество связей активно меняется. При этом каждая связь обеспечивает не просто факт передачи информации от выхода одного нейрона ко входу другого, а выполняет, в частности функции пространственного и временного обобщения входных данных.

Таким образом, представляется необходимым развитие искусственных нейронных сетей в рамках нейроморфного подхода, сосредоточившись на исследовании и реализации механизмов структурной адаптации.

Структура нейроморфной системы

Прежде всего необходимо сформулировать общие принципы формирования нейроморфных систем.

Особенность современного подхода в моделировании нейроморфных систем [3][4], и в частности проектов крупномасштабного моделирования мозга [5][6] в том, что они идут сверху. А именно – ведется моделирование высших нервных структур, коры мозга, функций мозжечка, и на основе этого идет попытка понять, как осуществляется высшая когнитивная деятельность.

Однако можно предложить другой подход – идти снизу [романов]. Поскольку нервная система появилась как ответ на потребность в первую очередь в движении, и движение (в широком смысле этого слова – восприятие и активная реакция на среду) является основной функцией всех организмов, над которой весь остальной функционал надстраивается [7,8,9], то можно пойти по пути создания систем управления поведением технической системы в среде. При этом это не обязательно должен быть физической робот, который перемещается в пространстве. Принципиальным моментом здесь является то, что нейроморфная система взаимодействует со средой, и нейронная сеть осуществляет весь цикл обработки информации, от получения ее с сенсоров, до влияния на среду, через какие-либо эффекторы. Можно назвать такую систему нейроморфной системой управления поведением (Рис. 1).

Здесь под обобщением сенсорных данных мы будем понимать процесс запоминания образов в общем (пока) смысле этого слова. Под моторной памятью мы понимаем возможность системы воспроизводить сложные воздействия на среду, набору которых система была научена ранее. Блок принятия решения намеренно упрощаем до блока рефлекторной деятельности, подразумевая, что рефлексы могут быть достаточно сложны.




Рис.1 – Схема нейроморфной системы управления в терминах памяти и рефлексов

На рис. 1 справа представлен общий вид предлагаемого варианта архитектуры моторной памяти. В ней можно выделить три уровня:

Уровень регуляторов (Regulatory control network - RCN) – обеспечивает базовые функции управления эффорторами исполнительской системы (приводами для робототехнической системы).

Уровень запоминания и воспроизведения положений (состояний) исполнительской системы (Position control network - PCN1 и PCN2) предоставляет возможности для фиксации в своей нейронной сети целевые положения исполнительской системы в пространстве состояний.

Уровень запоминания и воспроизведения паттернов движения, или иными словами динамической активности (Trajectory control network - TCN), обеспечивает последовательный переход исполнительской системы от одного запомненного положения к другому.

Нисходящие управляющие воздействия u следуют с высших уровней, а восходящие сигналы y – представляют собой ответную реакцию уровня (подтверждение выполнения поставленной задачи).

Важно отметить, что представленные уровни (начиная с PCN) на самом деле представляет собой иерархическую сеть, которая может динамически наращиваться как в глубину (обобщение комбинаций запомненных положений и элементов траекторий), так и в ширину (формирование новых положений и элементов траекторий).

В основу реализации уровней моторной памяти предлагается положить известные биологические нейронные структуры. При этом в нейрофизиологии достаточно глубоко изучены только низший уровень управления движением (спинальный), обеспечивающий регуляцию мышечных сокращений [10].

Для описания уровня запоминания положений можно воспользоваться известными гипотезами о сходстве в архитектуре моторной и зрительной коры мозга [11].

Наконец уровень запоминания и воспроизведения паттернов движения может быть основан на широко распространенных нейронных кольцевых структурах с

положительной обратной связью, обеспечивающих в нервной системе очаги задающей активности.

Пример решения задачи движения по траектории

Ранее были разработаны архитектура уровня регулятора [12], уровня запоминания в структуре сети положений исполнительный системы робота (или агента) [13] и уровня запоминания паттернов движения [14]. В основу моделей положена импульсная динамическая модель нейрона с возможностью описания и изменения онлайн как структуры дендритного дерева, так и динамических характеристик обобщения данных на дендритах [15]. Ниже представлен пример запоминания и воспроизведения в структуре нейронной сети паттернов движения мобильного робота в модельной среде.

Средствами библиотеки NMSDK [16] была синтезирована схема для управления двухколёсным мобильным роботом. На рис.2 приведен пример реализации такой схемы.




Рис. 2 – Пример схемы управления мобильным роботом

На этой схеме $PCN2^B_i$ и $PCN2^C_i$ – нейроны уровня PCN2. Причём $PCN2_1$ обозначает состояние «движение назад», $PCN2_2$ – состояние «поворот направо», $PCN2_3$ – состояние «движение вперёд», а $PCN2_4$ – состояние «поворот налево». «Движения» и «повороты» в данном случае следует трактовать как дискретное перемещение. В данном примере уровень TCN иерархический и состоит из двух уровней. Элемент T^2_1 запускает последовательность элементов T^1_1 - T^1_4 , а после завершения этой последовательности переключается на элемент T^2_2 , который, в свою очередь, запускает последовательность элементов T^1_5 - T^1_8 , после завершения которой движение прекращается.

Каждый элемент траектории представляет собой кольцевую структуру из пары импульсных нейронов с положительной обратной связью, запуск такой структуры приводит к активации нисходящими (возбуждающими) сигналами процесса перехода в положение, определяемое связями этого элемента траектории с уровнем запоминания положений и далее к регуляторам. При получении подтверждающего восходящего сигнала (тормозного), генерация прекращается и активируется следующий элемент траектории.

В соответствии со схемой и вышеописанным видно, что элементы T^1_1 - T^1_4 запускают последовательность состояний: «движение вперёд», «поворот направо», «движение вперёд», после чего посылается сигнал о завершении траектории на уровень T^2 , где запускается следующий элемент. Элементы T^1_5 - T^1_8 , в свою очередь, запускают последовательность состояний: «поворот налево», «движение вперёд», «поворот налево», после чего посылается сигнал о завершении траектории на уровень T^2 и движение прекращается.

На рис. 3а и 3б приведены примеры работы последовательностей T^1_1 - T^1_4 и T^1_5 - T^1_8 соответственно. На рис. 3в приведён пример работы всей схемы, в которой уровень T^2 сначала запускает последовательность T^1_1 - T^1_4 , а по её завершению запускает последовательность T^1_5 - T^1_8 .




Рис. 3 – Пример работы уровня управления движением по траектории
а) - траектория T^1_1 - T^1_4 ; б) - T^1_5 - T^1_8 ;
в) – последовательное выполнение траекторий а) и б)

Такой иерархический подход позволяет строить сколь угодно сложные траектории. Более того, можно встраивать траектории во время движения, например, траекторию для обхода препятствия по сигналу от внешних сенсоров.

Заключение

Предложенная архитектура нейронных сетей позволяет запоминать информацию с одной стороны классически обобщая входные данные и понижая размерность задачи, с другой стороны позволяет расширять сеть не только в глубину, но и в ширину, обобщая информацию в различных контекстах, которые в свою очередь могут быть использованы на высших уровнях.

Рассмотренные эксперименты показали принципиальную возможность применения динамических импульсных нейронных сетей с изменяющейся архитектурой для решения задач управления. В качестве направления дальнейших исследований планируется разработка алгоритмов обучения для предложенных архитектур нейроморфных систем управления.

Список литературы

1. Bengio, Y. Learning Deep Architectures for AI / Y. Bengio // Foundations and Trends in Machine Learning. – 2009. – Vol. 2, No. 1 - P. 1-12.
2. Рутковская, Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский; пер. с польск. И.Д. Рудинского. – М.: «Горячая линия – Телеком», 2006. – 452 с.

3. Жданов, А.А. Адаптивные машины – неизбежное направление развития техники. Задачи и проблемы / А.А. Жданов // XII конференция "Нейроинформатика -2010": Лекции по нейроинформатике. – 2010. – М.: НИЯУ МИФИ. – С. 162-211.
4. Krichmar, J.L. Brain-Based Devices for the Study of Nervous Systems and the Development of Intelligent Machines / J.L. Krichmar, G.M. Edelman // Artificial Life 2005. – 11 (1-2) – P. 63-78.
5. Garis, H. A world survey of artificial brain projects: Part I: Large-scale brain simulations / H. de Garis, Ch. Shuo, B. Goertzel et al. // Neurocomputing. – 2010. – 74. – P. 3-29.
6. Goertzel, B. A world survey of artificial brain projects: PartII: Biologically inspired cognitive architectures // Neurocomputing / B. Goertzel, L. Ruiting, I. Arel, H. d. Garis et al; 2010. – 74. – P. 30-49., т. 74, pp. 30-49.
7. Романов, С.П. Нейрокомпьютеры и "интеллектуальность" современных вычислительных сред: материал технической информации / С.П. Романов // Нейрокомпьютеры: разработка, применение. Научно-технический журнал. – 2007. – №6. – С. 96-104.
8. Бернштейн, Н.А., Физиология движений и активность / Н.А. Бернштейн; под редакцией академика О.Г. Газенко. – М.: «Наука», 1990. – 497 с.
9. Данилова, Н.Н. Психофизиология / Н.Н. Данилова. – М.: «Аспект Пресс», 2002. – 373 с.
10. Романов, С.П. Структурное обоснование функции нервной системы как автоматического регулятора / С.П. Романов // Нейрокомпьютеры: разработка, применение. – 2006. – №7. – С. 54-63.
11. Воронков, Г.С. Информация и мозг: взгляд нейрофизиолога / Г.С. Воронков // Нейрокомпьютеры: разработка, применение. 2002. № 1 – 2. С. 79-88.
12. Бахшиев, А. В. Перспективы применения моделей биологических нейронных структур в системах управления движением / А. В. Бахшиев // Информационно-измерительные и управляющие системы. - 2011. - №9. - С 71-80.
13. Бахшиев, А.В. Исследование метода запоминания пространственных конфигураций робототехнической системы на нейронных сетях со структурной адаптацией / А.В. Бахшиев, Ф.В. Гунделах // Робототехника и техническая кибернетика. Изд-во ЦНИИ РТК. - 2015. - №3(8). - С.46-51.
14. Bakhshiev, A.V. The model of the robot's hierarchical behavioral control system / A.V. Bakhshiev, F.V. Gundelakh //Proceedings of the 13th International Symposium on Neural Networks, ISNN 2016, St. Petersburg, Russia, July 6–8, 2016. Published on Advances in Neural Networks – ISNN 2016. - P.317-327.
15. Bakhshiev, A.V. Mathematical Model of the Impulses Transformation Processes in Natural Neurons for Biologically Inspired Control Systems Development / A.V. Bakhshiev, F.V. Gundelakh // Supplementary Proceedings of the 4th International Conference on Analysis of Images, Social Networks and Texts (AIST-SUP 2015), April 9-11. - Yekaterinburg, Russia, 2015. Published on CEUR-WS.- Vol. 1452. - P. 1-12. Scopus. - 15.10.2015. Online: <http://ceur-ws.org/Vol-1452/>
16. А.В. Бахшиев. – Библиотека средств разработки моделей нейронных сетей со сложной и динамически меняющейся архитектурой - NMSDK // Нейроинформатика, ее приложения и анализ данных - материалы XVIII Всеросс. семинара, 8-10 октября 2010г. / под ред. А.Н. Горбаня, Е.М. Миркеса; ИВМ СО РАН. Отв. за вып. Г.М.Садовская – Красноярск; 2010, с.26-30.

КЛАССИФИЦИРУЮЩИЕ МОДЕЛИ ДЛЯ ПРОГНОЗИРОВАНИЯ ИНФЕКЦИОННЫХ ЗАБОЛЕВАНИЙ В ГЕТЕРОГЕННОМ ПРОСТРАНСТВЕ ИНФОРМАТИВНЫХ ПРИЗНАКОВ

Васми Ихаб А Васми, Ю.Б. Мухатаев, В.В. Федянин

Юго-Западный государственный университет, кафедра биомедицинской инженерии,

SFilst@gmail.com

В гетерогенном пространстве информативных признаков сегменты информативного пространства выделяются таким образом, чтобы анализируемые признаки были независимы внутри сегментов или, наоборот, независимы вне сегментов. Так как чаще всего признаки являются частично зависимыми, то приходится искать компромисс путем коррекции диагностической модели в процессе обучения [1]. При реализации методов диагностики, построенных на основе сегментированных пространств информативных признаков, осуществляется разбиение (группирование) информативных признаков по N сегментам. Процесс сегментирования пространства информативных признаков рассмотрен в [2]. Для каждого сегмента формируется интеллектуальный агент (решающий модуль), который определяет локальный коэффициент уверенности KU_i в диагнозе ω_1 на основе информативных признаков, содержащихся в i -м сегменте.

Процедура определения локальных коэффициентов уверенности реализуется в цикле, затем определяется глобальный коэффициент уверенности $KU\omega_1$. При его определении используются формулы, которые в литературе известны как нечеткие операции. При синтезе классификатора для гетерогенного пространства информативных признаков реализован многоагентный подход к принятию диагностических решений [3]. Структурная схема многоагентной системы принятия решений, основанной на гетерогенном пространстве информативных признаков, представлена на рисунке 1.




Рис.1. Структурная схема многоагентной системы прогнозирования пиелонефрита, где БНЛВ – блок нечеткого логического вывода; БДОВ – база данных обучающих выборок; КУ - коэффициент уверенности

Многоагентная система прогнозирования пиелонефрита имеет двухуровневую структуру. На первом уровне формируются локальные коэффициенты уверенности KY_i , а на втором (верхнем) уровне определяется глобальный коэффициент уверенности KY по прогнозу пиелонефрита.

Первый иерархический уровень содержит шесть автономных интеллектуальных агентов. На входы каждого из этих агентов подается вектор информативных признаков с соответствующего сегмента пространства информативных признаков. Первые пять интеллектуальных агентов имеют однотипную структуру, в которую входит фаззификатор и блок формирования нечеткого решающего правила. Фаззификатором является совокупность математических моделей, преобразующих значения информативных признаков в соответствующее значение функций принадлежности. При синтезе решающего правила для первого агента учитывалось то, что добавление каждого из признаков в общее решение, приводит к увеличению уверенности в риске возникновения или обострения пиелонефрита, то коэффициент риска для них вычисляется по формуле:

$$KY_1 = KY_1 + \mu_{\omega_1}(x_i)[1-KY_1], \quad (1)$$

где $i = \overline{2,4}$; а начальное значение $KY_1 = \mu_{\omega_1}(x_1)$

Вторую группу составили производственные факторы (признаки x_5, x_6, x_7, x_8, x_9). Локальный коэффициент уверенности KY_2 в классе ω_1 определяется формулой с условием:

$$\begin{aligned} & \text{ЕСЛИ } (x_5=1) \text{ ТО } [KY_2=0,04] \text{ ИНАЧЕ} \\ & KY_2(j+1) = KY_2(j) + \mu_{\omega_1}(x_{5+j})[1-KY_2(j)], \end{aligned} \quad (2)$$

где номер итерации $j = \overline{1,4}$; $KY_2(1) = \mu_{\omega_1}(x_5)$.

В соответствии с поведенческими факторами (x_{10-21}) риск возникновения пиелонефрита определяется частным коэффициентом уверенности KY_3 по формуле:

$$KY_3(j+1) = KY_3(j) + \mu_{\omega_1}(x_{10+j})[1-KY_3(j)], \quad (3)$$

где номер итерации $j = \overline{1,11}$; $KY_3(1) = \mu_{\omega_1}(x_{10})$.

Локальный коэффициент уверенности по факторам питания (x_{22-27}), формируется путем итерации их функций принадлежности:

$$KY_4(j+1) = KY_4(j) + \mu_{\omega_1}(x_{22+j})[1-KY_4(j)], \quad (4)$$

где номер итерации $j = \overline{1,5}$; $KY_4(1) = \mu_{\omega_1}(x_{22})$.

Локальный коэффициент уверенности по медико-биологическим факторам (x_{28-55}) KY_5 рассчитывается согласно формуле:

$$KY_5(j+1) = KY_5(j) + \mu_{\omega_1}(x_{28+j})[1-KY_5(j)], \quad (5)$$

где $j = \overline{1,27}$; $KY_5(1) = \mu_{\omega_1}(x_{28})$.

Для получения шестого локального коэффициента уверенности использовалась сетевая модель, представленная на рисунке 2. Входной слой состоит из трех блоков вероятностных нейронных сетей (PNN), что соответствует числу используемых в шестом сегменте биоактивных точек (БАТ). Для каждого объекта из исследуемого класса исследовались вольтамперные характеристики (ВАХ) БАТ трех меридианов: меридиан

сердца – С7, меридиан легких – Р9, меридиан перикарда – МС7. ВАХ аппроксимировалась полиномом седьмого порядка.




Рис. 2. Структурная схема сети PNN-FNN для интеллектуального агента – анализатора БАТ

Вероятность риска пиелонефрита по информации с каждой БАТ способна только подтверждать диагноз, поэтому уверенность в этом решении по всем исследуемым БАТ для класса ω_i - наличие риска пиелонефрита - может быть определена по формуле алгебраического сложения, аналогичной (1-5).

На двух выходах каждого блока PNN_i слоя PNN присутствуют вероятность P_{ω_1} патологии ω_1 и вероятность $P_{\bar{\omega}_1}$ отсутствия патологии $\bar{\omega}_1$. Эти вероятности определяются соотношением и расположением в пространстве информативных признаков векторов обучающей выборки, а также выбранной шириной функций активации в слое PNN. Для принятия окончательного решения к вероятностному слою нейронной сети PNN добавляется слой, выполненный по нечеткой технологии - FNN, работа которого основана на нечеткой логике принятия решений.

Слой FNN имеет типовую структуру нечеткой нейронной сети и содержит два слоя: слой агрегаторов и дефазификатор. Нечеткая операция в узлах FNN первого слоя определяется посредством обучения модулей FNN и экспертной коррекции функций субъективной плотности вероятностей на выходе модуля PNN.

Второй слой модуля FNN содержит всего лишь один нейрон, который выполняет обязанности дефазификатора в системе нечеткого логического вывода. Дефазификатор FNN работает на основе «наивного Байеса», согласно выражению

$$KY_6 = \max(0, (h_{\omega_1} \cdot c_{\omega_1} \cdot K\bar{O}_{\omega_1} - h_{\bar{\omega}_1} \cdot c_{\bar{\omega}_1} \cdot K\bar{O}_{\bar{\omega}_1})), \quad (6)$$

где h - априорные вероятности соответствующего класса, c — цена ошибки классификации, KY — выходы агрегаторов.

Нечеткие операции, выполняемые в узлах FNN, при отсутствии или недостатке экспертных данных могут быть определены на основе методики, основанной на использовании генетических алгоритмов.

Этап построения агрегатора для определения глобального коэффициента уверенности представляет собой выбор способа объединения локальных коэффициентов уверенности с помощью набора нечетких логических операций. Для реализации генетического алгоритма в среде Matlab использовалось битовое кодирование нечетких операций R_i . Каждая нечеткая операция из базового набора кодируется уникальной битовой последовательностью длины d . Длина последовательности выбирается исходя из условия $2^d \geq g$, где g – общее количество нечетких операций в наборе $\{R\}$. Процесс «сборки» агрегатора из нечетких операций иллюстрирует рисунок 3.




Рис. 3. Структура битовой последовательности, используемой в генетическом алгоритме. Пример результата применения генетического алгоритма для формирования агрегатора представлен в таблице 1.

Таблица 1
Структура итогового агрегатора

Битовая строка	0000 1000 0101 0010 0011
Состав агрегатора	$R_1(KY_6, (R_9(KY_5, R_6(KY_4, R_3(KY_3, R_4(KY_1, KY_2))))))$

С целью проверки качества разработанных решающих правил были проведены испытания на репрезентативных контрольных выборках. Критерием отбора в группу наблюдения было превышение глобальным коэффициентом уверенности обострения пиелонефрита $KU_{ОРП}$ величины 0,2. В каждой группе были сформированы два класса обследуемых: класс ω_0 – люди без признаков пиелонефрита и ω_1 – пациенты, у которых в течение года наблюдения развилось воспаление почек.

С целью проверки качества разработанных решающих правил были проведены испытания на репрезентативных контрольных выборках. Критерием отбора в группу наблюдения было превышение глобальным коэффициентом уверенности обострения пиелонефрита $KU_{ОРП}$ величины 0,2. В каждой группе были сформированы два класса обследуемых: класс ω_0 – люди без признаков пиелонефрита и ω_1 – пациенты, у которых в течение года наблюдения развилось воспаление почек.

В результате проведенных исследований и вычислений для полученных решающих правил были определены показатели качества классификации: диагностическая чувствительность (ДЧ), диагностическая специфичность (ДС), прогностическая значимость положительных результатов (ПЗ⁺), прогностическая значимость отрицательных результатов (ПЗ⁻) и диагностическая эффективность (ДЭ).

В таблице 2 приведены сводные показатели качества прогнозирования пиелонефрита.

Таблица 2

Сводная таблица показателей качества прогнозирования пиелонефрита по $KU_{ОРП}$ при $KU_{ОРП}^H = 0,62$

Показатель	$KU_{ОРП}$	ДЧ	ДС	ПЗ ⁺	ПЗ ⁻	ДЭ
Значение показателя	0,95	0,91	0,92	0,88	0,93	0,90

Анализ полученных результатов показывает удовлетворительное совпадение результатов экспертного оценивания и проверки качества работы, синтезированных решающих правил на контрольной выборке по показателям диагностической чувствительности и специфичности, прогностической значимости положительных и отрицательных результатов и общей диагностической эффективности. Таким образом, результаты проверки на контрольной выборке эффективности работы правил прогнозирования развития острого пиелонефрита (активной фазы хронического пиелонефрита) и диагностики пиелонефрита посредством использования гетерогенного пространства информативных признаков показывают приемлемое качество для врачебной практики.

Список литературы

- 1 Ефремов М.А. Гибридная нейронная сеть с макрослоями для медицинских приложений / С.А. Филист, О.В. Шаталова // Нейрокомпьютеры. Разработка и применение, 2014. - №6. - С. 35-39.
- 2 Томакова, Р.А. Формирование пространства информативных признаков для интеллектуальной системы поддержки прогнозирования и диагностики пиелонефрита / Р.А. Томакова, В.В. Федянин, [и др.] // Технические науки - основа современной инновационной системы: матер. V Междунар. науч.- практ. конф. – М., 2015. – С. 11-16.
3. Филист, С.А. Многоагентный подход построения системы интеллектуальной поддержки принятия решений анализа и классификации флюорограмм. / С.А. Филист, М.В. Дюдин, С.В. Дегтярев // Биомедицинская радиоэлектроника, №9, 2014. – С. 15-21.

РЕШЕНИЕ УРАВНЕНИЙ В ЧАСТНЫХ ПРОИЗВОДНЫХ НА МЕМРИСТОРНЫХ КЛЕТОЧНЫХ СЕТЯХ¹

В.И. Горбаченко¹, С. Н. Катков²

Пензенский государственный университет,

¹кафедра "Компьютерные технологии", gorvi@mail.ru

²кафедра "Экономическая кибернетика", skat.pnz@yandex.ru

Л.О. Чуа (Leon Ong Chua) в 1971 году предложил новый элемент электрических схем, описывающий связь магнитного потока с зарядом — мемристор [1], лабораторный образец которого был создан только в 2008 фирмой Hewlett-Packard. Не останавливаясь на особенностях реализации мемристора (см., например, [2]), отметим, что он может выступать в качестве элемента памяти, элемента логических схем и управляемого резистора с памятью. Последнее делает мемристоры очень привлекательными для применения в качестве программируемых синапсов искусственных нейронов [3 – 6].

Использование мемристоров в качестве управляемых резисторов в схемах искусственных нейронов означает использование аналоговых методов обработки информации. Достоинствами аналоговой обработки информации являются высокие производительность и параллелизм обработки информации, малое потребление энергии, устойчивость к деградации компонентов и отказам. Кроме того, аналоговые компьютеры основаны на явлении аналогии и позволяют получить с приемлемой точностью решение плохо обусловленных задач, решение которых на цифровых компьютерах требует больших затрат времени или вообще не может быть получено. Недостатками аналоговых компьютеров, которые привели к переходу от аналоговой к цифровой технике, являлись низкая технологичность элементной базы, недостаточная точность решения и неуниверсальный характер аналоговых компьютеров. Мемристоры, являющиеся изделиями наноэлектроники, решают проблему нетехнологичности и громоздкости старых аналоговых компьютеров. Использование нейронных блоков как второго слоя в архитектуре суперкомпьютера [6] снимает, как будет показано ниже, проблему недостаточной точности аналогового компьютера.

Нейронные сети с успехом применяются не только в областях, традиционно относящихся к искусственному интеллекту и изучению мозга, но и при решении сложных вычислительных задач [7]. Целью данной работы является исследование возможностей решения краевых задач математической физики, описываемых дифференциальными уравнениями в частных производных (ДУЧП), на мемристорных клеточных нейронных сетях с дискретным представлением времени.

Клеточная нейронная сеть [8 – 11] (CNN — cellular neural network) — это система простых процессоров (cell — ячеек), расположенных на регулярной сетке и связанных между собой в одном или более слоях. Любая ячейка в клеточной нейронной сети связана только с соседними ячейками в соответствии с шаблоном. Шаблон ячейки $C(i, j)$ — это множество (окрестность) $N(i, j)$ ячеек $C(k, l)$, с которыми связана ячейка $C(i, j)$, и веса связи. Вес связи (синаптический вес) определяется значениями коэффициентов обратной связи (параметрами шаблона) $g_A(i, j; k, l)$ между выходами $u_{ykl}(t)$ ячеек, входящих в шаблон, и входами ячейки $C(i, j)$. В шаблон также входят внешние входы $u_{ukl}(t)$ и коэффициенты управления $g_B(i, j; k, l)$ (параметры входного шаблона), а также смещение z_{ij} . Пример двумерной клеточной нейронной сети, соответствующей пятиточечному шаблону, показан на рис. 1. Теоретически можно

¹ Работа поддержана грантами РФФИ 16-08-00906, 14-01-00660 и 14-01-00733.

определить клеточную нейронную сеть любого измерения и с произвольным шаблоном, но для простоты ограничимся двумерным случаем. Рассмотрим $M \times N$ клеточную нейронную сеть, имея $M \times N$ ячеек, построенных в M рядов (строк) и N колонок (столбцов).




Рис. 1. Пример структуры клеточной нейронной сети

Работа клеточной сети основана на динамическом обновлении состояния ячеек путем вычисления взвешенной суммы состояний соседей. Уравнение состояния ячейки с непрерывным представлением времени имеет вид [8 – 11]

$$\frac{du_{xij}(t)}{dt} = d_{ij}u_{xij}(t) + \sum_{C(k,l) \in N(i,j)} g_A(i,j;k,l)u_{ykl}(t) + \sum_{C(k,l) \in N(i,j)} g_B(i,j;k,l)u_{ukl}(t) + z_{ij}, \quad (1)$$

где $u_{xij}(t)$ — переменная состояния ячейки; d_{ij} — числовой коэффициент (в электрической схеме ячейки [8] — входное сопротивление ячейки); $u_{ykl}(t)$ — выход ячейки, входящей во множество $N(i,j)$ ячеек шаблона ячейки; $g_A(i,j;k,l)$ — синаптический вес, соединяющий ячейки $C(i,j)$ и $C(k,l)$; $u_{ukl}(t)$ — вход ячейки; $g_B(i,j;k,l)$ — коэффициент управления; z_{ij} — смещение.

Относительно параметров сети примем следующие предположения

$$g_A(i,j;k,l) = g_A(k,l;i,j), \quad d_{ii} > 0. \quad (2)$$

Состояния и веса являются непрерывными значениями. При решении ДУЧП на клеточных сетях [12] обычно исключают из (1) шаблон управления и используют линейную функцию активации: $u_{yij} = u_{xij}$.

В клеточных нейронных сетях с дискретным представлением времени [12, 13] производная по времени в уравнении (1) аппроксимируется по формуле

$$\frac{du_{xij}(t)}{dt} = \frac{u_{xij}(t) - u_{xij}(t-1)}{\Delta t},$$

где Δt — шаг по времени.

Тогда с учетом сделанных предположений уравнение (1) запишется в виде

$$\left[-\frac{1}{\Delta t} + d_{ij} \right] u_{xij}(t) + \sum_{C(k,l) \in N(i,j)} g_A(i,j;k,l) u_{ykl}(t) = - \left[z_{ij} + \frac{1}{\Delta t} u_{xij}(t-1) \right]. \quad (3)$$

В клеточной сети с дискретным представлением времени состояния сети изменяются в дискретные моменты времени.

Несложно показать [12], что система алгебраических уравнений (3) связана масштабными коэффициентами с соответствующей системой разностных уравнений,

аппроксимирующей по неявной схеме ДУЧП с различными граничными условиями. Действительно, пусть в некоторой двумерной области Ω решается ДУЧП

$$\frac{\partial w}{\partial t} = Lw, \quad (4)$$

где L — линейный дифференциальный оператор.

На границе области Ω заданы граничные условия, заданы начальные условия при $t = 0$. Заменяя входящие в Lw производные разностными отношениями, получим разностное выражение $L_h w_h$, являющееся линейной комбинацией значений сеточной функции w_h на некотором множестве $M(x_{ij})$ узлов сетки — сеточном шаблоне

$$(L_h w_h)_{ij} = \sum_{x_{kl} \in M(x_{ij})} a_h(i, j; k, l) w_h(x_{kl}),$$

где $a_h(x_{ij}, x_{kl})$ — коэффициенты, значения которых зависят от конкретной формы разностной аппроксимации, h — шаг сетки, $M(i, j)$ — шаблон в узле x_{ij} .

Такую же форму имеет аппроксимация граничных условий. Соотношение справедливо для произвольной размерности области решения. Применяя неявную аппроксимацию производной по времени в (4), получаем

$$\frac{w_h(x_{ij}, t) - w_h(x_{ij}, t-1)}{\tau} = \sum_{x_{kl} \in M(x_{ij})} a_h(i, j; k, l) w_h(x_{kl}, t),$$

или

$$\left[-\frac{1}{\tau} + a_h(i, j; i, j) \right] w_h(x_{ij}, t) + \sum_{\substack{x_{kl} \in M(x_{ij}), \\ x_{kl} \neq x_{ij}}} a_h(i, j; k, l) w_h(x_{kl}, t) = -\frac{1}{\tau} w_h(x_{ij}, t-1). \quad (5)$$

В (5) суммирование проводится по "окрестности" узла x_{ij} . При условии равенства шаблонов клеточной сети и разностной схемы выражения (3) и (5) подобны, если связать параметры разностной схемы и клеточной сети масштабными соотношениями

$$g_A(i, j; k, l) = m_g a_h(i, j; k, l), \quad g_t(i, j; k, l) = -\frac{1}{\Delta t} + d_{ij} = m_g \left[-\frac{1}{\tau} + a_h(i, j; k, l) \right], \quad (6)$$

$$I_{ij} = z_{ij} + \frac{1}{\Delta t} u_{x_{ij}}(t-1) = m_i \frac{1}{\tau} w_h(x_{kl}, t-1).$$

Связи ячейки с соседними ячейками с помощью пассивных проводимостей возможны, если коэффициенты $a_h(i, j; i, j)$ и $a_h(i, j; k, l)$ имеют разные знаки при $k \neq i$ и $l \neq j$ и выполняется неравенство $|a_h(i, j; i, j)| \geq \sum_{\substack{x_{kl} \in M(x_{ij}), \\ x_{kl} \neq x_{ij}}} |a_h(i, j; k, l)|$, что как правило,

справедливо для разностных схем. Тогда выход клеточной сети связан с сеточной функцией соотношением $w_h(x_{ij}, t) = m_u u_{x_{ij}}(t)$. Причем должен выполняться индикатор подобия $m_g m_u / m_i = 1$. Синаптические веса моделируются электрическими проводимостями, смещение — током, а выход сети — напряжением. Отсюда m_g , m_i и m_u — соответственно, масштабы по проводимости, току и напряжению.

Так как использование сети с дискретным представлением времени основано на неявной схеме аппроксимации, то такая сеть является абсолютно устойчивой при любых значениях шагов по пространству и времени. Клеточная нейронная сеть с дискретным

представлением времени проще сети с непрерывным представлением времени, позволяет использовать итерационную настройку параметров при решении нелинейных задачи, и, как будет показано ниже, позволяет уточнять на цифровых процессорах решение, полученное на аналоговой сети. Полученные результаты легко распространяются на случай стационарных задач.

Синаптические веса клеточной сети (g_A и g_t в (6)) могут быть реализованы с помощью мемристоров [14]. Сопротивление мемристоров можно регулировать, подавая импульсы амплитудой V и длительностью τ выше или ниже пороговых значений $V_{\text{порог}}$ и $-V_{\text{порог}}$. Длительность импульса рассчитывают исходя из знания максимальной G_{max} и минимальной G_{min} проводимостей мемристоров. Отображение синаптических весов сети g_A и g_t в проводимости мемристоров производится с помощью масштабного соотношения [15]

$$G_{ij_A} = \frac{g_A(i, j) - g_{A\min}}{g_{A\max} - g_{A\min}} (G_{\max} - G_{\min}) + G_{\min},$$

аналогично масштабируются величины $g_t(i, j)$, где $g_{A\min} \leq g_A(i, j) \leq g_{A\max}$ и $g_{t\min} \leq g_t(i, j) \leq g_{t\max}$.

Тогда клеточная сеть представляет собой сеть из мемристоров, реализующих синаптические веса g_A и соединенных в соответствии с шаблоном сети. Узлы сети соединены мемристорами, реализующими g_t , с общей точкой ("землей") сети. К узлам сети должны быть подключены схемы задания тока I_{ij} . Мемристоры могут также выполнять функции аналоговой памяти и коммутирующих элементов. Сеть представляет собой аналоговую параллельную систему с очень высокой производительностью. Теоретически решение формируется за время, определяемое переходными процессами в нанoeлектронных схемах. Сеть должна быть также снабжена системой измерения решения в произвольных ячейках, системой подготовки данных, хранения и обработки решения. Таким образом, архитектура вычислительной системы, включающей клеточную мемристорную сеть, должна быть двухслойной [6]: первый (внутренний) слой — мемристорная сеть, второй (внешний) слой — система параллельно работающих процессоров подготовки данных и обработки результатов. Второй слой должен иметь архитектуру и реализацию, обеспечивающие высокоскоростную обработку данных. Можно сказать, что предлагаемая двухслойная архитектура на принципиально новой основе близка к идее аналого-цифровых вычислительных комплексов "сеточная модель-ЦВМ" [16], очень успешно применявшихся для решения сложных краевых задач, но чрезвычайно громоздких и дорогих из-за ограничений тогдашней элементной базы.

Рассмотренная клеточная сеть использует метод прямой аналогии. Точность решения, получаемого на сети, определяется точностью аналоговых компонентов. Считается, что аналоговая техника обеспечивает низкую точность решения. Однако следует учитывать, что исходные данные задачи, как правило, задаются приближенно. Поэтому решение задачи до малых значений формальных показателей точности (например, нормы невязки) не всегда оправдано. Для плохо обусловленных задач, каковыми являются многие реальные задачи, малые значения формальных показателей точности не гарантируют действительную точность решения. Поэтому для многих задач предлагаемые сети могут обеспечить приемлемую точность решения. Следует также отметить устойчивость нейронных сетей по отношению к ошибкам в исходных данных.

Погрешности клеточной сети можно компенсировать, используя алгоритм аддитивной коррекции [12]. Отличительной особенностью алгоритма является то, что на сети формируется только поправка к решению, а само решение вычисляется в цифровом компьютере. При обеспечении сходимости процесса обучения и его устойчивости к аппаратным погрешностям алгоритм аддитивной коррекции обеспечивает точность, принципиально ограниченную лишь возможностями цифрового компьютера. Для описания алгоритма используем матричное описание сети. Система разностных уравнений может быть представлена в матричной форме в виде системы линейных алгебраических уравнений $\mathbf{Aw} = \mathbf{b}$. Если последовательно пронумеровать ячейки сети, то система (3) может быть записана в виде системы линейных алгебраических уравнений: $\mathbf{Gu} = \mathbf{i}$, причем из-за погрешности сети $\mathbf{G} \approx m_g \mathbf{A}$ и при принятых допущениях матрица $\mathbf{G}$ является симметричной положительно определенной. Матрица $\mathbf{G}$ является матрицей проводимостей синаптических весов межклеточных соединений, вектор $\mathbf{i} = m_i \mathbf{b}$ — вектор токов, подаваемых в узлы сети, вектор $\mathbf{u} = m_u \mathbf{w}$ — вектор напряжений выхода сети. Фактически сеть моделирует не матрицу $\mathbf{A}$, а матрицу $\mathbf{B} = \frac{1}{m_g} \mathbf{G}$.

Алгоритм аддитивной коррекции представляет собой итерационный процесс решения системы $\mathbf{Aw} = \mathbf{b}$. Начальным приближением является решение, полученное на сети. На k -ом шаге алгоритма в цифровой части двухслойной системы рассчитывается вектор невязки $\mathbf{r}^{(k)} = \mathbf{b} - \mathbf{Aw}^{(k-1)}$ и масштаб по току $m_i^{(k)} = I_{\max} / \|\mathbf{r}^{(k)}\|$, где $I_{\max}$ — максимальный по абсолютной величине ток, который можно задавать в сети (используется кубическая норма вектора невязки). В методе аддитивной коррекции принципиально важно использовать весь диапазон изменения токов смещения. Рассчитывается вектор токов смещения $\mathbf{i}^{(k)} = m_i^{(k)} \mathbf{r}^{(k)}$ и задается в сеть. На моделирующей сети формируется вектор напряжений поправки к решению, который формально можно описать матричным равенством $\Delta \mathbf{u}^{(k)} = \mathbf{G}^{-1} \mathbf{i}^{(k)}$. В цифровой части после демасштабирования вычисляется вектор поправки к решению $\Delta \mathbf{w}^{(k)} = \left(m_u^{(k)}\right)^{-1} \Delta \mathbf{u}^{(k)} = \mathbf{B}^{-1} \mathbf{r}^{(k)}$ и формируется новое приближение решения $\mathbf{w}^{(k)} = \mathbf{w}^{(k-1)} + \omega_k \Delta \mathbf{w}^{(k)}$, где ω_k — подбираемый или вычисляемый, например, одним из методов спуска, итерационный параметр.

Процесс продолжается до тех пор, пока не будет получено малое значение нормы невязки. Рассмотренный алгоритм можно трактовать как предобусловленный итерационный процесс, а клеточную сеть — как аппаратно реализованный предобусловливатель. В [12] получены условия сходимости процесса и доказана устойчивость процесса к погрешностям задания токов и измерения напряжений. Важно, что из-за близости матрицы предобусловливателя $\mathbf{B}$ к матрице $\mathbf{A}$ для уточнения решения требуется небольшое число итераций [12].

Для решения нелинейных задач можно использовать итерационный алгоритм с пересчетом нелинейных параметров задачи на каждом временном шаге. На каждой итерации на сети решается задача со своими параметрами. Причем можно не изменять параметры сети, а использовать аддитивную коррекцию. В некоторых задачах матрица $\mathbf{A}$ является несимметричной и знаконеопределенной. В этом случае можно рекомендовать использовать один из методов подпространств Крылова — предобусловленный устойчивый алгоритм бисопряженных градиентов (Preconditioned

BiCGSTAB) [17], в котором клеточная сеть выступает в качестве аппаратно реализованного преобусловливателя.

Таким образом, решение дифференциальных уравнений в частных производных возможно на аналоговых клеточных мемристорных сетях с дискретным представлением времени. Реализация вычислительной системы, содержащей мемристорную сеть, целесообразна в виде двухслойной архитектуры. Нижний слой представляет собой мемристорную сеть, верхний — параллельную цифровую систему.

Список литературы

1. Chua L.O. Memristor — The Missing Circuit Element / L.O. Chua. — IEEE Transactions On Circuit Theory. — 1971. — Vol. 18. — Issue 5. — P. 507–519.
2. Храповицкая Ю. В. Перспективные структуры с эффектом памяти, созданные на основе неорганических материалов / Ю.В. Храповицкая, Н.Е. Маслова, М.Л. Занавескин М. Л. // Наука и образование. — 2013. — № 12. E-print: <http://technomag.bmstu.ru/doc/669629.html>
3. Thomas A. Memristor-based neural networks / A. Thomas // Journal of Physics D: Applied Physics. — 2013. — Vol. 46. — No 9. E-print: http://iopscience.iop.org/0022-3727/46/9/093001/pdf/0022-3727_46_9_093001.pdf
4. Осипов В.Ю. Аналоговые ассоциативные интеллектуальные системы / Ю.В. Осипов // Труды СПИИРАН. — 2013. — Вып. 30. С. 141 – 155.
5. Фридман В. На пути к искусственному интеллекту / В. Фридман // В мире науки. — 2014. — № 2. — С. 46 – 53.
6. Галушкин А.И. На пути к нейрокомпьютерам с использованием мемристоров / А.И. Галушкин // XVI Всероссийская научно-техническая конференция с международным участием "Нейроинформатика-2014": лекции по нейроинформатике. — М.: НИЯУ МИФИ. 2014. — С. 62 – 105.
7. Нейроматематика / Агеев А.Д., Балухто А.Н., Бычков А.В. и др. Ред. А.И. Галушкин. — М.:ИПРЖ, 2002. — 448 с.
8. Chua L. Cellular Neural Networks: Theory / L. Chua, L. Yang. — IEEE Transactions on Circuits and Systems. — 1988. — Vol. 35. — No 10. — P. 1257 – 1272.
9. Chua L. Cellular Neural Networks: Applications / L. Chua, L. Yang. — IEEE Transactions on Circuits and Systems. — 1988. — Vol. 35. — No 10. — P. 1273 – 1290.
10. Chua L. Cellular Neural Networks and Visual Computing: Foundations and Applications / L. Chua, T. Roska. — Cambridge University Press, 2002. — 408 p.
11. Slavova A. Cellular Neural Networks: Dynamics and Modelling / A. Slavova. — Springer, 2010. — 220 p.
12. Горбаченко В.И. Нейрокомпьютеры в решении краевых задач теории поля /В.И. Горбаченко. — М.: Радиотехника, 2003. — 336 с.
13. Itoh M. Memristor Cellular Automata and Memristor Discrete-Time Cellular Neural Networks / M. Itoh, L. Chua // Memristor Networks. — Springer, 2014. — P. 649 – 713.
14. Laiho M. Memristive analog arithmetic within cellular arrays / M. Laiho, E. Lehtonen, Wei L. // 2012 IEEE International Symposium on Circuits and Systems (ISCAS). — Seoul, 2012. — p. 2665 – 2668.
15. Тарков А. С. Отображение матриц весовых коэффициентов слоя нейронной сети на мемристорный кроссбар / М.С. Тарков // XVII Всероссийская научно-техническая конференция с международным участием "Нейроинформатика-2015": сборник научных трудов. — М.: НИЯУ МИФИ. 2015. — С.126 – 133.
16. Козлов Э. С. Автоматизация процессов решения краевых задач / Э.С. Козлов, Н.П. Сергеев, Н.С. Николаев. — М.: Энергия, 1974. — 112 с.
17. Vorst van der H. Iterative Krylov Methods for Large Linear Systems / H. van der Vorst. — Cambridge: Cambridge University Press, 2003. — 232 p.

СИСТЕМНЫЙ ПОДХОД К ОБРАБОТКЕ СТРУКТУРНОЙ ИНФОРМАЦИИ О СВОЙСТВАХ ОРГАНИЗМА НА ОСНОВЕ НЕЧЕТКОЙ ЛОГИКИ

Денисова Т.Г.

Институт информационных и вычислительных технологий КН МОН РК,
elkaz41@mail.ru

Введение. Важным условием повышения эффективности и безопасности лекарственных средств (ЛС) является не только грамотная стратегия их применения, но и тактика для каждого конкретного пациента. Тактика выбора и применения ЛС во многом зависит от индивидуальных особенностей движения ЛС в организме конкретного пациента, а точнее, от различных факторов, воздействующих на нее. Знание и учет этих факторов позволяет индивидуализировано подойти к выбору как самого ЛС, так и его режима дозирования, а также к коррекции проводимого лечения, что лежит в основе принципов так называемой персонализированной медицины, применение в клинической практике которых позволит повысить эффективность и безопасность лечения.

Учет индивидуальных свойств организма очень важный фактор для построения математических моделей, описывающих динамику развития заболеваний и процессы терапии. Одними из важнейших свойств организма являются: 1) возраст; 2) масса тела; 3) функциональное состояние; 4) патологическое состояние; 5) пол; 6) генетические особенности. В данной статье приведены результаты системного подхода к обработке структурной информации о возрасте человека, с учетом влияния данного свойства организма на принципы дозирования ЛС.

Изучение особенностей действия и применения ЛС у лиц детского возраста имеет (педиатрическая фармакология) особое значение, так как именно данный возраст требует тщательного подбора доз ЛС [1]. Современные пробелы в наших знаниях (например, отсутствие полных данных о возрастной динамике экспрессии ферментов биотрансформации и транспортёров ЛС) препятствуют использованию простых лекарственных «антропометрических» подходов к выбору режимов дозирования ЛС у детей младшего возраста. Однако такие подходы могут иметь важное клиническое значение у детей старше восьми лет и у подростков, у которых функции органов приближены к таковым у взрослых.

Также и гериатрическая фармакология приобретает всё большее значение, так как доля пациентов этих возрастных групп среди населения значительно возросла. В работе [1] отмечено, что во всех высокоразвитых странах мира в настоящее время происходит стремительное старение населения. По прогнозам Организации Объединённых Наций, к 2025 году число людей старше 60 лет достигнет 1,2 млрд человек. Это потребует дальнейшего развития гериатрической фармакологии – раздела клинической фармакологии, изучающего принципы дозирования и особенности взаимодействия ЛС у пожилых, а также пути повышения устойчивости организма таких людей к нежелательному воздействию ЛС.

Прогрессирующее уменьшение адаптационных возможностей организма, изменение его реактивности создают условия для развития патологии [2 – 6]. Уровень заболеваемости у пожилых людей (60-74 года) почти в два раза выше, а у лиц старческого возраста (75 лет и старше) – в 6 раз выше, чем у лиц молодого возраста [3]. Имеются существенные различия в развитии патологических процессов у старых и молодых людей. Для большинства болезней в пожилом и старческом возрасте характерны малая выраженность и необычность клинических проявлений. У пожилых людей наблюдается

склонность к медленно нарастающим, вялотекущим патологическим процессам [6] .

Целью данного доклада является представление результатов системного подхода к обработке структурной информации о возрасте человека с учетом влияния данного свойства организма на принципы выбора и методики дозирования лекарственных средств с использованием методологии нечетких множеств. В дальнейших исследованиях будут представлены результаты оценки других свойств организма и их использование при построении искусственной иммунной системы терапии заболеваний человека.

Систематизация информации о принципах выбора и методики дозирования лекарственных средств в соответствии с возрастом. Чувствительность организма к лекарственным веществам меняется в зависимости от возраста. Для разных фармакологических средств закономерности в этом отношении различны. Однако в общем дети и пожилые люди более чувствительны к действию лекарств по сравнению с лицами среднего возраста [7].

Известно, что деятельность органов и систем нашего организма оказывает существенное влияние на всасывание, воздействие и выведение принимаемого нами препарата. Такое влияние может носить как общий, так и частный характер. К числу факторов частного характера относятся индивидуальные особенности организма, которые в значительной степени влияют на действие лекарств и требуют определенного подхода в каждом конкретном случае. К числу общих факторов, которые учесть значительно легче, относится возраст пациента. Чувствительность по отношению к лекарствам меняется в зависимости от возраста. Поэтому выделяют две категории пациентов – дети (до 14 лет) и пожилые люди (старше 65 лет), для которых в силу возрастных особенностей организма отдельно устанавливают дозировки и частоту приема лекарств.

С возрастом увеличивается масса тела и одновременно меняется чувствительность детского организма к лекарственным веществам, причем к различным веществам по-разному [8]. Поэтому трудно дать общие рекомендации в отношении дозировки лекарственных веществ для детей. Для того чтобы определить терапевтическую дозу каждого ядовитого или сильнодействующего лекарственного вещества, следует пользоваться Государственной фармакопеей [9]. Для остальных препаратов дозы уменьшают в зависимости от возраста по сравнению с дозами для взрослых (достигших 25-летнего возраста) следующим образом:

– для детей до 1 года: $\frac{1}{24} \div \frac{1}{2}$ дозы для взрослых; для детей 1 года: $\frac{1}{12}$ дозы для взрослых;

для детей 2 лет: $\frac{1}{8}$ дозы для взрослых; для детей 4 лет: $\frac{1}{6}$ дозы для взрослых; для детей

6 лет: $\frac{1}{4}$ дозы для взрослых; для детей 7 лет: $\frac{1}{3}$ дозы для взрослых; для детей 14 лет: $\frac{1}{2}$ дозы для взрослых;

– для молодых людей 18 лет: $\frac{3}{4}$ дозы для взрослых;

– для взрослых людей от 25 лет: 1 доза.

При назначении лекарственных веществ пожилым людям (старше 60 лет) учитывается их различная чувствительность к разным группам лекарственных средств. "Дозы препаратов, угнетающих центральную нервную систему (снотворные, нейролептические средства, препараты группы морфина, бромиды), а также сердечных

гликозидов, мочегонных средств уменьшают до $\frac{1}{2}$ дозы взрослого. Дозы других сильнодействующих и ядовитых лекарственных средств составляют $\frac{2}{3}$ дозы взрослого.

Дозы антибиотиков, сульфаниламидов и витаминов обычно равны дозам взрослых [8].

В пожилом и старческом возрасте замедлено всасывание ЛС, менее эффективно протекает их метаболизм, снижена скорость экскреции препаратов почками. В целом чувствительность к большинству лекарственных препаратов в пожилом и старческом возрасте повышена, в связи с чем дозу необходимо снизить. При этом ассортимент лекарственных веществ следует ограничивать минимально токсичными средствами.

Реакция пожилого больного на лекарственный препарат в значительной степени зависит от физиологических и патологических изменений, происходящих при старении. Физиологические процессы старения организма приводят к изменению фармакокинетики и фармакодинамики лекарственных средств [3 – 5]. У лиц пожилого возраста и престарелых для большинства препаратов практически все фармакокинетические процессы протекают замедленно, в связи с чем наблюдается повышение количества свободных препаратов в кровеносном русле. По этим причинам пожилые больные обычно нуждаются в меньшем количестве лекарств для достижения необходимого терапевтического эффекта.

В среднем у одного пациента старше 60 лет обнаруживают 4-5 различных заболеваний, что закономерно увеличивает потребление таким пациентом разнообразных ЛС и увеличивает вероятность взаимодействия препаратов. Риск возникновения побочных эффектов у больных старше 60 лет в 2-3 раза выше, чем у молодых людей и пациентов среднего возраста. Следует особо подчеркнуть, что наибольшее число смертельных исходов, связанных с нерациональной фармакотерапией, приходится на возрастную группу 80-90 лет. Функциональные способности большинства основных систем и органов постепенно снижаются в среднем после 45 лет. Для фармакологов и клиницистов наиболее важно ослабление выделительной функции почек. По некоторым данным, после 20 лет функции почек снижаются примерно на 1% ежегодно.

Современные достижения в области возрастной физиологии стареющего организма, а также многочисленные клинические наблюдения и накапливающиеся данные о действии медикаментозных средств в гериатрической практике свидетельствуют о необходимости научного развития фармакологии старческого возраста [10].

Таким образом, изменения процессов всасывания, распределения, биотрансформации и элиминации в пожилом и старческом возрасте способствуют снижению клиренса и увеличению периода полувыведения ЛС. Вследствие этого дозы большинства препаратов, которые назначают гериатрическим больным, советуют уменьшать на $\frac{1}{2} \div \frac{1}{4}$ от рекомендованной и соответственно увеличивать интервалы между их введением.

Развитие теории нечетких множеств обработки данных для методики дозирования лекарственных средств. В настоящее время существует широкий круг работ в области медицины, касающихся развитию методов вычислительных и информационных технологий для получения результатов по обработке данных для диагностики и лечения болезней пациентов. В связи с тем, что задачи, связанные с

вопросами медицины, имеют высокую сложность и неопределенность, используются методы интеллектуальных систем, такие как нечеткая логика, искусственные нейронные сети и генетические алгоритмы.

Во многих областях медицины, например при терапии болезней почек, диагностики рака, астмы, разработаны подходы на основе нечеткой логики [11]. Система управления на основе нечеткой логики помогает врачам давать быстрые и эффективные решения относительно дозы лекарственного средства с учетом всех факторов. С помощью этой системы медицинские ошибки сведены к минимуму, предотвращаются возможные осложнения. Более того, надежность этого метода была доказана и принята в статистических исследованиях [12,13].

В данном докладе приведены результаты построения нечеткого множества для такого свойства, как "возраст", в соответствии с отечественной Государственной фармакопеей [9].

На рисунке 1 показано представление лингвистических переменных функциями, обозначенными терминами: "дети", "молодые люди", "взрослый", "пожилой". В частности, построены нечеткие множества с функциями принадлежности: $\mu_{\text{дети}}(x)$, $\mu_{\text{мол.люди}}(x)$, $\mu_{\text{взрослый}}(x)$, $\mu_{\text{пожилой}}(x)$.




Рис. 1. График четырех нечетких множеств свойства "возраст"

Выражения для функций принадлежности, описывающих нечеткие множества (рисунок 1) имеют вид:

$$\mu_{\text{дети}}(x) = \begin{cases} 1, & 0 \leq x \leq 14, \\ \frac{18-x}{4}, & 14 < x \leq 18, \\ 0, & 18 < x. \end{cases} \quad \mu_{\text{мол.люди}}(x) = \begin{cases} 0, & 0 \leq x \leq 14, \\ \frac{x-14}{4}, & 14 < x \leq 18, \\ \frac{25-x}{7}, & 18 < x \leq 25, \\ 0, & 25 < x. \end{cases} \quad (1)$$

$$\mu_{\text{взрослый}}(x) = \begin{cases} 0, & 0 \leq x \leq 20, \\ \frac{x-25}{5}, & 20 < x \leq 25, \\ 1, & 25 < x \leq 45, \\ \frac{65-x}{20}, & 45 < x \leq 65, \\ 0, & 65 < x. \end{cases} \quad \mu_{\text{пожилой}}(x) = \begin{cases} 0, & 0 \leq x \leq 60, \\ \frac{x-60}{5}, & 60 < x \leq 65, \\ 1, & 65 < x. \end{cases}$$

Нечеткие множества для данных по возрасту, сформированные в соответствии с формулами (1), представляются как множества $\{x, \mu(x)\}$.

Заключение. Полученные нечеткие множества для свойства организма "возраст", наряду с другими свойствами организма человека используются для разработки правил нечеткой логики и построения искусственной иммунной системы оптимизации терапевтических доз лекарственных средств.

Исследования проводятся по гранту №ГР 0115РК00549 МОН РК по теме: Компьютерный молекулярный дизайн лекарственных препаратов на основе иммунносетевого моделирования (2015-2017 гг.).

Список литературы

1. Клиническая фармакокинетика: теоретические, прикладные и аналитические аспекты: руководство / под ред. В.Г. Кукеса. – М.: ГЭОТАР-Медиа, 2009. – 432 с.
2. Газизов, Р.М. Основы лекарственной терапии в пожилом и старческом возрасте / Р.М. Газизов // – Казань: Практическая медицина. – 2010. – №2 (41). – С. 11-14.
3. Денисова, Т.П. Клиническая геронтология: избранные лекции / Т.П. Денисова, Л.И. Малинова. – М.: Медицинское информационное агентство, 2008. – 256 с.
4. Основы клинической фармакологии и рациональной фармакотерапии: руководство для практикующих врачей / Ю.Б. Белоусов, М.В. Леонов, А.И. Вялков и др. – М.: Бионика. – 2002. – 368 с.
5. Пожилой больной / под ред. Л.И.Дворецкого. – М.: Русский Врач, 2001. – 144 с.
6. Руководство по геронтологии и гериатрии. В 4 т. Т.3. Клиническая гериатрия / под ред. В.Н.Ярыгина, А.С. Мелентьева. – М.: ГЭОТАР-Медиа, 2007. – 896 с.
7. Клиническая фармакология: учебник / сост. Н.В. Кузнецовой. – М.: ГЭОТАР-Медиа, 2013. – 272 с.
8. Майский, В.В. Фармакология с рецептурой / В.В Майский, В.К. Муратов. – М.: Медицина, 1986. – 448 с.
9. Государственная Фармакопея Российской Федерации XII. В 5 частях. Часть 2. – М.: Научный центр экспертизы средств медицинского применения, 2008. – 704 с.
10. Коркушко О.В. Клиническая кардиология в гериатрии / О.В. Коркушко. – М.: Медицина, 1980. – 288 с.
11. Barro, S. Fuzzy Logic in Medicine / S.Barro, R.Marin // Springer series: Studies in fuzziness and soft computing. – 2001. – Vol. 83. – 310 p.
12. Dev, U. Application of fuzzy logic in medical data interpretation / A. Sultana , D. Saha, N. K. Mitra // Bangladesh J. Sci. Ind. Res. – N 49(3). – 2014. –pp. 137-146.
13. Patel, A. Application of fuzzy logic in biomedical iformatics / A. Patel, S.K. Gupta, Q. Rehman, M.K.Verma // Journal of Emerging Trends in Computing and Information Sciences. – Vol. 4. – N. 1. – 2013. – pp. 57-62.

ВИЗУАЛЬНОЕ УПРАВЛЕНИЕ И КОГНИТИВНАЯ ГРАФИКА В ФУНКЦИОНАЛЬНЫХ ГИБРИДНЫХ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМАХ²

А.В. Колесников¹, С.В. Листопад², В.И. Данишевский³, С.Б. Румовская⁴, К.В. Суворов⁵

^{1,2,4} Калининградский филиал ФИЦ ИУ РАН,

^{1,3,5} БФУ им. И. Канта, кафедра телекоммуникаций

¹avkolesnikov@yandex.ru, ²ser-list-post@yandex.ru, ⁴danishevskii.v.i@mail.ru,

³sophiyabr@gmail.com, ⁵kest93suvorov@mail.ru

Задачи, возникающие в практике принятия решений, являются сложными в том смысле, что состоят из множества взаимосвязанных, взаимозависимых частей, для решения которых требуется использование знаний, полученных в рамках различных научных школ. Для работы с такими задачами актуально применение систем синергетического и гибридного искусственного интеллекта, в частности гибридных интеллектуальных систем (ГиИС), решающих задачи с высокой сложностью моделирования не хуже реальных экспертов [1]. Применение нескольких методов искусственного интеллекта в составе ГиИС дает возможность моделировать совместную работу нескольких экспертов с различными моделями внешнего мира. Знания в области синергетического и гибридного искусственного интеллекта изучены, обобщены и опубликованы в работах А. Н. Борисова, А. В. Гаврилова, В. Ф. Пономарева, А. В. Колесникова, Д. А. Поспелова, В. Н. Вагина, А. П. Еремеева, Г. В. Рыбиной, В. Б. Тарасова, Н. Г. Ярушкиной, С. Гунэтилэйка (S. Goonatilake), С. Кхеббала (S. Khebbal), Л. Медскера (L. Medsker).

Существенный недостаток ГиИС систем — моделирование преимущественно логического мышления, обеспечивающего возможность рассуждать в рамках абстрактных цепочек символов, с которыми связаны некоторые семантические и прагматические представления. Не менее важен и другой механизм мышления — способность использовать визуальные образы и представления о них [2]. Такие образы обладают большей конкретностью и интегрированностью, чем символьные представления. Они и более расплывчаты, менее логичны, чем то, что скрывается за элементами, с которыми оперирует логическое мышление. Без них нельзя отображать в сознании человека окружающий мир в той полноте, которая для него характерна. Вопросы принятия решений человеком на основе визуальных образов исследуются в таких научных направлениях, как визуальное управление, визуальный управленческий контроль, когнитивная графика, образное мышление и инженерия образов. В работе будет представлен краткий обзор методов и технологий этих научных направлений, уточнены понятия визуального управления и когнитивной графики, а также разработана общая схема рассуждений ГиИС над гетерогенным визуальным полем.

Феномен человеческого визуального восприятия заключается в том, что он способен воспринимать образ целиком, а не набор отдельных, независимых объектов [3]. Это явление изучено теоретиками Гештальта М. Вертхеймером (M. Wertheimer), В. Кехлером (W. Köhler) и К. Коффка (K. Koffka), определившими врожденные умственные законы восприятия объектов. Основной принцип Гештальта — целое не является простой суммой своих частей, а имеет большее значение, чем его отдельные компоненты. Принципы Гештальта определяют правила, согласно которым человеческое восприятие организует визуальные элементы в «единое целое». Эти

² Работа поддержана грантом РФФИ 16-07-00271а.

принципы не потеряли актуальность и на данный момент: фигура и земля, близость, общие черты, перекрытие, непрерывность, общая область, соединение и симметрия.

Визуальное представление улучшает понимание данных, информации и знаний специалистами, что, в свою очередь, повышает эффективность процесса принятия решений в целом [3]. В [4], сравнивая визуальное и текстовое представление задач из области физики, авторы указывают следующие причины этого явления: 1) локальность, близость расположения элементов, требующих совместной обработки; 2) минимизация количества обозначений в силу того, что люди способны воспринимать правильно организованную визуальную информацию без детального текстового описания; 3) улучшение восприятия: визуальное представление информации позволяет естественным образом представить отношения и зависимости между понятиями предметной области, за счет чего значительно повышается интенсивность умозаключений экспертов.

Использование визуального представления данных, информации и знаний изучается, в частности, в таких научных направлениях, как визуальное управление и когнитивная графика. Визуальное управление — принцип построения и организации рабочего места, при котором пользователь имеет возможность быстро получать ключевую информацию с помощью технологий визуализации и оперативно реагировать на нее. Основная цель визуального управления — организовать рабочее место пользователя таким образом, чтобы ситуация принятия решений стала для него прозрачной и понятной. Основная технология, применяемая при этом, — визуализация информации об объекте и субъекте управления.

В этом смысле визуальное управление имеет явное сходство с когнитивной графикой — совокупностью методов и средств представления знаний и работы с ними на уровне визуальных (статических и/или динамических) образов. Компьютерные образы при этом рассматриваются как декларативные структуры, трансформирующиеся во внутреннее представление процедурами, отражающими знания о законах преобразования сформированных образов, и позволяют активизировать представления об объектах, недоступных прямому наблюдению или не имеющих образного представления в реальном мире [5]. Когнитивная графика — базис, на основе которого строятся системы визуального управления.

Применение когнитивной графики и методов визуального управления оказывает положительное влияние не только на процесс индивидуального принятия решений, но и активно используется во время коллективной работы над задачами. Большинство методов визуального управления изначально нацелены на улучшение коммуникации между членами коллектива, принимающего решения. Д. Роэм (D. Roam) отмечает, что даже простейшие картинки, сделанные от руки на салфетке, могут запустить коллективное обсуждение задачи и ускорить процесс ее решения: «Рисую их, глядя на них или разговаривая о них, эксперты значительно усиливают свои способности думать, помнить и действовать» [6, с. 21].

Таким образом, визуальное представление данных, информации и знаний — неотъемлемая часть процесса решения задач экспертами. В связи с этим невозможно полноценно моделировать коллективные рассуждения с использованием ГиИС без учета визуального, образного мышления. Рассмотрим основные методы визуального представления информации с целью их дальнейшего применения в ГиИС.

На практике, используются более сотни методов визуального структурирования, что обусловлено существенными различиями в природе, особенностях и свойствах знаний различных предметных областей. В работах [3; 7; 8] проанализированы наиболее

известные методы визуализации, определены критерии классификации и классы методов (рис. 1).

Применение данных критериев классификации к методам визуализации информации, применяемым в ГиИС, позволит, определив степень релевантности каждого метода классу, выбирать методы визуализации в соответствии с теми задачами, которые стоят перед элементами ГиИС. Рассмотрим структуру ГиИС с когнитивным компонентом, в котором выполняются рассуждения на основе визуальных образов.



Рис. 1. Критерии классификации и классы методов визуализации

Использование когнитивной графики в ГиИС предполагается на двух уровнях:

1. Уровень субъекта управления системой предполагает использование методов когнитивной графики и визуального управления при разработке пользовательского интерфейса ГиИС. Предполагается, что данный уровень улучшит восприятие информации конечным пользователем системы – лицом, принимающим решения – за счет активации правополушарных рассуждений при принятии окончательного решения с использованием методов когнитивной графики.

2. Уровень внутренней структуры ГиИС предполагает использовать когнитивную графику и методы визуального управления при моделировании двух видов эффектов: групповые эффекты, проявляющиеся при выработке решений элементами ГиИС на уровне системы в целом; эффекты, возникающие в элементах ГиИС при моделировании визуальных рассуждений. Моделирование эффектов первого вида описано, например, в [1]. Что касается эффектов второго типа, их моделирование – предмет дальнейших исследований. Данные эффекты предполагается имитировать посредством распознавания образов и алгоритмов, порождающих эти визуальные образы.

Схема рассуждений над гетерогенным визуальным полем в ГиИС показана на рисунке 2. ГиИС состоит из элемента-ЛПР, элементов-экспертов, хранилища визуальных шаблонов и рабочего поля, которые взаимодействуют, обмениваясь, помимо прочего, визуальной информацией.

Элемент-ЛПР моделирует работу реального ЛПР по декомпозиции задачи, распределению подзадач по элементам-экспертам в соответствии с их возможностями, интеграции частных решений элементов-экспертов. Последние представляют собой компьютерные модели знаний реальных экспертов, при этом, в отличие от элементов-экспертов классических ГИИС, они могут обмениваться визуальной информацией. Для этих целей в состав каждого элемента ГИИС помимо подсистемы рассуждений включены подсистемы восприятия и генерации визуальной информации.




Рис. 2. Рассуждения над гетерогенным визуальным полем

Подсистема восприятия визуальной информации, своего рода «виртуальное зрение», производит распознавание входящего визуального образа. Обработанные данные поступают в подсистему рассуждений, где происходит обработка информации методами искусственного интеллекта, моделирующими поведение эксперта, в результате которой вырабатывается некоторое решение. Далее решение поступает в подсистему генерации визуальной информации. Данная подсистема обращается к хранилищу визуальных шаблонов, содержащему все доступные в этой системе методы визуализации информации, их характеристики и классификации в соответствии с критериями (рис. 1), с целью выбрать релевантный шаблон визуализации решения. На основе шаблона происходит генерация визуального образа, после чего он передается другим элементам ГИИС.

Элементы ГИИС с когнитивным компонентом могут взаимодействовать и обмениваться визуальной информацией как напрямую друг с другом, так и через общее

рабочее поле, которое представляет собой «доску объявлений», доступную всем элементам. Вывешивая на эту «доску объявлений» свои частные решения, элементы ГиИС модифицируют первоначальную постановку задачи, меняют ее восприятие другими элементами, конструируют общее, интегрированное решение.

В работе были рассмотрены и проанализированы понятия визуального управления и когнитивной графики. Проведен анализ технологий, используемых в области визуализации информации, данных и знаний, выделены классы методов по различным критериям, что позволит систематизировать изучение и разработку в области визуального управления. Использование предложенной классификации дает возможность реализовать отдельные подсистемы ГиИС с когнитивным компонентом, моделирующим рассуждения над гетерогенным визуальным полем.

В работе также представлена разработанная общая схема рассуждений ГиИС над гетерогенным визуальным полем. Моделирование визуальных рассуждений позволит более полно отображать в памяти компьютера окружающий мир и его свойства. Когнитивная составляющая позволит системе детально анализировать разнообразную информацию на нескольких уровнях представления, что повысит релевантность решений сложности исследуемых ситуаций.

Список литературы

1. Кириков И.А. Гетерогенные интеллектуальные компьютерные системы поддержки принятия решений: модели координации и согласованности / И.А. Кириков, А.В. Колесников, С.В. Листопад и др. // Системы и средства информатики. — 2015. — Т. 25. — Вып. 2. — С. 96 – 110.
2. Башмаков А.И. Интеллектуальные информационные технологии / А.И. Башмаков, И.А. Башмаков. — М. : Изд-во МГТУ им. Н. Э. Баумана, 2005. — 304 с.
3. Mazza R. Introduction to Information Visualization / R. Mazza. — London: Springer-Verlag London Limited, 2009. — 139 p.
4. Larkin J. H. Why a diagram is (sometimes) worth ten thousand words / J.H. Larkin, H.A. Simon // Diagrammatic Reasoning — Cognitive and Computational Perspectives. — Cambridge, CA: AAAI Press, MIT Press, 1995. — P. 69 – 109.
5. Данишевский В.И. Гибридная интеллектуальная система с когнитивной компонентой для диспетчерского управления региональной энергосистемой / В.И. Данишевский, А.В. Колесников // Интегрированные модели и мягкие вычисления в искусственном интеллекте: сб. науч. тр. VIII Междунар. науч.-техн. конф. : в 2 т. — М. : Физматлит, 2015. — Т. 1. — С. 391 – 399.
6. Роэм Д. Практика визуального мышления / Д. Роэм. — М.: Манн, Иванов и Фербер, 2014. — 396 с.
7. Lengler, R., Eppler, M. A Periodic Table of Visualization Methods. E-print: http://www.visual-literacy.org/periodic_table/periodic_table.html.
8. Li, K. Categorisation of visualisation methods to support the design of Human-Computer Interaction Systems / K. Li, A. Tiwari, J. Alcock, P. Bermell-Garcia // Applied Ergonomics. — 2016. — Vol. 55. — P. 85 – 107.

МЕТОД ПОВЫШЕНИЯ КАЧЕСТВА АНАЛИЗА РЕНТГЕНОВСКИХ СНИМКОВ НА ОСНОВЕ КОМБИНИРОВАННЫХ КЛАССИФИКАТОРОВ³

П.С. Кудрявцев, А.А. Кузьмин, О.В. Шаталова, С.А. Филист
Юго-Западный государственный университет, кафедра биомедицинской
инженерии, SFilist@gmail.com

Решение задач идентификации патологических структур на рентгеновских цифровых снимках (РС) грудной клетки представляет собой большое искусство и воплощает в себе умение распознавать даже самые малые изменения яркостей точек РС, а также способность обнаруживать аномальные структуры, особенно при низком разрешении снимка. Это требует высокой квалификации и доступно немногим. Поэтому разработка автоматизированных систем диагностики заболеваний легких является актуальной научно-технической задачей. Тем не менее, более 90% людей, у которых рентгенологическое обследование показало результат «туберкулез», на самом деле являются здоровыми. Этот известный парадокс Байеса обусловлен значительной разницей в долях больных туберкулезом и здоровых. Поэтому рентгеновская диагностика относится к «слабым» классификаторам и нуждается в методах, направленных на их усиление. Рентгеновские исследования, в частности, флюорография, остается одним из самых доступных методов скрининговой диагностики легочных заболеваний, поэтому задача повышения его диагностической эффективности в настоящее время остается актуальной.

Для повышения диагностической эффективности «слабых» классификаторов используется методология бустинга, сущность которой заключается в том, что путем агрегирования классификаторов с низкой диагностической эффективностью («слабых» классификаторов) пытаются получить классификаторы с более высокой диагностической эффективностью – «сильные» классификаторы. В частности, алгоритм бустинга может быть реализован последовательностью процедур обучения «слабых» классификаторов, выбору наиболее точных из них и составлению их линейной комбинации

$$C(x) = \begin{cases} 1, & \text{если } \sum_{t=1}^T a_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T a_t \\ 0, & \text{иначе,} \end{cases} \quad (1)$$

где $C(x)$ – итоговый сильный классификатор, T – число слабых классификаторов внутри сильного, a_t – весовой коэффициент t -го слабого классификатора, $h_t(x)$ – t -й слабый классификатор со своими параметрами.

При этом соответствующие всем экземплярам обучающей выборки весовые коэффициенты (изначально они одинаковые) модифицируются в процессе настройки алгоритма так, что каждый следующий слабый классификатор при своем обучении акцентирует внимание на тех изображениях тренировочного набора, с которыми не справились предыдущие [1].

Для классификации патологических образований на рентгеновских снимках необходимо выделить поля легких, а затем разбить их на сегменты. Алгоритмы автоматического выделения полей легких описаны в [2, 3]. Выделенные поля легких делятся на определенные отделы. Современные медицинские технологии предъявляют высокие требования к локализации патологических образований, поэтому дислокацию патологического очага желательно указывать в определенном сегменте легкого.

³ Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 16-07-00164 а.

Для поиска патологических образований на рентгеновском снимке осуществляется сканирование по сегментам снимка. Во вложенном цикле осуществляется поиск патологических образований внутри сканируемого отдела посредством классификатора, полученного на основе методологии бустингового анализа.

За основу алгоритма классификации взяты методы гибридной классификации, изложенные в работах [4, 5, 6], а также метод Виолы-Джонса [1]. В алгоритме используется два «слабых» классификатора. Идея селекции слабых классификаторов состоит в адаптации размера окна, используемого в методе Виолы-Джонса, под диагностируемое легочное заболевание, например, пневмонию.

При исследовании флюорограмм больных пневмонией было установлено, что патологические фрагменты изображения связаны с размыванием морфологических структур флюорограммы. Этот процесс может быть обнаружен двумя слабыми классификаторами: классификаторами, построенными на дескрипторах на основе функций Уолша, и классификаторами на дескрипторах, полученных по результатам аппроксимации гистограмм яркости в окне.

Дескрипторы на основе функций Уолша получают аналогично дескрипторам на основе примитивов Хаара. Отличие состоит лишь в том, что если в методе Виолы-Джонса используются все примитивы Хаара с последующим их исключением в зависимости от качества классификации, то в предлагаемом алгоритме классификации используется ограниченный набор функций Уолша, полученных во всем окне анализа, например, первые восемь. При этом оптимизируется размер окна от 24x24 до 4x4 пикселей.

Второй «слабый» классификатор основан на дескрипторах, полученных в результате аппроксимации гистограмм в окне анализа. Для понимания этого метода построения «слабого» классификатора рассмотрим рисунок 1. На рисунке 1, а слева показано окно анализа флюорограммы в поле легкого без патологических изменений. Справа на этом рисунке показана гистограмма яркости в этом окне.

Анализ аналогичных гистограмм различных рентгеновских снимков показал, что при отсутствии патологических изменений в окне анализа гистограммы имеют многомодальную форму. На рисунке 1, б слева показано окно анализа, которое моделирует пневмонию. Для модели пневмонии в окне анализа флюорограммы здорового пациента использовалась низкочастотная фильтрация посредством двумерного преобразования Фурье. При наличии низкочастотной фильтрации исчезает модальность гистограммы яркости и гистограмма приобретает форму, близкую к треугольной.

На рисунке 2 показаны окна анализа одного и того же изображения флюорограммы, у которого имеются сегменты, классифицируемые как пневмония.

Анализ представленных изображений позволяет сделать вывод, что и у реальных патологических образований с пневмонией гистограммы яркости в окне анализа приобретают треугольную форму. Поэтому дескрипторы второго классификатора формируются как примитивы, аппроксимирующие гистограммы яркости в окне анализа.

«Слабые» классификаторы 1 и 2 работают в окне анализа одного размера. Агрегатор классификаторов принимает окончательное решение о принадлежности фрагмента в окне анализа к исследуемому классу. Сегмент, принадлежащий окну анализа бинаризируется. По мере продвижения окна анализа по изображению осуществляется формирование бинарного изображения.

Реальные флюорограммы с пневмонией до обработки и после обработки представленным методом, показаны на рисунке 3.




Рис.1. Окна анализа и гистограммы яркости флюорограммы: окно без патологии – *а*; модель окна с патологией, полученная в результате низкочастотной фильтрации окна без патологии – *б*




Рис.2. Окна анализа и гистограммы яркости флюорограммы: окно без патологии – *а*; окно с пневмонией – *б*




Рис.3. Реальные флюорограммы с пневмонией до обработки и после обработки представленным методом

Программное обеспечение, реализующее предложенные метод и алгоритмы, испытывалось при различных рентгенологических синдромах, а также при различных структурах нейронных сетей. Анализ характеристик выделения исследованных патологических сегментов изображения РС грудной клетки показал, что предложенный метод анализа позволяют повысить эффективность сегментации более чем в 1,5 раза по сравнению с известными, на одних и тех же контрольных выборках.

В результате экспериментальных исследований получены количественные результаты качества диагностики рентгенологических синдромов. Для формирования обучающих и контрольных выборок использовались рентгеновские снимки и результаты клинических наблюдений больных больницы скорой медицинской помощи г. Курска. При этом было исследовано 34 флюорограммы больных пневмонией, для которых характерны синдромы, связанные с нарушением прозрачности легочных тканей: «Обширное (тотальное) снижение прозрачности легочной ткани»; «Субтотальное затемнение»; «Ограниченное затемнение». В качестве контрольной группы использовались флюорограммы пятидесяти пациентов той же больницы без легочных патологий.

На диаграмме (рисунок 4) представлены результаты анализа заключений по полу и критерию болен – здоров. Последний важен при принятии решения для последующей диспансеризации и дообследования в клинических условиях, если выявляется, что пациент болен, а программа не может указать точный диагноз.




Рис.4. Совпадений врачебных заключений и АСДЗЛ по критерию болен – здоров

При проведении экспериментальных исследований было выявлено, что заключение программы совпадает с врачебным по диагнозу: «патологии не обнаружено» в 91 % случаев у мужчин и 97,5 % - у женщин. Совпадения при заключениях «пневмония» около 66 % у мужчин, 100 % совпадений у женщин, что говорит о хорошей чувствительности решающих модулей, входящих в автоматизированную систему.

Выводы. Для классификации флюорограмм грудной клетки предложен метод бустинга. Метод позволяет получить комбинированный классификатор, в состав которого входят два «слабых» классификатора и один «сильный» классификатор. В качестве первого «слабого» классификатора используется классификатор, построенный на дескрипторах, сформированных на основе метода Виолы-Джонса и двумерных функций Уолша, построенных в окне анализа. В качестве второго классификатора используется классификатор, построенный на дескрипторах, сформированных на основе примитив, аппроксимирующих гистограммы яркости в окне анализа. Дескрипторы «слабых» классификаторов не зависят от динамического диапазона яркости флюорограммы или различия динамических диапазонов яркости в окнах анализа. Апробация метода классификации проведена на флюорограммах грудной клетки (задняя прямая проекция) с различными рентгенологическими синдромами.

Таким образом, экспериментальные исследования метода и алгоритмов анализа изображений рентгеновских снимков грудной клетки позволяют рекомендовать их в клиническую практику.

Список литературы

1. Акимов А.В. Разработка и исследование алгоритмов распознавания изображений на основе метода Виолы-Джонса с использованием технологии вычислений на графических процессорах Cuda / А.В. Акимов, А.А. Сирота // Вестник ВГУ, Серия: системный анализ и информационные технологии, 2014, № 3. – С. 105-108.
2. Дюдин, М.В. Нейросетевые модели принятия решений для диагностики заболеваний легких на основе анализа флюорограмм грудной клетки / М.В. Дюдин, Р.А. Томакова, М.В. Томаков // Биомедицинская радиоэлектроника, 2014, №9. - С.12-16.
3. Дюдин, М.В. Способ выделения и классификации контуров легких на изображениях флюорограмм грудной клетки / М.В. Дюдин, С.А. Филист, П.С. Кудрявцев // Научные технологии. - 2014. - № 12, т. 15. - С. 25-30.
4. Томакова, Р.А. Нечеткие нейросетевые технологии для выделения сегментов с патологическими образованиями и морфологическими структурами на медицинских изображениях / Р.А. Томакова, А.А. Маслак, Н.А. Швецова // Биомедицинская радиоэлектроника. 2012. № 4. - С. 56-62.
5. Филист, С.А. Автоматические классификаторы сложно структурируемых изображений на основе мультиметодных технологий многокритериального выбора / С.А. Филист, М.В. Дюдин, И.В. Зуев, и др. // Вопросы радиоэлектроники. Серия «Системы и средства отображения информации и управления спецтехникой» (СОИУ), 2015. Выпуск 1. - С.130-140.
6. Филист, С.А. Универсальные сетевые модели для задач классификации биомедицинских данных/ С.А. Филист, Р.А. Томакова, Яа Зар До. // Известия ЮЗГУ. - Курск: Изд-во ЮЗГУ, 2012. – № 4 (43). – Ч. 2. – С. 44-50.

МЕТОД ПОСТРОЕНИЯ РЕШАЮЩЕГО МОДУЛЯ ДЛЯ ПРОГНОЗИРОВАНИЯ РИСКА СОЦИАЛЬНО ЗНАЧИМЫХ ЗАБОЛЕВАНИЙ

А.Г.Курочкин¹, А.Н. Шуткин², Е.С. Шкатова²

¹Юго-Западный государственный университет, кафедра биомедицинской инженерии, SFilist@gmail.com

²Воронежский институт государственной противопожарной службы, vigps@mail.ru

пособи Одна из методик прогнозирования социально значимых заболеваний, которая используется при профессиональном отборе по профессиям, которые сопряжены с воздействием стрессогенных или экстремальных факторов, включает в себя комплексное выполнение 7 тестов: «Шкала состояний», «Опросник для оценки острого физического утомления», «Опросник для оценки острого умственного утомления», «Шкала дифференциальных эмоций», «Шкала ситуативной тревожности», «Шкала личной тревожности», «Степень хронического утомления» [1]. В результате прохождения каждого теста конкретный испытуемый характеризуется определенным числом показателей (от одного до четырех), выраженных в баллах. Эти показатели представлены на шкалах, определяющих уровень функционального состояния испытуемого. Шкалы являются достаточно субъективными и не имеют теоретического обоснования. То же самое может быть сказано относительно агрегации этих шкал при принятии окончательного решения. Полагаем, что результаты тестов являются соответствующими суррогатными маркерами.

Метод построения решающего модуля включает следующую последовательность процедур.

1. Выделить группы наблюдения и социально значимое заболевание (например, травматизм - ω_1): формируются эталонные группы, подверженные риску заболевания ω_1 .

2. На реальных данных опросных анкет и тестов, направленных на изучение условий и образа жизни тестируемого, построить пространство информативных признаков, содержащее семь суррогатных маркеров: в каждой эталонной группе для каждого образца формируем семь векторов информативных признаков, компоненты которых определяет реакция данного образца на соответствующий опросник (тест) (схема формирования пространства информативных признаков представлена на рисунке 1).

3. Для каждого суррогатного маркера построить подмножество «слабых» классификаторов, число элементов которого соответствует числу сформированных эталонных групп риска патологии ω_1 :

$$\{X_j^i = P_i(\omega_1 | \hat{\alpha}_{ij})\}, \quad i = \overline{1, N}. \quad (1)$$

Процесс формирования «слабого» классификатора для теста «Шкала состояний» (вектор информативных признаков в этом тесте имеет одну компоненту) представлен на фигуре 5. На фигуре 5а показана гистограмма для теста «Шкала состояний» эталонной группы из ста пациентов, подверженных травматизму. На фигуре 5б показана гистограмма эталонной группы из ста пациентов не подверженных травматизму. На фигуре 5в показана дифференциальная гистограмма, полученная как результат вычитания из гистограммы подверженных травматизму гистограммы не подверженных травматизму. Эта дифференциальная гистограмма взята за основу построения «слабого» классификатора по суррогатному маркеру «Шкала состояний».




Рис.1. Структура формирования обучающих выборок для одной эталонной группы, состоящей из K1 здоровых и K2 больных пациентов для M суррогатных маркеров

4. Построить множество промежуточных «сильных» классификаторов для каждой экспериментальной группы

$$\{Y_i = F(\overline{X_j})\}, i = \overline{1, N}; j = \overline{1, M}; \quad (2)$$

связывающих подмножество M суррогатных маркеров (*Тест*) с моделируемой расчетной величиной (*Риск*).

5. Для каждой экспериментальной группы провести фильтрацию моделей с учетом экспертной оценки влияния выбранных информативных признаков на прогноз риска заболевания ω_1 .

6. Построить промежуточные «сильные» классификаторы путем агрегирования «слабых» классификаторов по суррогатным маркерам с учетом «фильтра» по эталонным группам

$$\{Z_j(\overline{Y})\}, j = \overline{1, M}. \quad (3)$$

7. Реализовать выходной слой модуля принятия решений в виде агрегатора: на выходе решающего модуля присутствует финальный (обобщенный) критерий риска травматизма $R = \left(\bar{Z} \left(\bar{Y} \left(\bar{X} \right) \right) \right)$.

В результате прохождения каждого теста конкретный испытуемый получает определенное число баллов, которые получены на шкале, характеризующей уровень функционального состояния испытуемого. Риск $P_i(\omega_1 | \text{Тест}_j)$ заболевания ω_1 , определяемый на основе прохождения j -го теста на эталонной группе i , может быть определен по формуле Байеса

$$P_i(\omega_1 | \text{Тест}_j) = \frac{P(\text{Тест}_j | \omega_1) \cdot P(\omega_1)}{P(\text{Тест}_j)}, \quad (4)$$

где $P(\text{Тест}_j | \omega_1)$ - условная вероятность события Тест_j при наличии заболевания ω_1 , $P(\omega_1)$ - априорная вероятность заболевания ω_1 , $P(\text{Тест}_j)$ - априорная вероятность события Тест_j .

Априорная вероятность $P(\omega_1)$ определяется из медицинских статистических данных по травматизму в исследуемом регионе. Вероятность $P(\text{Тест}_j)$ определяется как статистический показатель Тест_j по исследуемым выборкам больных и здоровых пациентов. Так как здоровых, в смысле не больных заболеванием ω_1 , значительно больше больных заболеванием ω_1 , то здесь можно использовать только результаты на выборке класса ω_2 , то есть на выборке класса «Здоров».

Для определения условной вероятности события Тест_j при свершившемся событии ω_1 (наличия травмы у обследуемого), необходимо протестировать эталонную группу пациентов, страдающих заболеванием ω_1 , посредством теста Тест_j . Примеры таких гистограмм для выборок «ЗДОРОВ» и «БОЛЕН» представлены на рисунке 2. Для получения конкретного значения априорной величины $P(\text{Тест}_j | \omega_1)$ строят гистограмму результатов тестирования Тест_j по выборкам «Болен ω_1 » (для теста «Шкала состояний» она приведена на рисунке 2а). «Слабый» классификатор для методики Тест_j получаем согласно уравнению (4). Выполняя отсчет по оси ординат априорно полученной гистограммы, определенный по результатам апостериорного тестирования, и нормируя его по величине $\frac{P(\omega_1)}{P(\text{Тест}_j)}$, получаем «слабый»

классификатор. На рисунке 3а показан график нормирующего коэффициента. При построении этого графика полагали, что априорная вероятность $P(\omega_1)=0,1$.

На рисунке 3б показаны графики «слабых» классификаторов, полученные на основе формулы (4) и графиков рисунке 2в и рисунке 3б для классов ω_1 - травматизм и ω_2 - здоров (результат: перемножение этих графиков).




Рис.2. Гистограммы по тесту «Шкала состояний» для эталонных групп класса «Здоров» и класса «Болен»

Для определения «сильного» классификатора риска R_{1j} заболевания ω_1 по j -му маркеру объединяют частные риски, полученные по всем «слабым» классификаторам, полученным на N эталонных группах по соответствующему тесту функционального состояния по правилу нечеткого «ИЛИ»:

$$R_{1j} = \max_{i=1, N} \{R_{1ij}\}. \quad (5)$$




Рис.3. Графики (функции принадлежности), иллюстрирующие формирование «слабого» классификатора с использованием критерия Байеса на примере прогнозирования травматизма

Финальный «сильный» классификатор получаем по правилу сложения вероятностей совместных событий

$$R_1(j+1)=R_1(j) + R_{1(j+1)}[1-R_1(j)], \quad (6)$$

где номер итерации $j = 1, 6$; $R_1(1)=R_{11}$.

Полученные экспериментальные результаты показали, что разработанный метод прогнозирования риска заболевания является универсальным инструментом. Решающие модули как «слабых», так и «сильных» классификаторов могут строиться на основе любой интеллектуальной платформы: нейронные сети, нечеткая логика и т.д. Эффективность метода слабо зависит от диагностической эффективности суррогатных маркеров или от «удачного» формирования экспериментальных выборок. В случае неудачного выбора этих компонентов исследователь должен перейти к новым выборкам или новым суррогатным маркерам.

Разработанные интеллектуальные технологии направлены на повышение качества медицинского обслуживания населения и могут быть использованы в системах скрининговой диагностике, автоматизированных системах профессионального отбора, профилактической медицине. На их основе могут быть построены системы, позволяющие пациенту самостоятельно осуществлять контроль за своим функциональным состоянием, в частности, вести объективный контроль за эффективностью лекарственных назначений.

Список литературы

1. Стрелков Ю.К. Инженерная и профессиональная психология: Учеб. е для студ. высш. учеб. заведений. - М.: Издательский центр «Академия»; Высшая школа, 2001. - 360 с.

МГУА-НЕЙРОННЫЕ СЕТИ ДЛЯ ПРОГНОЗИРОВАНИЯ СОСТОЯНИЯ СЛОЖНЫХ СИСТЕМ С ВРЕМЕННЫМИ ЛАГАМИ

А.О. Позин, Е.А. Старцев, В.В. Уварова

Юго-Западный государственный университет, кафедра биомедицинской инженерии,
SFilst@gmail.com

В [1] была предложена МГУА-нейронная сеть для построения моделей с ассоциативной памятью. Основной недостаток предложенного технического решения связан с тем, что количество нейронов первого слоя, определяемое как число сочетаний по две из

$$\lambda = M + \sum_{i=1}^M \ell_i \quad (1)$$

где M - число факторов, ℓ_i - глубина запаздывания для i -го фактора.

Следовательно, λ может значительно превосходить число векторов, предназначенных для обучения нейронной сети (объем обучающей выборки).

В теории систем существует определенный класс систем: системы с памятью. Математическая модель системы с памятью может быть описана с помощью уравнения вида

$$\frac{dY(t)}{dt} = F(X(t), t, Y(t - \tau(t))), \quad (2)$$

где X - вектор входных воздействий на систему, Y - вектор состояния системы, $\tau(t)$ - запаздывание в общем случае различное для каждой компоненты вектора Y .

Уравнение (2) формально относится к дифференциальным уравнениям первого порядка. На самом деле это дифференциальное уравнение бесконечно высокого порядка, так как вектор $Y(t - \tau)$ может быть представлен в виде ряда Тейлора

$$Y(t - \tau) = Y(t) - Y^{(1)}(t) \frac{\tau}{1!} + Y^{(2)}(t) \frac{\tau^2}{2!} + \dots (-1)^k Y^{(k)}(t) \frac{\tau^k}{k!} + \dots \quad (3)$$

Учитывая, что мы имеем дело с дискретизированным процессом, а в итоге должна быть построена прогностическая модель, уравнение (2) можно представить в виде

$$\Delta Y(\theta) = F(X(\theta - 1), X(\theta - 2) \dots X(\theta - L), \theta), \quad (4)$$

где L - вектор, компоненты которого определяют максимальную задержку соответствующей компоненты вектора X .

Уравнение (4) записано для случая $\Delta t = 1$. Размерность вектора X в общем случае больше размерности вектора Y . Это объясняется тем, что вектор X содержит некоторое число независимых факторов, которые относятся к экзогенным факторам. В этом контексте в правой части (4) остаются только факторы X , так как прогностическая модель строится с учетом того, что управляемый фактор в момент θ будет управляющим в момент $\theta + 1$. Экзогенный фактор останется управляющим в настоящем и в будущем, а для эндогенного фактора

$$Y(\theta) = X(\theta + 1). \quad (5)$$

Таким образом, в левой части (2) присутствуют только эндогенные факторы, а в правой части как эндогенные, так и экзогенные факторы. Компоненты вектора L определяют

максимальную задержку по соответствующей компоненте эндогенного фактора в векторе X .

В общем случае значение компонент вектора L определяются по результатам настройки модели. Используют модели, как с конечным числом лагов, так и с бесконечным числом лагов. Обычно сам исследуемый ряд достаточно короток и не превышает 15...20 элементов. Компоненты вектора L укорачивают его на величину, равную максимальной величине компоненты вектора L . Это усложняет настройку модели, поэтому из этих соображений длина компонент вектора L не превышает трех элементов (задержка не превышает трехгодичной величины).

При этих условиях уравнение (4) примет вид

$$\Delta Y(\theta) = F(X(\theta-1), X(\theta-2), X(\theta-3), \theta). \quad (6)$$

В моделях (4) и (6) отсутствует краткосрочный мультипликатор, так как полагаем, что эффект от управляющего воздействия на шаге θ будет известен только на шаге $\theta+1$. Модель с учетом лагов строилась согласно схеме, представленной на рисунке 1. Она состоит из трех независимых слоев.




Рис.1. Структурная схема динамической модели на основе МГУА – нейронных сетей

Первый слой формирует множество моделей $\hat{Y}$. Для каждого эндогенного фактора посредством МГУА - моделирования получено свое подмножество моделей $\{Z_j\}_i \subseteq Z, \forall i = \overline{1, M}$. Каждое подмножество моделей $\{Z_j\}_i, j = 1...K_i$, где K_i – число МГУ – моделей для i -го фактора, полученных на основе МГУА-моделирования, которые

предполагается использовать для описания взаимного влияния эндогенных факторов в системе простых комбинаций эндогенных и экзогенных факторов. Множество статических моделей $\hat{Y}$ получается не посредством усложнения МГУА-моделей, а посредством МГУА-нейронной сети [1]. Отличие предлагаемой МГУА-нейронной сети от рассмотренной в [1] состоит в том, что каждый блок нелинейной статической модели первого слоя является МГУА-нейронной сетью, на входы которой поступают полученные путем МГУА-моделирования модели, включающие множество X эндогенных и экзогенных факторов. Структурная схема i -го блока нелинейного статического моделирования первого слоя представлена на рисунке 2.




Рис.2. Структурная схема i -й нелинейной статической модели первого слоя динамической модели на основе МГУА – моделирования

В качестве примера в ней использованы четыре МГУА - модели эндогенного фактора x_i : Z_1, Z_2, Z_3, Z_4 с нелинейными адалинами (N-A).

МГУА – нейронная сеть имеет переменную структуру, которая может изменяться в процессе обучения. Каждый нейрон сети – N-адалин представляет собой адаптивный

линейный ассоциатор с двумя входами и нелинейным процессором, образованным тремя блоками умножения, и вычисляет квадратичную комбинацию входов вида

$$\hat{y}_{gh} = f_{gh}(z_g, z_h) = w_{gh_0} + w_{gh_1} z_g + w_{gh_2} z_g^2 + w_{gh_3} z_g z_h + w_{gh_4} z_h^2 + w_{gh_5} z_h = w_{gh}^T z_{gh}, \quad (7)$$

где $w_{gh} = (w_{gh_0}, w_{gh_1}, w_{gh_2}, w_{gh_3}, w_{gh_4}, w_{gh_5})^T$, $z_{gh} = (1, z_g, z_g^2, z_g z_h, z_h^2, z_h)^T$.

Процесс обучения нелинейной статической модели первого слоя состоит в конфигурации нейронных сетей (рисунок 2), начиная с первого скрытого слоя, независимой настройке синаптических весов каждой нелинейной адалины и наращивании количества слоев для достижения необходимой точности прогнозирования. Количество нейронов первого скрытого слоя сети определяется количеством МГУА – моделей K соответствующего эндогенного фактора и не превышает значение $K(K-2)/2$ – количества сочетаний из K по 2.

После обучения нейронной сети посредством любого из известных алгоритмов обучение [2] оценивается точность моделирования, например, с помощью дисперсии ошибки предсказания для каждого нейрона и формируется группа нейронов, дающих ошибку ниже некоторого априорно заданного порога. Именно выходы этой группы $\hat{y}_i^{[1]}$ являются входами второго скрытого слоя.

Далее с помощью того же обучающего сигнала Z_j , $j=1,2,...,K$ настраиваются нейроны второго слоя при «замороженных» синаптических весах первого слоя и опять формируется группа, характеризующаяся наилучшей точностью. Процесс наращивания слоев и настройки синаптических весов продолжается до достижения хотя бы одним нейроном очередного слоя требуемой точности. Наилучшие нейроны последнего слоя полагаются выходным нейроном сети в целом.

Второй слой – линейная динамическая модель. Для моделирования таких ситуаций достаточно гибким инструментом является аппарат распределенных лагов Алмон.

Формальным представлением запаздываний во взаимодействии факторов, определяющих состояние сложной системы, является линейная модель

$$y_t = a_0 + b_{01}x_{1t} + b_{11}x_{1(t-1)} + b_{21}x_{1(t-2)} + b_{31}x_{1(t-3)} + b_{12}x_{2(t-1)} + b_{22}x_{2(t-2)} + b_{32}x_{2(t-3)} + ... + b_{1M}x_{M(t-1)} + b_{2M}x_{M(t-2)} + b_{3M}x_{M(t-3)} + \varepsilon(t), \quad (8)$$

где $\varepsilon(t)$ – случайная величина.

Уравнение (8) записано в предположении, что имеется только один экзогенный фактор x_1 , для которого существует краткосрочный мультипликатор, все остальные $M-1$ факторов – эндогенные и не имеют краткосрочного мультипликатора.

Модель Алмон строится в предположении, что значения коэффициентов b_j могут быть аппроксимированы полиномами соответствующей степени от величины лага j , т.е.

$$b_j = c_0 + c_1 j + c_2 j^2 + ... + c_k j^k. \quad (9)$$

Если ввести новые переменные

$$z_0 = \sum_{j=0}^L x_{t-j}, z_1 = \sum_{j=1}^L x_{t-j}, z_2 = \sum_{j=1}^L j^2 x_{t-j}, ..., z_k = \sum_{j=1}^L j^k x_{t-j}, \quad (10)$$

то модель с распределёнными лагами (8) может быть представлена в виде регрессионной модели

$$y_t = a_0 + c_0 z_0 + c_1 z_1 + c_2 z_2 + \dots + c_k z_k + \varepsilon_1, \quad (11)$$

коэффициенты которой можно определить с помощью метода наименьших квадратов (МНК).

Известно, что ошибки при определении величин $z_0, z_1, z_2 \dots z_k$ приводят к построению неадекватных моделей. Причем, если установленный лаг L меньше реального, то это приводит к неверной сертификации модели, так как эта ситуация равноценна тому, что в регрессионной модели учтены не все факторы и, следовательно, остатки будут коррелировать с зависимой переменной. Это значит, что не соблюдается предпосылка МНК о случайности остатков. Невыполнение этого условия приводит к получению смещенных и неэффективных оценок регрессионных коэффициентов.

В тех же случаях, когда L превосходит реальную величину, возникает ситуация, аналогичная включению в модель статистически незначимого фактора. Нежелательный эффект от такой ошибки заключается в снижении эффективности получаемых с помощью МНК оценок. Но всё же в этом случае оценки несмещённые и поэтому ошибка с завышением величины лага приводит к меньшим искажениям, чем оценка с заниженной его величиной.

В третьем слое модели (рисунок 1) строятся динамические нелинейные модели эндогенных факторов, которые представляются посредством вектора Y . Число моделей в слое определяется числом эндогенных факторов M . Экзогенные факторы, среди которых находятся управляемые, представлены вектором $\tilde{X}$ и тоже подаются на вход блоков нелинейного динамического моделирования третьего слоя. Таким образом, на входах решаемых диагностических моделей третьего слоя присутствуют динамические модели $3M$ эндогенных факторов (при $L=3$) и вектор $\tilde{X}$ экзогенных факторов, который имеет размерность $3Q$, где Q -число экзогенных факторов.

Для построения исследуемой динамической модели воспользуемся методикой, представленной в [3]. Структура самой исследуемой динамической модели представлена на рисунке 3.

Учитывая, что настройка каждого слоя идёт автономно (метод «замирания»), на вход блока моделирования третьего слоя поступает одинаковые векторы (при условии, что интервал прогноза одинаков для всех M компонентов вектора Y). Входной вектор состоит из двух составляющих. Составляющая, определяющая эндогенные факторы ($\hat{Y}$), определяется во втором слое. Составляющая, определяющая экзогенные факторы ($\tilde{X}$), задаётся или планируется самими ЛПР. В частном случае вектор $\tilde{X}$ может иметь только одну компоненту.

Таким образом, максимальная размерность входного вектора определяется как $3M+3Q$ при условии, что $L=3$. В таком случае, максимальное число нейронов в первом скрытом слое определяется как число сочетаний по 2 из $3M+3Q$. Структура МГУА - сети рисунок 3 меняется в процессе обучения, аналогично сети, представленной на рисунке 2. Нейроны сети, описываются уравнение (7).




Рис.3. Структурная схема i -го блока нелинейного динамического моделирования третьего слоя

Также, как и в сети рисунок 2, производится независимая настройка скрытых слоёв МГУА – нейронов сети и наращивание слоев нейронной сети для достижения более точного прогнозирования. При этом в каждом слое остаются только те нейроны, которые соответствуют модели, удовлетворяющей пороговой точности.

Список литературы

1. Мантула, Е.В. Прогнозирующие МГУА-полиномиальные модели в задачах экологического мониторинга / Е.В. Мантула, Е.С. Саколо // Збірник наукових праць Харківського університету Повітряних Сил. – 2013. - Випуск 2(35). – С.114-116.
2. Осовский, С. Нейронные сети для обработки информации / С. Осовский, пер. с польского под ред. И.Д. Рудинского. М.: Финансы и статистика, 2002. - 344 с.
3. Прасолов, А.В. Динамические модели с запаздыванием и их приложения в экономике и инженерии / А.В. Прасолов, 2010. – 192 с.

ОБРАБОТКА ДАННЫХ НА ОСНОВЕ АЛГОРИТМА RANDOM FOREST ДЛЯ ПРОГНОЗИРОВАНИЯ ЗАВИСИМОСТИ «СТРУКТУРА- АКТИВНОСТЬ» ЛЕКАРСТВЕННЫХ СОЕДИНЕНИЙ⁴

Г.А. Самигулина¹, З.И. Самигулина²

¹Институт информационных и вычислительных технологий,
Лаб. «Интеллектуальные системы управления и прогнозирования»,
galinasamigulina@mail.ru

²Казахский национальный технический исследовательский университет,
Институт информационных и телекоммуникационных технологий,
каф. «Автоматизация и управление», *zarinasamigulina@mail.ru*

В настоящее время одной из важнейших задач хемоинформатики является разработка современных интеллектуальных методов обработки химической структурной информации при компьютерном молекулярном дизайне новых лекарственных веществ. В мире наблюдается экспоненциальный рост потребности в новых соединениях в фармацевтической промышленности, растет и объем экспериментальных данных по физико-химическим свойствам и биологической активности различных органических веществ. Накоплено свыше 60 млн. структур химических соединений [1].

В связи с этим актуально применение современных методов в области искусственного интеллекта (ИИ) для решения задач прогнозирования зависимости «структура-активность» химических соединений (Quantitative Structure-Activity Relationship, QSAR,) и обработки больших массивов данных. Применение методов, таких как: нейронные сети, генетические алгоритмы, искусственные иммунные системы, роевой интеллект и др. позволяет существенно сократить временные и финансовые ресурсы при создании новых лекарственных соединений. Хорошо зарекомендовал себя алгоритм случайного леса (Random Forest, RF), впервые предложенный Лео Брейманом, который может применяться, как для решения задачи классификации, так и для определения оценки важности переменных при обработке больших массивов химической структурной информации [6-8]. Наряду с биологическими подходами ИИ для решения проблемы выделения информативных дескрипторов, характеризующих химическое вещество, широко применяются и статистические подходы, такие как: факторный анализ (Factor Analysis, FA) [9], метод опорных векторов (Support Vector Machine, SVM) [10], а так же алгоритмы на основе сингулярного разложения матриц (Singular value decomposition, SVD). Комбинирование различных методов искусственного интеллекта и статистического анализа является перспективным направлением при работе с большими массивами данными.

Постановка задачи формулируется следующим образом: необходимо решить задачу выделения информативных дескрипторов на основе алгоритма Random Forest, описывающих химические соединения (сульфаниламиды) для построения оптимальной иммунносетевой модели.

Для решения поставленной задачи рассмотрим группу противомикробных препаратов сульфаниламидной группы. Данные вещества относятся к средствам широкого антибактериального спектра действия. В настоящее время открыто и изучено

⁴Исследования проводятся по гранту КН МОН РК №ГР 0115РК00549 МОН РК по теме: Компьютерный молекулярный дизайн лекарственных препаратов на основе иммунносетевого моделирования (2015-2017 гг.).

более 6000 производных данной группы, однако практическое применение находят около 20 препаратов. В настоящее время сульфаниламиды часто используются при проведении исследований в области QSAR для поиска новых лекарственных соединений [11].

При описании свойств сульфаниламидов применяется дескрипторный подход. Информация о сульфаниламидах собрана на основе одной из самых больших баз данных химических веществ Mol-Instincts, которая содержит более 2.85 млн. химических веществ, 2100 наборов данных по компонентам и в общей сложности более 10 миллиардов наборов данных химической информации. Поиск в базе данных может быть осуществлен по следующим категориям: химической формуле, кодировке IUPAC (International Union of pure and Applied Chemistry), спецификации упрощенного представления молекул SMILES (Simplified Molecular Input Line Entry Specification), с помощью международного химического идентификатора InChI (International Chemical Identifier) и т.д. База данных Mol-Instincts представляет сведения по разделам: константы, описывающие органические соединения (дипольный момент, энтропия, нормальная точка кипения и т.д.), температурная зависимость (плотность жидкости, давление пара и т.д.), молекулярные дескрипторы (топологические дескрипторы, квантово-химические, электростатические и др.), квантовую информацию (число электронов, молекулярные орбитали и т.д.), медицинскую информацию (липофильность, гидрофобность и т.д.), спектральная информация (ядерно-магнитный резонанс, инфракрасный спектр и т.д.), анализ данных (3-D оптимизированная геометрия, длина связей, угол и т.д.). Данные ресурса Mol-Instincts хранятся в формате .csv (Comma-Separated Values), который легко конвертируются в другие форматы, например .arff позволяющий работать с мощным инструментом Data Mining, WEKA (Waikato Environment for Knowledge Analysis), который содержит в себе инструменты для предварительной обработки данных, кластеризации, классификации, отбора наиболее информативных признаков и визуализации данных.

В качестве метода выбора информативных дескрипторов сульфаниламидов для построения иммунносетевой модели рассмотрим алгоритм Random Forest [12,13], реализованный в программном обеспечении WEKA. В программном обеспечении WEKA данные представляются в виде матрицы объектов признаков [14]. В нашем случае в качестве признаков рассматриваются дескрипторы сульфаниламидов. Пусть X - множество объектов, тогда дескриптор является отображением $f: X \rightarrow D_f$, где D_f - множество допустимых значений дескриптора. В случае если имеется набор дескрипторов $f_1, \dots, f_n$, тогда вектор $(f_1(x), \dots, f_n(x))$ называется дескрипторным описанием объекта $x \in X$, для машинного обучения полагается, что $X = D_{f_1}(x), \dots, D_{f_n}(x)$ [14-15].

Матрица объектов признаков сформируется в следующем виде:

$$F = (f_j(x_i))_{l \times n} = \begin{Bmatrix} f_1(x_1) & \dots & f_n(x_1) \\ \vdots & & \vdots \\ f_1(x_l) & \dots & f_n(x_l) \end{Bmatrix} \quad (1)$$

где строки матрицы - это значения дескрипторов для различных соединений, столбцы - наименования дескрипторов.

Рассмотрим алгоритм Random Forest для решения задачи отбора информативных дескрипторов, описывающих сульфаниламиды. Метод основан на построении ансамбля деревьев решений. Введем следующие определения [8,16]: $T_i(x)$, $i=1..B$ - это ансамбль деревьев решений, где x - вектор дескрипторов размерности N , B - количество деревьев в ансамбле; $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ - обучающая выборка данных, где y_n - класс.

Далее из исходной выборки данных выбирается n случайных объектов с повторениями (bootstrap sample), принимающее значение D_i . Затем строится дерево решений для D_i (полное построение без отсечения ветвей) с повтором алгоритма B раз. Мера информативности дескрипторов, основанная на алгоритме Random Forest находится по следующему алгоритму.

Алгоритм.

1. Пусть x_i - некоторый дескриптор. Необходимо построить случайный лес и получить оценку вероятности ошибочной классификации E_i методом Out-Of-Bag, предложенным Брейманом на основе наблюдений, не входящих в bootstrap выборки. Данные выборки называются выборками Out-Of-Bag.

2. В выборках Out-Of-Bag осуществить случайную перестановку значений дескриптора x_i для каждого дерева из построенного случайного леса.

3. По модифицированным Out-Of-Bag определяется оценка вероятности ошибочной классификации $\hat{E}_i$.

4. Определение информативности дескриптора x_i реализуется как значение разницы: $I(x_i) = \max(0, \hat{E}_i - E_i)$.

Псевдокод алгоритма Random Forest представлен ниже:

Input: dataset tree $T_i(x)$, number of trees B , number of random features f

Output: D_i , a set of grown trees

Initialize D_i

For $i = 1$ to B do

$T_i \leftarrow \text{bootstrap}(T_i)$

$T_i \leftarrow \text{train } DT(T_i, f)$

add T_i to D_i

end for

Пример. Рассмотрим пример выделения информативных дескрипторов на основе алгоритма Random Forest. Обработка данных осуществляется с помощью программного обеспечения WEKA.

Разработана база данных дескрипторов сульфаниламидов, состоящая в общей сложности из 30 075 экземпляров. Сульфаниламиды разделены на 3 класса по продолжительности действия: короткой, менее 10 ч (sulfadiazine, sulfadimidine, sulfamethizole, sulfamethoxazole и т.д.); средней, 10-24 ч (sulfacetamide, sulfadoxine, sulfamoxole, sulfamethoxazole и т.д.); длительной продолжительности действия, 24-48 ч (sulfalene, sulfafenazole, sulfadimethoxine, sulfaperin и т.д.).

Каждое из представленных химических веществ описывается 2005 молекулярными дескрипторами. Особый интерес для исследований представляют сульфаниламиды с длительной продолжительностью действия. В качестве примера для удобства расчетов сформируем фрагмент базы данных сульфаниламидов размерности $(n \times m)$, $n = 1, \dots, 15$, $m = 1, \dots, 100$, где n – химическое вещество, m – дескриптор (Таблица 1). Всего выбранный фрагмент содержит 1500 экземпляров данных. В Таблице 1 представлены следующие молекулярные дескрипторы: Mass (молекулярная масса вещества); PI (isoelectric point, изоэлектрическая точка); logP, logD (липофильность и гидрофобность); M_p (Molecular polarizability, молекулярная поляризуемость); P_s (polar surface area, полярная площадь поверхности, дескриптор для оценки транспортных свойств препаратов); PI_l (Platt index, индекс Платта) R_l (Randic index, индекс Рандича); B_l (Balaban index, индекс Балабана) и т.д.

Таблица 1

Фрагмент базы данных дескрипторов сульфаниламидов

№	Вещество	Mass	pI	logP	logD	Mp	Ps	PII	RI	...	BI
		1	2	3	4	5	6	7	8	...	100
1	C ₉ H ₉ N ₃ O ₂ S ₂	255.31	4.48	0.88	-2.44	24.19	85.08	48	7.58	...	1.63
2	C ₁₂ H ₁₄ N ₄ O ₂ S	278.33	4.51	0.43	-3.08	28.10	97.97	58	8.87	...	1.70
3	C ₁₁ H ₁₂ N ₄ O ₃ S	280.30	4.43	0.47	-2.94	27.15	107.20	56	9.01	...	1.62
4	C ₁₂ H ₁₄ N ₄ O ₂ S	278.33	5.56	0.91	-3.09	28.10	97.97	58	8.87	...	1.70
5	C ₁₁ H ₁₂ N ₄ O ₂ S	264.30	4.50	0.52	-2.94	26.35	97.97	54	8.47	...	1.76
6	C ₁₀ H ₁₀ N ₄ O ₂ S	250.27	4.50	0.39	-2.62	24.59	97.97	50	8.08	...	1.84
7	C ₁₄ H ₁₂ N ₄ O ₂ S	300.33	4.46	1.55	-3.60	32.05	97.97	66	10.0	...	1.33
8	C ₁₁ H ₁₂ N ₄ O ₃ S	280.30	4.88	0.74	-2.91	27.14	107.20	56	9.01	...	1.67
...	...	...	...	...	...	...	...	...	...	...	...
15	C ₁₂ H ₁₄ N ₄ O ₄ S	310.32	4.43	1.26	-3.05	29.70	116.43	62	9.94	...	1.83

На Рис.1. представлен фрагмент выборки дескрипторов сульфаниламидов в программном обеспечении WEKA.




Рис.1. Визуализации дескрипторов сульфаниламидов в программном

обеспечении WEKA.

После обработки данных с помощью алгоритма Random Forest выбрано два информативных дескриптора, содержащих 200 экземпляров данных. Результаты моделирования представлены на Рис.2.




Рис.2. Визуализация информативных дескрипторов сульфаниламидов после обработки с помощью алгоритма Random Forest.

Представленный алгоритм Random Forest позволяет ранжировать данные по степени важности и выбрать информативные дескрипторы. По результатам моделирования примера из 1500 экземпляров молекулярных дескрипторов было выбрано 200.

Таким образом, достоинствами применения метода Random Forest является способность обрабатывать данные с большим количеством атрибутов и экземпляров, нечувствительность к масштабированию, наличие инструментов оценки степени важности переменных, способность к обобщению и т.д. В качестве недостатков можно указать возможность переобучения для некоторого рода задач и большой размер полученных моделей, в связи с чем возникают особые требования к вычислительным ресурсам.

Список литературы

1. Blum L. and Reymond J. 970 million drug like small molecules for virtual screening in the chemical universe database GDB -13 //Journal of American Chemical Society. - 2009. - Vol. 131(25). - P. 8732-8733.
2. Ivanciuc O. Drug Design with Artificial Intelligence Methods //Encyclopedia of Complexity and Systems Science. - 2009. - P. 2113-2139.
3. Montañez-Godínez N., Martínez-Olguín A.C., Deeb O., Garduño-Juárez R., Ramírez-Galicia G. QSAR/QSPR as an Application of Artificial Neural Networks //Artificial Neural Networks. - 2014. - №1260. - P. 319-333.
4. Sukumar N., Prabhu G., Saha P. Applications of Genetic Algorithms in QSAR/QSPR Modeling //Applications of Metaheuristics in Process Engineering. - 2014. P. 315-324.
5. Khajeh Aboozar, Modarress Hamid, Zeinoddini-Meymand Zeinoddini-Meymand. Modified particle swarm optimization method for variable selection in QSAR/QSPR studies // Structural Chemistry. - 2013. - Vol. 24. - №5. - P. 1401- 1409.
6. Gene M. Ko, A. Srinivas Reddy, Sunil Kumar, Barbara A. Bailey and Rajni Garg //A Random Forest Model for the Analysis of Chemical Descriptors for the Elucidation of HIV1 Protease Protein Ligand Interactions //Access Proceedings. - 2010. - P. 1- 6.
7. Ana Teixeira¹, João Leal and Andre Falcao¹. Random forests for feature selection in QSPR Models - an application for predicting standard enthalpy of formation of hydrocarbons // Journal of Cheminformatics. - 2013. - Vol. 5. - №9. - P. 1-15.
8. Чистяков С.П. Случайные леса: Обзор //Труды Карельского научного центра РАН. - 2013. - №1. - С. 117-136.
9. Shahlaie M., Fassihi A., Pourhossein, A., Arkan E. Statistically validated QSAR study of some antagonists of the human CCR5 receptor using least square support vector machine based on the genetic algorithm and factor analysis // Journal of Medicinal Chemistry Research. - 2013. - vol. 22. - №3. - P. 1399-1414.
10. Zhou X.B., Han W.J., Chen J. and Lu X.Q. QSAR study on the interactions between antibiotic compounds and DNA by a hybrid genetic-based support vector machine // Monatshefte für Chemie - Chemical Monthly. -2011. - Vol. 142. - №9. -P. 949-959.
11. Sharma B.K., Pilana P., Sarbhai K., Singh P., Prabhakar S.Y. Chemometric descriptors in modeling the carbonic anhydrase inhibition activity of sulfonamide and sulfamate derivatives // Molecular Diversity. - 2010. - №2. - P. 371-384.
12. Samigulina G. A., Samigulina Z. I., Wójcik W., Krak U.V. Structure-property dependence prediction of new organic compounds based on artificial immune systems //Control and Informatics. - 2015. - №2. - P. 81-88, 2015.
13. Samigulina G.A., Samigulina Z.I., Computational molecular design of sulfonamides based on immune network modeling //Twelve International Conference on Electronics Computer and Computation (ICECCO). - 2015. - P. 1-5.
14. Айвазян С.А., Енюков И.С., Мешалкин Л.Д. Прикладная статистика: основы моделирования и первичная обработка данных. -М.: Финансы и статистика, 1983. — 471 с.
15. Журавлев Ю.И., Рязанов В.В., Сенько О.В. Распознавание. Математические методы. Программная система. Практические применения. - М.: Фазис, 2006.
16. Самигулина Г.А., Самигулина З.И. Построение оптимальной иммуносетевой модели для компьютерного молекулярного дизайна сульфаниламидов на основе алгоритма Random Forest //Вестник ХПИ. - 2016. - №21(1193). - С. 102-109.

ОБРАБОТКА МНОГОМЕРНЫХ ДАННЫХ В SMART-СИСТЕМЕ ДИСТАНЦИОННОГО ОБУЧЕНИЯ ЛЮДЕЙ С НАРУШЕНИЯМИ ЗРЕНИЯ НА ОСНОВЕ КОГНИТИВНОГО ПОДХОДА И ФАКТОРНОГО АНАЛИЗА

Г.А. Самигулина¹, А.С. Шаяхметова²

¹Институт информационных и вычислительных технологий КН МОН РК
galinasamigulina@mail.ru

²Казахский национальный исследовательский технический
университет им. К.И. Сатпаева
asemshayakhmetova@mail.ru

В современном мире растет необходимость создания гибкой системы обучения. На ряду с традиционным обучением стремительно развивается дистанционное обучение (ДО), в котором особое внимание уделяется повышению эффективности учебного процесса, развитию личностного потенциала обучающегося. Данное обучение дает равные возможности всем людям независимо от социального положения, обеспечивает индивидуальный подход к каждому обучающемуся, снимает пространственные ограничения, может наиболее адекватно и гибко реагировать на потребности обучающихся. Особенно решение этих проблем важно при организации доступной среды и ДО людей с ограниченными возможностями, в том числе с дефектами зрения [1, 2].

Для выявления интеллектуальных и психофизиологических особенностей у обучающихся с различными заболеваниями зрения актуально использование когнитивного подхода. Процесс познания личности является деятельностью связанной с когнитивными способностями [3]. Новые методы и подходы при построении адаптивных систем ДО с применением интеллектуальных технологий на основе когнитивной модели обучающегося предложены в работе [4]. При разработке адаптивной обучающей среды с учетом индивидуальных особенностей обучающихся рассматриваются следующие параметры: внимание, стратегия мышления, стили обучения, создание комфортной среды обучения и др. В когнитивном подходе обучающийся [5] считается активным участником процесса обучения. Одним из путей развития когнитивных функций обучаемых в процессе ДО являются компьютерные когнитивные тренинги [6]. Они стимулируют обучающихся к успешному выполнению определенных учебных задач курса и выявляют их интеллектуальные способности и индивидуальные особенности.

В развитии интеллектуальных систем ДО хорошего результата можно достичь путем комбинации различных статистических и интеллектуальных методов. В данной работе для выделения информативных признаков, характеризующих каждого обучающегося использовался факторный анализ [7] на основе метода главных компонент (РСА). Это эффективный метод уменьшения размерности признакового пространства при сохранении максимума полезной информации. В статье [8] предлагается использование метода главных компонент для обработки многомерных результатов рейтинговой оценки обучающихся. Широко используются гибридные системы. Например, в исследовании [9] предложенная система базируется на использовании нейронной сети и метода главных компонент.

Постановка задачи. Постановка задачи формулируется следующим образом: необходимо решить задачу выделения информативных признаков для людей с ограниченными возможностями зрения (ЛОВЗ) на основе когнитивного подхода и с использованием факторного анализа (метода главных компонент) для построения модели обучающегося.


Решение данной задачи позволит создать ЛОВЗ благоприятные условия и получить качественное ДО, которое помогает социальной адаптации в обществе данной категории людей [10]. Обучающиеся проходят анкетирование, которое построено на основе когнитивного подхода с использованием теста интеллекта Р. Амтхауэра и теста вербального интеллекта Г. Айзенга [11]. Анкетирование обучающихся способствует выявлению интеллектуальных, физиологических и психофизиологических особенностей восприятия и осознания информации ЛОВЗ. Успешность обучения во многом зависит от учета психофизиологических особенностей восприятия информации обучающимися при различных дефектах зрения. Обучающиеся по характеру заболеваний и по степени нарушений основных зрительных функций воспринимают и осознают полученную информацию по-разному. Они влияют на психофизиологические особенности ЛОВЗ при обучении. Разработанная система адаптирована на обучающихся с дефектами зрения (миопия, гиперметропия) и с остаточным зрением. Предложенная система имеет ряд достоинств:


- предусмотрено озвучивание текста. Оно позволяет обучающимся прослушивать информацию с экрана монитора не напрягая зрение. Для лиц с частичной потерей зрения это является необходимым инструментом, так как возрастает нагрузка на слуховой аппарат;

- учитываются подача и наилучшее расположение информации на экране монитора в зависимости от заболевания зрения. К примеру, при миопии хорошо воспринимается информация расположенная в левой части экрана. Обучающемуся с гиперметропии предпочтительнее информация расположенная в правом нижнем углу экрана;

- имеется возможность выбора цветовых схем. Не менее важно при создании систем ДО ЛОВЗ является цвета представление информации (Таблица 1). Цвет оказывает большое влияние на психофизиологические состояния организма человека. При подборе цвета нужно знать влияние цвета на психику ЛОВЗ и на их восприятие информации. Цвет влияет на физиологические системы человека повышая или уменьшая их учебную деятельность [12].

Таблица 1. Цвето-схемы для людей с различными дефектами зрения

Цвет шрифта	Цвет фона	Длина волны (нм)	Дефекты зрения
1	2	3	4
Черный	 Блелно-	580-550	При миопии
Черный	 Ярко-	640-590	При гиперметропии

1	2	3	4
Белый	 Черный	полное отсутствие цвета	При остаточном зрении
Черный	 Белый	состоит из всех цветов	При обычном зрении

Из полученных результатов анкетирования строится вектор параметров характеризующие признаки ЛОВЗ, который обрабатывается в статистическом пакете прикладных программ SPSS на основе факторного анализа метода главных компонент.

Рассмотрим следующий пример. Берем группу обучающихся ЛОВЗ из 10 человек. Составляем матрицу исходных данных $A=(a_{ij})$ размерности (10×10) (Таблица 2). База данных признаков ЛОВЗ состоит из следующих характеристик: возраст, состояние здоровье по дефекту зрения, острота зрения, логическое мышление, познавательная деятельность, психологический, волевой потенциал, физиологический потенциал, мотивационный потенциал, техника чтения и восприятия информации. Необходимо осуществить редукцию малоинформативных признаков для каждого обучающегося.

Приведем алгоритм решения данной задачи:

Шаг 1. Исходную матрицу данных A_{ij} заносим в SPSS.

Таблица 2. Исходная матрица данных A_{ij}

№	ФИО	Возраст	Состояние здоровья по	Острота зрения	Логическое мышление	Познавательная деятельность	Психологический, волевой потенциал	Физиологический потенциал	Мотивационный	Техника чтения	Восприятие информации
1	Омарова К.М.	25	3,00	6,00	2,00	15	6	6	12	250	3
2	Ерболова Р.Е.	17	3,00	6,00	2,00	12	2	2	10	230	2
3	Мусина А.К.	30	2,00	1,00	1,00	11	4	5	11	180	1
4	Султангазина Н.	21	1,00	2,00	2,00	9	6	4	9	190	3
5	Жунусова Г.А.	23	2,00	1,00	1,00	14	2	3	8	156	2
6	Аукаримов Н.Д.	19	3,00	6,00	2,00	13	4	2	12	89	1
7	Нурпеисова С.И.	20	1,00	2,00	1,00	10	6	6	11	130	3
8	Жантасов Д.Т.	25	1,00	3,00	1,00	7	2	4	10	40	2
9	Жетенова Ж.С.	18	2,00	4,00	2,00	8	4	5	7	156	1
10	Чингисов Х.Б.	22	3,00	5,00	2,00	12	6	3	9	180	3

Шаг 2. Из исходной матрицы $A=(a_{ij})$ получаем матрицу стандартизированных данных $B=(b_{ij})$ размерности (10×10) .

Шаг 3. Определяются коэффициенты корреляции между переменными.

Шаг 4. Вычисляются собственные числа корреляционной матрицы (Таблица 3), рассчитывается процент дисперсии и вычисляется накопленный процент.

Таблица 3. Выделение главных компонент и распределение соответствующих дисперсий

Собственные числа	% объясненной дисперсии	Накопленный %
3,422	34,219	34,219
2,271	22,715	56,934
1,615	16,155	73,088
1,001	10,010	83,098
0,710	7,103	90,201
0,353	3,534	93,736
0,318	3,184	96,920
0,238	2,377	99,297
0,070	0,703	100,00
9,859	9,859	100,00

Шаг 5. Вращение факторов на основе варимаксного подхода.

Шаг 6. Формируется матрица факторных нагрузок F (Таблица 4), где строки соответствуют информативным признакам, а столбцы выделенным факторам. Признаки лежащие ближе к началу координат являются малоинформативными, поэтому не рассматриваются.

Таблица 4. Матрица факторных нагрузок

№	Признаки обучающихся	Фактор 1	Фактор 2	Фактор 3	Фактор 4
1	Возраст	-0,42	0,42	0,64	-0,13
2	Состояние здоровье по дефекту зрения	0,21	0,79	-0,34	0,21
3	Острота зрения	0,12	0,67	-0,36	-0,04
4	Познавательная деятельность	0,64	0,22	0,54	-0,27
5	Физиологический потенциал	-0,39	0,74	-0,08	0,07
6	Техника Чтения	0,57	0,46	-0,04	-0,56

Шаг 7. Анализируются результаты Таблицы 4 и выделяются 3 фактора: эмоциональная устойчивость, высокий интеллектуальный потенциал обучающегося, усвоение информации с учетом особенности зрения и мотивация. Четвертый фактор не поддается к интерпретации, поэтому отбрасываем.

Шаг 8. В результате представляется матрица факторных весов (Таблица 5), из которой видно, что хороший интеллектуальный потенциал у Нурпеисовой С.И., усвоение информации с учетом особенности зрения у Султангазиной Н. и Аукаримова Н.Д., высокая мотивация у Ерболовой Р.Е., Мусиной А.К. и у Жантасова Д.Т.

Таблица 5. Матрица факторных весов

ФИО	Фактор 1: Интеллектуальный потенциал обучающегося	Фактор 2: Усвоение информации с учетом особенности зрения	Фактор 3: Мотивация
Омарова К.М.	-0,82	0,16	0,06
Ерболова Р.Е.	0,14	0,04	0,88
Мусина А.К.	0,04	0,10	0,76
Султангазина Н.О.	0,02	0,87	-0,02
Жунусова Г.А.	-0,45	-0,17	0,68
Аукаримов Н.Д.	0,11	0,78	0,42
Нурпеисова С.И.	0,72	0,66	0,04
Жантасов Д.Т.	-0,32	0,22	0,89
Жетенова Ж.С.	-0,52	0,43	-0,44
Чингисов Х.Б.	0,31	-0,56	0,06

На основании полученных результатов выбирается соответствующая траектория обучения и режим подачи учебного материала с учетом особенностей каждого ЛОВЗ с целью повышения качества и эффективности обучения.

Таким образом, проведенные исследования и многочисленные публикации по данной тематике доказывают актуальность разработки Smart-систем ДО на основе современных инновационных интеллектуальных технологий. Выявлены физиологические, интеллектуальные и психофизиологические особенности восприятия и осознания информации обучающимися с дефектом зрения при построении индивидуальной модели обучающегося [13], которые учитываются при подаче информации с экрана монитора. Осуществлена редукция мало информативных признаков обучающихся.

На разработанное программное обеспечение получено свидетельство о государственной регистрации прав на объект авторского права [14] и акт внедрения в Алматинском филиале общественного объединения «Казахстанское общество слепых» (г. Алматы). Работа выполнена по гранту Комитета Науки Министерство образования и науки Республики Казахстан № ГР 0215РК01472 (2015–2017гг.), по теме «Разработка информационной технологии, алгоритмов и программно-аппаратного обеспечения для интеллектуальных систем управления сложными объектами в условиях параметрической неопределенности».

Список литературы

1 Самигулина Г. А., Шаяхметова А. С. Комбинированная онтологическая модель для дистанционного обучения людей с ограниченными возможностями зрения // Проблемы информатики. – Новосибирск, 2015. – С. 28-36.

2 Самигулина Г.А., Шаяхметова А.С. Smart-технология дистанционного обучения для людей с ограниченными возможностями зрения на основе подходов искусственного интеллекта // Труды XXIII Всероссийского семинара «Нейроинформатика, ее приложения и анализ данных». – Красноярск, 2015. – С.86 - 89.

3 Ахметова Л. В. Когнитивная сфера личности – психологическая основа обучения // Вестник ТГПУ. - 2009. - № 9 (87). – С. 108 - 115.

4 Котова, Е.Е. Разработка адаптивной дистанционной среды обучения с учетом индивидуальных когнитивных особенностей пользователя / Е.Е. Котова // Известия ЮФУ. Технические науки, - 2008. – С. 89 - 92.

5 Нагорнова А.Ю., Нагорнов Ю.С., Кирюхина Д.В., Абалакова О.В., Ли М.Г., Мустафина О.А., Тузова Е.М. Характеристика когнитивной технологии обучения студентов технических специальностей // [Электронный ресурс] URL: <http://www.science-education.ru/ru/article/view?id=7645>. Дата обращения: 05.01.2016.

6 Lisitsyna, L.S., Lyamin A.V., Bystritsky A.S., Martynikhin L.A. Support problem for cognitive functions in the e-learning: Scientific and technical journal of Information technologies.– 2014. - №6 (94). – P. 177- 184.

7 Aivazyan, S.A., Buchstaber, V.M., Yenyukov, I.S., Meshalkin, L.D. Classification and reduction of dimensionality / S.A. Aivazyan and oth. – M.: Finansy i statistika, 1989. - 608 p.

8 Elizabeth, W. Njoroge, Gladys, G. Njoroge and Dennis, K. Muriithi. Evaluating Secondary School Examination Results:Application of Principal Component Analysis / Njoroge W. Elizabeth and oth. // Journal of Statistical and Econometric Methods, 2014. - Vol.3, N.2. - P. 32-46.

9 Hemant, Singh Mittal, Harpreet, Kaur. Face Recognition Using PCA & Neural Network / Mittal Singh Hemant // International Journal of Emerging Science and Engineering, 2013. - Vol. 1, N. 6. - P. 71-75.

10 Samigulina Galina, Shayakhmetova Assem. The information system of distance learning for people with impaired vision on the basis of artificial intelligence approaches // Proceeding of the II International conference on Smart Education and E-learning. – Italy, Sorrento: Springer. - 2015. – P. 255-263.

11 Балашова Ю.В. Интеллектуальное развитие студентов очного и дистанционного обучения // Среднее профессиональное образование. 2011. №. 2. С. 33-35.

12 Базыма Б.А. Порядковые отношения цветов и цветовые предпочтения. // Вестник Харьковского университета, серия «Психология», 2002. - №550. - С. 13-15.

13 Самигулина Г. А., Шаяхметова А.С. Дистанционное обучение людей с ограниченными возможностями зрения // Образовательные ресурсы и технологии. - Красноярск. - 2016. - № 2 (14).– С. 74-81.

14 Самигулина Г. А., Шаяхметова А.С., Сулеймен О. DLS_PIV(Distance learning system for people with impaired vision) для дистанционного обучения людей с ограниченными возможностями зрения (программа для ЭВМ) // Свидетельство о государственной регистрации прав на объект авторского права МЮ РК. – Астана, 15 января 2016. - № 0090. – 25 с.

МЕТОД СИНТЕЗА ПОЛНОСТЬЮ ОПРЕДЕЛЕННЫХ НЕЙРО-НЕЧЕТКИХ МОДЕЛЕЙ НА ОСНОВЕ ВЫБОРОК БОЛЬШОГО ОБЪЕМА

С. А Субботин

Запорожский национальный технический университет, subbotin.csit@gmail.com

Введение

Нейро-нечеткие сети [1–4] являются парадигмой вычислительного интеллекта, широко используемой при решении задач автоматизации принятия решений в техническом и биомедицинском диагностировании, неразрушающем контроле качества и управлении. Это объясняется способностью нейро-нечетких сетей к обучению по прецедентам, интерпретабельностью получаемых нейромоделей, возможностью интегрировать имеющиеся экспертные знания в нейромодель, массированным параллелизмом вычислений нейро-нечетких моделей, возможностью использования для синтеза и обучения нейро-нечетких сетей методов оптимизации и машинного обучения.

Наиболее простым с точки зрения реализации способом синтеза нейро-нечетких моделей является разбиение пространства признаков и выделение правил человеком [3]. Однако это возможно лишь в очень хорошо изученных областях и сопряжено с субъективным подходом эксперта.

Другим, относительно простым, способом синтеза нейро-нечетких моделей является разбиение пространства признаков человеком и формирование правил по набору прецедентов путем преобразования каждого прецедента в отдельное правило [4, 5]. Однако это сопряжено с субъективным подходом к формированию разбиения и может приводить к построению недостаточно точных или плохо обобщающих данные модели.

Синтез структуры нейро-нечетких сетей, как правило, осуществляют путем разбиения пространства признаков на кластеры и формирования для каждого кластера правила отнесения экземпляров к кластеру, которые отображаются затем в структуру нейро-нечеткой сети [6]. При этом проблемами являются выбор способа разбиения значений признаков на интервалы и выбор метода кластер-анализа, а также необходимость вовлечения человека в процесс выбора данных методов и задания разбиения, а также определения экспертных правил.

Сети, построенные на основе разбиения и правил, полностью покрывающих признаковое пространство, ограниченное интервалами значений признаков, будем называть полностью определенными. Сети, построенные на основе разбиения и правил, покрывающих лишь частично признаковое пространство, ограниченное интервалами значений признаков, будем называть частично определенными.

В случае синтеза нейро-нечетких моделей по прецедентам для выборок данных ограниченного объема это дополнительно приводит к ряду проблем:

- если выборка покрывает не все пространство признаков и / или это покрытие является существенно неравномерным, то выделенные кластеры и правила, а также синтезированная на их основе частично определенная сеть могут недостаточно хорошо аппроксимировать (интерполировать и экстраполировать) моделируемую зависимость и плохо обобщать данные;

- процесс синтеза структуры сети не учитывает такие свойства результирующей модели как точность обобщения, сложность, интерпретабельность, что приводит к получению неоптимальных по данным свойствам моделей.

В случае синтеза нейро-нечетких моделей по прецедентам для выборок данных большого объема и значительной размерности признакового пространства из-за невозможности загрузки всей выборки в память ЭВМ процесс построения нейро-нечеткой модели становится крайне затруднительным и является неприемлемым из-за значительных затрат времени на выполнение синтеза и обучения нейромоделей.

Поэтому необходимо создать метод синтеза полностью определенных нейро-нечетких моделей, не требующий загрузки всей обучающей выборки в память ЭВМ, ускоряющий процесс синтез моделей и обеспечивающий приемлемый уровень обобщения данных.

Целью работы являлось создание метода синтеза нейро-нечетких моделей по прецедентам, способного получать полностью определенные модели, не требующего загрузки всей обучающей выборки в память ЭВМ и существенно ускоряющего процесс синтеза моделей по сравнению с известными методами, обеспечивающего при этом приемлемый уровень обобщения данных получаемой моделью.

Постановка задачи

Пусть мы имеем исходную выборку $X = \langle x, y \rangle$ – набор S прецедентов о зависимости $y(x)$, $x = \{x^s\}$, $y = \{y^s\}$, $s = 1, 2, \dots, S$, характеризующихся набором N входных признаков $\{x_j\}$, $j = 1, 2, \dots, N$, и выходным признаком y . Каждый s -й прецедент представим как $\langle x^s, y^s \rangle$, $x^s = \{x_j^s\}$, $y^s \in \{1, 2, \dots, K\}$, где x_j^s – значение j -го входного s -го прецедента, y^s – значение выходного признака для s -го прецедента, K – число классов, $K > 1$. Тогда задача синтеза нейро-нечеткой модели зависимости $y(x)$ будет заключаться в определении таких структуры $F()$ и значений параметров w модели, при которых будет удовлетворен критерий качества модели $f(F(), w, \langle x, y \rangle) \rightarrow opt$ [5].

Для задач с дискретным выходом критерий качества модели f определяют на основе ошибки обученной сети:

$$E = \frac{1}{S} \sum_{s=1}^S |y^s - F(w, x^s)| \rightarrow \min.$$

Метод синтеза полностью определенных нейро-нечетких моделей

Для обеспечения скорости разбиения признаков пространства и его независимости от человека предлагается использовать регулярное разбиение диапазонов значений признаков на интервалы. Число интервалов для разбиения диапазонов значений признаков целесообразно выбирать таким образом, чтобы обеспечить обобщение данных.

Для существенного сокращения затрат на процесс синтеза структуры нейро-нечеткой модели предлагается определять координаты центров кластеров как координаты центров прямоугольных блоков в пространстве признаков без учета выборки данных, но принадлежности кластеров к классам определять по выборке. Это позволит заранее рассчитать параметры интервалов признаков, а также координаты центров кластеров без фактического выполнения кластер-анализа, но для определения правил отнесения экземпляров к классам на основе центров кластеров потребует всего одного просмотра выборки, оперируя в памяти всего одним экземпляром.

Для построения полностью определенных сетей на основе выборки, не полностью покрывающей признаковое пространство, предлагается принадлежность кластеров к классам

Для кластеров, покрытых наблюдениями, определять по максимуму частоты экземпляров соответствующих классов в кластере, а для кластеров, не покрытых наблюдениями, принадлежность определять по максимальному потенциалу [7, 8], наводимому на данный кластер кластерами с известной принадлежностью к классам.

Полученный набор правил может быть легко отображен в структуру сети Мамдани, а её параметры настроены на основе параметров разбиения признаков и центров кластеров.

Формально предложенный метод можно изложить следующим образом.

Этап 1. Инициализация. Задать обучающую выборку $\langle x, y \rangle$. Определить N , S , K , $\{S^k\}$, $k = 1, 2, \dots, K$; $\{x_j^{\min}\}$, $\{x_j^{\max}\}$, $j = 1, 2, \dots, N$, где S^k – число экземпляров в выборке,

принадлежащих к k -му классу, $x_j^{\min}$, $x_j^{\max}$ – минимальное и максимальное значения признака x_j . Задать число интервалов, на которые разбиваются диапазоны значений признаков L , $L \geq 2$. Задать приемлемый уровень ошибки ε .

Этап 2. Формирование разбиения пространства признаков. Определить число кластеров $Q=L^N$. Для $q=1,2,...,Q$, $j=1,2,...,N$, $l=1,2,...,L$ установить номер интервала j -го признака, соответствующий q -му блоку-кластеру, $\lambda_{q,j}=l$. Установить число экземпляров, попавших в q -й кластер, $S_q=0$, число экземпляров k -го класса, попавших в q -й кластер, $S_q^k=0$, $q=1,2,...,Q$, $k=1,2,...,K$.

Определить длину интервала каждого j -го признака:

$$\delta_j = \frac{x_j^{\max} - x_j^{\min}}{L}, j = 1, 2, ..., N.$$

Этап 3. Определение числа экземпляров классов в кластерах.

Последовательно для экземпляров обучающей выборки ($s=1,2,...,S$):

- считать из выборки очередной s -й экземпляр и загрузить в память ЭВМ;
- определить номера интервалов признаков, в которые попал экземпляр x^s :

$$l_j = \left\lfloor 1 + \frac{x_j^s - x_j^{\min}}{\delta_j} \right\rfloor, j = 1, 2, ..., N;$$

- определить номер блока-кластера q , в который попал экземпляр x^s : $q=1,2,...,Q$:
 $\lambda_{q,j}=l_j, j = 1,2,...,N$.

- принять $S_q^{y^s} = S_q^{y^s} + 1$, $S_q = S_q + 1$.

Этап 4. Определение принадлежности кластеров к классам.

Для q -го кластера, $q=1,2,...,Q$, принять номер класса, сопоставленный q -му кластеру:

$$Y_q = \arg \max_{k=1,2,...,K} \{S_q^k \mid S_q > 0\}.$$

Для q -го кластера, $q=1,2,...,Q$, установить:

$$Y_q = \arg \max_{k=1,2,...,K} \left\{ \sum_{p=1}^Q \left\{ \frac{1}{1 + R(Y_q, Y_p)} \mid Y_p = k, S_p > 0 \right\} \mid S_q = 0 \right\},$$

где расстояние между q -м и p -м кластерами:

$$R(Y_q, Y_p) = \frac{1}{2} \sqrt{\sum_{j=1}^N (\lambda_{q,j} - \lambda_{p,j})^2}.$$

Этап 5. Формирование термов признаков. На основе выделенных интервалов значений признаков возможно определить функции принадлежности к термам признаков на основе трапецевидной функции:

$$\mu_{i,l}(x^s) = \begin{cases} 0, & x_i \leq a_{i,l}; \\ \frac{x_i - a_{i,l}}{b_{i,l} - a_{i,l}}, & a_{i,l} \leq x_i \leq b_{i,l}; \\ 1, & b_{i,l} \leq x_i \leq c_{i,l}; \\ \frac{d - x_i}{d - c_{i,l}}, & c_{i,l} \leq x_i \leq d_{i,l}; \\ 0, & d_{i,l} \leq x_i. \end{cases}$$

где $a_{i,l}$, $b_{i,l}$, $c_{i,l}$, $d_{i,l}$ – параметры функции принадлежности к l -му терму i -го признака: $a_{i,l} \leq b_{i,l} \leq c_{i,l} \leq d_{i,l}$: $a_{i,l} = (l-1)\delta + x_i^{\min}$, $b_{i,l} = (l-1)\delta + x_i^{\min}$, $c_{i,l} = l\delta + x_i^{\min}$, $d_{i,l} = l\delta + x_i^{\min}$.

Этап 6. Формирование системы нечеткого вывода. На данном этапе задаются принципы преобразования значений функций принадлежности к термам в принадлежности к кластерам и классам, а также способ дефаззификации результата.

Принадлежности к сформированным эталонам определим по формулам:

$$\mu^q = \min_{i=1,2,\dots,N} \{\mu_{i,l} \mid \lambda_{q,i} = l\},$$

где $q=1, 2, \dots, Q$, $l=1, 2, \dots, L$.

Принадлежности к классам определим по формулам:

$$\mu_k = \max_{q=1,2,\dots,Q} \{\mu^q \mid Y_q = k\}, \quad k = 1, 2, \dots, K.$$

Расчетный номер класса, соответственно, будет определяться по формуле:

$$y^s = \arg \max_{k=1,2,\dots,K} \{\mu_k\}.$$

Этап 7. Синтез нейро-нечеткой сети. На основе выделенных термов и определенных функций системы нечеткого вывода можно сформировать структуру нейро-нечеткой сети Мамдани [3, 4, 9, 10] в соответствии со схемой, приведенной на рис. 1.




Рис. 1. Схема нейро-нечеткой сети

На входной (первый) слой сети поступают входные сигналы – значения признаков распознаваемого экземпляра, которые далее поступают на второй слой, выполняющий фаззификацию. Выходы нейронов второго слоя представляют собой значения функций принадлежности распознаваемого экземпляра к термам признаков. Нейроэлементы третьего слоя сети комбинируют принадлежности к термам в принадлежности к эталонам кластеров, на основе которых нейроны четвертого слоя определяют принадлежности к классам. Единственный нейрон пятого (выходного) слоя осуществляет дефаззификацию и выдает на выходе расчетное значение номера класса распознаваемого экземпляра.

Этап 8. Проверка окончания поиска. Оценить ошибку для построенной сети E . Если ошибка является приемлемой ($E < \varepsilon$), то завершить синтез сети и вернуть полученную нейромодель как результат; в противном случае: если заданное значение L меньше, чем максимально допустимое при заданных N и S , то увеличить $L=L+1$ и перейти к этапу 2, в противном случае – вернуть найденную нейромодель как решение.

Для обеспечения обобщающих свойств нейромодели необходимо, чтобы число её настраиваемых параметров было меньше, чем размерность обучающей выборки NS .

Для нейро-нечеткой сети с трапециевидной функцией принадлежности к термам каждый нейрон второго слоя, соответствующий терму, будет иметь четыре настраиваемых параметра. Следовательно, общее число настраиваемых параметров нейронов второго слоя при равном числе интервалов L , на которое разбиваются диапазоны значений N входных признаков, составит $4NL$. Таким образом, можно сказать, что требуется, чтобы $4NL < NS \Rightarrow L < 0,25S$.

С другой стороны, очевидно, что диапазон значений каждого признака должен быть разбит на не менее, чем два интервала, т.е. $L \geq 2$. Таким образом, получаем $2 \leq L < 0,25S$. Данное соотношение является весьма грубым и допускает значительную неопределенность при выборе L .

Для более точной оценки интервала допустимых значений L рассмотрим полностью определенную (полносвязной прямонаправленную) нейро-нечеткую сеть, общее число весов которой N_w для обеспечения обобщающих свойств должно удовлетворять условию: $N_w < NS$. Число весов в полностью определенной прямонаправленной сети оценим по формуле: $N_w = 4NL + NLQ + QK + K$. Общее число многомерных блоков определения принадлежности к кластерам может быть определено как $Q = L^N$. Тогда условие выбора L будет $2 \leq L, 4NL + NLL^N + L^N K + K < NS$.

Введя переменную $\alpha = N / L \Rightarrow N = \alpha L$, получим: $2 \leq L, 4L + LL^{\alpha L} + \frac{K(L^{\alpha L} + 1)}{\alpha L} < S$. Поскольку, очевидно, что $L^{\alpha L} \gg 1$, приняв для простоты расчетов $K=L$, пренебрегая меньшими слагаемыми, преобразовав и упростив полученное условие получим: $2 \leq L < \sqrt[N+1]{S}$. Из полученного соотношения легко видеть, что сокращение числа используемых признаков позволяет существенно увеличить число интервалов при поддержании обобщающих свойств модели.

Вычислительная сложность полученной нейромодели может быть оценена как $O(8NL + 2NLQ + 2QK + 3K) \approx O(2NL^{N+1} + 2KL^{N+1} + 8NL + 3K)$.

Пренебрегая меньшими слагаемыми, получим оценку $O(2NL^{N+1})$. Полагая в худшем случае $L = \sqrt[N+1]{S}$, получим оценку $O(2NS)$, а, обозначив $n = NS$, относительно размерности обучающей выборки n получим оценку вычислительной сложности модели $O(2n)$.

Пространственная сложность полученной нейромодели может быть оценена как $O(N + 4NL + NLQ + QK + K) \approx O(NL^{N+1} + L^N K + 4NL)$.

Пренебрегая меньшими слагаемыми, получим оценку пространственной сложности модели $O(NL^{N+1})$. Полагая в худшем случае $L = \sqrt[N+1]{S}$, получим оценку пространственной сложности $O(NS) = O(n)$.

Вычислительная сложность одного прохода предложенного метода составит $O(26NS + SK + 2QN + 2QK + 2N + QNS + 2S + 0,5KQ^2 + 3,5Q + S(8NL + 2NLQ + 2QK + 3K))$.

Для случая двух классов ($K=2$), полагая в худшем случае $L = \sqrt[N+1]{S}$, получим $O(\sqrt[N+1]{S^2} + \sqrt[N+1]{S} (2N + 7,5 + 9NS) + 2NS^2 + 4S^2 + 26NS + 10S + 2N)$.

Полагая $S \gg N$ и пренебрегая меньшими слагаемыми, получим оценку вычислительной сложности метода $O(S^2)$.

Пространственная сложность метода может быть оценена как $O(5N + 2K + QN + 2QK + 2Q + L + 4NL + NLQ)$.

Для случая двух классов ($K=2$), полагая в худшем случае $L = \sqrt[N+1]{S}$, полагая $S \gg N$ и пренебрегая меньшими слагаемыми, получим $O(NS) = O(n)$.

Эксперименты и результаты

Предложенный метод был программно реализован как дополнение [11]. Разработанное программное обеспечение использовалось для изучения практической применимости и исследования свойств предложенного метода при решении практических задач автоматической классификации различной природы [5, 12].

При проведении экспериментов исследовались зависимости между параметрами метода для определения возможных ограничений на их значения и тенденций изменения параметров.

Проведенные эксперименты подтвердили работоспособность и практическую применимость предложенного метода. На рис. 2 представлены графики полученных зависимостей.

Предложенный метод при фиксированном числе разбиений не требует загрузки всей обучающей выборки в память ЭВМ, осуществляя её построчную обработку, не требует многократных просмотров обучающей выборки, ограничиваясь всего одним проходом при известных минимальных и максимальных значениях признаков или двумя – при неизвестных минимальных и максимальных значениях признаков.

Как видно из рис. 2а, с увеличением объема выборки наблюдается возможность увеличения предельно допустимого для сохранения обобщающих свойств значения числа интервалов, на которые разбиваются диапазоны значений признаков, L .

Однако, как следует из рис. 2а и рис. 2б, существенное ограничивающее влияние на L также имеет размерность признакового пространства N . Чем больше N , тем меньше будет возможное значение L .

С другой стороны, как видно из рис. 2в, существенное увеличение объема выборки S позволяет увеличивать допустимую границу размерности признакового пространства N . При этом, как следует из рис. 2г, с ростом N обеспечивается возможность увеличения предельно допустимого значения числа кластеров Q .

Также, как видно из рис. 2д, с ростом объема выборки S наблюдается увеличение предельно допустимого значения числа кластеров Q .

Как следует из рис. 2е, с ростом числа разбиений признаков L при фиксированных S и N для каждой из выборок наблюдается в среднем уменьшение ошибки E . Это уменьшение особенно существенно на начальном этапе и становится незначительным при достижении числа разбиений интервалов значений признаков, обеспечивающих создание такого числа кластеров Q , которое сопоставимо с числом экземпляров в выборке S .

Следовательно, для больших по объему выборок данных, если необходимо обеспечить высокий уровень обобщения данных моделью, следует предварительно выполнить отбор наиболее информативных признаков, минимизируя размерность признакового пространства N . Это позволит увеличить допустимую границу L и обеспечить большую точность (меньшую ошибку E).

Выводы

В работе решена актуальная проблема автоматизации синтеза моделей для классификации образов по признакам.

Научная новизна работы состоит в том, что впервые предложен метод синтеза нейро-нечетких моделей по прецедентам, способный получать полностью определенные нейромодели на основе регулярного разбиения признаков. Метод рассчитывает координаты центров кластеров как координаты центров прямоугольных блоков в пространстве интервалов признаков, а принадлежности кластеров к классам определяет по обучающей выборке: для кластеров, покрытых наблюдениями, принадлежность определяется по максимуму частоты экземпляров соответствующих классов в кластере, а для кластеров, не покрытых наблюдениями, принадлежность




Рис. 2. Грфики зависимостей:
а – L от S при разных значениях N ; б – N от L при разных значениях Q ;
в – N от S при разных значениях L ; г – Q от N при разных значениях S ;
д – Q от S при разных значениях N ; е – E от L при разных значениях N и S

определяться по максимальному потенциалу, наводимому на данный кластер кластерами с известной принадлежностью к классам. Полученный набор кластеров-правил отображается в структуру нейро-нечеткой сети Мамдани, а её параметры настраиваются на основе параметров разбиения признаков и центров кластеров. Предложенный метод не требует загрузки всей обучающей выборки в память ЭВМ и существенно ускоряет процесс синтеза моделей, обеспечивая при этом приемлемый уровень обобщения данных получаемой нейромоделью.

Практическая значимость результатов работы заключается в том, что разработано программное обеспечение, реализующее предложенный метод, а также проведены эксперименты, подтвердившие работоспособность разработанного математического обеспечения и позволяющие рекомендовать его для использования на практике при решении задач построения нейро-нечетких моделей для выборок большого объема.

Перспективы дальнейших исследований состоят в исследовании предложенного математического обеспечения на более широком наборе практических задач диагностики и распознавания образов.

Список литературы

1. Analysis and design of intelligent systems using soft computing techniques / eds.: P. Melin, O.R. Castillo, E.G. Ramirez, J. Kacprzyk. – Heidelberg: Springer, 2007. – 855 p.
2. Buckley J. J. Fuzzy neural networks: a survey / J. J. Buckley, Y. Hayashi // Fuzzy sets and systems. – 1994. – Vol. 66, Issue 1. – P. 1–13.
3. Дли М. И. Нечёткая логика и искусственные нейронные сети / М. И. Дли. – М.: Физматлит, 2003. – 225 с.
4. Рутковская Д. Нейронные сети, генетические алгоритмы и нечёткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский ; пер. с польск. И. Д. Рудинского. – М.: Горячая линия – Телеком, 2004. – 452 с.
5. Интеллектуальные информационные технологии проектирования автоматизированных систем диагностирования и распознавания образов : монография / [С. А. Субботин, Ан. А. Олейник, Е. А. Гофман, С. А. Зайцев, Ал. А. Олейник] ; под ред. С. А. Субботина. – Харьков : Компания СМІТ, 2012. – 318 с.
6. Осовский С. Нейронные сети для обработки информации / С. Осовский. – М.: Финансы и статистика, 2004. – 344 с.
7. Фор А. Восприятие и распознавание образов / А. Фор ; под ред. Г. П. Катуса. – М.:Машиностроение, 1989. – 271 с.
8. Айзерман М. А. Метод потенциальных функций в теории обучения машин / М. А. Айзерман, Э. М. Браверман, Л. И. Розоноэр. – М. : Наука, 1970. – 384 с.
9. Ярушкина Н. Г. Основы теории нечётких и гибридных систем / Н. Г. Ярушкина. – М.: Финансы и статистика, 2004. – 320 с.
10. Яхьяева Г. Э. Нечёткие множества и нейронные сети : учеб. пособие / Г. Э. Яхьяева. – М.: Интуит, 2006. – 316 с.
11. Комп'ютерна програма "Автоматизована система синтезу нейромрежних та нейро-нечітких моделей для неруйнівної діагностики та класифікації образів за ознаками" : свідоцтво про реєстрацію авторського права на твір № 35431 / С. О. Субботін. – Держ. департамент інтелектуальної власності. – № 34011 ; заявл. 21.04.10 ; зареєстр. 21.10.10.
12. Прогрессивные технологии моделирования, оптимизации и интеллектуальной автоматизации этапов жизненного цикла авиационных двигателей : монография / [А. В. Богуслаев, Ал. А. Олейник, Ан. А. Олейник, Д. В. Павленко, С. А. Субботин]; под ред. Д. В. Павленко, С. А. Субботина. – Запорожье: ОАО "Мотор Сич", 2009. – 468 с.

МОДЕЛЬ АНИМАТА СПОСОБНОГО К АДАПТИВНОМУ ПОВЕДЕНИЮ НА ОСНОВЕ ИСПОЛЬЗОВАНИЯ КОМБИНАЦИИ СЛУЧАЙНОГО ПОИСКА И ОПЫТА

А. Г. Туманян^{1,a}, С. И. Барцев^{1,2,b}

¹ Институт Фундаментальной Биологии и Биотехнологии,
Сибирского Федерального Университета
Россия 660041, Красноярск, Свободный 79,

² Институт Биофизики СО РАН, д-р физ.-мат. наук, профессор кафедры биофизики
Россия 660036, Красноярск, Академгородок 50/50

^a artur.tumanyan@gmail.com

^b bartsev@yandex.ru

Введение

Живые организмы, существуя в природе, руководствуются разного рода поведенческими навыками или паттернами для выживания: если организм голодает, значит нужно искать пищу, если рядом хищник, значит нужно убегать и др. Большинство паттернов – приобретенные в процессе жизни организма. Способность к формированию новых поведенческих паттернов помогает приспособиться к меняющейся среде, и позволяет выживать в новых условиях. Как устроены механизмы такого формирования, как они взаимодействуют друг с другом - являются важными и актуальными вопросами когнитивной биологии и искусственного интеллекта.

В данной работе главной целью ставится создание биологически реалистичного[1,2] алгоритма обучения анимата, который способен устанавливать соответствие между закономерностями окружающего мира (взаимное положение цели и "кисти" манипулятора) и «внутренними ощущениями» (положением пятен на сетчатке), приводящим к адекватной активной реакции анимата – захвату предмета. Особо отметим, что это не просто формирование условного рефлекса, а именно усвоение фундаментальных закономерностей отображения внешнего мира во внутреннее представление.

Основная идея алгоритма заключалась в том, что анимат использует при обучении[5-7] случайно реализованные успешные фрагменты траектории, набор которых расширяется по мере его функционирования. Другая особенность – использование двух источников принятия решений: накопленный опыт и случайные действия “на удачу”. Именно результирующее действие должно приводить к распознаванию ситуации и быстрому поиску целевой точки. При первом запуске анимат еще не имеет опыта и может руководствоваться только случайным поведением.

Основных источников «принятия решения» здесь два: нейросеть и генератор случайного движения. При конкуренции источников друг с другом за право осуществить шаг, анимат функционирует и самообучается. Влияние каждого из источников регулируется при помощи фактора качества обучения сети (g), который изменяется от 0 до 1. Фактор g введен для того, чтобы анимат мог корректировать динамически в процессе функционирования влияние прошлого опыта, отклика нейросети и случайных действий. При значении $g = 0$ вклад сети в решение о следующем шаге равен 0, т.е. анимат вообще не обращает внимания на отклик сети, хотя результат по-прежнему вычисляется на каждой итерации. По мере того, как анимат начинает попадать в цель, сеть обучается, g увеличивается при каждом попадании в целевую точку на небольшую величину (0.05) и отклик сети все больше влияет на следующие шаги. При неудачах захвата цели при определенном количестве попыток g уменьшается на 0.05. При $g=1$ сеть полностью перехватывает управление, и генератор случайных шагов не используется.

Для увеличения скорости обучения фиксируются только последние действия, которые привели к успеху, и со временем непрерывная цепочка правильных действий удлиняется – максимально используется предыдущий позитивный опыт, а негативный «забывается» и не используется. Этот способ может применяться для освоения сложных временных паттернов. Дополнительной особенностью алгоритма является способность комбинировать случайный поиск и действия на основе внутреннего опыта, при том, что никакие критерии в явном и неявном виде предварительно не вкладываются в анимат. Каждый захват цели запускает обучение на основе завершающего фрагмента траектории, после которого увеличивается количество распознаваемых ситуаций и, тем самым, увеличивается время, когда анимат находится под управлением «знающей» нейросети, а не генератора случайного движения.

Результаты

В начале своей работы анимат совершал исключительно случайные действия ($r=0$) (рисунок 1), ожидаемо затрачивая много времени на поиск цели. Затем, по мере накопления успешных завершающих фрагментов траекторий в его задачнике, обучения сети на их основе, сопровождающегося увеличением фактора r , анимат начинал пользоваться «опытом» нейросети (рисунок 2а). Когда значение r близко к 1, анимат практически перестает пользоваться случайным поведением и большую часть времени находится под управлением «знающей» нейросети (рисунок 2б).




Рисунок 1. Демонстрация работы станда в режиме чисто поискового поведения. Рука блуждает в области видимости для сетчаток случайно меняя направление движения.

В данном случае процесс обучение происходит непрерывно с процессом функционирования, что является важной характеристикой для автономных роботов, которым необходимо максимально быстро приспосабливаться к среде.





Рисунок 2. Левый рисунок (2а) – основное влияние оказывает генератор случайных действий ($r=0.2$), правый рисунок (2б) анимат под влиянием обученной сети ($r=0.9$).

На рисунке 3 показаны диаграммы временных затрат для анимата, в случае случайного поиска(3а) и в случае комбинированного поиска(3б), сочетающего случайный поиск при незнакомом паттерне ситуации и переключение на функционирование нейросети при распознавании знакомого паттерна ситуации. Видна большая разница в среднем времени поиска цели. На синем графике времена поиска цели носят случайный характер в ходе предъявления всех 21 точек, на зеленом графике – в течение нескольких начальных итераций анимат обучается, а затем начинает быстро достигать цели.






Рисунок 3. Времена поиска цели в секундах в зависимости от номера цели (21 целевая точка). Синяя диаграмма(3а) — только случайный поиск, зеленая диаграмма(3б) — комбинация случайного поиска и отклика обученной нейросети.

Заключение

В статье разработан биологически реалистичный алгоритм обучения анимата, ключевой особенностью которого является то, что фиксируются только последние действия, которые привели к успеху, и со временем непрерывная цепочка правильных действий удлиняется – максимально используется предыдущий позитивный опыт, а негативный «забывается» и не используется. Другая особенность – процессы обучения происходят неразрывно от процессов функционирования и жизнедеятельности, т.е. анимат с самого начала может комбинировать случайные действия и действия, основанные на опыте.

Алгоритм способен устанавливать соответствие между закономерностями окружающего мира и «внутренними ощущениями», внутренним состоянием самого анимата. Созданный алгоритм в этом смысле похож на алгоритм обучения с подкреплением (reinforcement learning[3,4]), так как у нас тоже исследуется аниматом внешняя среда и накапливается опыт, знания о среде, только это происходит быстрее. Отличием является возможность генерализации, обобщения данных на основе ограниченного набора траекторий, т.е. нет необходимости, как в обучении с подкреплением изучать каждый «миллиметр» среды.

Список литературы

1. Редько В.Г. Модели адаптивного поведения – биологически инспирированный подход к искусственному интеллекту // Искусственный интеллект и принятие решений, том 2, -2008
2. Гладков Л. А., Курейчик В. В., Курейчик В. М. Генетические алгоритмы: Учебное пособие. — 2-е изд. — М: Физматлит, 2006. — С. 320. — ISBN 5-9221-0510-8
3. Sutton R.S., Barto A.G. Reinforcement learning: An introduction. // Cambridge, MA: MIT Press – 1998 - 323 pp.
4. Legenstein R, Wilbert N, Wiskott L (2010) Reinforcement Learning on Slow Features of High-Dimensional Input Streams. PLoS Comput Biol 6(8): e1000894. doi:10.1371/journal.pcbi.1000894
5. Rumelhart D.E., Hinton G.E., Williams R.J. Learning internal representation by error propagation // Parallel Distributed Processing. - 1986 - vol.1.- №8
6. Туманян А.Г., Барцев С.И. “Простейшая поведенческая модель формирования импринта” Компьютерные исследования и моделирование, 2014, т. 6, № 5, с. 793-802
7. Туманян А.Г., Барцев С.И. Свидетельство о государственной регистрации программы для ЭВМ №2016611753, «Программа для создания реалистичной модели простейшего двигательного паттерна мобильного робота»

АНАЛИЗ ИНИЦИАТИВНЫХ НАУЧНЫХ ПРОЕКТОВ ПО РАЗНЫМ ОБЛАСТЯМ ЗНАНИЯ, ПОДДЕРЖАННЫХ РОССИЙСКИМ ФОНДОМ ФУНДАМЕНТАЛЬНЫХ ИССЛЕДОВАНИЙ

Р.А. Чиженкова

Институт биофизики клетки РАН, chizhenkova@mail.ru

В середине XX-ого века возникло четкое понимание, что гарантом процветания любого государства и вообще сохранения цивилизации является развитие фундаментальной науки [4, 5, 8], что привело к формированию специализированных фондов для ее поддержки. Становление нового отношения к науке связано с деятельностью американского физика В. Буша [4], который полагал, что "фундаментальные исследования - это научный капитал" [6]. По мнению президента США Барака Обамы, "для фундаментальных научных исследований необходимо государственное финансирование, поскольку исследования в области физики, химии или биологии зачастую не окупаются за год или даже 10 лет, а иногда не окупаются вообще" [6].

В самом начале становления нового государства РФ, по примеру других государств, в 1992 г был создан Российский Фонд Фундаментальных Исследований (РФФИ) [1, 2]. Материалы относительно 20-летнего юбилея РФФИ приведены в специальном выпуске журнала "Вестник РФФИ" [3]. Однако за все эти годы так и не был проведен подробный анализ научных направлений проектов, поддержанных Фондом. В связи с этим возникла необходимость выхода в свет наших работ, имеющих отношение к отдельным периодам деятельности РФФИ [9, 11 -13].

Лидирующим аспектом деятельности РФФИ является финансовая поддержка инициативных научных проектов, т.е. реальных исследований ученых. Именно эти исследования представляют основу фундаментальной науки, успехи которой в дальнейшем приводят к познанию окружающего нас мира, и дают возможность развития прикладных наук. Настоящие исследования посвящены библиометрическому анализу научных направлений инициативных научных проектов, поддержанных РФФИ за 20-летний период его деятельности, что полностью отсутствует в открытых публикациях.

Материалы и методы

Представленные здесь сведения основываются на материалах, опубликованных в Информационных бюллетенях (ИБ) РФФИ, выходящих раз в год и освещающих итоги прошедшего конкурса, которые позволяют рассмотреть количественные особенности последнего по разным областям знания.

Для каждого года составлялась обширная таблица с учетом данных по разным областям знания относительно чисел поданных заявок и выделенных грантов. При этом вычислялась процентная вероятность поддержки проектов. Проводили объединение результатов по анализируемым рубрикам за весь временной период и вычисляли статистическую значимость различия величин, принадлежавших к разным рубрикам. Для статистического анализа использовали сравнение двух выборочных долей вариант.

Результаты и обсуждение

За период с 1993 по 2012 г.г. РФФИ оказало финансовую поддержку 58667 инициативным проектам. Научные проекты имели отношение к следующим областям знания: (1) "Математика, информатика, механика"; (2) "Физика и астрономия"; (3) "Химия и науки о материалах", что до 2009 г. называлась просто "Химия"; (4) "Биология и медицинская наука"; (5) "Науки о Земле"; (6) "Науки о человеке и обществе"; (7) "Информационные технологии и вычислительные системы". Последнее название

области знания в ИБ РФФИ фигурирует с 2006 г. В 1993-1996 гг. аналогичная область знания носила название - "Информационные системы и базы данных", а в 1997-2003 гг. - "Создание и развитие информационных, вычислительных и телекоммуникационных ресурсов", а в 2004-2005 гг. - "Информационные, вычислительные и телекоммуникационные ресурсы". В 2001 и 2002 гг. было еще выделено "Программное обеспечение суперЭВМ", которое можно рассматривать в качестве составной части указанной выше рубрики. Претерпело изменение название области знания "Науки о человеке и обществе". Данное название отмечается в ИБ РФФИ только с 1997 г. Однако, в эту область знания логически вписывается научное направление "Гуманитарные и общественные науки", которое в ИБ РФФИ имело место в 1993-1996 гг. В 2006 г. возникла дополнительная рубрика (8) "Фундаментальные основы инженерных наук". Табл. 1 приводит количественные характеристики массивов выделенных грантов по указанным областям знания.

Таблица 1

Сравнение чисел поддержанных инициативных проектов по представленным областям знания со средним значением по общему массиву

Области знания	Число грантов	% от суммы (58667)	Критерий U . Сравнение со средним
Математика, информатика, механика	8209	13.99	<u>7.54</u>
Физика и астрономия	12376	21.10	<u>39.74</u>
Химия и науки о материалах	8145	13,88	<u>7.02</u>
Биология и медицинская наука	12093	20.61	<u>37.51</u>
Науки о Земле	8946	15.25	<u>13.70</u>
Науки о человеке и обществе	3439	5.86	<u>40.08</u>
Информационные технологии и вычислительные системы	2618	4.46	<u>50.87</u>
Фундаментальные основы инженерных наук	2841	4.84	<u>47.78</u>
Итого	58667	100	
Среднее	7333.375	12.50	

Примечание: Статистически достоверные значения подчеркнуты ($U > 2.58$ соответствует $p < 0.01$).

Из табл. 1 видно, что имело место явное преобладание числа поддержанных проектов по двум областям знания: "Физика и астрономия" (21.10% от общего числа) и "Биология и медицинская наука" (20.61% от общего числа). Следующий уровень принадлежал числам проектов по трем областям знания: "Науки о Земле"; "Математика, информатика, механика"; "Химия и науки о материалах". На низком уровне находились числа проектов также по трем областям знания: "Науки о человеке и обществе"; "Фундаментальные основы инженерных наук"; "Информационные технологии и вычислительные системы".

Существенной мерой оценки результатов финансовой поддержки научных проектов РФФИ является выяснение ее вероятности среди подаваемых заявок. К сожалению, числа поданных заявок по инициативным проектам в ИБ приведены без учета 1993-1995 и 2001 гг. Общее число поданных заявок по инициативным проектам за данный 16-летний период составляло 150189. Распределение чисел поданных заявок по разным областям знания за указанный период представлено в табл. 2.

Таблица 2

Сравнение чисел заявок инициативных проектов по представленным областям знания со средним значением по общему массиву

Области знания	Число заявок	% от суммы (18774)	Критерий У. Сравнение со средним
Математика, информатика, механика	17476	11.64	<u>7.40</u>
Физика и астрономия	31096	20.71	<u>60.84</u>
Химия и науки о материалах	21764	14.49	<u>15.89</u>
Биология и медицинская наука	31858	21.21	<u>64.12</u>
Науки о Земле	23265	15.49	<u>23.57</u>
Науки о человеке и обществе	8375	5.58	<u>67.41</u>
Информационные технологии и вычислительные системы	7616	5.07	<u>73.44</u>
Фундаментальные основы инженерных наук	8739	5.82	<u>64.67</u>
Итого	150189	100	
Среднее	18773.625	12.50	

Примечание: как у табл. 1.

Следует признать, что структура табл. 2 весьма сходна с таковой табл. 1. Наблюдается четкое подразделение чисел поданных заявок по рассматриваемым областям знания на три различных уровня. При этом имеет место также выраженное лидерование заявок по областям знания "Биология и медицинская наука" (21.21% от общего числа) и "Физика и астрономия" (20,71% от общего числа).

Наличие сведений по количественным аспектам выделенных грантов (за 16-летний период 47174) и поданных заявок позволяет перейти к конкретному рассмотрению процентного числа поддержанных проектов, что и было сделано для всех представленных областей знания. Полученные результаты демонстрируются в табл. 3.

Таблица 3

Сравнение долей поддержанных инициативных проектов по представленным областям знания со средним значением по общему массиву

Область знания	Число заявок	Число грантов	% поддержанных	Критерий U. Сравнение со средним
Математика, информатика, механика	17476	6313	36.12	<u>12.39</u>
Физика и астрономия	31096	9566	30.76	2.25
Химия и науки о материалах	21764	6456	29.66	<u>5.24</u>
Биология и медицинская наука	31858	9917	31.13	1.14
Науки о Земле	23265	7135	30.67	2.41
Науки о человеке и обществе	8375	2682	32.02	1.25
Информационные технологии и вычислительные системы	7616	2264	29.73	<u>3.07</u>
Фундаментальные основы инженерных наук	8739	2841	32.51	2.09
Итого	150189	47174	31.41	

Примечание: как у табл. 1.

Обращает на себя внимание тот факт, что, несмотря на некоторые статистически значимые различия процентных чисел поддержанных проектов по разным областям знания, тем не менее, отмечается близость их количественных характеристик. Диапазон колебаний составлял от 29.66% до 36.12%, т.е. 6.46%.

Заключение

Наиболее трудные годы только что созданной РФ ознаменовались организацией РФФИ для экстренной поддержки фундаментальной науки. За 20-летний период его деятельности была оказана существенная помощь в проведении научных исследований по основным областям знания. Наиболее перспективными направлениями фундаментальной науки в XXI веке могут быть "Биология и медицинская наука" и "Физика и астрономия", что согласуется с прогнозами, изложенными в наших других публикациях [10, 13 - 15]. Не исключено, что возможно увеличение ресурсного наполнение Фонда в ближайшие годы [7].

Список литературы

1. Алфимов М.В. История создания Фонда // Вестник РФФИ 20 лет: Специальный выпуск. - 2012. - С. 10-15.
2. Алфимов М.В., Минин В.А., Либкинд А.Н. Страна наука - РФФИ // Вестник РФФИ. - 2000. - № 2(20). - С. 5-29.
3. Вестник РФФИ 20 лет: Специальный выпуск. - 2012.
4. Коннов В.И. Самоуправление на "передовой": становление национального научного фонда США // Вестник РФФИ. - 2007. - №4(54). - С. 10-15.
5. Лебедев С.А. Праксиология науки // Вопросы философии. - 2012. - №4. - С. 52-63.
6. Обама Б. Выступление в Национальной академии наук 27-ого апреля 2009 г. // В защиту науки. Бюл. № 6 / Ред. Э.П. Кругляков. - М.: Наука, 2009. - С. 185-198.
7. Путин В.В. Выступление на Общем собрании Российской академии наук 22 мая 2012 // В защиту науки. Бюл. № 11 / Ред. Э.П. Кругляков. - М.: Наука, 2012. - С. 7-14.
8. Чиженкова Р.А. Наука в современном мире // Актуальные проблемы социальной философии / ред. Э.В. Гирусов. - М., 1998. - С. 111-112.
9. Чиженкова Р.А. Библиометрический анализ научных проектов, поддержанных Российским Фондом Фундаментальных Исследований (итог 15 лет) // Фундаментальные исследования. - 2010. - №1. - С. 100-106.
10. Чиженкова Р.А. Динамика нейрофизиологических исследований действия неионизирующей радиации во второй половине XX-ого века. - М.: Издат. дом Акад. Естествознания, 2012. - 88 с.
11. Чиженкова Р.А. Общий библиометрический анализ научных проектов, поддержанных Российским Фондом Фундаментальных Исследований в последнее десятилетие // В: Альманах научных открытий. Материалы научных трудов. / Ред. Н.Н.Ильинских. - Томск, 2013. - Т. 2. - № 1. - С. 158-159.
12. Чиженкова Р.А. Библиометрический анализ научных проектов, поддержанных Российским Фондом Фундаментальных Исследований за 20 лет: виды конкурсов // Успехи современного естествознания. - 2014. - № 5. - С. 145-149
13. Чиженкова Р.А. Российский фонд фундаментальных исследований. Библиометрический анализ поддержки научных проектов. - Germany: Palmarium Academic Publishing, 2015. - 88 с.
14. Чиженкова Р.А., Сафрошкина А.А., Слащева Н.А., Чернухин В.Ю. Библиометрический анализ нейрофизиологических аспектов действия неионизирующей радиации // Успехи современной биологии. - 2004. - Т. 124. - № 5. - С. 472-479.
15. Chizhenkova R.A. Bibliometrical review of neurophysiological investigation of action of non-ionized radiation in second half of the XXth century // Biophysics. - 2005. - Supplement. - № 1(50). - P. 163-172.

ГЕНЕТИЧЕСКОЕ АДАПТИВНОЕ УПРАВЛЕНИЕ ТРАЕКТОРИЕЙ ДВИЖЕНИЯ КОСМИЧЕСКОГО АППАРАТА

О.И. Ширяева, Т.И. Самигулин

Институт информационных и вычислительных технологий КН МОН РК,
oshiryayeva@gmail.com, timur.samigulin@yandex.kz

Введение. В настоящее время особую важность имеют разработки систем управления аэрокосмическими аппаратами, которые относятся к классу конструкций, которая подвержена случайным внешним возмущениям, шумам измерений и другим возмущениям [1, 2]. Синтез систем высокой точности при наличии существенной неопределенности объекта вынуждает проектировщика искать решение в классе адаптивных систем, которая обладает достаточной надежностью, грубостью и гибкостью. Разработка подобной системы относится к фундаментальным и актуальным проблемам современной теории и практики автоматического управления.

Это обуславливает актуальность развития задачи адаптивного управления при рассмотрении траектории движения космического аппарата (ТДКА) с непрерывной адаптацией параметров регулятора [3 – 5].

В свою очередь, при настройки параметров адаптивных регуляторов, используются различные методы теории оптимизации, в том числе, генетические алгоритмы [6, 7]. Генетические алгоритмы являются адаптивными методами поиска, основанные на биологической концепции "выживания наиболее приспособленных особей". Поэтому, генетический алгоритм применяется при настройки регуляторов для обеспечения оптимальной производительности управления при номинальных условиях эксплуатации.

Данный доклад включает в себя этапы синтеза адаптивной системы управления с эталонной моделью траекторией движения космического аппарата на основе на основе генетического алгоритма.

1 Синтез адаптивной системы управления с эталонной моделью траекторией движения космического аппарата. Рассмотрим оптимальную математическую модель траектории движения космического аппарата при переходе с эллиптической на параболическую орбиту. Результаты линеаризации нелинейных дифференциальных уравнений ТДКА на основе применения ряда Тейлора, выполненной авторами в работе [8], а также использование обозначений параметров и переменных математической модели ТДКА, позволяют получить модель в пространстве состояний [9]:

$$\begin{bmatrix} \dot{p}(t) \\ \dot{Q}(t) \\ \dot{L}(t) \end{bmatrix} = \begin{bmatrix} 1.63 & -0.53 & 0 \\ 1.37 & -0.46 & -3.42 \\ -2.13 & 5.63 & 0.55 \end{bmatrix} \cdot \begin{bmatrix} p(t) \\ Q(t) \\ L(t) \end{bmatrix} + \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} u_1(t) \\ u_2(t) \\ u_3(t) \end{bmatrix} \quad (1)$$

где $p(t) \in R$ – обозначает параметр оскулирующего эллипса; $\{Q(t), L(t)\} \in R$ – являются фазовыми координатами; $u_1(t), u_2(t), u_3(t)$ – являются входными сигналами; $\{p_0, Q_0, L_0\}$ – начальные условия, определяющие оптимальную траекторию движения, выражаются через эксцентриситет ε_0 и истинную аномалию v_0 .

Для представления модели (1) как эталонной модели, введем вектор переменных состояния $x_M(t) = [p(t) \ Q(t) \ L(t)]^T$ и вектор входных сигналов $u_M(t) = [u_1(t) \ u_2(t) \ u_3(t)]^T$:

$$\dot{x}_M(t) = Ax_M(t) + B_M u_M(t), \quad (2)$$

где $x_M(t) \in R^{3 \times 1}$ – вектор состояния эталонной модели; $A_M \in R^{3 \times 3}$ – матрица переменных, представляющая взаимосвязь с линеаризованными параметрами $p(t)$, $Q(t)$, $L(t)$; $B_M \in R^{3 \times 3}$ – матрица управления системы; $u_M \in R^{3 \times 1}$ – вектор управления системы.

Для описания реального движения КА введем вектор переменных состояния $y(t) = [p_S(t) \ Q_S(t) \ L_S(t)]^T$ и вектор входных сигналов $u_a(t) = [u_{a1}(t) \ u_{a2}(t) \ u_{a3}(t)]^T$.

$$\dot{y}(t) = A_p y(t) + B_p u_a(t), \quad (3)$$

где $y(t) \in R^{3 \times 1}$ – вектор выходного сигнала регулируемой системы ДКА; $A_p \in R^{3 \times 3}$ и $B_p \in R^{3 \times 3}$ – неизвестные матрицы.

В процессе реального движения космического аппарата имеет место система с параметрической неопределенностью, при которой параметры объекта управления A_p и B_p отличаются от параметров заданной модели A_M и B_M и являются неопределенными, при этом значения выходных сигналов $y(t)$ известны и отличаются от желаемых $x_M(t)$ на ошибку $e(t)$:

$$e(t) = x_M(t) - y(t), \quad (4)$$

где $e(t) \in R^{3 \times 1}$ – вектор ошибки, значения которого не известны; $y(t) \in R^{3 \times 1}$ – вектор состояния реального движения космического аппарата.

Недостатки параметрической неопределенности можно устранить путем применения адаптивного закона управления на основе 2-го метода Ляпунова [10]. Пусть вектор $u_a(t) = [u_{a1}(t) \ u_{a2}(t) \ u_{a3}(t)]^T$ – выбранный закон управления:

$$u_a(t) = f_y(e, t) \cdot y(t) + f_M(e, t) \cdot u_M(t), \quad (5)$$

где $f_y(e, t) \in R^{3 \times 3}$ и $f_M(e, t) \in R^{3 \times 3}$ – настраиваемые параметры регулятора;

Разработанная адаптивная система управления с эталонной моделью показана на рисунке 1. Верхняя часть рисунка 1 состоит из эталонной модели, которая включает в себя информацию о желаемой динамике ТДКА $x_M(t)$ и эталонный управляющий сигнал $u_M(t)$. Нижняя часть схемы состоит из объекта управления с выходным сигналом $y(t)$ и законом управления $u_a(t)$, полученным из адаптивного регулятора. Средняя часть схемы содержит механизм адаптации, который используется для настройки параметров адаптации f_a и f_b закона управления $u_a(t)$ на основе генетического алгоритма.




Рис. 1. Схема адаптивной системы управления ТДКА с эталонной моделью

Для осуществления процедуры настройки параметров регулятора перепишем уравнение выходного сигнала с учетом выражения входного сигнала [8]:

$$\dot{y}(t) = (A_p + B_p \cdot f_y(e, t)) \cdot y(t) + B_p \cdot f_M(e, t) \cdot u_M(t). \quad (6)$$

Введем в рассмотрение обозначения:

$$A_S(e, t) = A_p + B_p \cdot f_y(e, t), \dots B_S(e, t) = B_p \cdot f_M(e, t), \quad (7)$$

где $A_S(e, t) \in R^{3 \times 3}$ и $B_S(e, t) \in R^{3 \times 3}$ – неизвестные матрицы, которые зависят от состояния обобщенного вектора ошибки $e(t)$, на основе которой определяется цель управления (ЦУ) алгоритма:

$$\lim_{t \rightarrow \infty} e(t) = 0, \quad (8)$$

$$\lim_{t \rightarrow \infty} A_S(t) = A_M, \quad \lim_{t \rightarrow \infty} B_S(t) = B_M.$$

Необходимо отметить, что f_A и f_B изменяемые параметры и используются для определения функциональной связи между $A_S(e, t)$, $B_S(e, t)$ и значениями вектора ошибки $e(t)$ в интервале $0 \leq \tau \leq t$ [10].

Таким образом, для синтеза адаптивного регулятора (5), предваряющим разработку его технической реализации, необходимо выполнить процедуру настройки параметров f_A и f_B с достижением ЦУ (8).

2 Настройка параметров адаптивного регулятора на основе генетического алгоритма. По способу достижения цели управления данная система управления с эталонной моделью относится к параметрической адаптации. В данном случае, цель управления достигается за счет изменения двух параметров управляющего устройства (9) на основе генетического алгоритма. В работах [11, 12] приводится обоснование применимости метода генетического алгоритма для алгоритма адаптации.

В ходе реализации генетического алгоритма для настройки адаптивного регулятора ТДКА сформированы следующие этапы вычислительного алгоритма:

Этап 1. Выбор локального целевого функционала, в данном случае в форме скалярной квадратичной функции

$$q(e) = 0,5e^T H e, \quad (9)$$

где $H = H^T > 0$ – матрица размерности (2×2) , являющаяся решением уравнения Ляпунова для эталонной модели [8]:

$$HA_M + A_M^T H = -G,$$

где $G = G^T > 0$; очевидно, что из $q(e) \rightarrow 0$ при $t \rightarrow \infty$ следует выполнение ЦУ.

Этап 2. Генетический алгоритм настройки f_A и f_B (рисунок 2).




Рис. 2. Алгоритм настройки параметров адаптивного регулятора ТДКА

В ходе получения результатов, было сформулировано условие, что для настройки адаптивного регулятора хромосома особи должна кодировать не более одного параметра. Хромосома состоит из одного гена, длина которого равна 16 бит. Производится операция скрещивания для обмена генетической информацией между двумя хромосомами особей-родителей. По завершению работы генетического алгоритма производится перевод двоичного кода в инженерные величины (рисунок 2).

Разработанный адаптивный алгоритм управления траекторией движения космического аппарата, с настройкой параметров на основе генетического алгоритма, обладает высокой точностью и скоростью сходимости, что позволяет обеспечить

надежную систему автоматического управления в условиях неопределенности параметров и значительном изменении динамических свойств объекта управления.

Заключение. Для синтеза адаптивного управления траектории движения космического аппарата получены следующие результаты: получен алгоритм адаптации, который содержит настраиваемые параметры f_A и f_B адаптивного регулятора на основе генетического алгоритма; разработан алгоритм адаптивного управления системы с законом управления (5).

Исследования проводятся по гранту №0115PK00536 МОН РК по теме: Разработка информационной технологии, алгоритмов и программно-аппаратного обеспечения для интеллектуальных систем управления сложными объектами в условиях параметрической неопределенности (2015-2017 гг.).

Список литературы

1. Lavretsky E. Robust and Adaptive Control with Aerospace Applications / K.Wise. – Springer, 2013. – 454 p.
2. Rutkowski V.Yu. Some methods and adaptive the coordinate-parametric control objects for the aviation and space applications / S.D.Zemlaykov, V.M.Suhanov, V.M.Glumov // Gyroscopy and Navigation. – 2006. – V.2. – №1. – pp. 114 – 118.
3. Anton H.J. Adaptive Spacecraft Attitude Control with Actuator Saturation / H.J.Anton, De.Ruiter // Journal of Guidance, Control, and Dynamics. – 2010. – V.33. – №2. – pp. 1692 – 1696.
4. Keum W.L. Attractive manifold - based adaptive solar attitude control of satellites in elliptic orbits / K.W.Lee, N.S.Singh // Acta Astronautica. – 2011. – V.68. – №2. – pp. 185 – 196.
5. Keum W.L. L_1 adaptive control of flexible spacecraft despite disturbances / W.L.Keum, N.S.Sahjendra // Acta Astronautica. – 2012. – V.80. – pp. 24–35.
6. Lin F. Adaptive sliding mode controller based on real time genetic algorithm for induction motor servo drive / L.F.Lin, W.Chou, P.Huang // IEEE Proc. Electr. Power Appl. – V.150. – No.1. – 2003. – pp. 1 – 13.
7. Lavu B. A genetic algorithm approach for model reference adaptive control of ionic polymer metal composites / B.Lavu, M.Schoen, A.Mahajan // Proceeding of the 2004 American Control Conference, Boston, Massachusetts, June 30 – July 2, 2004. – pp. 5514 – 5519.
8. Samigulina Z. Adaptive Control strategy based reference model for Spacecraft Motion Trajectory / Z.Samigulina, O.Shiryayeva, G.Samigulina, H.Fourati // International Journal of Adaptive Control and Signal Processing. – 2014. – V.29. – pp. 639 – 652.
9. Golnaradhi F. Automatic Control Systems / F.Golnaradhi, B.Kuo. – Wiley: New-York. – 2009. – 504 p.
10. Landau I.D. Adaptive control – The Model Reference approach / I.D.Landau. – Dekker: New York. – 1979. – 406 p.
11. Jeffrey T.S. Stable Adaptive Control and Estimation for Nonlinear Systems: Neural and Fuzzy Approximator Techniques / T.S.Jeffrey, M.Maggiore, R.Ordonez, K.M.Passino. – Wiley: New York. – 2002. – 568 p.
12. Mohideen K.A. Real-coded Genetic Algorithm for system identification and tuning of a modified Model Reference Adaptive Controller for a hybrid tank system / K.A. Mohideen, G.Saravanakumar, K.Valarmathi, D.Devaraj, T.K.Radhakrishnan // Applied Mathematical Modelling. – 2013. – N37. – 3829–3847pp.

АНАЛИЗ СТРУКТУРЫ ТЕЧЕНИЯ НЕГЛУБОКОГО СТРАТИФИЦИРОВАННОГО ОЗЕРА В ЛЕТНИЙ ПЕРИОД С ИСПОЛЬЗОВАНИЕМ МЕТОДА ЭМПИРИЧЕСКИХ ОРТОГОНАЛЬНЫХ ФУНКЦИЙ

О.С.Володько¹, Л.А.Компаниец²

¹Балтийский федеральный университет, opitalskaya@kantiana.ru

²Институт вычислительного моделирования СО РАН, kla@icm.krasn.ru

Метод эмпирических ортогональных функций хорошо зарекомендовал себя в задачах анализа данных течений в различных водоемах. В силу своей сложной пространственно-временной структуры эти течения представляют собой идеальный объект для применения метода ЭОФ.

Возможно, одной из первых статей в этом направлении была статья [1]. Отметим в этой связи также статьи [2-6]. В статье [2] приводится теоретическое обоснование метода ЭОФ, в статье [3] авторы применяют этот метод для анализа распределения тропических волн. Работы [4-5] посвящены применению этого метода для анализа течений на побережье Орегона и течениям в Пьюджет-Саунде, в работе [6] проводится анализ поверхностных течений в Северной Каролине.

В данной работе представлены результаты анализа данных измерений скоростей течения за 2015 г. в озере Шира. Измерения были проведены в двух точках Т1 (54°31'46.5" с.ш., 90°10'42.6" в.д.) и Т6 (54°30'08.6" с.ш., 90°13'51.5" в.д.) приборами ADCP 600 и 1200 кГц в период с 1 июня по 7 августа 2015 г по всему столбу жидкости, начиная с глубины 12,6 м и 10,4 м соответственно и заканчивая на глубине 0,6 м от поверхности. Данные о восточной и северной скорости записывались с периодом 2 минуты.

Были проанализированы два массива измерений восточной и северной скоростей в точке Т6 по глубине (глубина озера в этой точке составляет 14,5 м). В течение периода измерений наблюдались значительные изменения горизонтальной скорости.

Для выделения общей составляющей течения был применен метод эмпирических ортогональных функций.

Цель этого метода – оптимально описать поле скоростей течений $w(x, t) = (u, v)$, где u – восточная, v – северная компоненты скорости, X – соответствующая система координат. В комплексном анализе (КЭОФ) поле течений записывается в виде

$$w(x_i, t_k) = u(x_i, t_k) + iv(x_i, t_k),$$

где $t_k (k = 1, \dots, K)$ и $x_i (i = 1, \dots, N)$ – переменные по времени и пространству соответственно. Для применения метода КЭОФ определяется комплексная матрица коэффициентов корреляции

$$R(x_i, x_j) = \frac{1}{K} \sum_{k=1}^K w^*(x_i, t_k) w(x_j, t_k)$$

и находятся ее собственные векторы $\phi_n(x_i)$ и собственные значения λ_n из равенства

$$\sum_{i=1}^N R(x_i, x_j) \phi_n(x_i) = \lambda_n \phi_n(x_j), \quad n = 1 \dots N.$$

Так как корреляционная матрица является Эрмитовой, то комплексные собственные векторы удовлетворяют условию ортогональности

$$\sum_{i=1}^N \varphi_n^*(x_i) \varphi_m(x_j) = \delta_{nm}$$

и собственные значения λ_n - действительные.

Более того, принимая во внимание неравенство Шварца

$$R(x_i, x_i) R(x_j, x_j) \geq R^*(x_j, x_i) R(x_i, x_j)$$

можно сделать вывод, что собственные значения λ_n будут также положительными.

Собственные векторы φ_n могут быть названы – «комплексные эмпирические ортогональные моды». Запишем поле скоростей течения w через эти моды

$$w(x_i, t_k) = \sum_{n=1}^N E_n(t_k) \varphi_n(x_i),$$

тогда комплексные амплитуды $E_n(t_k)$ выражаются следующим образом:

$$E_n(t_k) = \sum_{i=1}^N \varphi_n^*(x_i) w(x_i, t_k),$$

$$\sum_{i=1}^N E_n^*(t_k) E_m(t_k) = \lambda_n \delta_{nm}.$$

Отсюда следует, что амплитуды двух различных мод не коррелируют друг с другом и собственные значения являются средним значением энергии по времени в разных модах. Сумма всех собственных значений равна общей энергии:

$$\frac{1}{K} \sum_{k=1}^K \sum_{i=1}^N w^*(x_i, t_k) w(x_i, t_k) = \frac{1}{K} \sum_{k=1}^K \sum_{i=1}^N E_n^*(t_k) E_n(t_k) = \sum_{n=1}^N \lambda_n$$

Построим график аналога годографа горизонтальной скорости для первой моды и амплитуду и фазу изменения первой моды по времени (Рис.1.).




Рис.1. Метод КЭОФ, Мода 1.

Возможность представления решения первой модой подтверждается анализом энергии и спектра разложения (Рис.2).




Рис.2. Слева – накопленная доля от общей энергии, справа – спектр собственных чисел.

С другой стороны, можно метод эмпирических ортогональных функций применить к каждому ряду из действительных величин (северная и восточная скорость) и также построить аналог годографа скорости для первой моды (Рис.3).




Рис.3. Метод ЭОФ, Мода 1.

Энергия и спектр разложения для северной и восточной скорости представлены на Рис.4.




Рис.4. Слева – накопленная доля от общей энергии: кружочки - восточная компонента скорости u , плюсики – северная компонента v . Справа – спектр собственных чисел: сплошная линия – u , пунктирная – v .

Сравнение значений для первой моды, полученных с использованием методов ДЭОФ и КЭОФ, показано на Рис.5.




Рис.5. Распределение восточной и северных компонент горизонтальной скорости по глубине. Первое значение соответствует точке измерения, ближайшей к дну. Значения, полученные для первой моды с использованием метода ДЭОФ, нанесены сплошной линией, пунктирно – с использованием метода КЭОФ.

При определенной нормировке собственных функций можно получить «хорошее» совпадение в целом аналогов северной и восточной скоростей, полученных методами КЭОФ и ДЭОФ (Рис. 6-7).




Рис.6. Сравнение первой моды, полученной методом КЭОФ и ДЭОФ. Значения, полученные с использованием метода ДЭОФ, нанесены сплошной линией, пунктирно – с использованием метода КЭОФ.




Рис.7. Сравнение второй моды, полученной методом КЭОФ и ДЭОФ. Значения, полученные с использованием метода ДЭОФ, нанесены сплошной линией, пунктирно – с использованием метода КЭОФ.

В данном случае применение метода КЭОФ предпочтительнее, т.к., в отличие от метода ДЭОФ, обе горизонтальные компоненты скорости, как видно из сравнения Рис.2 и Рис.4, аппроксимируются с одинаковой точностью.

Аналог годографа горизонтальной скорости может быть применен для оценки величины вертикального турбулентного обмена в течение всего периода измерений.

Для анализа был взят годограф, полученный с использованием метода КЭОФ.

Выражение для компонент скорости в дрейфовом стационарном течении однородной жидкости согласно Экману [7] можно записать в виде:

$$\begin{aligned} u &= V_0 e^{-\alpha z} \cos\left(\frac{\pi}{4} - \alpha z\right), \\ v &= V_0 e^{-\alpha z} \sin\left(\frac{\pi}{4} - \alpha z\right), \\ V_0 &= \frac{\tau}{\sqrt{K_z \rho^2 f}}, \\ a &= \sqrt{\frac{f}{2K_z}}, \quad f = 2\Omega \sin \varphi, \end{aligned} \quad (1)$$

где τ – напряжение ветра, f – параметр Кориолиса, K_z – коэффициент вертикального турбулентного обмена, Ω – угловая скорость вращения Земли, $\Omega = 7,29 \cdot 10^{-5} \text{ с}^{-1}$, φ – широта места.

Глубина, на которой вектор скорости принимает направление, противоположное направлению на поверхности, называется глубиной слоя Экмана. Согласно (1) глубина слоя Экмана равна

$$D = \frac{\pi}{a} = \sqrt{\frac{2\pi^2 K_z}{f}}. \quad (2)$$

Посчитаем масштаб глубины a и коэффициент вертикального турбулентного обмена K_z для натурных измерений, сделанных в июле-августе 2015 г. с помощью доплеровского профилографа течений ADCP 1200 кГц на озере Шира.

Из формул (1) и (2) следует, что

$$a = \frac{\pi}{D}, \quad K_z = \frac{f}{2a^2} = \frac{2\Omega \sin \varphi}{a^2}.$$

Для точки Т6 анализ первой моды дает глубину слоя Экмана $D = 5,14 \text{ м}$. Тогда при применении формул (1-2) в этом случае получаем

$$\begin{aligned} a &= \frac{\pi}{5,14 \text{ м}} \cong 0,6112 \text{ м}^{-1} \cong 6,1 \cdot 10^{-3} \text{ см}^{-1}, \\ K_z &= \frac{7,29 \cdot 10^{-5} \text{ с}^{-1} \sin(54^\circ 30' 08,6'')}{(0,6112 \text{ м}^{-1})^2} \cong 10,6 \cdot 10^{-4} \text{ м}^2/\text{с} \cong 10,6 \text{ см}^2/\text{с}. \end{aligned}$$

Список литературы

1. Lorenz E.N. Empirical orthogonal functions and statistical weather prediction / E. Lorenz — Technical Report, Statistical Forecasting Project, Department of Meteorology, Massachusetts Institute of Technology, Cambridge, MA, 1956 — 49 p.
2. Wallace J. M. Empirical orthogonal representation of time series in the frequency domain. Part I: Theoretical consideration / J. M. Wallace, R.E. Dickinson // Journal of Applied Meteorology. — 1972 — Vol.11 — № 6 — P. 887-892.
3. Wallace J. M. Empirical orthogonal representation of time series in the frequency domain. Part II: Application to the study of tropical wave disturbances. / J. M. Wallace, R.E. Dickinson // Journal of Applied Meteorology. — 1972 — Vol.11 — № 6 — P. 893-900.

4. Kundu P.K. Some three-dimensional characteristic of low-frequency currents near the Oregon Coast / P.K. Kundu, J.S. Allen // Journal of Physical Oceanography. — 1976 — Vol.6 — P. 181-199.
5. Matsuura H. Wind Effects on Sub-Tidal Currents in Puget Sound / H. Matsuura, A. C. Glenn // Journal of Oceanography. — 1997 — Vol.53 —P. 53-66.
6. Kaihatu J.M. Empirical Orthogonal Function analysis of ocean surface currents using complex and real-vector methods / J.M. Kaihatu , R. A. Handler, G. O. Marmorino, L. K. Shay //Journal of atmospheric and oceanic technology. — 1998— Vol.15 — P. 927-941.
7. Ekman V.W. On the influence of the earth's rotation on ocean currents. / V.W. Ekman // Arkiv för Matematik, Astronomi och Fysik — 1905 — Vol. 2 — № 11 — P. 1–52.

СПИСОК ДОКЛАДОВ

РАЗРАБОТКА ГИБРИДНОЙ МОДЕЛИ С НЕЙРОСЕТЕВЫМИ КОМПОНЕНТАМИ ДЛЯ РЕШЕНИЯ ЗАДАЧИ КОМПЛЕКСНОЙ ОЦЕНКИ ДЕЯТЕЛЬНОСТИ АВТОСЕРВИСНОГО ПРЕДПРИЯТИЯ Д.Д. Барышев, М.Н. Коршикова, О.И. Пятковский	3
ИССЛЕДОВАНИЕ ПРОЦЕССОВ САМОРЕГУЛЯЦИИ ОРГАНИЗМА ТЕПЛОВИЗИОННЫМ МЕТОДОМ Н.М. Богатов, А.Н. Богатова, С.А. Сухих	9
МОДЕЛЬ НЕЙРОМОРФНОЙ СИСТЕМЫ УПРАВЛЕНИЯ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ СО СТРУКТУРНОЙ АДАПТАЦИЕЙ А.В Бахшиев, Ф.В. Гунделах	13
КЛАССИФИЦИРУЮЩИЕ МОДЕЛИ ДЛЯ ПРОГНОЗИРОВАНИЯ ИНФЕКЦИОННЫХ ЗАБОЛЕВАНИЙ В ГЕТЕРОГЕННОМ ПРОСТРАНСТВЕ ИНФОРМАТИВНЫХ ПРИЗНАКОВ Васми Ихаб А Васми, Ю.Б. Мухатаев, В.В. Федянин	19
РЕШЕНИЕ УРАВНЕНИЙ В ЧАСТНЫХ ПРОИЗВОДНЫХ НА МЕМРИСТОРНЫХ КЛЕТОЧНЫХ СЕТЯХ В.И. Горбаченко, С. Н. Катков	24
СИСТЕМНЫЙ ПОДХОД К ОБРАБОТКЕ СТРУКТУРНОЙ ИНФОРМАЦИИ О СВОЙСТВАХ ОРГАНИЗМА НА ОСНОВЕ НЕЧЕТКОЙ ЛОГИКИ Т.Г. Денисова	30
ВИЗУАЛЬНОЕ УПРАВЛЕНИЕ И КОГНИТИВНАЯ ГРАФИКА В ФУНКЦИОНАЛЬНЫХ ГИБРИДНЫХ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМАХ А.В. Колесников, С.В. Листопад, В.И. Данишевский, С.Б. Румовская, К.В. Суворов	35
МЕТОД ПОВЫШЕНИЯ КАЧЕСТВА АНАЛИЗА РЕНТГЕНОВСКИХ СНИМКОВ НА ОСНОВЕ КОМБИНИРОВАННЫХ КЛАССИФИКАТОРОВ П.С. Кудрявцев, А.А. Кузьмин, О.В. Шаталова, С.А. Филист	40
МЕТОД ПОСТРОЕНИЯ РЕШАЮЩЕГО МОДУЛЯ ДЛЯ ПРОГНОЗИРОВАНИЯ РИСКА СОЦИАЛЬНО ЗНАЧИМЫХ ЗАБОЛЕВАНИЙ А.Г.Курочкин, А.Н. Шуткин, Е.С. Шкатова	45

МГУА-НЕЙРОННЫЕ СЕТИ ДЛЯ ПРОГНОЗИРОВАНИЯ СОСТОЯНИЯ СЛОЖНЫХ СИСТЕМ С ВРЕМЕННЫМИ ЛАГАМИ А.О. Позин, Е.А. Старцев, В.В. Уварова	50
ОБРАБОТКА ДАННЫХ НА ОСНОВЕ АЛГОРИТМА RANDOM FOREST ДЛЯ ПРОГНОЗИРОВАНИЯ ЗАВИСИМОСТИ «СТРУКТУРА-АКТИВНОСТЬ» ЛЕКАРСТВЕННЫХ СОЕДИНЕНИЙ Г.А. САМИГУЛИНА, З.И. САМИГУЛИНА	56
ОБРАБОТКА МНОГОМЕРНЫХ ДАННЫХ В SMART-СИСТЕМЕ ДИСТАНЦИОННОГО ОБУЧЕНИЯ ЛЮДЕЙ С НАРУШЕНИЯМИ ЗРЕНИЯ НА ОСНОВЕ КОГНИТИВНОГО ПОДХОДА И ФАКТОРНОГО АНАЛИЗА Г.А. Самигулина, А.С. Шаяхметова	62
МЕТОД СИНТЕЗА ПОЛНОСТЬЮ ОПРЕДЕЛЕННЫХ НЕЙРО-НЕЧЕТКИХ МОДЕЛЕЙ НА ОСНОВЕ ВЫБОРОК БОЛЬШОГО ОБЪЕМА С. А Субботин	68
МОДЕЛЬ АНИМАТА СПОСОБНОГО К АДАПТИВНОМУ ПОВЕДЕНИЮ НА ОСНОВЕ ИСПОЛЬЗОВАНИЯ КОМБИНАЦИИ СЛУЧАЙНОГО ПОИСКА И ОПЫТА А. Г. Туманян, С. И. Барцев	76
АНАЛИЗ ИНИЦИАТИВНЫХ НАУЧНЫХ ПРОЕКТОВ ПО РАЗНЫМ ОБЛАСТЯМ ЗНАНИЯ, ПОДДЕРЖАННЫХ РОССИЙСКИМ ФОНДОМ ФУНДАМЕНТАЛЬНЫХ ИССЛЕДОВАНИЙ Р.А. Чиженкова	80
ГЕНЕТИЧЕСКОЕ АДАПТИВНОЕ УПРАВЛЕНИЕ ТРАЕКТОРИЕЙ ДВИЖЕНИЯ КОСМИЧЕСКОГО АППАРАТА О.И. Ширяева, Т.И. Самигулин	85
АНАЛИЗ СТРУКТУРЫ ТЕЧЕНИЯ НЕГЛУБОКОГО СТРАТИФИЦИРОВАННОГО ОЗЕРА В ЛЕТНИЙ ПЕРИОД С ИСПОЛЬЗОВАНИЕМ МЕТОДА ЭМПИРИЧЕСКИХ ОРТОГОНАЛЬНЫХ ФУНКЦИЙ О.С.Володько, Л.А.Компаниец	90

СПИСОК АВТОРОВ

Ф.И.О.	Место работы	Стр.
Барышев Денис Дмитриевич	656038 г. Барнаул, Алтайский государственный технический университет им. И. И. Ползунова, E-mail: denis.baryshev@bk.ru	3
Барцев Сергей Игоревич	Россия 660041, Красноярск, Свободный 79, Сибирский федеральный университет, Институт Фундаментальной Биологии и Биотехнологии, Институт Биофизики СО РАН E-mail: bartsev@yandex.ru	76
Бахшиев Александр Валерьевич	Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики (ЦНИИ РТК)	13
Богатов Николай Маркович	350040, г. Краснодар, ул. Ставропольская, 149, ФГБОУ ВПО «Кубанский государственный университет», E-mail: bogatov@phys.kubsu.ru	9
Богатов Анна Николаевна	350040, г. Краснодар, ул. Ставропольская, 149, ФГБОУ ВПО «Кубанский государственный университет», т. 8(861)2199501266, E-mail: bogatov@phys.kubsu.ru	9
Васми Ихаб А Васми	305029, г. Курск, ул. Южный переулок, 21, Юго-Западный государственный университет, E-mail: SFilist@gmail.com	19
Володько Ольга Станиславовна	236041, Калининград, ул. Александра Невского, 14, Балтийский федеральный университет имени Иммануила Канта E-mail: opitalskaya@kantiana.ru	
Горбаченко Владимир Иванович	440026, Пенза, ул. Красная, 40, Пензенский государственный университет E-mail: gorvi@mail.ru	24
Гунделах Филипп Викторович	Центральный научно-исследовательский и опытно-конструкторский институт робототехники и технической кибернетики (ЦНИИ РТК), f.gundelakh@rtc.ru	13
Данишевский Владислав Игоревич	236041, Калининград, ул. Александра Невского, 14, Балтийский федеральный университет имени Иммануила Канта, Калининградский филиал ФИЦ «Информатика и управление» РАН E-mail: danishevskii.v.i@mail.ru	35
Денисова Татьяна Геннадьевна	050010, Республика Казахстан, Алматы, ул. Пушкина, 125, Институт информационных и вычислительных технологий КН МОН РК E-mail: elkaz@mail.ru	30
Катков Сергей Николаевич	440026, Пенза, ул. Красная, 40, Пензенский государственный университет E-mail: skat.pnz@yandex.ru	24
Колесников Алек-	236041, Калининград, ул. Александра Невского, 14, Балтийский федеральный университет имени Иммануила Канта,	35

сандр Васильевич	Калининградский филиал ФИЦ «Информатика и управление» РАН E-mail: avkolesnikov@yandex.ru	
Компаниец Лидия Алексеевна	660036, Красноярск, Академгородок, Институт вычислительного моделирования СО РАН E-mail: kla@icm.krasn.ru	90
Коршикова Мария Николаевна	656038 г. Барнаул, Алтайский государственный технический университет им. И. И. Ползунова, E-mail: korshikovamary@mail.ru	3
Кудрявцев Павел Сергеевич	305029, г. Курск, ул. Южный переулок, 21, Юго-Западный государственный университет, E-mail: 79pavel97@mail.ru	40
Кузьмин Александр Алексеевич	305029, г. Курск, ул. Южный переулок, 21, Юго-Западный государственный университет, E-mail: SFilist@gmail.com	40
Курочкин Алек- сандр Геннадиевич	305029, г. Курск, ул. Южный переулок, 21, Юго-Западный государственный университет, E-mail: ak76@kursk.ru	45
Листопад Сергей Викторович	236041, Калининград, ул. Александра Невского, 14, Балтийский федеральный университет имени Иммануила Канта, Калининградский филиал ФИЦ «Информатика и управление» РАН E-mail: ser-list-post@yandex.ru	35
Мухатаев Юрий Беркович	305029, г. Курск, ул. Южный переулок, 21, Юго-Западный государственный университет, E-mail: SFilist@gmail.com	19
Позин А.О.	305029, г. Курск, ул. Южный переулок, 21, Юго-Западный государственный университет, E-mail: SFilist@gmail.com	50
Пятковский Олег Иванович	656038, Российская Федерация, Алтайский край, г. Барнаул, пр. Ленина, 46, Алтайский государственный технический университет им. И. И. Ползунова E-mail: poi1952@mail.ru	3
Румовская София Борисовна	236041, Калининград, ул. Александра Невского, 14, Балтийский федеральный университет имени Иммануила Канта, Калининградский филиал ФИЦ «Информатика и управление» РАН E-mail: sofiyabr@gmail.com	35
Самигулин Тимур Илдусович	050010, Республика Казахстан, г. Алматы, ул. Пушкина, 125, Институт информационных и вычислительных технологий E-mail: timur.samigulin@yandex.kz	85
Самигулина Галина Ахметовна	050010, Республика Казахстан, г. Алматы, ул. Пушкина, 125, Институт информационных и вычислительных технологий E-mail: galinasamigulina@mail.ru	56, 62
Самигулина Зарина Ильдусовна	050013, г. Алматы, ул. Сатпаева, 22 а, Казахский национальный технический исследовательский университет, Институт информационных и телекоммуникационных технологий E-mail: zarinasamigulina@mail.ru	56

Старцев Евгений Александрович	305029, г. Курск, ул. Южный переулок, 21, Юго-Западный государственный университет, E-mail: SFilist@gmail.com	50
Субботин Сергей Александрович	Запорожский национальный технический университет, Украина, 69063, Запорожье, ул. Жуковского, 64, т.: +38-(097) 355-61-55, E-mail: subbotin@zntu.edu.ua	68
Суворов Константин Васильевич	236041, Калининград, ул. Александра Невского, 14, Балтийский федеральный университет имени Иммануила Канта, Калининградский филиал ФИЦ «Информатика и управление» РАН E-mail: kest93suvorov@mail.ru	35
Сухих Станислав Алексеевич	350040, г. Краснодар, ул. Ставропольская, 149, ФГБОУ ВПО «Кубанский государственный университет», E-mail: suhikh_52@mail.ru	9
Туманян Артур Геворкиевич	Россия 660041, Красноярск, Свободный 79, Сибирский федеральный университет, ИФББ E-mail: artur.tumanyan@gmail.com	76
Уварова В.В.	305029, г. Курск, ул. Южный переулок, 21, Юго-Западный государственный университет, E-mail: SFilist@gmail.com	50
Федянин Вадим Витальевич	305029, г. Курск, ул. Южный переулок, 21, Юго-Западный государственный университет, E-mail: fedyanin.50@mail.ru	19
Филист Сергей Алексеевич	305029, г. Курск, ул. Южный переулок, 21, Юго-Западный государственный университет, E-mail: SFilist@gmail.com	40
Чиженкова Рогнеда Александровна	142290, г. Пушкино Московской области, Институт биофизики клетки РАН E-mail: chizhenkova@mail.ru	80
Шаталова Ольга Владимировна	305029, г. Курск, ул. Южный переулок, 21, Юго-Западный государственный университет, E-mail: shatolg@mail.ru	40
Шаяхметова Асем Серикбаевна	050010, Республика Казахстан, г. Алматы, ул. Пушкина, 125, Институт информационных и вычислительных технологий, E-mail: asemshayakhmetova@mail.ru	62
Ширяева Ольга Ивановна	050010, Республика Казахстан, Алматы, ул. Пушкина, 125, Институт информационных и вычислительных технологий КН МОН РК E-mail: oshiryayeva@gmail.com	85
Шкатова Елена Александровна	394052, Воронеж, ул. Краснознамённая, 231, Воронежский институт государственной противопожарной службы E-mail: vigps@mail.ru	45
Шуткин Александр Николаевич	394052, Воронеж, ул. Краснознамённая, 231, Воронежский институт государственной противопожарной службы E-mail: vigps@mail.ru	45

Научное издание

Нейроинформатика, её приложения и анализ данных

Материалы XXIV Всероссийского семинара 30 сентября – 2 октября 2016 г.

Редактор М.Ю. Сенашова
Компьютерная верстка: М.Ю. Сенашова

Подписано в печать «15» августа 2016 г. Формат 60 × 90/8. (А4)
Бумага офсетная. Печать плоская.
Усл. печ. л. 11,0. Уч.-изд. л. 11,3.
Тираж 500 экз. Заказ 15

Отпечатано в типографии ИВМ СО РАН
660036, Красноярск, Академгородок