



ПЕРМСКИЙ
УНИВЕРСИТЕТ
Классика будущего



НАУКА и глобальные ВЫЗОВЫ XXI века

**ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ
В РЕШЕНИИ АКТУАЛЬНЫХ СОЦИАЛЬНЫХ
И ЭКОНОМИЧЕСКИХ ПРОБЛЕМ XXI ВЕКА**

г. Пермь, 2017

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РОССИЙСКОЙ ФЕДЕРАЦИИ

Пермское отделение Научного совета РАН
по методологии искусственного интеллекта

Пермский государственный национальный исследовательский университет

Пермский национальный исследовательский политехнический университет

Национальный исследовательский университет «Высшая школа экономики»

Пермский государственный гуманитарно-педагогический университет

Пермский государственный медицинский университет им. академика Е. А. Вагнера

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В РЕШЕНИИ АКТУАЛЬНЫХ СОЦИАЛЬНЫХ И ЭКОНОМИЧЕСКИХ ПРОБЛЕМ XXI ВЕКА

Сборник статей по материалам

Второй всероссийской научно-практической конференции,
проводимой в рамках Пермского естественнонаучного форума
«Математика и глобальные вызовы XXI века»

(г. Пермь, 16–17 мая 2017 г.)



Пермь 2017

УДК 004.8: 3
ББК 32.813 + 6/8
И86

Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Второй всерос. науч.-практ. конф. (г. Пермь, 16–17 мая 2017 г.) / Перм. гос. нац. исслед. ун-т. – Пермь, 2017. – 246 с.

ISBN 978-5-7944-2905-3

В сборнике представлены материалы Второй всероссийской научно-практической конференции «Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века», которая проводилась 16–17 мая 2017 г. в г. Пермь в рамках Пермского естественнонаучного форума «Математика и глобальные вызовы XXI века».

Сборник предназначен для научных и педагогических работников, преподавателей, аспирантов, магистрантов и студентов, всех, кто интересуется проблемами и перспективами развития и применения методов искусственного интеллекта.

УДК 004.8: 3
ББК 32.813 + 6/8

Редакционная коллегия

Вяткин Бронислав Александрович, д-р психол. наук
Гусев Андрей Леонидович, д-р техн. наук
Кузнецов Андрей Геннадьевич, канд. техн. наук
Левченко Елена Васильевна, д-р психол. наук
Пенский Олег Геннадьевич, д-р техн. наук
Русаков Сергей Владимирович, д-р физ.-мат. наук
Столбов Валерий Юрьевич, д-р техн. наук
Хлынова Ольга Витальевна, д-р мед. наук, чл.-корр. РАН
Шестакова Лидия Валентиновна, канд. физ.-мат. наук

Ответственный редактор

Ясницкий Леонид Нахимович, д-р техн. наук

Сборник подготовлен при финансовой поддержке РФФИ: грант № 16-01-00164

Статьи публикуются в авторской редакции, авторы несут ответственность за содержание статей, за достоверность приведенных в статье фактов, цитат, статистических и иных данных, имен, названий и прочих сведений

ISBN 978-5-7944-2905-3

© ПГНИУ, 2017

СОДЕРЖАНИЕ

1. ПЛЕНАРНЫЕ ДОКЛАДЫ	7
О ПРИОРИТЕТЕ СОВЕТСКОЙ НАУКИ В ОБЛАСТИ НЕЙРОИНФОРМАТИКИ.....	8
НЕЙРОСЕТЕВОЙ ПОДХОД КАК ПУТЬ ДАЛЬНЕЙШЕГО РАЗВИТИЯ СИСТЕМНЫХ ИДЕЙ В ТЕОРИИ ИНТЕГРАЛЬНОЙ ИНДИВИДУАЛЬНОСТИ В.С. МЕРЛИНА.....	12
ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ ТЕРМОМЕТРИЧЕСКИХ ДАННЫХ В ДИАГНОСТИКЕ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ.....	16
2. ЭКОНОМИКА И УСТОЙЧИВОЕ РАЗВИТИЕ	23
ВОЗМОЖНОСТИ ОПРЕДЕЛЕНИЯ ГОДНОСТИ К ВОЕННОЙ СЛУЖБЕ МЕТОДОМ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЕ.....	24
ИСПОЛЬЗОВАНИЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ПРОГНОЗИРОВАНИИ ПОЛА БУДУЩЕГО РЕБЕНКА	27
СИСТЕМА ПРОГНОЗИРОВАНИЯ ТИПА ОСАДКОВ НА ОСНОВЕ ПОГОДНЫХ ЯВЛЕНИЙ.....	31
НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ ЗАРПЛАТЫ WEB-РАЗРАБОТЧИКА В МОСКВЕ	35
ПРОГНОЗИРОВАНИЕ ОБЪЕМА ПРОДАЖ СОКА В ПРОДУКТОВОЙ РОЗНИЧНОЙ СЕТИ ПОСРЕДСТВОМ НЕЙРОННЫХ СЕТЕЙ.....	41
УПРАВЛЕНИЕ РЫНКОМ НЕДВИЖИМОСТИ С ПОМОЩЬЮ СЦЕНАРНОГО ПРОГНОЗИРОВАНИЯ РЫНОЧНОЙ СТОИМОСТИ НА БАЗЕ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ.....	47
ИСПОЛЬЗОВАНИЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ПРОГНОЗИРОВАНИИ СТОИМОСТИ АРЕНДЫ ЖИЛЬЯ В ГОРОДЕ ПЕРМЬ.....	53
3. МЕДИЦИНА	59
РЕАЛИЗАЦИЯ АЛГОРИТМА ДИАГНОСТИКИ ЗАБОЛЕВАНИЙ МОЛОЧНЫХ ЖЕЛЕЗ ПО ДАННЫМ КОМБИНИРОВАННОЙ ТЕРМОМЕТРИИ С ИСПОЛЬЗОВАНИЕМ НЕЧЕТКИХ МНОЖЕСТВ	60
ГИБРИДНЫЕ КЛАССИФИКАТОРЫ В ЗАДАЧАХ КЛАССИФИКАЦИИ РЕНТГЕНОГРАММ ГРУДНОЙ КЛЕТКИ	64
АДАПТИРУЕМЫЕ К СТРУКТУРЕ ДАННЫХ КЛАССИФИКАТОРЫ В ЗАДАЧАХ ПРОГНОЗИРОВАНИЯ ПРОФЕССИОНАЛЬНЫХ ЗАБОЛЕВАНИЙ.....	70
ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ ДИАГНОСТИКИ ОНКОЛОГИЧЕСКИХ ЗАБОЛЕВАНИЙ МОЛОЧНЫХ ЖЕЛЕЗ.....	75

МЕТОДИКА ОПТИМИЗАЦИИ КОЛИЧЕСТВА ДИАГНОСТИЧЕСКИХ ПРИЗНАКОВ ЗАБОЛЕВАНИЙ МОЛОЧНЫХ ЖЕЛЕЗ НА ОСНОВЕ ТЕРМОМЕТРИЧЕСКИХ ДАННЫХ	78
РАЗРАБОТКА НЕЙРОСЕТЕВОЙ СИСТЕМЫ ПРЕДВАРИТЕЛЬНОЙ ДИАГНОСТИКИ ЗАБОЛЕВАНИЙ ЖЕЛУДОЧНО-КИШЕЧНОГО ТРАКТА	84
НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ДИАГНОСТИКИ И ПРОГНОЗИРОВАНИЯ РАЗВИТИЯ СЕРДЕЧНО-СОСУДИСТЫХ ЗАБОЛЕВАНИЙ	91
4. ПСИХОЛОГИЯ	96
О ВОЗМОЖНОСТИ СОЗДАНИЯ НЕЙРО-ЭКСПЕРТНОЙ СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ В СФЕРЕ ПРОДАЖ.....	97
ПОСТРОЕНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ ПРОГНОЗИРОВАНИЯ ВЕРОЯТНОСТИ РАСПОЛОЖЕНИЯ К СЕБЕ ЛЮДЕЙ.....	100
ОБНАРУЖЕНИЕ ДЕВИАНТНОГО ПОВЕДЕНИЯ ЛЮДЕЙ НА ОСНОВЕ АНАЛИЗА ТРАЕКТОРИЙ ДВИЖЕНИЯ	105
ИССЛЕДОВАНИЕ ЗАКОНА РАСПРЕДЕЛЕНИЯ ИНДИВИДУАЛЬНОЙ СКОРОСТИ РЕАГИРОВАНИЯ НАБЛЮДАТЕЛЯ	108
ПРОГНОЗИРОВАНИЕ ПРОДОЛЖИТЕЛЬНОСТИ БРАКОВ	113
5. КРИМИНАЛИСТИКА И БЕЗОПАСНОСТЬ	119
ВОПРОСЫ ВЫБОРА ПРОГРАММНЫХ СРЕДСТВ ДЛЯ РЕАЛИЗАЦИИ АЛГОРИТМОВ РАСПОЗНАВАНИЯ ОБРАЗОВ В ЗАДАЧАХ АВТОМАТИЗАЦИИ РАБОТЫ ЭКСПЕРТОВ-КРИМИНАЛИСТОВ	120
ПРОГНОЗИРОВАНИЕ ГОРОДСКИХ ПОЖАРОВ В ПАКЕТЕ STATISTICA.....	125
РАЗРАБОТКА МОДЕЛИ ОБНАРУЖЕНИЯ СЕТЕВЫХ АТАК НА ОСНОВЕ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ	129
РАЗРАБОТКА НЕЙРОСЕТЕВОЙ СИСТЕМЫ ДЛЯ ОПРЕДЕЛЕНИЯ ВМЕНЯЕМОСТИ СЕРИЙНЫХ УБИЙЦ.....	135
ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА КАК ЦЕЛЕНАПРАВЛЕННАЯ СИСТЕМА, ОСНАЩЕННАЯ КОМПЛЕКСОМ ИНТЕЛЛЕКТУАЛЬНОГО УПРАВЛЕНИЯ И РАЗВИТИЯ НА ВСЕХ ЭТАПАХ ЖИЗНЕННОГО ЦИКЛА	139
6. ПЕДАГОГИКА	143
ПРОБЛЕМЫ И ВОЗМОЖНОСТИ ИСПОЛЬЗОВАНИЯ ИНТЕЛЛЕКТУАЛЬНЫХ ТЕХНОЛОГИЙ В ОБУЧЕНИИ СТУДЕНТОВ — БУДУЩИХ УЧИТЕЛЕЙ ИНФОРМАТИКИ.....	144

СИСТЕМА РЕКОМЕНДАЦИЙ ФАКУЛЬТЕТОВ АБИТУРИЕНТАМ НАЦИОНАЛЬНОГО ИССЛЕДОВАТЕЛЬСКОГО УНИВЕРСИТЕТА «ВЫСШАЯ ШКОЛА ЭКОНОМИКИ – ПЕРМЬ».....	150
ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ ДЛЯ АНАЛИЗА МЕТАПРЕДМЕТНЫХ ОБРАЗОВАТЕЛЬНЫХ РЕЗУЛЬТАТОВ ОБУЧЕНИЯ НА УРОВНЕ ОСНОВНОГО ОБЩЕГО ОБРАЗОВАНИЯ	156
7. СПОРТ	161
ПОСТРОЕНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ ПРОГНОЗИРОВАНИЯ РЕЗУЛЬТАТОВ НАЦИОНАЛЬНОЙ ХОККЕЙНОЙ ЛИГИ	162
НЕЙРОСЕТЕВОЙ МЕТОД ЭФФЕКТИВНОСТИ БЮДЖЕТНОГО СУБСИДИРОВАНИЯ ПРИ ВНЕДРЕНИИ ВСЕРОССИЙСКОГО КОМПЛЕКСА ГТО ...	168
ОЦЕНКА ПРОХОЖДЕНИЯ БАСКЕТБОЛЬНЫХ КОМАНД В ФИНАЛ НАЦИОНАЛЬНОЙ БАСКЕТБОЛЬНОЙ ЛИГИ МЕТОДОМ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ.....	174
НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ СТАТИСТИКИ СТРЕЛЬБЫ В СОРЕВНОВАНИЯХ ПО БИАТЛОНУ	178
8. ИНТЕЛЛЕКТУАЛЬНЫЕ И ЭМОЦИОНАЛЬНЫЕ РОБОТЫ	185
СПЕЦИАЛЬНЫЙ АЛГОРИТМ БОТА-СОБЕСЕДНИКА.....	186
МАТЕМАТИЧЕСКИЕ МОДЕЛИ ВОСПИТАНИЯ ГРУППЫ РОБОТОВ С НЕАБСОЛЮТНОЙ ПАМЯТЬЮ	192
ОСНОВНЫЕ ПОЛОЖЕНИЯ МАТЕМАТИЧЕСКОЙ ТЕОРИИ АМБИВАЛЕНТНЫХ ПСЕВДОЭМОЦИЙ РОБОТОВ.....	196
9. МАТЕМАТИЧЕСКАЯ ФИЗИКА И ПРОМЫШЛЕННОСТЬ	201
ПЕРСПЕКТИВЫ ИНТЕЛЛЕКТУАЛЬНОГО МОДЕЛИРОВАНИЯ ФИЗИЧЕСКИХ ПРОБЛЕМ НА СУПЕРКОМПЬЮТЕРАХ.....	202
СРАВНИТЕЛЬНЫЙ АНАЛИЗ ОДНОСЛОЙНОГО И МНОГОСЛОЙНОГО РЕШЕНИЙ ЗАДАЧИ О ПОРИСТОМ КАТАЛИЗАТОРЕ	208
О МОДИФИКАЦИИ КЛАССИЧЕСКИХ ИТЕРАЦИОННЫХ МЕТОДОВ ДЛЯ ПОЛУЧЕНИЯ НЕПРЕРЫВНЫХ РЕШЕНИЙ НА ПРИМЕРЕ ЗАДАЧИ ТЕПЛОПРОВОДНОСТИ	214
10. МЕТОДЫ И ИНСТРУМЕНТЫ СОЗДАНИЯ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ	220
ВЕРОЯТНОСТНОЕ МОДЕЛИРОВАНИЕ ТЯЖЕЛОХВОСТЫХ РАСПРЕДЕЛЕНИЙ ...	221
ПОСТРОЕНИЕ «УСПЕШНОЙ» ПРОГНОЗИРУЮЩЕЙ НЕЙРОСЕТИ	226

ОБ ОДНОМ ПОДХОДЕ К ПОСТРОЕНИЮ СТРУКТУРЫ БАЗЫ ЗНАНИЙ ЭКСПЕРТНОЙ СИСТЕМЫ	229
АНАЛИЗ МЕТОДОВ БИНАРНОЙ КЛАССИФИКАЦИИ ДЛЯ ПРОГНОЗИРОВАНИЯ ПОСЛЕОПЕРАЦИОННЫХ ОСЛОЖНЕНИЙ У БОЛЬНЫХ ЖЕЛЧНО-КАМЕННОЙ БОЛЕЗНЬЮ	236
МЕТОД ГРУППОВОГО УЧЕТА АРГУМЕНТА В ЗАДАЧАХ ФОРМИРОВАНИЯ КЛАССИФИКАТОРОВ ДЛЯ ПРОГНОЗИРОВАНИЯ ПРОФЕССИОНАЛЬНЫХ ЗАБОЛЕВАНИЙ	240

1. ПЛЕНАРНЫЕ ДОКЛАДЫ

О ПРИОРИТЕТЕ СОВЕТСКОЙ НАУКИ В ОБЛАСТИ НЕЙРОИНФОРМАТИКИ. В ПАМЯТЬ О ПРОФЕССОРЕ АЛЕКСАНДРЕ ИВАНОВИЧЕ ГАЛУШКИНЕ

Ясницкий Леонид Нахимович

Пермский государственный национальный исследовательский университет,
614600, г.Пермь, ул. Букирева, 15, yasn@psu.ru

Кратко прослеживается история развития нейроинформатики. Анализируются причины кризиса нейроинформатики второй половины XX века, сравниваются методы и результаты американской и советской научных школ в преодолении этого кризиса. Обосновывается приоритет советских ученых в открытии первых алгоритмов обучения многослойных перцептронов, отмечается влияние этого открытия на последующие успехи нейроинформатики. Статья посвящена памяти профессора А.И.Галушкина – одного из авторов открытия указанных алгоритмов.

Ключевые слова: искусственный интеллект, нейронные сети, многослойный перцептрон, обучение, открытие, алгоритм.

Сегодня применение нейроинформационных технологий обеспечило успех множества инновационных проектов во многих областях. Ведущие аналитики мира единогласно зачислят нейронные сети в ТОП самых перспективных технологий. Они в центре внимания многих инвестиционных фондов. Их изучение включено в учебные программы лучших вузов и учебных центров. «В некоторых кругах незнание нейронных сетей начинает трактоваться как светская бестактность!» [1].

Но не всегда нейроинформатика была на пике своей популярности. История ее становления, как научной области, знает немало драматических событий – головокружительных подъемов и не менее впечатляющих падений. Датой рождения новой науки считается середина XX века, ознаменовавшаяся появлением первого нейрокомпьютера – перцептрона – устройства, сконструированного «по образу и подобию» человеческого мозга, обученного типичным для обучения живых существ методом «поощрения-наказания», способного решать сложнейшую для того времени интеллектуальную задачу – распознавать буквы латинского алфавита. Это был головокружительный успех в познании самой природы человеческого мышления. Это была сенсация, приковавшая к себе внимание мыслящих людей всего мира. Мозг начал раскрывать свои тайны. Казалось, что ключ к интеллекту был найден и полное воспроизведение человеческого мозга и всех его функций – всего лишь вопрос времени. Писателям-фантастам, ученым и инженерам, бизнесменам и политикам виделись самые радужные перспективы практического применения идей искусственного интеллекта. Правительство Соединенных Штатов Америки выделило крупные субсидии на

развитие нового научного направления. Особое внимание уделялось проекту создания системы распознавания летящих объектов «Свой-Чужой». Актуальность этого проекта была тем выше, чем сложнее становились отношения между США и СССР, достигшие своего апогея во времена Карибского кризиса 1962-го года.

Но случилось непредвиденное. Если при обучении распознаванию букв погрешность перцептрона быстро падала, то при обучении распознавания летящих объектов она и не снижалась. Проект государственной важности был провален. Новая наука зашла в тупик. Настроения общественности резко изменились. Для нейроинформатики наступили «черные дни». Нейроинформатике присвоили статус «тупикового научного направления». Кризис нейроинформатики в Америке затянулся более чем на 20 лет. Вот, например, высказывание одного из учеников У.Мак-Каллока, известного специалиста в области искусственного интеллекта, свидетеля тех событий А.Эндрю [2, с. 154], опубликованное им в 1976 году: «Сегодня уже не воспринимаются всерьез предположения, высказанные в первых работах по перцептронам...».

Тем не менее, идея использования нейрокомпьютеров в системах распознавания «Свой-Чужой» была успешно реализована, но... в другой стране и в другое время. Только к началу 80-х годов, т.е. спустя 20 лет после провала американского проекта, мир узнал о появлении в Советском Союзе нейрокомпьютерных систем, причем не только решающих проблему распознавания «Свой-Чужой», но и управляющих полетами ракет и самолетов. Причем, эти нейрокомпьютеры обнаружили еще одно свойство, унаследованное от мозга – свойство живучести. Они стойко переносили довольно серьезные повреждения, продолжая работать в сложных условиях воздействия окружающей среды, что было особенно важно для объектов военного назначения.

В чем же была причина провала американского проекта, и почему он получился в СССР? В чем была причина кризиса нейроинформатики начала второй половины XX века, и благодаря какому открытию этот кризис был преодолен?

Дело было в том, что нейронные сети, известные в середине 50-х годов прошлого столетия, не имели скрытых нейронных слоев, либо их синаптические веса не корректировались ввиду отсутствия эффективных алгоритмов обучения. Многие исследователи понимали, что нужно создавать нейросети более сложной архитектуры, содержащие настраиваемые скрытые слои нейронов, но не представляли, как такие сети обучать. Правила Хебба и дельта-правило годились только для корректировки синаптических весов нейронов выходного слоя, тогда как вопрос о настройке параметров скрытых нейронных слоев оставался нерешенным.

Как отмечается во многих изданиях, особенно зарубежных, первым эффективным алгоритмом обучения многослойных персептронов, открывшим путь их широкому практическому применению, был алгоритм обратного распространения ошибки, описанный Д.Румельхартом, Г.Хинтоном и Р.Вильямсом [3] в 1986 году при работе над проектом по Параллельным распределенным вычислениям.

Однако этот алгоритм, как и многие другие выдающиеся научные открытия, на самом деле имеет несколько авторов. Так, впоследствии выяснилось, что алгоритм обратного распространения ошибки был предложен на один год ранее в работах А.Паркера и А.Ле-Кана, изданных независимо одна от другой, а еще на 11 лет раньше (1974 г.) этот алгоритм был защищен П.Дж.Вербосом [4] в его докторской диссертации.

Кроме того, на западе долгое время не было известно, что идеи и алгоритмы обучения многослойных структур персептронного типа были опубликованы в еще более ранних трудах советских ученых: А.И.Галушкина, В.А.Ванюшина, Б.П.Тюхова [5-7], относящихся к 1972 – 1974 гг. Кульминацией серии работ по алгоритмы обучения многослойных структур того времени стала монография А.И.Галушкина "Синтез многослойных систем распознавания образов", 1974 г. [7]. Как показано Э.Д.Аведьяном [10], алгоритмы американской [3, 4] и советской [5-9] научных школ отличаются, главным образом, лишь способом вычисления градиента минимизируемого функционала, причем оба алгоритма приводят к одинаковым положительным результатам.

Сравнивая даты первых публикаций (1972 и 1974 гг.), нетрудно сделать вывод о том, что советские ученые нашли выход из кризиса нейроинформатики, по крайней мере, на два года раньше американских. На основании этого в работе [10] сделано заключение о приоритете советских ученых в этом замечательном научном открытии.

Теперь, спустя более 40 лет после тех поворотных событий, мы можем в полной мере понять и оценить историческую роль этого научного открытия, сделанного независимо советскими и американскими учеными. Именно благодаря этому открытию прекратился затянувшийся более чем на 20 лет кризис нейроинформатики второй половины XX века. Нейроинформатика вышла из тупика и стала лидирующей научной областью современности. И мы можем утверждать, что пальма первенства в этом научном открытии принадлежит коллективу наших соотечественников, в частности – нашему коллеге и учителю Александру Ивановичу Галушкину.

В 2016 году выпущена в свет еще одна книга, в которой еще раз обоснован приоритет Советской науки в разрешении кризиса нейроинформатики [11, с.70]. Книга имеет гриф

учебника для вузов, присвоенный Учебно-методическим отделом по классическому университетскому образованию России.

Библиографический список

1. Элементарное введение в технологию нейронных сетей с примерами программ / Перевод с польского И.Д. Рудинского. – М.: Горячая линия – Телеком, 2011. – 408 с.
2. Эндрю Э. Искусственный интеллект / Перевод с английского В.Л. Стефанюка под ред. Д.А. Пospelова. – М.: Мир, 1985. 265с.
3. Rumelhart D.E., Hinton G.E., Williams R.J. Learning internal representations by error propagation. // In: D.E. Rumelhart and J.L. McClelland, Eds., Parallel Distributed Processing. Cambridge, MA: The MIT. Press. 1986. Vol. 1. P. 318-362.
4. Werbos P.J. Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences // Phd Thesis, Dept. of Applied Mathematics. Harvard University, Cambridge, MA., 1974.
5. Ванюшин В.А., Галушкин А.И., Тюхов Б.П. Построение и исследование оптимальных многослойных систем распознавания образов в режиме обучения // Сб. "Некоторые вопросы биологической кибернетики" под ред. акад. Берга А.Л. Изд-во Наука: 1972. С. 315-323.
6. Галушкин А.И. Об алгоритмах адаптации в многослойных системах распознавания образов // Доклады АН УССР (представлено акад. Глушковым В.М.). 1973. Т.91. № I, С. 15-21.
7. Галушкин А.И. Синтез многослойных систем распознавания образов. – М.: «Энергия», 1974. 367с.
8. Галушкин А.И., Симоров С.Н. Нейросетевые технологии в России (1982-2010). М.: Горячая линия-Телеком, 2011. 316 с.
9. Галушкин А.И. Нейронные сети: основы теории. М: Горячая линия–Телеком, 2012. 496 с.
10. Аведьян Э.Д. Исторические аспекты развития теории многослойных нейронных сетей // Информационные технологии. 2005. № 12. С. 67-75.
11. Ясницкий Л.Н. Интеллектуальные системы : учебник. М.: Лаборатория знаний, 2016. 221с.

THE PRIORITY OF SOVIET SCIENCE IN THE AREA OF NEUROINFORMATICS. IN MEMORY OF PROFESSOR ALEXANDER IVANOVICH GALUSHKIN

Leonid N. Yasnitsky

Perm State University, 614600, Perm, Russia, Bukirev St., 15, yasn@psu.ru

This article briefly traces the history of the development of Neuroinformatics. Analyzed the causes of the crisis of Neuroinformatics second half of the twentieth century. Made sravnenie methods and results of the American and Soviet scientific schools in overcoming this crisis. Justified the priority of Soviet scientists in the opening of the first algorithms for training multilayer perceptrons. Otmecheno the impact of this discovery on subsequent success of Neuroinformatics. The article is dedicated to the memory of Professor A. I. Galushkin, one of the authors of the discovery of these algorithms.

Keywords: artificial intelligence, neural networks, multilayer perceptron, learning, discovery, algorithm.

НЕЙРОСЕТЕВОЙ ПОДХОД КАК ПУТЬ ДАЛЬНЕЙШЕГО РАЗВИТИЯ СИСТЕМНЫХ ИДЕЙ В ТЕОРИИ ИНТЕГРАЛЬНОЙ ИНДИВИДУАЛЬНОСТИ
В.С. МЕРЛИНА

*Вяткин Бронислав Александрович, Калугин Алексей Юрьевич,
Попова Варвара Владимировна*

Пермский государственный гуманитарно-педагогический университет,
614990, г. Пермь, ул. Сибирская, 24, bronislav.vyatkin@gmail.com

В статье рассматриваются системные идеи, лежащие в основе теории интегральной индивидуальности (ИИ), предложенной В.С. Мерлиным. Отмечается актуальность данных идей в свете постнеклассической парадигмы в науке. Раскрываются перспективы и потенциал развития теории интегральной индивидуальности, а также возможности использования нейронных сетей для изучения полиморфных связей в ИИ.

Ключевые слова: теория интегральной индивидуальности, системность и полисистемность, полиморфизм, иерархия, нейронные сети.

В январе 2018 года психологическая общественность отмечает 120 лет со дня рождения выдающегося отечественного психолога В.С. Мерлина, автора теории интегральной индивидуальности (ИИ). В основе теории ИИ лежат некоторые фундаментальные системные идеи: структурных уровней, телеологической детерминации и полиморфизма [2]. Указанные идеи не потеряли своей значимости и сейчас, спустя три десятилетия после публикации «Очерка интегрального исследования индивидуальности» [4], более того, открываются новые перспективы системных исследований в рамках данной теории. В настоящей статье намечаются возможные точки соприкосновения теории ИИ и теории нейронных сетей в современных психологических исследованиях.

В становлении психологии как науки выделяют доклассический, классический, неклассический и постнеклассический этапы [3]. Доклассический этап характеризовался развитием психологического знания в рамках философии, классическая психология, по сути, апеллировала к детерминизму Лапласа – жесткой причинности; опиралась на простые системы (понимание сознания в концепциях В.Вундта и Э.Титченера, памяти в теории Г. Эббингауза и высшей нервной деятельности И.П. Павловым и др.). В отличие от классической, неклассическая парадигма опиралась на сложноорганизованные и саморегулирующиеся системы, в которых целое не сводимо к сумме образующих его элементов, а детерминизм – вероятностный (сюда относится, например, общая теория систем Л. фон Берталанфи, кибернетика, физиология активности Н.А. Бернштейна и т.п.). Предметом постнеклассической науки являются сложные саморазвивающиеся системы [3].

Как отмечает Ю.П. Зинченко: саморазвивающимся системам «присуща иерархия уровневой организации элементов и способность порождать новые уровни, оказывающие обратное воздействие на ранее сложившиеся, формируя новые, относительно самостоятельные подсистемы. Такая система на каждом этапе развития сохраняет свою открытость и обмен с внешней средой» [3, с. 47]. Вероятностная причинность в постнеклассической парадигме видоизменяется благодаря появлению «целевой причинности»: «В ходе развития меняется мера вероятности события. То, что представлялось маловероятным в начальном состоянии развития, может стать более вероятным при формировании новых уровней организации» [Там же, с. 47-48].

Обсуждая системный подход, нельзя обойти вниманием идеи, высказанные П.К. Анохиным при разработке теории функциональных систем. П.К. Анохин активно критиковал общую теорию систем Л. фон Берталанфи за отсутствие системообразующего фактора и выдвигал ряд положений, которые могли бы характеризовать полноценную общую теорию систем:

«1. Теория может получить право стать общей только в том случае, если она вскрывает и объединяет собой такие закономерности процессов или механизмов, которые являются изоморфными для различных классов явлений.

2. Изоморфизм явлений различных классов может быть выявлен только в том случае, если мы найдем достаточно убедительный критерий изоморфности. Чем более значимым является этот критерий для разрабатываемых явлений, тем более выраженным является их изоморфизм.

3. Для принятия «общей теории систем», пригодной для различных классов явлений, наиболее важным критерием изоморфности, естественно, является изоморфность системообразующего фактора» [1, с. 61].

Идеи иерархичности, изоморфизма и системообразующего фактора в полной мере представлены в концепции интегральной индивидуальности В.С. Мерлина, что позволяет отнести его теорию к теориям постнеклассического этапа развития науки. За последние 30 лет теория ИИ активно развивалась его учениками и последователями, мы приведем лишь некоторые системные идеи, развиваемые в рамках теории, которые наиболее актуальны сейчас.

Так многокачественность проистекает из того, что она содержит в себе качество самостоятельной системы и в то же время актуализирует качества больших систем – социальной и биологической, в которые входит. Иерархичность обнаруживается в уровне строения: в интегральной индивидуальности выделяется некоторое множество относительно

самостоятельных уровней, каждый из которых подчиняется своим закономерностям, из чего возникает многомерность.

Ряд предпосылок указывает на правомерность иерархизации ИИ.

1. Индивидуальные свойства, принадлежащие разным уровням ИИ, возникли на разных ступенях филогенеза и онтогенеза, начиная от биохимических свойств и кончая социальным статусом человека в группе и обществе. Они приобрели устойчивый характер и сохранились в форме относительно автономных систем и подсистем.

2. На каждом иерархическом уровне действуют специфические каузальные закономерности, например, биохимические, нейродинамические, психодинамические, личностные, социально-психологические, социально-исторические.

3. Уровни ИИ не только обособляются. Их свойства вступают в отношения друг с другом, а телеологический тип детерминации обеспечивает их связи. По В. С. Мерлину, уровни ИИ параллельны и равнозначны – в том значении, что между ними возникают не каузальные отношения. Вместо них полиморфные связи скрепляют разноуровневые свойства.

4. Разноуровневые индивидуальные свойства отличаются от одноуровневых по типу взаимного соответствия. Внутриуровневые связи свойств носят однозначный характер, межуровневые связи свойств – много-многозначный (полиморфный) характер.

5. Представителями отдельного уровня ИИ выбираются не изолированные свойства, а те из них, которые связаны и образуют относительно замкнутую подсистему. Например, маркерами нейродинамического уровня могут быть показатели силы и лабильности, потому что их сочетание характеризует тип нервной системы. Маркерами психодинамического уровня могут быть эмоциональность и экстраверсия–интроверсия, потому что их сочетание характеризует тип темперамента [2].

Особую роль в понимании интегральной сущности индивидуальности, играет выход за пределы каузального типа детерминации, где существенную роль занимает телеологический тип детерминации. Они выражаются в особом характере связей свойств разных уровней интегральной индивидуальности. Если каузальный тип детерминации дифференцирует индивидуальность на отдельные уровни, то телеологический тип детерминации обеспечивает их интеграцию. Через телеологическую детерминацию и иерархию интегральной индивидуальности определяется полиморфизм.

В русле общей теории систем суть полиморфизма выражается в том, что одна и та же система может принимать несколько разных форм. Между ними могут возникать отношения транзитивности, они могут изменяться, приобретать новые качества и свойства, развиваться. При этом удержание системы в состоянии целостности, несмотря на разнообразие форм ее

существования – основной результат процессов полиморфизации. Разновидностью полиморфизма является изомерия, суть которой заключается в том, что один и тот же состав компонентов может быть основанием для разных явлений – в зависимости от того, как компоненты взаимосвязаны.

В последние годы получен ряд данных, в которых эмпирическим путем совершена попытка зафиксировать эффект изомерии – качественные преобразования системы разноуровневых свойств индивидуальности в разных видах деятельности при изменении их условий в труде (Ковтун, 2015), искусстве (Соснина, 2014) и спорте (Вяткин, Попова, 2012) (см. также [5]).

В наших исследованиях для анализа и интерпретации данных обычно используются линейные корреляции. Достаточно ли этого для выявления механизмов данных явлений? Каковы настоящие механизмы полиморфизма и изомерии? Очевидно, для интерпретации полученных данных целесообразно использовать нейросетевые технологии.

Надеемся, что применение нейросетевых технологий, в том числе и неклассических нейронных сетей (Ясницкий, 2016), усилит эмпирические подтверждения ряда системных идей в теории В.С. Мерлина, что позволит расширить имеющиеся представления о механизмах межуровневых связей индивидуальных свойств – полиморфизма и изомерии.

Библиографический список

1. Анохин П.К. Философские аспекты теории функциональной системы: Избранные труды. М.: Наука, 1978. 400 с.
2. Вяткин Б.А., Дорфман Л.Я. Теория интегральной индивидуальности В.С. Мерлина: история и современность // Образование и наука. 2017. Т. 19. № 2. С. 145-160. DOI: 10.17853/1994-5639-2017-2-145-160.
3. Зинченко Ю.П. Методологические проблемы фундаментальных и прикладных психологических исследований // Национальный психологический журнал. 2011. № 1 (5). С. 42-49.
4. Мерлин В.С. Очерк интегрального исследования индивидуальности. М.: Педагогика, 1986. 256 с.
5. Психология интегральной индивидуальности: Пермская школа / Сост. Б.А. Вяткин, Л.Я. Дорфман, М.Р. Щукин. М.: Смысл, 2011. 636 с.

NEURAL NETWORK APPROACH AS A WAY OF FURTHER DEVELOPMENT OF SYSTEMIC IDEAS IN THE THEORY OF INTEGRAL INDIVIDUALITY BY V.S. MERLIN

Vyatkin Bronislav Aleksandrovich, Kalugin Aleksey YUR'evich,
Perm State Humanitarian Pedagogical University,
Perm, 614990, Sibirskaya Str., 24, bronislav.vyatkin@gmail.com

The article considers systematic ideas with underlying the theory of integral individuality, offered by V.S. Merlin. The relevance of these ideas is noted in the light of the postnonclassical paradigm in science. The prospects and potential of development of the theory of integral individuality, as also is possibility of using neural networks for studying polymorphic connections in the integral individuality, are revealed.

Keywords: theory of integral individuality, systemic and multi-systemic viewpoints, polymorphism, hierarchy, neural networks.

УДК 519.23

ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ ТЕРМОМЕТРИЧЕСКИХ ДАННЫХ В ДИАГНОСТИКЕ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ²

Лосев Александр Георгиевич, Левшинский Владислав Викторович

Волгоградский государственный университет, 400062, Россия, г. Волгоград,
пр. Университетский, 100, alexander.losev@volsu.ru, vladi.lev.email@gmail.com

Целью данного исследования является разработка методов и алгоритмов искусственного интеллекта, предназначенных для анализа и интерпретации медицинских данных, получаемых с помощью микроволновой радиотермометрии. На их основе планируется создание технологии разработки соответствующих консультативных интеллектуальных систем, т.е. экспертных систем, содержащих механизм объяснения и обоснования предлагаемых решений на языке, понятном пользователю. Основной задачей данного исследования является разработка метода формирования пространства информационных признаков. В основе получения его элементов лежит количественное описание медицинских знаний о поведении температурных полей молочных желез. Также описывается метод обнаружения новой медицинской информации, базирующийся на изучении изменения внутреннего градиента температурного поля пациентки, т.е. использующий параметры соответствующих физико-математических моделей.

Ключевые слова: интеллектуальный анализ данных, микроволновая радиотермометрия, консультативные интеллектуальные системы, маммология, онкология.

Данное исследование выполнено в рамках тематики, посвященной разработке диагностических технологий, основанных на интеграции современных достижений медицины и математических методов искусственного интеллекта. В настоящее время трудности диагностики зачастую возникают не как следствие дефицита информации, но из-за недостатков методов ее обработки. Решение указанных проблем обеспечивает создание консультативных интеллектуальных систем, т.е. экспертных систем, содержащих механизм объяснения и обоснования предлагаемых решений на языке, понятном пользователю.

² Публикация подготовлена при финансовой поддержке РФФИ и Администрации Волгоградской области (грант № 15-47-02475-р_поволжье_a).

© Лосев А.Г., Левшинский В.В., 2017

В работе развивается новый метод интеллектуального анализа данных микроволновой радиотермометрии в применении к диагностике рака молочной железы. Микроволновая радиотермометрия – биофизический метод неинвазивного обследования, заключающийся в измерении внутренних и поверхностных температур тканей по интенсивности их теплового излучения, соответственно, в микроволновом (РТМ) и инфракрасном (ИК) диапазонах. Комплекс РТМ-01-РЭС позволяет оценивать функциональное состояние тканей путем измерения внутренней температуры (РТМ) на глубине до 5 см. и температуры кожи (ИК). Обследование начинается с измерения температур в опорных точках Т1 и Т2, расположенных, первая – в центре грудной клетки сразу под и между молочными железами, вторая – непосредственно под мечевидным отростком. Далее измерения проводятся в 10 точках на каждой железе, и в аксиллярной области (схема представлена на Рис. 1).

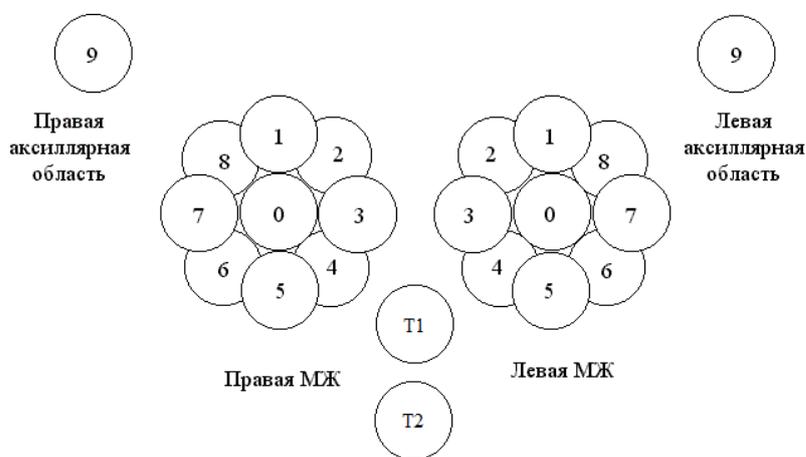


Рисунок 1 – Схема обследования молочной железы

В течение последних нескольких лет формировалась экспертная база термометрических данных, которые предоставлялись онкологическими центрами. В настоящее время она включает в себя информацию о 734 молочных железах пациенток, которые делятся на следующие группы: «Здоровые» – 148 молочных желез, «Узловой рак» (185 молочных желез), «Диффузный рак» (13 молочных желез), «Узловые изменения, но не рак» (90 молочных желез), «Диффузные изменения, но не рак» (125 молочных желез), «Неотдифференцированные гистологически» (8 молочных желез), «Норма-2» (165 здоровых молочных желез больных пациенток).

В ходе исследований и анализа данных, специалистами были выявлены следующие качественные признаки рака молочной железы: повышенная величина термоасимметрии между одноименными точками молочных желез; повышенный разброс температур между отдельными точками в пораженной молочной железе; повышенная дисперсия разности

температур между железами; разница температур сосков; повышенная температура соска в пораженной молочной железе по сравнению со средней температурой молочной железы с учетом возрастных изменений температуры; соотношение кожной и глубинной температур; повышенное значение осцилляции температур в областях и некоторые другие.

На первом этапе исследования был сформирован набор функций, который представляет собой достаточно серьезно расширенное описание известных качественных признаков и получен на базе уже известных медицинских фактов. Например, асимметрия полей температур молочных желез может быть описана различными функциями вида

$$g(f(t_{0,пр}, \dots, t_{n,пр}) - f(t_{0,л}, \dots, t_{n,л})),$$

где $f(t_{0,пр}, \dots, t_{n,пр})$ – значение функции температур для точек t_0, \dots, t_n правой молочной железы, $f(t_{0,л}, \dots, t_{n,л})$ – значение аналогичной функции температур для точек t_0, \dots, t_n левой молочной железы, а $g(x)$ – некоторая функция одного переменного.

Но особенно важной, задачей интеллектуального анализа данных, является выявление новых знаний. За последние годы было построено несколько математических моделей, описывающих поведение температурных полей молочных желез с помощью уравнений в частных производных второго порядка [1]. Для обнаружения аномалий температурных полей пациенток, оказалось значимым изучение поведения разностных аналогов вторых производных функции температур. А именно, рассматривались функции вида:

$$\nabla(t_0 - f(t_0, \dots, t_n)) = t_{0,РТМ} - f(t_{1,РТМ}, \dots, t_{n,РТМ}) + t_{0,ИК} - f(t_{1,ИК}, \dots, t_{n,ИК}).$$

Всего при исследовании рассмотрено порядка 900 числовых функций.

Перейдем к точным определениям информативных диагностических признаков. Обучающую выборку представим в виде матрицы:

$$S = \begin{pmatrix} t_0^1 & \dots & t_{43}^1 \\ \vdots & \ddots & \vdots \\ t_0^k & \dots & t_{43}^k \\ t_0^{k+1} & \dots & t_{43}^{k+1} \\ \vdots & \ddots & \vdots \\ t_0^n & \dots & t_{43}^n \end{pmatrix},$$

где t_i^j при $j = 1, \dots, k$ – температуры молочных желез пациенток класса «Здоровые (отсутствие рака МЖ)», t_i^j при $j = k + 1, \dots, n$ – температуры молочных желез пациенток класса «Больные (рак МЖ)». Пусть f_q – q-я исследуемая функция, рассматриваемая на

множестве векторов $\Omega_q = \{(t_0^j, \dots, t_{43}^j)\}$, где $j = 1, \dots, n$. Обозначим $f_j^q = f^q(t_0^j, \dots, t_{43}^j)$.

Высокоинформативным признаком будем называть тройку (f^q, V, X) , где f^q – функция, описывающая поведение температурных полей, $V = I(f^q, X)$ – информативность признака, X – «информативная» область множества значений функции f^q .

Определим, указанные выше характеристики. Под информативностью традиционно понимается количественный параметр, определяющий, насколько хорошо закономерность описывает различия между искомой и отделяемой группами. В качестве $I(f^q, X)$ в данной работе использовались статистическая, эвристическая, энтропийная и комбинированные информативности (см., например, [2]). Например, энтропийная информативность, вычисляется по формуле:

$$EN(f^q, X) = H\left(\frac{k}{k+(n-k)}, \frac{(n-k)}{k+(n-k)}\right) - \frac{k+(n-k)-h-s}{k+(n-k)} H\left(\frac{k-h}{k+(n-k)-h-s}, \frac{(n-k)-s}{k+(n-k)-h-s}\right),$$

где n – количество векторов с температурными данными пациенток в выборке, k – количество векторов с температурными данными пациенток класса «Здоровые» в обучающей выборке, h – количество молочных желез класса «Здоровые», для которых $f^q \in X$, s – количество молочных желез класса «Рак МЖ», для которых $f^q \in X$, а $H(q_0, q_1) = -q_0 \log_2 q_0 - q_1 \log_2 q_1$ – математическое ожидание количества информации.

Комбинированная информативность, вычисляется по формуле:

$$CI(f^q, X) = \sqrt[n]{I_1(f^q, X) I_2(f^q, X) \dots I_n(f^q, X)},$$

где I_1, I_2, \dots, I_n – различные информативности. Далее, пусть

$$I_s = \sup_{X_\alpha} I(f^q, X_\alpha),$$

где X_α – все возможные подобласти числовой прямой, на которых указанная информативность имеет смысл. «Информативной» областью множества значений функции f^q будем называть подмножество числовой прямой, обеспечивающее достижение (или приближение с заданной точностью) величины I_s . Для j -ых молочных желез признак (f_j^q, V, X) считается выполненным, если $f_j^q \in X$.

Для оценки эффективности диагностических методов в медицине традиционно используются следующие показатели.

Чувствительность (иначе, истинно-положительный результат диагностики):

$$Sens = \frac{TP}{DP} \times 100\%,$$

где TP – количество молочных желез класса «Больные», которые были классифицированы как «Рак МЖ», DP – общее количество молочных желез класса «Рак МЖ»;

Специфичность (иначе, истинно-отрицательный результат диагностики):

$$Spec = \frac{TN}{DN} \times 100\%,$$

где TN – множество молочных желез класса «Здоровые», которые не были классифицированы как «Рак МЖ», DN – общее количество молочных желез класса «Здоровые»;

Некоторые примеры высокоинформативных признаков приведены в таблице 1. В данном случае, при поиске использовался показатель комбинированной энтропийной и эвристической информативностей (приведены расчеты по тестовой выборке).

Таблица 1. Высокоинформативные признаки

Признак	Sens	Spec
1. $(\sqrt{t_0 - \frac{t_8+t_1+t_2+t_3+t_4}{5}}, 9.4, (-\infty, -0.44))$	28%	81%
2. $(\frac{t_{0n} + t_{1n} + t_{2n}}{3} - \frac{t_{0n} + t_{1n} + t_{2n}}{3}, 9.4, (0.81, +\infty))$	10%	97.5%
3. $(\sqrt{\frac{\sum_{i=0}^8 (t_{in} - t_{in})^2}{9}}, 9.1, (0.88, +\infty))$	35%	92.5%
4. $(\max_{i=1,8} \left\{ \left(\frac{t_0 + \sum_{j=1}^8 t_{(i+j)(\text{mod } 9)+1}}{3} \right)_n - \left(\frac{t_0 + \sum_{j=1}^8 t_{(i+j)(\text{mod } 9)}}{3} \right)_n \right\}, 9.4, (0.81, +\infty))$	40%	87.5%

Во 2-м и 3-м признаках измерения проводились в ИК-диапазоне, в 4-м - в РТМ-диапазоне.

Полученные наборы высокоинформативных признаков предназначены для обозначения найденных аномалий поведения температурных полей и обоснования предполагаемого диагноза в консультативной интеллектуальной системе. Предлагаемая их структура вполне позволяет обнаруживать и описывать особенности поведения температурных полей молочных желез на языке, понятном пользователю системы, т.е. врачу-диагносту. Кроме того, вполне обоснованным выглядит их дальнейшее использование в различных алгоритмах классификации. Для иллюстрации, проверим данную возможность с помощью логистической регрессии. В качестве основного критерия эффективности алгоритма классификации будем использовать следующий показатель:

$$D = \sqrt{Sens * Spec.}$$

Были получены следующие результаты.

Таблица № 2. Результаты работы алгоритма логистической регрессии.

Информативность	Выборка	<i>Sens</i>	<i>Spec</i>	<i>Acc</i>	D
Комбинированная эвристической и энтропийной	Обучающая	63.59	72.58	68.5	67.94
	Тестовая	61.67	74.38	68.93	67.72
Комбинированная статистической, эвристической и энтропийной	Обучающая	66.02	70.56	68.5	68.25
	Тестовая	65.83	69.38	67.86	67.58
Статистическая	Обучающая	66.5	70.56	68.72	68.5
	Тестовая	64.17	68.12	66.43	66.12
	Тестовая	68.02	53.45	65.0	60.29

Совершенно очевидно, что применение на базе полученных признаков более мощных алгоритмов классификации, например, нейронных сетей, улучшит получаемые результаты диагностики. Однако обоснование получаемых результатов будет производиться на основе полученных характеристических и высокоинформативных признаков. Впрочем, реальная чувствительность и специфичность консультационной системы должна выявляться путем опытной эксплуатации, т.е. более интересным является вопрос, насколько полученные признаки улучшат диагностику, осуществляемую специалистами.

Библиографический список

1. Лосев А.Г., Хоперсков А.В., Астахов А.С., Сулейманова Х.М. Проблемы измерения и моделирования тепловых и радиационных полей в биотканях: анализ данных микроволновой радиотермометрии// Вестник Волгоградского государственного университета. Серия 1: Математика. Физика. 2015. № 6. С. 31-71.
2. Лосев А.Г., Зенович А.В., Бочкарев О.А., Левшинский В.В. Интеллектуальный анализ многомерных термометрических данных в медицинской диагностике// Вестник Волгоградского государственного университета. Серия 1: Математика. Физика. 2016. № 5. С. 150-161.

THERMOMETRIC DATA MINING IN DIAGNOSIS OF BREAST CANCER

Losev Alexander G., Levshinsky Vladislav V.

Volgograd State University, 100, Univarsitetsky Av., Volgograd, 400062, Russia,
alexander.losev@volsu.ru, vladi.lev.email@gmail.com

The purpose of this study is to develop methods and algorithms for artificial intelligence designed for the analysis and interpretation of medical data obtained with the help of microwave radio thermometry and the creation on their basis of technology to develop an advisory intellectual system, i.e. An expert system that contains a mechanism for explaining and justifying the proposed solutions in a language that the user understands. The main objective of this study is to develop a method for the formation of a space of information features. The basis for obtaining its elements is a

quantitative description of medical knowledge about the behavior of the temperature fields of the mammary glands. A method for detecting new medical information is also described, based on the study of the change in the internal gradient of the patient's temperature field, i.e. Using the parameters of the corresponding physical and mathematical models.

Key word: data mining, microwave radiometry, intelligent advisory systems, mammalogy, oncology

2. ЭКОНОМИКА И УСТОЙЧИВОЕ РАЗВИТИЕ

ВОЗМОЖНОСТИ ОПРЕДЕЛЕНИЯ ГОДНОСТИ К ВОЕННОЙ СЛУЖБЕ МЕТОДОМ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЕ

Молчанов Евгений Викторович

Пермский государственный гуманитарно-педагогический университет,

614990, г. Пермь, ул. Пушкина, 42, molchanov1994@yandex.ru

Рассмотрены призывные мероприятия в отношении призывника. При проведении призывных мероприятий, одной из составляющих является медицинская комиссия. Призывники проходят ее в военкомате, на котором выдают заключение о пригодности к военной службе. Годность определяется в соответствии со списком болезней. От вида болезни зависит, годен ли призывник на военную службу. В статье описана нейронная сеть, обученная определять степень годности призывника к военной службе. С помощью разработанной нейронной сети определена значимость параметров, влияющих на решение комиссии.

Ключевые слова: медицинская комиссия, военной службе, программы, нейронная сеть.

При формировании нейросетевой математической модели большое значение имеет выбор значимых входных параметров, т.е. тех параметров, которые оказывают влияние на результат моделирования. После посещения сайтов, а также, исходя из доступности информации [1, 2], в качестве входных параметров нейросетевой математической модели были использованы следующие факторы (1 – означает, что болезнь присутствует, 0 – болезнь отсутствует):

1. Общее недомогание;
2. Слабость;
3. Заболевание дыхательных путей;
4. Ожирение;
5. Нарушение обмена веществ;
6. Диабет;
7. Искривление позвоночника;
8. Врожденные патологии;
9. Растяжение;
10. Раны;
11. Сосудистая непроходимость;
12. Гангрена;
13. Шизофрения;
14. Косоглазие;

15. Плохое зрение;
16. Болезни горла;
17. Острые, хронические и врожденные болезни ушных отделов.

Выходной параметр модели кодировал результат моделирования: 1 – годен к военной службе и 0 – не годен к военной службе.

Оптимальная структура нейронной сети, обеспечивающая минимальные ошибки обучения и тестирования, определенная по методике [3], представляет собой персептрон, имеющий семнадцать входных нейронов, один скрытый слой с шестью нейронами и один выходной нейрон. В качестве активационных функций выходного нейрона и нейронов скрытого слоя использовался тангенс гиперболический, а в качестве алгоритма обучения – алгоритм упругого распространения.

Ошибка обучения составила 0%, ошибка тестирования – 0,2%. Гистограмма сопоставления реальных и прогнозируемых нейронной сетью результатов на тестовом множестве примеров представлена на рис. 1.

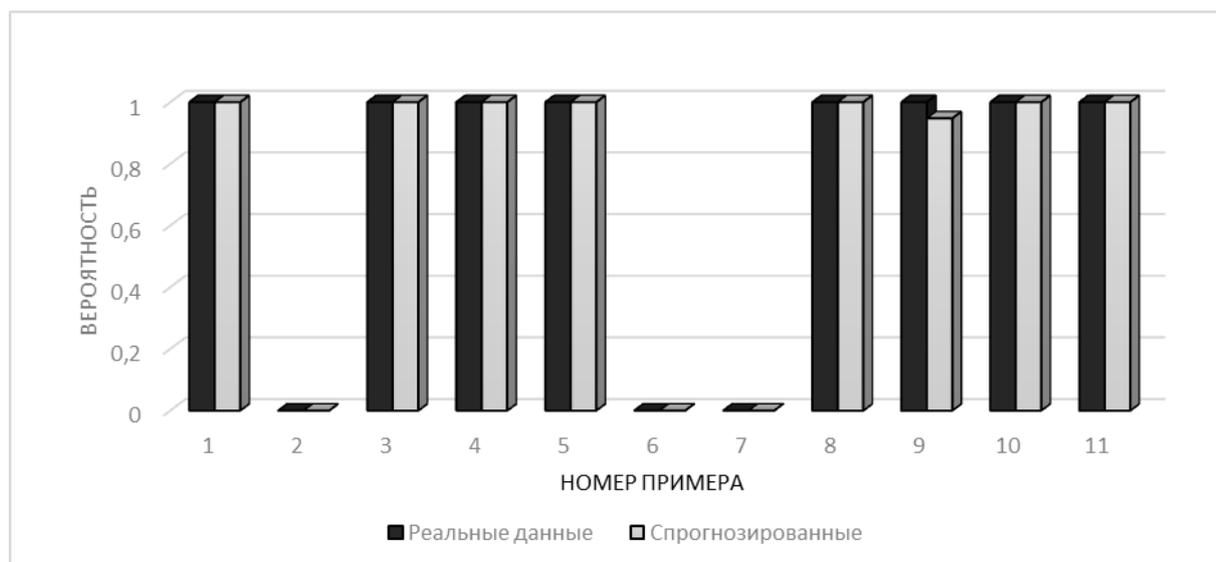


Рис. 1. Ошибка тестирования

После того, как работа нейронной сети проверена на тестовых примерах и, таким образом, доказана адекватность нейросетевой математической модели, можно приступать к ее исследованию. Обученная нейросетевая модель реагирует на изменение входных переменных и ведет себя так же, как вела бы себя сама предметная область. Поэтому с помощью нейросетевой модели можно исследовать зависимости прогнозируемой величины от ее входных параметров.

Первый вопрос, на который можно получить ответ с помощью модели – выяснить степень влияния ее входных параметров на результат – годности к военной службе.

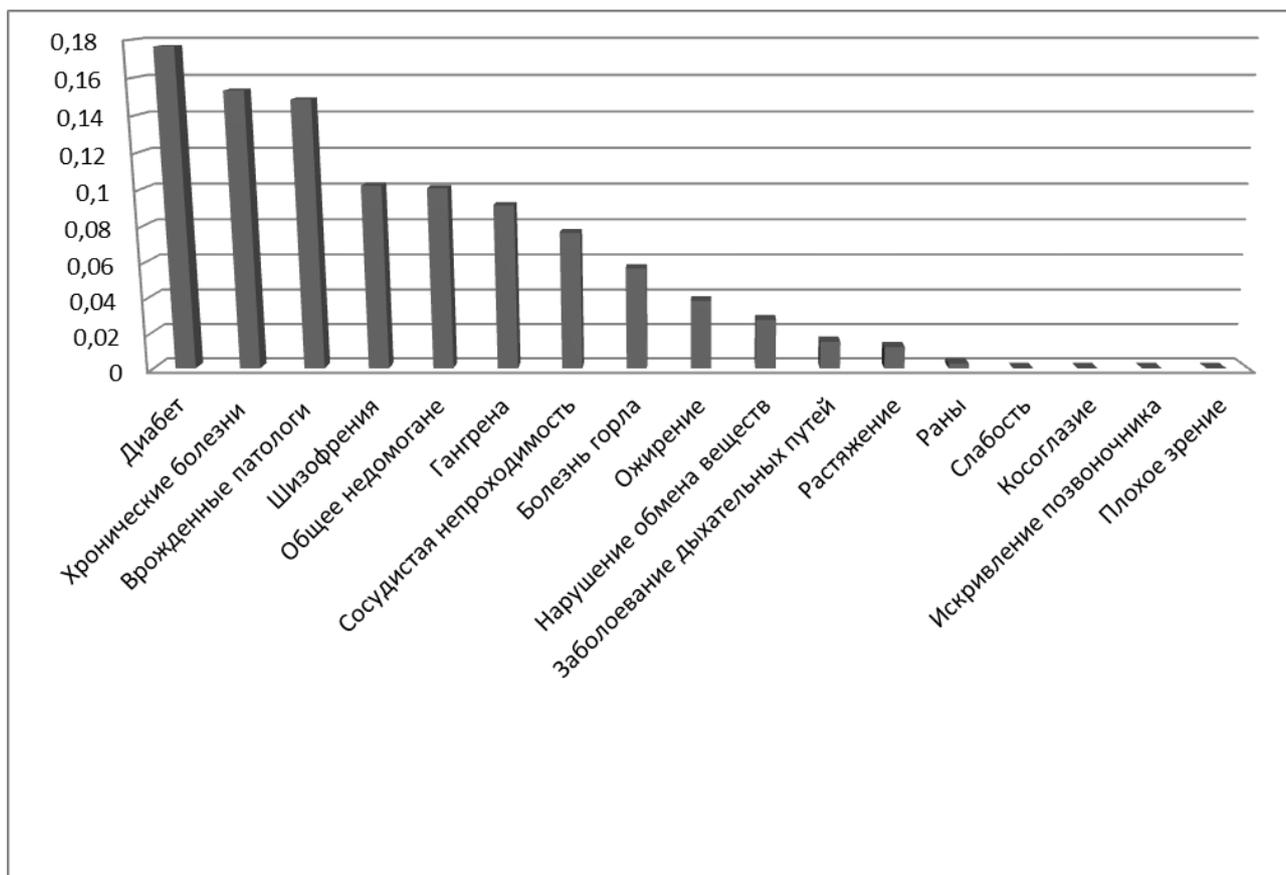


Рис. 2. Гистограмма распределения значимости входных параметров математической модели

Как видно из рисунка 2, полученного в Нейросимуляторе [4], наиболее значимым параметром оказался диабет, плохое зрение, врожденные патологии, общее недомогание и т.д. Отметим, что, в отличие от распространенных в математической статистике способов оценки значимости входных параметров в приведённой здесь методике учитывается сложный нелинейный характер выявляемых закономерностей. Кроме того, в этой методике не используется часто невыполнимая гипотеза нормального распределения случайных данных.

ЗАКЛЮЧЕНИЕ

Разработана нейросетевая математическая модель, предназначенная для проверки годности к военной службе.

С помощью математической модели выявлены наиболее значимые болезни, которые влияют на результат оценки годности к военной службе.

Библиографический список

1. Форум по медицинскому праву: <http://medzona-forum.ru/viewtopic.php?id=140>.
2. Доблесть и честь <http://doblest-chest.ru/info/voennaya-sluzhba-i-obrazovanie/315-kategorii-godnosti-k-voennoj-sluzhbe-otlichiya-kategorij-opisanie-kazhdoy>.
3. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.

4. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.

THE POSSIBILITIES OF MODELING FOR MILITARY SERVICE BY THE METHOD OF ARTIFICIAL INTELLIGENCE

Molchanov Evgeniy Viktorovich

Perm State Humanitarian and Pedagogical University, 614990, Perm, Pushkina st., 42,
molchanov1994@yandex.ru

When conducting recruitment activities with regard to the draftee, one of its components is a medical commission (medical examination). At the medical commission, a conclusion is made regarding the suitability for military service for health reasons. The category of validity is determined in accordance with the Schedule of Diseases (Appendix to the Regulations on Military Medical Examination). From the approved category of fitness for service, it depends whether he will go on to serve in the army, or will be released from the performance of military duty. In this program, we will only consider whether you are fit for military service. The program is based on a neural network.

Keywords: military service, program, neural network.

УДК 004.832.34

ИСПОЛЬЗОВАНИЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ПРОГНОЗИРОВАНИИ ПОЛА БУДУЩЕГО РЕБЕНКА

Зверева Юлия Владимировна

ФГБОУ ВПО «Пермский государственный национальный исследовательский университет»,
614990 г.Пермь, Россия, ул.Букирева, д.15, julia_zverevaa@mail.ru

В статье дается описание и анализ попытки разработать нейросетевую систему планирования пола ребенка. Рассматриваются общие параметры и их влияние на результат. Делается вывод, наиболее значимыми атрибутами являются количество родов у мамы, количество сестер у папы, возраст мамы при рождении ребенка и возраст папы при рождении ребенка.

Ключевые слова: искусственный интеллект, нейросетевые технологии, пол ребенка.

Тема планирования пола будущего ребенка всегда была и остается актуальной. Целью работы является исследование возможности прогнозирования пола будущего ребенка с помощью технологии нейронных сетей.

Впервые технология нейросетевого моделирования для построения методики прогнозирования пола будущего ребенка была применена в работе [2, с. 25]. Ее авторы использовали 10 входных параметров: возраст мужчины и женщины, разница в возрасте, месяц зачатия, роды по счету, курение, тип волос, ритм жизни, преобладание мальчиков или

девочек в роду по обеим линиям, продукты питания. Однако точность прогнозов в разных вариантах нейросетей оказалась крайне нестабильной и колебалась от 50 до 75%.

Настоящая работа выполнена по аналогичной методике и является продолжением исследований [2].

Основным источником, раскрывающим теоретические основы построения и применения нейронных сетей, являются учебные пособия [3, 4], а основным программным инструментом, предназначенным для проектирования и применения нейронных сетей – программа «Нейросимулятор 5.10» [1].

Подбирая количество примеров, необходимо принимать во внимание, что количество обучающего множества удовлетворяет требованию репрезентативности: оно больше чем $7Nx+15$, где Nx – число входных параметров [4]. В свою очередь количество примеров делится на обучающее множество и тестирующее. Проектирование сети было осуществлено в программе «Нейросимулятор 5.10» [1]. Этот программный продукт включает в себя режимы проектирования, обучения, проверки и прогноза. Первоначально необходимо определить структуру персептрона, а именно количество входных и выходных параметров, количество скрытых слоев и количество нейронов на каждом из них и активационные функции скрытых нейронов. Оптимальная структура нейронной сети представляла собой персептрон, имеющий одиннадцать входных нейронов, один скрытый слой с тремя нейронами и один выходной нейрон. В качестве активационных функций нейронов скрытого слоя и выходного нейрона использовался тангенс гиперболический, в качестве активационной функции входных нейронов – логарифмическая функция. В качестве алгоритма обучения — алгоритм упругого распространения.

Обрабатываемые данные получены с помощью социального опроса. Объем исходного множества составляет 201 пример.

Всего было использовано 11 входных параметров:

- x_1 – количество родных братьев у ребенка;
- x_2 – количество родных сестер у ребенка;
- x_3 – количество родных братьев у отца ребенка;
- x_4 – количество родных сестер у отца ребенка;
- x_5 – количество родных братьев у матери ребенка;
- x_6 – количество родных сестер у матери ребенка;
- x_7 – какие роды по счету;
- x_8 – курение отца до зачатия:
0 – не курил;

- 1 – курил.
- x_9 – курение матери до зачатия:
 - 0 – не курила;
 - 1 – курила.
- x_{10} – возраст отца при рождении ребенка;
- x_{11} – возраст матери при рождении ребенка.

Выходным параметром сети являлся пол будущего ребенка $d = 1$, если мальчик, $d = 2$, если девочка.

Результаты проверки показали, что нейросеть обучилась и предсказывает довольно близкие к реальным результаты с ошибкой в 31%. Коэффициент детерминации построенной модели для оценки ее адекватности (R^2) составил 0,27. За основу было взято тестирующее множество из 16 примеров, разницу можно посмотреть на рис.1, на котором видно, что из 16 рассмотренных примеров нейронная сеть выдала правильный результат в 10-ти случаях.

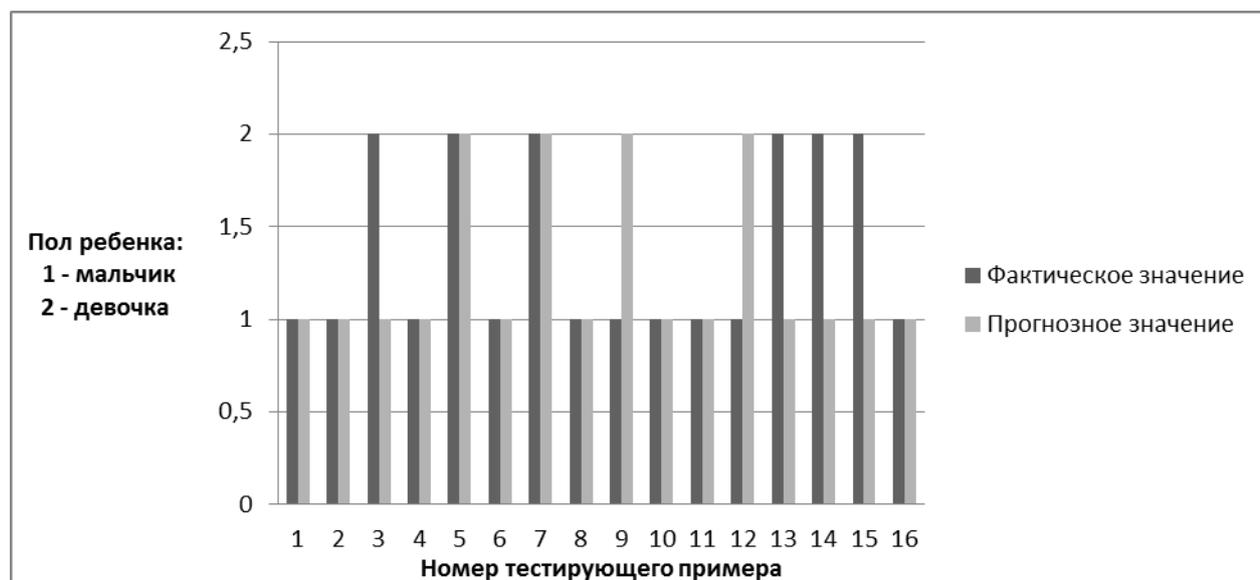


Рисунок 1 – Результат проверки работы нейронной сети на тестовых примерах

После того, как установлена адекватность нейросетевой математической модели, ее можно применять как инструмент для исследования моделируемой предметной области с целью получения новых знаний [6]. Оценка значимости параметров, выполненная в пакете [1], позволила определить, что наиболее весомыми оказались количество родов у мамы, количество сестер у папы, возраст мамы при рождении ребенка и возраст папы при рождении ребенка, что отражено на рис. 2.

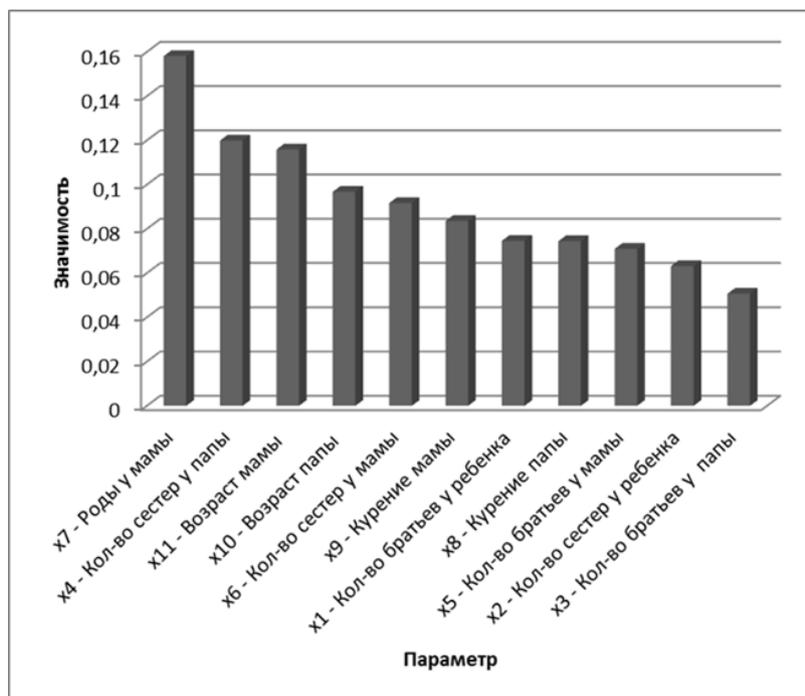


Рисунок 2 – Распределение значимости входных параметров

Рассмотрим зависимость пола ребенка от курения родителей (Рис 3). Для вывода закона этой зависимости в качестве примера неизменными мы взяли следующие параметры: возраст родителей двадцать пять лет; количество братьев и сестер у ребенка – ноль; количество братьев и сестер у родителей – по одному; роды первые. Курение папы и мамы изменяется от 0 (не курит) до 1 (курит). Для выбранных данных получилось, что рождение мальчика возможно, только если оба родителя не курят. Данный вывод согласуется с гипотезой и данными статистического анализа, выполненными датскими и японскими учеными [5].

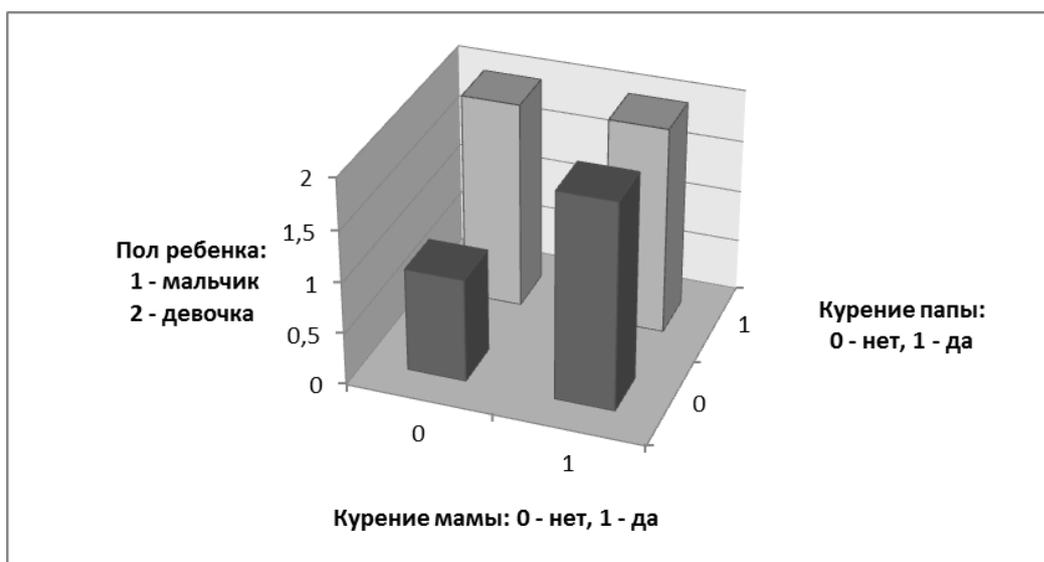


Рисунок 3 – Зависимость пола ребенка

Таким образом, в данной работе методом нейросетевого моделирования были выявлены наиболее значимые входные параметры. Предсказанные нейросетью значения пола ребенка на тестирующей выборке отличаются от реальных не более чем на 31%, что нельзя признать высококачественным результатом. Следовательно, помимо учтенных одиннадцати параметров родителей, на пол будущего ребенка влияют и другие факторы, не принятые во внимание в нашей нейросетевой модели.

Библиографический список

1. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014612546. Заявка Роспатент № 2014610341. Зарегистрировано в Реестре программ для ЭВМ 28 февраля 2014г
2. Ясницкий Л. Н., Бондарь В. В., Бурдин С. Н. и др. Пермская научная школа искусственного интеллекта и ее инновационные проекты. 2-е изд. М.; Ижевск: НИЦ «Регулярная и хаотическая динамика», 2008. 75 с.
3. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. 176 с.
4. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
5. Курящие останутся без сына URL:<http://www.materinstvo.ru/art/105/>.
6. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56.

USING METHODS OF ARTIFICIAL INTELLIGENCE IN PLANNING THE GENDER OF THE BABY

Zvereva Yulia Vladimirovna

Perm State University. Bukirev St., 15, Perm, 614990, Russia, julia_zverevaa@mail.ru

This article provides the specification and analysis of an attempt to develop a neural network system for planning the gender of the baby. The article gives a description and analysis of attempts to develop a neural network system of assessment cost parking per hour in the city of Moscow. We consider the general parameters and their influence on the result. With the elastic of the algorithm, the network is trained and tested. The conclusion, the most important attributes are the number of births to mothers, the number of nurses dad, the age of mother at birth, the age of the father at birth.

Keywords: artificial intelligence, neural network technology, the gender of the baby

УДК 004.855.5

СИСТЕМА ПРОГНОЗИРОВАНИЯ ТИПА ОСАДКОВ НА ОСНОВЕ ПОГОДНЫХ ЯВЛЕНИЙ

Константинов Денис Андреевич

Национальный исследовательский университет «Высшая школа экономики»,
614070, Россия, г. Пермь, ул. Студенческая, 38, d.a.konstantinov@outlook.com

В статье описано создание и анализ полученных результатов нейронной сети, которая прогнозирует виды осадков на основе погодных явлений. Данные были взяты с метеостанции находящейся в г. Пермь аэропорт «Большое Савино». Нейронная сеть создана

и обучена с помощью программы «Нейросимулятор». В анализе представлены проценты ошибок и сравнительная гистограмма весов каждого входного параметра для обучающей и тестовой выборки.

Ключевые слова: нейронная сеть, прогнозирование, погода, погодные явления.

Проблема с прогнозированием погоды всем известна. Люди всегда сомневаются прогнозам на какой-либо период. И обычно верят только тому, что происходит сейчас на улице. Было решено создать нейронную сеть, которая позволяла бы по входным параметрам, погодным явлениям на данный момент, определять какой тип осадков будет

Данные были выгружены с сайта <https://goo.gl/471rPH>, на котором можно найти данные метеостанции под номером 28224. Это метеостанция находится в аэропорту «Большое Савино» города Перми. Метеостанция основана в 2005 году. Но данные были взяты только за последние пять лет, чтобы выборка была оптимальной по величине. За пять лет в выборке было чуть больше двадцати тысяч записей. Данная выборка являлась хорошей для анализа, так как был большой список параметров, но его пришлось привести к виду, пригодному для обучения нейронных сетей с помощью программы excel. В приведении к нужному виду подразумевается привести все данные к числовому типу, вместо текстовых строк, а также убрать лишние и неинформативные параметры. Помимо этого, была проведена нормализация параметров [1, 2] и выделение категориальных и непрерывных входных параметров, а также разделение категориальных параметров на отдельные входные поля. Поэтому параметр «Направление ветра» из одного поля был разделен на 16 входных параметров, а выходной параметр на 10, так как в выборке было выделено 9 видов осадков и погода без осадков со значениями 0 и 1 для исключения аномалий [3]. В итоге в выборке получились следующие входные параметры:

1. Температура.
2. Атмосферное давление на уровне станции.
3. Атмосферное давление, приведенное к среднему уровню моря.
4. Относительная влажность на высоте 2 метра от земли.
5. Общая облачность.
6. Количество наблюдаемых облаков.
7. Высота образования самых низких облаков.
8. Горизонтальная дальность видимости.
9. Температура точки росы на уровне 2 метра над землей.
10. Скорость ветра.
11. Ветер (наличие).
12. Ветер, дующий с юга.

13. Ветер, дующий с юго-юго-запада.
14. Ветер, дующий с юго-запада.
15. Ветер, дующий с западо-юго-запада.
16. Ветер, дующий с запада.
17. Ветер, дующий с западо-северо-запада.
18. Ветер, дующий с северо-запада.
19. Ветер, дующий с северо-северо-запада.
20. Ветер, дующий с севера.
21. Ветер, дующий с северо-северо-востока.
22. Ветер, дующий с северо-востока.
23. Ветер, дующий с востоко-северо-востока.
24. Ветер, дующий с востока.
25. Ветер, дующий с востоко-юго-востока.
26. Ветер, дующий с юго-востока.
27. Ветер, дующий с юго-юго-востока.

А выходными параметрами являются следующие:

1. Ливень (ливни).
2. Дождь со снегом или другими видами твердых осадков.
3. Снег и/или другие виды твердых осадков.
4. Дождь.
5. Метель.
6. Морось.
7. Туман или ледяной туман, или сильная мгла.
8. Облака покрывали более половины неба в течение всего соответствующего периода.
9. Гроза (грозы) с осадками или без них.
10. Нет осадков

Нейронная сеть представляет собой многослойный персептрон [1, 2] с тремя скрытыми слоями. На первом уровне 2 нейрона, на втором уровне 4 нейрона, на третьем уровне 6 нейронов. Было экспериментально выявлено, что данное количество скрытых слоев с данным количеством нейронов показывает лучший результат, как в скорости обучения, так и в низкой ошибке.

В ходе многочисленных испытаний, была выявлена наиболее удачная конфигурация остальных параметров, где на входном, выходном и скрытых слоях в качестве

активационной функции используется тангенс гиперболический. Для обучения сети использовалась функция упругого распространения, инициализация весов происходила в автоматическом режиме (режим, используемый по умолчанию в «Нейросимуляторе 5»). Количество итераций в обучении было 3000. Ошибка при первых 100 итерациях была максимальной и составляла около 34-36%. После проведения 1000 итераций, ошибка уже была около 14-16%, после прохождения 3000 итераций обучения, сеть имела общую ошибку прогнозирования по обучающей выборке 14,9% и по тестовой выборке 14,25%.

На рисунке 2 представлено сравнение значимости параметров тестовой и обучающей выборки. самыми значимыми параметрами являются температура, горизонтальная дальность видимости, температура точки росы на уровне 2 метра над землей и скорость ветра.

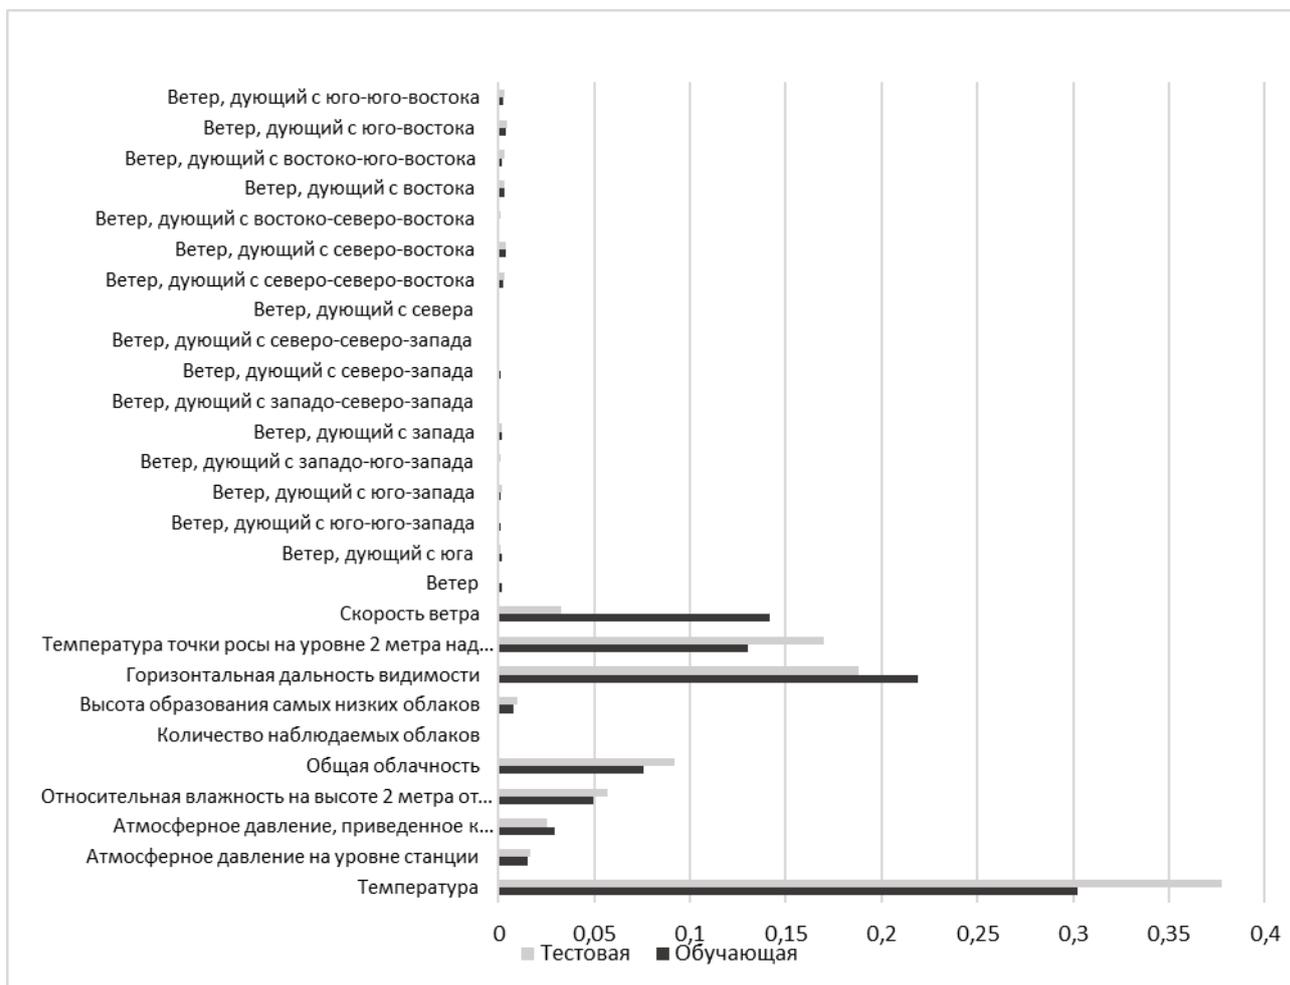


Рисунок 1. Значимость параметров

Результаты работы сети получились достаточно хорошими. Для примера были выбраны случайные результаты проверки на тестовом множестве (рис. 3 и рис. 4). На рисунке 3 видно, что результат работы сети практически сходится с ожидаемым, а на рисунке 4 можно наблюдать, что погрешность прогноза не превышает 4%.

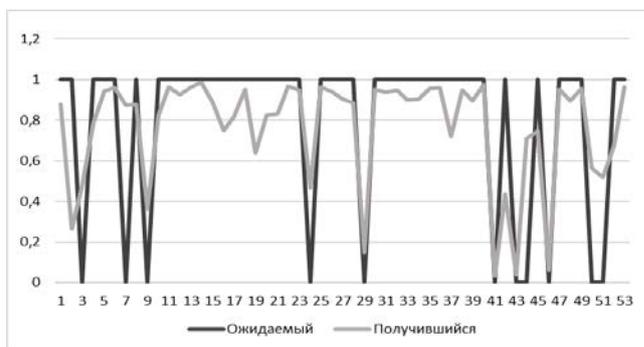


Рисунок 2. Параметр "Нет осадков"

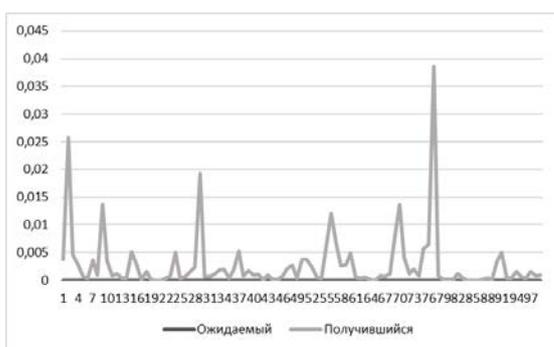


Рисунок 3. Параметр «Количество облаков»

Библиографический список

1. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221с.
2. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.
3. Черепанов Ф.М., Ясницкий Л.Н. Нейросетевой фильтр для исключения выбросов в статистической информации // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2008. № 4. С. 151-155.

SYSTEM PREDICTS PRECIPITATION TYPE BASED ON WEATHER EVENTS

Konstantinov Denis A.

High School of Economics Perm, 614070, Russia, st. Studencheskaya, 38,

d.a.konstantinov@outlook.com

The article describes the creation and analysis of the results of a neural network, which predicts precipitation types based on weather events. The data were taken from the meteorological station of the airport "Bolshoe Savino", located in Perm. The neural network is created and trained with the help of the program "Neuroimaging". In the analysis, percent errors and a comparative histogram of the weights of each input parameter for the training and test sample are presented.

Keywords: neural network, prediction, weather, weather events.

УДК 004.855.5

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ ЗАРПЛАТЫ ВЕБ-РАЗРАБОТЧИКА В МОСКВЕ

Мальцев Алексей Андреевич

Национальный исследовательский университет «Высшая школа экономики»,
614070, Россия, г. Пермь, ул. Студенческая, 38, alexey_maltsev@bk.ru

В статье описано создание и анализ полученных результатов нейронной сети, прогнозирующей диапазон заработной платы для Московских разработчиков веб-систем. В работе представлена основная информация об архитектуре нейронной сети, а также анализ парадоксов, связанных с нелинейностью модели, и графики обучения и значимости входных

параметров. Модель была протестирована в программе Нейросимулятор 5, а также была внедрена в веб-приложение на языке JavaScript.

Ключевые слова: нейронная сеть, прогнозирование, заработная плата, интернет.

Проблема прогноза заработной платы для разработчиков складывается из двух актуальных проблем, связанных с человеческими ресурсами компании. Первая, со стороны HR (human resources), когда специалист отдела кадров пытается выставить наиболее подходящую зарплату для вакансии. Ему приходится собирать статистические данные вручную, а также обращаться к помощи технического специалиста, который может дать какие-либо рекомендации.

Вторая проблема заключается в том, что и самому специалисту крайне интересно знать, насколько востребованы его навыки на рынке труда, а также сколько это может «стоять».

Для решения этих двух похожих проблем было решено разработать нейросетевую аналитическую систему, которая бы позволила оценить возможный диапазон заработной платы для специалиста, принимая на входе оценки по нескольким наиболее популярным технологиям или навыкам. Данное приложение стоит на гипотезе, что навыки программиста коррелируют с его заработной платой.

Нейронная сеть представляет собой многослойный персептрон [1, 2] с одним скрытым слоем из 10 нейронов. Было экспериментально выявлено, что данное количество неплохо балансирует между достаточно высокой скоростью обучения и низким уровнем ошибки.

Входных нейронов в сети 18, все означают присутствие и интенсивность того или иного навыка веб-разработчика. Каждый входной параметр принимает оценку данного навыка от 0 до 5. Все входные параметры в обучающей и тестовой выборках, а также те, что передает пользователь системы, были нормализованы к значениям от 0 до 1, чтобы исключить аномальное влияние на работу нейронной сети единичных параметров.

Выходных нейронов у сети 2, первый показывает начало диапазона прогнозируемых зарплат, второй означает конец данного диапазона. Для обучающей и тестовых выборок, а также для тех, что передаются пользователю, применена нормализация к значениям от 0 до 1.

Список входных параметров:

1. Владение языком программирования "php" – значение от 0 до 5
2. Владение фреймворком "laravel" – значение от 0 до 5
3. Владение фреймворком "symfony" – значение от 0 до 5
4. Владение технологией "nodejs" – значение от 0 до 5
5. Владение фреймворком "expressjs" – значение от 0 до 5
6. Владение языком программирования "python" – значение от 0 до 5
7. Владение фреймворком "django" – значение от 0 до 5

8. Владение языком программирования "java" – значение от 0 до 5
9. Владение платформой "android" – значение от 0 до 5
10. Владение языком программирования "csharp" – значение от 0 до 5
11. Владение фреймворком "aspnet" – значение от 0 до 5
12. Владение СУБД "mysql" – значение от 0 до 5
13. Владение СУБД "postgres" – значение от 0 до 5
14. Владение языком программирования "javascript" – значение от 0 до 5
15. Владение фреймворком "angular" – значение от 0 до 5
16. Владение библиотекой "react" – значение от 0 до 5
17. Владение фреймворком "ember" – значение от 0 до 5
18. Владение библиотекой "jquery" – значение от 0 до 5

В ходе многочисленных испытаний, была выявлена наиболее удачная конфигурация остальных параметров, где на входном и скрытом слоях в качестве активационной функции используется сигмоидальная функция, а на выходном – линейная.

В ходе реализации приложения был использован пакет Нейросимулятор 5 для тестирования модели и библиотека Synaptic для проектирования, обучения и использования нейронной сети в конечном приложении.

Все исходные коды приложения доступны в открытом доступе и под лицензией MIT (нет никаких ограничений на использование и модификацию) на сайте GitHub: <https://github.com/AxelUser/Relationship-between-Skills-and-Wages>

Само работающее приложение (веб-интерфейс) доступно по адресу: <https://axeluser.github.io/Relationship-between-Skills-and-Wages/>

Для построения, обучающего и тестового множеств было сформировано множество примеров, полученных путем обращения к публичному API сайта HeadHunter. Всего в обучающей и тестовой выборках в сумме было собрано 1390 записей. Поскольку из-за большой разности зарплат в различных регионах, было решено анализировать только один регион с наибольшим количеством вакансий, поэтому исследование проводилось в рамках вакансий в городе Москва.

Было сформировано обучающее и тестовое множество в пропорциях 70/30, что в переводе на числа означает 1390 примера в обучающей выборке и 595 примеров в тестовой выборке. Примеры для тестовых и обучающих выборок выбирались случайным образом, чтобы увеличить точность исключить обучение в рамках примеров одного контекста, а проверку в рамках другого, то есть чтобы повысить эффективность обучения, и чтобы повысить достоверность результатов проверки.

Для «обогащения» примеров, была разработана онтология для навыков, так как, несмотря на то, что знания некоторых навыков подразумевает так же как минимум осведомленность в других, эти связи не указываются в оригинальных данных о вакансиях.

Нейронная сеть обучалась методом обратного распространения ошибки, где в качестве функции потерь была выбрана функция среднеквадратичной ошибки (Mean Squared Error, MSE), так как задача прогнозирования зарплаты сводилась к задаче регрессии. В результате удалось добиться уровня ошибки в 0.0031, что в переводе на деньги, означает ошибку в 3100 тыс. рублей. Данный уровень ошибки более чем приемлем, так как средняя зарплата в Москве для веб-разработчика составляет около 100 тыс. рублей и погрешность можно считать относительно небольшой. На тестовой выборке ошибка составляет 0.004, что также довольно неплохой результат.

В процессе обучения и тестирования нейросети был выполнен поиск выбросов по определенной методике [3]. Очевидных выбросов не оказалось.

После построения нейросети и проверки ее на адекватность при помощи тестирующего множества, можно начать ее исследовать. Путем поочередного включения (активации) входных нейронов по определенной методике [1,2] и наблюдением за результатом сети была определена значимость входных параметров модели, т.е. степень их влияния на начало (Delta Salary To) и конец (Delta Salary From) диапазона прогнозируемой заработной платы.

Наиболее значимыми навыками оказались: СУБД Postgres, языки программирования Python и Java, а также фреймворк React. Наименее значимыми навыками оказались фреймворки Ember, Laravel, Django и Asp.Net. На рис. 1 приведена гистограмма значимости каждого входа на каждый выход.

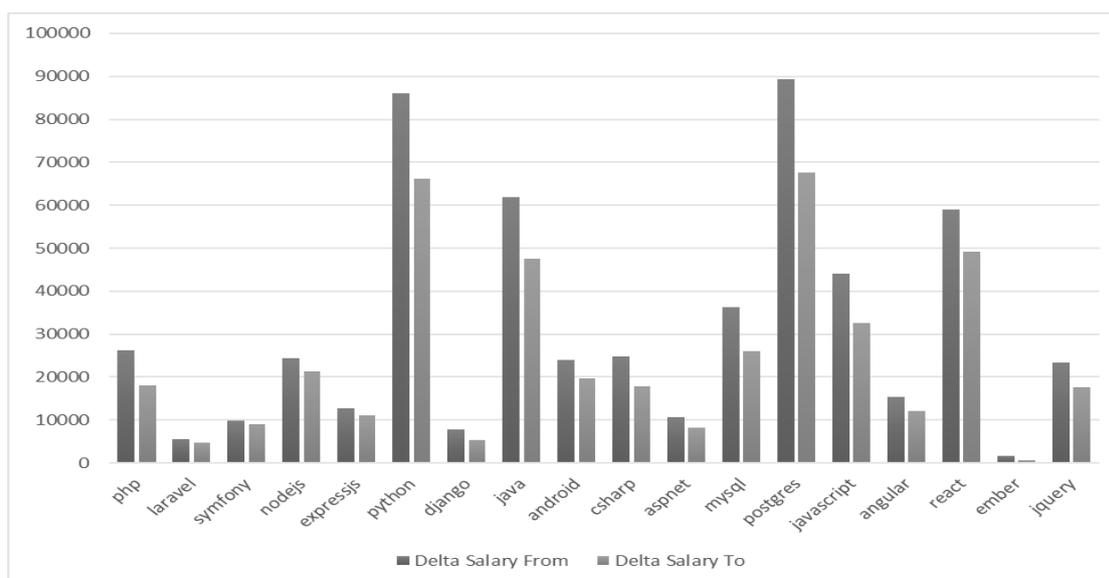


Рисунок 1. Значимость входных параметров.

В процессе тестирования готового приложения был замечен парадокс, связанный с комбинацией «дорогих» и «дешевых» навыков. Так, например, при выборе группы «дорогих» навыков Python, Postgres и React зарплата будет достаточно высокая, что достаточно логично. Но если, например, включить в этот набор какой-либо «дешевый» навык, например, PHP, то значения диапазона зарплат неожиданно уменьшатся, что кажется не логичным, ведь чем больше знает специалист, тем лучше.

Это связано с особенностью данных в обучающей выборке. Данные были получены из вакансий, а не из анкет работников. И поскольку в вакансиях программистов обычно требуется какой-то определенный специалист с определенным набором навыков в рамках какой-нибудь конкретной экосистемы для решения какой-либо конкретной задачи, то и зарплата будет формировать не только исходя из навыков, но и исходя из тех задач и исходя из типа проекта, на которые идет специалист.

Например, специалист на популярном наборе технологий PHP + Laravel будет стоить дешевле, чем специалист на Python. На самом деле это не значит, что PHP более простой чем Python. Всё далеко не так, но, во-первых, PHP более популярен и больше специалистов готовы им заниматься, а так же проектам, которым требуется человек со знанием PHP скорее всего нужен специалист, который должен заниматься разработкой сайтов. Для вакансии с одним лишь знанием Python скорее всего требуется специалист, как-то связанный с искусственным интеллектом, аналитикой, data-science и в целом более грамотный в научном плане специалист.

Исходя из данных допущений и полученного результата, складывается предположение, что парадокс заключается в том, какие данные были использованы и какой результат предполагалось получить. Возможно, для исключения такого рода парадоксов необходимо вводить дополнительный параметр, который бы как-то сигнализировал о специфичности и сложности задач. Но, к сожалению, такой параметр придется проставлять вручную, так как сложность написания бизнес-приложения (англ. Enterprise-software) для банковского сектора на языке Java может быть отнюдь не легче, чем разработка аналитической системы на Python. Там же среди разработчиков особо ценятся те специалисты, которые могут работать со старым кодом на устаревших технологиях (англ. legacy), так как поддерживать проект тоже необходимо. Поэтому разработчики для каких-либо старых версий PHP очень ценны.

Исходя из этого, формируется гипотеза, что причина возникновения данного парадокса заключается в недостающих параметрах, которые очень сложно получить.

Для исправления данного было парадокса, было решено пожертвовать точностью модели, сделав её более линейной, снизив количество нейронов на скрытом слое до 3 и

применив линейную активационную функцию для всех трех слоев. Так же, поскольку для навыка ember было внесено недостаточно много информации, было решено в онтологии прибавить в каждом правиле для ember по 2 балла. В результате значимость параметров изменилась, как показано на рис. 2.

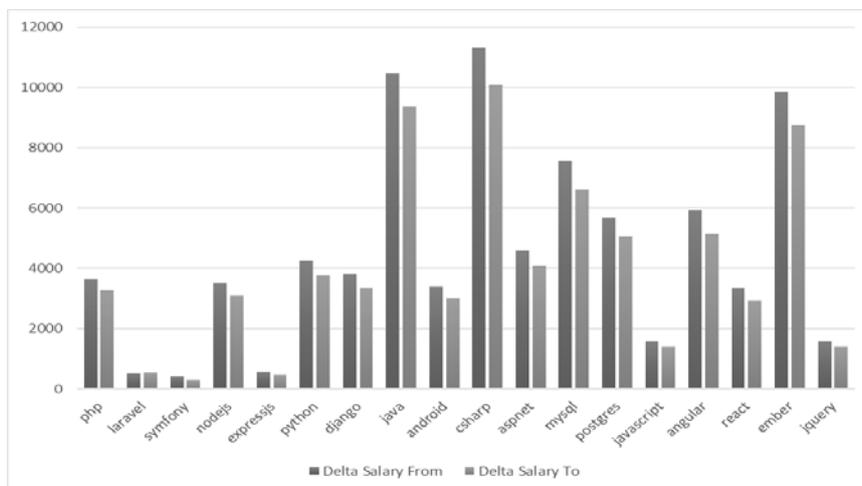


Рисунок 2. Значимость входных параметров после уменьшения уровня нелинейности модели

В лидирующих позициях продолжает держаться Java, но при этом CSharp стал значительно дороже её, а на 3-м месте оказался ember. Если учесть область применения данного набора технологий, то можно отследить связь – все 3 технологии по историческим причинам особо присущи иностранным бизнес-приложениям, тем самым обновленная нейросеть определила технологии данного стека, как наиболее дорогими, в то время как предыдущая модель ярко выражала преимущество технологий, используемых в стартапах.

После преобразований модель оказалась менее точной, продемонстрировав ошибки обучения и тестирования равными 0.004 и 0.005 соответственно.

В ходе выполнения данного проектного задания была разработана нейросетевая математическая модель, позволяющая выполнять прогнозирование заработной платы веб-разработчика в Москве. Была проделана попытка выявления и исследования наиболее значимых параметров, оказывающих наибольшее влияние на ожидаемую зарплату. Так же для демонстрации результатов работы было создано рабочее веб-приложение и опубликовано на сайте (ссылка и инструкция приведены в главе «Разработка»). Результаты работа нейронной сети соотносятся с финансовыми ожиданиями опрошенных специалистов, тем самым подтверждая корреляцию между навыками и заработной платой в сфере IT в городе Москва. Но при определенных комбинациях входных параметров возникает парадоксы, причина которых в недоступной дополнительной информации о входных данных. Для решения данной

проблемы с минимальными трудозатратами модель была упрощена до достаточно линейного вида.

Так же одним из основных недостатков данной модели является то, что она не учитывает сезонность и не может предугадать тренд, будет ли какой-либо набор технологий таким же актуальным завтра или через несколько лет, тем самым делая прогноз относительно прошлого, а не будущего.

Библиографический список

3. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221с.
4. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы / Пермь: Пермский университет, 2007. 271с.
5. Черепанов Ф.М., Ясницкий Л.Н. Нейросетевой фильтр для исключения выбросов в статистической информации // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2008. № 4. С. 151-155.

NEURAL NETWORK AT FORECASTING SYSTEM OF WEB DEVELOPER'S WAGES IN MOSCOW

Maltsev Alexey A.

High School of Economics Perm, 614070, Russia, st. Studencheskaya, 38, alexey_maltsev@bk.ru

The article describes the creation and analysis of the results of a neural network that predicts the salary range for Moscow web system developers. The paper presents basic information about the neural network architecture, as well as analysis of paradoxes related to model nonlinearity, and training schedules and the significance of input parameters. The model was tested in the Neuro-simulator 5 program, and was also implemented in a web application in the JavaScript language.

Keywords: neural network, prediction, salary, internet.

УДК 004.891.2

ПРОГНОЗИРОВАНИЕ ОБЪЕМА ПРОДАЖ СОКА В ПРОДУКТОВОЙ РОЗНИЧНОЙ СЕТИ ПОСРЕДСТВОМ НЕЙРОННЫХ СЕТЕЙ

Бондаренко Анна Сергеевна

Национальный исследовательский университет «Высшая школа экономики», Пермский филиал, Россия, 614070, Пермь, ул. Студенческая, 38, annpostanogova@edu.hse.ru

Статья представляет результаты исследования объемов продаж и факторов, влияющих на их изменение, с помощью нейронных сетей. Исходными данными для анализа являются данные продуктовой розничной сети. В работе поясняется выбор входных и выходных данных для построения моделей, обосновывается выбор метода предобработки данных. Проведение анализа реализовано в программном инструменте «Нейросимулятор 5.0». Результаты показали, что на продажи определенного бренда сока влияют не только его предыдущие

продажи, но и продажи наиболее популярных марок. Также в работе было выявлено, что приближение определенных праздников существенно сказывается на спросе соков определенных брендов.

Ключевые слова: искусственный интеллект, нейронная сеть, прогноз, маркетинг, продажи.

Введение

Маркетинговые отделы продуктовых сетей столкнулись с необходимостью автоматизации процесса обработки данных продаж с целью их увеличения. Классические инструменты современного маркетинга не позволяют принимать эффективных маркетинговых решений, так как они не адаптированы под динамические типы больших данных, с которыми на данный момент приходится иметь дело крупным торговым сетям. В данном бизнесе важно быстро среагировать на поведение клиента и принять соответствующие решения. Компании, которые используют в своей работе методы машинного обучения более эффективны на рынке и получают большую прибыль. Описанная в этой статье модель позволит прогнозировать будущие продажи конкретных брендов сока на основе предыдущих продаж. Знание будущих продаж может помочь в планировании работы мерчендайзера, маркетолога, логиста и даже производителя. Используя эти данные, они смогут оптимизировать свои ресурсы и бизнес-процессы, что в конечном итоге позволяет увеличить прибыль компании.

Анализ литературы

Прогнозирующие методы могут быть реализованы в различных алгоритмах обработки данных. Для решения маркетинговых задач зачастую сравнивают нейронные сети, байесовские алгоритмы, логистическую регрессию и деревья решений. Исследования показывают, что для большинства выбранных продуктов нейронные сети значительно превосходят логистические регрессионные модели с точки зрения прогнозирующей способности. Исследования West, Brockett and Golden (1997) также подтвердили, что в большинстве приложений, где нейронные сети используются для моделирования бизнес-задач финансов и маркетинга, они превосходили традиционные компенсационные модели, такие как дискриминантный и регрессионный анализ [1].

В сравнении различных техник Data Mining Pavel Turcinek, Jiri Stastny, Arnost Motycka и Rochana Lahiri рассматривали применение дерева решений, байесовский классификатор, логистическую регрессию и нейронные сети на выборках продуктовых сетей [2, 3]. В одном случае оказался лучше алгоритм логистической регрессии, в другом байесовский классификатор, но превосходство было небольшим, так как равнялось примерно 1%. Поэтому исследователи отмечают конкурентную способность нейронных сетей в точности предсказания на разных типах данных. West, Brockett and Golden отмечают в своих

исследованиях в первую очередь гибкость нейронной сети, которая предоставляет лучшую точность предсказания даже при условии отсутствия базового правила.

Недостатком нейронных сетей в этих работах была выявлена скорость обучения сети, которая превосходит в некоторых случаях в 10 раз время на формирования моделей другими алгоритмами. West, Brockett and Golden считают основной проблемой нейронной сети ее переобучаемость. Для того, чтобы с ней справиться исследователи количественно сравнивают точность внутри выборки (при наличии возможности переобучения в учебный образец) с точностью вне выборки (что является несмещенной оценкой производительности модели).

Все рассмотренные мной исследователи подтверждают перспективность использования нейронных систем для решения задач маркетинга, однако они обращают внимание на специфичность построения сетей, необходимость правильного подбора факторов и адаптацию алгоритма в целях избавления его от переобучения.

Построение математической модели

Данные содержат информацию о соке и его количестве, приобретенном определенным человеком в конкретную дату. Эти данные были собраны за 5 лет и содержат 3 113 731 записей. Идентификация человека происходит с помощью номера его дисконтной карты.

В ходе первичного исследования было выявлено, что праздники очень сильно влияют на продажи. Далее была выдвинута гипотеза о том, что продажи одного бренда зависят не только от продаж этого бренда за предыдущие периоды, но и от продаж других брендов. Так как данные представляют собой временные ряды, то мы использовали метод окон в качестве формата представления входных данных. Было решено взять окно, которое равняется 7 дням, так как неделя является достаточно презентативным периодом. В результате размер выборки составил 2274 строки. Так как в качестве входных параметров мы рассматривали данные о продажах 7 самых популярных соков и данные о праздниках, то, в конечном счете, получилось 57 входных параметра и 7 выходных:

X_1 – объем продаж 1 бренда за 1й день, шт.

X_2 – объем продаж 1 бренда за 2й день, шт.

X_3 – объем продаж 1 бренда за 3й день, шт.

X_4 – объем продаж 1 бренда за 4й день, шт.

X_5 – объем продаж 1 бренда за 5й день, шт.

X_6 – объем продаж 1 бренда за 6й день, шт.

X_7 – объем продаж 1 бренда за 7й день, шт.

...

- X₄₃ – объем продаж 7 бренда за 1й день, шт.
X₄₄ – объем продаж 7 бренда за 2й день, шт.
X₄₅ – объем продаж 7 бренда за 3й день, шт.
X₄₆ – объем продаж 7 бренда за 4й день, шт.
X₄₇ – объем продаж 7 бренда за 5й день, шт.
X₄₈ – объем продаж 7 бренда за 6й день, шт.
X₄₉ – объем продаж 7 бренда за 7й день, шт.
X₅₀ – количество дней до следующего праздника.
X₅₁ – является ли следующий праздник 11 января: 1 – Да; 0 – Нет.
X₅₂ – является ли следующий праздник 23 февраля: 1 – Да; 0 – Нет.
X₅₃ – является ли следующий праздник 8 марта: 1 – Да; 0 – Нет.
X₅₄ – является ли следующий праздник 1 мая: 1 – Да; 0 – Нет.
X₅₅ – является ли следующий праздник 9 мая: 1 – Да; 0 – Нет.
X₅₆ – является ли следующий праздник 1 сентября: 1 – Да; 0 – Нет.
X₅₇ – является ли следующий праздник 31 декабря: 1 – Да; 0 – Нет.
Y₁ – объем продаж 1 бренда на 1 день вперед, шт.
Y₂ – объем продаж 2 бренда на 1 день вперед, шт.
Y₃ – объем продаж 3 бренда на 1 день вперед, шт.
Y₄ – объем продаж 4 бренда на 1 день вперед, шт.
Y₅ – объем продаж 5 бренда на 1 день вперед, шт.
Y₆ – объем продаж 6 бренда на 1 день вперед, шт.
Y₇ – объем продаж 7 бренда на 1 день вперед, шт.
Y₈ – объем продаж 8 бренда на 1 день вперед, шт.

Проектирование, обучение и тестирование сети выполнялось с помощью нейропакета «Нейросимулятор 5.0» [4], с применением методики Пермской научной школы искусственного интеллекта [5]. Наилучшие результаты показала нейронная сеть, которая имела 57 входных параметров, 3 скрытых слоя с 3 нейронами на каждом слое и 7 выходных нейронов.

Исходная выборка была поделена на обучающее и тестовое множества в соотношении 80:20. В начале мы не перемешивали данные, что позволило нам проследить чувствительность нейронной сети к праздникам. Мы провели несколько экспериментов с разными выборками и еще раз убедились в том, что информация о праздниках помогает сети точнее предсказать будущий объем продаж (Рис.1).

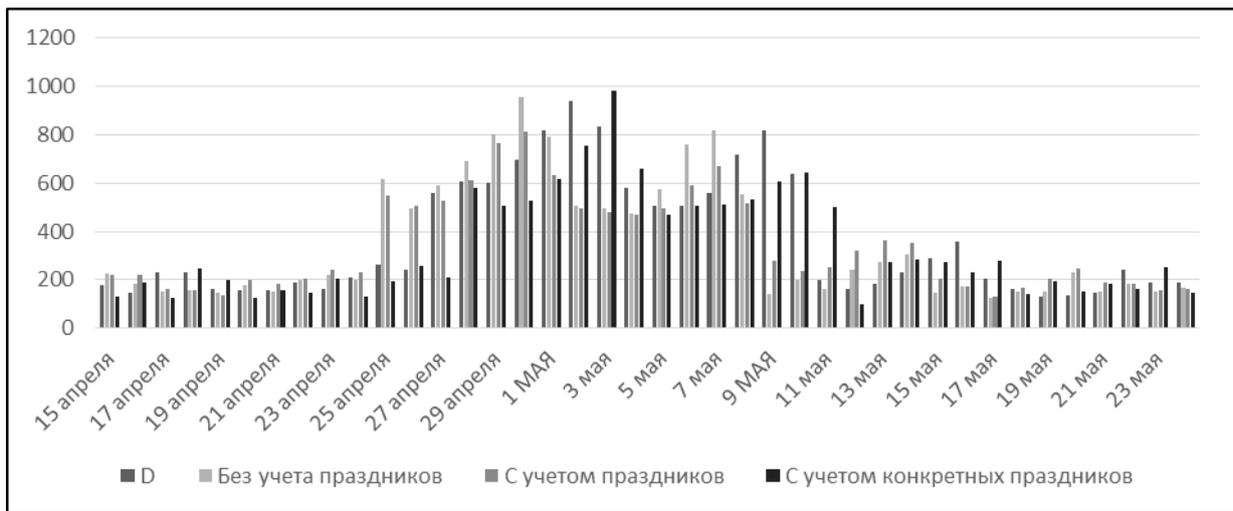


Рис.4. Сравнение результатов анализа без учета праздников, с учетом праздников и с учетом конкретных праздников

Для того, чтобы определить какие факторы в большей степени влияют на объем продаж, мы построили гистограмму, которая отображает значимость каждого параметра.

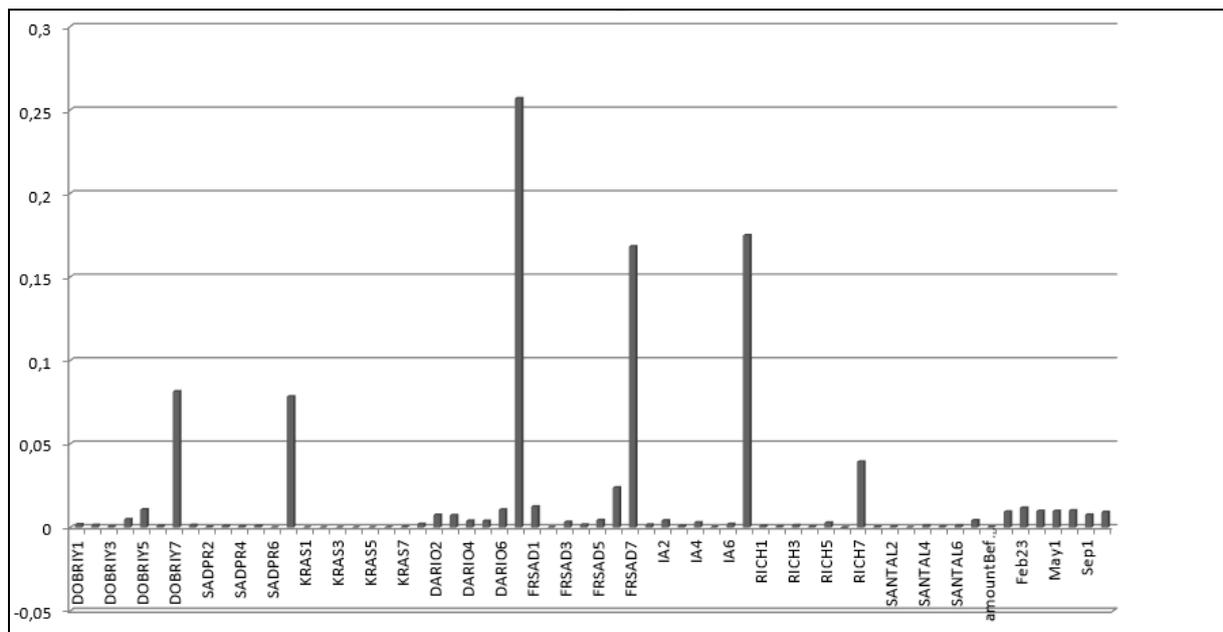


Рис. 5. Значимость параметров

Если проанализировать значимость параметров и рейтинг объемов продаж по брендам сока (Табл.1), то можно сделать интересный вывод о том, что чем более покупаем сок определенного бренда, тем он в меньшей степени влияет на продажи других брендов.

Таблица 1. Рейтинг брендов по объему продаж

Рейтинг	Бренд	Объем продаж, шт
1	Красавчик	32623
2	Добрый	29594
3	Фруктовый сад	18153

4	Дарио	16091
5	Сады Придонья	15049
6	Santal	13991
7	Я	13614
8	Rich	12510

Заключение

Проведя анализ предметной области, и выполнив глубинный анализ данных с помощью нейронных сетей в Нейросимуляторе 5.0, было выявлено, что на объем продаж определенного бренда сока в большинстве влияет продажи данного сока и его конкурентов за прошлый период, а также информация о том, сколько дней осталось до конкретного праздника. Большую роль для покупки брендов сока играет приближение праздников.

Библиографический список

1. *West, P. M., Brockett, P. L., & Golden, L. L.* (1997). A comparative analysis of neural networks and statistical methods for predicting consumer choice. *Marketing Science*, 16 (4), 370–391.
2. *Turcinek, P., Stastny, J., & Motycka, A.* (2012). Usage of Data Mining Techniques on Marketing Research Data. In *Proceedings of the 11th WSEAS International Conference on Applied Computer and Applied Computational Science* (pp. 159-164).
3. *Rochana Lahiri B.E.*, Jadavpur University, India, December 2006.
4. *Черепанов Ф.М., Ясницкий Л.Н.* Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.
5. *Ясницкий Л.Н.* Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221с.

FORECASTING THE VOLUME OF JUICE SALES IN THE PRODUCT RETAIL NETWORK BY MEANS OF NEURAL NETWORKS

Bondarenko Ann S.

National Research University Higher School of Economics, 38 Studenchskaya st., Perm, 614070, Russia, annpostanogova@edu.hse.ru

This article presents the results of a study of sales volumes and factors affecting their change, using neural networks. The initial data for the analysis are the data of the food retail network. The paper explains the choice of input and output data for constructing models, justifies the choice of the method for preprocessing data. The analysis was implemented in the software tool "Neuro-simulator 5.0". The results showed that sales of a certain brand of juice are affected not only by its previous sales, but also by sales of the most popular brands. Also it was revealed that the approach of certain holidays significantly affects the demand of juices of certain brands.

Keywords: artificial intelligence, neural network, forecast, marketing, sales

УПРАВЛЕНИЕ РЫНКОМ НЕДВИЖИМОСТИ С ПОМОЩЬЮ СЦЕНАРНОГО ПРОГНОЗИРОВАНИЯ РЫНОЧНОЙ СТОИМОСТИ НА БАЗЕ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ

*Алексеев Александр Олегович, Харитонов Валерий Алексеевич,
Ясницкий Виталий Леонидович*

Пермский национальный исследовательский политехнический университет,
614000, Россия, г. Пермь, Комсомольский проспект, д. 29, yasnitskiy@mail.ru

В исследовании решается задача повышения эффективности управления рынком жилой недвижимости на базе сценарного прогнозирования рыночной стоимости жилых объектов. На основе обобщенной комплексной нейросетевой модели разработана система поддержки принятия решений, позволяющая видеть, как изменение ключевых ценообразующих факторов влияет на рыночную стоимость объектов. Также в ходе исследования подтверждена устойчивость построенных нейросетевых моделей к динамическому изменению внешних экономических факторов. В результате чего данный подход прогнозирования может быть использован в расчете сценариев развития при направленных управляющих экономических воздействиях, что расширяет область применения существующих систем поддержки принятия решений в задачах девелопмента жилой недвижимости.

Ключевые слова: Сценарное прогнозирование, интеллектуальный анализ данных, аналитика, моделирование, бизнес-аналитика, нейронные сети, анализ рынка, оценка, недвижимость, девелопмент.

Рынок недвижимости, будучи саморегулируемой системой, выполняя информационную функцию, консолидирует данные о территории. Так, в цене объекта недвижимости концентрируется большой объем информации о насыщенности рынка, предпочтениях покупателей, хозяйственной и социальной политике государства. Поэтому анализ и исследование моделей региональных рынков недвижимости позволяет решать вопрос более эффективного использования территории, что обуславливает высокую актуальность задачи компьютерного моделирования [1-3].

Основная цель моделирования состоит в том, что модель должна достаточно хорошо отображать функционирование моделируемой системы, что является методом описания знаний. С одинаковым успехом описывать эти закономерности могут различные модели. Чтобы получить ответ на вопрос, какой метод выбрать, необходимо проанализировать свойства используемого математического аппарата. Область применения аппарата искусственных нейронных сетей во многом совпадает с кругом задач, решаемых традиционными статистическими методами, выступает в роли приемлемого средства решения задачи, когда присутствует большое количество эмпирической информации, но нет алгоритма способного получить достаточно точное решение.

Рынок недвижимости, будучи сложной системой, является подсистемой для систем более высокого уровня: региональной экономики, экономики страны и мировой экономики. Для стабильной работы модели в условиях изменяющейся экономической обстановки, а также, для обеспечения прогностических свойств модели, необходимо учитывать в составе ценообразующих факторов мезо-, макро- и мега-экономические параметры. С целью моделирования рынка в рамках исследования предлагается экономико-математическая модель прогнозирования жилой недвижимости, согласно которой в качестве входных параметров модели используются два типа описывающих систему параметров: строительно-эксплуатационные характеристики и факторы внешнего воздействия на систему. Модель строится на базе математического аппарата искусственных нейронных сетей.

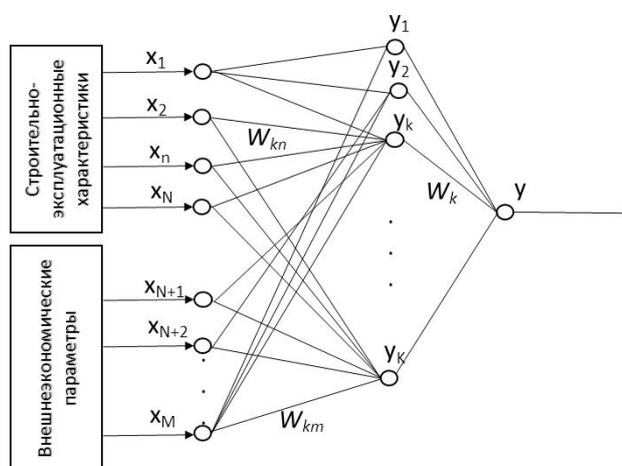


Рис. 1. К концепции экономико-математического моделирования процессов массовой оценки и сценарного прогнозирования рыночной стоимости объектов жилой недвижимости

Согласно предложенной концепции (рис.1), в экономико-математические модели предлагается вводить две группы входных параметров:

x_1, x_2, \dots, x_N – строительно-эксплуатационные параметры;

$x_{N+1}, x_{N+2}, \dots, x_M$ – внешние экономические (мега- макро- и мега) параметры.

Здесь:

N – количество строительно-эксплуатационных параметров;

M – общее количество входных параметров модели;

$M - N$ – количество внешних экономических параметров.

Выходным параметром модели y является стоимость объекта жилой недвижимости.

Согласно предлагаемой концепции регрессионное уравнение модели генерируется нейронной сетью персептронного типа с сигмоидными активационными функциями. На рис. 1 нейронная сеть имеет M входных нейронов, один скрытый слой с K сигмоидными

нейронами и один выходной нейрон также с сигмоидной активационной функцией. Сигнал выходного нейрона вычисляется с помощью формулы

$$y = \frac{1}{1 + e^{-S}}, \quad (1)$$

где S – сумма входных сигналов выходного нейрона:

$$S = \sum_{k=1}^K w_k y_k. \quad (2)$$

Здесь: w_k – сила синаптической связи выходного нейрона с k -м нейроном скрытого слоя, y_k – выходной сигнал k -го нейрона скрытого слоя. Для вычисления выходного сигнала y_k k -го нейрона используется формула:

$$y_k = \frac{1}{1 + e^{-S_k}}, \quad (3)$$

в которой S_k – сумма входных сигналов k -го нейрона скрытого слоя:

$$S_k = \sum_{n=1}^M w_{kn} x_n. \quad (4)$$

w_{kn} – сила синаптической связи между k -м нейроном скрытого слоя и n -м входным нейроном, x_n – входной сигнал n -го входного нейрона.

Последовательная подстановка выражений (4) и (3) в (2) и (1) формирует общий вид выражения:

$$y = \left(1 + e^{-\sum_{k=1}^K w_k \left(1 + e^{-\sum_{n=1}^M w_{kn} x_n} \right)^{-1}} \right)^{-1} \quad (5)$$

Выражение (5) представляет собой обобщенную комплексную экономико-математическую модель процессов массовой оценки и сценарного прогнозирования рыночной стоимости объектов жилой недвижимости, соответствующую предлагаемой выше концепции экономико-математического моделирования. В данной модели параметры w_k и w_{kn} определяются в ходе обучения нейронной сети на примерах поведения конкретных локальных рынков.

Исследование эффективности построенной модели

С целью исследования адекватности разработанной нейросетевой модели процесса массовой оценки в исследовании выполнено сопоставление результатов нейросетевого моделирования с результатами традиционного регрессионного моделирования по двум

моделям: линейной и мультипликативной [4-6]. Описательные статистики для каждой полученной модели приведены в таблице 1.

Таблица 1. Описательные характеристики линейной, мультипликативной и нейросетевой моделей массовой оценки рыночной стоимости объектов недвижимости, выполненные на базе локального рынка г.Екатеринбурга

Показатель	Линейная регрессионная модель	Мультипликативная регрессионная модель	Нейросетевая модель
Вид уравнения, используемого при моделировании	$Y = A_0 + A_1 X_1 + \dots + A_n X_n,$	$Y = B_0 \cdot X_1^{B_1} \cdot X_2^{B_2} \cdot \dots \cdot X_n^{B_n},$	$y = \left(1 + e^{-\sum_{k=1}^K w_k \left(1 + e^{-\sum_{n=1}^M w_{kn} x_n} \right)^{-1}} \right)^{-1}$
Коэффициент детерминации R^2	84,33%	85,16%	87%
Средняя ошибка аппроксимации	10%	9,30%	6,50%

По результатам исследования, представленного в таблице 1, можно сделать вывод, что прогнозирование с помощью нейронной сети, имеет наибольшее значения коэффициента детерминации R^2 (87%) и наименьшую среднеквадратичную относительную погрешность (6,5%), т.е. позволяет получить наилучший результат.

Для подтверждения прогностических свойств системы на примере гг.Перми и Екатеринбурга показана устойчивость нейросетевой модели по отношению к динамичному изменению экономической ситуации. На рис. 2, а представлены кривые распределения относительных частот отклонений расчетной стоимости, полученные на тестовых множествах данных, относящихся к периоду 2011 – 2015 гг. Из рисунка видно, что со временем качество модели ухудшается: кривые смещаются вправо, т.е. модели дают существенно заниженные стоимости квартир. Как видно из рис. 2, б, комплексная модель, учитывающая экономические параметры внешней среды, ведет себя более стабильно, несмотря на изменение внешних параметров. Аналогичный вывод можно сделать из данных таблицы 2, в которой приведены среднеквадратичные относительные погрешности прогнозных оценок квартир, выполненных на данном временном ряде с помощью комплексной модели, учитывающей внешние экономические факторы.

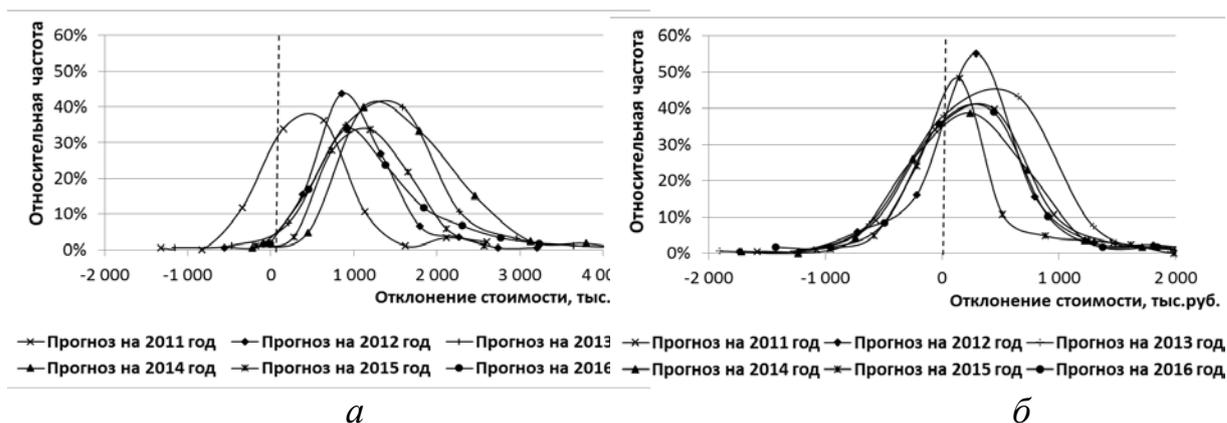


Рис. 2. Кривые распределения относительных частот отклонений расчетных стоимостей квартир от их заявленных стоимостей, полученные путем прогнозирования за период 2011–2016 гг. с помощью модели без входных экономических параметров внешней среды и (а) и комплексной (б) моделей. Исследования выполнены на базе локального рынка г.Екатеринбурга

Таблица 2. Среднеквадратичные относительные погрешности оценки стоимости квартир, полученные путем прогноза на период 2011–2016 гг на примере двух локальных рынков недвижимости г.Екатеринбурга и г.Перми

Период	Величина погрешности для модели г.Екатеринбурга		Величина погрешности для модели г.Перми	
	Модель без учета внешних параметров	Комплексная модель	Модель без учета внешних параметров	Комплексная модель
2011	7,70%	5,90%	6,80%	5,30%
2012	11,60%	6,90%	11,00%	7,20%
2013	17,60%	8,10%	14,00%	7,50%
2014	18,90%	7,00%	17,20%	6,80%
2015	20,50%	7,60%	24,34%	6,20%
2016	22,20%	8,90%	28,00%	6,50%

Идентичность результатов, полученных для рынков гг.Перми и Екатеринбург, является подтверждением того, что нейросетевая модель адаптируема к различным локальным рынкам недвижимости. Таким образом, результаты показывают, что традиционно применяемые в ряде западных стран модели массовой оценки недвижимости, учитывающие одни только строительно-эксплуатационные параметры, в условиях нестабильной экономики, характерной для регионов России, не являются стабильными, быстро устаревают. Разработанные для одного какого-то периода, в течение которого экономическая обстановка в регионе, а также в стране и в мире меняется слабо, они могут быть применены для массовой оценки стоимости недвижимости в одном только этом временном периоде. Предлагаемые нами комплексные модели, учитывающие в качестве входных параметров факторы внешней среды, указанного недостатка не имеют и являются пригодными для сценарного прогнозирования поведения исследуемых локальных систем, на базе которых

становится возможным строить системы поддержки принятия решений. Подобная модель сценарного прогнозирования дает возможность определить вероятные тенденции развития событий и возможные последствия принимаемых решений с целью выбора наиболее подходящей альтернативы управления рынком и наиболее эффективные управленческие воздействия [7, 8].

Библиографический список

1. Стерник Г.М., Стерник С.Г. Анализ рынка недвижимости для профессионалов. – М.: «Экономика», 2009. – 606 с.
2. Стерник Г.М., Стерник С.Г. Методология прогнозирования российского рынка недвижимости. Часть 1. Основные допущения, ограничения и рабочие гипотезы// Механизация строительства. – 2013. – №8(830). – С.53-63.
3. Малкина М.Б. Особенности формирования спроса, предложения и равновесия на рынке жилой недвижимости России// Экономический анализ: теория и практика. – 2013. – №16. – С.2-15.
4. Грибовский С.М., Сивец С.А. Математические методы оценки стоимости недвижимого имущества. – М.: «Финансы и статистика», 2014. – 368 с.
5. Грибовский С.В., Федотова М.А., Стерник Г.М., Житков Д.Б. Экономико-математические модели оценки недвижимости// Финансы и кредит. – 2005. – № 3(171). – С.24–43.
6. Мунерман И.В. Нейро-нечеткие модели и инструменты для регионального управления объектами коммерческой недвижимости: дисс. кандидата экон. наук: 08.00.13. Москва, 2011. 156 с.
7. Ясницкий Л.Н., Ясницкий В.Л. Разработка и применение комплексных нейросетевых моделей массовой оценки и прогнозирования стоимости жилых объектов на примере рынков недвижимости Екатеринбурга и Перми // Имущественные отношения в Российской Федерации. – 2017. – №3(186). – С.68-84.
8. Алексеев А.О., Харитонов В.А., Ясницкий В.Л. Разработка и исследование нейросетевых моделей массовой оценки и прогнозирования рыночной стоимости объектов жилой недвижимости // XV Всероссийская научная конференция «Нейрокомпьютеры и их применение». Тезисы докладов. – М: МГППУ, 2017. С. 266-269.

MANAGEMENT OF THE REAL ESTATE MARKET WITH THE SCENARIO FORECASTING MARKET VALUE OF RESIDENTIAL PROPERTY ON THE BASIS OF NEURAL NETWORK MODELING

A.O. Alekseev, V.A. Kharitonov, V.L. Yasnitsky
State National Research Politechnical University of Perm,
Komsomolsky Av. 29, Perm, Russia, 614000

Abstract. The study addressed the problem of increasing of management efficiency of real estate market on the basis of scenario planning and mass valuation of residential properties. On the basis of generalized complex neural network model of the developed system of support of decision-making that allows you to see how changes in the key pricing factors affecting the market value of the properties. Also the study confirmed the stability of the constructed neural network models to dynamic changes in external economic factors. This predictive approach can be used in the calculation of scenarios by targeted governing economic impacts that expanding the scope of the existing systems of decision support in the task of development of residential property.

Key words: Scenary forecasting, data mining, Analytics, modeling, business Analytics, neural networks, market analysis, valuation, real estate development.

УДК 004.832.3

ИСПОЛЬЗОВАНИЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ПРОГНОЗИРОВАНИИ СТОИМОСТИ АРЕНДЫ ЖИЛЬЯ В ГОРОДЕ ПЕРМЬ

Шеломова Кристина Денисовна

Национальный исследовательский университет «Высшая школа экономики», Пермский филиал, Россия, 614070, Пермь, ул. Студенческая, 38, vienosdotres@mail.ru

Разработана компьютерная программа, которая предназначена для выявления закономерностей и прогнозирования стоимости аренды жилья в городе Пермь. Программа обучена на данных, предоставленных в открытом доступе на Интернет-сайтах: bibliofond.ru, realty.yandex.ru и avito.ru. На основе собранных данных были выявлены закономерности, которые отражают зависимость стоимости аренды жилья от тех или иных критериев. Таким образом, были проранжированы и определены наиболее «дорогие» районы города, и те, где стоимость аренды недвижимости самая низкая. В дополнение, была определена зависимость между стоимостью аренды недвижимости и материала, из которого построено здание.

Ключевые слова: искусственный интеллект, нейронная сеть, прогноз, стоимость аренды.

На сегодняшний день, в эпоху развития информационных технологий, в современном мире возникает необходимость в системах, способных не просто выполнять ряд последовательных запрограммированных действий, а также уметь проводить анализ полученной информации и делать прогнозы.

Стоит отметить, что в современном мире отношение человека к собственности видоизменяется кардинальным образом. Так, современный житель большого города предпочитает аренду жилья вместо покупки собственного, а совместное использование – безраздельному владению. Этот феномен объясняется изменением мышления современного человека. Как результат, существует проблема оценки стоимости аренды жилья, с целью проанализировать желания и предпочтения и сопоставить их с ценой аренды и своими возможностями.

Для того, чтобы решить данную проблему, возможно использовать интеллектуальные системы, а именно: нейронные сети, так как они являются наиболее эффективным инструментом интеллектуального анализа данных [1]. Нейронные сети представляют собой мощный инструмент, поскольку совмещают в себе как качества мозга человека, к примеру: способность анализа данных, получение новых знаний, обобщение знаний и вывод закономерностей [2, 3]. В дополнении, стоит отметить, что такие сети представляют собой

способ решения многих нестандартных задач, характеризуясь низкой трудоемкостью их создания, что является одним из главных преимуществ [1].

Целью работы является создание компьютерной программы, основанной на зависимостях, которые существуют между стоимостью аренды жилья и его характеристиками.

Область оценки недвижимости является актуальной и является объектом изучения многих исследователей, как зарубежных, так и отечественных. В российской практике первая нейросетевая система массовой оценки объектов недвижимости, описание которой изложено в коллективной монографии 2008 года [4], была создана Л.Н.Ясницким. Опыт нейросетевого моделирования для массовой оценки объектов недвижимости оказался успешным и нашел продолжение в работах [5-7].

Однако, наряду с нейронными сетями, в практике оценки жилья в России широко используются методы классического регрессионного анализ. Так, Г.М.Стерник [8] рассматривал использование методов эконометрического анализа для прогнозирования стоимости жилья в городах России, выделяя основные закономерности, влияющие на повышение цен на жилье. А.П. Дарманян [9] при исследовании эконометрического анализа использует методы корреляционного анализа для прогнозирования стоимости 1м² недвижимости в России.

Настоящая работа является продолжением исследований, начатых в [4-7] и сосредоточена на вопросах оценки стоимости аренды жилой площади. Для построения нейросети, с целью прогнозирования стоимости аренды жилья, было сформировано 445 примеров, собранных с помощью открытой информации на таких сайтах, как: bibliofond.ru, realty.yandex.ru и avito.ru. Данные для обучения сети были взяты за январь-февраль 2017 года. Также, были определены следующие 10 входных параметров, а именно:

X₁ – район: 1 – Орджоникидзевский; 2 – Кировский; 3 – Дзержинский; 4 – Мотовилихинский; 5 – Индустриальный; 6 – Свердловский; 7 – Ленинский.

X₂ – тип стен: 1 –Блоки; 2 – Монолит; 3 – Панель; 4 – Кирпич.

X₃ – количество комнат (в квартире).

X₄ – общая площадь (в квартире).

X₅ – Наличие балкона или лоджии: 1 – Отсутствует; 2 – Есть балкон/лоджия; 2 балкона/лоджии.

X₆ –Наличие мебели: 1 – Нет мебели; 2 – Частично укомплектована; 3 – Полностью укомплектована.

X₇ – Наличие ремонта: 1 – Нет ремонта; 2 – Косметический ремонт; 3 – Евроремонт.

X_8 – Наличие бытовой техники: 1 – Нет техники; 2 – Частично укомплектована; 3 – Полностью укомплектована.

X_9 – Этаж.

X_{10} – Наличие парковки: 1 – Нет парковочного места; 2 – Есть парковочное место.

Выходной параметр модели Y – стоимость месячной аренды квартиры в городе Пермь.

Проектирование, обучение и тестирование сети выполнялось с помощью «Нейросимулятор 5.10», с применением методики Пермской научной школы интеллекта [4]. Наилучшая структура нейронной сети представляла собой персептрон, который имеет 10 входных параметров, 1 скрытый слой с 5 нейронами, а также 1 выходной нейрон.

Далее, собранные примеры, были разделены на две составные части: обучающую выборку, состоящую из 375 примеров и тестирующую – из 70 примеров. В качестве активационных функций был использован тангенс гиперболический. После того, как сеть была обучена, точность прогноза подверглась испытанию на тестовом множестве. Среднеквадратическая ошибка тестирования составила 10,7%. На рисунке 1 представлен результат тестирования, в котором отражено соотношение реальных и прогнозируемых данных.

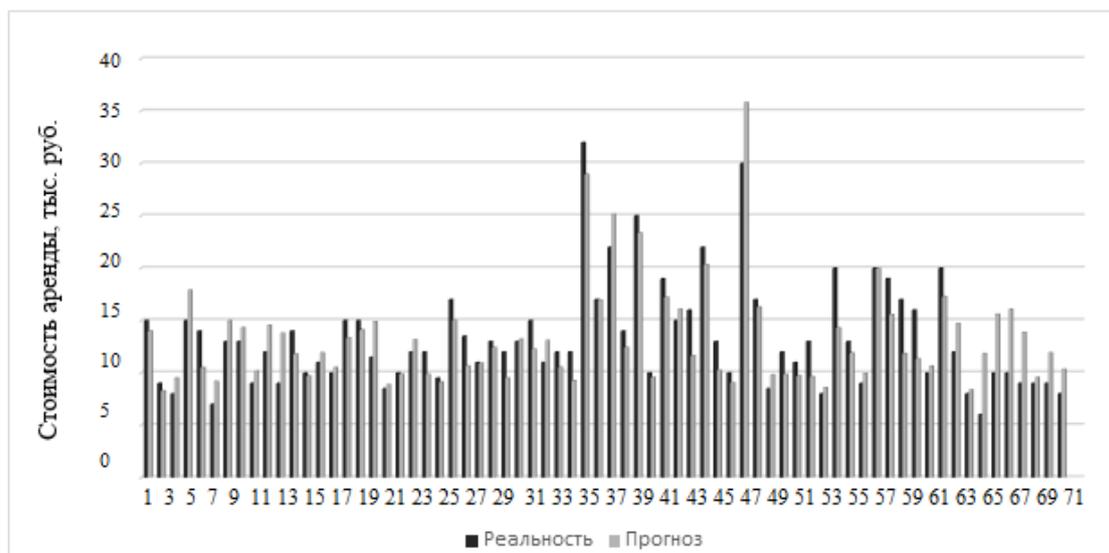


Рис.1. Результат тестирования нейросети

На этапе исследования модели, необходимо оценить значимость параметров с целью определения, тех критериев, которые влияют на стоимость аренды жилья, что представлено на рисунке 2.

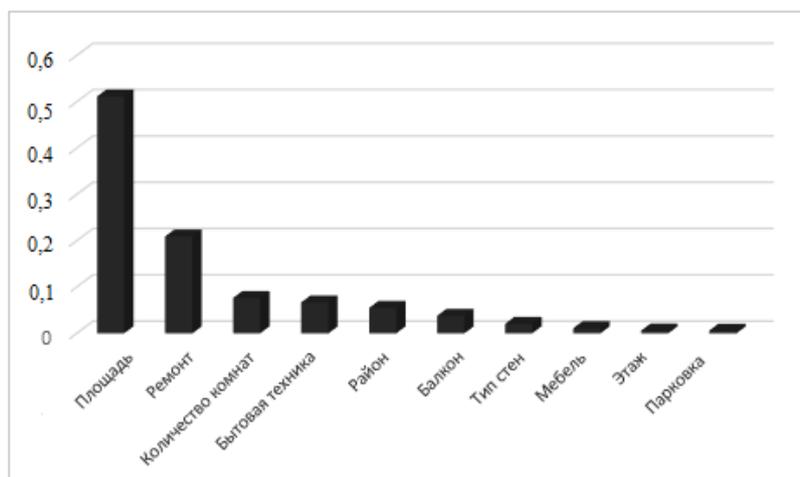


Рис.2. Значимость параметров

Как результат, самым значимым параметром при формировании стоимости аренды является общая площадь квартиры, что является весьма понятным, поскольку при покупке квартиры владелец платит за каждый метр и конечная сумма складывается, исходя из метража. Также, немаловажным фактором является наличие ремонта. На стоимость также значительным образом оказывает влияние количество комнат, наличие бытовой техники и район расположения. Наименее значимые факторы – этаж и наличие парковки.

Далее, проанализируем зависимость стоимости аренды квартиры от района. Пример: трехкомнатная квартира на 4 этаже в кирпичном доме Ленинского района площадью 100 кв.м. В квартире есть балкон, евроремонт, полна комплектация бытовой техникой и мебелью, есть парковка. Стоимость аренды данной квартиры на месяц – 50 тысяч рублей. При изменении района и сохранении остальных параметров неизменными, стоимость квартиры меняется, что дает право определить самый дорогой и самый дешевый район. Результаты представлены на рисунке 3.

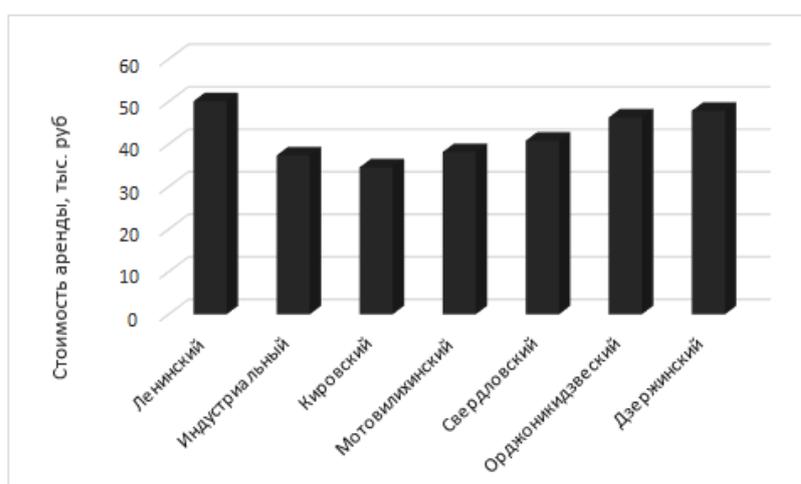


Рис. 3. Зависимость стоимости аренды от района

По рисунку 4 можно сделать вывод, что наиболее дорогой район для аренды жилья является Ленинский район, то есть самый центр города, что является вполне справедливым. Наиболее дешевым – Орджоникидзевский, ввиду его удаленности от центра.

Также исследуем стоимость аренды квартиры, опираясь на разные типы стен в домах. За основу возьмем вышеописанный пример. Результаты моделирования представлены ниже, на рисунке 4.

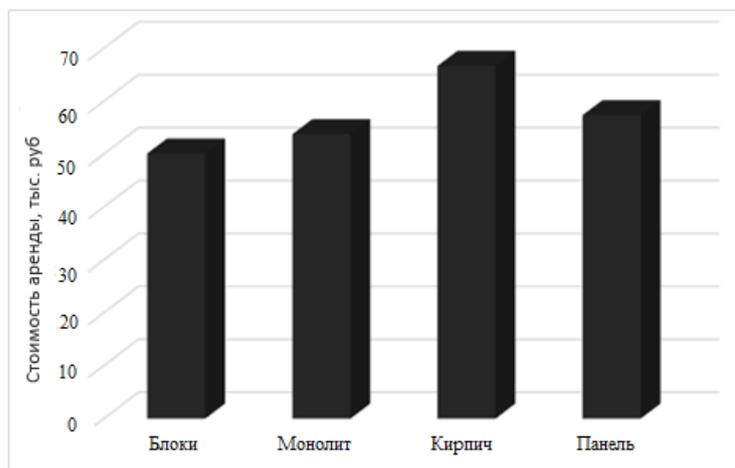


Рис.4. Зависимость стоимости аренды от типа стен в домах

Выводы. В результате серии компьютерных экспериментов было установлено, что самая дорогая аренда квартир находится в Ленинском районе, а самый дорогой материал – кирпич, что является вполне логичным и закономерным.

Самыми незначимыми критериями оказались: этаж и наличие парковки. Можно сделать вывод, что это незначимо только в условиях временного проживания, когда есть возможность в любое время выбрать другое жилье, в соответствии с предпочтениями.

Библиографический список

1. Ясницкий Л. Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
2. Электронный учебник по статистике StatSoft [Электронный ресурс] [Режим доступа: <http://www.statsoft.ru/home/textbook/modules/stneunet.html>] [Проверено: 20.02.2017].
3. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56.
4. Ясницкий Л.Н., Бондарь В.В., Бурдин С.Н. и др. Пермская научная школа искусственного интеллекта и ее инновационные проекты. 2-е изд. Москва-Ижевск: НИЦ «Регулярная и хаотическая динамика», 2008. 75 с.
5. Ясницкий Л.Н., Ясницкий В.Л. Разработка и применение комплексных нейросетевых моделей массовой оценки и прогнозирования стоимости жилых объектов на примере рынков недвижимости Екатеринбурга и Перми // Имущественные отношения в Российской Федерации. 2017. № 3(186). С. 68-84.
6. Ясницкий Л.Н., Ясницкий В.Л. Методика создания комплексной экономико-математической модели массовой оценки стоимости объектов недвижимости на

примере квартирного рынка города Перми // Вестник Пермского университета. Сер. «Экономика» = Perm University Herald. Economy. 2016. № 2(29). С. 54–69. doi: 10.17072/1994–9960–2016–2–54–69.

7. *Yasnitsky L.N., Yasnitsky V.L.* Technique of design of integrated economic and mathematical model of mass appraisal of real estate property by the example of Yekaterinburg housing market // Journal of Applied Economic Sciences. Winter 2016. Volume XI. Issue 8(46). Pp. 1519-1530.
8. *Стерник Г.М.* Эконометрический анализ и прогноз цен на жилье в городах России.- Доклад на конференции Европейской сети исследователей жилищного рынка. Вена, 1997.
9. *Дарманян А. П.* Прогнозирование стоимости жилищного строительства в России // Бизнес. Образование. Право. Вестник Волгоградского института бизнеса . 2013. №2 (23). С. 122-125

USING METHODS OF ARTIFICIAL INTELLIGENCE IN FORECASTING THE COST OF RENTAL HOUSING IN PERM

Shelomova Kristina D.

National Research University Higher School of Economics, 38 Studenckskaya st.,
Perm, 614070, Russia, yienosdotres@mail.ru

A computer program was developed to identify patterns and predict the cost of renting a house in Perm. To develop a computer program, the experience of researchers was reviewed to reflect the relevance of this topic. The program is trained based on the data provided in the public domain on such Internet sites as: bibliofond.ru or realty.yandex.ru. Further, regularities were revealed that reflect the dependence of the rent cost from some criteria. Thus, the most "expensive" areas of the city were ranked and identified, and those where the cost of renting is the lowest.

Keywords: artificial intelligence, neural network, forecast, rent cost.

3. МЕДИЦИНА

РЕАЛИЗАЦИЯ АЛГОРИТМА ДИАГНОСТИКИ ЗАБОЛЕВАНИЙ МОЛОЧНЫХ ЖЕЛЕЗ ПО ДАННЫМ КОМБИНИРОВАННОЙ ТЕРМОМЕТРИИ С ИСПОЛЬЗОВАНИЕМ НЕЧЕТКИХ МНОЖЕСТВ ⁹

Гребнев Виталий Игоревич, Зенович Андрей Васильевич
Волгоградский государственный университет, 400062, Россия, г. Волгоград,
университетский проспект, 100, zenovich@rambler.ru

Рассматривается задача диагностики заболеваний молочных желез по данным комбинированной (радио и инфракрасной) термометрии. Реализован новый алгоритм диагностики с применением нечетких множеств. Проведены вычислительные эксперименты с целью подбора параметров алгоритма. В качестве критерия эффективности алгоритма взято среднее геометрическое его специфичности (доли правильно диагностированных здоровых) и чувствительности (доли правильно диагностированных больных). При оптимальных значениях параметров эффективность алгоритма составляет 75%. Работа выполнена в рамках группового проекта, посвященного созданию экспертной системы экспресс-диагностики заболеваний молочных желез.

Ключевые слова: алгоритмы диагностики, комбинированная термометрия, нечеткие множества, характеристические признаки.

Онкологические заболевания в настоящий момент представляют собой проблему чрезвычайной важности. У женщин самым распространенным онкологическим заболеванием является рак молочных желез. Современная медицина способна успешно лечить опухоли размером 5-7мм, тогда как средний размер опухолей, выявляемых при диагностике, почти в два раза больше. Поэтому необходимы периодические медицинские обследования неинвазивными методами, не наносящими ущерба здоровью пациентки. Одним из таких методов является метод комбинированной термометрии (см., например, [1]). В связи с тем, что температурные аномалии в молочной железе появляются на самой ранней стадии возникновения опухоли, метод позволяет квалифицированному врачу-диагносту по карте температурных полей пациентки выявлять опухоли в тот момент, когда они еще поддаются успешному лечению. К сожалению, при профилактических осмотрах использование метода комбинированной термометрии затруднено, так как для его применения необходим врач-маммолог высокой квалификации.

В связи с этим возникает проблема создания электронной консультативной информационной системы, которая могла бы предложить врачу общей практики предварительный диагноз и его обоснование. Последние несколько лет коллективом специалистов ВолГУ под руководством д.ф.-м.н. Лосева А.Г. ведется разработка такой системы (см. [2]). Главной частью системы является блок принятия решений. В блоке

⁹ Работа выполнена при финансовой поддержке РФФИ (Проект №15-47-02475_p_поволжье_a).
© Гребнев В.И., Зенович А.В., 2017

реализуются различные алгоритмы диагностики (на основе нейросетей, на основе генетических алгоритмов, на основе одномерных и двумерных характеристических признаков и т.д.), окончательное решение принимается методом взвешенного голосования. В данной работе рассматривается реализация одного из алгоритмов диагностики с применением аппарата нечетких множеств.

Диагностика начинается с измерений поверхностных и глубинных температур в двух опорных точках, девяти точках на каждой молочной железе и двух точках в аксиллярных областях. Методика измерений подробно изложена в [3]. Таким образом, каждой пациентке ставится в соответствие вектор из 44-х температур, по которому проводится предварительная диагностика. На основе анализа полученных температур медиками выявлен ряд качественных признаков онкологических заболеваний молочной железы ([1],[3],[4]). Такими признаками, например, являются:

- повышенная термоасимметрия между одноименными точками (областями) молочных желез
 - повышенный разброс температур между различными точками в пораженной молочной железе
 - соотношение кожной и глубинной температуры
- и другие.

По каждому качественному признаку строится набор моделирующих функций $f(t)$ от вектора температур, которые будут использоваться при реализации алгоритма диагностики. Для каждого качественного признака можно построить достаточно большой набор моделирующих функций. Например, при анализе повышенной термоасимметрии можно брать разность температур между одноименными точками, средние арифметические разностей температур между различными областями, разницу температур сосков, дисперсию разностей температур между одноименными точками молочной железы и т.п.

Обучающая и тестовая выборки для задач диагностики сформированы на основе данных онкологических центров. На данный момент в выборке содержится информация о 74 здоровых и 302 больных пациентах. По каждой моделирующей функции строится нечеткое множество. В дальнейшем эти нечеткие множества будут использованы в алгоритме диагностики.

Алгоритм построения нечеткого множества больных по моделирующей функции $f(t)$ заключается в следующем. Пусть множество значений функции f представляет собой промежуток $[m;M]$. Выделяем промежутки $[m;a]$ и $[b;M]$, в которых содержатся значения моделирующей функции только больных пациентов. На указанных промежутках функцию

принадлежности нечеткому множеству больных считаем равной 1. Оставшееся множество $[a;b]$ разбиваем на значимые промежутки, в каждом из которых не меньше 10 % МЖ из класса «Больные» и 10% из класса «Здоровые». На каждом промежутке вычисляем долю здоровых $P1$ и долю больных $P2$ пациентов. Функцию принадлежности нечеткому множеству больных в центре заданного промежутка вычисляем по формуле $\mu = P2/(P1+P2)$. Далее методом наименьших квадратов аппроксимируем полученный набор точек. Проводились вычислительные эксперименты с целью оптимального подбора аппроксимирующей функции, в результате был выбран многочлен 4-й степени.

Алгоритм классификации зависит от скалярного параметра α и вектора параметров $\beta = (\beta_1, \beta_2, \beta_3, \beta_4, \beta_5)$. Обычно $\beta_1 = 1$, а элементы вектора β отсортированы в порядке убывания. Параметры подбираются в процессе вычислительных экспериментов с целью обеспечения наибольшей эффективности алгоритма. В алгоритме используется от 8 до 12 моделирующих функций $f(t)$. Значения функций также отсортированы в порядке невозрастания. Алгоритм состоит из трех шагов:

- 1) Если значения всех моделирующих функций меньше α , то относим пациента к группе здоровых;
- 2) Если для некоторого $i = 1, \dots, 5$ найдется i признаков $f_1(t), \dots, f_i(t)$, для которых верно неравенство $f_i(t) \geq \beta_i$, то относим пациента к группе больных;
- 3) Если п.1 и п.2 не выполнены, пациент остается без диагноза.

В качестве показателей эффективности алгоритма медицинской диагностики традиционно используются его чувствительность (доля верно диагностированных больных) и специфичность (доля верно диагностированных здоровых). В качестве критерия эффективности D алгоритма выберем среднее геометрическое специфичности и чувствительности.

Было написано приложение на языке C++, которое реализует заданный алгоритм. Проводились вычислительные эксперименты с целью оптимального подбора параметров и анализа эффективности алгоритма. При этом использовались различные наборы моделирующих функций. Для каждого качественного медицинского признака в набор включались 2-3 моделирующие функции, слабо коррелирующие между собой. В лучших версиях алгоритма удалось получить значение критерия эффективности до 0.75. (см. Таблицу 1). Рассматривались два значения $V1$ и $V2$ вектора β . В результате вычислительных экспериментов было найдено два подходящих набора моделирующих функций $P1$ и $P2$. $V1=(1; 0,9;0,85;0,8;0,75)$, $V2 = (1; 0,95;0,9;0,85;0,8)$.

Таблица 1. Результаты применения алгоритма для некоторых наборов признаков.

Набор признаков	α	β	Специфичность	Чувствительность	Без диагноза	D
P1	0,65	B2	0,87	0,49	0,23	0,65
P1	0,6	B2	0,81	0,71	0,42	0,76
P1	0,65	B1	0,82	0,49	0,22	0,64
P1	0,6	B1	0,75	0,71	0,39	0,73
P2	0,65	B1	0,85	0,6	0,23	0,71
P2	0,6	B1	0,84	0,62	0,24	0,72
P2	0,65	B2	0,85	0,59	0,23	0,71
P2	0,6	B2	0,84	0,61	0,26	0,72

В настоящее время проводится работа по нахождению оптимального набора моделирующих функций и улучшению параметров алгоритма.

Библиографический список

1. *Веснин С.Г.* Современная микроволновая радиотермометрия молочных желез / Веснин С.Г., Каплан М.А., Авакян Р.С. // Опухоли женской репродуктивной системы. – 2008. – № 3. – С. 28-33.
2. *Зенович А.В.* Алгоритмы принятия решений в консультативной интеллектуальной системе диагностики молочных желез / Зенович А.В., Глазунов В.А., Опарин А.С., Примаченко Ф.Г. // Вестник Волгоградского государственного университета. Серия 1, Математика. Физика. – 2016. - №6 (37). – С.141-151.
3. *Лосев А.Г., Хоперсков А.В., Астахов А.С., Сулейманова Х.М.* Проблемы измерения и моделирования тепловых и радиационных полей в биотканях: анализ данных микроволновой термометрии. // Вестник Волгоградского государственного университета. Серия 1, Математика. Физика. 2015. №6. С. 31–71.
4. *Лосев, А.Г.* О некоторых характерных признаках в диагностике патологий молочных желез по данным микроволновой термометрии / А.Г.Лосев, Е.А. Мазепа, Т.В. Замечник // Современные проблемы науки и образования. -2014.-№6.-С.254.

IMPLEMENTATION OF THE ALGORITHM OF DIAGNOSTICS OF MILK GLAND DISEASES BY THIS COMBINED THERMOMETRY WITH THE USE OF FUZZY SETS

Grebnev Vitaliy Igorevich, Zenovich Andrey Vasilievich,
Volgograd State University, 400062, Russia, г. Volgograd, University prospectus, 100,
zenovich@rambler.ru

In this work, we consider the problem of breast diseases diagnosis according to combined (radio and infrared) thermometry. We implemented a new algorithm for diagnosis using fuzzy sets. We've run some computational experiments to select parameters of the algorithm. Criterion for effectiveness of an algorithm is the geometric mean of its specificity (share of correctly diagnosed healthy ones) and sensitivity (share of correctly diagnosed patients). The efficiency of our algorithm is 75% at optimal values of the parameters. The work is a part of a group project on the creation of an expert system for rapid diagnosis of breast diseases.

Keywords: Diagnostic algorithms, combined thermometry, fuzzy sets, characteristic features.

ГИБРИДНЫЕ КЛАССИФИКАТОРЫ В ЗАДАЧАХ КЛАССИФИКАЦИИ РЕНТГЕНОГРАММ ГРУДНОЙ КЛЕТКИ ¹⁰

Кудрявцев Павел Сергеевич, Малютина Ирина Алексеевна, Томакова Римма Александровна
Юго-Западный государственный университет, 305040, Россия, г. Курск, ул. 50 лет Октября,
94, SFilist@gmail.com

Предложена гибридная технология классификации рентгенограмм грудной клетки, основанная на трехуровневой иерархической структуре. На первом уровне формируются «слабые» классификатора, основанные на двух способах анализа данных. Подход к построению «слабого» классификатора по первому способу основан на анализе амплитудных спектров Фурье в скользящем окне. Рентгеновское изображение последовательно сканируется окнами различного масштаба. В каждом окне определяется амплитудный спектр Фурье, на основе которого строят «слабый» классификатор. Он относит фрагмент изображения, попавшего в скользящее окно, к определенному классу. Второй способ построения «слабого» классификатор основан на дескрипторах, полученных в результате аппроксимации гистограмм яркости в окне анализа. «Слабых» классификаторов, основанных на двух способах анализа, получают столько, сколько масштабов окон анализа было выбрано. На втором иерархическом уровне объединяются решения «слабых» классификаторов внутри каждого способа анализа первого иерархического уровня. Окончательное решение принимает финальный классификатор, агрегирующий решения двух классификаторов второго иерархического уровня.

Ключевые слова: рентгенограмма грудной клетки, классификатор, окно анализа, гистограмма яркости, спектр Фурье, агрегатор решений

Обработка медицинских цифровых изображений на протяжении последних десятилетий является объектом пристального внимания исследователей. Множество работ посвящено математическим и программным методам в данной области, а также разработке аппаратных средств. Интерес исследователей к современным средствам обработки рентгеновских медицинских изображений обусловлен возросшими требованиями к качеству и надежности разрабатываемых диагностических систем.

Для исследования цифровых биомедицинских изображений на кафедре биомедицинской инженерии ЮЗГУ создано программное обеспечение, позволяющее получить набор дескрипторов, предназначенных для построения классификаторов изображений. Исходный интерфейс (главное окно) этого программного обеспечения, разработанного в среде МАТЛАБ, представлен на рис. 1.

¹⁰ Публикация подготовлена при финансовой поддержке РФФИ (грант № 16-07-00164 а)
© Кудрявцев П.С., Малютина И.А., Томакова Р.А., 2017

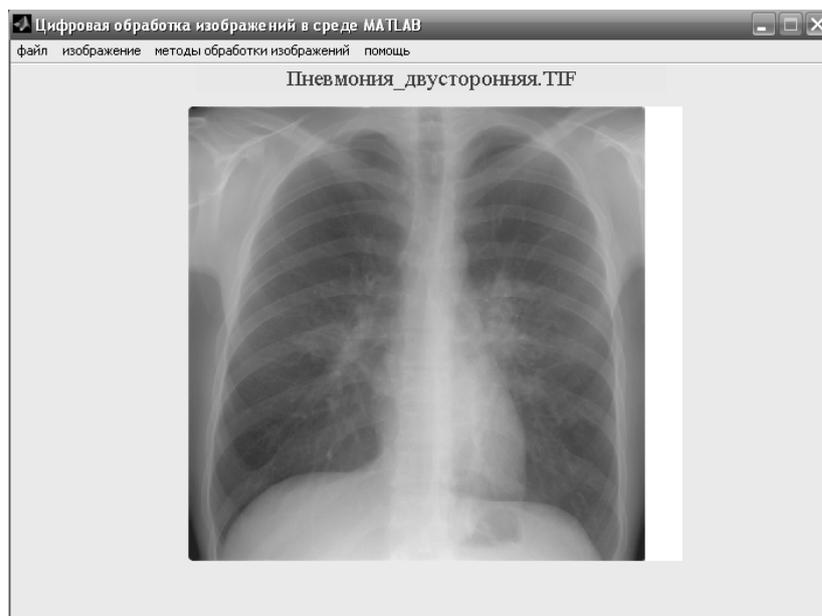


Рис. 1 – Исходный интерфейс программного обеспечения для обработки биомедицинских изображений в среде МАТЛАБ

Среди многочисленных возможностей данного программного обеспечения необходимо выделить программные модули, реализующие спектральные методы обработки изображений. Цель разработки этих модулей – получить инструментальную среду для классификации изображений на основе дескрипторов Фурье. Дескрипторы Фурье определялись из модулей отсчетов оконного двумерного преобразования Фурье на основе выдвинутой концепции построения классификатора рентгенограмм грудной клетки. Согласно этой концепции рентгенограмма грудной клетки сканируется окнами переменного размера. Для каждого размера окна строится свой классификатор, который относят к «слабым» классификаторам. Для построения «слабого» классификатора используют дескрипторы, определяемые по гистограмме яркости амплитудного двумерного спектра Фурье [1]. На рис. 2 в качестве примера представлены два фрагмента рентгенограммы грудной клетки, полученных в окнах одного и того же размера. Справа показаны соответствующие им амплитудные спектры Фурье.

При исследовании оконных спектров рентгенограмм грудной клетки были обнаружены эволюции амплитудных спектров Фурье в зависимости от наличия или отсутствия патологии. Эти эволюции могут быть обнаружены посредством «слабых» классификаторов, построенных на основе обучаемых нейронных сетей. В качестве информативных признаков были использованы гистограммы яркости изображения оконного амплитудного спектра Фурье. Примеры таких гистограмм показаны на рис. 3.

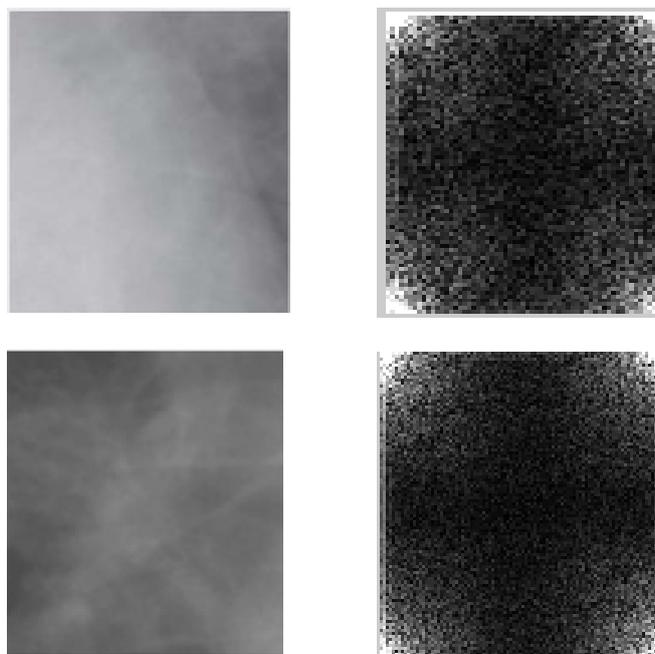


Рис. 2 – Изображения оконных фрагментов рентгенограммы грудной клетки (слева) и их оконные двумерные преобразования Фурье (справа)

Для сравнения, слева показаны гистограммы яркости соответствующих исходных изображений в окне.

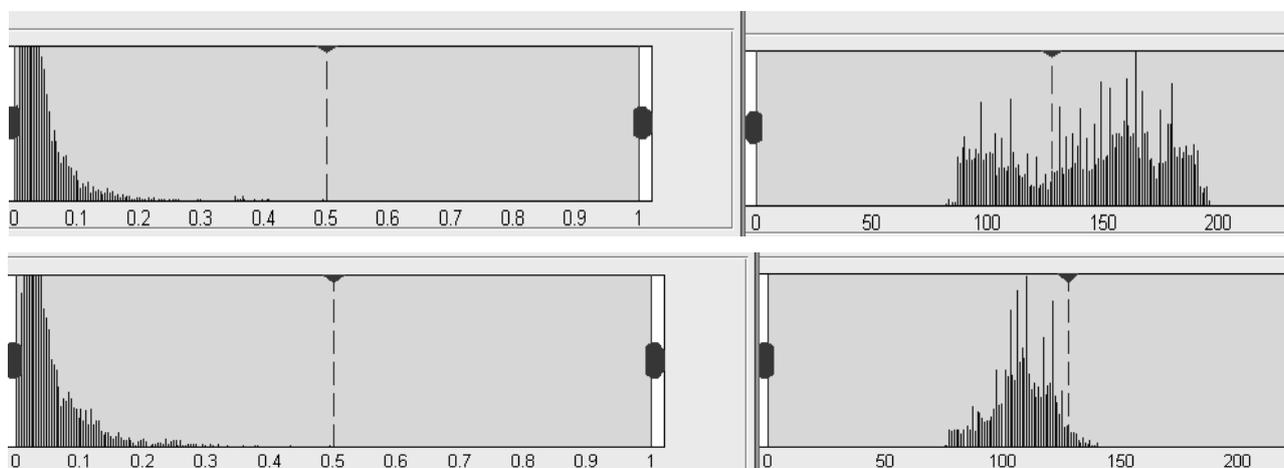


Рис. 3 – Гистограммы яркости оконных фрагментов рентгенограммы грудной клетки (справа) и гистограммы их оконных двумерных амплитудных преобразований Фурье (слева)

Анализ изображений, пример которых показан на рисунках 2 и 3, показал, что форма гистограммы яркости оконных спектров показала более высокую устойчивость по сравнению с соответствующими формами, получаемыми у изображений-оригиналов, что позволило на ее основе сформировать дескрипторы, воспользовавшись методикой, предложенной в [2, 3].

Второй «слабый» классификатор основан на дескрипторах, полученных в результате аппроксимации гистограмм в окне анализа. Для понимания этого метода построения «слабого» классификатора рассмотрим рис. 4. На рис. 4, а слева показано окно анализа рентгенограммы в поле легкого без патологических изменений. Справа на этом рисунке показана гистограмма яркости в этом окне.

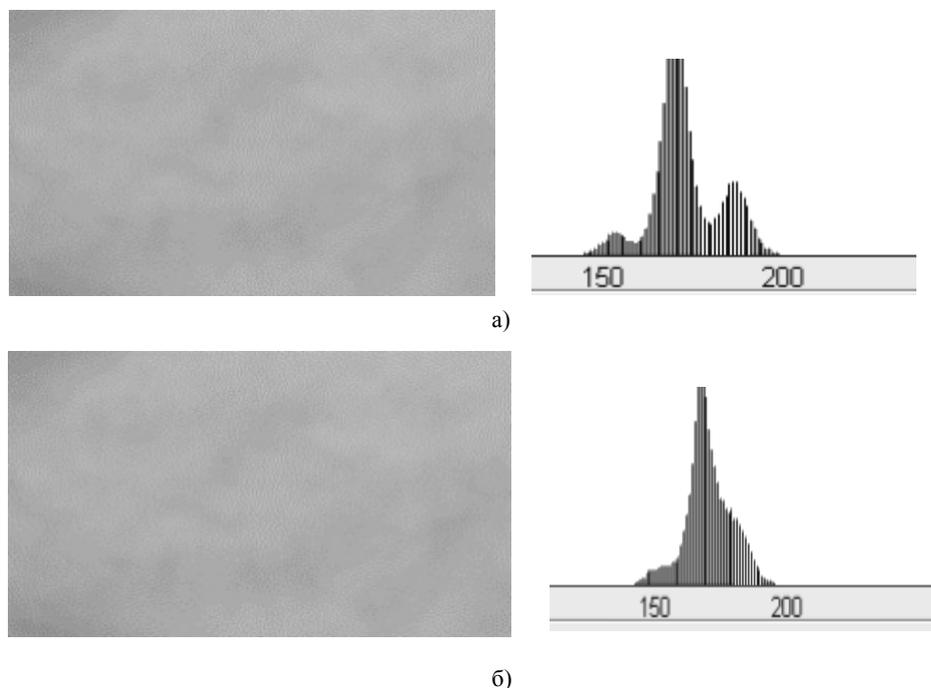


Рис. 4 – Окна анализа и гистограммы яркости рентгенограммы: окно без патологии – а; модель окна с патологией, полученная в результате низкочастотной фильтрации окна без патологии - б

Анализ аналогичных гистограмм различных рентгеновских снимков показал, что при отсутствии патологических изменений в окне анализа гистограммы имеют многомодальную форму. На рис. 4, 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 рис. 5 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.

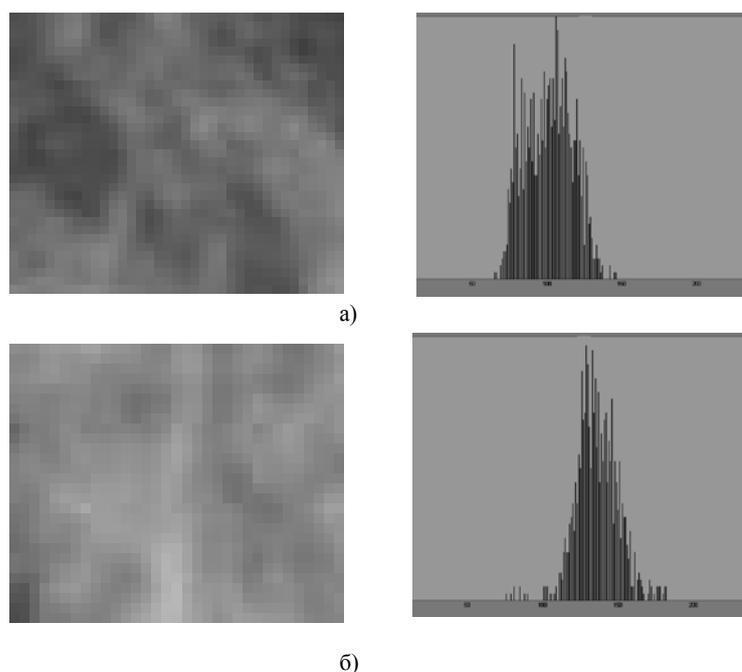


Рис. 5– Окна анализа и гистограммы яркости рентгенограммы: окно без патологии – *а*; окно с пневмонией - *б*

«Слабые» классификаторы строятся для каждого размера окна. Для объединения «слабых» классификаторов в «сильные» используются обучаемые нейронные сети прямого распространения. Обучение классификаторов осуществляется для каждой патологии и для каждого размера окна.

Таким образом, разработан трехуровневый классификатор и программное обеспечение для анализа и классификации рентгеновских снимков, позволяющий осуществлять анализ амплитудных спектров Фурье и гистограммы яркости в скользящем окне. Рентгеновское изображение последовательно сканируется скользящими окнами различного размера. В каждом окне определяется амплитудный спектр Фурье и гистограмма яркости исходного изображения. На основе анализа гистограмм амплитудного спектра Фурье и гистограмм яркости в окне получают дескрипторы, которые используют в качестве пространства информативных признаков для «слабых» классификаторов, построенных на основе обучаемых нейронных сетей. «Слабых» классификаторов, основанных на двух способах анализа, получают столько, сколько масштабов окон анализа было выбрано. На втором иерархическом уровне объединяются решения «слабых» классификаторов внутри каждого способа анализа первого иерархического уровня. Окончательное решение принимает финальный классификатор, агрегирующий решения двух классификаторов второго иерархического уровня.

Библиографический список

1. *Кудрявцев, П.С.* Развитие методологии бустинга для классификации флюорограмм грудной клетки / П.С. Кудрявцев, А.А. Кузьмин, С.А. Филист// Биомедицинская радиоэлектроника, №9, 2016. – С. 10-14.
2. *Томакова, Р.А.* Интеллектуальные технологии сегментации и классификации биомедицинских изображений / Р.А. Томакова, С.Г. Емельянов, С.А. Филист. - Курск: Юго-Зап. гос. ун-т, 2012. - 222с.
3. *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.

ADAPTED TO STRUCTURE GIVEN QUALIFIERS IN PROBLEM OF THE FORECASTING OF THE PROFESSIONAL DISEASES

Kudrjavcev Pavel Sergeevich, Malutina Irina Alekseevna, Tomakova Rimma Aleksandrovna
Southwestern State University, 305040, Russia, г. Kursk, st. 50 years of October, 94,
SFilist@gmail.com

It Is Offered hybrid technology to categorizations of the x-rays of the thorax, founded on трехуровневой to hierarchical structure. On the first level are formed "weak" qualifier, founded on two ways of the analysis data. The Approach to building "weak" qualifier on the first way is founded on analysis amplitude spectrum Furie in slithering window. The X-ray scene is consecutively scanned window of the different scale. In each window is defined amplitude spectrum Furie, on base which build "weak" qualifier. He refers the fragment of the scene, попавшего in slithering window, to determined class. The Second way of the building "weak" qualifier is founded on descriptor, got as a result of aproximations of the histograms to brightness in window of the analysis. "Weak" qualifier, founded on two ways of the analysis, get as much as scale of the windows of the analysis was chose. The decisions "weak" qualifier unite On second hierarchical level inwardly each way of the analysis first hierarchical level. The Final judgement takes the final qualifie, uniting decisions two qualifiers second hierarchical level.

Keywords: x-ray of the thorax, qualifier, window of the analysis, histogram to brightness, spectrum Furie, aggregator of decisions

АДАПТИРУЕМЫЕ К СТРУКТУРЕ ДАННЫХ КЛАССИФИКАТОРЫ В ЗАДАЧАХ ПРОГНОЗИРОВАНИЯ ПРОФЕССИОНАЛЬНЫХ ЗАБОЛЕВАНИЙ

Позин Андрей Олегович, Филист Сергей Алексеевич

Юго-Западный государственный университет, 305040, Россия, г. Курск, ул. 50 лет Октября, 94, SFilist@gmail.com

Шуткин Александр Николаевич

Воронежский институт государственной противопожарной службы, 394052, Россия, г. Воронеж, Краснознаменная, д. 231, anshutkin@email.ru

Рассмотрены вопросы построения классификаторов на основе неполных и противоречивых данных, что характерно для интеллектуальных систем прогнозирования профессиональных заболеваний. Классификаторы строят путем экспертных оценок риска профессионального заболевания в пространстве информативных признаков. Каждая экспертная оценка риска по одному признаку является «слабым» классификатором. «Сильные» классификаторы получают путем агрегации «слабых» классификаторов по группам информативных признаков, формируемым в пространстве признаков, посредством нечеткого логического вывода по схеме Шортлифа. Полученные нечеткие классификаторы агрегируются посредством адаптивной нейронной сети, вектор информативных признаков которой состоит из двух частей: первая формируется из выходов нечетких классификаторов, а вторая - из выходов аппроксиматоров, полученных из нейронных сетей, обучаемых по укороченным векторам информативных признаков, или на основе МГУА – моделей и N – адалинов.

Ключевые слова: риск профессиональных заболеваний, нечеткий логический вывод, нейронные сети, агрегация классификаторов.

При прогнозировании профессиональных заболеваний приходится иметь дело с противоречивыми и неполными данными с преобладанием латентных переменных, нахождение которых плохо формализовано. В этом случае пространство информативных признаков целесообразно представить в виде блоков, каждый из которых определяет структурно независимый сегмент признакового пространства. Это позволяет привлечь к оценке риска в каждом блоке экспертов, специализирующихся в той предметной области, к которой принадлежит блок. По каждому признаку блока эксперты строят «слабые» классификатор, которые агрегируются в более «сильный» классификатор, дающий оценку риска по выбранному блоку информативных признаков [1]. Если построена таблица экспериментальных данных (ТЭД) объект-признак, в которой показатели риска «сильных» классификаторов выступают в качестве независимых переменных, а сам риск определен априорно и является зависимой переменной, то имеется возможность построить обучаемый классификатор, агрегирующий показатели риска профессионального заболевания «сильных» классификаторов.

Вышеизложенная методика построения классификатора обладает рядом недостатков. Например, выходным блоком классификатора является нейронная сеть, которая строит аппроксимирующую эмпирическую модель для входных переменных на интервале определения выходной переменной от нуля до единицы посредством известных алгоритмов обучения, обладающих известными недостатками [2]. В частности, параметры нейронной сети сильно зависят от начальных условий обучения и локальных экстремумов функции ошибки [2]. Кроме того, входы нейронной сети могут быть коррелированы, а «сильный» классификатор, построенный по одному из алгоритмов нечеткого вывода, не адекватно оценивать показатели риска заданного заболевания и являться источником шумового сигнала. При наличии «коротких» выборок это типичное явление. Все это требует построение адаптированных к структуре признакового пространства классификаторов, позволяющих использовать различные классификационные решения, которые, с одной стороны, были бы автономны, а с другой стороны, более «сильное» решение не компенсировалось бы более «слабым» решением при их агрегации.

Одна из возможных структур такого классификатора представлена на рисунке 1. Для сокращения иллюстрационного материала классификатор рассмотрен в трехмерном пространстве информативных признаков, то есть для трех блоков информативных признаков. Полагаем, что x_1 , x_2 и x_3 – выходы «сильных» классификаторов, которые составляют вектор $X1=(x_1, x_2, x_3)^T$.

Классификатор *NET* обучают по ТЭД, в качестве независимых параметров в которой используем эти три информативных признака, а в качестве зависимой переменной – априорный риск R . Трехмерное пространство информативных признаков позволяет сформировать три аппроксиматора *NET1*, *NET2* и *NET3*, которые настраиваются по той же ТЭД, что и классификатор *NET*, только для независимых переменных (x_1, x_2) , (x_1, x_3) и (x_2, x_3) . В случае, если диагностическая эффективность одного из аппроксиматоров *NET1*, *NET2* и *NET3* ниже наперед заданного порогового значения, соответствующий аппроксиматор исключают из схемы рисунок 1. Выходы настроенных таким образом аппроксиматоров составляют вектор $X2=(x_{NET1}, x_{NET2}, x_{NET3})^T$. После построения аппроксиматоров, классификатор *NET* настраивают по ТЭД, в качестве независимых признаков в которой используют исходные признаки и признаки, полученные при контрольном испытании аппроксиматоров, сформированных на предыдущем шаге, то есть вектор информативных признаков X формируется как $X = X1 \cup X2$.

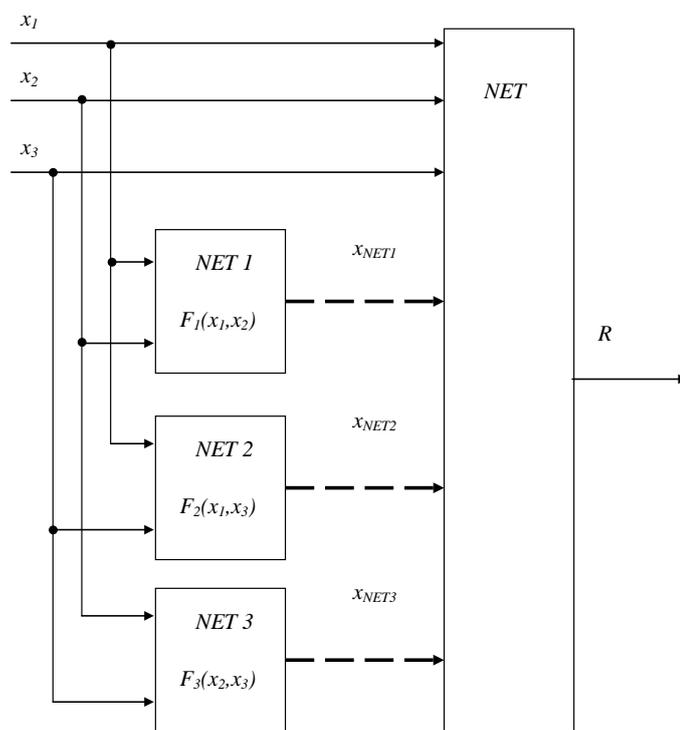


Рисунок 1 – Структурная схема классификатора, адаптированного к структуре признакового пространства

Аппроксиматоры могут быть построены не только на основе нейросетевых технологий, но и на основе МГУА – моделей [3]. Для каждого «сильного» классификатора i посредством МГУА - моделирования получают свое подмножество моделей $\{z_j\}_i \subseteq Z, \forall i = \overline{1, M}$, где M – число «сильных» классификаторов (на рисунке 1 их три). Каждое подмножество моделей $\{z_j\}_i, j = 1 \dots K_i$, где K_i – число МГУА - моделей для i -го «сильного» классификатора, предназначено для описания взаимного влияния «сильных» классификаторов.

Таким образом, для каждого из трех «сильных» классификаторов имеем

$$\begin{aligned}
 z_{11} &= f_{11}(x_1, x_2); & z_{12} &= f_{12}(x_1, x_2); & z_{13} &= f_{13}(x_1, x_2); & z_{14} &= f_{14}(x_1, x_2); \\
 z_{21} &= f_{21}(x_1, x_3); & z_{22} &= f_{22}(x_1, x_3); & z_{23} &= f_{23}(x_1, x_3); & z_{24} &= f_{24}(x_1, x_3); \\
 z_{31} &= f_{31}(x_2, x_3); & z_{32} &= f_{32}(x_2, x_3); & z_{33} &= f_{33}(x_2, x_3); & z_{34} &= f_{34}(x_2, x_3).
 \end{aligned}
 \tag{1}$$

Функции (1) формируются либо на основе исследования статистических связей между компонентами вектора XI , либо на основе одной из схем нечеткого вывода [4].

Соответствующие функции двух переменных и окончательные структуры аппроксиматоров формируют согласно [3]. В этом случае каждый аппроксиматор является МГУА - нейронной сетью, на входы которой поступают полученные путем МГУА - моделирования модели (1), включающие множество выходов «сильных» классификаторов.

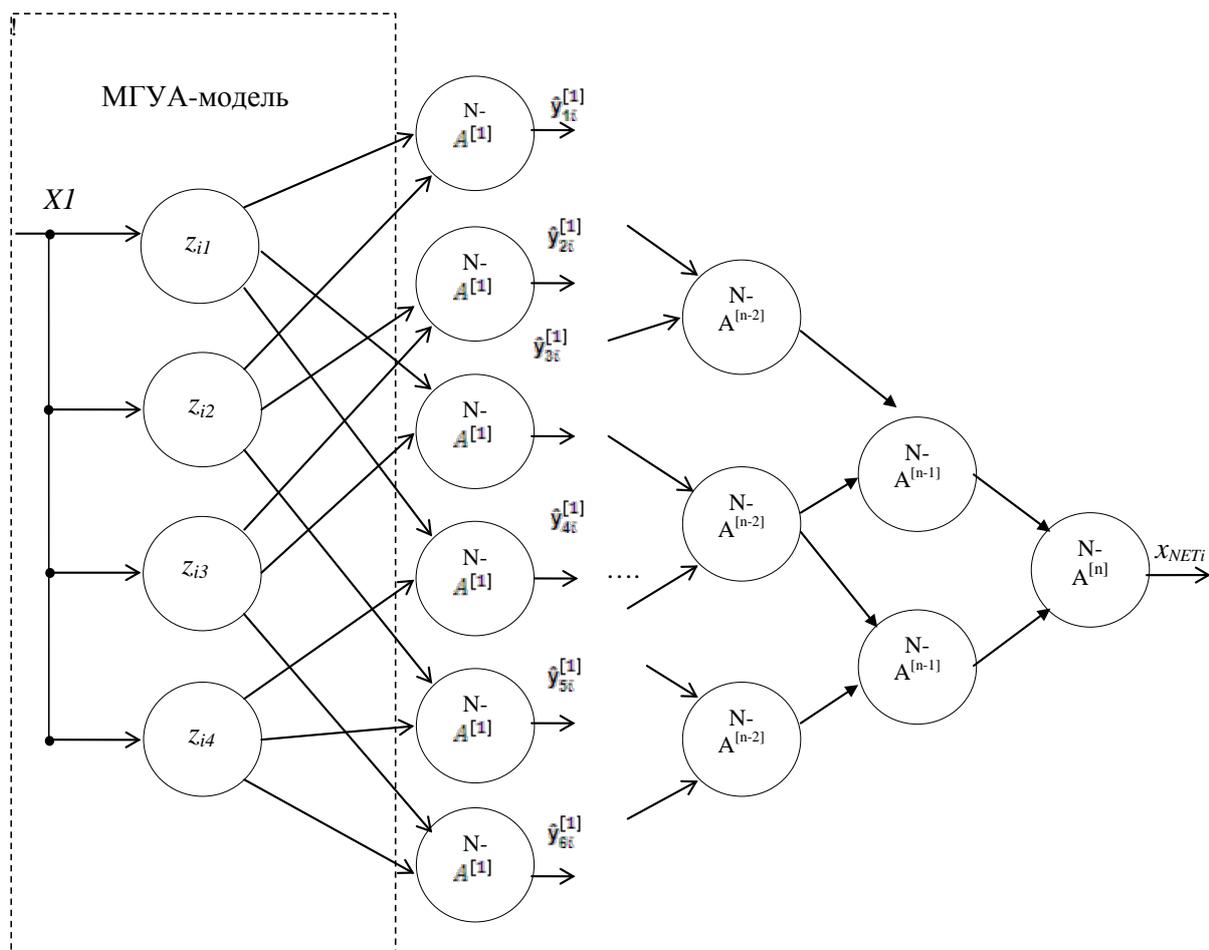


Рисунок 2 – Структурная схема i -го аппроксиматора на основе МГУА – моделирования

МГУА – сеть (рисунок 2) имеет переменную структуру, которая может изменяться в процессе обучения. Каждый нейрон сети – N -адалина представляет собой адаптивный линейный ассоциатор с двумя входами z_g и z_h и нелинейным процессором, образованным тремя блоками умножения, и вычисляет квадратичную комбинацию входов вида

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

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 адальины и наращивании количества слоев для достижения необходимой точности прогнозирования. Количество нейронов первого скрытого слоя сети определяется количеством K МГУА – моделей

соответствующего выхода «сильного» классификатора и не превышает значение $K(K-1)/2$ – 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 множества $\{z_j\}$, $j = 1, 2, \dots, K$ 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, и определяют выход нейросетевого аппроксиматора x_{NETi} .

Представленные модели классификаторов апробированы при прогнозировании профессиональных заболеваний работников аграрно-промышленного комплекса. «Сильные» классификаторы строились по социально-экономическому блоку, блоку признаков, определяющих микроклимат в производственном помещении, блоку производственно-поведенческих факторов и блоку индивидуальных факторов (показателей здоровья).

Библиографический список

1. *Кудрявцев, П.С.* Развитие методологии бустинга для классификации флюорограмм грудной клетки / П.С. Кудрявцев, А.А. Кузьмин, С.А. Филист// Биомедицинская радиоэлектроника, №9, 2016. – С. 10-14.
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. *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.
4. *Моросанова, Н.А.* Алгебраические свойства схемы Шортлифа/ Н.А. Моросанова, С.Ю. Соловьев// Управление большими системами, 2012. Т 36. С. 5-38.

ADAPTED TO STRUCTURE GIVEN QUALIFIERS IN PROBLEM OF THE FORECASTING OF THE PROFESSIONAL DISEASES

Pozin Andrey Olegovich, Filist Sergey Aleksevich

Southwestern State University,

305040, Russia, г. Kursk, st. 50 years of October, 94, SFilist@gmail.com

Shutkin Aleksander Nikolaevich

Voronezh Institute of the State Fire Service,

394052, Russia, г. Voronezh, Krasnoznamennaya, h. 231, anshutkin@email.ru

The Considered questions of the building qualifier on base incomplete and inconsistent data that for intellectual systems of the forecasting of the professional diseases characteristic of. The Qualifiers build the way expert risk assessment professional disease in space of informative sign. Each expert risk assessment on one sign is "weak" qualifier. "Strong" qualifiers get the way to aggregations "weak" qualifier on group of informative sign, formed in space sign, by means of ill-defined inference on Shortlif scheme. Got ill-defined qualifiers aggregate by means of adaptive neurons network, which vector of informative sign consists of two parts: first is formed from output ill-defined qualifier, but second - from output approximators, got from neurons networks, trained on shortcut vector of informative sign, or on base MGUA - a models and N - adalins.

Keywords: risk of the professional diseases, ill-defined inference, neurons network, aggregation qualifier.

УДК 004.032.26

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ ДИАГНОСТИКИ ОНКОЛОГИЧЕСКИХ ЗАБОЛЕВАНИЙ МОЛОЧНЫХ ЖЕЛЕЗ

Примаченко Филипп Германович

Волгоградский государственный университет, 400062, Россия, г. Волгоград,
пр-т. Университетский, 100, kantor.lopital@gmail.com

Работа выполнена в рамках группового проекта по созданию консультативной интеллектуальной системы, предназначенной для диагностики патологии молочных желез по данным микроволновой радиотермометрии. Предложены алгоритмы построения нейронных сетей, способных проводить классификацию молочных желез пациентов с высокой точностью. Рассмотрен метод тестирования предложенных алгоритмов для повышения скорости и качества работы нейронных сетей. Разработан программный модуль, основанный на самоорганизующейся нейронной сети, предназначенный для встраивания в интеллектуальную систему. Приведены результаты экспериментальных исследований программного модуля.

Ключевые слова: микроволновая термометрия, нейронные сети, интеллектуальный анализ данных.

В последнее время метод микроволновой радиотермометрии активно используется при раннем выявлении температурных аномалий молочной железы [1]. Актуальна проблема массовых осмотров, поскольку анализ данных обследования выполняется врачом-маммологом высокой квалификации, прошедшим специальную подготовку, а количество таких специалистов невелико. С целью решения указанной проблемы разрабатывается интеллектуальная система, воспользоваться которой могут не только высококвалифицированные врачи, но и врачи общей практики.

Методика диагностики заболеваний молочных желез подразумевает измерение температур в РТМ и ИК диапазонах в 22 точках. Помимо температур, важным диагностическим признаком является информация с предварительного осмотра пациентов – такая, как наличие и количество точек, в которых пациент испытывал боль на момент осмотра. При диагностике в качестве входных параметров будут применяться поставленные в соответствие каждому пациенту его температуры и информация с предварительного осмотра. Основная цель работы – разработка метода построения и тестирования нейронных сетей с высокой точностью диагностики и скоростью работы.

Исследовались показатели многослойной полносвязной нейронной сети с двумя нейронами на выходе, подтвердившей свою применимость в задачах диагностики в медицине. В качестве альтернативы рассматривалась самоорганизующаяся нейронная сеть, способ построения которой заключён в последовательном добавлении нейронов скрытого слоя по следующему алгоритму:

- 1) Построение и обучение стандартного персептрона (рисунок 1);
- 2) Добавление скрытого нейрона и соединение его со входным слоем и всеми скрытыми нейронами, добавленными до этого. Входные веса нейрона-кандидата настраиваются так, чтобы была достигнута максимальная корреляция между этим нейроном и ошибкой нейронной сети;
- 3) Соединение нейрона кандидата с выходным слоем и обучение весов выходного слоя. После выполнения 2-3 шагов нейронная сеть имеет следующий вид (рисунок 2);
- 4) Если достигнут критерий останова, то добавление скрытых нейронов заканчивается, иначе происходит переход на шаг 2. В качестве критерия останова проводилась проверка точности работы нейронной сети на сторонней (верификационной), не участвующей в обучении, выборке. Если точность диагностики по данной выборке начинала снижаться, обучение заканчивалось.

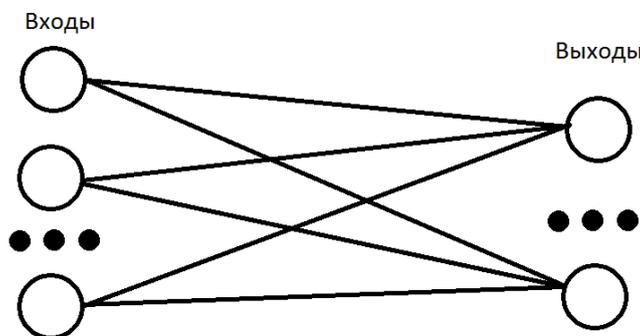


Рисунок 1 – стандартный полносвязный персептрон.

Для обучения весов связей нейронов были апробированы три различных алгоритма оптимизации: алгоритм обратного распространения ошибки [2], метод Хука-Дживса и метод имитации отжига, позволяющий игнорировать локальные минимумы функции ошибки работы нейронной сети и двигаться к глобальному минимуму.

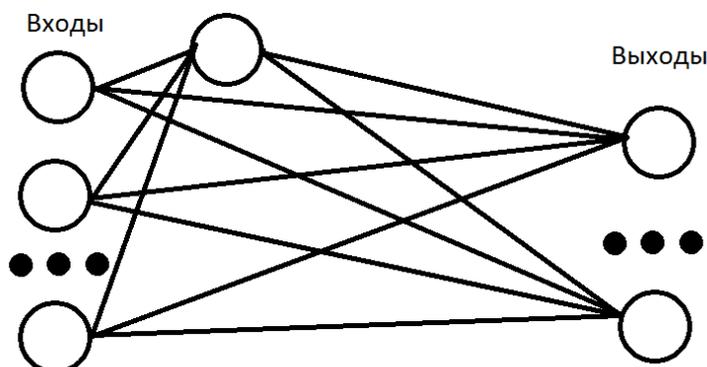


Рисунок 2 – нейронная сеть с одним добавленным нейроном на промежуточный слой.

Помимо прочего, для частичного исключения зависимости результата экспериментов от начальных весов, применяются методы параллелизма, при которых одновременно создаются и обучаются несколько нейронных сетей одной архитектуры с различными начальными весами, после чего выбирается сеть, показавшая лучший результат.

В таблице 1 показаны результаты работы исследованных нейронных сетей на тестовой выборке, где под точностью понимается среднее геометрическое точности классификации объектов каждого класса.

Алгоритм	Архитектура	Точность
Обратное распространение	Многослойный персептрон	56%
Конфигурации Хука-Дживса	Многослойный персептрон	48%
Имитация отжига	Многослойный персептрон	70%
Имитация отжига	Самоорганизующаяся сеть	86%

Анализ данных результатов позволяет сделать вывод, что максимальная эффективность диагностики достигается при использовании самоорганизующейся нейронной сети, обученной методом имитации отжига, которая и стала основой разрабатываемого программного модуля.

Оригинальность выбранного метода построения нейронной сети заключается в том, что его можно применять и в диагностике других заболеваний, включая те, к которым неприменим метод комбинированной термометрии.

Библиографический список

1. Лосев А.Г., Хоперсков А.В., Астахов А.С., Сулейманова Х.М. Проблемы измерения и моделирования тепловых и радиационных полей в биотканях: анализ данных микроволновой термометрии. // Вестн. Волгогр. гос. ун-та. Сер. 1, Мат. Физ. 2015. №6. С. 31–71
2. Хайкин С. Нейронные сети: полный курс. Второе издание. 2006.

USING NEURAL NETWORKS IN THE DIAGNOSTICS OF BREAST CANCER

Primachenko Filipp Germanovich

Volgograd State University, 100, Universitetskiy pr., Volgograd, 400062, Russia,
kantor.lopital@gmail.com

The work was performed as part of a group project to create intelligent Advisory system for diagnostics of breast pathology on the data of microwave radiometry. The algorithms for construction of neural networks that is capable of classifying breast patients with high accuracy. The method of testing the proposed algorithms to improve the speed and quality of work of neural networks. Developed software module based on self-organizing neural networks designed for integration into an intelligent system. The results of experimental studies of the software module.

Keywords: microwave radiometry, neural networks, data mining.

УДК 618.19+004.021

МЕТОДИКА ОПТИМИЗАЦИИ КОЛИЧЕСТВА ДИАГНОСТИЧЕСКИХ ПРИЗНАКОВ ЗАБОЛЕВАНИЙ МОЛОЧНЫХ ЖЕЛЕЗ НА ОСНОВЕ ТЕРМОМЕТРИЧЕСКИХ ДАННЫХ¹³

Сулейманова Хеди Мовладовна

Волгоградский Государственный университет, 4, Россия, г. Волгоград,
проспект Университетский, 100, hedi.medi@mail.ru

Мазепа Елена Алексеевна

Волгоградский Государственный университет, 4, Россия, г. Волгоград,
проспект Университетский, 100, lmazepa@rambler.ru

Исследуются корреляционная взаимосвязь признаков, полученных на основе медицинских термометрических данных, предназначенных для диагностики заболеваний молочных желез с использованием пакета статистических программ SPSS. Определяется степень тесноты взаимосвязи между переменными, выделяются наиболее значимые признаки того или иного заболевания для экспресс-диагностики злокачественных новообразований молочной железы.

Ключевые слова: консультативные интеллектуальные системы, экспресс-диагностика, злокачественные новообразования молочной железы, корреляционный анализ, микроволновая радио-термометрия.

¹³ Работа выполнена при финансовой поддержке РФФИ (проект № 15-47-02475-р_поволжье_a).

Статистические методы анализа данных применяются практически во всех областях деятельности человека, а также для решения задач медицинской диагностики, мониторинга и прогнозирования. Их используют всегда, когда необходимо получить и обосновать какие-либо суждения о группе (объектов или субъектов) с некоторой внутренней неоднородностью. Для решения задачи медицинской диагностики используют класс систем, различающиеся методами, которые положены в их основу. Один из таких классов составляют системы, базирующиеся на статистических и других математических моделях - их основой служат математические алгоритмы, занимающиеся поиском обычно частичного соответствия между симптомами очередного пациента и симптомами наблюдавшихся ранее пациентов, диагнозы которых известны [1, 2].

Диагностика рака молочной железы – это комплексный метод исследования, который состоит из обширного списка методов диагностики. Они применяются в современной медицине, а в частности, в онкологии. На сегодняшний момент диагностика заболеваний молочных желез основывается на осмотре и расспросе больного. В специализированных клиниках и кабинетах применяются такие инструментальные исследования, как ультразвуковое сканирование, рентгенологические методы и др. Применение этих методов, требует подготовки высококвалифицированных кадров, наличия дорогостоящего оборудования и не решает проблему ранней диагностики и динамического контроля над течением заболеваний. Работа комплекса основанная на применении метода комбинированной радиотермометрии (это биофизический метод неинвазивного обследования, который базируется на измерение температуры тела на глубине нескольких сантиметров (РТМ) и на кожном покрове (ИК)), вполне может решить вышеописанные проблемы. Данную технологию в маммологии и во флебологии рекомендуют для скрининга, дифференциальной диагностики и для оценки эффективности проводимого лечения.

Методика обследования подробно описана в работе [3]. Схема измерений представлена на (Рис. 1). Обследование пациентки начинается с измерения температур в опорных точках T_1 и T_2 , расположенных, первая – в центре грудной клетки сразу под и между молочными железами, вторая – непосредственно под мечевидным отростком. Далее измерения проводятся в 10 точках на каждой железе и в аксиллярной области.

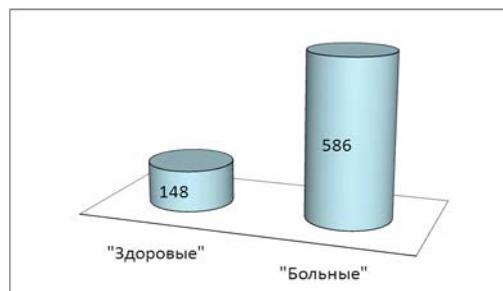
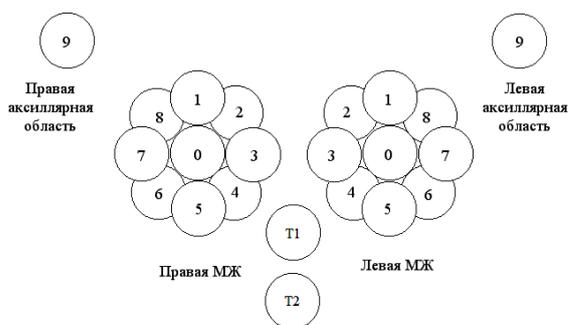


Рис. 1. Схема обследования молочной железы Рис. 2. Структура обучающей выборки.

В течение последних нескольких лет формировалась экспертная база термометрических данных, которые были предоставлены онкологическими центрами. В настоящее время она включает в себя информацию о 734 молочных железах пациенток, которые делятся на два контрольных класса: «Здоровые» – 148 молочных желез и «Больные» – 586 молочных желез.

В ходе исследований и анализа данных, специалистами были выявлены следующие признаки рака молочной железы [4, 5], будем называть их качественными:

- ✓ повышенная величина термоасимметрии между одноименными точками молочных желез;
- ✓ повышенный разброс температур между отдельными точками в пораженной молочной железе;
- ✓ повышенная дисперсия разности температур между железами;
- ✓ повышенная величина разницы температур сосков;
- ✓ повышенная температура соска в пораженной молочной железе по сравнению со средней температурой молочной железы с учетом возрастных изменений температуры;
- ✓ повышенная величина соотношения кожной и глубинной температур;
- ✓ повышенное значение осцилляции температур в областях и некоторые другие.

Поскольку целью данной работы, является оптимизация количества диагностических признаков с учетом их некоррелированности и с сохранением их максимальной информативности. Для достижения поставленной цели будут решены следующие задачи: определение степень корреляционной зависимости диагностических признаков друг с другом; выделение групп взаимозависимых признаков; нахождение внутригрупповых признаков с максимальной информативностью.

В основе исследования связи между диагностическими признаками лежат статистические методы, основанные на вычислении выборочного коэффициента корреляции и на проверке гипотез о его значимости. При этом большинство параметрических критериев

проверки статистических гипотез предполагает нормальность распределения выборочных данных. Для проверки выборочных распределений на принадлежность к нормальному распределению могут быть использованы как приближенный метод проверки гипотезы о нормальном распределении, основанный на вычислении выборочных коэффициентов асимметрии и эксцесса, так и более точный метод проверки согласованности - критерий согласия Пирсона.

Ранее проводились аналогичные теоретические исследования, определяющие степень зависимости температурных изменений в молочной железе от диаметра железы, температуры в аксиллярной области, в контрольных точках на теле пациентки, а также от ряда анамнестических данных [6, 7]. В указанной работе было показано, что большинство выборочных термометрических данных не удовлетворяет нормальному распределению. Поэтому для изучения взаимосвязи диагностических признаков друг с другом целесообразно применять ранговые методы исследования корреляционной взаимосвязи, в частности, основанные на вычислении коэффициента корреляции Спирмена.

В основе данного метода лежит вычисление коэффициентов ранговой корреляции Спирмена ρ_a по формуле [8]):

$$\rho_a = 1 - \frac{6}{n^3 - n} \sum_{i=1}^n d_i^2, \quad (1)$$

где $d_i = x_i - y_i$, а x_i и y_i ($i=1, 2, \dots, n$) – ранги исходных объектов, записанные по исследуемым признакам.

Чтобы выяснить, насколько значение коэффициентов ранговой корреляции Спирмена ρ_a несет случайный или неслучайный характер, необходимо исследовать значимость полученных коэффициентов. Для выбора гипотезы о значимости значение коэффициентов ранговой корреляции Спирмена использовался статистический критерий уровня $\alpha=0,05$ ($p=1-\alpha$) и следующие значения критических точек распределения Стьюдента $t_{кр}$: группа «Здоровые» - 1,97; группа «Больные» - 1,96.

При этом вывод о значимости или незначимости корреляционной взаимосвязи между признаками делался в соответствии со следующим правилом: если $|T_{набл}| < t_{кр}$, то принимается гипотеза $\rho_a = 0$, т.е. между признаками нет корреляционной зависимости; если $|T_{набл}| > t_{кр}$, то принимается гипотеза $\rho_a \neq 0$, что говорит о наличии корреляционной зависимости между признаками [7, 8], Заметим, что в данном правиле в качестве критерия используется статистика

$$T_{i\hat{a}\hat{a}\hat{e}} = \frac{\rho_{\hat{a}}}{\sqrt{1-\rho_{\hat{a}}^2}} \sqrt{n-2}, \quad (2)$$

имеющая распределение Стьюдента с $n-2$ степенями свободы, где $\rho_{\hat{a}}$ – коэффициент ранговой корреляции Спирмена, n – число элементов выборки.

Для каждой из выявленных групп признаков, описанных выше, по термометрическим данным были построены корреляционные матрицы. Было исследовано всего порядка 980 числовых функций между различными исходными термометрическими данными, каждая из которых была пронумерована и имела свой порядковый номер. Они позволили в каждой группе выделить подгруппы коррелирующих друг с другом признаков. В каждую из подгрупп относили признаки, у которых парные корреляции с каким-то признаком этой группы (хотя бы с одним) такие, что $\rho_{\hat{a}} \geq 0,7$. Таким образом, было получено 9 подгрупп, в каждой из которых насчитывалось порядка 100 признаков. Для оценивания степени корреляционной взаимосвязи использовалась шкала Чеддока.

Заметим, что при таком значении $\rho_{\hat{a}}$ выполнено неравенство $|T_{i\hat{a}\hat{a}\hat{e}}| > t_{\hat{e}\hat{d}}$, т.е. корреляционная взаимосвязь признаков является значимой.

Каждый из полученных признаков оценивался с точки зрения его информативности, которая отражает степень диагностической способности этого признака, и вычисляется по формуле [8]:

$$I_l^q = -\ln \left(\frac{C_M^m C_K^k}{C_{M+K}^{m+k}} \right) \lim_{x \rightarrow \infty} \quad (3)$$

где M – количество молочных желез класса «Здоровые», m – количество молочных желез класса «Здоровые», у которых выполнен признак; K – количество молочных желез класса «Больные», k – количество молочных желез класса «Больные», у которых выполнен признак.

Однако, многие из полученных в подгруппах количественных признаков оказываются взаимозависимыми и взаимозаменяемыми. Таким образом, для оптимизации числа полученных диагностических признаков была предложена следующая методика, основанная на понятии информативности. *Упорядочиваем все признаки по возрастанию информативности и начинаем проверку с признаков с наименьшей информативностью. Если для пары признаков коэффициент $\rho_{\hat{a}} \geq 0,7$ оставляем признак с большей информативностью; если же для этой пары $\rho_{\hat{a}} < 0,7$, то оставляем оба.*

Для примера ниже приведена таблица (см. Таблица 1) признаков из первой подгруппы, выделенная по методике описанной выше.

Таблица 1. Выделенные диагностические признаки

№	Функция	Диапазон	Информативность
12	$\frac{(t_{2D\dot{O}} - t_{2E\dot{E}}) + (t_{3D\dot{O}} - t_{3E\dot{E}})}{2}$		9,89
85	$\max\{t_{2D\dot{O}} - t_{2E\dot{E}}, t_{3D\dot{O}} - t_{3E\dot{E}}, t_{4D\dot{O}} - t_{4E\dot{E}}\}$		6,08
294	$\min_{1,6}\{\min_{1,8}\left\{\frac{t_0 + \sum_{j=1}^k t_{(i+j)(\text{mod}8)+1}}{k+1}\right\}\}$	Разность РТМ и ИК	8,93

Уменьшение числа диагностических признаков с учетом их независимости и максимальной информативности является одним из направлений повышения качества работы консультационных интеллектуальных систем.

Библиографический список

1. Медик В.А., Токмачев М.С., Фишман Б.Б. М 42 Статистика в медицине и биологии: Руководство. В 2-х томах/ под ред. Ю.М. КОМАРОВА, Т.1. Теоретическая статистика – М.: Медицина, 2000. – 412 с.
2. В.П. Харченко. Маммология: национальное руководство/ под ред. В.П. Харченко, Н.И. Рожковой. –М. : ГЕОТАР-Медиа, 2009. – 328с.
3. Тихомирова Н.Н. Микроволновая радиотермометрия. Техника проведения РТМ-обследования молочных желез. 2008. – 64с.
4. Лосев А.Г., Мазепа Е.А., Замечник Т.В. О некоторых характерных признаках в диагностике патологии молочных желез по данным микроволновой радиотермометрии // Современные проблемы науки и образования. – 2014. – № 6.
5. Моисеенко В.М. Кинетические особенности роста рака молочной железы и их значение для раннего выявления опухоли / Моисеенко В.М., Семиглазов В.Ф. – Маммология, №3, 1997. с. 3-11.
6. Замечник Т.В., Мазепа Е.А., Черкесова С.И., Панкова Г.В. «К вопросу об оптимизации скринингового обследования молочных желез методом микроволновой радиотермометрии» // Вестник новых медицинских технологий. 2014. Т. 21. № 4. С.34-38
7. Лосев А.Г., Мазепа Е.А., Сулейманова Х.М. О взаимосвязи некоторых признаков РТМ-диагностики заболеваний молочных желез Вестник ВолГУ. Серия 1. Математика. Физика, 2015, № 4(29), 35–44
8. Воронцов К.В., Лекции по логическим алгоритмам классификации, 2007.

THE METHOD OF OPTIMIZATION NUMBER OF DIAGNOSTIC SIGNS OF BREAST DISEASES ON THE BASIS OF THERMOMETRIC DATA

Suleymanova Khedi Movladovna

Volgograd State University, 400062, Russia, г. Volgograd, prospekt Universitetskiy, 100,
hedi.medi@mail.ru

Mazepa Elena Alekseevna

Volgograd State University, 400062, Russia, г. Volgograd, prospekt Universitetskij, 100,
lmazepa@rambler.ru

The work is devoted, the study of the correlation relationship signs, derived from medical thermometer data intended for the diagnosis of breast diseases. One of the directions of development of artificial intelligence systems is the development of expert systems for medical diagnostics. Their use helps the doctor to improve the quality of their work. The objective of such systems is not only the definition but also consulting assistance in identifying diseases (one or more), which may ill patient, based on his observations. When creating intelligent advisory systems developers rely on a number of high-quality diagnostic features, these doctors. For their mathematical interpretation of a variety of functional relationships between the initial thermometric data can be used. In this regard, the number of possible diagnostic quantitative traits that may be employed in diagnostic systems eksperss increases to several hundred or even thousands. Each of the resulting symptoms was assessed in terms of its information content, which reflects the degree of diagnostic ability of this feature. However, many of the quantified traits are interdependent and interchangeable. Reducing the number of diagnostic features with regard to their independence and maximum information content is one of the ways of increasing the quality of advisory intelligent systems.

Keywords: microwave radiometry, intellectual consulting systems, express diagnostics, cancer of the breast, correlation analysis.

УДК 004.89; 616.34

РАЗРАБОТКА НЕЙРОСЕТЕВОЙ СИСТЕМЫ ПРЕДВАРИТЕЛЬНОЙ ДИАГНОСТИКИ ЗАБОЛЕВАНИЙ ЖЕЛУДОЧНО-КИШЕЧНОГО ТРАКТА¹⁵

Хлынова Ольга Витальевна

Пермский государственный медицинский университет им. академика Е.А. Вагнера
614000, Россия, г. Пермь, Петропавловская, д. 26, olgakhlynova@mail.ru

Скачкова Ирина Николаевна

Пермский государственный национальный исследовательский университет
614990, Россия, г. Пермь, ул. Букирева, 15, skachkova596@gmail.com

Описан опыт разработки нейросетевой системы дифференциальной диагностики некоторых заболеваний желудочно-кишечного тракта. Для ее построения были использованы данные реальных пациентов разных половозрастных категорий. В качестве входных параметров модели учитывались различные группы факторов, включая основные жалобы пациента, диагностически важные детали его анамнеза жизни и заболевания, а также результаты лабораторно-инструментального обследования. Для построения нейросетевых моделей были использованы два нейропакета (Нейросимулятор 5.0, STATISTICA 12), результаты сравнивались между собой. Для каждой нейросетевой модели была оценена ее адекватность, а также была произведена оценка значимости факторов, которые оказывают наибольшее

¹⁵ Публикация подготовлена при финансовой поддержке РФФИ: грант № 16-01-00164.

влияние на развитие заболеваний «Гастрит» и «Язвенная болезнь желудка и двенадцатиперстной кишки».

Ключевые слова: система диагностики, гастрит, язвенная болезнь, предварительная диагностика, нейронная сеть.

За последние несколько лет интерес к нейронным сетям существенно возрос: они применяются в финансах, бизнесе, медицине, промышленности, и других областях. Нейронные сети могут использоваться везде, где требуется решать задачи прогнозирования, классификации или управления, потому что они применимы практически в любой ситуации, когда имеется связь между входными и прогнозируемыми переменными, даже если эта связь имеет сложную природу. Медицинская статистика отмечает, что в последние десятилетия патология желудочно-кишечного тракта занимает в списке заболеваний одно из ведущих мест. Вопросы диагностики в гастроэнтерологии одно из самых дискуссионных моментов в современной медицине, в первую очередь из-за неопределенности данных; большого индивидуального разброса параметров; невысокой специфичности большинства диагностических признаков. Отсутствие четких диагностических критериев и обилие диагностической информации часто делают сложным ее осмысление врачом. Поэтому, в сложившейся ситуации, совершенствование системы диагностики заболеваний желудочно-кишечного тракта с применением высоко чувствительных, но при этом не инвазивных тестов является достаточно востребованной.

Классическая схема построения сети предполагает наличие группы входных параметров (нейронов), являющихся информацией об объекте исследования, и нескольких выходных нейронов, количество которых задается равным количеству всевозможных заболеваний [1]. Эта схема используется во многих нейросетевых диагностических системах, но в ходе экспериментов выяснилось, что, замена одной сети N с выходами на N сетей с одним выходом позволяет снизить погрешность постановки диагнозов, поэтому возможно исследование каждого диагноза отдельно. Такими диагнозами были выбраны «Гастрит», «Язвенная болезнь желудка и двенадцатиперстной кишки».

Цель исследования – проектирование нейросетевых моделей, позволяющих с высокой степенью точности ставить предварительные диагнозы заболеваний желудочно-кишечного тракта, на основании параметров, полученных с помощью анкет, содержащих данные обследованных пациентов. В статьях, которые были изучены при анализе литературы, целью нейросетевых систем было определение наличия или отсутствия заболеваний [2, 3], либо выражение степени уверенности в наличии заболевания [4-6]. В данной работе целью является не только выявить, здоров или болен пациент, но также определить степень развития его заболевания.

Для создания системы сотрудниками Пермского государственного медицинского университета им. акад. Е.А. Вагнера МЗ РФ, был предоставлен набор данных, состоящий из 588 примеров. Каждый пример содержал информацию в виде признаков о пациентах, у которых выявлены заболевания желудочно-кишечного тракта различной степени, закодированные следующим образом: 0 – заболевания нет, ..., 4 – самая тяжелая форма. В предоставленном множестве отображено максимально возможное количество параметров, характеризующих степень заболевания: демографические данные, жалобы пациента, анамнез жизни, анамнез заболевания, объективный статус и дополнительные методы исследования. Все множество, разбивалось на обучающее и тестирующее, в соотношении 90 %: 10 %. Таким образом, в качестве структуры для каждой нейросети использовался многослойный персептрон с 208 входными параметрами и одним выходным. Количество скрытых слоев и нейронов на скрытых слоях подбирались экспериментальным путем, исходя из минимума среднеквадратичной погрешности на обучающем и тестирующем множествах.

Под погрешностью тестирования понимается среднеквадратичная ошибка, вычисленная на тестирующей выборке по формуле:

$$\varepsilon_T = \frac{\sqrt{\frac{\sum_{n=1}^N (d_n - y_n)^2}{N}}}{|\max(y_n) - \min(y_n)|} 100\% ,$$

где N – число примеров тестирующей выборки, d_n – степень заболевания, вычисленная нейросетью, y_n – фактические степень заболевания. В качестве активационных функций нейронов скрытого и выходного слоев использовались логарифмическая функция и функция гиперболического тангенса. Проектирование, обучение и тестирование нейронных сетей производилось с помощью двух нейропакетов: Нейросимулятор [7] и STATISTICA.

Диагностирующие свойства нейросетей проверялись на тестирующем множестве с помощью различных оценок: вычисление среднеквадратичной ошибки тестирования и вычисление точность постановки диагноза (процент правильно поставленных диагнозов среди пациентов тестирующей выборки). Под правильно поставленным диагнозом понимается тот, в котором разница между фактическим диагнозом и диагнозом нейросети не превосходит единицы по модулю.

На первоначальном этапе ошибки тестирования составляли: 24% для заболевания «Гастрит» и 19% для заболевания «Язва». Точность постановки диагноза составляла: 52% для заболевания «Гастрит» и 88% для заболевания «Язва». Таким образом, изначально нейронные сети показали недостаточное качество постановки диагнозов. Поэтому было

необходимо проанализировать исходные данные на наличие выбросов и противоречащих примеров [8]. Под выбросами понимаются элементы совокупности, по каким-либо причинам выпадающие из общих закономерностей предметной области. Обнаружение таких примеров в обучающем множестве происходило с помощью статистических методов, и с помощью метода, определения подозрительных примеров, на основе нейросетевой модели [8]. Суть его заключается в анализе примеров, для которых обученная нейросеть затрудняется поставить верную степень развития заболевания, то есть модуль разности между постановкой диагноза врача и диагнозом нейросети максимален. Было выдвинуто предположение, что подобные примеры выпадают из общей закономерности, но не означает, что их следует удалить. Так как существовала вероятность, что изначально при составлении множества могла быть допущена ошибка в постановке степени развития диагноза. Подозрительные на выброс примеры повторно изучались врачами-специалистами и при необходимости были исправлены.

После оптимизации нейросетевых моделей и выявления выбросов удалось снизить погрешность тестирования и повысить точность постановки диагнозов.

В таблице №1 представлены вычисленные среднеквадратичные ошибки тестирования и точности постановки диагнозов в двух нейропакетах:

Таблица 2. Сравнение результатов нейросетевых моделей, построенных с помощью двух нейропакетов

Заболевание	Нейросимулятор		STATISTICA	
	Среднекв. ошибка на тестовом множестве	Точность	Среднекв. ошибка на тестовом множестве	Точность
Гастрит	7,51%	90%	7,22%	90%
Язва	5,68%	95%	8,06%	89%

Поскольку разница между полученными среднеквадратичными погрешностями для заболевания «Гастрит» в Нейросимуляторе и STATISTICA незначительна, а для заболевания «Язва» лучшую ошибку удалось получить в Нейросимуляторе [7], то модели, созданные с помощью Нейросимулятора, были выбраны как лучшие.

Результаты проверки работы нейросетевой диагностической системы на тестирующем множестве представлены на рис.1-2 в виде сопоставления диагноза, поставленного врачами, и диагноза, полученного в результате вычислений нейронной сети.

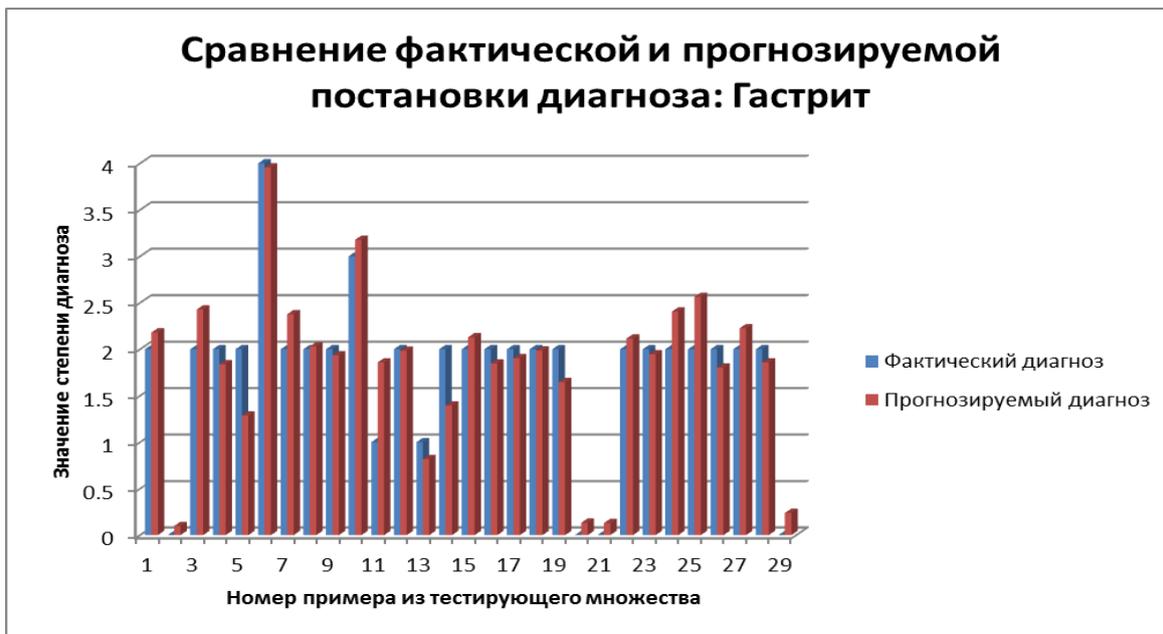


Рисунок 6. Сравнение фактической и прогнозируемой постановки заболевания для заболевания "Гастрит"



Рисунок 7. Сравнение фактической и прогнозируемой постановки заболевания для заболевания "Язва"

С помощью определенной методики, а именно путем поочередного включения (активации) входных нейронов и наблюдением за результатом сети были определены значимости входных параметров моделей [1] (рис.3-4). Оценка значимости входных параметров показала, что для постановки диагноза «Гастрит» наибольшее влияние имели данные, связанные с состоянием слизистой желудка, питанием и жалобами пациента на боли в животе. Для постановки диагноза «Язва» самыми значимыми оказались параметры,

связанные с состоянием слизистой желудка и двенадцатиперстной кишки, жалобами пациента на боль в эпигастральной области и симптом «ниши».

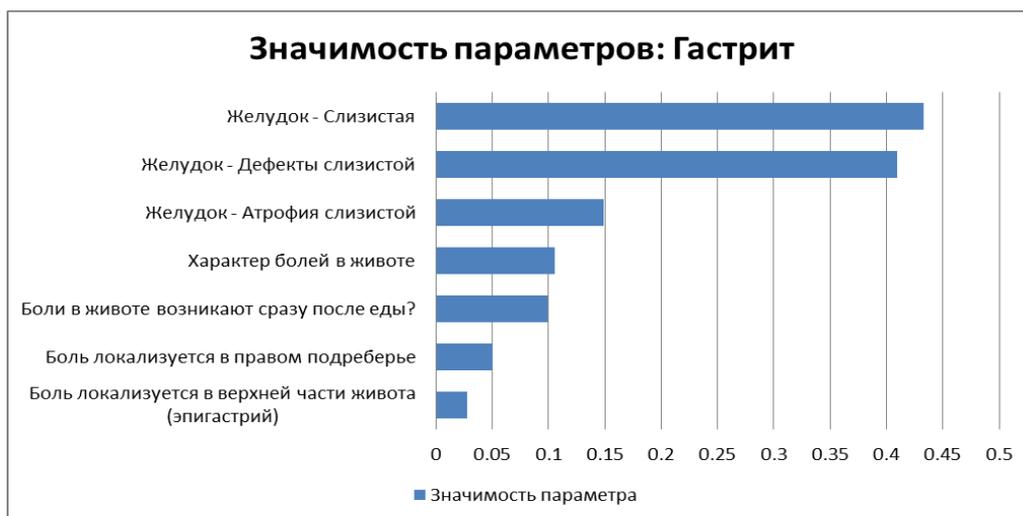


Рисунок 8. Наиболее значимые параметры для диагноза "Гастрит"

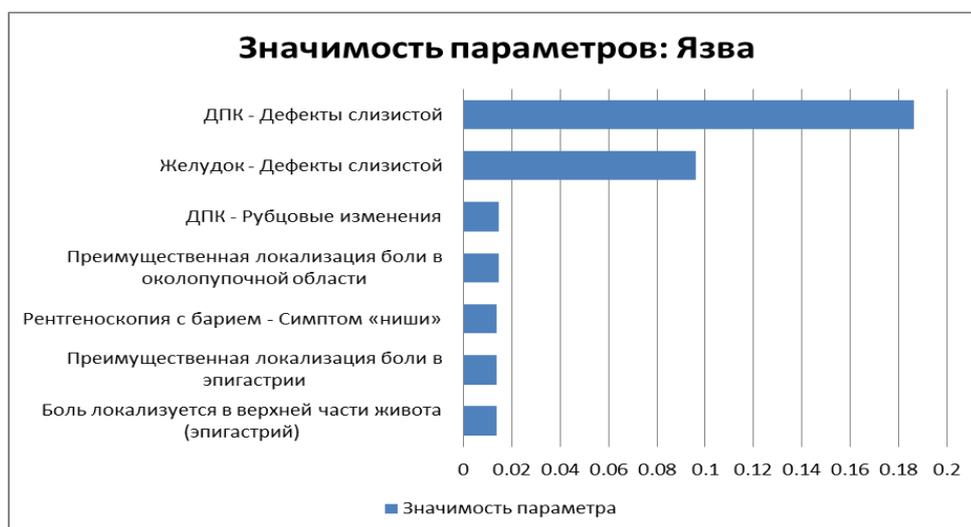


Рисунок 9. Наиболее значимые параметры для диагноза "Язва"

Наиболее значимые параметры, выявленные нейросетью, подтверждают медицинские факты, что говорит об адекватности построенных моделей.

В перспективах данного исследования расширение класса прогнозируемых заболеваний желудочно-кишечного тракта и проведение исследований с целью выявления новых медицинских знаний [5, 9].

Библиографический список

1. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы. Пермь, 2007. 271с.
2. Utomo C.P., Kardiana A., Yuliwulandari R. Breast Cancer Diagnosis using Artificial Neural Networks with extreme learning techniques // International Journal of Advanced Research in Artificial Intelligence, Vol. 3, No. 7, 2014.

3. *Pournik O., Dorri S., Zabolinezhad H., Alavian S.M., Eslami S.* A diagnostic model for cirrhosis in patients with non-alcoholic fatty liver disease: An artificial neural network approach // *Medical Journal of the Islamic Republic of Iran*. Vol. 28, Issue 1, 2014, Pages 1-6.
4. *Ясницкий Л.Н., Думлер А.А., Богданов К.В., Полещук А.Н., Черепанов Ф.М., Макурина Т.В., Чугайнов С.В.* Диагностика и прогнозирование течения заболеваний сердечно-сосудистой системы на основе нейронных сетей // *Медицинская техника*. 2013. № 3. с. 42-44.
5. *Yasnitsky L.N., Dumler A.A., Poleshchuk A.N., Bogdanov C.V., Cherepanov F.M.* Artificial Neural Networks for Obtaining New Medical Knowledge: Diagnostics and Prediction of Cardiovascular Disease Progression // *Biology and Medicine*. 2015. 7(2). BM-095-15.
6. *Ясницкий Л.Н., Думлер А.А., Полещук А.Н., Богданов К.В., Черепанов Ф.М.* Нейросетевая система экспресс-диагностики сердечно-сосудистых заболеваний // *Пермский медицинский журнал*. 2011. Т.28. №4. С. 77-86.
7. *Черепанов Ф.М., Ясницкий Л.Н.* Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.
8. *Черепанов Ф.М., Ясницкий Л.Н.* Нейросетевой фильтр для исключения выбросов в статистической информации // *Вестник Пермского университета. Серия: Математика. Механика. Информатика*. 2008. № 4. С. 151-155.
9. *Ясницкий Л.Н.* Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // *Нейрокомпьютеры: разработка, применение*. 2015. № 5. С. 48-56.

NEURAL NETWORK SYSTEM FOR MEDICAL DIAGNOSTIC OF GASTROINTESTINAL DISEASES

Khlynova Olga V.

Perm State Medical University after Academician E.A.Wagner, st. Petropavlovskaya, 26, Perm,
Russia, 614000, olgakhlynova@mail.ru

Skachkova Irina N.

Perm State University, st. Bukireva, 15, Perm, Russia, 614990, skachkova596@gmail.com

Abstract. This article describes development experience of the neural network system for medical diagnostic of gastrointestinal diseases. There was used patient's practical medical information for its creation. As input parameters were taken into consideration different factor groups, include demographic, patient's complaints, life history, medical history and additional methods of research. Neural network model allowed making a significance assessment of factors, which have disease's development influence. As a result, was designed neural network system of differential diagnosis, allowing diagnoses "gastritis", "peptic ulcer". In the future, developed diagnostic system can be used as a "provisional diagnosis of gastrointestinal diseases".

Key words: gastrointestinal diseases, neural network system, gastritis, gastric ulcer, provisional diagnosis.

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ДИАГНОСТИКИ И ПРОГНОЗИРОВАНИЯ РАЗВИТИЯ СЕРДЕЧНО-СОСУДИСТЫХ ЗАБОЛЕВАНИЙ¹⁷

Думлер Андрей Артурович, Чугайнов Сергей Владимирович

Пермский государственный медицинский университет им. академика Е.А. Вагнера
614000, Россия, г. Пермь, Петропавловская, д. 26, ivan.ivanovskii.2000@mail.ru

Черепанов Федор Михайлович

Пермский государственный гуманитарно-педагогический университет,
614000, Россия, г. Пермь, ул. Пушкина, 42, fe-c@yandex.ru

Ясницкий Леонид Нахимович

Пермский государственный национальный исследовательский университет
614990, Россия, г. Пермь, ул. Букирева, 15, yasn@psu.ru

В статье описан опыт разработки и применения нейросетевой системы для диагностики, прогнозирования и выявления новых знаний в области заболеваний сердечно-сосудистой системы. Обнаруженные методом математического моделирования закономерности и следующие из них выводы в некоторых частных случаях не вполне согласуются со сложившейся в современной медицине практикой профилактики заболеваний, что свидетельствует о необходимости дальнейших исследований.

Ключевые слова: система диагностики, прогнозирование развития, инфаркт, рекомендации, нейронная сеть.

На сайте Пермского отделения Научного совета РАН по методологии искусственного интеллекта (www.PermAi.ru) в разделе «Проекты» размещен демонстрационный прототип интеллектуальной системы диагностики и прогнозирования развития сердечно-сосудистых заболеваний человека [1, 2]. Нейронные сети, составляющие основу интеллектуальной системы, обучены на статистической информации, сформированной с помощью данных о пациентах отделения неотложной кардиологии ГАУЗ ПК ГКБ №4 г. Перми.

Работа с системой осуществляется в три этапа.

На первом этапе запускается нейронная сеть, выполняющая «Самостоятельное обследование» клиента, предназначенная для пользователя, не имеющего медицинского образования. В меню «Общие сведения» и «История жизни» пользователю предлагается ввести 27 параметров, характеризующих его дату рождения, возраст, пол, рост, вес, группу крови, наличие вредных привычек (курение, употребление алкоголя, наркотиков), занятие физкультурой, сведения о ранее перенесенных заболеваниях, сведения о наличии заболеваний у родственников, жалобы и т.д. На основании этих данных система ставит

¹⁷ Публикация подготовлена при финансовой поддержке РФФИ: грант № 16-01-00164.

предварительный диагноз в виде гистограммы из семи столбцов, высота каждого из которых отражает вероятность (или степень развития) соответствующего заболевания сердечно-сосудистой системы: инфаркт миокарда, стенокардия стабильная, стенокардия нестабильная, гипертоническая болезнь, аритмии и блокады сердца, хроническая сердечная недостаточность, острая сердечная недостаточность.

На втором этапе с помощью пункта меню: «Первичное обследование» пользователю предлагается ввести дополнительно еще 22 параметра: пальпация пульса, артериальное давление, наличие ожирения, окраска кожных покровов, данные электрокардиографии и т.д., после чего система выставляет уточненный диагноз, учитывающий эти дополнительные сведения.

На третьем этапе с помощью пункта меню «Специальное обследование» пользователю предлагается ввести еще 20 параметров, с результатами эхокардиографии, общего и биохимического анализа крови. Таким образом, окончательный диагноз система выставляет с учетом 69 параметров пациента. Причем, на каждом из этих трех этапов пользователь имеет возможность, путем изменения своего возраста, выполнить прогноз развития обнаруженных заболеваний на будущие периоды жизни, а также посмотреть, как и на сколько изменятся прогнозы в случае изменения образа жизни: курения, употребления алкоголя, занятий спортом, физкультурой, соблюдения диеты, изменения веса, употребления некоторых лекарственных препаратов.

Интеллектуальная система является математической моделью изучаемой предметной области – человека с его комплексом сердечно-сосудистых заболеваний. Поэтому, в пределах математической погрешности, математическая модель ведет себя так же, как вела бы себя сама моделируемая предметная область. Поэтому разработанную математическую модель можно использовать для исследования закономерностей предметной области. Например, изменяя какой-либо один или несколько входных параметров (возраст, вес, привычки и др.) наблюдать за поведением выходных параметров – степенью развития заболеваний.

Этот метод исследования математических моделей называется «методом замораживания», поскольку все остальные входные параметры, характеризующие человека и его состояния здоровья в процессе компьютерного эксперимента остаются неизменными. Метод замораживания имеет недостаток, заключающийся в том, что в действительности, входные параметры системы обычно имеют между собой сложные корреляционные взаимозависимости, и при изменении одного из входных параметров другие параметры тоже должны быть изменены согласно этим зависимостям. Например, с возрастом появляются

новые симптомы, изменения на электрокардиограмме, результаты эхокардиографии и т.д. Но такие зависимости заранее неизвестны. Поэтому, при создании нейросетевых моделей, предназначенных для исследования предметных областей с целью получения новых знаний, рекомендуется [3, 4] использовать минимальное количество входных параметров, оставляя остальные входные параметры «за кадром», т.е. не ограничивая их изменение. Иногда, при умелом подборе минимального количества входных параметров удается добиться относительно высокой точности диагностики. Например, на первом этапе работы предлагаемой интеллектуальной системы, используя только такие первоначальные сведения о пациенте, как дата рождения, возраст, пол, рост, вес, группа крови, наличие вредных привычек, занятие физкультурой, сведения о ранее перенесенных заболеваниях, сведения о наличии заболеваний у родственников, минимальное количество жалоб, нейронные сети прогнозируют вероятность наличия (или степени развития) заболеваний с погрешностью 15 – 20%. Поэтому, для исследования закономерностей моделируемой предметной области были выбраны нейронные сети именно первого этапа предлагаемой интеллектуальной системы.

Для первой серии компьютерных экспериментов были выбраны 89 больных инфарктом. Нейронная сеть первого этапа интеллектуальной системы всем больным вычислила вероятность инфаркта 75%, что на рисунке 1 изображено столбцами темного цвета. Светлыми столбцами на этом же рисунке представлены результаты вычислений нейросети при изменении входного параметра с «Пациент курит» на «Пациент не курит». Как видно из рисунка, у семи пациентов из 89 вероятность инфаркта снизилась с 75% до 9,5%. Это пациенты № 23, 24, 39, 46, 53, 60, 77.



Рис. 1. Вероятность инфаркта, прогнозируемая нейросетью больным инфарктом для случаев – «Пациент курит» и «Если бы не курил»

Все семеро пациентов, оказавшиеся чувствительными к курению, были мужчины в возрасте: 50, 51, 54, 55, 58, 60, 66 лет. Обнаружить какой-либо один общий входной параметр, выделяющий их из всех остальных пациентов, к сожалению, не удалось. По-видимому, чувствительность к курению зависит не от одного входного параметра, а от сочетания многих входных параметров.

Аналогичные исследования были проведены на предмет влияния веса и занятий физзарядкой. Вот предварительные результаты:

- Из шестнадцати инфарктников, занимающихся физзарядкой у троих не было бы инфаркта, если бы они физзарядкой не занимались.

- Двести инфарктников, не занимающихся физзарядкой, не смогли бы предотвратить инфаркт, если бы занимались физзарядкой.

- Если бы 200 инфарктников имели вес на 5 кг меньше, то 14 из них избежали бы инфаркт.

- Если бы 200 инфарктников имели вес на 10 кг меньше, то 22 из них избежали бы инфаркт.

- Если бы 200 инфарктников имели вес на 10 кг больше, то инфаркта не избежал бы никто.

- 30 курильщиков болеют аритмией и блокадами сердца. Если бы они не курили, то из 30 человек только у одного не было бы аритмии.

- Если бы 100 некурящих человек, болеющих аритмией и блокадами сердца – курили, то это не избавило бы их от этой аритмии.

- Занятия физкультурой не влияют на вероятность аритмии и блокад сердца.

- Увеличение или уменьшения веса не влияют на вероятность заболевания аритмиями и блокадами сердца.

Взяли 176 инфарктников, имеющих плохую наследственность. Если бы у них у всех наследственность была хорошей, то 11-ти из них удалось бы избежать инфаркт. Вывод наличие наследственности увеличивает риск инфаркта на 6,25%

Взяли 33 инфарктника, больных сахарным диабетом. Если бы у них диабета не было, инфаркт был бы по-прежнему у всех. Вывод: Наличие сахарного диабета не влияет на предрасположенность к инфаркту миокарда.

Взяли 189 инфарктников больных гипертонией. Если бы у них не было гипертонии, то в 14 случаях не было бы и инфаркта. Вывод: Наличие гипертонии увеличивает риск инфаркта на 7,4%.

Взяли 172 инфарктника, у которых индекс массы выше нормы. Если бы они привели ИМ в норму ($ИМ_{ср}=21,75$), то у 12 инфаркта бы не было. Вывод: снижение Индекса массы до $ИМ_{ср}$ снижает риск инфаркта на 12,6%.

Заключение. Приведенные результаты компьютерных экспериментов в большинстве случаев согласуются с положениями классической медицинской науки. Однако, в некоторых

случаях, имеются противоречия, что свидетельствует о необходимости проведения дальнейших исследований.

Библиографический список

1. Yasnitsky L.N., Dumler A.A., Poleshchuk A.N., Bogdanov C.V., Cherepanov F.M. Artificial Neural Networks for Obtaining New Medical Knowledge: Diagnostics and Prediction of Cardiovascular Disease Progression // *Biology and Medicine (Aligarh)*. 2015. 7(2): BM-095-15, 8 pages. (http://www.biolmedonline.com/Articles/Vol7_2_2015/BM-095-15_Artificial-Neural-Networks-for-Obtaining-New-Medical-Knowledge-Diagnostics-and-Prediction-of-Cardiovascular-Disease-Progr.pdf).
2. Yasnitsky L.N., Dumler A.A., Bogdanov K.V., Poleschuk A.N., Cherepanov F.M., Makurina T.V., Chugaynov S.V. Diagnosis and Prognosis of Cardiovascular Diseases on the Basis of Neural Networks // *Biomedical Engineering*. 2013. Vol. 47. No 3. Pp. 160-163. DOI: 10.1007/s10527-013-9359-0.
3. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
4. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // *Нейрокомпьютеры: разработка, применение*. 2015. № 5. С. 48-56.

NEURAL NETWORK MODELING TO DIAGNOSE AND PREDICT THE DEVELOPMENT OF CARDIOVASCULAR DISEASES

Dumler, Andrey A., Tuganov Sergey V.

Perm State Medical University n. a. academician E.A.Wagner

614000, Russia, Perm, Petropavlovskaya, d. 26, ivan.ivanovskii.2000@mail.ru

Cherepanov Fyodor M.

Perm State Humanitarian-Pedagogical University,

614000, Russia, Perm, Pushkin str, 42, fe-c@yandex.ru

Yasnitsky Leonid N.

Perm State University

614990, Russia, Perm, street bukireva, 15, yasn@psu.ru

The article describes the development and application of neural network systems for diagnosis, prognosis and identification of new knowledge in the field of cardiovascular diseases. Method of mathematical modeling of the regularities and conclusions, which are not always consistent with current modern medicine practice disease prevention. This fact indicates the need for further research.

Key words: diagnostics, forecasting, heart attack, recommendations, neural network.

4. ПСИХОЛОГИЯ

О ВОЗМОЖНОСТИ СОЗДАНИЯ НЕЙРО-ЭКСПЕРТНОЙ СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ В СФЕРЕ ПРОДАЖ

Заречная Ольга Юрьевна

ООО «NewVision», 614000, Россия, г. Пермь, ул. Сибирская, 9, realnewvision@gmail.com

Сичинава Зураби Иродиевич, Черепанов Федор Михайлович

Пермский государственный гуманитарно-педагогический университет, 614000, Россия, г. Пермь, ул. Пушкина, 42, zurabs@pspu.ru

Ясницкий Леонид Нахимович

Пермский государственный национальный исследовательский университет, 614600, г. Пермь, ул. Букирева, 15, uasn@psu.ru

Рассмотрена попытка создания нейро-экспертной системы поддержки в сфере продаж. Описанная система предназначена для повышения продаж торговыми организациями за счет индивидуального подхода к каждому конкретному клиенту. Использование системы не требует личного участия испытуемого. Система позволяет получать заключения, которые состоят из конкретных фраз и описаний, последовательности используемых коммуникационных приемов, рекомендаций, о том, что необходимо делать для данного клиента для повышения шансов на успешную продажу, а что категорически нельзя делать, чтобы не потерять клиента.

Ключевые слова: психодиагностика, нейросетевые технологии, искусственный интеллект, взаимодействие машины и человека, эффективные стратегии поведения, экспресс-диагностика, психосемантика, нейронные сети.

В условиях экономического кризиса в нашей стране, да и в целом в мире, одной из основных проблем современного бизнеса является прогрессирующее падение спроса:

- в России за 1-2 кв. 2016 г. спрос упал на 3,7% в среднем по стране,
- в отдельных сегментах с момента начала кризиса и санкций спрос упал на 25-30% по сравнению с пиком 2014 г.

В связи с вышесказанным цена ошибки при проведении продажи, особенно в сегменте дорогих товаров и услуг, становится крайне высокой. Для торговой организации особенно важным является повышение лояльности клиента, для чего необходим индивидуальный подход к клиенту. Зная индивидуальные характеристики личности каждого клиента, организация сможет победить в тяжелой «борьбе за клиента». Особенно актуальным индивидуальный подход к клиенту становится в сегменте дорогих товаров и услуг, где количество клиентов не так велико по сравнению с массовым сектором продаж, и каждый клиент располагает ограниченным ресурсом времени на покупки. За счет индивидуального подхода к клиенту возможно сократить время необходимое на продажу клиенту товара, а

также повысить его лояльность к продающей организации за счет разговора с клиентом «на его языке».

В данной статье описывается возможный вариант решения указанной проблемы с использованием нейросетевых технологий [1-4]. Для повышения продаж торговым организациям предлагается использовать нейро-экспертную систему, состоящую из обученных определенным функциям модулей:

- модуль визуальной экспресс-диагностики характера,
- модуль построения индивидуальных семантических пространств человека.

Особенность описываемой нейро-экспертной системы состоит в сочетании методик психологического анализа личности и средств анализа и диагностики, предоставляемых таким мощным средством как нейронные сети.

В рамках реализации системы был разработан алгоритм поддержки продаж, представляющий собой адаптивный нейро-экспертный анализ поведения потенциального покупателя и составление кода профиля личности без его участия в процессе диагностики. Данный алгоритм предназначен для применения менеджером, осуществляющим продажу, и помогает менеджеру классифицировать профиль личности покупателя без проведения психологических тестов. После того как алгоритм определяет код профиля личности, система автоматически формирует уникальные заключения для общения с данным респондентом в рамках решения задачи по продаже. Таким образом система подсказывает менеджеру каким образом вести себя с клиентом, какие слова или фразы использовать, а какие не использовать, для того чтобы осуществить успешную продажу.

При разработке алгоритма поддержки продаж использовалось объединение методологии визуальной экспресс-диагностики поведенческих паттернов покупателя и методологии управляемого речевого воздействия для решения прикладных бизнес-задач повышения продаж. Данные методологии призваны смоделировать мышление психолога эксперта. Таким образом, использование системы поддержки продаж менеджером призвано заменить собой психологическое тестирование личности покупателя, проведенное экспертом-психологом, при этом на данное тестирование тратится минимум времени т.к. оно проходит в рамках обычной беседы менеджера и покупателя и не требует присутствия психолога.

В рамках работы по составлению психологических методик был разработан классификатор признаков для психологического анализа покупателей и предложен собственный подход к кодировке профиля личности человека. Также была разработана библиотека экспертных рекомендаций на основе нейросемантики и психолингвистики.

Алгоритм работы системы поддержки процесса продажи:

- Менеджер отмечает несколько простых признаков внешности или речи покупателя в соответствии с классификатором.

- Аналитический блок производит анализ введенных признаков и генерирует цифровой профиль личности покупателя. Расчет профиля личности покупателя реализуется через специально обученную нейросетевую модель

- Синтезатор рекомендаций, реализованный через кодировку связей между цифровым кодом профиля и соответствующими блоками библиотеки, выдает рекомендации менеджеру.

В среднем данный сервис позволяет менеджеру за 2-3 минуты получить точное заключение о характере покупателя в конкретных рекомендациях для решения актуальной задачи.

Ключевыми особенностями разрабатываемой системы являются:

- Использование системы не требует личного участие покупателя. Систему использует менеджер или другое лицо, которому необходимо выстроить вовлекающий диалог.

- Заключение, выдаваемое системой, состоит из конкретных фраз и описаний, последовательности используемых коммуникационных приемов, рекомендаций, что необходимо делать для данного клиента для повышения шансов на успешную продажу, а что категорически нельзя, чтобы не потерять клиента и не спровоцировать конфликт.

Представленная система поддержки решений в настоящий момент проходит тестирование в рамках пилотного проекта в салоне элитных аксессуаров. Одновременно прорабатывается интеграция представленной системы поддержки решений с алгоритмами аудио- и видео-распознавания для создания полностью автоматизированного сервиса, который будет работать с видеочамеры или телефона.

Библиографический список

1. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
2. Сичинава З.И. Нейросетевые алгоритмы анализа поведения респондентов. Диссертация на соискание ученой степени кандидата технических наук. Специальность: 05.13.01 / Пензенский государственный университет. Пенза, 2014.
3. Ясницкий Л.Н., Сичинава З.И. Нейросетевые алгоритмы анализа поведения респондентов // Нейрокомпьютеры: разработка, применение. – 2011. – №10. – С. 59-64
4. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г

ABOUT THE POSSIBILITY OF CREATING A NEURO-EXPERT SYSTEM FOR DECISION SUPPORT IN THE FIELD OF SALES

Zarechnaya Olga

ООО "NewVision", 614000, Russia, Perm, Sibirskaya St, 9, realnewvision@gmail.com

Sichinava, Surabi R., Cherepanov F. M.
Perm State Humanitarian-Pedagogical University, 614000, Russia, Perm, Pushkin str, 42,
zurabs@pspu.ru

Leonid N. Yasnitsky
Perm State University, 614600, Perm, street bukireva, 15, yasn@psu.ru

This article describes an attempt to create a neuro-expert system for decision support in the field of sales. The system described is designed to improve sales organizations through individual approach to each client. The use of the system does not require the personal participation of the subject. The system allows to obtain the conclusion, which consist of specific phrases and descriptions, sequence of the used communication methods, and recommendations about what must be done for the client to increase the chances of a successful sale and what you should not do in order not to lose the client.

Keywords: diagnostics, neural network technology, artificial intelligence, the interaction of machine and humans, effective strategies behavior, rapid diagnosis, psychosemantics, neural networks.

УДК 159.923.3

ПОСТРОЕНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ ПРОГНОЗИРОВАНИЯ ВЕРОЯТНОСТИ РАСПОЛОЖЕНИЯ К СЕБЕ ЛЮДЕЙ

Лапин Александр Андреевич, Дерябин Александр Иванович

Национальный исследовательский университет «Высшая школа экономики» - Пермь, 614046,
Россия, г. Пермь, ул. Студенческая, 38, alexanderlapin@yandex.ru, paid2@yandex.ru

Рассмотрен вопрос построения нейронной сети «Вероятность расположения к себе людей» на основании данных, полученных в ходе опроса. Опрос полностью построен на основании книги Дейла Карнеги «Как приобретать друзей и оказывать влияние на людей». В опросе принимали участие люди разных профессий, возрастов, материальных положений и пр., что позволило сделать наиболее разносторонний подбор входных данных. Полученные результаты позволили разработать нейронную сеть, которая вычисляет процент умения располагать к себе людей с минимальным коэффициентом погрешности. Данная нейронная сеть может быть задействована в области исследования людских взаимоотношений, помогая людям понять их слабые стороны, над которыми следует поработать для достижения более высокого результата.

Ключевые слова: расположение к себе людей, принципы правильного ведения коммуникаций, нейронные сети.

Взаимоотношения с окружающими является далеко не самым последним фактором для человека. Ни для кого не секрет, что люди, умеющие искусно вести беседы и заинтересовывать окружающий своей личностью, имеют большой как в области карьеры, так и в других смежных областях.

Впервые подробно данную тему рассмотрел Дейл Карнеги в книге «Как приобретать друзей и оказывать влияние на людей». Дейл Брекенридж Карнеги – американский педагог, лектор, писатель, оратор-мотиватор. Стоял у истоков создания теории общения, переведя научные разработки психологов того времени в практическую область, разработав собственную концепцию бесконфликтного общения.

Целью данной работы является создание нейросетевой модели для прогнозирования вероятности расположения к себе людей. Для достижения данной цели необходимо прочесть книгу Дейла Карнеги «Как приобретать друзей и оказывать влияние на людей» и знать ее основные принципы, опросить людей по основным принципам вышеуказанной книги и сделать выводы об их способности располагать к себе людей, спроектировать нейронную сеть по полученным данным, обучить и протестировать нейронную сеть, после чего сделать выводы по разработанной нейронной сети.

Для сбора информации необходимо было провести анкетирование по основным принципам, описанным в книге Дейла Карнеги «Как приобретать друзей и оказывать влияние на людей» [1, с. 52]. Количество опрошенных составляет 104 человека. Опрошенными являются: сотрудники компаний, студенты, бизнесмены и прочие люди, которые находятся в различных социальных и материальных положениях. На основании полученных ответов давался конечный процент расположения к опрашиваемому людей.

В основу опроса легли руководствующие положения, которые отражены в книге «Как приобретать друзей и оказывать влияние на людей». Гайд состоял из следующих 10 вопросов: Бывают ли ситуации, когда вы критикуете человека? Признаете ли вы искренне хорошие черты в человеке? Стараетесь ли вы побуждать в человеке желание что-либо сделать, нежели заставлять? Проявляете ли вы уважение к мнению других, никогда не говоря человеку о том, что он не прав? Улыбаетесь ли вы во время общения с людьми? Называете ли вы людей по имени? Во время общения стараетесь ли вы прежде всего слушать человека, нежели говорить самому? Стараетесь ли вы во время общения говорить на темы, больше интересующие вашего собеседника? Стараетесь ли вы дать людям почувствовать их собственную значимость? Умеете ли вы признавать свою неправоту?

Вес каждого вопроса составляет 10%. За каждый ответ на вопрос человеку присваивалось 0, 5 или 10%. В случае, если человек уверенно отвечал на вопрос «Нет», то присваивалось 0%, если отвечал неоднозначно (сомневался в ответе, объяснял, в каких ситуациях он ведет себя одним способом, а в каких – другим), то присваивалось 5%, и, если человек уверенно отвечал на вопрос «Да» и объяснял свою философию поведения, то

присваивалось 10%. Таким образом, формировался процент способности человека располагать к себе людей, который максимально мог составлять 100%.

Входные параметры нейронной сети представлены в Табл. 1.

Таблица 1. Входные параметры нейронной сети

Наименование	Обозначение
Пол	X1
Стихия	X2
Семейный статус	X3
Количество детей	X4
Уровень жизни	X5
Наличие знаний в области психологии взаимоотношений	X6
Образование	X7
Вид деятельности	X8

Кодировка входных параметров представлена в Табл. 2.

Таблица 2. Кодировка входных параметров

Варианты:	1	2	3	4	5
Пол (X1)	М	Ж	-	-	-
Семейный статус (X3)	Женат/Замужем	Гражд. брак	Развод	Холост	-
Уровень жизни (X5)	Высокий	Средний	Низкий	-	-
Наличие знаний в области психологии отношений (X6)	Колоссальные	Большие	Небольшие	Нет	-
Образование (X7)	Высшее	Среднее	Начальное	Нет	-
Вид деятельности (X8)	Работа в компании	Гос. Служба	Бизнес	Творчество	Безработный/Пенсия

Параметр X4 (Количество детей) является числом в диапазоне от 0 до 100. Параметр X2 (Стихия) зависит от знака Зодиака человека, который в свою очередь зависит от дня и месяца рождения опрашиваемого.

На Рис. 1 представлен корреляционный анализ, отображающий значимость входных параметров.

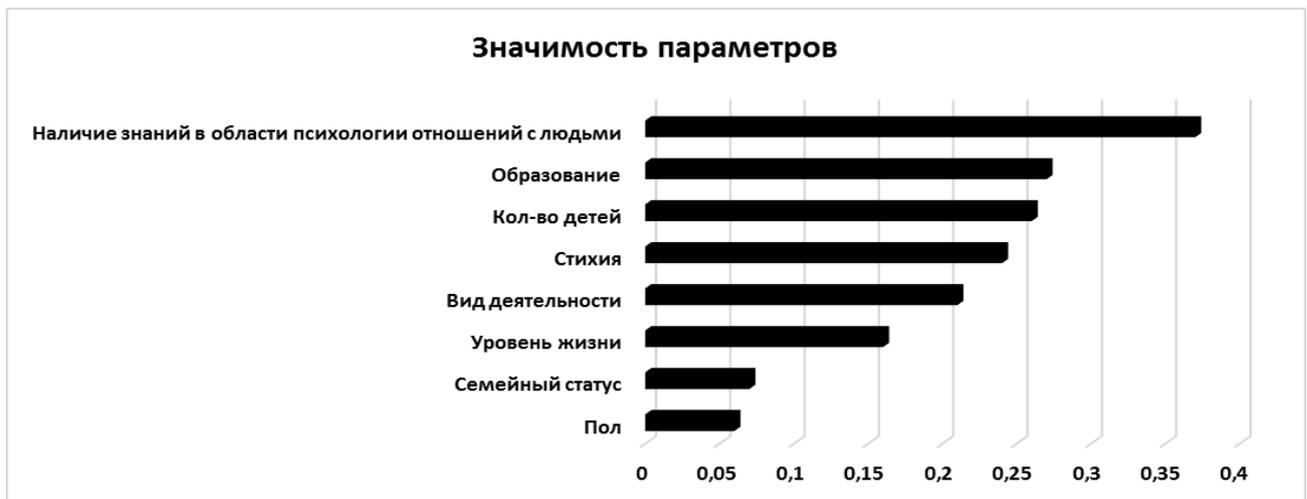


Рисунок 1. Корреляционный анализ параметров

Диаграмма позволяет сделать вывод, что все входящие параметры определенно имеют значимость при получении результата, но такие параметры, как «Пол» и «Наличие знаний в области отношений с людьми» имеют достаточно разные веса, что логично для данной темы, которая является психологической.

Проектирование нейронной сети осуществлено в программном продукте «Нейросимулятор 5.0» [2] по методике [3, 4]. На проектирование нейронной сети потребовался 71 пример, на обучение – 22 примера.

Следующим этапом является проверка работы нейронной сети. Для этого было использовано проверяющее множество в размере 11 штук, примеры которого не входили в проектирующее и обучающее множества. Количество и соотношение цифр получилось исходя из того, что множество примеров для создания нейронной сети должно быть больше или равно семикратной размерности вектора и 15 дополнительных примеров, после чего проектирующее, обучающее и тестирующее множества должны быть в соотношении 3:1:1.

На основании данного этапа была построена диаграмма, отображающая действительную и предсказанную вероятность расположения человека к общению. Данная гистограмма представлена ниже, на Рис. 2.

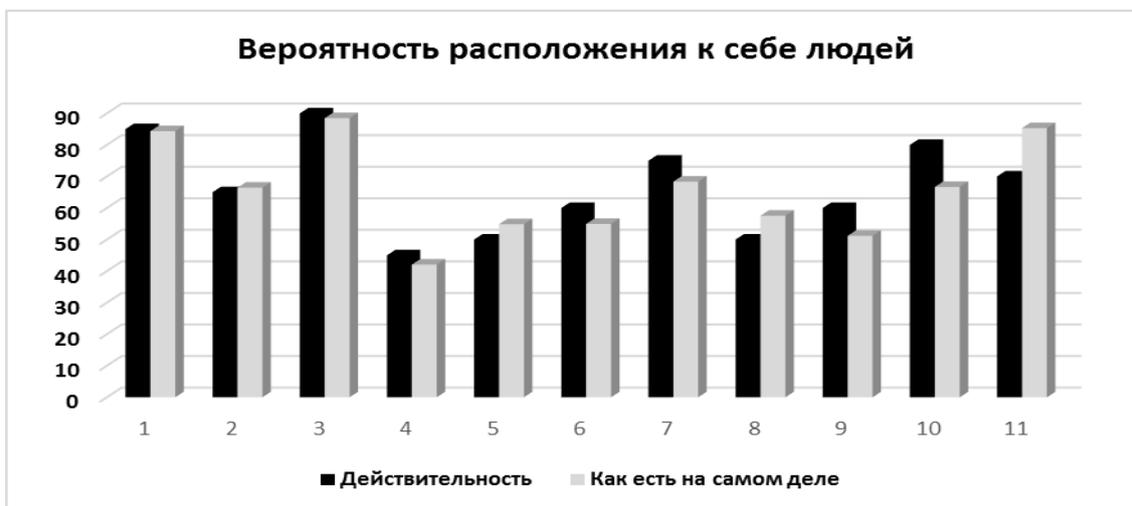


Рисунок 2. Диаграмма сравнения желаемых результатов с действительных

Результаты сравнения оказались достаточно близкими, а получившиеся небольшие расхождения объясняются спецификой затронутой темы (тема «Психология человеческого поведения»).

Разработанная нейронная сеть позволяет определять степень способности человека располагать к себе людей. Это может быть расположение к общению, к своей точке зрения и пр. Также данная нейронная сеть, поможет человеку понять, насколько он близок к совершенству в области взаимодействия с людьми и над чем ему необходимо работать, чтобы быть более успешным в этом плане.

Библиографический список

1. Карнеги Д. Как приобретать друзей и оказывать влияние на людей (в переводе М. Островцева). – М.: Прогресс, 1936.
2. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.
3. Ясницкий Л. Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
4. Ясницкий Л. Н. Искусственный интеллект. Элективный курс. М.: БИНОМ. Лаборатория знаний, 2012. 197 с.

THE CONSTRUCTION OF NEURAL NETWORK MODEL PREDICTING THE PROBABILITY TO WIN PEOPLE

Lapin Alexander Andreevich

Perm National Research University Higher School of Economics, 614046, Russia, Perm,
st. Studencheskaya, 38, alexadnerlapin@yandex.ru

Consider the construction of a neural network "The probability of winning people" on the basis of data obtained in the survey. The survey is completely built on the basis of the book of Dale Carnegie "How to win people and influence people." The survey involved people of different professions, ages, financial provisions, etc., that allowed us to make the most versatile selection of inputs. The obtained results allowed to develop a neural network that calculates the percentage of skills to win people with a minimal margin of error. This neural network can be involved in the

study of human relationships, helping people understand their weaknesses, over which it is necessary to work for achievement better result.

Keywords: to win people, the principles of proper communications management, neural network.

УДК 004.942

ОБНАРУЖЕНИЕ ДЕВИАНТНОГО ПОВЕДЕНИЯ ЛЮДЕЙ НА ОСНОВЕ АНАЛИЗА ТРАЕКТОРИЙ ДВИЖЕНИЯ

Янгузаров Артем Олегович

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, artemyangurazov@gmail.com

Рассмотрена задача обнаружения отличительного поведения людей на основе классификации траектории их передвижения. Это дает возможность заблаговременно предупредить опасную ситуацию и идентифицировать злоумышленника. Траектория перемещения строится на основе трекинга движущихся объектов. Классификация производится по таким признакам траектории, как искривленность, замкнутость и самоналожение. Искривленность вычисляется на основе метода главных компонент. Алгоритмы определения замкнутости и самоналожения реализуются на основе перебора окрестностей точек траектории. Траектория считается отличительной от нормальной (девиантной) при обнаружении одного из таких признаков, как большая величина искривленности, наличие замкнутости, наличие самоналожения. Получены подтверждения корректной работы алгоритма на экспериментальных видеороликах. Предложены методы по улучшению, оптимизации и расширению области использования разработанного алгоритма с учетом недостатков выявленных при тестировании.

Ключевые слова: девиантное поведение, метод главных компонент, трекинг.

Видеонаблюдение приобретает все большее значение, предоставляя важную информацию для охраны правопорядка, как в общественных местах, так и на частных территориях. Но из-за большого потока информации операторы систем видеонаблюдения не справляются с поставленными задачами и пропускают тревожные события. Во избежание таких ситуаций создатели систем видеонаблюдения разрабатывают различные интеллектуальные модули для обработки видеопотока с целью обнаружения отличительного, ненормального поведения, которое может повлечь за собой нарушение правопорядка и безопасности жизнедеятельности граждан.

Успехи в области распознавания событий на видеоизображениях показали эффективность использования траекторий движения в качестве признаков для классификации поведения [1]. Тем не менее, для успешной классификации необходимы примеры всех интересующих типов поведения, что затрудняет применение предложенных методов к задаче видеонаблюдения, где потенциально опасные ситуации возникают

достаточно редко. В связи с этим, интерес представляет использование методов обнаружения отклонений от некой модели нормального поведения.

Целью данной работы является разработка метода обнаружения отклонений траектории от модели нормального перемещения человека по следующим признакам: искривленность, замкнутость, самоналожение (совпадение отрезков траекторий с другими отрезками этой же траектории). Под нормальной траекторией понимается несамопересекающаяся, незамкнутая, близкая к прямой линии, основываясь на следующих тезисах. Во-первых, человек существо рациональное и, поэтому для того, чтобы пересечь какую-либо площадь, двор или холл в помещении, он выберет оптимальный маршрут, который с большой вероятностью будет представлять из себя близкую к прямой линию. Во-вторых, хождение человека кругами или назад-вперед означает, что он либо чего-то ждет, либо чего-то замышляет, что является признаком отличительного поведения. Подход применим только к сценам, где люди или другие отслеживаемые объекты перемещаются по плоской поверхности.

На каждом кадре видеопоследовательности выделяются движущиеся объекты с помощью алгоритмов обнаружения движения, основанных на построении модели фона с использованием модели распределения точек по распределению Гаусса (англ. *Mixture of Gaussians, MOG*) [2]. Выделенные на предыдущем этапе движущиеся объекты добавляются в список для дальнейшего отслеживания с помощью трекинга на основе построения гистограмм ориентированных градиентов (англ. *Histogram of Oriented Gradients, HOG*) и метода опорных векторов (англ. *SVM, support vector machine*) [3][4]. Этап анализа траекторий состоит из нескольких подэтапов: определение кривизны, определение замкнутости, определение повторения отрезков траекторий. Определение кривизны траектории происходит с помощью метода главных компонент. Вектор главной компоненты указывает на основное направление перемещения объекта в координатах изображения. Вектор побочной компоненты определяет величину отклонения траектории объекта от основного направления. Если отношение величины побочной компоненты к величине превышает наперед заданного порога, то траектория помечается соответствующим флагом. Пороговое значение отношения выявлено эмпирическим способом и равно 0.2. Определение наличия замкнутости траектории реализуется на основе сравнения положений начальной и конечной точки одного отрезка и начальной и конечной точки другого отрезка составляющих одну и ту же траекторию. Определение самоналожения отрезков одной траектории реализуется на основе перебора начальной (E) и конечной точки одного отрезка и соответственно области \in начальной (S) и конечной точки другого отрезка этой же траектории. Если выполняется условие (1), то

траектория помечается соответствующим флагом. Область ε задается в виде окружности с радиусом 1% от размера кадра. Схема работы представлена на Рис. 1.

$$\begin{cases} E_x < S_x + \varepsilon \\ E_y < S_y + \varepsilon \\ E_x > S_x - \varepsilon \\ E_y > S_y - \varepsilon \end{cases} \quad (1)$$

При обнаружении положительного флага хотя бы одного из соответствующих признаков траектория обозначается как девиантная. Все пороговые значения были подобраны эмпирическим методом.

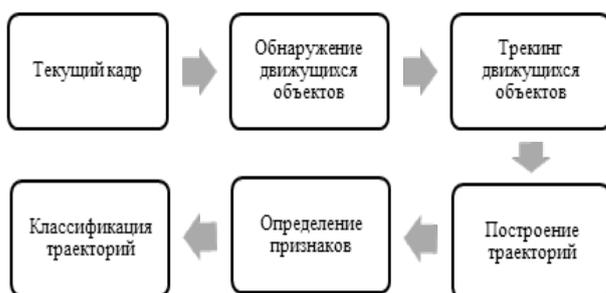


Рисунок 1. Архитектура представленного метода

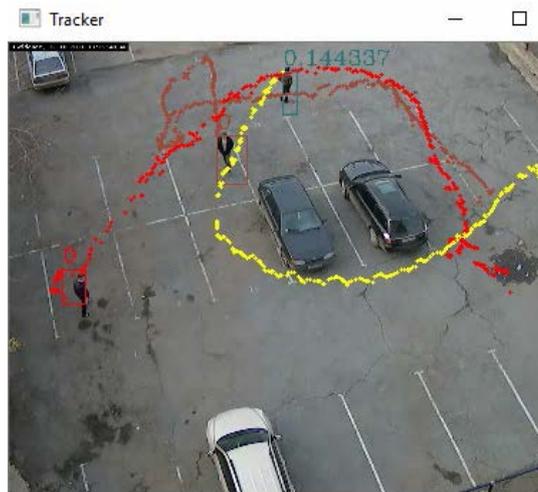


Рисунок 2. Визуализация работы алгоритма

Алгоритм был реализован с помощью открытой библиотеки компьютерного зрения OpenCV на языке программирования C++. Визуализация программы представлена на Рис. 2. Разработанная программа была протестирована на экспериментальных видеороликах и показала хорошие результаты определения девиантного поведения. При тестировании были выявлены некоторые недостатки разработанного алгоритма: неспособность работы в условиях толпы, отсутствие учета того, что человек может обходить препятствия. Предложены следующие способы повышения качества работы: переход от алгоритмов слежения за единичным объектом к алгоритмам слежения в целом за сценой с помощью таких методов, как вычисление оптического потока, которые доказали свою робастность в условиях быстроменяющейся сцены.

Библиографический список

1. Wang H., Klaser A., Schmid C., Liu C. Dense trajectories and motion boundary descriptors for action recognition. // International Journal of Computer Vision, Springer Verlag, 2013, V. 103, № 1, P. 60-79.

2. Янгуразов А.О. Обнаружение оставленных предметов по данным видеопоследовательности. Материалы краевой научно-практической конференции "Физика для Пермского края", Пермь, 2014, С. 39-42
3. Deepthi V.K.P, Mr. Mohammed Anvar P.K Visual Tracking Using HOG and SVM International Journal of Advanced Engineering Research and Technology (IAERT) Volume 4 Issue 5, May 2016, P.181-184.
4. Morris B., Trivedi M. A Survey of Vision-Based Trajectory Learning and Analysis for Surveillance // IEEE Transactions on Circuits and Systems for Video Technology, 2008, V. 18, № 8, P. 1114-1127.

DEVIANT PEOPLE BEHAVIOR DETECTION BASED ON MOVEMENT TRAJECTORY ANALYSIS

Iangurazov Artem O.

Perm State University, 15, Bukireva st., Perm, 614990, Russia, artemyangurazov@gmail.com

The problem of deviant people behavior detection based on their movement trajectory classification is considered. This classification makes possible to warn a dangerous situation and identify the attacker. The motion trajectory building based on the tracking of moving objects. We make classification on trajectory signs such as curvature, closure and self-imposing. We calculate curvature based on the principal component analysis. We realized algorithms for determining closedness and self-imposing based on a search of trajectory point neighborhoods. We consider distinct from normal (deviant) the trajectory when one of signs is detected, such as the large amount of curvature, the presence of closedness, the presence of self-imposing. We received confirmation of the correct operation of the algorithm on experimental video clips. We propose methods for improving, optimizing and expanding the scope of the developed algorithm, taking into account the shortcomings revealed during testing.

Key words: deviant behavior, principal component analysis, tracking.

УДК 51-7:159.938

ИССЛЕДОВАНИЕ ЗАКОНА РАСПРЕДЕЛЕНИЯ ИНДИВИДУАЛЬНОЙ СКОРОСТИ РЕАГИРОВАНИЯ НАБЛЮДАТЕЛЯ

Перекрест Иван Игоревич, Холодняк Михаил Андреевич, Тархов Дмитрий Альбертович
Санкт-Петербургский политехнический университет Петра Великого, 195251, Россия,
г. Санкт-Петербург, Политехническая, 29, dtarkhov@gmail.com

В данной работе мы исследовали методы восстановления закона распределения случайной величины по измерениям: по гистограмме и по исходному распределению. Закон распределения восстанавливался в виде нормального распределения, произведения экспоненты на линейную функцию и RBF-сети с двумя и тремя нейронами. Полученные результаты были проанализированы с психологической точки зрения.

Ключевые слова: нейронные сети, приближённое решение, нормальное распределение, распределение Гаусса, ступенчатая функция, хронометрия, время реакции.

Первые исследования времени произвольной реакции человека были проведены в начале девятнадцатого века астрономами. Необходимость в них возникла после того, как

было обнаружено, что наблюдатели, засекающие момент прохождения звезды через меридиан, дают разные показания. Анализ этих данных, накопленных в течение нескольких лет, показал, что ошибки наблюдателей не являются случайными, а характеризуют индивидуальную скорость реагирования каждого наблюдателя.

Эти исследования привлекли внимание физиологов и психологов. Немецкий физиолог Г. Гельмгольц, интересуясь проблемой скорости передачи возбуждения по центростремительным нервам у человека, воспользовался методикой измерения времени реакции. Работы Г. Гельмгольца и его последователей оказали большое влияние на разработку хронометрического эксперимента. Опираясь на исследования Гельмгольца, Ф. Дондерс и З. Экснер пытались подойти с помощью хронометрического эксперимента к физиологическому анализу так называемых психических процессов.

Простая реакция зависит от ряда факторов, таких как индивидуальные особенности испытуемого, модальности раздражителя, различных рода внешних условий эксперимента, действий фармакологических и алкогольных средств.

В рамках лабораторной работы мы провели 50 измерений случайной величины (времени) – t_i . Искомый промежуток времени – 5 секунд. Необходимо было построить гистограмму и сравнить её с функцией Гаусса, однако полученная гистограмма визуально не соответствовала нормальному распределению.

Для того чтобы уточнить полученную математическую модель, было решено использовать нейронные сети. Изначально были попытки для построения нейронной сети использовать гистограмму.

В первой попытке для сглаживания гистограммы использовалась нейросетевая функция с различным числом слагаемых вида $c \operatorname{th}[a(x - xc)]$. Затем была использована функция $c(x - xc)e^{-a(x-xc)}$, но и она не дала удовлетворительного результата.

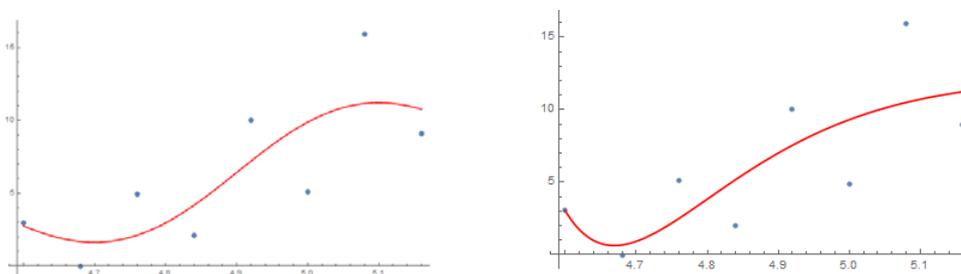


Рис. 1. График решения, найденный в пакете Mathematica для функций гиперболического тангенса (слева) с использованием 3 нейронов и функций гауссиан с использованием 1 нейрона (справа).

Как можно наблюдать, в точке $t=5.0$ (что является нашей хронометрически измеренной случайной величиной) в обоих случаях функция не принимает максимального значения, так как она должна была.

После этого было решено перейти к рассмотрению измерений, полученных двумя разными людьми отдельно. Также все полученные значения были раздроблены на 5 равных интервалов.

В этот раз использовалась только функция гауссиан.

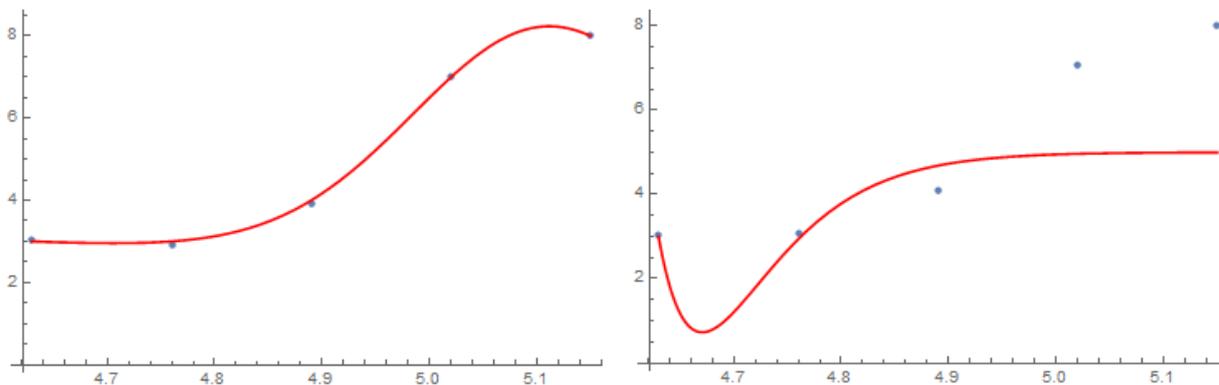


Рис. 2. Графики решений, найденные в пакете Mathematica для значений, полученных при измерении времени одним человеком. В первом случае использовалась сумма двух гауссиан вида

$$ce^{-a^2(x-xc)^2}. \text{ Во втором случае использовалась функция } c(x-xc)e^{-a(x-xc)}.$$

Как можно видеть, только в первом случае приближенные значения функции совпадают с точным решением, кроме того, минимальная погрешность оказалась очень малой. Однако по-прежнему в точке $t=5.0$ функция не принимает максимального значения. Кроме того, можно сделать вывод о том, что с данной задачей успешнее справляется сеть с большим количеством нейронов.

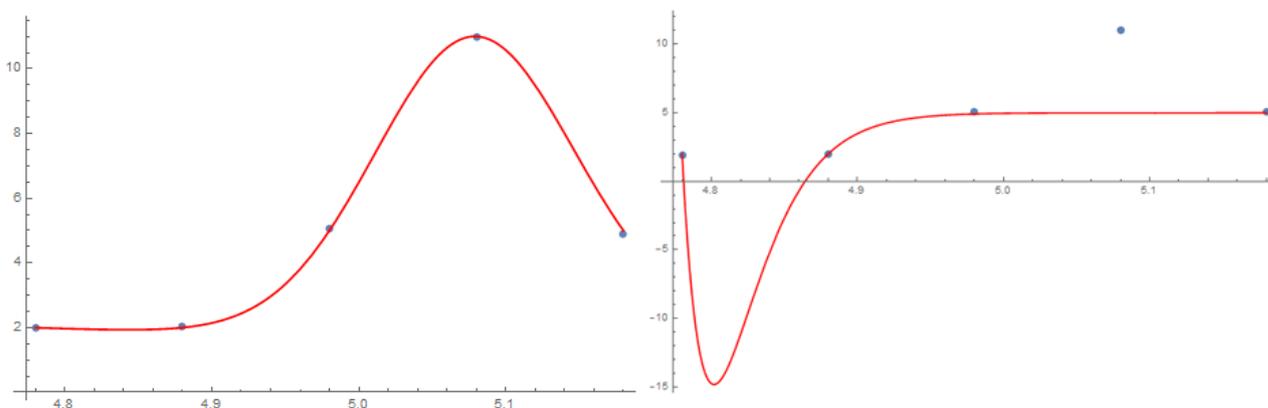


Рис. 3. Графики решений, найденные в пакете Mathematica для значений, измеренных другим человеком. Аналогично с Рис. 2. Здесь результаты очень похожи на результаты графиков рисунка 2.

Таким образом, реализовать уточнение математической модели с помощью сглаживания гистограммы проблематично. Поэтому было решено использовать исходную выборку.

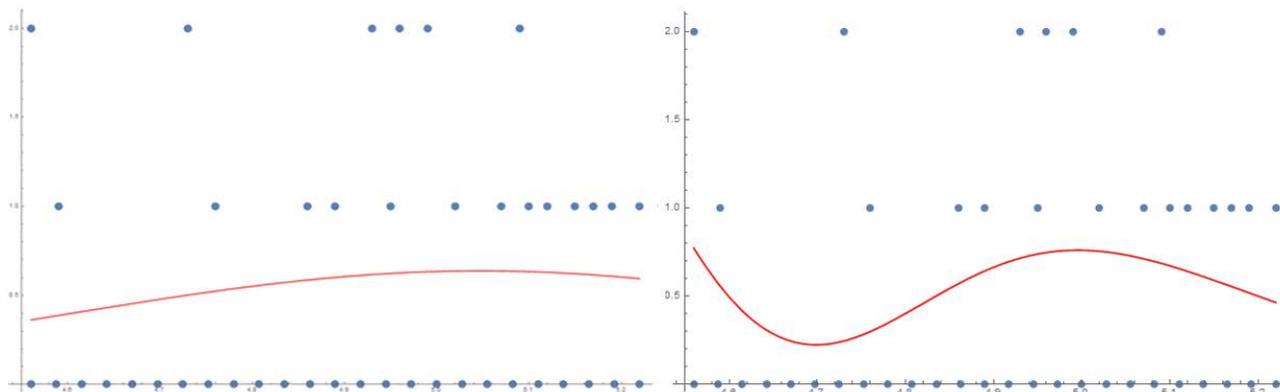


Рис. 4. Графики решений, найденные в пакете Mathematica для значений, измеренных одним человеком. Использовалась нейросетевая функция с 1 слагаемым вида $ce^{-a^2(x-xc)^2}$ (слева) или 2 слагаемыми (справа).

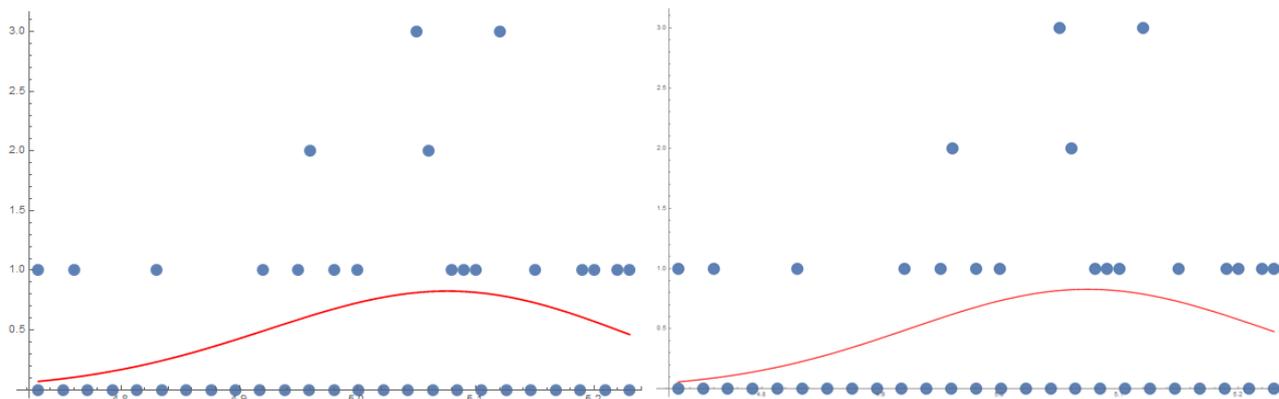


Рис. 5. Графики решений, найденные в пакете Mathematica для значений, измеренных другим человеком. Используются те же функции, что и в предыдущем случае.

В данном случае на графиках (Рис. 4, Рис. 5) мы получаем более точную кривую случайного распределения.

Если рассматривать опыт с психологической точки зрения, то процесс измерения времени можно отнести к так называемым «простым реакциям» - испытуемому предъявляется один целевой стимул (в данном случае – отмерить 5 секунд) и он должен просигнализировать о его обнаружении (нажать кнопку секундомера). Хронометрический индекс, то есть время от получения целевого стимула до его обнаружения в данном случае называется Временем Простой Реакции (ВПр).

Существует ряд рекомендаций при сборе первичных данных: дать испытуемому некоторое количество тренировочных проб (от 10 до 50), исключить сверхбыстрые ответы, а также ответы со слишком высокими значениями ВР. При сборе данных данные

рекомендации не были соблюдены, что, как можно полагать, привело к появлению значений, которые слишком сильно отклонялись от нормы. Также для более успешной имитации случайной величины следовало привлечь к опыту большее количество человек, так как в таком случае было бы гораздо труднее предугадать то, какие данные будут получены.

Другая проблема заключается в так называемом «балансе точности и скорости» - если испытуемый слишком спешит дать ответ, прореагировать, то это отрицательно сказывается на полученном результате. Чаще всего такое происходит, если испытуемому во время опыта дается установка на скоростной ответ. В это же время, установка испытуемого на точность приводит к снижению скорости. Следует отметить, что из-за этой проблемы хронометрические данные считаются пригодными для анализа тогда, когда ошибка составляет не более 2-3%, но это требование не является слишком строгим.

Таким образом, мы можем сделать вывод о том, что проблематичность уточнения модели случайной величины вызвана несоблюдением рекомендаций по хронометрии а также проблемой баланса точности и скорости. Несмотря на это, благодаря переходу от гистограммы к исходной выборке, уточнение на основе нейронных сетей было успешным.

Библиографический список

1. А.Н.Васильев, Д.А.Тархов. Принципы и техника нейросетевого моделирования. - СПб.:Нестор-История,2014. – 218 с.
2. В.В. Козловский, С. Б. Михрин. Общая физика. Механика и молекулярная физика: Учебно-методическое пособие. – СПб.: 2000, 64с
3. А.Н. Гусев, И. С. Уточкин. Психологические измерения. Теория. Методы – М.: Аспект Пресс, 2011. – 317 с.

RESEACH OF A RANDOM VALUE AND INDIVIDUAL RESPOSE SPEED OF THE OBSERVER (INSTANT REACTION OF A HUMAN)

Perekrest Ivan Igorevich, Kholodnyak Michael Andreevich, Tarkov Dmitri Albertovich

In this research we studies dependence of the accuracy of measuring a random value on using different methods of representation: as a bar chart, normal distribution curve and exponential function. The method of refinement of a mathematical model based on neural webs has been developed and the received results had been analyzed with using psychological methods of mental chronometry.

Key words: Neural webs, approximate solution, normal distribution, exponential function, chronometry, response time.

ПРОГНОЗИРОВАНИЕ ПРОДОЛЖИТЕЛЬНОСТИ БРАКОВ

Пономарева Юлия Вячеславовна

Национальный исследовательский университет «Высшая Школа Экономики», 614046,
Россия, г. Пермь, ул. Студенческая 38, julka1811@gmail.com

В работе рассмотрен процесс создания и обучения нейросетевой модели для прогнозирования продолжительности браков. В основе модели лежит выборка, полученная на 80% с помощью интервьюирования людей и на 20% с помощью исследования жизни знаменитостей. Исследование проводилось на основе сравнения результатов обучения двух выборок: первой, где были все входные параметры и второй, в которой обоснованно отсутствовали некоторые входные параметры. Для каждого эксперимента была проведена оценка адекватности модели, высчитана абсолютная и относительная погрешности обучения сети, а также были выявлены значимые параметры. Полученные результаты затем сравнивались, комментировались и на их основе выявлялись закономерности.

Ключевые слова: Искусственный интеллект, нейросетевые технологии, продолжительность браков.

Согласно статистике [1] 4 из 10 сознательных отношений ведут к браку. Под сознательными отношениями в данном контексте понимаются отношения в сознательном возрасте, то есть подростки к данной статистике не относятся. При этом ежегодно половина браков распадается [3]. Однако от чего зависит, будет ли брак успешным?

Иногда бывает так, что пара очень долго встречается, а потом играет свадьбу и в скором времени разводится. Иногда же возникает так называемая любовь с первого взгляда, когда отношения могут продлиться меньше полугода, после чего люди живут в браке всю жизнь. Казалось бы, невозможно предугадать будущее пары, однако, зачастую, уже на раннем этапе отношений можно определить, будет ли их брак успешным и даже спрогнозировать предположительную продолжительность брака.

Согласно семейным психологам и социологам достаточно сильно влияют на продолжительность такой фактор, как возраст вступления в брак. Так, браки, заключённые до 30 лет, в два раза долговечнее и перспективнее союзов, зарегистрированных между супругами после 30 лет. Это связано с тем, что людям до 30 лет легче привыкнуть и притереться друг к другу.

Однако большинство разводов происходит в возрасте 18-35 лет. Количество разводов резко увеличивается в возрасте 25 лет.

Достаточно много исследований было проведено на данную тему. Американский психолог Джон Готтман создал тест [4], который может определить продолжительность

брака той или иной пары. Однако тесты, в которых всего четырнадцать вопросов зачастую дают неверных ответ. Также стоит учитывать, что людям свойственно привирать при ответах на ряд личных вопросов.

Американский социальный психолог Джон Ли на протяжении года анализировал отношения 2 тысяч пар и пришел к выводу, что в отношениях есть всего три типа поведения: любовь-страсть, любовь-дружба и любовь-игра, из которых только вторые ведут к долговечному браку [2]. Однако если человек сам захочет определить модель поведения своих отношений с партнером, он вряд ли сможет это сделать, поэтому лучшим средством будет обучить нейросеть по заранее определенным параметром, которая с некоторой вероятностью сможет прогнозировать, насколько долгим брак у пары может быть.

Наиболее эффективным средством прогнозирования и выявления закономерностей в плохо формализуемых предметных областях (а барки являются не формализованной предметной областью) являются нейросетевые технологии, использующие для обучения различные математические модели.

Целью настоящей работы является исследование результатов построения нейросетевой модели, основанной на зависимостях между параметрами пары, находящейся на этапе отношений и предполагаемой продолжительности их брака.

На вход подавалось 32 входных параметра, которые были выбраны на основе анализа предыдущих сопряженных работ и исследований значимости различных параметров на браки людей. Таким образом, выборка составила 239 записей. Тестовое множество составило 10% от обучающего, то есть 24 записи. Проверяющее множество составило 5% от обучающего множества, то есть 12 записей. Выборка на 80% строилась на основе анкетирования, состоящих или состоявших в браке людей через Интернет. Остальные 20% составляла собранная информация о знаменитостях.

x1 – Общие дети до брака: 1 – есть, 0 – нет;

x2 – Дети от предыдущих браков: 1 – есть, 0 – нет;

x3 – Общие хобби: 1 – есть, 0 – нет;

x4 – Длительность отношений до брака. Здесь указывается конкретный срок отношений пары;

x5 – Одобрение родителей: 1 – родители одобряют отношения, 0 – не одобряют;

x6 – Совместное проживание до брака: 1 – проживают, 0 – не проживают;

x7 – Общая религия: 1 – да, 0 – нет;

x8 – Развод родителей: 1 – у одного из пары родители в разводе, 0 – родители обоих партнеров не разведены;

- x9 – Знак зодиака женщины: 1 – Козерог, 2 – Водолей, 3 – Рыбы, 4 – Овен, 5 – Телец, 6 – Близнецы, 7 – Рак, 8 – Лев, 9 – Дева, 10 – Весы, 11 – Скорпион, 12 – Стрелец;
- x10 – Стихия женщины: 1 – Земля, 2 – Водолей, 3 – Вода, 4 – Огонь;
- x11 – Градус солнца женщины: По формуле высчитывается градус солнца;
- x12 – Знак по восточному календарю женщины: 1 – Крыса, 2 – Бык, 3 – Тигр, 4 – Кролик, 5 – Дракон, 6 – Змея, 7 – Лошадь, 8 – Овца, 9 – Обезьяна, 10 – Петух, 11 – Собака, 12 – Свинья;
- x13 – Вредные привычки женщины: 1 – есть, 0 – нет;
- x14 – Достаток до брака женщины: 1 – низкий, 2 – средний, 3 – высокий;
- x15 – Недвижимость до брака женщины: 1 – есть, 0 – нет;
- x16 – Любовь к детям: 1 – любит детей, 0 – не любит детей;
- x17 – Мимолетные увлечения женщины: 1 – ветреная, 2 – не особо ветрена, 3 – не ветрена;
- x18 – Образование женщины: 1 – есть, 0 – нет;
- x19 – Ревнивая ли женщина: 1 – да, 0 – нет;
- x20 – Возраст вступления в брак: Указывается конкретный возраст девушки;
- x21 – Знак зодиака мужчины: 1 – Козерог, 2 – Водолей, 3 – Рыбы, 4 – Овен, 5 – Телец, 6 – Близнецы, 7 – Рак, 8 – Лев, 9 – Дева, 10 – Весы, 11 – Скорпион, 12 – Стрелец;
- x22 – Стихия мужчины: 1 – Земля, 2 – Водолей, 3 – Вода, 4 – Огонь;
- x23 – Градус солнца мужчины: По формуле высчитывается градус солнца;
- x24 – Знак по восточному календарю мужчины: 1 – Крыса, 2 – Бык, 3 – Тигр, 4 – Кролик, 5 – Дракон, 6 – Змея, 7 – Лошадь, 8 – Овца, 9 – Обезьяна, 10 – Петух, 11 – Собака, 12 – Свинья;
- x25 – Вредные привычки мужчины: 1 – есть, 0 – нет;
- x26 – Достаток до брака мужчины: 1 – низкий, 2 – средний, 3 – высокий;
- x27 – Недвижимость до брака мужчины: 1 – есть, 0 – нет;
- x28 – Любовь к детям: 1 – любит детей, 0 – не любит детей;
- x29 – Мимолетные увлечения мужчины: 1 – ветреный, 2 – не особо ветренный, 3 – не ветренный;
- x30 – Образование мужчины: 1 – есть, 0 – нет;
- x31 – Ревнив ли мужчина: 1 – да, 0 – нет;
- x32 – Возраст вступления в брак: Указывается конкретный возраст мужчины.

Целевой параметр (выходные данные): d1 – продолжительность брака: 1 – короткий брак (0-10 лет), 2 – средняя продолжительность брака (11-20 лет), 3 – долгий брак (21 – конец жизни одного из супругов).

Проектирование и оптимизация нейронной сети выполнялись по методике [5] в нейропакете [6]. Согласно формуле Арнольда – Колмогорова – Хехт-Нильсена количество нейронов в скрытых слоях для выборки из 239 примеров должно варьироваться в диапазоне от 27 до 288. Также число нейронов скрытого слоя двухслойного персептрона должно равняться 8. Однако экспериментальным методом было выявлено, что нейросеть для первого эксперимента лучше обучается с одним скрытым слоем и четырьмя нейронами на нем. Также экспериментальным методом было выявлено, что лучшее обучение нейросети обеспечивает алгоритм упругого распространения ошибки.

С приведенными выше параметрами можно сказать, что нейросеть обучилась не очень хорошо, потому что ошибка обучения и тестирования равнялись 13% и 29% соответственно. Сеть с описанными выше характеристиками научилась отлично прогнозировать краткосрочные браки и хуже обучилась прогнозу долгосрочных браков.

На основании примеров тестового множества были рассчитаны абсолютная и относительная погрешность тестирования нейронной сети, которые равняются 0,4 и 26,9% соответственно. Также в данном эксперименте наиболее значимыми параметрами являлись недвижимость до брака у мужчины и женщины, а также дети от предыдущих браков, ревность женщины и ее образование.

Для того чтобы сравнить степень обучаемости сети на меньшем количестве параметров во втором эксперименте были убраны входные параметры: Недвижимость до брака у женщины и мужчины и совместное проживание до брака. Параметры «Наличие общих детей до брака» и «Наличие детей от предыдущих браков» было решено соединить в один параметр. Таким образом, входных нейронов стало 28. Экспериментальным путем было выявлено, что количество нейронов на скрытом слое должно быть 5.

Вторая сеть обучилась гораздо лучше, и ошибка тестирования упала до 21%. Также абсолютная и относительная погрешности упали до 0,3 и 16,0% соответственно. Данная сеть хорошо прогнозирует уже не только краткосрочные, но и долгосрочные браки. А так же неплохо прогнозирует браки средней продолжительности (рис. 1). Из рисунка 2 можно увидеть, что значимыми параметрами стали мимолетные увлечения мужчин и осталась значимой ревность женщины.

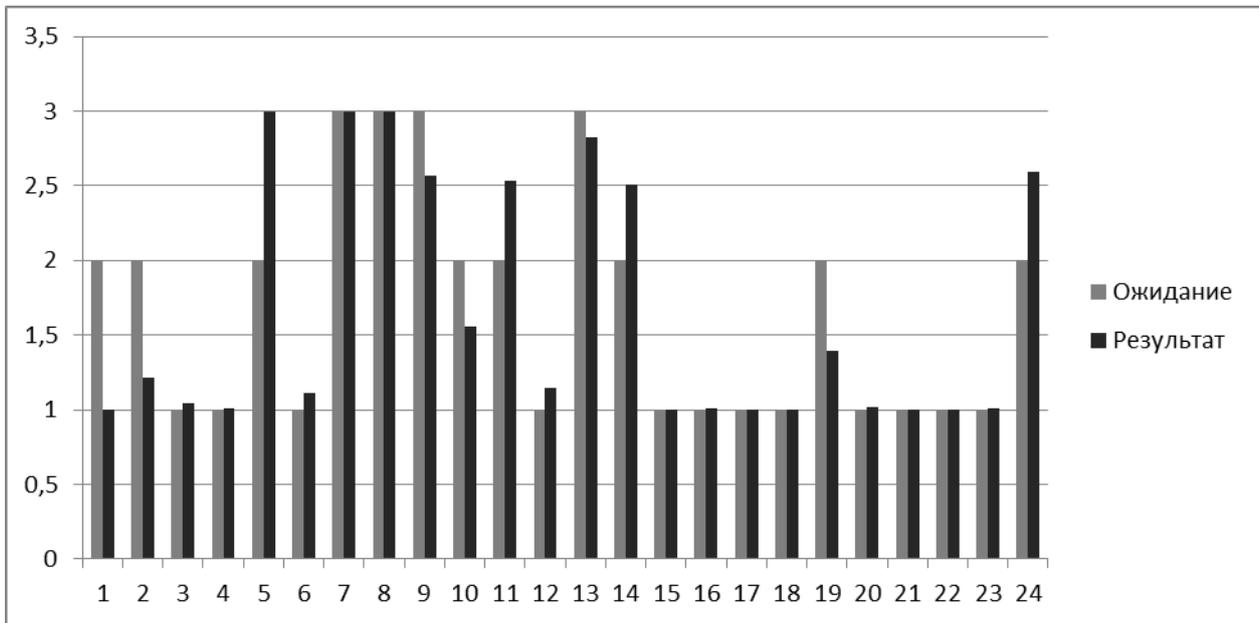


Рисунок 10. Гистограмма, отображающая реальные результаты и прогноз для второго эксперимента

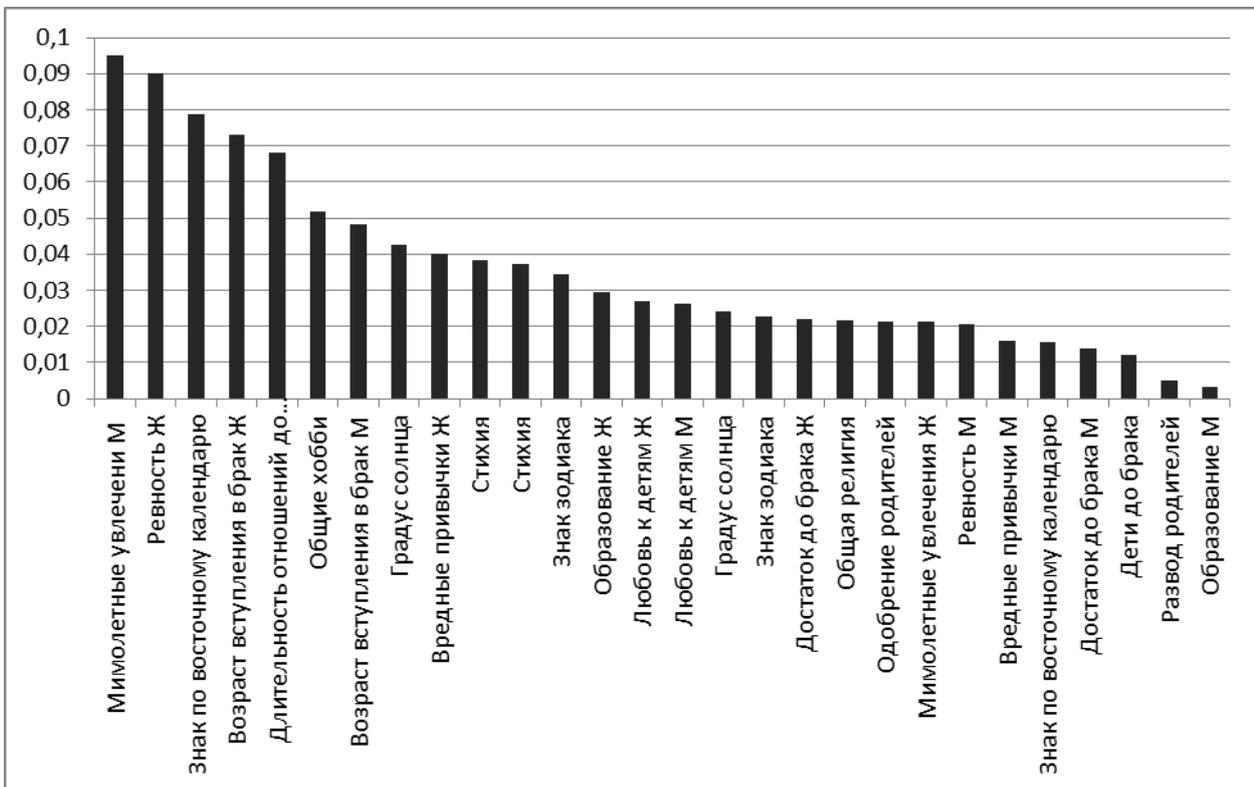


Рисунок 11. Гистограмма значимости параметров для второго эксперимента

Несмотря на лучший прогноз второго эксперимента, стоит заметить, что в обоих случаях средняя продолжительность брака прогнозируется гораздо хуже, чем короткие и долгие браки, что может быть вызвано тем, что данные для средней продолжительности могут быть похожи как на данные для долговечных, так и на данные краткосрочных браков. Также следует обратить внимание, что несмотря на то, что многие предсказания ведутся именно по знакам зодиака, в данных экспериментах было выявлено, что они практически не

вливают на продолжительность брака, по сравнению, например, со стихией или знаку по восточному календарю, где последний, в свою очередь стал третьим параметром по значимости.

Библиографический список

1. Какие романы заканчиваются свадьбами // <http://ladypravda.ru> URL: <http://ladypravda.ru/articles/love/relations/10-08-2015/11148-para/> (дата обращения: 26.02.2016).
2. Психологи выяснили, какие отношения приведут к браку // <http://juliel.info> URL: <http://juliel.info/psihologi-vyiasnili-kakie-otnosheniia-privedyt-k-braky/> (дата обращения: 08.03.2016).
3. Статистика различных браков и измен в них // <http://helprazvod.ru> URL: <http://helprazvod.ru/okolorazvoda/statistika-brakov-i-izmen.html> (дата обращения: 26.02.2016).
4. Тест на долговечность брака // <http://www.b17.ru> URL: <http://www.b17.ru/blog/31210/> (дата обращения: 08.03.2016).
5. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221с.
6. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.

MARRIAGE DURATION PREDICTIONS

Ponomareva Yulia V.

State National Research University “High School of Economics”, 38, Studencheskaya st., Perm, 614046, Russia, julka1811@gmail.com

The neural network model creation and learning process of prediction the marriage duration is considered in this paper. The model is based on the sample obtained at 80% with interviewing people and 20% with studying celebrities' lives. The research was conducted on a learning outcomes comparison of two samples: first, where were all the input parameters and the second, where there were reasonable lacked some of the input parameters. For each experiment, were evaluated the adequacy of the model, specified absolute and relative error of network training, and also identified significant parameters. The results are then compared, and commented upon them on the basis of revealed regularities.

Keywords: artificial intelligence, neural network technology, marriage duration.

5. КРИМИНАЛИСТИКА И БЕЗОПАСНОСТЪ

ВОПРОСЫ ВЫБОРА ПРОГРАММНЫХ СРЕДСТВ ДЛЯ РЕАЛИЗАЦИИ АЛГОРИТМОВ РАСПОЗНАВАНИЯ ОБРАЗОВ В ЗАДАЧАХ АВТОМАТИЗАЦИИ РАБОТЫ ЭКСПЕРТОВ-КРИМИНАЛИСТОВ

Кулик Сергей Дмитриевич

Национальный исследовательский ядерный университет «МИФИ», 115409, Россия,
г. Москва, Каширское ш., 31, sedmik@mail.ru

Никонец Денис Артурович

ЗАО «Компания Информконтакт», 123060, Россия, г. Москва, ул. Маршала Рыбалко, 4,
denis_n@mail.ru

В статье описана разработка подсистемы распознавания "RSFHWE" для автоматизированного рабочего места (АРМа) эксперта-криминалиста (почерковеда) "FHWE". Рассмотрены вопросы выбора программных средств для реализации в этой подсистеме алгоритмов распознавания образов, используемых при автоматизации существующих и разработке новых почерковедческих методик. Эти программные средства должны позволять многопользовательский режим работы АРМа в локальной сети и для удаленных пользователей, а также допускать работу с информацией ограниченного доступа. Было принято решение разработать подсистему распознавания "RSFHWE" средствами СУБД. Для этого были использованы такие СУБД как Oracle Database Express Edition, Firebird и PostgreSQL. Предложенные программные средства, а также выбранный способ реализации подсистемы распознавания "RSFHWE" полностью отвечают требованиям, предъявляемым к программной реализации АРМа эксперта-криминалиста (почерковеда).

Ключевые слова: автоматизированное рабочее место, почерковедческая методика, нейронные сети.

Важную роль в деле раскрытия преступлений, проведения следственных действий и оперативно-розыскных мероприятий играют результаты различного рода криминалистических исследований. Почерковедческая экспертиза является одним из основных видов криминалистических исследований. Хотя в данный момент из-за повсеместного внедрения электронного документооборота, все реже используются рукописные документы, однако количество проводимых судебно-почерковедческих экспертиз увеличивается.

Состояние дел в области почерковедческих экспертиз убедительно показывает на необходимость разработки новых почерковедческих методик, разработки эффективных методов и средств, созданных с учетом новейших достижений в области кибернетики, криминалистики, почерковедения, распознавания образов, теории нейронных сетей и компьютерных технологий для автоматизации работы экспертов-почерковедов, например, специализированных АРМов (автоматизированных рабочих мест) и поисковых средств для

создания автоматизированных учетов почерковых объектов, используемых для раскрытия и расследования преступлений.

Анализ уже созданных АРМов (например, “Почерк“, “Око-1“, “MAN-wo-MAN“ и ряд других [1]) убедительно показывает, что отсутствует программное обеспечение для разработки и реализации АРМа эксперта-почерковеда, решающее все основные задачи почерковедческих исследований. Поэтому разработка такого АРМа является крайне актуальной и необходимой. В виду этого, принято решение о разработке АРМ эксперта-криминалиста (почерковеда) “FHWE” [1].

Для разработки подсистемы принятия решений ”RSFHWE” [2] АРМа эксперта-криминалиста необходимо было выбрать способ решения задач распознавания образов. Одна из особенностей используемых методик выполнения почерковедческих экспертиз это достаточно большое количество признаков почерка (около 2000). Также заказчиком был высказан ряд требований к разрабатываемому АРМу:

- использование только бесплатного программного обеспечения;
- необходим многопользовательский режим работы АРМа в локальной сети и для удаленных пользователей;
- необходим однопользовательский режим работы АРМа со сменных носителей;
- необходимо предусмотреть возможность использования информации ограниченного доступа.

Учтя эти особенности и требования, был выбран способ реализации подсистемы распознавания (см. рисунок 1) при помощи СУБД.

Подсистема обеспечивает выполнение следующих функций:

- создание и модификация справочников функций активации и структуры нейронных сетей, проверка корректности задания структуры нейронной сети;
- автоматическое формирование на основании справочников функций активации и структуры нейронных сетей, хранимых процедур СУБД, необходимых для обучения и реализации работы нейронной сети (см. рисунок 2);
- обучение нейронной сети;
- экспорт в СУБД Firebird и PostgreSQL;
- реализация нейронной сети и её применение на практике.

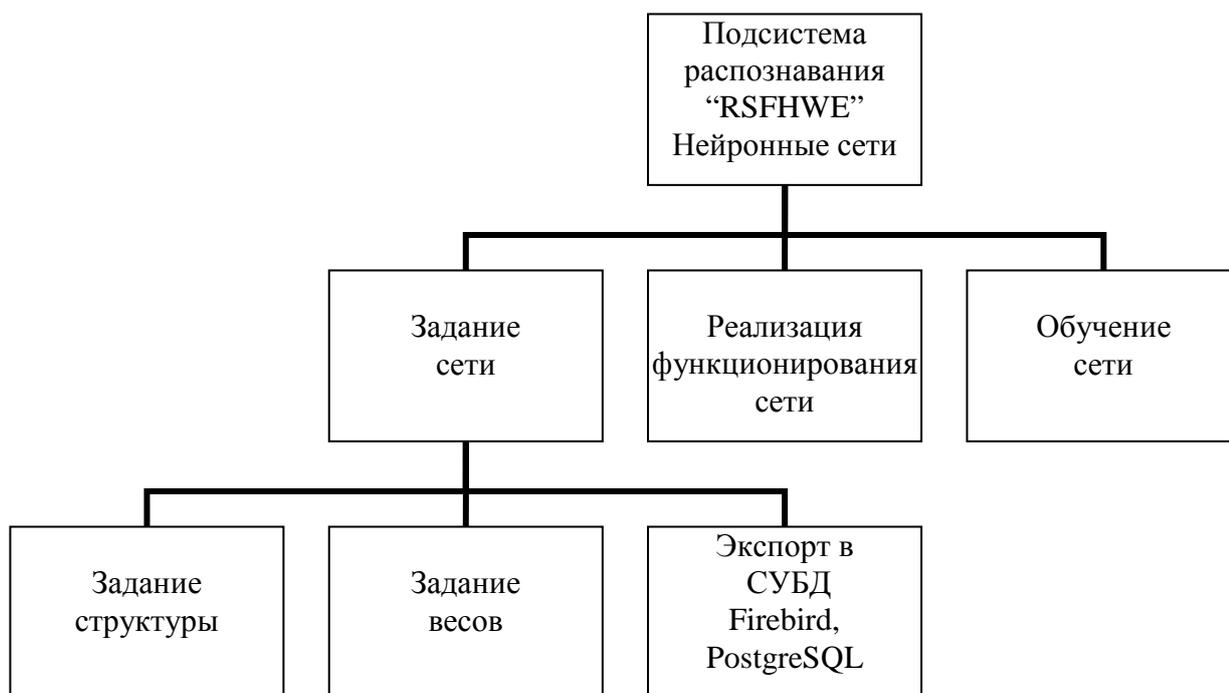


Рис. 1. Структурная схема модуля моделирования нейронных сетей в подсистеме распознавания “RSFHWE”

Рассмотрим подробнее моделирование работы нейронных сетей, использующихся для принятия решений при криминалистическом исследовании письма во время проведения судебно-почерковедческих экспертиз, при помощи подсистемы распознавания. Подсистема “RSFHWE” и ее база данных “DBRSFHWE” реализованы при помощи СУБД Oracle Database Express Edition (Oracle Database XE). Задание структуры, обучение нейронной сети и автоматическое формирование на основании структуры сети хранимых процедур выполняется в СУБД Oracle. А уже готовую обученную сеть можно автоматически экспортировать в используемую в АРМ эксперта-криминалиста (почерковеда) “FHWE” СУБД Firebird или PostgreSQL.

Ограничения в реализованном варианте подсистемы:

- поддерживаются нейронные сети без обратных связей;
- количество слоёв нейронной сети не должно превышать 100;
- количество входов и нейронов нейронной сети ограничено только возможностями СУБД;
- не должно быть нейронов, входом которых одновременно являются выход другого нейрона и вход нейронной сети.

```

declare
  svNameNet varchar2(200):='TEST';--Название создаваемой сети
  nvQtyNodes integer; --Количество нейронов в слое
  svNameFunc varchar2(200);--Название функции активации в слое
begin
  NeuroNetAPI.RegisterNet(svNameNet);--Создаем нейронную сеть
  -- Задаем структуру нейронной сети
  -- Первый слой
  nvQtyNodes:= 3;--Количество нейронов в слое
  svNameFunc:='Sigmoid';--Сигмоидальная функции активации
  NeuroNetAPI.AddLayer(svNameNet,nvQtyNodes,svNameFunc);
  -- Второй слой
  nvQtyNodes:= 1;--Количество нейронов в слое
  svNameFunc:= 'Linear';--Линейная функция активации в слое
  NeuroNetAPI.AddLayer(svNameNet,nvQtyNodes,svNameFunc);
  -- Обучение нейронной сети
  -- Предварительно обучающая выборка помещается в
  -- специальную таблицу БД
  -- По обучающей выборке определяется количество входов сети
  --обучение нейронной сети с настройками по умолчанию
  NeuroNetAPI.DoTeaching(svNameNet);
  --В результате обучения полученные веса сохраняются в
  --структуре нейронной сети
  --Автоматическая генерация исходного кода хранимых процедур
  --БД, реализующих работу сети, и их компиляция
  NeuroNetAPI.CreateNet(svNameNet);
  --В результате создана хранимая процедура, моделирующая
  --работу нейронной сети
  -- Экспорт нейронной сети в СУБД FireBird
  NeuroNetAPI.ExportNetToFirebird(svNameNet);
end;

```

Рис. 2. Пример PL/SQL скрипта для создания и обучения при помощи подсистемы распознавания “RSFHWE” нейронной сети

Использование СУБД (например, бесплатная версия Oracle, Firebird, PostgreSQL) для обучения и реализации работы нейронных сетей имеет следующие преимущества:

- доступен достаточно мощный встроенный язык программирования (например, PL/SQL), который используется для обучения нейронных сетей и для автоматической генерации хранимых процедур, реализующих функционирование нейронных сетей;
- используются таблицы базы данных для хранения обучающей выборки, входных и выходных данных, тем самым, способствуя более эффективному доступу к большому массиву данных;

- возможность, используя один SQL запрос, произвести вычисления сразу для нескольких наборов входных данных;
- реализовать АРМ в схеме с «тонким клиентом», что позволяет быстро переносить клиентское приложение на другую платформу, не меняя программный код, реализующий моделирование нейронных сетей.

Для СУБД PostgreSQL (в рамках ОС Astra Linux Special Edition) получен сертификат Федеральная служба по техническому и экспортному контролю (ФСТЭК), т.е. СУБД PostgreSQL можно использовать для хранения информации, представляющей гостайну с грифом «Совершенно секретно».

Также вариации СУБД PostgreSQL и Firebird заняли высокие места по классу СУБД как проекты по импортозамещению инфраструктурного программного обеспечения [3].

Следует отметить, что в подсистему распознавания "RSFHWE" кроме блока работы с нейронными сетями входят также блок статистической обработки данных, блок Байесовского классификатора и блок кластеризации данных. Эти блоки тоже организованы средствами СУБД.

Таким образом, можно сделать вывод, что предложенные программные средства, а также выбранный способ реализации подсистемы распознавания "RSFHWE" полностью отвечают требованиям, предъявляемым к программной реализации АРМа эксперта-криминалиста (почерковеда).

Библиографический список

1. *Kulik S.; Nikonets D.* Forensic Handwriting Examination and Human Factors: Improving the Practice through Automation and Expert Training // Proc. 2016 Third International Conference on Digital Information Processing, Data Mining, and Wireless Communications (DIPDMWC). — pp. 221–226.
2. *Кулик С.Д., Никонец Д.А.* Свидетельство на программу Российской Федерации №2007614121 "Подсистема распознавания для автоматизированного рабочего места эксперта-криминалиста v.1.0" (RSFHWE). Заяв. 31.07.2007; Опубли. Бюл. №4(61).
3. Протокол экспертной оценки проектов по импортозамещению инфраструктурного программного обеспечения, соответствующего пунктам 4-8 плана импортозамещения программного обеспечения, утвержденного приказом Минкомсвязи России от 1 апреля 2015 г. №96 «Об утверждении плана импортозамещения программного обеспечения» (протокол Министерство связи и массовых коммуникаций Российской Федерации от 02 июня 2015 года №П11-215пр).

CHOOSING OF THE SOFTWARE FOR IMPLEMENTING ALGORITHMS OF PATTERN RECOGNITION DURING AUTOMATION OF THE ACTIVITIES OF THE FORENSIC EXPERTS

Kulik Sergey Dmitrievich

National Research Nuclear University MEPHI (Moscow Engineering Physics Institute), », 31, Kashirskoye av., Moscow, 115409, Russia, sedmik@mail.ru

Nikonets Denis Arturovich

Company Informcontact Consulting, 4, Marshal Rybalko st., Moscow, 123060, Russia,
denis_n@mail.ru

Abstract. This paper describes the development of a recognition subsystem "RSFHWE" for the automated workplace (AWP) of the forensic handwriting expert "FHWE". The selection of the software for the implementation of this subsystem and of the pattern recognition algorithms used for the automation of existing and development of new handwriting techniques are described. These software tools should enable multiuser mode for AWP in local network and for remote users, and also allow to work with information of restricted access. The decision was taken to develop a recognition subsystem "RSFHWE" by means of the DBMS. This was done using a DBMS such as Oracle Database Express Edition, Firebird and PostgreSQL. The proposed software and the method of implementation of the subsystem "RSFHWE" fully meet the requirements for the software implementation of the automated workplace of the forensic handwriting expert.

Key words: automated workplace, handwriting technique, neural network

УДК 332.145

ПРОГНОЗИРОВАНИЕ ГОРОДСКИХ ПОЖАРОВ В ПАКЕТЕ STATISTICA

Пономарева Ольга Андреевна

Национальный исследовательский университет «Высшая школа экономики», 614070, Россия,
г. Пермь, ул. Студенческая, 38, pnmrgva@mail.ru

Городские пожары – событие, которое сложно предсказать. Городские пожары наносят большой ущерб экономике города, причем последствия пожаров не только сгоревшие здания, но и человеческие жизни. Тем не менее, на сегодняшний день существуют различные инструменты прогнозирования. Одним из таких инструментов является нейронная сеть. В работе рассматривается построение нейронной сети с помощью пакета STATISTICA с указанием выбранных переменных, количества нейронов, функции активации и слоев. С помощью таких возможностей как «Таблицы предсказания значений», «Матрицы ошибок», «Итоги моделей» была определена, какая сеть оказалась наиболее удачно построенной. Результатом работы являются нейронные сети с различной архитектурой для прогнозирования городских пожаров с целью предотвратить экономические и человеческие потери. Одним из главных достоинств выбранного пакета является анализ построенных сетей и возможность построения разнообразных графиков. С помощью созданной модели были построены 3-D график зависимости вероятности пожара от дня недели и времени.

Ключевые слова: нейронные сети, нейроны, городские пожары, пакет STATISTICA.

Городские пожары являются событием, которые очень сложно предсказать. Их ущерб может быть связан не только с уничтожением зданий, но и с человеческой смертью. Это значит, что прогнозирование количества пожаров является актуальной задачей на сегодняшний момент, решение которой поможет сократить материальные ущербы, число погибших и травмированных людей в пожарах.

Для прогнозирования вероятности городского пожара была спроектирована нейросеть с конкретными входными параметрами, где параметры были определены на основе анализа пожаров на объектах жилого сектора в Пермском муниципальном районе 2016 года. По официальным статистическим данным МЧС России на 2016 год в Перми зарегистрировано 392 пожара, погибло в пожаре 20 человек, пострадавших 54 человека (см. табл.1).

Таблица 1. Количества пожаров на 2015 и 2016 год

	Количество пожаров	Количество погибших на пожарах	Количество травмированных
2015	434	25	66
2016	392	20	54

Всего в Перми 7 районов, по которым имеются статистические данные о количестве пожаров, количестве погибших и количестве травмированных [1]. В качестве входных параметров были выбраны X1 – Район, X2 – Объект пожара, X3 – Этажность дома, X4 – Этаж проживания, X5 – Наличие печного отопления, X6 – Наличие электрооборудования, X7 – Наличие газового оборудования, X8 – День недели, X9 – Время, X10 – Категория населения, X11 – Состояние алкогольного опьянения, X12 – Наличие привычки курить. В качестве выходного параметра D была выбрана вероятность возникновения пожара [2].

Создание нейронной сети было проведено в пакете «STATISTICA». На первом этапе была загружена таблица с данными в таблицу. После этого были указаны, какие переменные являются категориальными и непрерывными. В данном случае непрерывными входными переменными являются этажность дома, этаж проживания, день недели и время, а остальные параметры - категориальные входные параметры. При построении сети необходимо указать тип сети, минимальное и максимальное число скрытых нейронов, функцию активации [3, 4].

После выбора параметров сети обучают сеть. В результате, после обучения вывелось пять типов сетей с различными архитектурами MLP 33-4-2, MLP 33-4-2, MLP 33-5-2, MLP 33-11-2, MLP 33-10-2. Среди пяти сетей, наибольшей производительностью обучения обладает четвертая сеть с архитектурой MLP 33-11-2 (см. рис.1).

Итоги моделей (Таблица данных1)								
N	Архитектура	Производительность обуч.	Контр. производительность	Тест. производительность	Алгоритм обучения	Функция ошибки	Ф-я актив. скрытых нейр.	Ф-я актив. выходных нейр.
1	MLP 33-4-2	96,32739	97,04433	92,11823	BFGS 23	Энтропия	Гиперболическая	Софтмакс
2	MLP 33-4-2	96,95698	97,04433	94,08867	BFGS 31	Сум. квадр.	Гиперболическая	Логистическая
3	MLP 33-5-2	97,06191	96,55172	93,59606	BFGS 34	Сум. квадр.	Логистическая	Логистическая
4	MLP 33-11-2	98,63589	98,02956	94,08867	BFGS 62	Энтропия	Экспонента	Софтмакс
5	MLP 33-10-2	97,79643	98,02956	92,61084	BFGS 34	Энтропия	Логистическая	Софтмакс

Рисунок 1. «Итоги моделей» для построенных нейросетей с разными архитектурами

Пакет «STATISTICA» позволяет выводить информацию, насколько хорошо обучились построенные сети с помощью вывода таблицы [5]. В такой таблице выводятся

значения входных и выходных параметров для каждой сети, причем если не совпадает ожидаемый и реальный результат, то значения подсвечиваются красным цветом.

Наблюд. номер #	Таблица предсказанных значений для ВероятностьПожара (Таблица данных1) Выборки: Тестовая					
	ВероятностьПожара Целевая	ВероятностьПожара - Выход 1. MLP 33-4-2	ВероятностьПожара - Выход 2. MLP 33-4-2	ВероятностьПожара - Выход 3. MLP 33-5-2	ВероятностьПожара - Выход 4. MLP 33-11-2	ВероятностьПожара - Выход 5. MLP 33-10-2
1114	0	0	0	0	0	0
1131	1	1	1	1	1	1
1133	0	0	0	0	0	0
1138	0	0	0	0	0	0
1150	0	0	0	0	0	0
1158	0	0	0	0	0	0
1160	0	0	0	0	0	0
1166	1	0	0	1	1	0
1170	1	1	1	1	1	1
1173	0	1	1	1	1	1
1177	0	1	1	1	0	1

Рисунок 2. Проверка построенной нейросети с помощью таблицы предсказанных значений

Для анализа построенных сетей в пакете выводится матрица ошибок. Статистика выдается отдельно для каждой сети. В нашем случае сеть MLP 33-5-2 дает 93,9024% правильных результатов, а остальные сети 95,122% (см. рис.3).

	ВероятностьПожара (Итоги классификации) (Таблица данных1) Выборки: Тестовая			
		ВероятностьПожара-0	ВероятностьПожара-1	ВероятностьПожара-Все
1. MLP 33-4-2	Все	164,0000	39,00000	203,0000
	Правильно	156,0000	31,00000	187,0000
	Неправильно	8,0000	8,00000	16,0000
	Правильно (%)	95,1220	79,48718	92,1182
	Неправильно (%)	4,8780	20,51282	7,8818
2. MLP 33-4-2	Все	164,0000	39,00000	203,0000
	Правильно	156,0000	35,00000	191,0000
	Неправильно	8,0000	4,00000	12,0000
	Правильно (%)	95,1220	89,74359	94,0887
	Неправильно (%)	4,8780	10,25641	5,9113
3. MLP 33-5-2	Все	164,0000	39,00000	203,0000
	Правильно	154,0000	36,00000	190,0000
	Неправильно	10,0000	3,00000	13,0000
	Правильно (%)	93,9024	92,30769	93,5961
	Неправильно (%)	6,0976	7,69231	6,4039

Рисунок 3. Матрица ошибок

Одно из главных преимуществ пакета STATISTICA является возможность создавать графики 3-D. Рисунок 4 показывает вероятность пожара в зависимости от таких параметров, как день недели и времени. Можно заметить, что пик вероятности пожара приходится на дни недели – пятница, суббота, воскресенье и на время от 20:00 до 24:00. Данный прогноз подтверждается официальными данными МЧС, согласно которым утверждается, что наибольшее количество пожаров приходится на выходные дни [1].

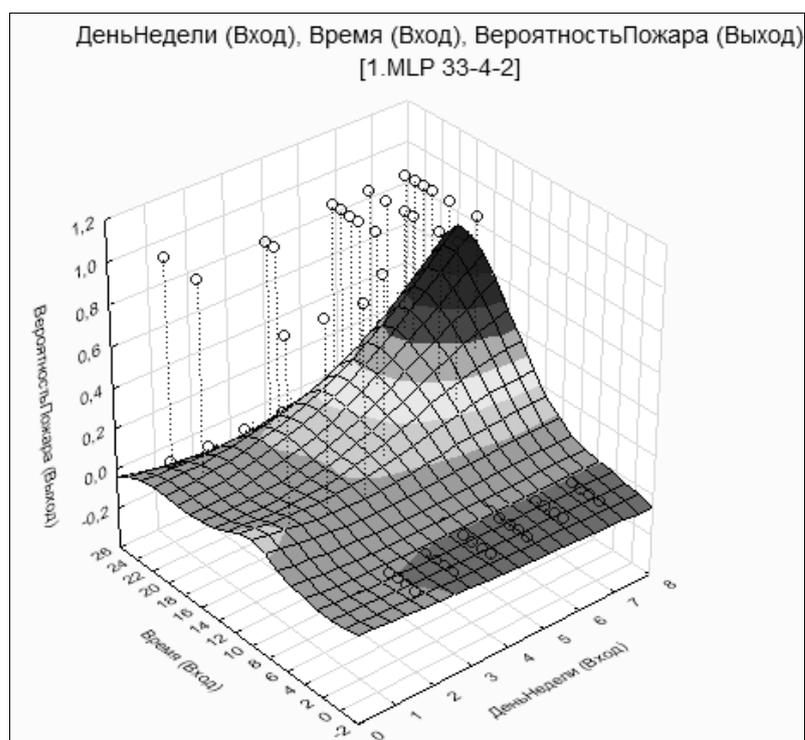


Рисунок 4. Вероятность пожара в зависимости от времени и дня недели

Аналогичным образом можно строить и другие графики, отображающие зависимость вероятности пожара от одного или нескольких параметров. Такие графики хорошо подходят для анализа и определения значимых параметров [6].

В результате исследования получены несколько сетей для предсказания городских пожаров с различными архитектурами. С помощью таких возможностей как «Таблицы предсказания значений», «Матрицы ошибок», «Итоги моделей» можно понять, какая архитектура наиболее удачна. На основе сети был построен наглядный график вероятности пожара от дня недели и времени, позволяющий определить, при каких параметрах наиболее вероятно возникновение пожара. Полученные прогнозы могут быть применены для предотвращения городских пожаров благодаря более эффективному распределению ресурсов при проведении проверок в различных районах города. Построенная нейронная сеть позволяет предсказывать пожары на объектах жилого сектора, таким образом, служба пожарной безопасности в ходе проверок зданий сможет обнаружить пожароопасные помещения и предотвратить их возгорание.

Библиографический список

1. Сводка ЧС и происшествий по Перми [Электронный ресурс] URL: <http://59.mchs.gov.ru/operationalpage/digest/2016/> (дата обращения: 29.01.2017).
2. Боровиков В.П. Нейронные сети. Statistica Neural Networks. Методология и технологии современного анализа данных. М.: Горячая линия – Телеком, 2008.
3. Ясницкий Л. Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
4. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы. Пермь,

2007. 271с.

5. Григорьева Д.Р., Файзуллина А.Г., Куликова А.Н. Применение пакета STATISTICA для анализа и прогнозирования экономических показателей предприятия // Социально-экономические и технические системы: исследование, проектирование, оптимизация. 2015. №2 С. 47.
6. Пономарева О.А. Прогнозирование городских пожаров с помощью нейронной сети. Всероссийская научная конференция «Нейрокомпьютеры и их применение». Тезисы докладов. – М: ФГБОУ ВО МГППУ, 2017.

URBAN FIRE PREDICTION IN “STATISTICA”

Ponomareva Olga A.

National Research University Higher School of Economics of Perm,
Studencheskaya str.38, Perm, Russia, 614070, pnmrva@mail.ru

Abstract. Urban fires are an event that is difficult to predict. Nevertheless, there are various forecasting tools. One such tool is the neural network. The paper deals with the construction of a neural network using the package “STATISTICA”, indicating selected variables, the number of neurons, the activation function. "Value prediction tables", "Error matrixes", "Model results" help to determine which the network is the most successfully built. The result of this work is neural networks with different architectures for forecasting urban fires. The main advantages of “STATISTICA” are the analysis of constructed networks and the possibility of constructing various graphs. 3-D graph that predicate fire in accordance with time and day was be created based on constructed networks.

Key words: the neural networks, neurons, urban fires, the package “STATISTICA”.

УДК 004.89

РАЗРАБОТКА МОДЕЛИ ОБНАРУЖЕНИЯ СЕТЕВЫХ АТАК НА ОСНОВЕ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

Суворова Валерия Александровна

Пермский государственный национальный исследовательский университет,
614600, г.Пермь, ул. Букирева, 15, Valery.Suvorova@yandex.ru

Суворов Александр Олегович

Пермский институт железнодорожного транспорта – филиал Уральского государственного
университета путей сообщения,
614000, г.Пермь, Максима Горького, 1, AOSuvorov@usurt.ru

В статье описана разработка нейронной сети, предназначенной для обнаружения и классификации сетевых атак, с использованием общедоступной базы данных KDD Cup 1999. В работе выполнена комплексная оценка значимости входных параметров соединений, выделены незначимые параметры. Построены нейронные сети с полным и сокращенным набором входных признаков, выполнен сравнительный анализ их характеристик. В результате была получена оптимальная модель нейронной сети, использующая 21 входной

параметр, способная определять тип атаки с вероятностью 99,83%. Сравнение полученной нейросетевой модели с аналогичными нейронными сетями показало высокую эффективность спроектированной нейронной сети. Полученная нейронная сеть может быть успешно применена в качестве одного из компонент системы обнаружения вторжений.

Ключевые слова: искусственные нейронные сети, сетевые атаки, система обнаружения вторжений.

На сегодняшний день защита данных в компьютерных сетях становится одной из важнейших проблем в области компьютерной безопасности. Одним из методов обеспечения технической защиты информации является построение систем обнаружения вторжений (Intrusion detection system) [1], которые предназначены для активного исследования защищенности информационных ресурсов.

В работе предлагается построение системы обнаружения атак на основе анализа сетевого трафика с использованием искусственной нейронной сети, а именно – многослойного персептрона [2]. В дальнейшем данная система может быть применена в качестве одного из элементов многоуровневой системы защиты от вторжений наряду со стандартными методами. Таким образом, основная цель работы – разработка модели обнаружения атак, обладающей способностью адаптации к изменениям поведения вычислительной сети, основанной на использовании аппарата искусственных нейронных сетей.

Исходя из поставленной цели, были выделены следующие задачи:

1. Построение модели нейронной сети с оптимальными характеристиками;
2. Обучение и тестирование нейронной сети;
3. Сравнение полученной модели с аналогичными нейронными сетями.

Работа является актуальной, поскольку ни одни из существующих методов не обеспечивает 100% защиту компьютерных систем от сетевых атак, и разработка новых методов обнаружения вторжений, позволяющих повысить уровень защищенности компьютерных систем от несанкционированного воздействия, является востребованной.

Данные для обучения и тестирования нейронной сети были взяты из общедоступной базы KDD Cup 1999 Data [3], содержащей сведения о легальных сетевых соединениях и атаках, где для каждой записи имеется 41 параметр. Всего в базе хранится информация о 22 видах атак, а также данные о легальных соединениях (normal).

Для того, чтобы проверить возможность использования нейронных сетей для обнаружения сетевых атак, была спроектирована нейронная сеть в нейросимуляторе Nsim5.0 [4], способная отличать нормальные соединения от подозрительных, без определения вида атаки. Данная сеть содержит 41 входной параметр и один выходной, который принимает

значения 1 и 2 (1 – соединение типа «normal», 2 – имеется атака, вторжение). Затем в нейросимуляторе экспериментальным путем подбирались различные варианты построения нейронной сети из условия обеспечения минимальной ошибки тестирования. В результате была получена конкретная нейронная сеть MLP 41-7-1, способная обнаруживать наличие атаки с высокой долей вероятности (ошибка обучения и тестирования сети составила 0% на обучающем и тестирующем множестве соответственно). Данная сеть была проверена на множестве из 1000 примеров, которые не входили в обучающее и тестовое множества, при этом ошибка проверки составила примерно 0,6%, что говорит о высоком качестве обнаружения атак.

Далее с помощью функции автоматического построения нейронных сетей (ANS) пакета Statistica [5], были получены нейронные сети, способные не просто выявлять атаку в соединении, но и определять её вид.

Рассмотрим полученные нейронные сети с полным набором параметров, построенные на входном множестве мощностью 50 000 записей. Входное множество разбивается на обучающее, тестовое и проверочное в соотношении 70%:15%:15%.

В результате автоматического перебора с помощью функции ANS были получены 5 наилучших вариантов построения нейронных сетей, представленные в таблице 1 [6].

Таблица 1. Нейронные сети с полным набором параметров

Название	Верность обучения (%)	Верность тестирования (%)	Верность проверки (%)	Алгоритм обучения	Функция ошибки	Функция активации скрытого слоя	Функция активации выходного слоя
MLP 122-24-23	99,90	99,853	99,84	BFGS 87	Entropy	Logistic	Softmax
MLP 122-11-23	99,85	99,813	99,85	BFGS 51	Entropy	Identity	Softmax
MLP 122-17-23	99,94	99,853	99,85	BFGS 66	Entropy	Tanh	Softmax
MLP 122-24-23	99,91	99,826	99,85	BFGS 73	Entropy	Identity	Softmax
MLP 122-7-23	99,86	99,82	99,88	BFGS 60	Entropy	Identity	Softmax

Каждая из нейронных сетей имеет 122 входа и 23 выхода, хотя при описании исходных данных было указано, что всего имеется 41 входной параметр и 1 выходной. Увеличение числа параметров происходит потому, что часть параметров представлены в нечисловом

виде, и программа автоматически разбивает их на множество входных (выходных) полей в зависимости от числа различных значений, которое принимает данное поле.

Как видно из таблицы 1, каждая из нейронных сетей позволяет с достаточно высокой точностью определить вид атаки – ошибка обучения не превышает 0,15%, ошибка тестирования не более 0,18% и ошибка проверки не превышает 0,16%, что говорит о высокой точности определения типов атак.

Для того чтобы уменьшить нагрузку на нейронную сеть и снизить вычислительные затраты следует избавиться от параметров, которые мало влияют на результат, то есть необходимо устранить избыточность входных данных.

Для сокращения числа входных параметров нейронной сети можно определить группы линейно-зависимых признаков соединения и избавиться от наличия линейных зависимостей. Анализ линейной корреляции данных был выполнен в MS Office Excel. Вычисление коэффициента линейной корреляции возможно только для числовых параметров, поэтому в анализе не участвовали признаки, отражающие качественные характеристики. Корреляционная матрица была построена для 31 признака, на множестве из 150 000 записей. Результаты определения коэффициента линейной корреляции позволили выявить группы линейно зависимых параметров. В дальнейшем при построении нейронной сети с сокращенным набором параметров нет необходимости использовать все параметры, которые являются линейно зависимыми, поэтому из каждой группы оставлен только один из признаков.

Далее были определены наименее значимые признаки для сетей с полным набором параметров с помощью встроенных инструментов Neural Networks пакета STATISTICA. Было вычислено среднее значение значимости для каждого признака по пяти нейронным сетям (из таблицы 1) с полным набором параметров. В таблице 2 представлено 10 признаков с наименьшей средней значимостью.

Таблица 2. Признаки с наименьшей значимостью для нейронных сетей с полным набором параметров

Признак	MLP	MLP	MLP	MLP	MLP	Значимость (среднее)
	122-24-23	122-11-23	122-17-23	122-24-23	122-7-23	
duration	1,19	1,05	1,33	1,17	1,05	1,16
num_shells	1,05	1,05	1,18	1,15	1,09	1,10
num_failed_logins	1,04	1,02	1,16	1,08	1,13	1,08
num_file_creations	1,01	1,11	1,05	1,07	1,08	1,06
dst_bytes	1,00	1,03	1,02	1,06	1,10	1,04
num_access_files	1,01	1,04	1,04	1,03	1,04	1,03
urgent	1,01	1,01	1,02	1,04	1,00	1,02

num_root	1,02	1,00	1,03	1,00	1,00	1,01
src_bytes	1,00	1,00	1,01	1,00	1,00	1,00
num_compromised	1,01	1,00	1,00	1,00	1,00	1,00

Данные признаки являются наименее информативными при вычислении результата. Следовательно, в дальнейшем при построении нейронных сетей с сокращенным числом параметров, их можно будет исключить из входного набора параметров.

Полученные результаты позволили сократить входное множество признаков на 20 параметров и построить нейронные сети с сокращенным набором параметров (таблица 3). В качестве входного множества использовались те же данные, что и для построения нейросетей из таблицы 1, т.е. объем входных данных составил 50 000 записей о соединениях.

Таблица 3. Нейронные сети с сокращенным набором параметров

Название	Верность обучения (%)	Верность тестирования (%)	Верность проверки (%)	Алгоритм обучения	Функция ошибки	Функция активации скрытого слоя	Функция активации выходного слоя
MLP 98-16-23	99,87	99,80	99,80	BFGS 130	Entropy	Logistic	Softmax
MLP 98-17-23	99,82	99,76	99,83	BFGS 63	Entropy	Identity	Softmax
MLP 98-6-23	99,83	99,76	99,83	BFGS 91	Entropy	Identity	Softmax
MLP 98-15-23	99,83	99,75	99,83	BFGS 75	Entropy	Identity	Softmax
MLP 98-15-23	99,82	99,76	99,77	BFGS 104	Entropy	Logistic	Softmax

Несмотря на то, что входное множество параметров было существенно сокращено, полученные нейронные сети обладают высокой способностью распознавания атак: ошибка проверки для каждого из 5 случаев не превышает 0,23%, что незначительно выше ошибки проверки для сетей с полным набором параметров.

Наилучшими характеристиками обладает сеть MLP 98-6-23, поэтому далее было выполнено сравнение данной модели с аналогичными нейронными сетями, решающими задачу распознавания сетевых атак, описанными в работах [7-9].

Результаты сравнения представлены в таблице 4.

Таблица 4. Сравнение MLP 98-6-23 с аналогичными нейросетевыми моделями

Источник	Количество входных параметров	Выходной результат	Точность определения результата (%)
[7]	9	Факт наличия атаки	93%
[8]	38	Факт наличия атаки	92,5% - 99,6%
[9]	41	Определение типа атаки	73%-99% (в зависимости от вида атаки)
MLP 98-6-23	21	Определение типа атаки	99,83%

Результаты сравнения полученной модели с аналогичными нейросетями показывают высокую эффективность разработанной модели и сравнительно высокую точность определения типа атак. Следовательно, модель нейронной сети MLP 98-6-23 может быть успешно встроена в различные системы обнаружения вторжений в качестве одного из компонент подсистемы обнаружения атак.

Таким образом, в ходе проделанной работы были построены различные варианты искусственных нейронных сетей, а именно сети с полным и сокращенным набором входных параметров, проведен анализ их характеристик. В результате была получена оптимальная модель нейронной сети MLP 98-6-23, использующая 21 входной параметр, способная определять тип атаки с вероятностью 99,83 % (на проверочном множестве мощностью 7500 записей). В дальнейшем на основе полученной модели предполагается разработка системы обнаружения атак, обладающей способностью адаптации к изменениям поведения вычислительной сети, которая может быть использована в составе различных программных комплексов для повышения уровня сетевой безопасности.

Библиографический список

1. *Олифер В.Г., Олифер Н.А.* Компьютерные сети. Принципы, технологии, протоколы: Учебник для вузов. 4-е изд. – СПб.: Питер, 2010. 944 с.
2. *Ясницкий Л.Н.* Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221с.
3. KDD Cup 1999 Data [Электронный ресурс] URL: <http://kdd.ics.uci.edu/databases/kddcup99> (дата обращения: 3.01.2017)
4. *Черепанов Ф.М., Ясницкий Л.Н.* Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014 г.
5. *Боровиков В.П.* Нейронные сети. STATISTICA Neural Networks: Методология и технологии современного анализа данных. 2-е изд., перераб. и доп. – М.: Горячая линия – Телеком, 2008. 392 с.
6. *Суворова В.А.* Опыт разработки и исследования модели обнаружения сетевых атак на основе искусственных нейронных сетей. XV Всероссийская научная конференция «Нейрокомпьютеры и их применение». Тезисы докладов. – М: ФГБОУ ВО МГППУ, 2017. с.203-206.

7. *Мустафаев А.Г.* Нейросетевая система обнаружения компьютерных атак на основе анализа сетевого трафика // Вопросы безопасности. 2016. № 2. с.1-7. [Электронный ресурс] URL: http://e-notabene.ru/nb/article_18834.html (дата обращения: 3.01.2017)
8. *Жигулин П.В., Мальцев А.В., Мельников М.А., Подворчан Д.Э.* Анализ сетевого трафика на основе нейронных сетей // Электронные средства и системы управления. 2013. №2. с.44-48.
9. *Емельянова Ю.Г., Талалаев А.А., Тищенко И.П., Фраленко В.П.* Нейросетевая технология обнаружения сетевых атак на информационные ресурсы // Программные системы: Теория и приложения. 2011. № 3(7). с. 3-15.

THE DEVELOPMENT OF INTRUSION DETECTION MODEL BASED ON ARTIFICIAL NEURAL NETWORK

Suvorova Valeria Aleksandrovna

Perm State University, st. Bukireva, 15, Perm, Russia, 614990, Valery.Suvorova@yandex.ru

Suvorov Aleksander Olegovich

Perm Institute of Railway Transport, st.M.Gorkova, 1, Perm, Russia, 614000, AOSuvorov@usurt.ru
The article describes the development of a neural network for the detection and classification of network attacks. The paper estimated the importance of the input parameters of compounds, represents built a neural network with a full and reduced set of parameters, depicts a completed comparative analysis of their performance. The result is the optimal model of the neural network, which has the 21 input parameter and can determine the type of attack with a probability of 99.83%. Comparison of the resulting neural network model with the same neural networks shows high efficiency of designed neural network. The resulting neural network can be used successfully as a component of the intrusion detection system.

Keywords: artificial neural networks, network attacks, intrusion detection system.

УДК 004.89

РАЗРАБОТКА НЕЙРОСЕТЕВОЙ СИСТЕМЫ ДЛЯ ОПРЕДЕЛЕНИЯ ВМЕНЯЕМОСТИ СЕРИЙНЫХ УБИЙЦ

Чернышева Екатерина Сергеевна

Пермский государственный национальный исследовательский университет,
Юридический факультет.

614990, Россия, г. Пермь, ул. Букирева, д. 15, waxkat@yandex.ru

В статье дается описание и анализ попытки разработать нейросетевую систему для определения вменяемости серийных убийц. Рассматриваются общие параметры и их влияние на результат. Используя алгоритм упругого распространения, сеть обучается и тестируется. Делается вывод о значимости параметров. Также сравниваются действительные и прогнозируемые значения вменяемости. Делается заключение о точности сети и прогнозируемых результатах.

Ключевые слова: Искусственный интеллект, вменяемость, нейросетевые технологии.

Необходимым условием уголовной ответственности является наличие вины, т.е. умысла или неосторожности у лица, совершившего общественно опасное деяние.

Лица душевно больные, слабоумные, не способные осознавать характер совершаемых ими действий или оценивать их социальное значение, а также не способные руководить своими действиями из-за поражения волевой сферы психики, не могут действовать умышленно или неосторожно в уголовно-правовом смысле. В их объективных действиях нет вины, поэтому, рассматривая дела об общественно опасных деяниях, совершенных лицами в состоянии невменяемости, суд выносит не приговор (решение о виновности или невиновности), а определение.

Лица, не понимающие фактическую сторону своих действий или их социальное значение, не могут быть субъектами преступления. Они нуждаются не в исправлении путем применения наказания, а в лечении. Поэтому наряду с достижением определенного возраста субъект преступления должен обладать признаком **вменяемости**. Н.С. Таганцев отмечал: «Физическое лицо только тогда, в смысле юридическом, может быть виновником преступления, когда оно совмещает в себе известную сумму биологических условий, обладает, употребляя техническое выражение доктрины, способностью ко вменению».

Действующий российский уголовный закон не дает определения вменяемости.

В истории существуют яркие примеры того, что вынесенные приговоры не всегда являются верными [1, 2]. Серийные убийцы, проблеме выявления которых с помощью нейронных сетей посвящена работа [3], признанные психиатрами и судом невменяемыми, вследствие чего освобожденные от уголовной ответственности и направленные на принудительное лечение в психиатрические больницы, по истечении какого-то времени признавались не представляющими опасность обществу и выпускались на свободу. Обычно после непродолжительного промежутка времени эти преступники совершали очередные зверские убийства. Данный факт, возможно, означает, что убийства совершаются ими осознанно и судить их следовало как вменяемых.

Поэтому актуально создание информационных систем, которые помогут определять вменяемость или невменяемость преступников.

Проектирование нейронной сети, как и в работе наших предшественников [3], было осуществлено в программе «Нейросимулятор 5.0» [4] по методике [5, 6]. Этот программный продукт включает в себя режимы проектирования, обучения, проверки и прогноза. Первоначально необходимо определить структуру персептрона, а именно количество входных и выходных параметров, количество скрытых слоев и количество нейронов на каждом из них, а также активационных функции скрытых нейронов. Оптимальной структурой нейронной сети

является персептрон, имеющий четырнадцать входных нейронов, один выходной нейрон и один скрытый слой с тремя нейронами (рис.1). В качестве активационных функций нейронов входного и выходного слоев использовались линейные функции, скрытого слоя – сигмоидная функция.

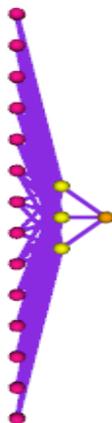


Рис. 1. Структура разработанного персептрона

Обрабатываемые данные собраны с помощью сети Интернет. Множество примеров серийных убийц было разбито на обучающее, состоящее из 61 примера, использованное для обучения сети, и тестирующее множество, состоящее из 6-ти примеров, предназначенное для проверки ее прогностических свойств. Примеры тестирующего множества при обучении нейронной сети не использовались.

Для построения нейросетевой модели были выбраны следующие входные параметры: пол, наличие родителей, их социальное положение, судимость и склонность к алкоголю, факт изнасилования, семейный статус, наличие детей, в том числе и астрологические: знак Зодиака, день недели рождения, стихия, знак по восточному календарю, фаза Луны и градусы Солнца. Выходной параметр модели кодирует значение 1, если серийный убийца является вменяемым, 0 – если невменяемым.

После обучения прогностические свойства нейронной сети проверялись на примерах тестирующего множества, которые не использовались при ее обучении. Результат тестирования представлен на рис. 2 в виде гистограммы, позволяющей сопоставить желаемые и действительные (вычисленные нейронной сетью) значения вменяемости серийных убийц. Среднеквадратическая ошибка тестирования составила 8%.

Таким образом, можно утверждать, что нейронная сеть усвоила закономерности моделируемой предметной области, и теперь ее можно использовать для проведения вычислительных экспериментов.

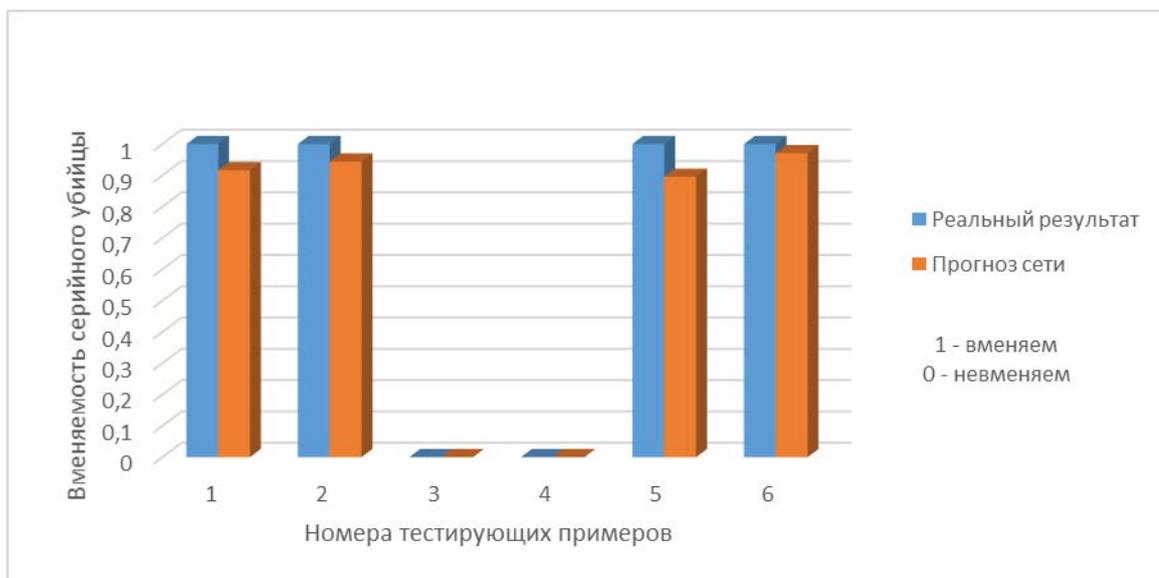


Рис. 2. Адекватность разработанной нейросетевой модели

Оценка значимости параметров позволила определить, что наибольшее значение при выявлении вменяемости серийного убийцы имеет его семейный статус. Немаловажными являются и такие астрологические факторы, как градусы Солнца, знак Зодиака, стихия, фаза Луны и проч. (рис.3).

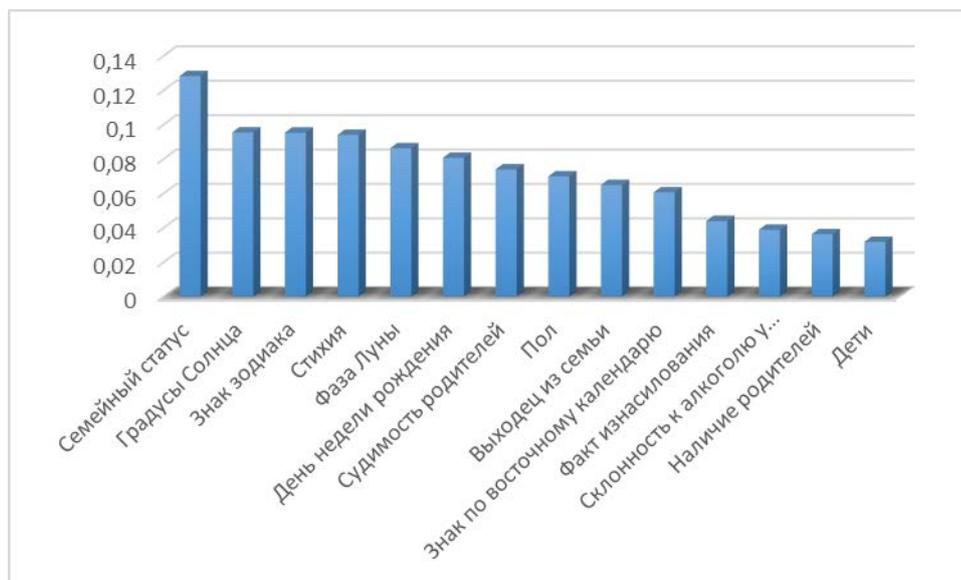


Рис. 3. Распределение значимости параметров, влияющих на вменяемость серийного убийцы

Таким образом, на примере разработанной нейросетевой модели показано, что метод нейросетевого моделирования позволяет с высокой точностью определять вменяемость или невменяемость серийных убийц.

Библиографический список

1. Психологический портрет серийного преступника [Электронный ресурс][Режим доступа: <http://diplomba.ru/work/111808>] (дата обращения: 19.06.2016)

2. Михеев Р.И. Проблемы вменяемости и невменяемости в советском уголовном праве. Владивосток, 1983. С. 49.
3. Ясницкий, Л. Н., Ваулева С. В., Сафонова Д. Н., Черепанов Ф. М. Использование методов искусственного интеллекта в изучении личности серийных убийц // Криминологический журнал Байкальского государственного университета экономики и права. 2015. Т.9, №3. С. 423-430.
4. Черепанов, Ф. М., Ясницкий, Л. Н. Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ №2014612546. Заявка Роспатент №2014610341. Зарегистрировано в Реестре программ для ЭВМ 28 февраля 2014г.
5. Ясницкий, Л. Н. Искусственный интеллект. Элективный курс. Москва, 2012.
6. Ясницкий Л.Н., Богданов К.В., Черепанов Ф.М. Технология нейросетевого моделирования и обзор работ Пермской научной школы искусственного интеллекта // Фундаментальные исследования. 2013. № 1-3. С. 736-740.

DEVELOPMENT OF A NEURAL NETWORK TO DETERMINE THE SANITY OF SERIAL MURDERERS

Chernysheva Ekaterina S.

614990, Perm State University, Russia, Perm, Bukireva Str. 15, waxkat@yandex.ru

The article provides a description and an analysis of attempt to develop neural network system to determine the sanity of serial murderers. We consider the general parameters and their influence on the result. The network is trained and tested with the elastic spread algorithm. The inference about the parameters significance is made. The real and predicted values are also compared. The conclusion about the network accuracy and predicted results is made.

Keywords: Artificial intelligence, sanity, neural network technologies.

УДК 004.8

ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА КАК ЦЕЛЕНАПРАВЛЕННАЯ СИСТЕМА, ОСНАЩЕННАЯ КОМПЛЕКСОМ ИНТЕЛЛЕКТУАЛЬНОГО УПРАВЛЕНИЯ И РАЗВИТИЯ НА ВСЕХ ЭТАПАХ ЖИЗНЕННОГО ЦИКЛА

Чечкин Александр Витальевич.

Военная академия РВСН имени Петра Великого,
Финансовый университет при правительстве РФ, 125993, Россия,
г. Москва, Ленинградский проспект, 49, a.chechkin@mail.ru

Рассматривается целенаправленная система любого назначения. Вводится ее интегральная характеристика, информационно системная безопасность. Для обеспечения такой безопасности требуется интеллектуализация системы, т.е. оснащение системы комплексом интеллектуального управления и развития. В свою очередь основой комплекса является радикальная модель системы, т.е. избыточная модель "театра действий целенаправленной системы" в форме среды радикалов. В результате целенаправленная система становится интеллектуальной системой, поведенческая активность которой направлена на обеспечение ее информационно системной безопасности.

²⁷ Публикация подготовлена при финансовой поддержке РФФИ (грант № 16-29-04326).

© Чечкин А.В., 2017

Ключевые слова: целенаправленная система, проблемная область, информационно системная безопасность, избыточное моделирование, радикал, интеллектуальная система.

1. Интеллектуализация целенаправленных систем

Ключевой проблемой всякой целенаправленной системы (ЦС) является эффективное прохождение ею всех этапов своего жизненного цикла (ЖЦ). Для этого требуется обеспечение информационно системной безопасности (ИСБ) системы [1]. ИСБ ЦС охватывает две взаимосвязанные стороны глобальной безопасности ЦС:

1. *Информационная сторона ИСБ ЦС* - это эффективное решение каждой *штатной* задачи ЖЦ ЦС на основе создания избыточной модели широкой проблемной области ЦС. При этом такая избыточная модель ЦС является моделью "театра действий ЦС"; обеспечена защитой информации этой модели; должна иметь средства эффективного решения любой *штатной задачи* жизненного цикла ЦС. Кроме того, модель должна иметь средства организации эффективных попыток решения любой *нештатной* задачи ЦС и на этой основе обеспечить развитие и самообучение ЦС;

2. *Системная сторона ИСБ ЦС* - это учет и обработка всех последствий решения каждой штатной и нештатной задачи во всей проблемной области ЦС, включая уход от появившихся конфликтов и обеспечение развития ЦС; сохранение гомеостаза, целостности ЦС и эффективности функционирования ЦС.

Для обеспечения ИСБ ЦС требуется оснащение ЦС комплексом интеллектуального управления эффективным решением каждой штатной задачи ЖЦ и организацией успешных попыток решения каждой нештатной задачи, являющейся "точкой роста ЦС" и развития ЦС.

2. Радикальная модель - избыточная система в форме среды радикалов

Сегодня в эпоху информатики, в отличие от предыдущей эпохи физики, на передний план вышли избыточные системы [1, 2]. Это всевозможные базы данных, базы знаний, библиотеки программ, компьютерные и коммуникационные сети, леготехнологии и др. Главное отличие избыточных систем - организация всех элементов системы в форме среды радикалов. Избыточные системы в форме среды радикалов естественно называть *радикальными системами*. *Радикалами* (корнями) называют любые функциональные (имеющие назначение) системы, которые имеют два вида состояний, *пассивные* и *активные*. Радикалы в пассивном состоянии находятся в режиме хранения, запаса, выжидания. Они как бы выключены и не функционируют. Активные радикалы функционируют согласно своему назначению. Радикальные системы требуют оснащения их активирующей, операционной подсистемой. Оснащенные активирующей подсистемой, радикальные системы обладают *поведенческой активностью*, реализуя свою целенаправленную деятельность в "театре своих

действий". При этом при решении каждой штатной задачи своего ЖЦ в радикальной модели активируется соответствующая временная рабочая сеть активных радикалов, называемая *системоквантом* радикалов. Системоквант отвечает за свой этап решения очередной штатной задачи или попытки решения нештатной задачи и за этап своего развития. Пассивные радикалы системы каждый раз образуют временно не востребуемый потенциал избыточной системы.

3. Интеллектуальное управление и развитие ЦС

Радикальная модель ЦС, оснащенная активирующей надсистемой и реализованная программно техническими средствами представляет собой систему обеспечения комплексного управления и развития (СОКУР) ЦС [3]. Оснащенная дружественным интерфейсом, СОКУР ЦС служит для автоматизации процесса управления решением целевых задач ЦС (целевой процесс), для организации постоянного обновления данных и знаний о всей широкой проблемной области ЦС (сенсорный процесс). Кроме целевого и сенсорного процессов в ЦС проводится постоянная сертификация, тестирование радикальной модели ЦС и обеспечивается бесконфликтное обновление этой модели (сертификационный процесс). При этом все три процесса, целевой, сенсорный и сертификационный должны происходить в СОКУР ЦС одновременно в режиме решения штатных задач ЖЦ ЦС.

Кроме организации интеллектуального управления СОКУР ЦС организует, в случае появления нештатных ситуаций, процесс развития ЦС в режиме «проб, ошибок и самообучения». Тем самым, в рамках и под контролем радикальной модели с помощью активации входящих в нее радикалов происходит целенаправленное функционирование и комплексное развитие ЦС.

СОКУР отвечает за развитие ЦС, за разработку, создание и модификацию очередных составляющих, связей между ними в рамках широкой проблемной области ЦС. В частности, только в рамках СОКУР может быть решена центральная проблема программной инженерии любых ЦС, создание и развитие эффективных программно технических средств (ПТС) ЦС любого назначения. Такая технология программирования названа радикальным программированием [4]. При этом радикальная модель ЦС отражает семантику всех частных ПТС ЦС и позволяет учесть, в том числе, ресурсные потребности и возможности ЦС. Тем самым СОКУР является *избыточной* (в меру) *системой*, достаточной для рассмотрения ЦС как *локально открытой* и *постоянно развивающейся системы*.

4. Заключение

Радикальное моделирование имеет идейного предшественника в отечественной информатике. В середине 80-х гг. академик А.П. Ершов опубликовал работу о Лексиконе программирования [5]. Лексикон должен был содержать в себе семантику всей проблемной области и одновременно формальную нотацию для выражения всех общезначимых конструкций, которые употребляются при формулировании и решении разнообразных задач, при синтезе, преобразовании и верификации программ. Если программа выражена средствами Лексикона, то в своем тексте она содержит описание своей семантики. Лексикон является открытой системой, и этим он отличается от языка программирования. Кроме того, Лексикон – это развивающаяся система тщательно отобранных обозначений. Цели, поставленные А.П. Ершовым, становятся достижимыми с помощью радикального моделирования, языка схем радикалов, реализуемых с помощью современных ПТС

Библиографический список

1. Чечкин А. В. Математическая информатика // М.: Наука, 1991. 412 с.
2. Соболева Т.С., Чечкин А.В. Дискретная математика. Углубленный курс. Учебник.//
3. М.: КУРС. ИНФРА-М. 2016. 278 с.
4. Чечкин А.В. Обеспечение информационно-системной безопасности сложной системы на основе среды нейрорадикалов ее проблемной области // М.: Нейрокомпьютеры: разработка, применение. 2008, №7, С. 6-11.
5. Васенин В.А., Пирогов М.В., Чечкин А.В. Радикальное моделирование и инженерия сложных программных систем // М.: Программная инженерия. 2014. - №10. С. 3 – 10.
6. Чечкин А.В., Пирогов М.В.. Радикальное программирование на основе радикального моделирования // М.: Нейрокомпьютеры: разработка, применение. 2016. №1. С. 3-16.

INTELLIGENT SYSTEM AS A PURPOSE SYSTEM, EQUIPPED WITH INTELLECTUAL MANAGEMENT AND DEVELOPMENT COMPLEX AT ALL STAGES OF THE LIFE CYCLE

Chechkin Alexander V.

*Financial University under the Government of the Russian Federation,
Leningradsky prospect, 49, Moscow, Russia, 125993, a.chechkin@mail.ru*

Abstract. A purposeful system of any purpose is considered. Its integral characteristic, information system security is introduced. To ensure such security requires the intellectualization of the system, equipping the system with a complex of intelligent management and development. In turn, the basis of the complex is a radical model of the system, redundant model of "the theater of action of a purposeful system" in the form of a radical media. As a result, a purposeful system becomes an intellectual system, the behavioral activity of which is aimed at ensuring its information system security.

Key words: purposeful system, problem area, information system security, redundant modeling, radical, intellectual system.

6. ПЕДАГОГИКА

ПРОБЛЕМЫ И ВОЗМОЖНОСТИ ИСПОЛЬЗОВАНИЯ ИНТЕЛЛЕКТУАЛЬНЫХ ТЕХНОЛОГИЙ В ОБУЧЕНИИ СТУДЕНТОВ — БУДУЩИХ УЧИТЕЛЕЙ ИНФОРМАТИКИ

Кувалдина Татьяна Александровна

Волгоградский государственный социально-педагогический университет, 400131,
Россия, г. Волгоград, просп. им. В.И. Ленина, 27, kuvalditana@gmail.com

Представлены результаты сравнительного анализа определений понятия «интеллектуальные технологии» в информатике, а также — применительно к теории и методике обучения информатике (сфере образования, педагогике). Дана интерпретация результатов анкетирования студентов — будущих учителей информатики — по вопросам, связанным с информационными технологиями и интеллектуальными системами. Кратко представлены результаты словарной работы, в том числе — с использованием Интернет-поиска, а также — результаты построения интуитивно-логических схем и спонтанных ответов студентов на вопросы, посвящённые систематизации знаний по информатике. Показана взаимосвязь проблем систематизации, визуализации и интеграции знаний в теории и методике обучения информатике — через интеллектуальные технологии.

Ключевые слова: интеллектуальные технологии, визуализация знаний, систематизация знаний, интеграция знаний, семантические сети, тезаурусный метод, интеллект-карты.

В настоящее время в методике и практике профессионального педагогического образования получают всё более широкое распространение т.н. новые интеллектуальные технологии, под которыми в самом общем, популярном смысле понимают программные средства, позволяющие наглядно представить какие-либо данные либо информацию (или, как часто говорят: визуализировать знания учащихся и учителей). Формами визуализации при этом называют: интеллектуальные карты, карты знаний, ментальные карты и т.п. [1, с. 85-86]. На самом деле такие средства созданы для того, чтобы «облегчить» процедуру вычерчивания вручную, по возможности «автоматизировать» визуализацию учебной информации, как для учителя, так и для учащихся. И здесь всегда подразумевается гипотетическая возможность увеличения эффективности обучения за счёт компактного и удобного для восприятия представления учебного материала в формально- и/или интуитивно-логических схемах, аналитических таблицах — в соответствии с классической дидактикой (см., в частности, работы А.М. Сохора, В.П. Беспалько [2-4]).

В теории и методике обучения информатике проблема использования интеллектуальных технологий не возникает, т.к. преподаватели и учителя давно и успешно используют информационные технологии и в качестве важной составляющей содержания образования по информатике, и для подготовки учебных и методических материалов. В

настоящее время и в школьном, и в университетском образовании происходит постепенная замена уже ставших традиционными информационных технологий более новыми — т.н. интеллектуальными, что особенно актуально для дистанционной формы обучения. Попробуем определить, в чём, собственно, состоит их новизна, и так ли она принципиальна. В качестве примера укажем на публикации красноярских учёных — см., Дорошенко Е.Г., Пак Н.И., Хакимов Д.Р. и др. [5, 6]. Если в других предметных методиках уже обсуждаются возможности и проблемы использования интеллект-карт в обучении студентов, то в методике информатики вышеназванными исследователями предложен такой термин, как «ментальные карты», на наш взгляд, не самый удачный в русском переводе, т.к. этимологически связывается с понятием менталитета, а не интеллекта.

Как связаны интеллект-карты и интеллектуальные технологии? Ответ на этот вопрос можно получить, если провести сравнительный анализ определений понятий. В качестве вводного замечания укажем, что понятие интеллектуальных технологий пока имеет лишь чисто техническое определение, видимо, в силу своей новизны.

Считается, что выражение «интеллектуальная технология» было введено в употребление американским социологом Д. Беллом, получившим широкую известность благодаря предложенной им концепции постиндустриального общества [7]. Интеллектуальная технология, по Д. Беллу, есть замена интуитивных рассуждений алгоритмами (правилами решения задач). Эти алгоритмы могут быть реализованы в автоматической машине, в компьютерной программе или в наборе инструкций, основанных на некоторых математических формулах. Как отмечает в связи с этим И.Ю. Алексеева, интеллектуальная технология, таким образом, предполагает использование математической или логической техники при работе с «организованной сложностью», в качестве которой могут быть рассмотрены различные, в том числе социальные, организации и системы [8]. Таким образом, в данных трактовках понимание интеллектуальной технологии, по сути, сводится к понятию новой информационной технологии, активно используемому в сфере педагогического образования в 1990-е гг.

Обратимся к другим определениям понятия «интеллектуальные технологии». В сфере научно-технических знаний это понятие, как правило, интегрируется с понятием интеллектуальной системы. В качестве наиболее полного приведём определение, данное в работе Болотовой Л.С. и др. [9]: «Под интеллектуальными информационными технологиями обычно понимают такие информационные технологии, в которых предусмотрены следующие возможности: наличие баз знаний, отражающих опыт конкретных людей, групп, обществ, человечества в целом, в решении творческих задач в выделенных сферах

деятельности, традиционно считавшихся прерогативой интеллекта человека (например, такие плохо формализуемые задачи, как принятие решений, проектирование, извлечение смысла, объяснение, обучение и т. п.); наличие моделей мышления на основе баз знаний: правил и логических выводов; аргументации и рассуждения; распознавания и классификации ситуаций; обобщения и понимания и т. п.; способность формировать вполне чёткие решения на основе нечётких, нестрогих, неполных, недоопределённых данных; способность объяснять выводы и решения, то есть наличие механизма объяснений; способность к обучению, переобучению и, следовательно, к развитию. Уникальная особенность интеллектуальных информационных технологий (ИИТ) — их «универсальность». Они практически не имеют ограничений по применению в таких областях, как управление, проектирование, машинный перевод, диагностика, распознавание образов, синтез речи и т.д. ИИТ также находят широкое применение для распределённого решения сложных задач, совместного проектирования изделий, построения виртуальных предприятий, моделирования больших производственных систем и электронной торговли, электронной разработки сложных компьютерных систем, управления системами знаний и информации и т.п. Ещё одно эффективное применение — поиск информации в Internet и других глобальных сетях, её структуризация и доставка заказчику».

В самом кратком определении «интеллектуальные информационные технологии (ИИТ) — это информационные технологии, помогающие человеку ускорить анализ политической, экономической, социальной и технической ситуации, а также — синтез управленческих решений» [10].

В рамках наших исследований, связанных с интеграцией знаний, на основе проведённого методического эксперимента мы можем утверждать, что используемый нами методологический аппарат (сетевое моделирование и тезаурусный метод), разработанная методика обучения, составленные для этого комплекты/средства (формально-логические и интуитивно-логические схемы, аналитические таблицы, контрольные вопросы логического характера, примерные наборы понятий и терминов, а также — вопросы, посвящённые систематизации знаний по информатике, для спонтанных ответов) — вполне соответствуют понятию «интеллектуальная технология».

С нашей точки зрения, как сами интеллектуальные технологии, так и возможности их использования в обучении студентов — будущих учителей информатики — следует рассматривать в контекстах трёх взаимосвязанных проблем современной дидактики, а именно: систематизации, визуализации и интеграции знаний — в основе которых лежит систематизация понятий с использованием методов искусственного интеллекта, в частности,

сетевого моделирования и тезаурусного метода. Рассмотрим это утверждение более подробно. В соответствии с теорией обучения наглядное представление учебного материала должно способствовать лучшему его усвоению. Отметим также, что в последнее время стало модным, распространилось употребление понятий «информация» и «знания» — вместо точно определённого термина «учебный материал» или даже «содержание обучения», что, к сожалению, не всегда точно отражает суть исследуемой проблемы.

С нашей точки зрения, интеллектуальные технологии могут быть эффективно использованы, прежде всего (во-первых), для визуализации знаний учителя и учащихся, понимаемой здесь как выявление той первичной интуитивно-логической структуры знаний, что может представить сам субъект обучения; во-вторых, для систематизации знаний учащихся в процессе обучения — как постепенное формирование системы знаний учащихся и выявление этого выстраивания, обеспечивающее связность и непротиворечивость системы знаний — на основе модели системы понятий; в-третьих, для того, чтобы обеспечить возможность интеграции знаний, т.е. объединения в целостность, воссоздание целостного образа изучаемого предмета, особенно — для проблем, находящихся на стыке двух или более областей.

В связи с этим, как нам представляется, целесообразно уточнить понятие целостности в обучении информатике. Мы предлагаем новые, «рабочие» варианты определений, или *схему основных принципов интеграции знаний*: 1) множество объектов (+ процессов, явлений), соединённых смысловыми и формально-логическими связями, представленное как целостный образ на одном экране (в одном кадре, сеансе работы); 2) соединение разных видов информации в представлении одного объекта разными субъектами = мультимедийность; 3) визуализация знаний подразумевает выявление целостности, системности, систематизированности знаний как учителя, так и учащихся; 4) целостность знаний как результат систематизации учебного материала; 5) методика обучения информатике, построенная на основе интеллектуальных технологий.

Чтобы разработать проект и реализовать такую методику в практике, сначала необходимо сделать проект в рукописи, т.е. провести вводную часть работы со студентами максимально отвлечённо от программно-технических средств, на чистой формально-логической и творческой основе, предъявляя те или иные учебно-методические материалы — готовые фрагменты знаний, с целью выявить на интуитивно-логической основе имеющийся у студентов запас знаний, с учётом их реальной мотивации. Далее можно проводить «машинную» часть эксперимента с интеллект-картами, используя те или иные программные средства — для визуализации индивидуальной картины знаний каждого

студента. По результатам этой работы сопоставить рукописные варианты и машинные. Накопить данные для анализа, чтобы можно было оценить эффективность усилий преподавателя и студентов для обучения информатике по данной методике. И главное — определить реальность достижения цели (систематизация, визуализация, интеграция знаний) и возможности применения данной технологии с учётом её трудоёмкости.

В завершение нашего аналитического обзора кратко укажем самые важные моменты, относящиеся к многолетнему наблюдению за эволюцией взглядов студентов, касающихся понятий информационных технологий (ИТ) и интеллектуальных систем (ИС). Как показывают результаты анкетирования студентов, обучающихся по направлениям «Информатика—Физика» (ранее «Физика—Информатика») (2004-2016 гг.), «Информатика», «Физика», «Математика», «Математика—Информатика» (2010-2016 гг.), «Прикладная информатика» (2014-2016 гг.), большинство современных студентов (2012-2016 гг.) на вопрос об интеллектуальных системах дали такие определения: «ИС — это программные системы (средства), предназначенные для решения сложных задач и выполнения функций, свойственных человеку», «... для решения творческих задач». Некоторые отождествили интеллектуальные системы с системами искусственного интеллекта, прямо указав, что интеллектуальные системы предназначены для создания или реализации ИИ (представлены оригинальные формулировки ответов). Ранее, приблизительно до 2010 г. довольно большое количество студентов, в разных группах от 30 до 50%, затруднялись ответить на вопрос либо отвечали почти так же, как и на вопрос об определении информационной технологии. Заметим, что анкетирование проводилось в 5-м либо 7-м семестрах, для студентов разных направлений — в рамках изучения курсов «ИКТ в образовании», «Использование ИКТ в образовательном процессе», «Электронные образовательные ресурсы в обучении информатике», до изучения курса «Основы искусственного интеллекта».

В качестве выводов отметим, что реализация предлагаемой нами концепции методического эксперимента [11, 12] подтверждает эффективность применения описанной методики обучения — на основе результатов словарной работы, в том числе — с использованием Интернет-поиска, а также — результатов построения интуитивно-логических схем и спонтанных ответов студентов на вопросы, посвящённые систематизации знаний по информатике.

Библиографический список

1. *Кувалдина Т.А.* К проблеме визуализации знаний в обучении информатике // III Международная научно-практическая конференция «Педагогический опыт: теория, методика, практика»: Педагогика высшей профессиональной школы (Чебоксары, 31 июля 2015 г.). Чебоксары: Центр научного сотрудничества «Интерактив плюс», 2015.

- (304 с.) С. 83-89. [Электронный ресурс]. — Режим доступа: <https://interactive-plus.ru/e-articles/145/Action145-11076.pdf>. (12 с. / 0,75 п.л.)
2. *Сохор А.М.* Логическая структура учебного материала. Вопросы дидактического анализа. — М.: Педагогика, 1974. — 192 с.
 3. *Беспалько В.П.* Слагаемые педагогической технологии. — М.: Педагогика, 1989. — 190 с.
 4. *Беспалько В.П.* Теория учебника: Дидактический аспект. — М.: Педагогика, 1988. — 160 с.
 5. *Дорошенко Е.Г., Пак Н.И., Рукоусева Н.В., Хегай Л.Б.* О технологии разработки ментальных учебников // Вестник ТГПУ. 2013. №12 (140). С. 145-151. URL: <http://cyberleninka.ru/article/n/o-tehnologii-razrabotki-mentalnyh-uchebnikov> (дата обращения: 15.03.2017).
 6. *Хакимов Д.Р.* Применение в учебном процессе ментальных карт // Образовательные ресурсы и технологии. 2016. №1 (13). URL: <http://cyberleninka.ru/article/n/primenenie-v-uchebnom-protsesse-mentalnyh-kart> (дата обращения: 15.03.2017).
 7. *Белл Д.* Грядущее постиндустриальное общество. Опыт социального прогнозирования / Пер. с англ. под ред. В.Л. Иноземцева. Изд. 2-е, испр. и доп. — М.: Academia, 2004. — 788 стр.
 8. *Алексеева И.Ю.* Традиционная и современная технологии. Часть 2. Примеры исследований традиционных и современных технологий. Идея интеллектуальной технологии // Гуманитарные технологии: Информационно-аналитический портал. ISSN 2310-1792. URL: <http://gtmarket.ru/laboratory/basis/4532/4542> (дата обращения: 15.03.2017).
 9. *Болотова Л.С., Любкин М.С., Резер В.С.* Интеллектуальные технологии (история и тенденции развития) // Директор информационной службы. 2002. № 5. URL: <https://www.osp.ru/cio/2002/05/172154/> (дата обращения: 22.03.2017).
 10. *Интеллектуальная технология* / Терминологический словарь библиотекаря по социально-экономической тематике. — СПб.: Российская национальная библиотека. 2011. URL: http://socialeconom.academic.ru/934/интеллектуальная_технология (дата обращения: 23.03.2017).
 11. *Кувалдина Т.А.* Систематизация знаний и интеллектуальные технологии в подготовке учителя информатики // Актуальные проблемы методики обучения информатике в современной школе: Международная научно-практическая интернет-конференция (г. Москва, ФГБОУ ВО МПГУ, 16-17 февраля 2016 г.). Сб. научных материалов / Под ред. Т.Б. Захаровой, Н.К. Нателаури. — М.: МПГУ, 2016. — 397 с. (С. 198-202. 4 с. / 0,25 п.л.) РИНЦ URL: <http://elibrary.ru/item.asp?id=27284618>
 12. *Кувалдина Т.А., Мазина О.В.* О концепции методического эксперимента по интеграции знаний информатики и экологии для студентов и школьников // Информационные технологии в образовании. XXV Международная конференция-выставка (Москва, 6-7 ноября 2015 г.). Сборник трудов. Ч. II. — М.: Издательский отдел факультета ВМК МГУ имени М.В. Ломоносова, 2015. — С. 47-50. [Электронный ресурс]. — Режим доступа: <http://ito.su/main.php?pid=26&fid=9387>.

PROBLEMS AND POSSIBILITIES OF USING INTELLECTUAL TECHNOLOGIES IN PREPARING OF STUDENTS — INFORMATICS FUTURE TEACHERS

Kuvaldina Tatiana Aleksandrovna

Volgograd State Social-Pedagogical University, av. by V.I. Lenin, 27, Volgograd, Russia,
400131, kuvalditana@gmail.com

This article provides the comparing analysis' results of concepts determination of intellectual technologies using in informatics and also in theory and teaching methods considered as education

technology. Results of students questioning upon the problems dealing with information technologies and intellectual systems are interpreted. Results of dictionary work using Internet-search, intuitive-logic schemes construction and spontaneous answers dealing with knowledge systematization provided by students are presented briefly. The interrelation between the problems of systematization, visualization and integration of knowledge in the theory and methodology of teaching informatics through intellectual technologies is shown. Methodical experiment is realized upon students — informatics future teachers. The research concluded that the concept of methodical experiment is effective in its realization.

Keywords: intellectual technologies, knowledge visualization, knowledge systematization, knowledge integration, semantic nets, thesaurus method, intellect-maps.

УДК 004.891.2

**СИСТЕМА РЕКОМЕНДАЦИЙ ФАКУЛЬТЕТОВ АБИТУРИЕНТАМ
НАЦИОНАЛЬНОГО ИССЛЕДОВАТЕЛЬСКОГО УНИВЕРСИТЕТА «ВЫСШАЯ
ШКОЛА ЭКОНОМИКИ – ПЕРМЬ»**

Коклемина Юлия Дмитриевна, Горбунова Мария Андреевна,

Судоргина Виктория Алексеевна

Национальный исследовательский университет «Высшая школа экономики»,

Пермский филиал, Россия, 614070, Пермь, ул. Студенческая, 38,

julishna94@mail.ru, gorbunova123@inbox.ru, um.sudorgina@gmail.com

Разработана нейросеть, позволяющая определить направление для обучения в НИУ ВШЭ на основе введенных параметров. Нейросеть обучена на результатах опроса студентов всех направлений НИУ ВШЭ-Пермь и протестирована. Определены степени влияния различных параметров на результат. Выяснено, что наибольшее влияние на результат имеет параметр “Комбинации экзаменов ЕГЭ”, “Направления интересов абитуриента”, “Комбинации личностных характеристик”. Работа содержит анализ предметной области и теоретическую информацию о нейронных сетях, информацию о проектировании нейронной сети, информацию о разработке и тестировании созданной нейронной сети. Нейросеть создана в симуляторе нейронных сетей «Нейросимулятор 5».

Ключевые слова: искусственный интеллект, нейронная сеть, прогноз, абитуриент.

Введение

В ходе курса «Интеллектуальные системы» наша группа реализовала нейросетевую математическую модель, на основе изученного материала по книгам Ясницкого Л.Н. «Введение в искусственный интеллект» [2-4] и используя симулятор нейронных сетей «Нейросимулятор 5» [6].

При поступлении абитуриенты часто сталкиваются с проблемой выбора факультета. Из-за неправильно-принятого решения студент сталкивается с такими проблемами как:

отчисления, отсутствие интереса к будущей профессии. Разработанная нейросеть может помочь избежать подобных ошибок и будет являться эффективным инструментом при выборе подходящего факультета на основе проанализированных данных студентов всех направлений НИУ ВШЭ Пермь. В ходе работы было опрошено 350 студентов. На основе опроса была получена и структурирована информация для создания нейросети. При таком количестве респондентов планируется достичь наиболее точных результатов. Также выявляется степень влияния различных параметров на результат.

Анализ литературы

Главным примером, который лег в основу идеи разработки нейросети для абитуриентов, является нейросеть предназначенная для определения способности человека к предпринимательской деятельности. Более того, выявлено влияние нетипичных факторов (например, цвет глаз), учет которых позволил повысить точность прогнозов [1].

В работе предлагается методика оценки вероятности успешности бизнеса в зависимости от личностных и других параметров предпринимателя и вида его предполагаемого бизнеса. Например, применив эту методику, вы можете получить ответ на вопрос, будет ли успешным автомобильный бизнес, если им начнет заниматься голубоглазый бездетный мужчина 35 лет. Методика, несомненно, является полезной предпринимателям, решающим вопрос об открытии нового бизнеса [2].

На основе данной работы и личного интереса было принято решение о разработке нейросети способствующей определить наиболее подходящее направление для обучения в НИУ-ВШЭ.

Построение математической модели

Данная система предназначена для помощи в принятии решения при выборе факультета НИУ ВШЭ Пермь. Так как большая часть входных данных имеет строковый формат, их необходимо закодировать. Коды для каждого из параметров приведены в соответствующих таблицах. В качестве входных параметров были выбраны: x_1 - суммарные баллы ЕГЭ, x_2 - код комбинации экзаменов ЕГЭ, x_3 - код формы обучения, x_4 - код направлений интересов абитуриента, x_5 - код ответа на ситуационный вопрос, x_6 - код комбинации личностных характеристик.

Для работы в «Нейросимуляторе 5» все данные были закодированы. Коды комбинаций экзаменов: 1- Математика + Русский язык + Обществознание + Иностранный язык («Экономика»/«Менеджмент»); 2 - Русский язык + Обществознание + История + Иностранный язык («Юриспруденция»); 3 - Русский язык + Иностранный язык + История

(«История»); 4 - Математика + Русский язык + Информатика («Программная инженерия»); 5 - Математика + Русский язык + Иностранный язык («Бизнес-информатика»).

Коды форм обучения: 1 – бюджетная основа; 2 – коммерческая основа.

Коды профессиональной склонности абитуриента: 1 - гуманитарный; 2 – технический.

Коды ответа на ситуационный вопрос: 1 - изучить рынок компьютерных программ, изучить по какой цене и где лучше продавать программу, продумать стратегию продвижения "от" и "до", спланировать весь комплекс мероприятий по продвижению («Бизнес-информатика»); 2 - принять участие в разработке программного продукта («Программная инженерия»); 3 - придумать логотип, дизайн, договориться о размещении рекламы в журналах и на сайтах («Менеджмент»); 4 - рассчитать бюджет проекта, окупаемость, затраты, возможную прибыль («Экономика»); 5 - подготовить и проверить сопровождающие документы («Юриспруденция»); 6 - договориться с журналом о написании статьи о новом программном продукте, изучить развитие этой области и конкурентов («История»).

Коды комбинаций личностных характеристик: 1 - усидчивость, старательность, терпение, легкообучаемость, логическое мышление, целеустремленность, мобильность («Бизнес-информатика»); 2 - ответственность, общительность, уверенность в себе, харизма, креативность, коммуникативность, энергичность («Менеджмент»); 3 - логическое мышление, самообладание, эрудированность, инициативность, аналитический склад ума («Экономика»); 4 - усердность, терпеливость, эрудированность, ответственность, аналитический склад ума, хорошая память («История»); 5 - стрессоустойчивость, рассудительность, логический склад ума, пунктуальность, хладнокровие, красноречие, коммуникабельность («Юриспруденция»); 6 - нестандартное мышление, трудолюбие, умение распределять время, упорство, усидчивость, старательность, заинтересованность, собранность («Программная инженерия»).

В качестве выходных параметров выступает матрица с процентным соотношением того насколько абитуриенту подходит тот или иной факультет. Кодирование выходного параметра: 1 - бизнес-информатика, БИ (Y1); 2 - программная инженерия, ПИ (Y2); 3 – менеджмент, М (Y3); 4 – экономика, Э (Y4); 5 – юриспруденция, Ю (Y5); 6 – история, И (Y6).

Идея состоит в том, чтобы показать студенту, что выбор направления может быть не однонаправленным. Таким образом, на основе ответов на тест, студент получает матрицу с процентами соответствия для каждого факультета. Нейросетевая модель создана при помощи специальной программы «Нейросимулятор 5», которая представляет собой полноценный симулятор нейронных сетей.

Сеть имеет 6 нейронов на входном слое, один скрытый слой с 9 нейронами и 6 нейронами на выходном слое.

Исследование полученной модели

В качестве активационной функции была выбрана функция тангенса гиперболического. В качестве алгоритма обучения выбран алгоритм быстрого распространения [5]. В данном примере ошибка обучения 0,024 %, а обобщения 0,022%, что является приемлемым.

В режиме проверки загрузим тестовые данные. Ниже указана гистограмма, на которой расположены желаемые результаты (D1) и реальные результаты (Y1) по одному из выходных параметров – «Бизнес-информатика» (см. Рисунок 1).

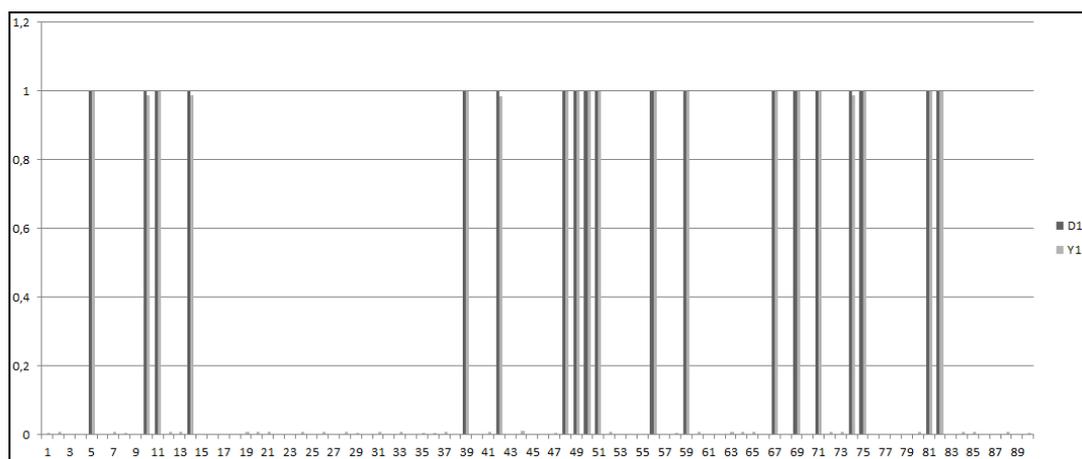


Рисунок 1. Ожидаемые и реальные результаты по параметру «Бизнес-информатика»

Модель дает довольно точные результаты. Данный симулятор позволяет посмотреть значимость различных параметров. На рисунке 2 представлена гистограмма со значимыми параметрами.

Как можно видеть по графику, самым значимым параметром является параметр «Личностные характеристики». Далее по значимости следуют параметры «Интересы абитуриента» и «Экзамены ЕГЭ». Как оказалось, суммарные баллы ЕГЭ, формы обучения и ответ на ситуационный вопрос имеют малое влияние на результат.

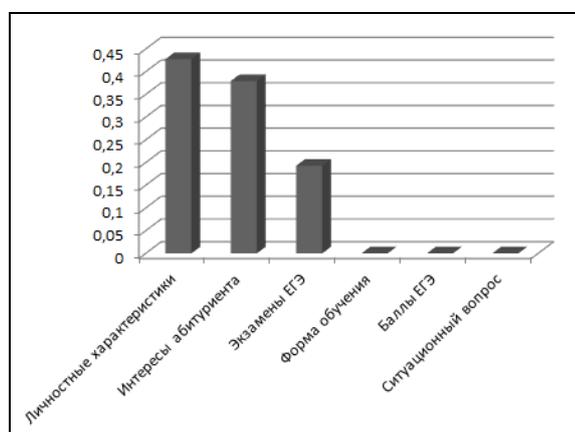


Рисунок 2. Значимость параметров

Для проверки значимости параметров последовательно изменим значение каждого из них в соответствии со степенью значимости. Для этого возьмем одну из строк тестового множества и используем как исходную для подтверждения значимости параметров. Строка представлена на рисунке 3.

	X1	X2	X3	X4	X5	X6	Y1	Y2	Y3	Y4	Y5	Y6
1	195	4	2	2	2	6	0.0033	0.9956	0	0.0094	0.0088	0

Рисунок 3. Исходная строка

Изменим значение параметра 6 (комбинация личностных характеристик) на значение 3, что соответствует направлению «Экономика». Система вывела 0.6693% направлению «Бизнес-информатика», 0.178% - «Программная инженерия», 0.0125% - «Экономика», проценты других направлений поменялись незначительно.

Изменим параметр 4 (направление интересов абитуриента), со значения 2 (техническое направление) на значение 1 (гуманитарное направление), при этом параметр 6 возвращаем к исходному значению. Система выдает процентное соотношение: 0.9941% - «Юриспруденция», 0.1329% - «История» и 0.8337% - «Программная инженерия». Как видим, изменение этого параметра повлияло на повышение процента соответствия у гуманитарных направлений, но также снизило показатель для направления «Программная инженерия».

Изменение параметра 2 (комбинация экзаменов ЕГЭ) с 4 («Программная инженерия») на 1 («Экономика»/«Менеджмент»), показало следующие результаты: 0.9439% - «Экономика», 0.0713% - направление «Программная инженерия», 0.0107% - направление «Юриспруденция». Как можем видеть, данный параметр меньше всего сократил процент соответствия для направления «Программная инженерия». Опытным путем было установлено, что изменение остальных параметров практически не изменяет процентных показателей.

Заключение

По результатам данной работы можно сделать вывод, что с помощью нейронных сетей можно решить многие важные проблемы. В данной работе была рассмотрена проблема выбора факультета абитуриентом НИУ ВШЭ Пермь.

Разработанная нейросеть поможет абитуриентам определиться в выборе факультета на основе теста, а также позволит сократить время, затрачиваемое на данный процесс. С помощью нейросети абитуриент получает возможность с легкостью сориентироваться в требуемой информации. Данная разработка еще не была реализована на сайте университета НИУ ВШЭ. Внедрение системы для абитуриентов может повысить конкурентоспособность, а также привлечь новых студентов за счет удобства выбора факультета.

Библиографический список

1. Ясницкий Л.Н., Порошина А.М., Тавафиев А.Ф. Цвет глаз предпринимателя и успешность его бизнеса. Нейросетевые технологии как инструмент для прогнозирования успешности предпринимательской деятельности // Российское предпринимательство. – 2010. – № 4-2. – С. 8 – 13.
2. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221с.
3. Ясницкий Л. Н., Богданов К. В., Черепанов Ф. М. Технология нейросетевого моделирования и обзор работ Пермской научной школы искусственного интеллекта // Фундаментальные исследования. 2013. № 1-3. С. 736-740.
4. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы. Пермь, 2007. 271с.
5. НИУ ВШЭ в Перми – Национальный Исследовательский Университет в Перми [Электронный ресурс] [Режим доступа: <https://perm.hse.ru/>] [Проверено: 20.02.2017].
6. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.

SYSTEM OF THE RECOMMENDATIONS OF THE FACULTIES TO THE STUDENTS NATIONAL RESEARCH UNIVERSITY "HIGHER SCHOOL OF ECONOMICS – PERM"

Koklemina Julia D.

National Research University Higher School of Economics, 38 Studenchkaya st., Perm,
614070, Russia, julishna94@mail.ru

Gorbunova Mariia A.

National Research University Higher School of Economics, 38 Studenchkaya st., Perm,
614070, Russia, gorbunova123@inbox.ru

Sydorgina Viktoria A.

National Research University Higher School of Economics, 38 Studenchkaya st., Perm,
614070, Russia, viki.as@rambler.ru

This work has developed neural network to determine the direction for study in HSE based on parameters entered. Neural Network trained and on the results of the poll of students of all HSE directions-Perm and tested. Defined the extent of influence of various parameters on the result. Found that the greatest influence on the result is "a combination of exams", "interests", "combination of the entrant's personal characteristics". The first chapter contains an analysis of the subject area and theoretical information about neural networks. The second chapter is devoted to the design of a neural network. The third chapter contains data on the development and testing of the created a neural network. Neural network created in the emulator, neural networks "Neyrosimulyator" 5.

Keywords: artificial intelligence, neural network, forecast the entrant.

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ ДЛЯ АНАЛИЗА МЕТАПРЕДМЕТНЫХ ОБРАЗОВАТЕЛЬНЫХ РЕЗУЛЬТАТОВ ОБУЧЕНИЯ НА УРОВНЕ ОСНОВНОГО ОБЩЕГО ОБРАЗОВАНИЯ

Худякова Анна Владимировна, Топольский Вадим Владимирович
Пермский государственный гуманитарно-педагогический университет,
614990, г. Пермь, ул. Сибирская, 24, ahudyakova@pspu.ru

В статье рассматривается проблема создания внутришкольной системы оценки качества образования, соответствующей требованиям нового Федерального государственного образовательного стандарта. Предложена информационная система для автоматизации сбора, обработки, анализа и хранения информации о состоянии и динамике метапредметных результатов обучающихся на уровне образовательной организации. Внедрение данной системы позволяет перейти на управление образовательным процессом по результатам, обеспечить всех участников образовательного процесса точной, объективной и сопоставимой информацией для повышения качества образования в целом. Использование нейросетевых методов обработки информации при анализе образовательных результатов дает возможность спрогнозировать их дальнейшее развитие, определить факторы, влияющие на динамику данного развития, принять меры по минимизации действия отрицательных факторов, предложить наиболее оптимальный вариант построения индивидуальной образовательной траектории обучающегося.

Ключевые слова: информационная система, мониторинг образовательных результатов, метапредметные результаты, нейросетевые технологии.

В условиях перехода на цифровой формат обучения необходим инструментарий для мониторинга его результатов. Используемая во многих образовательных организациях система электронных дневников и журналов позволяет отслеживать динамику только предметных результатов обучающихся, в то время как новые Федеральные государственные образовательные стандарты (ФГОС) смещают акцент на формирование и диагностику метапредметных результатов обучения, включающих в себя познавательные, регулятивные и коммуникативные универсальные учебные действия (УУД).

Проектирование и реализация единой базы данных о состоянии и динамике показателей метапредметных результатов каждого обучающегося обеспечит координацию деятельности всех участников образовательного процесса, позволит определить факторы, влияющие на динамику метапредметных результатов образовательной деятельности и принять меры по минимизации их действия и устранению отрицательных последствий.

Для создания базы данных необходимо определиться с количеством, содержанием и критериями УУД, формирующимися на каждом уровне общего образования. В соответствии с примерными программами по формированию УУД на уровне начального и основного

общего образования в структуре метапредметных результатов выделяют 13 УУД, на уровне среднего общего образования – 19 УУД [1].

Мониторинг метапредметных результатов может проводиться в ходе различных процедур: в результате выполнения специально сконструированных диагностических задач, направленных на оценку уровня сформированности конкретного вида универсальных учебных действий; в ходе выполнения учебных и учебно-практических задач средствами учебных предметов; при выполнении комплексных заданий на межпредметной основе (итоговые комплексные работы).

Конечно, ряд коммуникативных и регулятивных действий трудно или невозможно оценить в ходе стандартизированных работ. Например, умение работать в группе, слушать и слышать собеседника, координировать свои действия с партнёрами и т.д. В этом случае в ходе внутренней оценки, фиксируемой в портфолио в виде оценочных листов наблюдения, может быть оценено и достижение таких действий.

На первом этапе создания внутришкольной системы оценки качества образования, соответствующей требованиям нового ФГОС, мы выбрали экспериментальную группу (параллель 5-х классов одной из образовательных организаций Пермского края) и определились с компонентами УУД для диагностики и развития. Среди коммуникативных УУД были выбраны: умение выражать свои мысли, планирование учебного сотрудничества, умение решать конфликтные ситуации. В регулятивных УУД выделены три группы: целеполагание, планирование и контроль. Из всех познавательных УУД выбрано смысловое чтение: поиск информации, понимание прочитанного, преобразование и интерпретация информации. Личностные УУД диагностировались классными руководителями и включали в себя: усвоение нравственно-этических норм и школьных норм поведения, успешность социальных контактов, эмоциональное благополучие.

Для удобства оценки была разработана единая трехбалльная шкала и критерии (уровни) развития. Работа над целенаправленным формированием определенного вида УУД (за исключением личностных) проводилась в течение одной четверти. Результаты диагностики уровня развития УУД фиксировались в Google-таблицах. Каждый учитель-предметник, работающий с экспериментальной группой, оценивал уровень сформированности выбранных компонентов УУД. По каждому виду УУД производился подсчет среднего значения его сформированности.

По результатам первого этапа работы над цифровой диагностикой личностных и метапредметных результатов обучающихся были сделаны следующие выводы. Подсчет среднего значения сформированности каждого вида УУД является неудобным, поскольку

разница в сотые балла затрудняет анализ информации. Гораздо удобнее считать суммарный балл и выстраивать шкалы перевода баллов в проценты или оценки, количественные или качественные.

Хранение результатов в Google-таблицах позволяет координировать деятельность учителей, но в дальнейшем затрудняет поиск информации и делает неудобным ее анализ. Поскольку диагностика проводится ежегодно, нужны сводные данные по уровню развития УУД каждого обучающегося на протяжении нескольких лет. Проблема такого подхода к хранению информации заключается в отсутствии индексации объектов, к которым относятся результаты. Эту проблему может решить хранение информации в базе данных.

Поэтому на втором этапе создания внутришкольной системы оценки качества образования мы начали проектирование базы данных о состоянии и динамике показателей личностных и метапредметных результатов обучающихся (<http://uudm.ru>). Кроме того, был расширен спектр познавательных УУД. В его состав вошли: смысловое чтение, критическое мышление и исследовательские действия обучающихся.

Главной сущностью структуры спроектированной базы данных является «Школа» (рис.1). От сущности «Школа», связанной с ней по ключевому полю, формируются сущности «Класс», «Ученик», «Сотрудники», «Должности сотрудников» и «Предметы». Сущность «Класс» и «Ученик» связываются через таблицу «Ученики в классах». Такой способ связи позволит хранить информацию о переводах ученика в другие классы, например из 6 «Б» в 7 «Б». Сущность «Ведет предмет» позволяет указать, какие предметы ведет учитель. Связь «один ко многим» необходима для того, чтобы один учитель мог вести несколько предметов. Другими глобальными сущностями, не привязанными к школе, являются «УУД» и «Критерии УУД». Сводная сущность «Результаты» связана с сущностями «Критерии УУД», «Ученик в классе» и «Ведет предмет». Таким образом, в сводной таблице мы получаем информацию о результатах оценки критериев УУД ученика в определённом классе по предмету, который ведет учитель (рис.2).

Создание единой базы данных о состоянии и динамике показателей метапредметных результатов каждого обучающегося позволит определить факторы, влияющие на динамику метапредметных результатов образовательной деятельности и на основе нейросетевых методов спрогнозировать их дальнейшее развитие. Нейросеть обучается решению конкретной задачи на некоторой обучающей выборке.

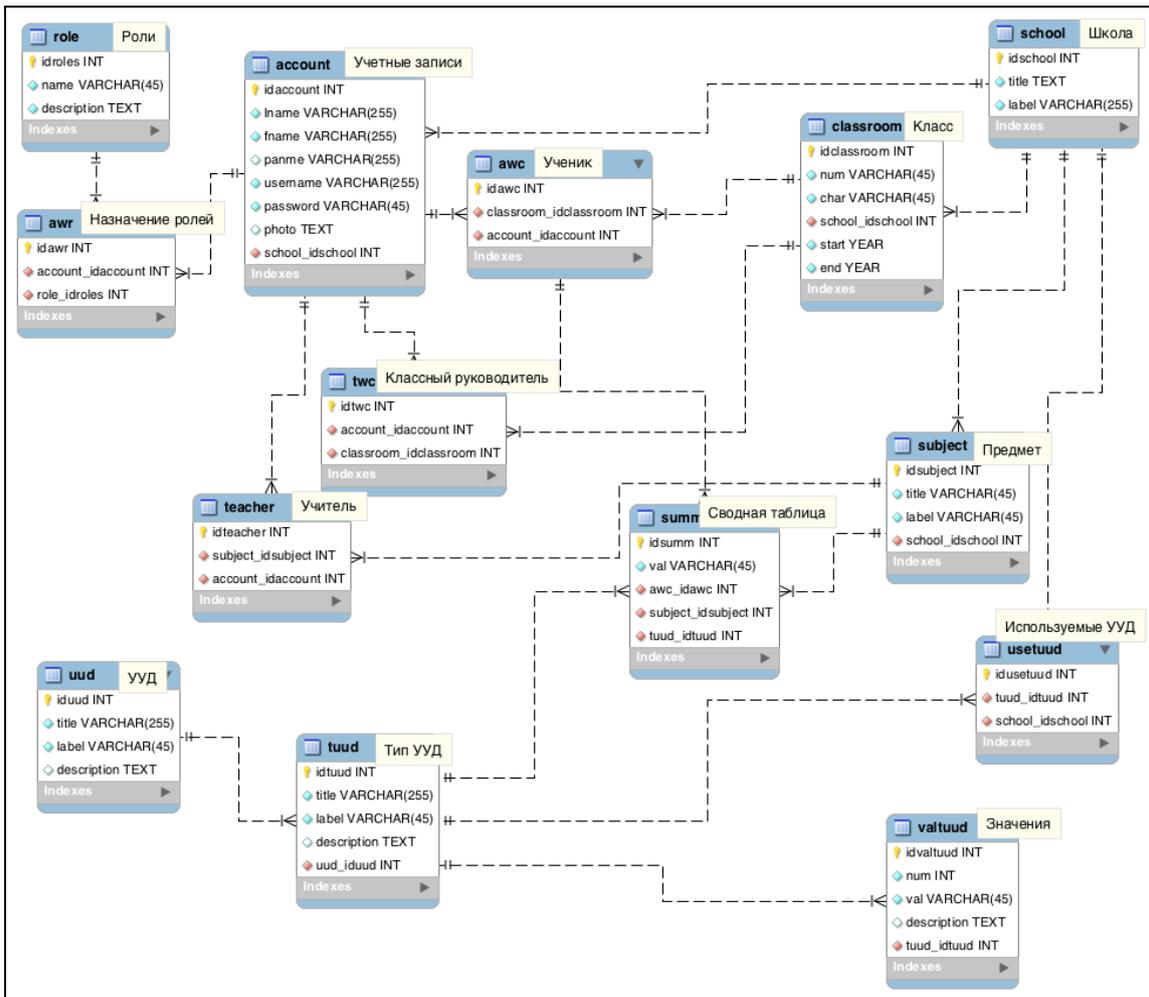


Рис. 1

Отчеты по результатам мониторинга УУД

Отчеты учителя

- Отчет по обучающемуся
- Отчет по классу
- Отчет по предмету

Отчеты классного руководителя

- Отчет по обучающемуся
- Отчет по классу

Отчеты администратора школы

- Отчет по предмету
- Отчет по учителю

Рис. 2

На третьем этапе создания внутришкольной системы оценки качества образования выбрана обучающая выборка и выявлены общие параметры, которые прямо или косвенно способны повлиять на уровень развития универсальных учебных действий. При обучении нейросеть сама находит зависимости между данными, подающимися на вход и требуемыми выходными сигналами. Обученная нейронная сеть может обобщать полученный навык решения и выдавать прогноз для новых значений входных сигналов. В качестве основного инструмента для разработки нейросетевой модели анализа метапредметных образовательных результатов использован программный продукт «Нейросимулятор 5.0» [2].

К главному эффекту внедрения данной системы относится повышение качества образования за счет целенаправленной адресной работы педагогов по формированию универсальных учебных действий обучающихся.

Библиографический список

1. Формирование универсальных учебных действий в основной школе: от действия к мысли. Система заданий: пособие для учителя / А.Г. Асмолов, Г.В. Бурменская, И.А. Володарская и др.; под ред. А. Г. Асмолова. – М.: Просвещение, 2010.
2. *Черепанов Ф.М., Ясницкий Л.Н.* Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.

NEURAL NETWORK APPLICATION FOR ANALYSIS OF META-SUBJECT RESULTS OF GENERAL EDUCATION

Hudyakova Anna V., Topolskiy Vadim V.

Perm State Humanitarian Pedagogical University, 24, Sibirskaya st., Perm, Russia, 614990,
ahudyakova@pspu.ru

The article is dedicated to the creating a school system for assessing the quality of education according to the new Federal State Educational Standard. An information system is proposed to automate the collection, processing, analysis and storage of information and dynamics of meta-subject results of students at the level of an educational organization. The introduction of this system makes it possible to transfer to the management of the educational process by results, to provide all participants in the educational process with accurate, objective and comparable information for improving the quality of education in general. The use of neural network information processing methods in the analysis of educational results makes it possible to predict their further development, to determine the factors influencing the dynamics of this development, to take steps to reduce the effect of negative factors, to offer the most optimal option for constructing an individual educational trajectory of the learner.

Keywords: information system, the federal state educational standard, universal learning activities, meta-subject results, neural network technology.

7. СПОРТ

ПОСТРОЕНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ ПРОГНОЗИРОВАНИЯ РЕЗУЛЬТАТОВ НАЦИОНАЛЬНОЙ ХОККЕЙНОЙ ЛИГИ

Мамаева Вероника Сергеевна

Национальный исследовательский университет «Высшая школа экономики», Пермский филиал, Россия, 614070, Пермь, ул. Студенческая, 38, veronikamamaewa@yandex.ru.

Филипсон София Константиновна

Национальный исследовательский университет «Высшая школа экономики», Пермский филиал, Россия, 614070, Пермь, ул. Студенческая, 38, lyubov.filipson@inbox.ru.

Данная статья посвящена прогнозированию результатов игр Национальной хоккейной лиги 2016-2017. С помощью статистических данных, собранных с официального сайта НХЛ за 5 лет, была построена нейронная сеть. Проектирование происходило в Нейросимулятор 5.0 и включало в себя следующие этапы: определение входных и выходных параметров и, как следствие, структуры перцептрона с помощью анализа данных, обучение и тестирование сети. В связи с тем, что сезон игр уже начался, в качестве прогнозируемого множества были взяты реальные данные, т.е. есть обеспечена возможность мгновенной проверки результатов, полученных с помощью нейронной сети. В работе представлены полученные результаты прогноза.

Ключевые слова: искусственный интеллект, нейронная сеть, прогноз, хоккей, ставки.

Введение

Национальная хоккейная лига (НХЛ)— профессиональная спортивная организация, объединяющая хоккейные клубы США и Канады. С сезона 2000—2001 играет 30 команд из 29 городов США и Канады, ежегодно борющихся за главный трофей лиги — Кубок Стэнли.

Просмотр хоккея является не только популярным времяпрепровождением фанатов данного вида спорта, но еще и заработком. Люди стараются предсказать счет игр, места в турнире, самого эффективного игрока и т.д.

Актуальность данной работы заключается в том, что на сегодняшний день еще не существует нейронной сети для прогнозирования результатов НХЛ.

Целью этой работы является построение нейронной сети для прогнозирования результатов национальной хоккейной лиги.

Впервые нейронные сети начали использоваться для составления прогнозов именно в области спорта. Так, были спрогнозированы результаты Чемпионата Европы по футболу [1] и Чемпионата мира по легкой атлетике [2].

Чемпионат проводится каждый год, в нем участвует множество команд. Для того чтобы создать нейронную сеть было решено собрать статистику за последние 5 лет, что позволит сделать прогноз на НХЛ 2016-2017 года.

Анализ предметной области. Сбор статистики

Нейронная сеть – это система, работающая по принципу действия человеческого мозга. Её обучение начинается с определения входных параметров. В процессе обучения сеть находит зависимости входных параметров для вывода оптимального ответа.

В качестве основного источника для сбора информации были использованы сайты с представленной статистикой [3,4], в которых были собраны все данные с 2011 по 2016 гг. по матчам НХЛ. Основным источником, раскрывающим теоретические основы построения и применения нейронных сетей, являлись учебные пособия [5, 6].

Для построения нейронной сети была проанализирована информация, предоставленная на указанных сайтах и выбраны наиболее важные параметры. Полученные результаты сформировали обучающее множество.

Изучив предметную область, было выяснено, что особую роль играют следующие параметры: средний возраст игроков команды, число и поражений, поражения в овертайме, количество забитых и пропущенных голов, процент реализации большинства и защиты меньшинства, количество штрафных минут.

Таким образом, был сформирован вектор X из 9 параметров и вектор Y , который содержит один параметр: место команды в итоговом зачете.

Согласно [6], обучающее множество должно содержать в себе не менее 78 примеров ($N_{\text{прим.}} \geq 7 \cdot N_x + 15$, где N_x – количество параметров). Список выбранных входных параметров нейронной сети представлен в таблице 1.

Таблица 3. Описание параметров

Параметр	Название (кодировка)
X1	Средний возраст игроков команды (числовое значение, кодировка не нужна)
X2	Число побед (числовое значение, кодировка не нужна)
X3	Число поражений (числовое значение, кодировка не нужна)
X4	Поражения в овертайме (числовое значение, кодировка не нужна)
X5	Количество забитых голов (числовое значение, кодировка не нужна)
X6	Количество пропущенных голов (числовое значение, кодировка не нужна)
X7	Процент реализации большинства (числовое значение, кодировка не нужна)
X8	Процент защиты в меньшинстве (числовое значение, кодировка не нужна)
X9	Количество штрафных минут (числовое значение, кодировка не нужна)

Y1	Место команды в своей конференции по итогам сезона (числовое значение, кодировка не нужна)
----	--

После того как данные собраны, они были разделены на обучающее и тестовое множества. Тестовое множество составило примерно 15% от обучающего.

Проектирование нейронной сети

Для построения нейронной сети было необходимо определить структуру персептрона: количество входных и выходных параметров, количество скрытых слоев и количество нейронов на каждом из них и активационные функции скрытых нейронов. В итоге количество входных нейронов равнялось 9, выходных – 1. Количество нейронов в скрытом слое равнялось 2.

Экспериментальным путем установлено, что при двух нейронах в скрытом слое погрешность нейросети минимальна. В качестве алгоритма обучения был выбран «Алгоритм упругого распространения», а в качестве функции активации «Тангенс гиперболический».

Гистограмма распределения значимости входных параметров, определенная с помощью нейропакета [7], представлена на рис. 1.

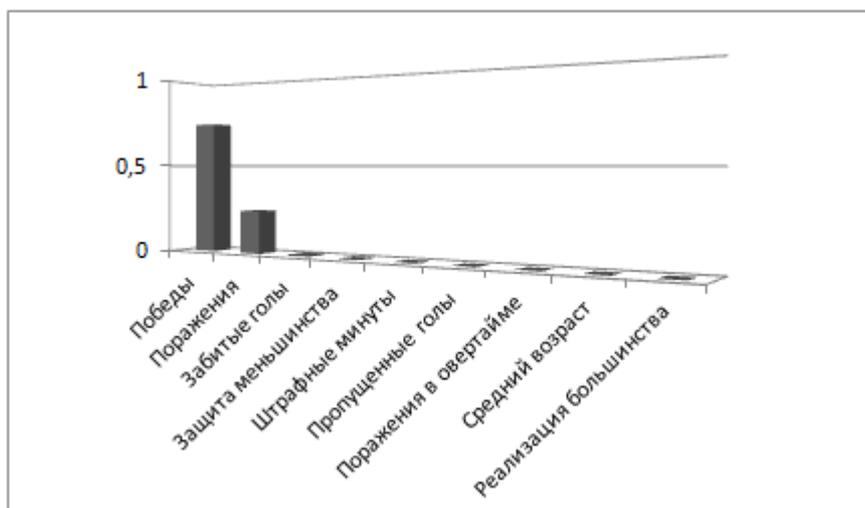


Рисунок 12. Оценка степени влияния параметров команд на их результаты в НХЛ

Согласно [8], нейронные сети путем проведения виртуальных компьютерных экспериментов могут быть использованы как инструмент для получения новых знаний. Результаты виртуальных компьютерных экспериментов представлены на рис. 2, 3. Здесь представлены графики зависимости результата (места) от изменения самых значимых параметров: количество побед и количество поражений.

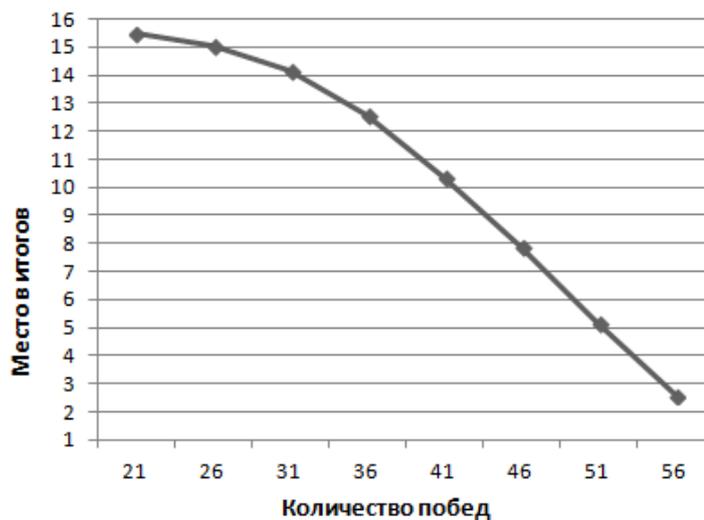


Рисунок 13. Зависимость места от количества побед

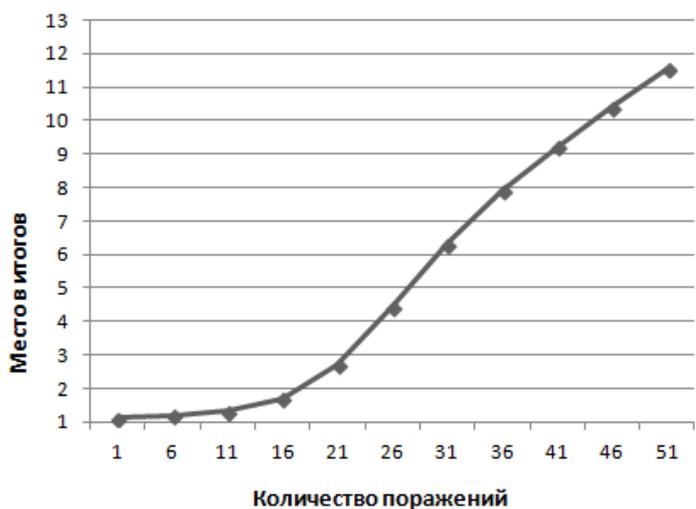


Рисунок 14. Зависимость места от количества проигрышей

Таким образом, основное значение имеют данные о выигрышах и проигрышах, значимостью остальных параметров можно было пренебречь. Ниже представлена числовая таблица с сопоставлением параметров и их значимости:

Таблица 4. Значимость параметров

Параметр	Значимость
Победы	0,744175034
Поражения	0,241058766
Забитые голы	0,007251051
Защита меньшинства	0,002950394
Штрафные минуты	0,00160996
Пропущенные голы	0,001514378

Поражения в овертайме	0,000878769
Средний возраст	0,000427847
Реализация большинства	0,000133801

После обучения сети мы получили следующие результаты (рисунок 4):

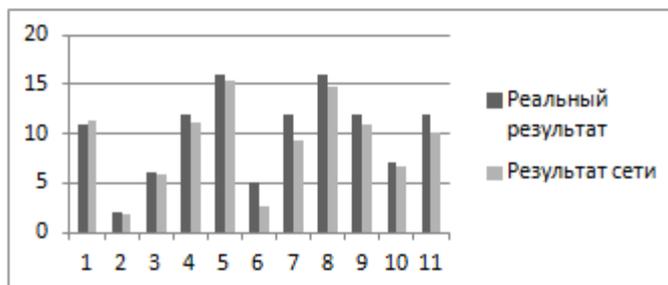


Рисунок 15. Результаты обучения сети

Построенная сеть показала следующие проценты ошибок: 1,5% на обучающем, 6,2% на тестовом и 9,5% на проверяющем.

Прогноз с помощью нейронной сети

Целью построения нейросетевой модели является возможность спрогнозировать результат команд в рамках НХЛ для сезона 2016-2017, половину которого прошло на момент написания работы.

На рис. 5 представлены результаты прогнозов на сезон 2016-2017 года.

Как оказалось, разница между реальными результатами и результатами, полученными сетью варьировалась от 0,09 до 10,0087, что безусловно являлось не самым лучшим результатом, несмотря на то что разница 10,0087 – единичный случай. В основном разница оставалась в пределах 3 единиц.

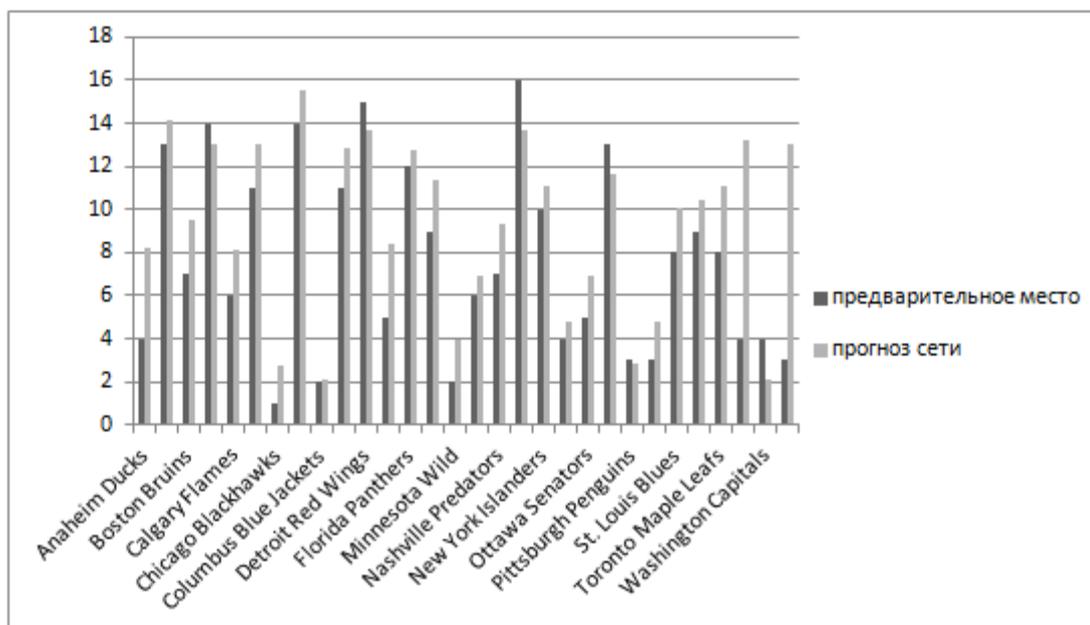


Рисунок 16. Сравнение результатов прогноза, полученных сетью, с реальными результатами

Заключение

Таким образом, была построена нейронная сеть, основанная на результатах НХЛ за последние пять лет. Построенная сеть показала следующие проценты ошибок: 1,5% на обучающем, 6,2% на тестовом и 9,5% на проверяющем. В процессе прогнозирования, сеть в большинстве случаев предсказывала результаты близкие к реальности, однако в отношении двух команд (Vancouver Canucks, Winnipeg Jets) наблюдались значительные выбросы.

Библиографический список

1. Ясницкий Л.Н., Абрамова Ю.С., Бабушкина С.Д. Возможности получения рекомендаций по улучшению результативности сборных команд, готовящихся к участию в чемпионате Европы по футболу Евро-2016 методом нейросетевого моделирования // Вестник спортивной науки. № 5. 2015. С. 15-20.
2. Ясницкий Л.Н., Киросова А.В., Ратегова А.В., Черепанов Ф.М. Методика прогнозирования результатов спортивных состязаний на примере чемпионата мира-2015 по легкой атлетике // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2014. № 3. С. 90-97.
3. Сайт статистики НХЛ [Электронный ресурс][Режим доступа: <http://stats.nhlnumbers.com/teams>] [Проверено: 20.03.2017]]
4. Сайт статистики НХЛ [Электронный ресурс][Режим доступа: <http://www.nhl.com/stats/team?aggregate=0&gameType=2&report=teamssummary&reportType=season&seasonFrom=20162017&seasonTo=20162017&filter=gamesPlayed,gte,1&sort=points,wins>] [Проверено: 20.03.2017]]

5. Ясницкий Л.Н. Искусственный интеллект. Элективный курс. Москва, 2012.
6. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
7. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014 г.
8. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56.

FORECASTING THE VOLUME OF JUICE SALES IN THE PRODUCT RETAIL NETWORK BY MEANS OF NEURAL NETWORKS

Mamaeva Veronika S.

National Research University Higher School of Economics, 38 Studenchskaya st., Perm, 614070,
Russia, veronikamamaewa@yandex.ru

Filipson Sofiya K.

National Research University Higher School of Economics, 38 Studenchskaya st., Perm, 614070,
Russia, lyubov.filipson@inbox.ru

The article describes the results derived from creating an neural network in order to get the forecast for NHL 2016-2017. The neural network was created with the help of "Neuro-simulator 5.0" neural network designer. The network is based on data from official statistics website got for the recent 5 years. In this paper the factors influencing the result are depicted. The paper includes the reasons why such factors were chosen. As the NHL has already started the data got from analysis is tested and comparison analysis is carried out.

Keywords: artificial intelligence, neural network, forecast, hockey, rates.

УДК 336.563.1

НЕЙРОСЕТЕВОЙ МЕТОД ЭФФЕКТИВНОСТИ БЮДЖЕТНОГО СУБСИДИРОВАНИЯ ПРИ ВНЕДРЕНИИ ВСЕРОССИЙСКОГО КОМПЛЕКСА ГТО³²

Бирюков Александр Николаевич

Стерлитамакский филиал Башкирский государственный университет, 453103, Россия,
Республика Башкортостан, 453103, РБ, г. Стерлитамак, проспект Ленина, 49,
biryukov_str@mail.ru

Глущенко Ольга Ивановна

Стерлитамакский институт физической культуры (филиал) Уральского государственного университета физической культуры, 453104, Россия, Республика Башкортостан, г. Стерлитамак, ул. Кочетова, д. 26 б, olga.glushhenko@mail.ru

Вопросы формирования ценностей здорового образа жизни, повышения общего уровня здоровья подрастающего поколения являются в настоящее время одними из главных национальных приоритетов Российской Федерации (РФ), определенными Стратегией развития физической культуры и спорта в РФ до 2020 года. В рамках данной Стратегии в РФ

³² ©Бирюков А.Н., Глущенко О.И., 2017

возрождается Всероссийский физкультурно-спортивный комплекс «Готов к труду и обороне» (ГТО)». Немаловажным является вопрос финансирования комплекса ГТО на всех трёх этапах, учитывая сложную экономическую ситуацию в РФ. Предлагается экономическая методика на внесение элемента объективности в процедуру принятия решений по планированию объёма финансирования бюджетополучателям субсидий на комплекс ГТО. Нейросетевая модель является и служит механизмом извлечения новых знаний о закономерностях «вход-выход», скрытых в базе данных при софинансировании расходных обязательств субъектов РФ для комплекса ГТО.

Ключевые слова: комплекс ГТО, центры тестирования, субсидии, нейросетевая модель (НСМ), «оздоровительно-рекреативной функции» (ОРФ).

На Западе уже около десятка лет нейронные сети применяются для прогнозирования спортивных событий, правда, с переменным успехом. Сегодня технология нейронных сетей ещё слишком малоизвестна в широких кругах. Она обросла множеством мифов и домыслов, поэтому восторженные отзывы соседствуют с самым свирепым скептицизмом.

Утверждать нормативы комплекса ГТО по трем уровням сложности поручено Министерству спорта Российской Федерации. Фиксироваться результаты сдачи комплекса ГТО гражданами, будут в специальной учетной карточке. Пройти тестирование по требованиям комплекса ГТО можно будет в некоммерческих центрах тестирования, которые созданы муниципалитетами.

Правительство РФ утвердило «Правила предоставления российским регионам субсидий на поэтапное внедрение комплекса ГТО» [1], определена сумма финансирования комплекса ГТО. Размер конкретной, перечисляемой субъекту Федерации субсидии, будет определяться исходя из стоимости одного комплекта оборудования и инвентаря для ГТО (573 тыс. рублей), количества созданных центров тестирования и уровня софинансирования расходного обязательства субъекта Федерации.

Субсидии предоставляются в целях софинансирования расходных обязательств субъектов РФ, осуществляющих мероприятия по тестированию в рамках комплекса ГТО на приобретение оборудования и инвентаря для оснащения центров тестирования по выполнению видов испытаний (тестов), нормативов, требований к оценке уровня знаний и умений для успешной сдачи нормативов комплекса ГТО.

Критерием отбора для предоставления субсидии является наличие у субъекта РФ опыта тестирования физической подготовленности населения для сдачи норм комплекса ГТО.

Оценка эффективности расходов бюджетов субъектов РФ, источником финансового обеспечения которых являются субсидии, осуществляется Министерством спорта РФ исходя из показателей, установленных соглашениями. Показателем результативности

предоставления субсидии является доля граждан (всех возрастных категорий), выполнивших нормативы Всероссийского физкультурно-спортивного комплекса «ГТО», в общей численности населения, принявшего участие в выполнении нормативов ГТО.

В Стратегии развития физической культуры и спорта в РФ показатель результативности – это число российских граждан, систематически занимающихся физической культурой и спортом, который в 2012 году составлял 22,5%. К 2020 году предполагается возможность его увеличения до 40%, из них показатель числа лиц с ограниченными физическими возможностями до 20%, показатель числа обучающихся – до 80 %.

Нами предлагается исследовать сложную (трудноформализуемую) социально-экономическую систему «государство - региональные структуры (бюджетополучатели) – центры тестирования ГТО в муниципалитетах» для разработки экономической методики принятия решений по повышению эффективности финансирования комплекса ГТО. Для конкретизации и лучшего понимания существа предлагаемой идеи, изложение ведётся на конкретном примере бюджетополучателей (получение субсидий на комплекс ГТО) – субъектами Российской Федерации. Однако суть методики не меняется и для муниципальных центров тестирования ГТО – спортивно-физкультурной и физкультурно-образовательной направленности.

Основная идея предлагаемой экономической методики направлена на внесение элемента объективности в процедуру принятия решений по планированию объёма финансирования бюджетополучателям субсидий на комплекс ГТО, с одной стороны, и повышения *гомеостаза* системы комплекса ГТО на последующие годы.

Элемент объективности заключается в том, что в объёме S_i планируемого на последующий год субсидирования на комплекс ГТО i -ой структуры (регион-муниципалитет) выделяется независимая часть S_{i0} , равная объёму финансирования в прошлом году, и некоторый фонд развития S_{ip} :

$$S_{ip} = S_i - S_{i0}, \quad (1)$$

При этом составляющая S_{i0} обусловлена выполнением закона гомеостаза, а составляющая S_{ip} характеризует стратегию спортивно-оздоровительного развития данной структуры, взаимосвязана с показателями качества работы бюджетополучателя субсидий на комплекс ГТО в прошлом году и предопределяет эти показатели в планируемом периоде.

В рассматриваемой экономической методике предлагается составляющую фонда развития S_{ip} формировать как некоторую стохастическую усреднённую функцию ряда

показателей x_j «оздоровительно-рекреативной функции» (ОРФ) деятельности кластера достаточно однородных муниципальных структур, например, определённых центров тестирования ГТО в муниципалитетах:

$$Y = \hat{S}_p = f\left(\vec{x}\right); \quad \left(x = x_1, x_2, \dots, x_{j, \dots}, \dots, x_n\right), \quad (2)$$

Сделаем замечания по экономической и математической природе функции \hat{S}_p . Она имеет смысл аналога усреднённой по базе данных для множества бюджетополучателей спортивных объектов (теперь «центров тестирования ГТО») за период наблюдения $T=[t_1, t_N]$ (обычно 2...5 лет) «оздоровительно-рекреативной функции». Роль обобщённого «продукта» на выходе моделируемой системы финансирования бюджетополучателей субсидий на ГТО, играют удельные фактические расходы на одного обсуживаемого субъекта (гражданина) при подготовке и сдаче норм комплекса ГТО.

Чем выше этот показатель, тем лучше качество процесса сдачи норм комплекса ГТО (выше оплата труда работников центров тестирования ГТО и, соответственно, их профессиональная квалификация, лучше качество спортивных сооружений и инвентаря, выше обеспеченность спортивными площадями, выше качество медицинского обеспечения и т.д.).

Роль «оздоровительно-рекреативных входных факторов» играют группы (блоки) ресурсных, расходных, социальных, спортивных факторов, а также факторы внешней экономической среды и динамические переменные (время t и так называемые «*лаговые переменные*» [3, С.79-82], отражающие предысторию динамического процесса).

Теперь остановимся на математической природе «оздоровительно-рекреативной функции» \hat{S}_p . Предлагается получать эту функцию как нейросетевую аппроксимацию [4]

условного математического ожидания $M\left[S_p \mid \vec{x} = \vec{x}_0\right]$ случайной величины S_p при условии,

что вектор входных (объясняющих) переменных принял конкретное значение \vec{x}_0 :

$$\hat{S}_p = M\left[S_p \mid \vec{x} = \vec{x}_0\right] \rightarrow F\left(\vec{x}, W\right) + \ell, \quad (3)$$

Здесь $M[\cdot]$ – оператор вычисления математического ожидания случайной величины S_p ; $F(\cdot)$ – оператор нейросетевого отображения, который будучи реализован программно, позволяет по известному значению \vec{x}_0 вектора объясняющих переменных на входе

нейросети (НС) вычислять значение \hat{S}_p на её выходе; W – матрица так называемых «синаптических весов» или параметров нейросетевой модели; W находит сама НС при её обучении на множестве примеров из базы данных; т.е. e – случайная ошибка расчёта \hat{S}_p в НС; крышечка сверху « \wedge » означает, что это приближённая (расчётная) оценка случайной величины S_p , которая может принимать любые значения в срезе $\vec{x} = \vec{x}_0$, т.е. аппроксимируется по существу некоторая трубка в $(n+1)$ -мерном пространстве; стрелка « \rightarrow » заменяет слова «оценивается» (в смысле выборочной статистической оценки).

Таким образом, можно отметить пять главных экономико-математических особенностей «оздоровительно-рекреативной функции» (ОРФ) $\hat{S}_p(\vec{x})$ по (3):

- эта функция может служить объективной мерой качества спортивно-оздоровительной деятельности данного i -го бюджетополучателя субсидий на комплекс ГТО, характеризующегося конкретными значениями \vec{x}_{i0} объясняющих переменных, поскольку аппроксимация (3) строится на реальной базе данных и при обучении НС данные разных бюджетополучателей (центров тестирования ГТО) сопоставляются между собой;

- аппроксимацию (3) следует понимать в среднем, т.е. она справедлива только для той базы данных, для которой проводилось обучение НС и расчётные значения $\hat{S}_p(\vec{x}, W)$ находятся в трубке (имеют случайный разброс за счёт величины ℓ в (3)) при фиксированном срезе $\vec{x} = \vec{x}_0$;

- поскольку параметры НС получаются самой НС при её обучении, аппроксимация (3) представляет собой адаптированную обучаемую математико-информационную модель процесса деятельности совокупности бюджетополучателей субсидий на комплекс ГТО, эта нейросетевая модель (НСМ) является и служит механизмом извлечения новых знаний о закономерностях «вход-выход», скрытых в базе данных;

- НСМ является эффективным инструментарием построения математических моделей по планированию объёма финансирования бюджетополучателей субсидий на комплекс ГТО, где при отмеченных сложных условиях моделирования применение традиционных методов регрессивного анализа (3) весьма проблематично;

- на основе «оздоровительно-рекреативной функции» (ОРФ) (3) можно увеличить объективность принятия решения для реализации экономической методики повышения эффективности финансирования комплекса ГТО в муниципалитетах РФ.

Библиографический список

1. Постановление Правительства Российской Федерации от 26 декабря 2014 г. N 1533 г. Москва "Об утверждении Правил предоставления субсидий из федерального бюджета бюджетам субъектов Российской Федерации на реализацию мероприятий по поэтапному внедрению Всероссийского физкультурно-спортивного комплекса "Готов к труду и обороне" (ГТО) в рамках подпрограммы "Развитие физической культуры и массового спорта" государственной программы Российской Федерации "Развитие физической культуры и спорта". **Опубликовано:** 31 декабря 2014 г. на Интернет-портале "Российской Газеты".
2. *Бирюков А.Н., Глущенко О.И.* Моделирование бюджетных процессов на муниципальном уровне на основе нейросетей/ Гатауллин Р.Ф., Горбатков С.А.// – Уфа: Издательство «Восточный университет», 2008. – 216 с.
3. *Айвазян С.А., Мхкаторян В.С.* Прикладная статистика и основы эконометрики/ Учебник для вузов// – М.: Юнити, 2008. – С. 79-82.
4. *Бирюков А.Н.* Бюджетно - налоговое администрирование: нейросетевые методы исследований – Стерлитамак: РИО СФ БашГУ, 2014.- 152 с.

NEURAL NETWORK METHOD THE EFFICIENCY OF BUDGET SUBSIDIES IN THE IMPLEMENTATION OF THE ALL-RUSSIAN COMPLEX TRP

Biryukov Alexander

Sterlitamak branch of the Bashkir state University, 453103,Russia, Respublika Bashkortostan, 453103, Bashkortostan, Sterlitamak, Lenin prospect, 49, biryukov_str@mail.ru

Glushchenko Olga

Sterlitamak Institute of physical culture (branch) Ural state University of physical culture, 453104,Russia, Respublika Bashkortostan, Sterlitamak, ul Kochetova, d. 26 b,

olga.glushhenko@mail.ru

Issues of formation of healthy lifestyle, enhance the overall level of health of the younger generation are now among the main national priorities of the Russian Federation (RF), defined by Strategy of development of physical culture and sports in Russia until 2020. In the framework of this Strategy in Russia is reviving the all-Russian sports complex "Ready for labor and defense" (TRP)". Also important is the issue of funding of the TRP at all three stages, given the difficult economic situation in Russia. Proposed economic methodology to introduce element of objectivity to the decision-making process for planning funding to the budget subsidies for the TRP. Neural network model is a mechanism of extracting new knowledge about the patterns of "log out" is hidden in the database with the co-financing of expenditure obligations of constituent entities of the Russian Federation for the TRP.

Key words: TRP, testing centers, subsidies, neural network model (NSM), "health and recreational functions" (RUF).

ОЦЕНКА ПРОХОЖДЕНИЯ БАСКЕТБОЛЬНЫХ КОМАНД В ФИНАЛ НАЦИОНАЛЬНОЙ БАСКЕТБОЛЬНОЙ ЛИГИ МЕТОДОМ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ

Скворцов Роман Олегович.

Пермский государственный научно-исследовательский университет, 614990,
Россия, г. Пермь, ул. Букирева 15, goodlock01@yandex.ru

В статье представлено описание разработки и применения нейросетевой модели для оценки попадания команд в финал Национальной Баскетбольной Ассоциации (НБА). Нейросети используются довольно часто для прогнозирования различных событий. Спортивная тематика - актуальна в наше время и многие букмекеры считают, что спрогнозировать победы в командных видах спорта практически невозможно. Однако, целью проекта было создание нейросетевой модели, которая опровергнет мнения букмекеров. Для работы было выявлено десять наиболее важных параметров, от которых зависит поведение команд в плей-офф, а именно какое количество раундов пройдет команда. Модель реализована в виде компьютерной программы, которая позволяет выявлять закономерности разного рода: зависимость прохождения раундов в плей-офф от попадания с трехочковой линии, положения в турнирной таблице по итогам сезона и др. Данная модель может быть интересна любителям баскетбола для предугадывания матчей, а также тренерам баскетбольных команд, которым будет интересно, в какое направление стоит развивать баскетболистов, какие навыки более полезные и какие схемы нападения и обороны лучше использовать.

Ключевые слова: искусственный интеллект, нейросетевые технологии, Национальная Баскетбольная Ассоциация (НБА), оценка побед, прогнозирование.

Об истории НБА: Национальная Баскетбольная Ассоциация появилась в 1968 году, благодаря слиянию двух баскетбольных лиг БАА и АБА [1]. Каждый год баскетбол поражает своей интригой и непредсказуемостью. Этот год не исключение, никто не ожидал такого поворота событий, но все оказалось именно так. Изначальная поставленная цель была определение победителя НБА, но пришлось поменять тематику на более простую, так как в данной баскетбольной лиге есть разделение на конференции, причем не всегда равные. А это означает, что в Финал НБА не обязательно выходят две сильные команды. Поэтому было решено определить победителя Конференций. Существует 2 конференции: Западная и Восточная. Победители конференций получают право бороться за титул лучшей командой НБА и всего мира. Поэтому всегда интересно, какие же команды выйдут в финал.

Как показано в работах [2, 3], перспективным инструментом прогнозирования результатов спортивных состязаний являются нейронные сети. При формировании статистических множеств для обучения нейронных сетей были использованы данные о командах, которые вышли в плей-офф за последние 3 года [4]. Проектирование нейронной

сети и эксперименты с нейросетевой моделью осуществлялись по методике [5, 6] в нейропакете [7].

В баскетболе главное – количество владений и точность. Проанализировав баскетбольные параметры были выявлены основные и вспомогательные входные параметры. Для создания эффективной нейросети была использована функция гиперболического тангенса.

Всего было выделено 10 входных параметров:

X1 – место среди команд, находящихся в плей-офф (от 1 до 8)

X2 – разница в очках в среднем за игру

X3 – вероятность попадания в двухочковой зоне (от 0 до 1)

X4 – вероятность попадания с трехочковой линии (от 0 до 1)

X5 – количество подборов за игру

X6 – количество перехватов за игру

X7 – количество потерь за игру

X8 – количество фолов за игру

X9 – средний возраст игроков перед плей-офф

X10 – место в конференции (от 1 до 8)

Для обучения было сформировано 48 примеров команд за 3 года [4]. Тестовое множество состоит из 7 примеров, часть из которых только недавно появились. Выходной параметр кодирует значение от 1 до 4, где 1 – участвовал только в 1 раунде, 2 – прошел первый и участвовал во втором, 3 – прошел до финала конференции, но проиграл, и 4 – прошел до финала и стал победителем конференции.

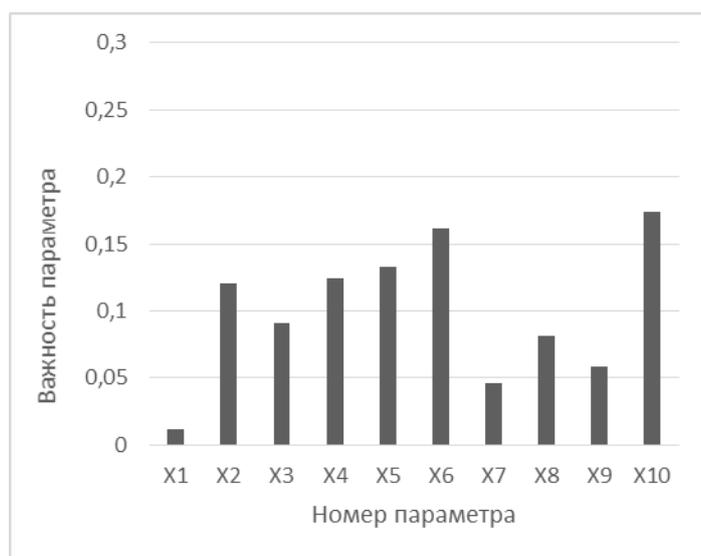


Рисунок 1 – Значимость вводимых параметров

Заметим, что параметр X10 (Место в конференции) оказывает наибольшее влияние среди всех остальных параметров, однако X6 (количество перехватов за игру) и X5 (количество подборов за игру) тоже оказывают достаточно большое влияние. Меньше всего оказывает влияние X1 (место среди команд в плей-офф)

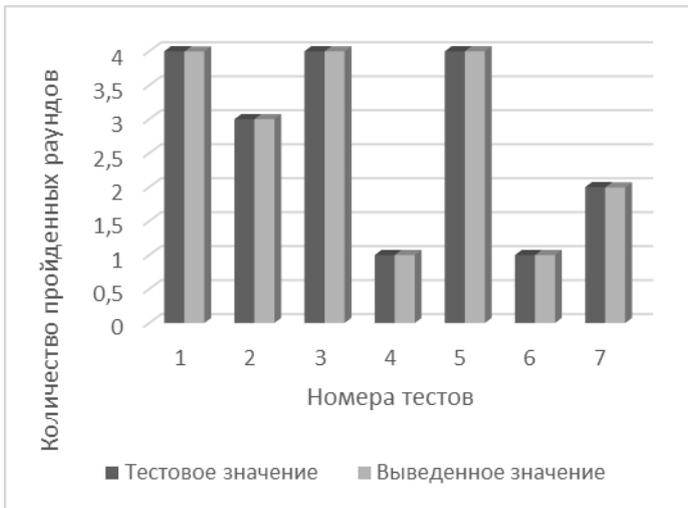


Рисунок 2 – Сравнение предполагаемых параметров с действительными

Если внимательно взглянуть на гистограмму, то можно заметить, что тестовые параметры практически не отличаются от действительных. Дело в том, что полученная ошибка обучения (0.62%) и ошибка тестирования (0.06%)

были минимальны.

Рисунок 3 – Зависимость победы в конференции от вероятности реализации трехочкового броска

Было проведено исследование, показывающее, как изменяется количество пройденных раундов от каких-либо испытаний, к примеру, от вероятности реализации трехочкового броска (рис. 3). На диаграмме видно, что чем выше реализация, тем больше шанс попадания в финал.

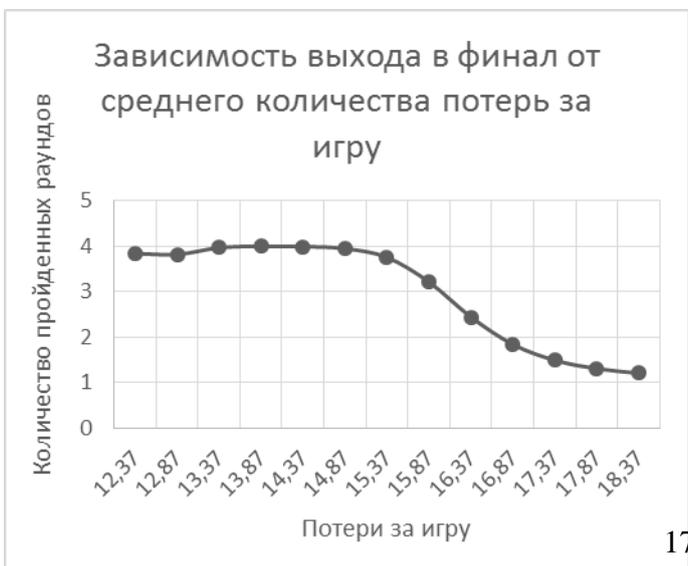
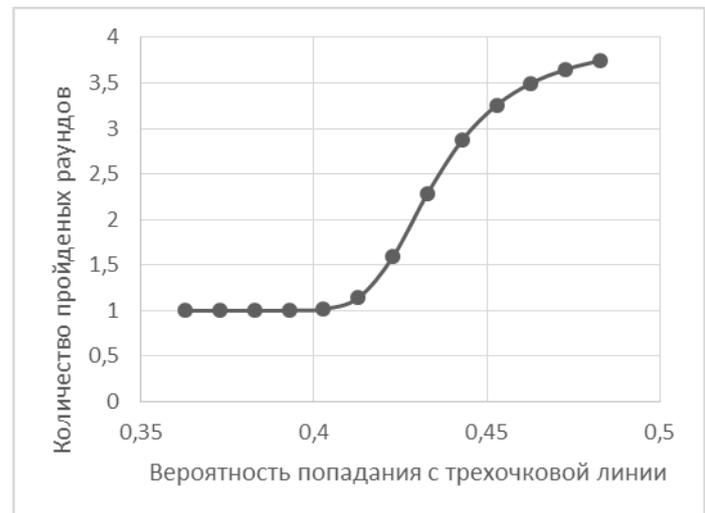


Рисунок 4 – Зависимость победы в конференции от среднего количества потерь за игру

Далее было проведено исследование на зависимость побед от среднего количества потерь. Из графика замечено, что только в промежутке от 13 до 15 потерь за игру шансы на выход в финал НБА максимальные.

В заключении можно отметить, что построенная математическая модель работает верно и предсказывает результат правильно. Данная математическая модель позволяет определить финалистов НБА и рассчитывать примерные значения вероятностей прохождения игроками в тот или иной раунд.

Библиографический список

1. www.nba.com – сайт с положениями команд.
2. Ясницкий Л.Н., Киросова А.В., Ратегова А.В., Черепанов Ф.М. Методика прогнозирования результатов спортивных состязаний на примере чемпионата мира-2015 по легкой атлетике // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2014. № 3. С. 90-97.
3. Ясницкий Л.Н., Абрамова Ю.С., Бабушкина С.Д. Возможности получения рекомендаций по улучшению результативности сборных команд, готовящихся к участию в чемпионате Европы по футболу Евро-2016 методом нейросетевого моделирования // Вестник спортивной науки. № 5. 2015. С. 15-20.
4. www.basketball-reference.com – база данных НБА.
5. Ясницкий, Л. Н. Интеллектуальные информационные технологии и системы. Пермь: Пермский университет, 2007. 271с.
6. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56.
7. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.

ASSESSMENT OF PASSAGE BASKETBALL TEAM IN THE NATIONAL BASKETBALL ASSOCIATION FINAL BY NEURAL NETWORK MODELING

Skvortsov R.O.

Perm State University Research, 614990, Russia, Perm, ul. Bukireva 15,
goodlock01@yandex.ru

The article describes the development and application of neural network model to evaluate the hitting teams in the finals of the National Basketball Association (NBA). Neural networks used quite often to predict the various events. Sport theme - is relevant in our time, and many bookmakers consider that predict victory in team sports is almost impossible. However, the aim of the project was to create a neural network model, which refute the views of bookmakers. For it was revealed the ten most important parameters that determine the behavior of the teams in the playoffs, namely how many rounds will take place team. The model implemented in the form of a computer program that allows you to identify patterns of various kinds. Dependence

passing rounds in the playoffs by getting a three-point line, position in the standings at the end of the season, etc. This model can be interesting to fans of basketball for the prediction matches, as well as basketball coach, who would be interested in that direction is to develop players, that skills are more useful, and schemes of attack and defense is better to use.

Keywords: artificial intelligence, neural network technology, National Basketball Association, assessment of winners, prediction.

УДК 004.032.26; 796.92.093.642

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ СТАТИСТИКИ СТРЕЛЬБЫ В СОРЕВНОВАНИЯХ ПО БИАТЛОНУ

Зеленский Алексей Валерьевич

Смоленская государственная академия физической культуры, спорта и туризма, 214018, г. Смоленск, пр. Гагарина, 23, biatlon.05@mail.ru.

Лесникова Юлия Юрьевна

Пермский государственный научно-исследовательский университет, 614990, г. Пермь, ул. Букирева, 15, tselisheva.yulia@yandex.ru.

Работа посвящена прогнозированию успешности выступления на соревнованиях спортсменов-биатлонистов. Одним из наиболее важных показателей успешности выступления является статистика стрельбы. Существует два положения стрельбы: стоя и лежа. В данной работе рассматривается статистика стрельбы стоя.

Ключевые слова: нейросетевое моделирование, искусственный интеллект, биатлон.

Введение

Нейросетевое моделирование все чаще находит применение во многих областях науки и техники. Активное развитие данного метода делает возможным его применение в одной из наиболее сложных для моделирования областей — в спорте.

Предсказание претендентов на победу в чемпионате мира 2015 по легкой атлетике сделано в [1]. Статья [2] посвящена разработке рекомендаций по улучшению результативности футбольных команд с помощью нейронных сетей. Возможность использования карт Кохонена для моделирования тренировочного процесса биатлонистов была показана в [3]. Приемы игры в баскетбол, оказывающие наибольшее влияние на счет, определены в [4]. Выявление перспективных спортсменов для отбора в команды производится в статье [5].

Настоящая работа посвящена прогнозированию одного из показателей успешности выступления на соревнованиях по биатлону: статистики стрельбы стоя.

Построение нейронной сети

Начальный этап построения нейронной сети подразумевает выделение признаков, которые могли бы оказывать влияние на интересующий показатель. Предполагается, что статистика стрельбы биатлониста определяется следующими характеристиками спортсмена:

Параметр	Расшифровка	Значения
X1	Пол	0 — женский, 1 — мужской
X2	Месяц рождения	1 — январь, 2 — февраль, 3 — март и т.д.
X3	Возраст	Непрерывный параметр (количество полных лет)
X4	Округ (регион) рождения	1 — центральный, 2 — восточный, 3 — сибирский, 4 — северный
X5	Патология по медицинскому признаку	0 — отсутствие патологии, 1 — зрение, 2 — мышцы, 3 — костный аппарат, 4 — сердце, 5 — физическое развитие, 6 — энергетическое, 7 — позвоночник, 8 — психика, 9 — половое развитие
X6	Уровень знаний, оценки в школе	3 — удовлетворительно, 4 — хорошо, 5 — отлично
X7	Занималась ли мать спортом	0 — нет, 1 — да
X8	Занимался ли отец спортом	0 — нет, 1 — да
X9	Темперамент	1 — сангвиник, 2 — холерик, 3 — флегматик, 4 — меланхолик
X10	Тип личности	1 — экстраверт, 2 — интроверт, 3 — эмоционально стабильный, 4 — эмоционально неустойчивый
X11	Характер	0 — гипертимность, 1 — дистимность, 2 — застревание, 3 — тревожность, 4 — эмотивность, 5 — циклотимность, 6 — экзальтированность, 7 — педантичность
X12	Звание/разряд в текущем году	0 — кандидат в мастера спорта, 1 — первый взрослый разряд, 2 — мастер спорта
X13	RWC170 — функциональные данные по всем параметрам: вес, рост, время восстановления, работа на разных режимах	Непрерывный параметр (кг/м/мин)
X14	Максимальное потребление кислорода (МПК)	Непрерывный параметр (мл/кг/мин)
X15	МПК при пересчете на килограмм веса	Непрерывный параметр
X16	Гемоглобин	Непрерывный параметр (г/л)
X17	Рост	Непрерывный параметр (см)
X18	Вес	Непрерывный параметр (кг)
X19	Количество выстрелянных патронов за сезон	Непрерывный параметр (шт)

Параметр	Расшифровка	Значения
X20	Стрелковое годовое тестирование: 10 выстрелов в спокойном состоянии (лежа)	Непрерывный параметр (очки)
X21	Стрелковое годовое тестирование: 10 выстрелов в спокойном состоянии (стоя)	Непрерывный параметр (очки)
X22	Количество часов холостого тренажа в течение сезона	Непрерывный параметр (ч)
X23	Количество тренировочных дней за сезон	Непрерывный параметр (дн)
X24	Объем циклической работы за сезон (кросс, лыжи, бег, роллеры, велосипед)	Непрерывный параметр (км)
X25	Объем выполненной работы бег за сезон	Непрерывный параметр (км)
X26	Объем выполненной работы лыжи за сезон	Непрерывный параметр (км)
X27	PWC170kg — в пересчете на килограмм веса	Непрерывный параметр

Целевая переменная — статистика стрельбы стоя — показывает процент попаданий в мишень по отношению к общему количеству произведенных выстрелов, полученный за один соревновательный сезон:

Параметр	Расшифровка	Значения
D1	Статистика стрельбы стоя	Непрерывный параметр (%)

Моделирование осуществлялось с помощью нейросимулятора [6]. Набор данных содержит 28 колонок и 105 наблюдений. 105 наблюдений — это информация о 21 биатлонисте, полученная за 5 лет. 95 наблюдений будут использованы для обучения нейронной сети, а оставшиеся 10 наблюдений — для проверки построенной сети. Оптимальная структура нейронной сети: двадцать семь входных нейронов, по два нейрона на двух скрытых слоях, один выходной нейрон; алгоритм обучения — Левенберга-Марквардта, активационная функция — гиперболический тангенс. Ошибка сети на обучающем множестве составила 3,02%, а ошибка на тестирующем множестве — 16,91%. Соответствие между желаемыми значениями статистики стрельбы стоя и действительными, полученными в результате моделирования, представлено на рис. 1.

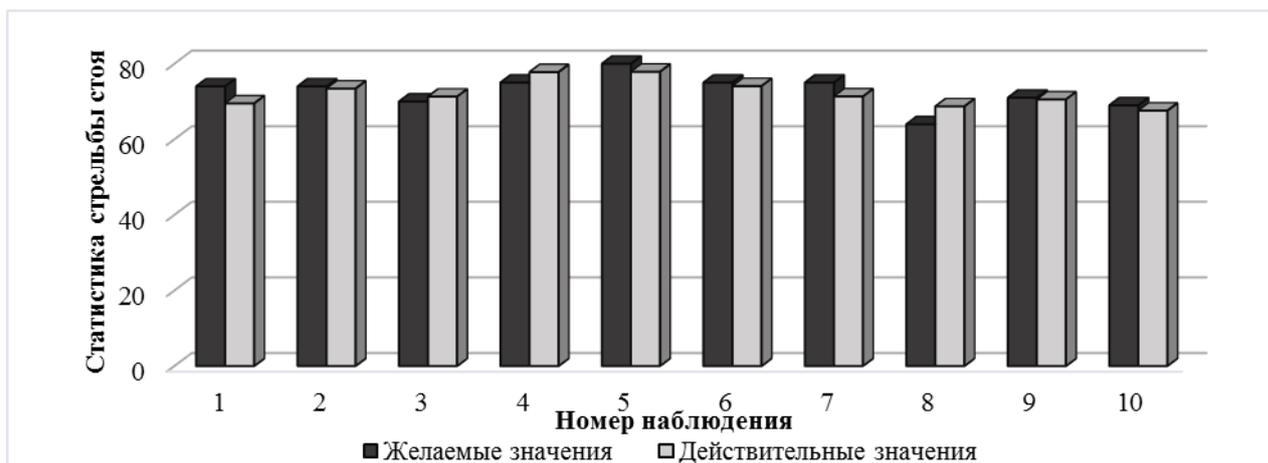


Рисунок 17. Гистограмма адекватности для статистики стрельбы стоя

С помощью нейронной сети [6] вычислена средняя значимость параметров, влияющих на статистику стрельбы стоя, и по полученным данным на рис. 2 построена гистограмма.

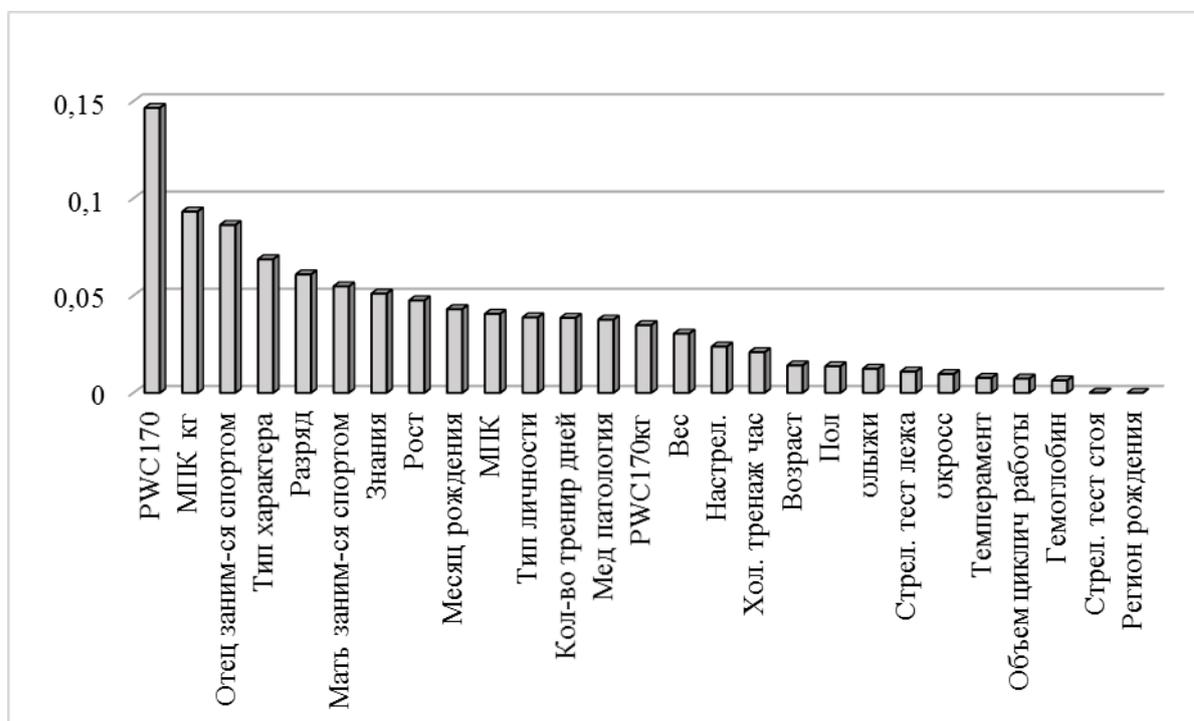


Рисунок 18. Значимость параметров оптимальной сети для статистики стрельбы стоя

Как видно из рис. 2, наибольшее влияние на статистику стрельбы стоя оказывают: PWC170, МПК на килограмм веса, занимается ли спортом отец спортсмена, тип характера и звание/разряд.

Анализ зависимости статистики стрельбы от наиболее значимых параметров

После того, как доказана адекватность нейросетевой математической модели, она может быть использована для получения полезных знаний путем проведения виртуальных компьютерных экспериментов [7]. С помощью нейросетевой модели могут быть получены

рекомендациям тренеру, например, на что стоит обратить внимание при организации тренировочного процесса. Необходимо иметь в виду, что ряд параметров не могут быть изменены спортсменом. Например, занятия спортом отца в большинстве случаев могут быть учтены только до начала тренировочного процесса, когда тренеру ничего не известно о потенциальном воспитаннике. На рис. 3 представлены результаты нейросетевого моделирования, позволяющие сделать вывод о том, что дети отцов, занимающихся спортом, имеют лучшую статистику стрельбы.

Прослежена динамика результатов спортсменов в зависимости от того, занимаются ли их отцы спортом.

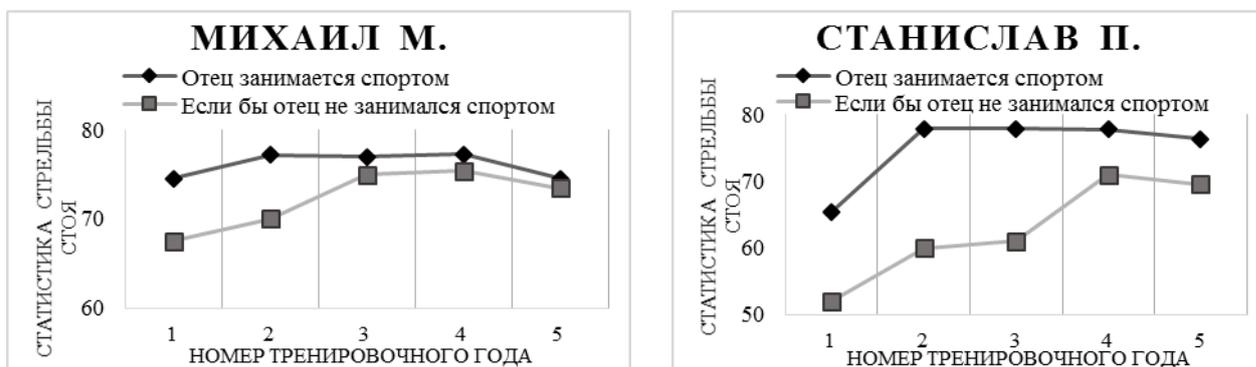


Рисунок. 3. Зависимости результативности спортсменов от номера тренировочного года и параметра «Занимается ли отец спортом»

Тип характера спортсмена так же, как параметр, обозначающий, занимается ли отец спортом или нет, не поддается корректировке: изменить характер спортсмена представляется практически невозможным. Зависимость между статистикой стрельбы и званием/разрядом достаточно очевидна: качество стрельбы играет значительную роль при выполнении более высокого разряда или при получении более высокого звания.

На рис. 4 представлено влияние значений параметров PWC170 и МПК на килограмм веса на статистику стрельбы стоя. Графики в первой колонке отражают зависимость статистики стрельбы от показателя PWC170, а графики во второй колонке — от показателя МПК на килограмм веса.

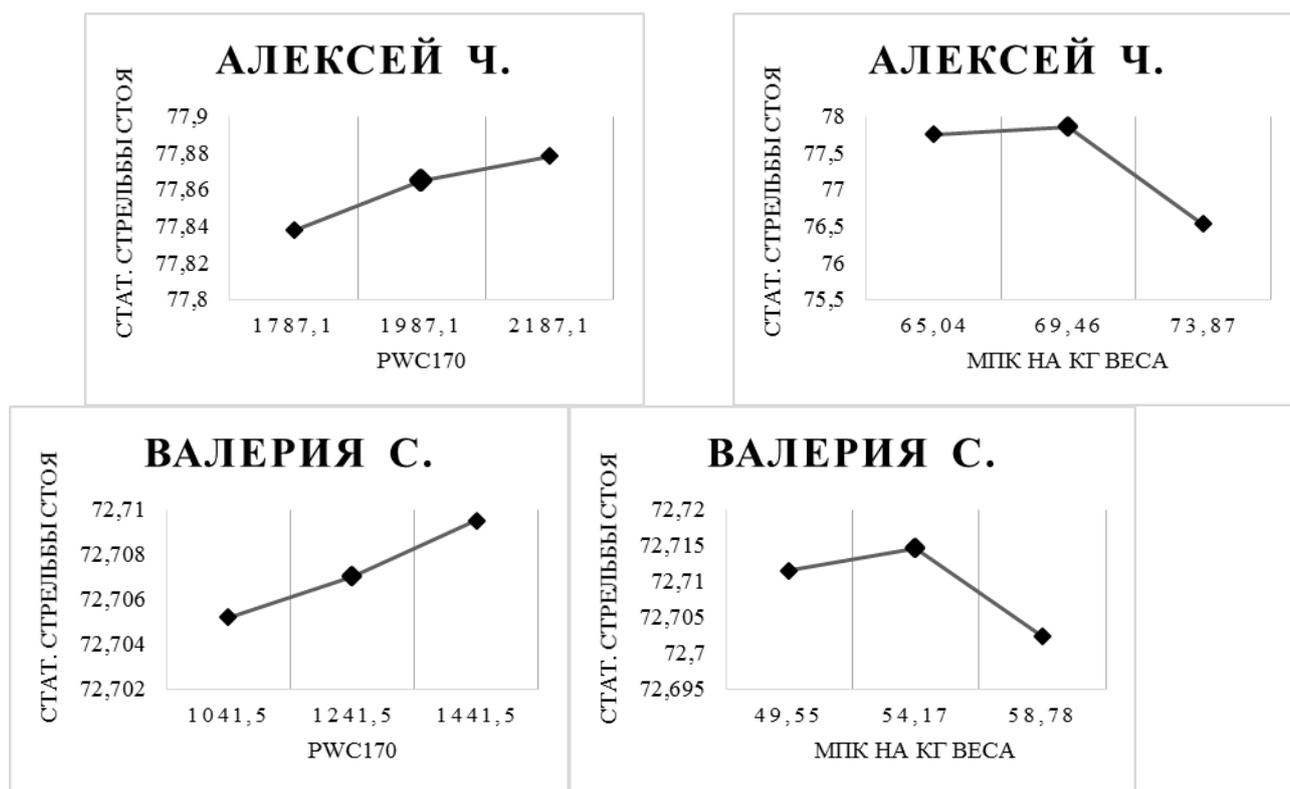


Рисунок 4. Зависимости результативности спортсменов от их параметров

Графики построены следующим образом. Взяты значения данных показателей некоторых спортсменов за последний год тренировок. Вычислены средние значения, на которые изменяются данные показатели за год тренировок (шаг) и получены величины статистики стрельбы для самих значений показателей и для двух значений, отличных от реальных значений показателей на шаг в меньшую и большую стороны.

Как видно из рис. 4, увеличение показателей РWC170 и МПК на килограмм веса, как правило, приводит к улучшению статистики стрельбы. Следовательно, тренеру лучше организовать тренировочный процесс таким образом, чтобы тренировки способствовали росту данных показателей.

Заключение

Создана нейросетевая математическая модель, предсказывающая статистику стрельбы биатлониста из положения стоя. Выявлены наиболее значимые характеристики спортсмена, оказывающие определяющее влияние на статистику стрельбы из положения стоя.

Библиографический список

1. Ясницкий Л.Н., Кирсова А.В., Ратегова А.В., Черепанов Ф.М. Методика прогнозирования результатов спортивных состязаний на примере чемпионата мира-2015 по легкой атлетике // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2014. № 3. С. 90-97.

2. Ясницкий Л.Н., Абрамова Ю.С., Бабушкина С.Д. Возможности получения рекомендаций по улучшению результативности сборных команд, готовящихся к участию в чемпионате Европы по футболу Евро-2016 методом нейросетевого моделирования // Вестник спортивной науки. № 5. 2015. С. 15-20.
3. Зеленский А.В., Зеленский А.В. Моделирование тренировочного процесса в биатлоне с помощью искусственного интеллекта // Ученые записки университета имени П.Ф. Лесгафта. – 2017. – №2(144); URL: <http://lesgaft-notes.spb.ru/ru/node/10050> (дата обращения: 12.04.2017).
4. Ivanković Z., Racković M., Markoski B., Radosav D., Ivković M. Applianse of Neural Networks in Basketball Scouting // Acta Polytechnica Hungarica. 2010. Vol. 7, No. 4. Pp. 167-180.
5. McCullagh J. Data Mining in Sport: A Neural Network Approach // International Journal of Sports Science and Engineering. 2010. Vol. 04. No. 03. Pp. 131-138.
6. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0. Свидетельство о государственной регистрации программы для ЭВМ № 2014618208. Заявка Роспатент № 2014614649. Зарегистрировано в Реестре программ для ЭВМ 12 августа 2014г.
7. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56.

NEURONETWORK FORECASTING OF THE SHOOTING STATISTICS IN THE BIATHLON COMPETITIONS

Zelenskiy Aleksey V.

Smolensk State Academy of Physical Training, Sports and Tourism, Gagarina Ave, 23, Smolensk, Russia, 214018, biatlon.05@mail.ru

Lesnikova Julie Y.

Perm State University, st. Bukireva, 15, Perm, Russia, 614990, tselisheva.yulia@yandex.ru

This article is devoted to the prediction of successfulness of the biathletes' performances in competitions. Shooting statistics is a key indicator of the successful performance. There are two positions to shoot from in biathlon competitions: prone position and standing position. The standing position is considered.

Key words: neural network, artificial intelligence, biathlon.

8. ИНТЕЛЛЕКТУАЛЬНЫЕ И ЭМОЦИОНАЛЬНЫЕ РОБОТЫ

СПЕЦИАЛЬНЫЙ АЛГОРИТМ БОТА-СОБЕСЕДНИКА

Левин Евгений Олегович, Кулик Сергей Дмитриевич

Национальный исследовательский ядерный университет «МИФИ», 115409, Россия, г. Москва, Каширское ш., 31, levin.inf@yandex.ru

В статье рассматривается алгоритм работы бота-собеседника, умеющего отвечать на запросы пользователя, вести с ним так называемую «светскую беседу». В алгоритме предусмотрена балансировка частоты выдачи одинаковых ответов, что позволяет разнообразить общение с ботом и сделать его более живым. Поддерживается голосовое управление: пользователь может посылать голосовые сообщения боту (бот вернет ответ также с помощью голосового сообщения). Для распознавания и синтеза речи используется Yandex SpeechKit Cloud — технология распознавания и синтеза речи компании Яндекс. В алгоритме реализована возможность самообучения бота — улучшение качества его ответов по мере его использования. Бот разработан для мессенджера Telegram, взаимодействие с которым происходит с помощью Telegram Bot API. Создан рабочий вариант программного средства бота, способной работать онлайн на устройствах с различными ОС.

Ключевые слова: чат-бот, тест Тьюринга, искусственный интеллект.

Люди ведут разговоры с раннего детства. Это часть нашей повседневной жизни, и смартфоны только помогают оставаться на связи со всеми знакомыми. Вполне естественно, что бизнес начинает интересоваться платформами, на которых пользователи проводят большую часть своего времени — мессенджерами. Это эффективнее, чем строить собственные экосистемы и пытаться заманивать клиентов. Это одна из причин, почему было принято решение создать чат-бота для популярного мессенджера, а не как полностью самостоятельный продукт.

Основной потенциал чат-ботов заключается в возможности более эффективно организовывать связь один-ко-многим. Сейчас существует много инструментов, которые помогают координировать подобное взаимодействие — от сервисов email-маркетинга до социальных медиа. Они позволяют захватить широкую аудиторию и таргетировать сообщение на конкретную группу пользователей. Однако по большей части эти инструменты не позволяют общаться с каждым клиентом индивидуально. До сих пор не существовало эффективных технологий, которые помогли бы одновременно охватывать большой объём аудитории и при этом находить к каждому пользователю индивидуальный подход. Поэтому чат-боты набирают все большую популярность в наше время [4].

В качестве платформы был выбран Telegram Messenger, в качестве языка программирования — Python. Для целенаправленной работы с Telegram Bot API

используется библиотека pyTelegramBotAPI. Также используется программа ffmpeg для перекодирования аудиофайла, которая необходима для распознавания речи.

Отметим, что в данной реализации не принималось попыток пытаться извлечь смысл сообщения, отправленного пользователем.

Разработанный алгоритм состоит из **двух** основных частей:

- Обучение бота — когда пользователь отправляет сообщение, которое понимается как ответ на предыдущее сообщение, сделанное чат-ботом. Предложение, введенное (напечатанное) человеком, будет связано со словами, присутствующими в предыдущем сообщении.
- Ответ бота — человеческое сообщение состоит из слов. Программа будет пытаться определить, какие предложения лучше соответствуют этим словам, в соответствии с его предыдущим "опытом".

На практике люди общаются не только с помощью письменного текста, но и с помощью устной речи. Поэтому разработанный бот умеет распознавать и синтезировать речь. Для этого использовалась технология Yandex SpeechKit Cloud. SpeechKit Cloud — это программа, которая открывает разработчикам доступ к технологиям распознавания и синтеза речи Яндекса, а также выделения смысловых объектов в произносимом тексте. Взаимодействие со SpeechKit Cloud идет через HTTP API [5].

SpeechKit Cloud решает задачу распознавания речи в два этапа. На первом этапе в аудио сигнале выделяются наборы звуков, которые могут быть интерпретированы как слова. Для каждого набора звуков обычно существует несколько вариантов слов — то есть несколько гипотез [5]. На втором этапе подключается языковая модель, которая позволяет проверить каждую гипотезу с точки зрения структуры языка и контекста — насколько данное слово согласуется со словами, распознанными ранее. Система распознавания проверяет гипотезы, пользуясь языковой моделью как словарем. Создание такого словаря — это сложная вычислительная задача, здесь используется машинное обучение нейронных сетей [5]. Синтез речи — это процесс генерирования речи согласно тексту. SpeechKit Cloud позволяет озвучить любой текст на русском или английском языке [5].

В обоих случаях на вход алгоритма обработки текста и генерации ответа поступает печатный текст. Ответ также будет текстовым, но, в случае, если пользователь посылает боту голосовой запрос, то программа выполнит синтез речи и озвучит текст.

Для реализации алгоритма необходима база данных, содержащая:

1. Словарный запас — массив использованных слов, который пополняется при каждом общении с ботом новых слов (табл. 1).

Таблица 1

Words

2. Таблица использованных предложений, состоящая из массивов предложений и количества их использования (табл. 2).

Таблица 2

Sentence	Used
----------	------

3. Таблица ассоциаций, состоящая из слов, предложений и весов, определяющих силу связи слова с данным предложением (табл. 3).

Таблица 3

Word_id	Sentence_id	Weight
---------	-------------	--------

4. Таблицу последних отправленных ботом сообщений, состоящую из самих предложений и id пользователя, которому это сообщение было отправлено. Это необходимо для правильной работы бота, так как с ним может общаться много разных людей (табл. 4).

Таблица 4

Chat_id	Last_message
---------	--------------

При получении запроса от пользователя программа обращается к базе данных и получает последнее сообщение от бота, отправленное этому пользователю.

Затем она разбивает полученное сообщение на отдельные слова, заносит предложение, отправленное пользователем, в БД и строит зависимости между предложением и словами.

После этого программа находит подходящие ответы в БД и выбирает наилучший из них.

Далее полученный ответ бота сохраняется в БД в соответствующем поле и посылается пользователю. После этого программа остается в ожидании других запросов пользователей.

Ниже представлена блок-схема (рис. 1) предложенного алгоритма, где для удобства понимания бот обозначается как “В”, а пользователь как “Н”.

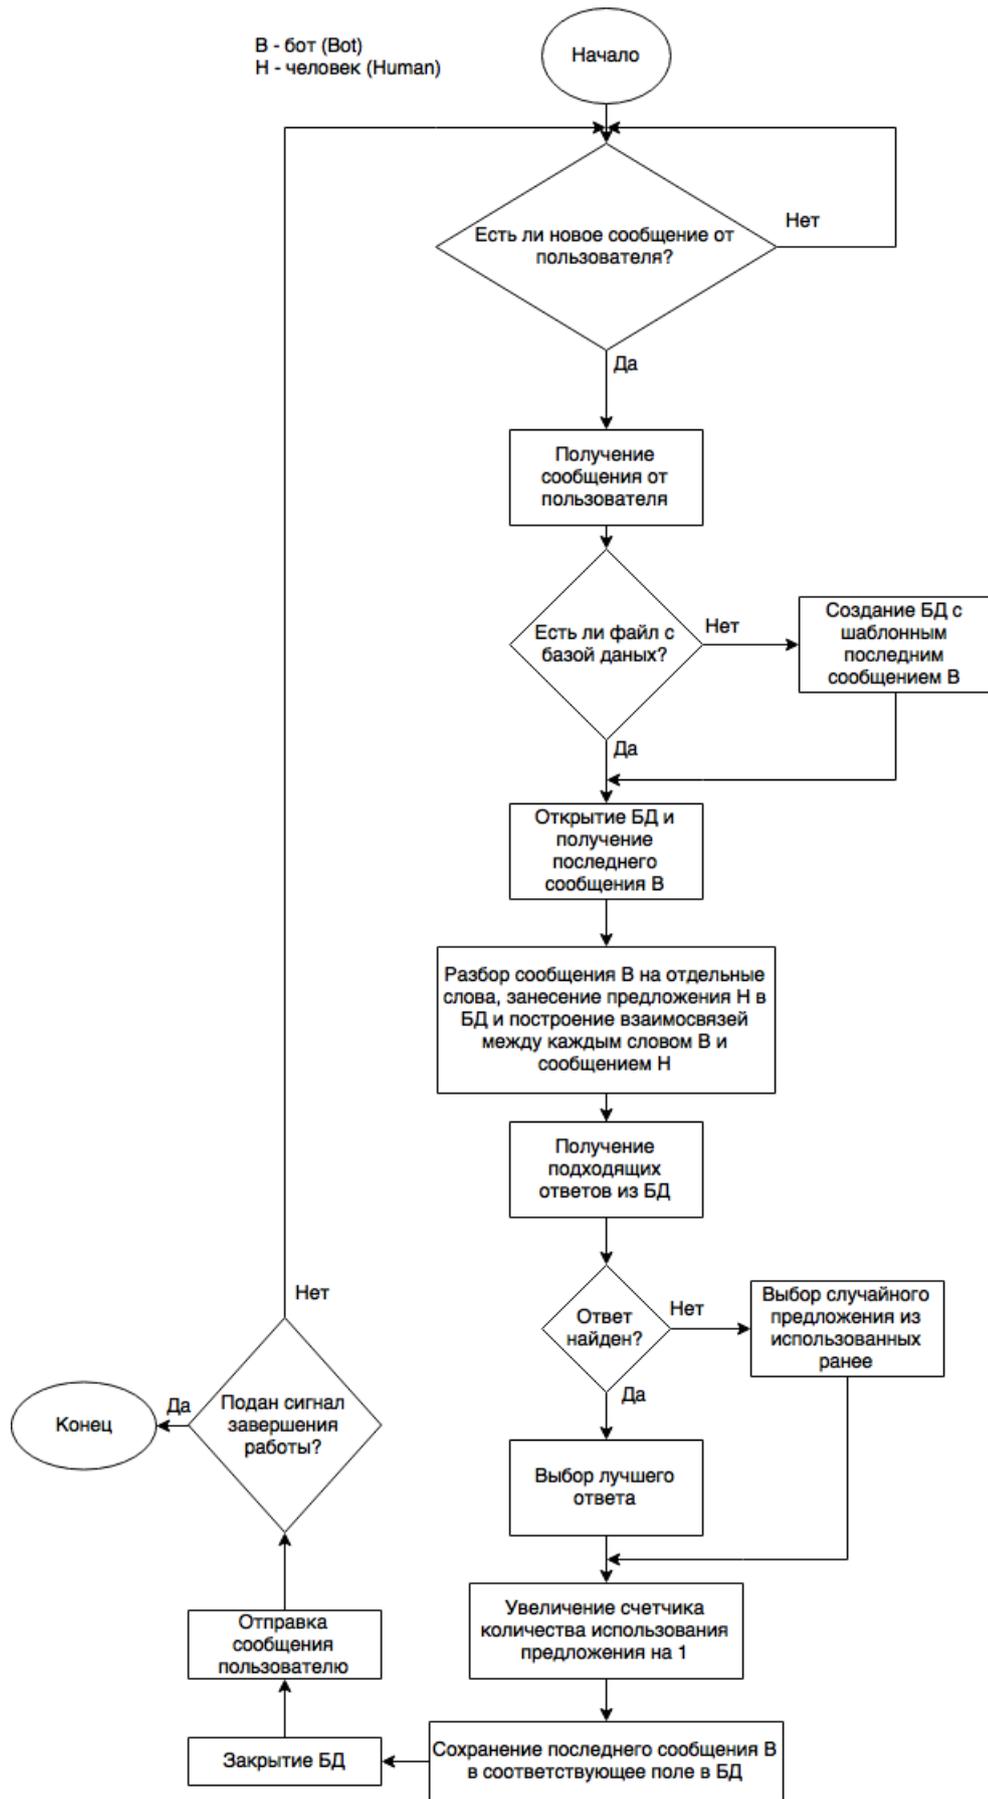


Рис. 1. Алгоритм работы бота

В настоящее время разработана достаточно упрощенная версия алгоритма, который не идеален. Созданный бот не может работать идеально и с высокой долей вероятности выдать себя за человека. При большей выборке бот начинает общаться значительно лучше — но для эффективной автоматизации процесса обучения необходимо сделать так, чтобы бот пообщался с достаточно большой группой людей (пользователей), либо разработать еще другую программу, которая будет сама обучать этого бота. Поэтому была разработана дополнительная программа для обучения бота на субтитрах к фильмам. Но этот метод не идеален, так как предложения, идущие в титрах к фильму друг за другом, далеко не всегда связаны, что «путает» алгоритм и расстраивает связи, что иногда приводит лишь к ухудшению качества работы бота.

Ниже приведен пример работы бота с текущим процессом обучения (рис. 2).

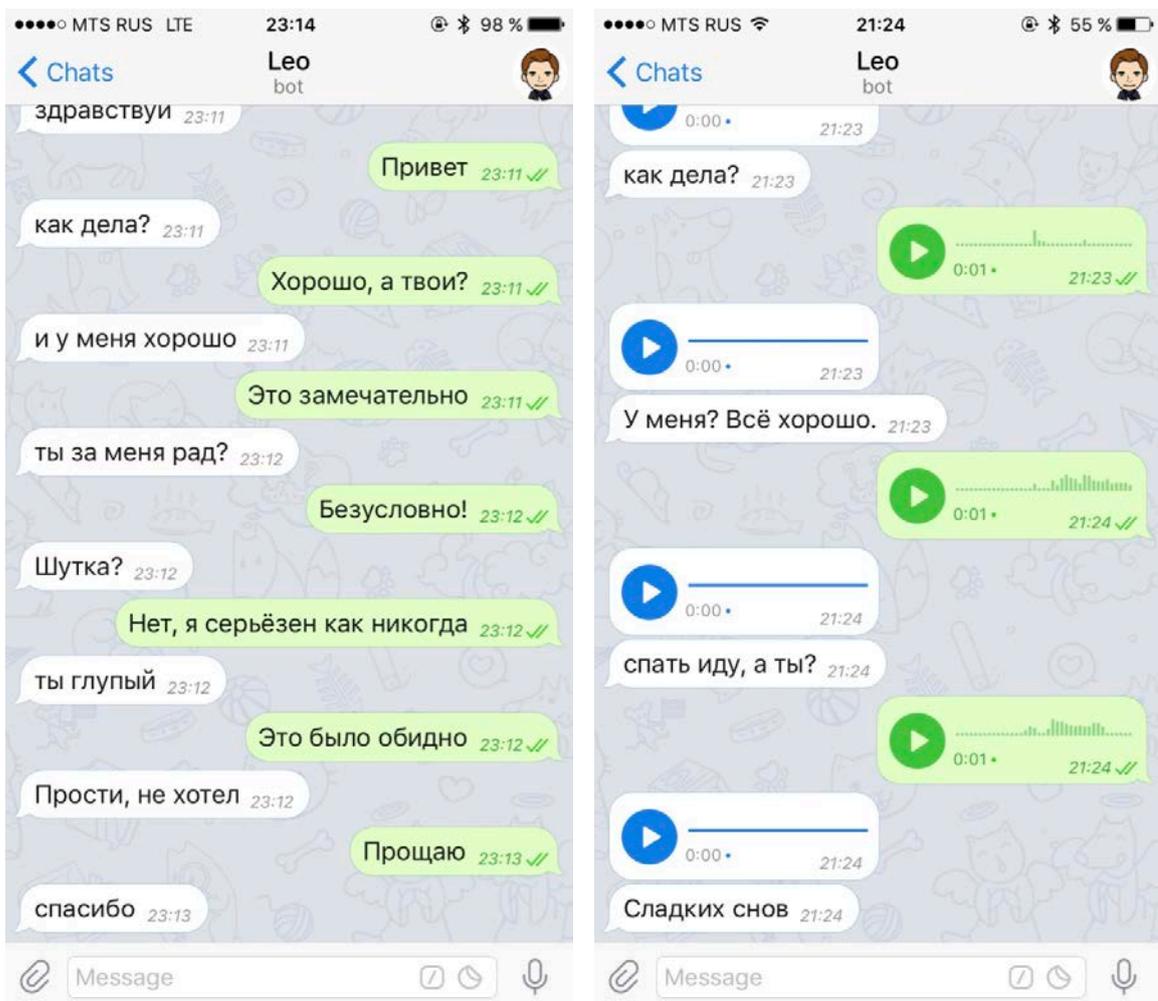


Рис. 2. Пример работы бота

Таким образом, данный алгоритм позволяет создать бота-собеседника, способного с некоторой вероятностью давать достаточно разумные ответы на запросы пользователя и вести с ним беседу. Программа самообучаема, так что с увеличением количества ее использований ответы, в общем-то, становятся разнообразнее, а осмысленные диалоги смогут вестись на большее количество тем.

Благодаря тому, что голосовые сообщения преобразуются в текстовые и обратно, не требуется изменять алгоритм работы бота, достаточно лишь добавить функцию преобразования голоса в текст перед вызовом алгоритма, и функцию синтеза речи после. Из-за этого не требуется хранить аудиофайлы в памяти компьютера, что позволяет значительно сократить общий объем программы.

Авторы полагают, что экспериментальная версия бота позволит далее разработать более совершенный вариант бота, способного (при выполнении некоторых ограничений) пройти успешно усеченный тест Тьюринга.

Библиографический список

1. *Лутц М.* Изучаем Python — 4-е изд. — М.: Символ-Плюс, 2011.
2. *Бизли Д.* Python. Подробный справочник — 4-е изд. — Символ-Плюс, 2010.
3. *Лутц М.* Программирование на Python — 4-е изд.— М.: Символ-Плюс, 2011.
4. [Электронный ресурс] — <https://vc.ru/p/chatbot-guide>
5. [Электронный ресурс] — <https://tech.yandex.ru/speechkit/cloud/doc/guide/>

SPECIAL ALGORITHM OF THE BOT-INTERLOCUTOR

Levin Evgeny Olegovich, Kulik Sergey Dmitrievich

National Research Nuclear University "MEPhI", 115409, Russia, Moscow, Kashirskoye highway,
31, levin.inf@yandex.ru

The article considers the algorithm of the bot-interlocutor, which can respond to user's requests, to conduct a so-called "socialite talk" with him. The algorithm provides for balancing the frequency of issuing identical answers, which allows to diversify communication with the bot and make it more alive. Bot supports voice control: the user can send voice messages to the bot (the bot will return the response also using a voice message). For speech recognition and synthesis, Yandex SpeechKit Cloud is used - Yandex's speech recognition and synthesis technology. The algorithm implemented the possibility of self-learning of the bot - improving the quality of its responses as it is used. The bot is designed for the Telegram messenger, interaction occurs through the Telegram Bot API. A working version of the bot software has been created that can work online on devices with different operating systems.

Keywords: chat-bot, Turing test, artificial intelligence

МАТЕМАТИЧЕСКИЕ МОДЕЛИ ВОСПИТАНИЯ ГРУППЫ РОБОТОВ С НЕАБСОЛЮТНОЙ ПАМЯТЬЮ

*Пенский Олег Геннадьевич, Ощепкова Наталья Владимировна, Бахтин Вадим
Вячеславович*

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, ogpensky@mail.ru

Предложены математические модели, описывающие воспитание группы роботов, способных забывать прошлое. На основе коэффициентов индивидуальной памяти каждого из роботов, входящих в группу, предложены характеристики групповой памяти роботов и исследованы их свойства.

Ключевые слова: Робот, память, воспитание, математические модели, эмоции, группа роботов.

Математическая модель воспитания отдельного робота

В работе [1] приведено соотношение, позволяющее вычислять воспитание робота, получаемое им в результате непрерывного воздействия на него сюжетами и порождающимися в результате этого у него эмоциями:

$$R_i = r_i + \theta_i R_{i-1}, \quad (1)$$

где i – порядковый номер сюжета, воздействующего на робота и порождающего у него элементарное воспитание r_i , R_i – суммарное воспитание робота, полученное им в результате воздействия на него общего количества сюжетов, равных величине i , θ_i – коэффициент памяти, характеризующий долю предыдущего суммарного воспитания, которую помнит робот к моменту воздействия на него сюжетом с порядковым номером i , $\theta_i \in (0, 1 - \delta]$, $0 < \delta < 1$, $\delta = const$.

Предположим, что $r_i = q = const$, $q > 0$, $\theta_i = \theta$, $R_0 = 0$. Легко видеть, что в рамках этих допущений соотношение (1) представляет собой сумму членов геометрической прогрессии, которая описывается известной формулой [2]:

$$R_i = q \frac{1 - \theta^i}{1 - \theta}. \quad (2)$$

Математическая модель одновременного воспитания группы роботов

В настоящее время не изучен вопрос построения математических моделей вычисления воспитания группы роботов. Предложим простейшие модели одновременного воспитания этой группы.

Пусть n - количество роботов в группе, j - порядковый номер робота в этой группе, $j = \overline{1, n}$, $\theta_{j,i}$ - коэффициент памяти робота к моменту воздействия на него сюжетом с порядковым номером i , $\theta_{j,i} \in (0, 1 - \delta_j]$, $0 < \delta_j < 1$, $\delta_j = const$, $r_{j,i}$ - элементарное воспитание робота j , $R_{j,i}$ - суммарное воспитание робота, полученное им в результате воздействия на него общего количества сюжетов.

При введенных обозначениях аналогично соотношению (1) введем следующее равенство

$$R_{j,i} = r_{j,i} + \theta_{j,i} R_{j,i-1}. \quad (3)$$

По аналогии с формулой (3) будем считать, что суммарное воспитание группы роботов определяется формулой

$$\sum_{j=1}^n R_{j,i} = \sum_{j=1}^n r_{j,i} + \sum_{j=1}^n \theta_{j,i} R_{j,i-1} \quad (4)$$

Разделив обе части равенства (4) на величину n , получим соотношение

$$\frac{\sum_{j=1}^n R_{j,i}}{n} = \frac{\sum_{j=1}^n r_{j,i}}{n} + \frac{\sum_{j=1}^n \theta_{j,i} R_{j,i-1}}{n}. \quad (5)$$

Преобразовывая соотношение (5), получим формулу

$$\text{Введем следующие обозначения } \bar{R}_i = \frac{\sum_{j=1}^n R_{j,i}}{n}, \quad \bar{r}_i = \frac{\sum_{j=1}^n r_{j,i}}{n}.$$

Согласно введенным обозначениям равенство (5) примет вид

$$\bar{R}_i = \bar{r}_i + \frac{\sum_{j=1}^n \theta_{j,i} R_{j,i-1}}{n}. \quad (6)$$

Математическая модель памяти группы роботов

Пусть

$$\frac{\sum_{j=1}^n \theta_{j,i} R_{j,i-1}}{n} = \bar{\theta}_i \frac{\sum_{j=1}^n R_{j,i-1}}{n} = \bar{\theta}_i \bar{R}_{i-1}. \quad (7)$$

С учетом (7) формула (6) примет вид

$$\bar{R}_i = \bar{r}_i + \bar{\theta}_i \bar{R}_{i-1}. \quad (8)$$

Нетрудно заметить, что согласно соотношению (7) справедливо равенство

$$\bar{\theta}_i = \frac{\sum_{j=1}^n \theta_{j,i} R_{j,i-1}}{\sum_{j=1}^n R_{j,i-1}}. \quad (9)$$

Коэффициент $\bar{\theta}_i$ назовем коэффициентом групповой памяти роботов.

Очевидно, что коэффициент групповой памяти роботов при $r_{j,i} > 0$ удовлетворяет соотношению $\bar{\theta}_i \in (0, 1 - \delta]$, $0 < \delta < 1$, $\delta = \text{const}$.

Исследуем математические свойства коэффициента групповой памяти для некоторых частных случаев.

Случай 1. Пусть каждый робот в группе имеет равноценные эмоции и каждый робот является равномерно забывчивым [1], т.е., справедливы равенства $\theta_{j,i} = \theta_j$, $r_{j,i} = q_j > 0$.

Легко видеть, что при этих условиях соотношение (9) примет вид

$$\bar{\theta}_i = \frac{\sum_{j=1}^n \theta_j q_j \frac{1 - \theta_j^{i-1}}{1 - \theta_j}}{\sum_{j=1}^n q_j \frac{1 - \theta_j^{i-1}}{1 - \theta_j}} \quad (10)$$

Случай 2. Пусть $\theta_{j,i} = \theta_j$, $r_{j,i} = q > 0$

Нетрудно заметить, что в этом случае равенство (10) примет вид

$$\bar{\theta}_i = \frac{\sum_{j=1}^n \theta_j \frac{1 - \theta_j^{i-1}}{1 - \theta_j}}{\sum_{j=1}^n \frac{1 - \theta_j^{i-1}}{1 - \theta_j}} \quad (11)$$

Равенство (11) позволяет сделать вывод о том, что равноценность эмоций всех роботов в группе и равномернотабывчивость каждого робота по отдельности не влечет равномерную забывчивость всей группы роботов в целом.

Случай 3. Пусть выполняется условие $\theta_{j,i} = \theta = const$.

Преобразование формулы (10) позволяет получить равенство $\bar{\theta}_i = \theta$, на основе которого можно сформулировать вывод о том, что равноценность эмоций каждого из роботов в группе и одинаковая равномерная забывчивость всех роботов группы влечет равномерную забывчивость всей группы роботов.

Заключение

Приведенные математические модели могут быть использованы при проектировании роботов, составляющих группу с заданными свойствами, касающимися особенностей памяти этой группы.

Библиографический список

1. Пенский О.Г., Черников К.В. Основы математической теории эмоциональных роботов. Пермь: изд-во Перм.гос.ун-та. 2010. 256с. – URL: https://arxiv.org/find/cs/1/au:+Pensky_O/0/1/0/all/0/1
2. Черников К.В. Математические модели роботов с неабсолютной памятью: автореф. дис. на соиск. учен. степ. канд.физ.-мат.н. (05.13.18) ПНИПУ. Пермь, 2013. 16с.

MATHEMATICAL MODELS OF EDUCATION OF THE ROBOT GROUP WITH NON-ABSOLUTE MEMORY

Pensky Oleg Gennadievich, Oshchepkova Natalya Vladimirovna, Bakhtin Vadim Mikhailovich

Perm State University, 614990, Russia, Perm, ul. Bukireva, 15, ogpensky@mail.ru

Mathematical models are proposed that describe the upbringing of a group of robots capable of forgetting the past. Based on the coefficients of individual memory of each of the robots included in the group, the characteristics of group memory of robots are proposed and their properties are investigated.

Keywords. Robot, memory, education, mathematical models, emotions, robot group.

ОСНОВНЫЕ ПОЛОЖЕНИЯ МАТЕМАТИЧЕСКОЙ ТЕОРИИ АМБИВАЛЕНТНЫХ ПСЕВДОЭМОЦИЙ РОБОТОВ

Шафер Александр Евгеньевич

Пермский государственный национальный исследовательский университет Россия,
614990, Пермь, ул. Букирева, 15 mexmatpsu@gmail.ru

В статье дается определение амбивалентных псевдоэмоций робота, описывается математическая модель амбивалентных псевдоэмоций робота. Выводятся основные формулы для описания амбивалентных псевдоэмоций робота. Вводится понятие «эмоциональное отношение» робота по паре амбивалентных эмоций, которое может выступать в качестве критерия достижения роботом поставленной цели воспитания. Описывается способ разложения псевдоэмоции робота на пару амбивалентных псевдоэмоций.

Ключевые слова: эмоциональный робот; эмоция; амбивалентная эмоция; воспитание; математическое моделирование.

Введение

Амбивалентными называются эмоции, противоположные друг другу, переживаемые одновременно. В данной работе будет рассмотрена пара амбивалентных эмоций эмоционального робота.

Введем ансамбль [1] эмоций роботов \bar{M} , определяющий текущее эмоциональное состояние робота.

$$\bar{M}(\tau) = (M_1, M_2, \dots, M_n),$$

где M_i ($i = \overline{1, n}$) – эмоция, соответствующая типу эмоции i [2].

Выделим из этого вектора пару ненулевых амбивалентных [2] эмоций (M_1, M_2) .

Так как эмоции являются амбивалентными, логично предположить, что они имеют разные знаки, т.е. $M_1 * M_2 \leq 0$. Для удобства будем считать, что $M_1 \geq 0, M_2 \leq 0$. Стоит отметить, что знаки данных эмоций не могут измениться с течением времени, поскольку эмоцией с противоположным знаком является вторая эмоция из амбивалентной пары, а один вид эмоции не может перейти в другой. Как следствие $M_2 \in [-\infty, 0], M_1 \in [0, +\infty]$.

1. Математическая модель

В работе [2] были определены такие величины, как элементарное воспитание и воспитание робота.

$$r_j^i = \int_0^T M_i^j(\xi) d\xi,$$

как следствие, $r_1 > 0, r_2 < 0$, где r_j^i - элементарное воспитание робота в такте под номером j. $i \in \{1,2\}$

$$R_i^j = r_i^j + \theta_i^j R_i^{j-1},$$

как следствие, $R_1 > 0, R_2 < 0$, где R_i^j - воспитание робота на конец воспитательного такта под номером j. $i \in \{1,2\}$

В случае если известна цель воспитания (A_1, A_2) по данным эмоциям, величина достижения цели δ вычисляется по формуле

$$\delta = \frac{A_1 R_1^j + A_2 R_2^j}{A_1^2 + A_2^2},$$

Причем справедливо отношение $R_i^j = r_i^j + \theta_i^j R_i^{j-1}$, где j – номер воспитательного такта [2], R_i^j – воспитание робота, получаемое в результате действия эмоции с номером j, $i \in \{1,2\}$, θ_i^j – коэффициент памяти, причем $\theta_i^j \in [0,1]$, r_i^j - элементарное воспитание, полученное роботом на такте с номером j, R_i^{j-1} – воспитание робота на конец такта с номером j-1.

2. Эмоциональное отношение робота

Введем следующее определение.

Определение 1 «Эмоциональным отношением» ρ по паре воспитаний (R_1, R_2) , порождёнными амбивалентными эмоциями (M_1, M_2) . Называется выражение:

$$\rho = \ln \left| \frac{R_1}{R_2} \right|, \text{ при } R_1 \neq 0, R_2 \neq 0 \quad (1)$$

Это понятие имеет право на существование, поскольку амбивалентные эмоции являются эмоциями одного типа с различными знаками – как следствие, мы можем посчитать частное. Эмоциональное отношение робота показывает выраженность позитивной или негативной составляющей амбивалентной эмоции робота. При $\rho \gg 0$ можно сказать, что у робота превалирует позитивная часть воспитания, при $\rho \ll 0$ более ярко выражена негативная часть воспитания, при $\rho \approx 0$ воспитания робота по паре амбивалентных эмоций примерно равны.

Приведем основные теоремы, об эмоциональном отношении роботов.

Теорема 1. Для робота с одинаковыми коэффициентами памяти для пары амбивалентных эмоций, получающего элементарные воспитания по положительной эмоции в λ раз больше, чем по отрицательной, эмоциональное отношение не будет изменяться в течение всего воспитательного процесса и будет справедлива следующая формула:

$$\rho = \ln|\lambda|$$

Теорема 2. Для робота с постоянными коэффициентами памяти для пары амбивалентных эмоций, получающего одинаковые по модулю элементарные воспитания по паре этих эмоций справедливо следующее равенство:

$$\rho_j = \ln \frac{(1-\theta^j)(1-\lambda\theta)}{(1-(\lambda\theta)^j)(1-\theta)}, \text{ где } \theta_1^j = \theta, \theta_2^j = \lambda\theta.$$

Теорема 3. Для робота с постоянными коэффициентами памяти для пары амбивалентных эмоций, получающего элементарные воспитания по положительной эмоции в γ раз больше, чем по отрицательной, справедливо следующее равенство:

$$\rho_j = \ln \gamma \frac{(1-\theta^j)(1-\lambda\theta)}{(1-(\lambda\theta)^j)(1-\theta)}, \text{ где } \theta_1^j = \theta, \theta_2^j = \lambda\theta$$

Также,

справедливо

соотношение:

$$\frac{dp}{dt} = \frac{M_1}{R_1} - \frac{M_2}{R_2} \quad (2)$$

Будем говорить, что при выполнении условия $\frac{dp}{dt} > 0$ эмоциональное отношение робота по паре амбивалентных эмоций улучшается (эмоциональное отношения увеличивается), при выполнении условия $\frac{dp}{dt} < 0$ эмоциональное отношение ухудшается (эмоциональное отношения уменьшается).

Определение 2 «Усилением эмоции» M назовем увеличение модуля эмоции вне зависимости от ее знака.

Анализируя формулу (2), можно увидеть, что эмоциональное отношение будет расти при усилении эмоции с положительным знаком и уменьшаться при усилении отрицательной эмоции. Обратный эффект можно наблюдать по отношению к воспитанию - при росте положительного воспитания эмоциональное отношение будет уменьшаться, при росте отрицательного – расти.

3. Способ разложения псевдоэмоции на вектор амбивалентных псевдоэмоций.

Предположим, робот испытал единственную псевдоэмоцию M_0 , породившую псевдовоспитание R_0 , которое состоит из пары псевдовоспитаний (R_0^+, R_0^-) , причем $R_0 = R_0^+ + R_0^-$. От первоначального воспитания R_0 отмерим несколько фиктивных тактов [2] – промежутков времени, в которые робот не испытывает новых псевдоэмоций а псевдовоспитание робота уменьшается в геометрической прогрессии.

Пусть на фиктивном такте под номером j робот имеет воспитание R_j , причем

$$R_j = R_j^+ + R_j^-$$

$$R_j^+ = (\theta^+)^j R_0^+$$

$$R_j^- = (\theta^-)^j R_0^-$$

Пусть прошло n фиктивных тактов. Для каждого из тактов известно $R_j^{\text{эксп}}$ - значение полного воспитания робота в такте с номером j . В работе [3] описан способ экспериментального вычисления текущей эмоции робота.

Для такта с номером j значение квадратичного отклонения экспериментально вычисленного значения воспитания от значения по формулам будет равно

$$\delta_j = (R_j^{\text{эксп}} - (\theta^+)^j R_0^+ - (\theta^-)^j R_0^-)^2$$

Для n фиктивных тактов суммарное значение квадратичного отклонения будет равно

$$\Delta = \sum_{j=1}^n \delta_j = \sum_{j=1}^n (R_j^{\text{эксп}} - (\theta^+)^j R_0^+ - (\theta^-)^j R_0^-)^2 \quad (1)$$

Экспериментально вычисленные значения должны быть максимально близки к вычисленным по формулам, как следствие, Δ должно быть минимально.

Для данной задачи также справедливы неравенства.

$$\begin{cases} 0 \leq \theta^+ \leq 1 \\ 0 \leq \theta^- \leq 1 \\ R_0^+ \geq 0 \\ R_0^- \leq 0 \end{cases}$$

Таким образом, для нахождения неизвестных $R_0^+, R_0^-, \theta^+, \theta^-$ необходимо решить задачу минимизации Δ при заданных ограничениях.

Для решения поставленной задачи используем метод Лагранжа [5] для определения условного экстремума функции (1) с ограничениями (2).

Стоит отметить, что для однозначного определения значений $\theta^+, \theta^-, R_0^+, R_0^-$ необходимо число экспериментальных замеров $n \geq 4$.

Для решения данной задачи разработана программа в пакете Mathematica [6]. Входными параметрами для программы является последовательность (R_1, \dots, R_n) , где R_i – псевдовоспитание робота на конец i -ого фиктивного воспитательного такта, причем $n \geq 4$.

На выходе программа выдает значения $R_0^+, R_0^-, \theta^+, \theta^-$ для которых значение целевой функции Δ минимально.

Заключение

В работе был рассмотрен механизм разложения воспитания робота на пару амбивалентных воспитаний. Была выдвинута гипотеза о том, что полное воспитание робота является арифметической суммой воспитаний по амбивалентным эмоциям, а элементарное воспитание на каждом такте равно сумме элементарных воспитаний, порождённых амбивалентными эмоциями. В рамках данной гипотезы были предложены и доказаны основные теоремы. Рассмотрена связь коэффициентов памяти для суммарного воспитания робота и пары воспитаний, порожденными амбивалентными эмоциями.

Библиографический список

1. Клод Шеннон. Математическая теория связи. — 1948 – 240с.
2. Пенский О.Г. Математические модели эмоциональных роботов: монография / О.Г. Пенский – Пермь: изд-во Перм.гос.ун-та, 2010 – 192с.
3. Черников К.В., Пенский О.Г. Обобщение модели эмоционального воспитания. Вестник Пермского университета. Математика. Механика. Информатика. 2010. №2(2). С. 55–57
4. Гурса Э. Курс математического анализа, том 1, часть 1. Производные и дифференциалы. Определенные интегралы - М.-Л.: ГТТИ. – 1933 – 225с.
5. Галеев Э.М. Оптимизация. Теория. Примеры. Задачи. – М.: Эдиториал УРСС, 2000. – 320 с.
6. Пакет Математика [Электронный ресурс]. – Режим доступа: <http://www.exponenta.ru/educat/systemat/lerner/1.asp> (дата обращения 20.11.2016).

MAIN THESISES OF THE MATHEMATICAL THEORY OF AMBIVALENT PSEUDOEMOTATIONS OF ROBOTS

Shafer Aleksandr E.

Perm State University, Russia, 614990, Perm, Bukirev st., 15 mexmatpsu@gmail.com

This paper defines ambivalent pseudoemotions of emotional robot. Displays the basic formulas that describe the ambivalent emotions of the robot. Introduces the concept of "emotional relationship" of the robot by pair of ambivalent emotions, which can act as criteria for achieving the education goal for robot. A method for decomposing a robot pseudoemotion into a pair of ambivalent pseudoemotions is described.

Key words: emotional robot; emotion; ambivalent emotion; math modeling.

9. МАТЕМАТИЧЕСКАЯ ФИЗИКА И ПРОМЫШЛЕННОСТЬ

ПЕРСПЕКТИВЫ ИНТЕЛЛЕКТУАЛЬНОГО МОДЕЛИРОВАНИЯ ФИЗИЧЕСКИХ ПРОБЛЕМ НА СУПЕРКОМПЬЮТЕРАХ

Гладкий Сергей Леонидович

ООО «Сателлит Инновация», 614000, Россия, г. Пермь, ш. Космонавтов, 111,
lrndlrnd@mail.ru

Рассматриваются перспективы развития одного из направлений интеллектуального моделирования физических проблем, основанного на применении метода фиктивных канонических областей, методов искусственного интеллекта и распределенных вычислений на современных суперкомпьютерах. Проанализированы преимущества данного подхода и возможные проблемы при его применении для расчета сложных трехмерных конструкций. Предложены способы решения выявленных проблем с применением методов искусственного интеллекта и распределенных вычислений. Показано, что такой подход обеспечивает получение надежных и высокоточных решений краевых задач математической физики и применим для расчета конструкций ответственного назначения.

Ключевые слова: искусственный интеллект, математическое моделирование, суперкомпьютеры.

Математическое моделирование физических процессов является одним из первых практических приложений математики. Изначально, методы математического моделирования представляли собой, фактически, прямые аналитические решения краевых задач математической физики. Первые такие решения были получены великими математиками Ж.Л. Д'Аламбером и Ж.Б.Ж. Фурье в XVIII – начале XIX вв. Дальнейшее развитие математического моделирования физических процессов заключалось в совершенствовании метода разделения переменных и разработке других приемов, позволяющих получить решение краевых задач для различных дифференциальных уравнений в частных производных, для областей различных топологий с различными типами краевых условий. Решение каждой краевой задачи было своего рода событием в математическом мире. Применение математического моделирования физических процессов было доступно узкому кругу математиков-профессионалов, и представляло собой высшее проявление интеллектуальной деятельности ученых. Важной составляющей такого процесса моделирования была обязательная оценка точности получаемых решений и оценки физических границ применимости при постановке задачи. Для многих задач авторам удавалось получать точные аналитические решения для геометрически простейших областей. В любом случае, автор каждого решения проводил тщательное исследование точности, таким образом, надежность решения была строго математически обоснована.

Вторым этапом развития математического моделирования физических процессов можно считать появление и широкое распространение численных методов решения краевых задач с использованием ЭВМ. Начало данного этапа ознаменовало появление в 1950-х гг. XX века компьютеров и новой области математики, называемой дискретной. Все численные методы решения краевых задач сводят процесс интегрирования дифференциальных уравнений к множеству операций с числами. Можно сказать, что данный подход основан на решении задачи с позиции ‘грубой силы’. Поскольку выполнение всех элементарных операций можно полностью поручить компьютеру, математическое моделирование физических процессов стало общедоступным. Любой пользователь персонального компьютера может решить сложнейшую краевую задачу ‘нажатием одной кнопки’. Преимущества такого подхода очевидны – быстрота и доступность моделирования и получения результата. Однако, такой подход обладает и серьезным недостатком – сложность оценки точности полученного решения. Численное решение краевой задачи представляет собой огромный массив значений физической величины. Оценка такого решения на удовлетворение дифференциальным уравнениям, моделирующим физический процесс, представляет сложнейшую математическую проблему, исчерпывающее решение которой до сих пор не предложено.

Многие исследователи считают, что третьим этапом развития математического моделирования физических процессов должно стать объединение первых двух подходов – совмещение интеллектуального и компьютерного моделирования как единого метода решения задач математической физики [1, 2].

В настоящее время можно выделить два направления развития интеллектуального компьютерного моделирования. Первое направление связано с прямым применением методов искусственного интеллекта для решения краевых задач [3]. Основным инструментом при таком моделировании являются нейросетевые модели, которые обучаются специальными методами таким образом, чтобы выходные значения удовлетворяли дифференциальным уравнениям и краевым условиям задачи. Фактически, при таком подходе, сеточные модели в численных методах заменяются нейронной сетью.

Второе направление основано на применении аналитических методов, разработанных великими математиками XVIII–XX вв. и имитации их творческой деятельности методами искусственного интеллекта [1]. Применение аналитических методов обеспечивает надежность полученных решений. Методы искусственного интеллекта, с другой стороны,

позволяют сделать доступным такое моделирование широкому кругу исследователей и решать задачи для геометрически сложных конструкций.

Одним из перспективных аналитических методов для реализации данного подхода является метод фиктивных канонических областей (ФКО). Метод ФКО был предложен в 1973 году Л. Н. Ясницким [4] как геометрическая интерпретация решения задач методом Треффца. Метод обладает двумя преимуществами, которые делают его наиболее подходящим для использования в интеллектуальном моделировании. Первым является то, что решение, полученное данным методом, тождественно удовлетворяет дифференциальным уравнениям краевой задачи. Это свойство обеспечивает надежность получаемых результатов, точность которых всегда может быть вычислена по точности удовлетворения граничных условий [5]. Второе преимущество – наличие геометрической интерпретации при выборе базисных функций, которая позволила сформулировать и доказать теорему сходимости, названную теоремой продолжимости. Геометрическая интерпретация позволяет применить методы искусственного интеллекта для автоматизации решения задач математической физики [1].

Метод ФКО успешно применялся Ясницким Л.Н. и его учениками для решения задач расчета прочности конструкций ответственного назначения [4]. В 2000-2005 гг. была разработана универсальная программа REGIONS, основанная на методе ФКО [6]. Программа позволяла решать краевые задачи теплопроводности, электростатики, статической теории упругости и термоупругости в 2D и осесимметричной постановке. В программе были заложены алгоритмы, основанные на методах искусственного интеллекта, позволяющие автоматизировать выбор и расположение ФКО для получения решения задачи с максимальной точностью [7, 8].

В 2005-2010 гг. была разработана программа REGIONS Multi-Physics, позволяющая решать те же задачи математической физики в 3D постановке [9, 10]. Применение программы показало, что использование метода ФКО позволяет получать решения краевых задач в трехмерной постановке с высокой точностью.

Далее приведен пример решения статической задачи деформирования трехмерной цилиндрической оболочки с отверстием под внутренним равномерным давлением. Расчетная область изображена на Рис. 1. В силу геометрической симметрии изображена 1/8 часть трехмерного тела. На внутренней поверхности, включая поверхность отверстия, задано постоянное давление. На плоскостях геометрической симметрии тела заданы условия симметрии деформации. Для решения задачи, согласно методу ФКО, тело было погружено в

пересечение четырех канонических областей: цилиндра и трех сферических полостей. Общее число базисных функций в решении составило 1318. Для вычисления коэффициентов разложения по методу наименьших квадратов, на поверхности тела была использована дискретизация, содержащая 936808 четырехугольных элементов. На Рис.2 представлены результаты решения - изолинии интенсивности напряжений. Был определен коэффициент концентрации напряжений, обусловленный наличием отверстия. Его значение составляет $K_s=4.2$. Была проведена оценка точности полученного решения, которая показала, что интегральное значение давления на внутренней поверхности отличается от заданного не более чем на 0.005%. С точки зрения численного результата, фактически, для данного решения речь о погрешности не идет в принципе.

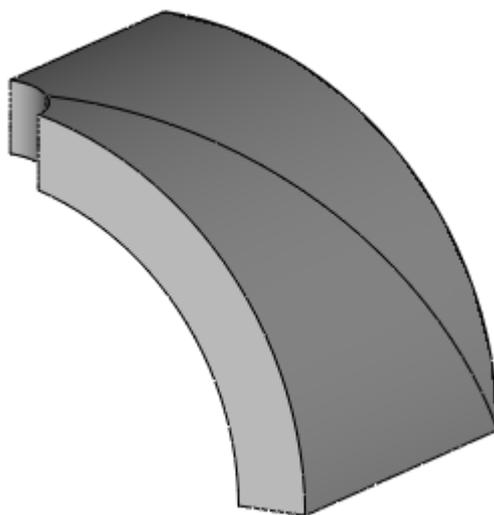


Рис. 1. Геометрия 3D модели с учетом симметрии.

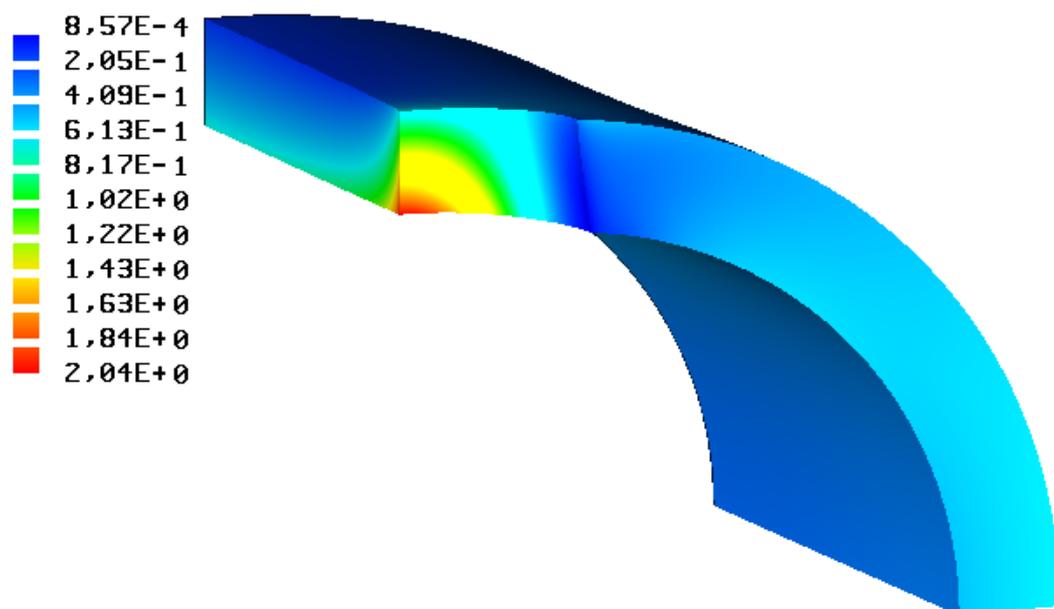


Рис. 2. Изолинии интенсивности напряжений (в безразмерных единицах, на деформированном состоянии).

Приведенный пример решения модельной задачи показывает, что применение метода ФКО позволяет получать высокоточные решения краевых задач, надежность которых не вызывает сомнений.

Тем не менее, исследования показывают, что использование метода ФКО для решения сложных задач в 3D постановке, сталкивается с проблемой скорости вычислений. Например, для решения приведенного выше примера на персональном компьютере с процессором Intel Core i7, понадобилось приблизительно 12 часов (отметим, что при решении использовалось только одно вычислительное ядро). Причиной такой скорости решения является объективная вычислительная сложность алгоритма, основанного на методе ФКО. Во-первых, используемые в методе ФКО базисные функции тождественно удовлетворяют дифференциальным уравнениям задачи, в данном случае – уравнениям теории упругости. Соответственно, функции имеют сложный вид (по сравнению с численными методами), и в данном примере включают специальные цилиндрические функции Бесселя и сферические полиномы Лежандра. Во-вторых, вычислительная сложность алгоритма растет в зависимости от требуемой точности. Рост вычислительной сложности пропорционален 3-ей степени общего числа базисных функций, используемых в решении. Очевидно, что собственно для числа слагаемых зависимость является линейной. Дополнительная квадратичная зависимость обусловлена тем, что для обеспечения точности отыскания неизвестных коэффициентов

разложения, требуется дискретизация границы тела, число элементов которой для 3D постановки должно быть пропорционально второй степени числа базисных функций.

Проблема вычислительной сложности метода ФКО может быть решена с использованием современных суперкомпьютеров. Алгоритмы метода могут быть эффективно ускорены с использованием современных технологий параллельного программирования. Большинство современных суперкомпьютеров используют технологию MPI для распределения между узлами вычислительного кластера и технологию Open MP для параллельных вычислений в пределах одного узла. Алгоритм формирования матрицы разрешающих уравнений в методе ФКО, который занимает основную часть времени решения, идеально подходит для реализации такого способа распределенных вычислений. Распределение между узлами может быть произведено по различным частям поверхности расчетного трехмерного тела, в то время, как распараллеливание в пределах узла будет осуществлено по вычислению различных базисных функций.

Таким образом, интеллектуальное моделирование физических проблем, основанное на использовании метода ФКО, алгоритмов искусственного интеллекта и суперкомпьютеров является перспективным направлением исследований. Метод ФКО позволяет получать надежные решения с высокой точностью, алгоритмы искусственного интеллекта позволяют автоматизировать процесс решения задачи, а применение распределенных вычислений позволяет получить решение за приемлемое время.

Библиографический список

1. *Гладкий С.Л., Степанов Н.А., Ясницкий Л.Н.* Интеллектуальное моделирование физических проблем. Москва–Ижевск: НИЦ «Регулярная и хаотическая динамика», 2006. 200 с.
2. *Ясницкий Л.Н.* Интеллектуальные системы М.: Лаборатория знаний, 2016. 221с.
3. *Тархов Д.А.* Нейросетевые модели и алгоритмы. М: Радиотехника, 2014. 352с.
4. *Ясницкий Л.Н.* Метод фиктивных канонических областей в механике сплошных сред. М.: Наука, 1992. 128с.
5. *Гладкий С.Л., Ясницкий Л.Н.* Об оценке погрешности метода фиктивных канонических областей // Известия Академии наук. Механика твердого тела. М., 2002. № 6. С. 69-75.
6. *Гладкий С.Л., Ясницкий Л.Н.* Программа «REGIONS». Свидетельство о государственной регистрации программы для ЭВМ № 2006611607. Заявка Роспатент № 2006610920. Зарегистрировано в Реестре программ для ЭВМ 12 мая 2006г.
7. *Гладкий С.Л., Ясницкий Л.Н.* Экспертная система для точного решения краевых задач механики // IX Всероссийский съезд по теоретической и прикладной механике. Тезисы докладов. – Нижний Новгород, 2006. Т. 3. С. 67.
8. *Гладкий С.Л., Тарасов М.А., Ясницкий Л.Н.* Генетические алгоритмы в математической физике // Искусственный интеллект: философия, методология,

- инновации. Материалы V Всероссийской конференции студентов, аспирантов и молодых ученых. М.: «Радио и Связь», 2011. С. 118-121.
9. Гладкий С.Л., Ясницкий Л.Н. Решение трехмерных задач теплопроводности методом фиктивных канонических областей // Вестник Пермского университета. Математика, механика, информатика. Пермь: Пермский государственный национальный исследовательский университет, 2011. № 5. С. 41-45.
10. Scientific research software [Электронный ресурс] URL: http://sergey-l-gladkiy.narod.ru/index/regions_x/0-15 (дата обращения: 05.04.2017).

PROSPECTS OF INTELLIGENT SIMULATION OF PHYSICAL PROBLEMS ON SUPERCOMPUTERS

Sergey L. Gladkiy

LLC «Satellite Innovation», Kosmonavtov st., 111, Perm, Russia, 614000, lrndlrnd@mail.ru

This article examines the prospects for the developing an approach of intelligent modeling of physical problems based on the use of fictitious canonic regions method, methods of artificial intelligence and distributed computing on modern supercomputers. The advantages of this approach and possible problems in its application for calculating complex three-dimensional structures are analyzed. Methods for solving the identified problems using methods of artificial intelligence and distributed computing are proposed. It is shown that this approach ensures reliable and high-precision solutions of the boundary value problems of mathematical physics and is applicable to the validation of responsible designs.

Keywords: artificial intelligence, mathematical modeling, supercomputers.

УДК 001.82

СРАВНИТЕЛЬНЫЙ АНАЛИЗ ОДНОСЛОЙНОГО И МНОГОСЛОЙНОГО РЕШЕНИЙ ЗАДАЧИ О ПОРИСТОМ КАТАЛИЗАТОРЕ

*Боровская Ольга Дмитриевна, Васильев Александр Николаевич,
Гусельникова Ирина Викторовна, Сколис Ксения Владимировна,
Тархов Дмитрий Альбертович*

Санкт-Петербургский политехнический университет Петра Великого, 195251, Россия,
г. Санкт-Петербург, Политехническая, 29, dtarkhov@gmail.com

Рассматривается анализ процессов переноса тепла и массы в грануле пористого катализатора при каталитической химической реакции. Задача моделирования (с учётом геометрии гранулы) сводится к приближённому решению краевой задачи для обыкновенного дифференциального уравнения второго порядка. Однослойные и многослойные решения сравнивались как в случае фиксированных значений параметров, так и значений, изменяющихся в пределах различных интервалов. Было установлено, что однослойное решение достаточно точно моделирует совместные процессы переноса тепла и массы в частице пористого катализатора не только для конкретных значений параметров, но и в интервалах изменения этих параметров. Результаты вычислений для многослойного решения

показали, что этот метод может оказаться эффективным для более широкого круга задач построения приближённых решений обыкновенных дифференциальных уравнений и уравнений в частных производных.

Ключевые слова: пористый катализатор, краевая задача, приближённое решение, искусственная нейронная сеть, многослойное решение, неклассическая постановка задачи.

При изучении физико-технических объектов и протекающих в них процессов часто строят математические модели в форме задач для дифференциальных (или иных) уравнений. Порой это приводит к неклассическим постановкам. В реальных задачах коэффициенты и параметры уравнений, как правило, задаются неточно: например, параметр может изменяться в некотором интервале. К таким ситуациям применим нейросетевой подход для построения устойчивых решений в случае разнородной информации [1]. При использовании данного подхода отпадает необходимость в обучении моделирующей нейронной сети заново, при условии достаточно близких входных данных: достаточно использовать уже обученную нейронную сеть (в случае необходимости эту сеть нужно лишь доучить до получения требуемого уровня точности). Нейросетевой подход применим к нелинейным задачам и к задачам в неклассической постановке, что лишь добавляет ему преимуществ.

Именно к такому виду задач можно причислить и анализ процессов переноса тепла и массы в грануле пористого катализатора при каталитической химической реакции [2]. Моделирование сводится к приближённому решению краевой задачи для обыкновенного дифференциального уравнения второго порядка, построенного с учетом геометрии гранулы. В работе рассматривается случай плоской гранулы – задача о пористом катализаторе приводит к решению дифференциального уравнения (1) с краевыми условиями (2):

$$\frac{d^2y}{dx^2} + \frac{p}{x}y = \alpha(1+y)\exp\left[-\frac{\gamma\beta y}{1-\beta y}\right], \quad (1)$$

$$\frac{dy}{dx}(0) = 0, \quad y(1) = 0. \quad (2)$$

Параметр p учитывает геометрию гранулы: для сферической частицы $p = 2$, для цилиндрической – $p = 1$. Далее рассматривается случай плоской гранулы $p = 0$.

К решению этой задачи можно применить нейросетевой подход к построению устойчивых приближённых моделей сложных задач, подробно описанный в [1]. Приближённое решение задачи находится в виде выхода искусственной нейронной сети (3), веса которой определяются в процессе минимизации функционала ошибки.

$$y(x, \alpha, \beta, \gamma) = \sum_{i=1}^N c_i v(x, \alpha, \beta, \gamma, \mathbf{a}_i) \quad (3)$$

Рассматривалась формула из одного слоя с количеством нейронов N , равным 10, 30 и

100.

Минимизируемый функционал ошибки задаётся в виде (4), учитывающем как уравнения, так и краевые условия.

$$J(y) = \sum_{j=1}^M \left(\left[\frac{d^2 y}{dx^2}(x_j, \alpha_j, \beta_j, \gamma_j) - \right. \right. \\ \left. \left. - \alpha_j (1 + y(x_j, \alpha_j, \beta_j, \gamma_j)) \exp \left[-\frac{\gamma_j \beta_j y(x_j, \alpha_j, \beta_j, \gamma_j)}{1 - \beta_j y(x_j, \alpha_j, \beta_j, \gamma_j)} \right] \right]^2 \right) + \\ + \delta \sum_{j=1}^M \left(\left| \frac{dy}{dx}(0, \alpha_j, \beta_j, \gamma_j) \right|^2 + |y(1, \alpha_j, \beta_j, \gamma_j)|^2 \right). \quad (4)$$

В случае, когда при построении нейронной сети использовались значения параметра из некоторого интервала, также были рассмотрены два варианта:

- 1) Изменение всех трех параметров;
- 2) Изменение только одного параметра, но в расширенном интервале.

Сам метод был исследован и для фиксированных значений параметров, и для интервальных значений. В первом случае все расчёты были проведены с неизменяемыми параметрами задачи, представленными в монографии [3], в которой они получены методом интегральных уравнений. При этом, нейросетевое решение в контрольных точках совпадало с данными из работы. На, а относительная погрешность уже для сети из 6 нейроэлементов не превышала 0,08%. Во втором случае (при изменении трёх параметров) рассматривались сети из 10, 30 и 100 нейроэлементов. Полученное приближённое решение давалось нейронной сетью для следующих областей изменения параметров: $\alpha \in (0.05; 0.15)$, $\beta \in (0.4; 0.6)$, $\gamma \in (0.8; 1.2)$, в контрольных точках наблюдалось отличие от результатов. На не более, чем на 2%. При изменении одного параметра с расширением интервала его значений, рассматривались сети из 10, 30 и 100 нейронов. Было установлено, что ошибку, наблюдаемую при малых значениях изменяемого параметра, можно устранить наращиванием используемой нейросети. С целью получения наиболее точного решения можно значительно увеличить время обучения, в этом случае использовался гибридный метод построения модели. Результаты экспериментов, проведённых при первом подходе, показали, что построенное в явной форме приближённое нейросетевое решение весьма точно моделирует совместные процессы переноса тепла и массы в частице пористого катализатора не только для конкретных значений параметров, но и в интервалах изменения этих параметров: модель задается одной нейросетью. Наиболее точное нейросетевое приближение было получено при максимальном

рассматриваемом количестве нейроэлементов ($N=100$), как для изменения одного параметра, так и для изменения трёх параметров. Параметры могут быть определены по экспериментальным данным на основе полученного решения.

Кроме того, строилось многослойное решение задачи на основе известного метода Штёрмера для численного интегрирования обыкновенных дифференциальных уравнений второго порядка. При этом, неизвестное значение функции на левом конце интервала представляется нейронной сетью, веса которой подбираются из условий согласования с условием на правом конце. Простейший вариант метода Штёрмера, который применяется к уравнению вида $y''(x) = f(x, y(x))$, состоит в использовании рекуррентного соотношения $y_{k+1} = 2y_k - y_{k-1} + h^2 f(x_k, y_k)$, $h = x/n$. Такой вариант многослойного подхода позволил существенно увеличить точность решения задачи и расширить область изменения параметров.

Данная работа имела своей целью исследовать зависимость между различными комбинациями количества слоёв, соответствующих многослойной формуле, и нейронов в сети, приближающей начальное условие, с величиной среднеквадратичной ошибки и сделать выводы об эффективности применения рассматриваемых комбинаций относительно поставленной задачи.

Исследовалась погрешность, получаемая при расчётах с использованием не фиксированных значений параметров α , β и γ , а их значений из некоторого интервала. Применительно к каждой из исследуемых комбинаций слоёв и нейронов приближающей сети в рассмотрение были введены все три параметра, изменяющиеся в пределах двух интервалов: $\alpha, \beta, \gamma \in (0;1)$ и $\alpha, \beta, \gamma \in (0;2)$. Исследуемые интервалы значительно больше, чем интервалы, в которых исследование значений параметров проводилось в первом подходе. Также в данной работе все три параметра принимали значения из одного и того же интервала, в то время как в ходе экспериментов, проводимых в соответствии с первым подходом, значения брались из различных интервалов.

Для формулы, количество слоёв в которой соответствовало двум, увеличение количества нейронов приближающей сети не выявило значительного увеличения точности полученного нейросетевого приближения. Наименьшая ошибка была достигнута при максимальном рассматриваемом количестве нейронов – 15, она составила 0.0024659 при изменении входных параметров α , β и γ в интервале $(0;1)$.

Уже при проведении первой серии расчётов, в которой рассматривались приближающие сети с количеством нейронов 2, 5 и 15 для количества слоёв 2, 3 и 4,

наблюдалось, что для приближающей сети из двух нейронов погрешность при изменении параметров α , β и γ в интервале (0;1) меньше погрешности при их изменении в интервале (0;2) на порядок, тогда как при рассмотрении приближающей сети, включающей 5 или 15 нейронов, погрешности при разных интервалах изменения параметров отличаются на меньшие величины.

Результаты расчётов, проводимых для трёхслойной формулы, показали, что наименьшая погрешность также достигается при большем количестве нейронов в приближающей сети и при изменении входных параметров в меньшем интервале. Стоит отметить, что минимальная ошибка в данной серии экспериментов была получена при 5 нейронах, однако она отличалась от ошибки при 15 нейронах (максимальном рассматриваемом количестве) всего на 0,000056.

Также рассматривая погрешности, применительно к трёхслойным формулам, можно было заключить, что, как и для первой серии экспериментов, с увеличением количества нейронов в приближающей сети разность между значениями среднеквадратических ошибок для разных интервалов изменения параметров α , β и γ уменьшалась: если для двух нейронов разность между ошибкой при изменении входных параметров α , β и γ в интервале (0;1) и ошибкой при их изменении в интервале (0;2) составила 0,027, то для 5 нейронов она составила уже 0,010, а для 15 нейронов – 0,0058.

Последняя серия экспериментов, исследовавшая погрешности для четырёхслойных формул, показала следующие результаты: наименьшая погрешность для данной серии как для интервала (0;1) изменения параметров α , β и γ , так и для интервала (0;2) была получена при 5 нейронах приближающей сети и составила 0.0020 и 0.0085 соответственно. Данные показатели стали минимальными для всех трёх серий проведённых экспериментов.

Таблица 1. Значения ошибки для различных сочетаний количества слоёв и нейронов приближающей сети. Выделенные значения являются наименьшими для всей серии проведённых экспериментов. Над чертой – случай, когда $\alpha, \beta, \gamma \in (0;1)$, под чертой – когда $\alpha, \beta, \gamma \in (0;2)$.

Количество слоёв, соответствующее многослойной формуле \n Количесво нейронов в приближающей сети	2	3	4
2	0.00337548 0.0362735	0.00349286	0.00377985 0.025073

		0.0299988	
5	0.00274109	0.00246041	0.00201928
	0.00837256	0.0124121	0.00852682
15	0.00246591	0.00251643	0.00230252
	0.00802758	0.00832399	0.010769

Второй способ позволил построить решение для более широких интервалов изменения параметров. Использование многослойного метода позволило достигнуть высокой точности с меньшим количеством нейроэлементов, чем при однослойном решении. Таким образом, можно заключить, что многослойный метод может оказаться эффективным для более широкого спектра задач построения приближённых решений обыкновенных дифференциальных уравнений и уравнений в частных производных.

Библиографический список

1. *Васильев, А.Н.* Принципы и техника нейросетевого моделирования/ А.Н. Васильев, Д.А. Тархов. – СПб.: Нестор-История, 2014. – 218 с.
2. *Кузнецов, Е.Б.* Перенос тепла и массы в пористом катализаторе/ Е.Б. Кузнецов, С.С. Дмитриев// Материалы VI Международной конференции по неравновесным процессам в соплах и струях – NPNJ – 2006, СПб. – М.: Вузовская книга, 2006. – С.159-160.
3. *На, Ц.* Вычислительные методы решения прикладных граничных задач/ Ц. На. – М.: Мир, 1982. – 296 с.

COMPARATIVE ANALYSIS OF SINGLE-LAYER AND MULTI-LAYER SOLUTIONS OF THE PROBLEM ABOUT THE POROUS CATALYST

*Borovskaya Olga Dmitrievna, Vasilyev Alexander Nikolaevich,
Gusel'nikova Irina Viktorovna, Skolis Ksenia Vladimirovna, Tarkhov Dmitry Albertovich*
Peter the Great St-Petersburg Polytechnic University, 29 Politechnicheskaya Str,
Saint-Petersburg, Russia, 195251, dtarkhov@gmail.com

The article considers the analysis of heat and mass transfer processes in the granule of a porous catalyst under catalytic chemical reaction. The objective of the simulation (taking into account the geometry of the granule) is reduced to the approximate solution of boundary value problem for the ordinary second-order differential equation. The data obtained as a result of single-layer and multi-layered solutions were analyzed using both fixed parameter values and parameter values varying within different intervals. It was found that a single-layer solution accurately simulates the joint processes of heat and mass transfer in a porous catalyst particle not only for specific values of the parameters but also in the intervals of variation of these parameters. The calculation results for a multilayer solution of the porous catalyst problem showed that the multilayer method could be effective for a broader spectrum of problems of constructing approximate solutions of ordinary differential equations and partial differential equations.

Keywords: porous catalyst, boundary value problem, approximate solution, artificial neural network, multilayer solution, nonclassical statement of problem.

УДК 519.6

О МОДИФИКАЦИИ КЛАССИЧЕСКИХ ИТЕРАЦИОННЫХ МЕТОДОВ ДЛЯ ПОЛУЧЕНИЯ НЕПРЕРЫВНЫХ РЕШЕНИЙ НА ПРИМЕРЕ ЗАДАЧИ ТЕПЛОПРОВОДНОСТИ

Лазовская Татьяна Валерьевна

ВЦ ДВО РАН, 680000, Россия, г.Хабаровск, ул. Ким Ю Чена, 65, tatianala@list.ru

Тархов Дмитрий Альбертович

Санкт-Петербургский политехнический университет Петра Великого, 195251, Россия, г. Санкт-Петербург, Политехническая, 29, dtarkhov@gmail.com

В статье рассматривается новый способ приближенного решения краевой задачи для уравнения теплопроводности, основанный на модификации классического неявного метода Эйлера. Полученные результаты сравниваются с точным решением.

Ключевые слова: приближенные методы, дифференциальные уравнения, неявный метод Эйлера, уравнение теплопроводности.

Рассмотрим классическое уравнение теплопроводности [1] в безразмерном виде

$$\frac{\partial u(x,t)}{\partial t} = \frac{\partial^2 u(x,t)}{\partial x^2}, \quad (1)$$

где $x \in R$, пространственная переменная, и $t \in R^+$, переменная времени. Будем решать краевую задачу с кусочно-заданным начальным условием

$$u(x,0) = \begin{cases} 1, & \text{при } x \in [-1,1]; \\ 0, & \text{иначе.} \end{cases} \quad (2)$$

В статье [2] нами было показано, как с помощью классических итерационных методов, обычно позволяющих решать задачи лишь точно, можно получить непрерывные приближенные решения. Такие результаты достигаются путем несложной модификации, когда итеративный процесс применяется к интервалу с переменным концом.

Как и в случае с применением классических вычислительных методов, успешность того или иного выбранного метода зависит от характера конкретной задачи. Для решения задачи (1)-(2) нами были использованы модификации таких классических схем, как метод трапеций

и методы Эйлера. С наилучшей стороны себя показал именно неявный метод Эйлера, который и будет подробно описан ниже.

Напомним классическую итерационную схему неявного метода Эйлера [3] для решения задачи Коши для обыкновенного дифференциального уравнения первого порядка

$$\begin{cases} u'(t) = f(t, u), \\ u(t_0) = y_0, \end{cases} \quad (3)$$

Решение ищется на промежутке $[t_0, T]$, который разбивается на N равных частей $[t_i, t_{i+1}]$ длины h . Обозначим через y_n приближенное значение искомой функции в точке t_n . Для его вычисления применяется следующая неявная итерационная схема

$$y_{n+1} = y_n + h \cdot f(t_{n+1}, y_{n+1}). \quad (4)$$

Будем применять правило (4) к задаче (1)-(2), которая имеет вид (3) относительно переменной времени, считая переменную пространства параметром. При этом, используем модификацию метода (4), описанную в [2]. Исследуем, насколько точным будет полученное решение при малом числе итераций.

Итак, при $N = 1$ приближенное решение строится на переменном временном интервале $[0, t]$ (с учетом краевого условия (2)), тогда $h = t$. Получим линейное уравнение второго порядка относительно переменной x

$$y_1''(x) - \frac{1}{t} y_1'(x) + \frac{1}{t} y_0(x) = 0. \quad (5)$$

Решая уравнение (5) для кусочно-заданной функции $y_0(x)$, получим систему

$$u(x, t) = y_1(x) = \begin{cases} c_1 \exp(x/\sqrt{t}) + c_2 \exp(-x/\sqrt{t}), & x \geq 1; \\ 1 + c_3 \exp(x/\sqrt{t}) + c_4 \exp(-x/\sqrt{t}), & |x| \leq 1; \\ c_5 \exp(x/\sqrt{t}) + c_6 \exp(-x/\sqrt{t}), & x \leq -1. \end{cases} \quad (6)$$

Так как функция $u(x, t)$ по своей природе симметрична и при $|x| \rightarrow \infty$ обнуляется, получим, что

$$u(x, t) = y_1(x) = \begin{cases} c_1 \exp(-x/\sqrt{t}), & |x| \geq 1; \\ 1 + c_2 \left(\exp(x/\sqrt{t}) + \exp(-x/\sqrt{t}) \right), & |x| \leq 1. \end{cases} \quad (7)$$

Далее, приравнивая значения функции и ее производной в точке разрыва (очевидно, задачу можно решать только на правой половине оси), получим итоговое решение

$$u(x, t) = y_1(x) = \begin{cases} \text{sh}(1/\sqrt{t}) \cdot \exp(-x/\sqrt{t}), & |x| \geq 1; \\ 1 - \exp(-1/\sqrt{t}) \cdot \text{ch}(x/\sqrt{t}), & |x| \leq 1. \end{cases} \quad (8)$$

Сравним полученное решение (8) с точным решением

$$u(x,t) = \frac{1}{\sqrt{\pi}} \left(\int_0^{(1-x)/(2\sqrt{t})} e^{-t^2} dt + \int_0^{(1-x)/(2\sqrt{t})} e^{-t^2} dt \right). \quad (9)$$

Соответствующие графики для различных моментов времени представлены ниже (рис. 1-3).

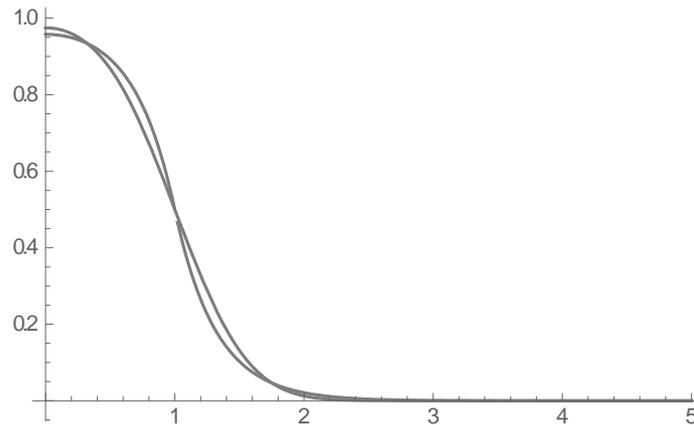


Рис. 1 Точное решение (9) задачи (1) - (2) и решение модифицированным неявным методом Эйлера в первой итерации (8) на интервале $x \in [0; 5]$ в момент времени $t = 0.1$

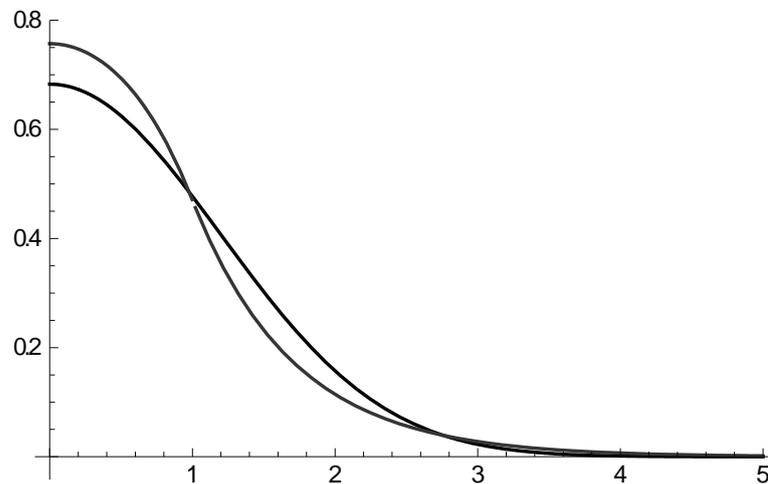


Рис. 2 Точное решение (9) задачи (1) - (2) и решение модифицированным неявным методом Эйлера в первой итерации (8) на интервале $x \in [0; 5]$ в момент времени $t = 0.5$

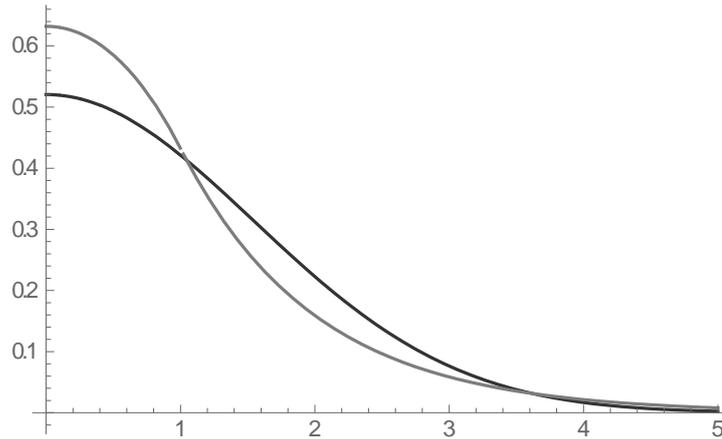


Рис. 3 Точное решение (9) задачи (1) - (2) и решение модифицированным неявным методом Эйлера в первой итерации (8) на интервале $x \in [0; 5]$ в момент времени $t = 1.0$

Посмотрим теперь, какой результат будет после применения схемы (4) для случая $N = 2$. Отметим, что в этом случае шаг схемы будет равен $h = t/2$, уравнение $y_2''(x) - \frac{1}{t} y_2(x) + \frac{1}{t} y_1(x) = 0$ решаем с учетом того, что

$$y_1(x) = \begin{cases} c_1 \exp(-x/\sqrt{h}), & |x| \geq 1; \\ 1 + c_2 (\exp(x/\sqrt{h}) + \exp(-x/\sqrt{h})), & |x| \leq 1. \end{cases}$$

Действуя аналогично (6)-(7), получим кусочно-заданное решение

$$u(x, t) = y_2(x) = \begin{cases} \frac{1}{2} \exp(-\frac{x}{\sqrt{t}}) \left((\frac{x}{\sqrt{t}} + 2) \operatorname{sh} \frac{1}{\sqrt{t}} - \frac{1}{\sqrt{t}} \operatorname{ch} \frac{1}{\sqrt{t}} \right), & |x| \geq 1; \\ 1 + \frac{1}{2} \exp(-1/\sqrt{t}) \left(\frac{x}{\sqrt{t}} \operatorname{sh} \frac{x}{\sqrt{t}} - (\frac{1}{\sqrt{t}} + 2) \operatorname{ch} \frac{x}{\sqrt{t}} \right), & |x| \leq 1. \end{cases} \quad (10)$$

Графики сопоставления приближенного решения (10) и точного решения (9) для различных моментов времени представлены на рис. 4-6.

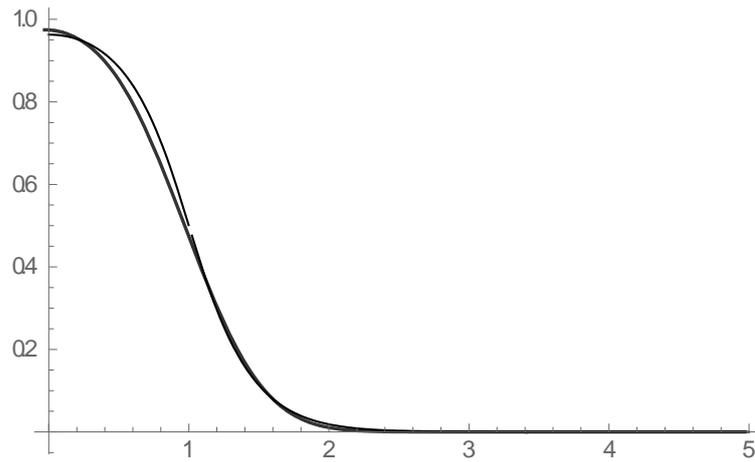


Рис. 4. Точное решение (9) задачи (1) - (2) и решение модифицированным неявным методом Эйлера во второй итерации (10) на интервале $x \in [0; 5]$ в момент времени $t = 0.05$

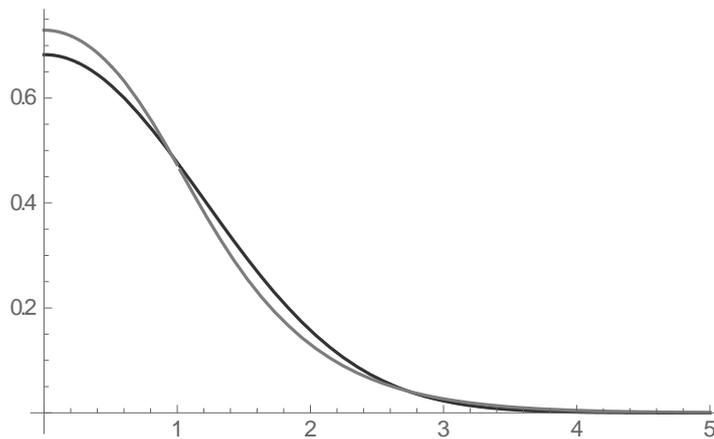


Рис. 5 Точное решение (9) задачи (1) - (2) и решение модифицированным неявным методом Эйлера во второй итерации (10) на интервале $x \in [0; 5]$ в момент времени $t = 0.5$

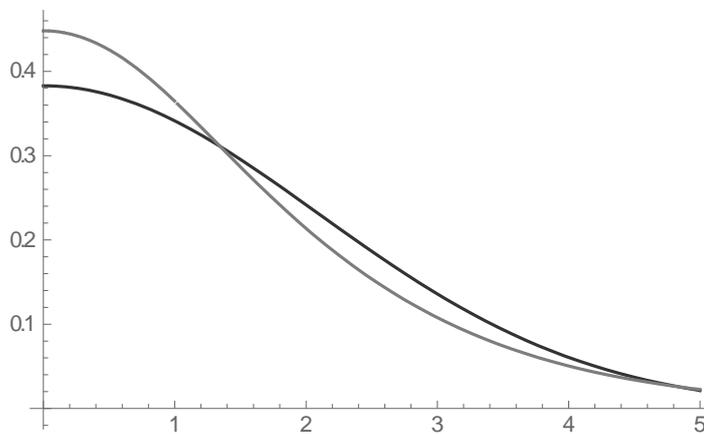


Рис. 6 Точное решение (9) задачи (1) - (2) и решение модифицированным неявным методом Эйлера во второй итерации (10) на интервале $x \in [0; 5]$ в момент времени $t = 1.0$

Как мы видим, точность решения при использовании схемы для двух итераций выше, чем для одной. В дальнейших исследованиях планируется выведение общих формул для произвольного числа слоёв и вывод условий сходимости построенных методов.

Библиографический список

1. *Тихонов А. Н., Самарский А. А.* Уравнения математической физики. Издательство МГУ, 1999.
2. *Lazovskaya T., Tarkhov D.* Multilayer neural network models based on grid methods // IOP Conference Series: Materials Science and Engineering. 2016. Vol. 158, №1.
3. *Самарский А. А.* Введение в численные методы. СПб: Лань, 2005.

ABOUT MODIFICATION OF CLASSICAL ITERATIVE METHODS TO PRODUCE CONTINUOUS SOLUTIONS ON EXAMPLE OF HEAT PROBLEM

Lazovskaya Tatiana V.

CC FEBRAS, 680000, 65, Kim Yu Chen Street, Khabarovsk

Tarkhov Dmitry A.

Peter the Great St-Petersburg Polytechnic University, 29 Politechnicheskaya Str, Saint-Petersburg, Russia, 195251, dtarkhov@gmail.com

Abstract. The paper considers a new method for the approximate solution of the boundary value problem for the heat equation based on the modification of the classical implicit Euler method. While classical methods allow us to obtain only point solutions, our modification gives a continuous approximate solution. The obtained results are compared with the exact solution.

Keywords: approximate methods, differential equations, implicit Euler method, heat equation.

10. МЕТОДЫ И ИНСТРУМЕНТЫ СОЗДАНИЯ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ

ВЕРОЯТНОСТНОЕ МОДЕЛИРОВАНИЕ ТЯЖЕЛОХВОСТЫХ РАСПРЕДЕЛЕНИЙ

Багаев Иван Владимирович, Канищев Илья Сергеевич

Вятский государственный университет,
610000, Россия, г. Киров, ул. Московская, д.36 ivan.bagaev1993@gmail.com

Современное вероятностное программирование позволяет решать различные задачи с помощью построения моделей и Байесовского вывода. Одной из таких задач является аппроксимация параметров различных вероятностных распределений. В этой статье рассматривается подход к оценке разности между двумя группами, каждое из которых имеет тяжелохвостое распределение. Эта задача является довольно распространённой в маркетинговых исследованиях, например, при оценке результатов А/В тестирований. В статье описываются основные принципы построения вероятностной модели, выбора вида целевого распределения и априорных распределений для его параметров. Результатом работы является вероятностная модель, позволяющая достоверно оценить разницу между двумя группами, имеющими тяжелохвостые распределения. В качестве программного инструмента используется PyMC3, библиотека для вероятностного программирования и Байесовского моделирования на языке Python.

Ключевые слова: Байесовский вывод, вероятностное моделирование, тяжелохвостые распределения, проверка гипотез, MCMC, PyMC3, Python.

Основная идея вероятностного программирования - использование компьютера для построения вероятностных моделей. Для этого в настоящее время существуют как отдельные языки программирования, так и библиотеки различной степени сложности [1, 2, 3]. Все они должны предоставлять возможности построения модели, вывода её параметров и оценки её качества. Спектр задач, решаемых данными методами очень широк – от моделирования распределений и проверки гипотез до машинного обучения, и глубоких нейронных сетей.

В данной работе рассматривается задача моделирования распределений, имеющих длинный и тяжелый хвост, и применение такой модели для проверки гипотез. Во многих отраслях проблема достоверного сравнения двух групп является одной из самых распространённых. Проверка статистических гипотез находит своё применение в психологии, медицине, экономике, физике и т.д. Одним из распространённых примеров является задача оценки результатов А/В тестирований. А/В тестирование - метод маркетингового исследования, суть которого заключается в том, что контрольная группа элементов сравнивается с набором тестовых групп, в которых один или несколько показателей были изменены, для того, чтобы выяснить, какие из изменений улучшают целевой показатель.

Тяжелохвостые распределения

Тяжелохвостым, по определению [4], является распределение, хвосты которого не ограничены экспоненциально, то есть распределение, которое имеет хвост тяжелее чем, экспоненциальное распределение. Чаще всего в задачах встречаются распределения, имеющие правый тяжелый хвост. Классический пример – распределение Парето, моделирующее благосостояние или доход населения, встречающееся помимо экономики в социологических, физических и прочих исследованиях. Для тяжелохвостых распределений также остро стоит и без того субъективная проблема “выбросов” в данных – хвост, как правило, достаточно длинный, и сложно однозначно сказать, что является обычным для наблюдаемого распределения, а что – выбросом. Поэтому выбор вида целевого распределения целиком зависит от специфики задачи и критичности влияния выбросов на результат, по которому будет принято решение.

В рамках рассматриваемой проблемы тяжелохвостое распределение будет иметь, например, доход с покупателей интернет магазина, с игроков и мобильном приложении и подобные – большая часть пользователей совершает 1-2 покупки по минимальным ценникам, но в тоже время есть сегмент, совершающих их регулярно или просто на большие суммы (рис. 1).

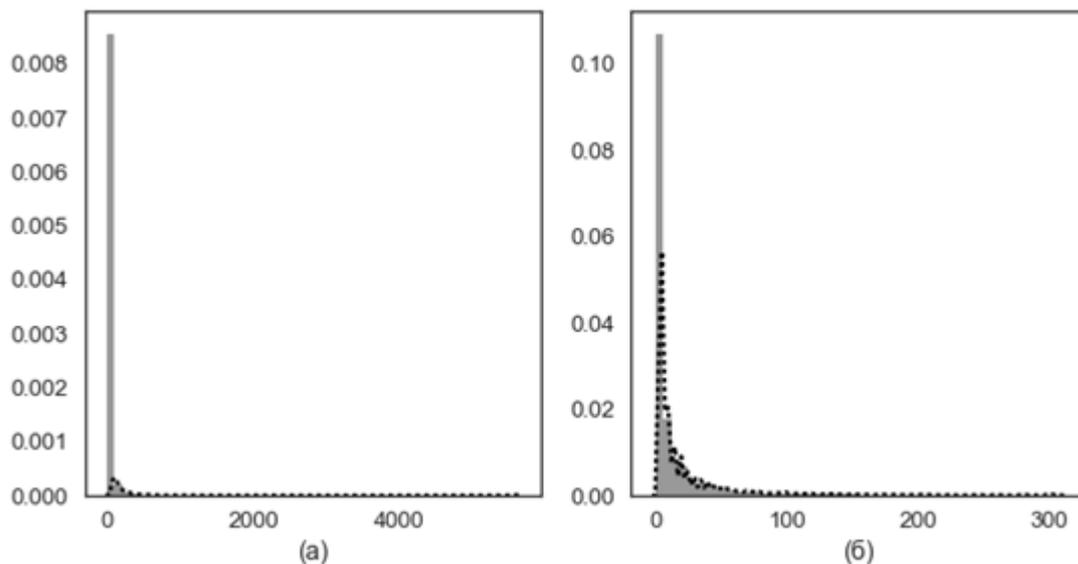


Рисунок 1 - Пример тяжелохвостого распределения (а) – полная гистограмма, (б) – первые 99% распределения

Вероятностная модель для сравнения двух групп с тяжелохвостыми распределениями.

Разработка вероятностной модели состоит из трёх шагов – построение модели, Байесовский вывод, проверка и критика [5]. Обычно в качестве оцениваемой метрики берётся математическое ожидание по каждой из групп, что и будет главным параметром,

который необходимо аппроксимировать в модели. Помимо этого, часто ещё сравнивают дисперсии и силу эффекта [6].

Модель строится соответствии с принципом действия метода МСМС (Markov Chain Monte Carlo), который основывается на использовании теоремы Байеса

$$P(A | B) = \frac{P(B | A)P(A)}{P(B)} \quad (1)$$

Для нахождения апостериорного распределения $P(A | B)$ нам необходимо задать априорные вероятностные распределения параметров модели $P(A)$ и функцию правдоподобия $P(B | A)$. Апостериорное распределение модели может быть использовано, чтобы сгенерировать новые данные с учетом прошлых наблюдений и также делать предсказания. Это производится путем вычисления правдоподобия для новых данных, усредняя по каждому множеству скрытых переменных в соответствии с апостериорным распределением.

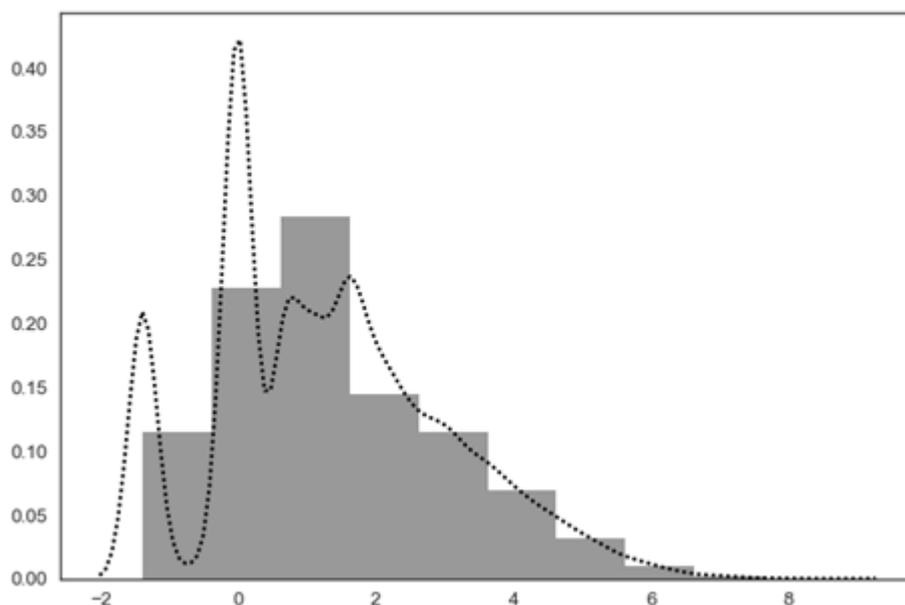


Рисунок 2 - Распределение вероятней для логарифмированных наблюдаемых данных

Так как целью стоит аппроксимация апостериорного распределения математического ожидания исходных распределений, в качестве правдоподобия выберем логнормальное распределение, предположив, что логарифм наблюдаемых данных распределен нормально или как минимум близок к этому (рис. 2).

Математически модель формализуется следующим образом:

$$\begin{aligned}
\alpha_{ij} &\sim \nu(l, u) \\
\beta_{ij} &\sim \nu(l, u) \\
\tau_i &\sim \Gamma(\alpha_{i,1}, \beta_{i,1}) \\
\mu_i &\sim \Gamma(\alpha_{i,2}, \beta_{i,2}) \\
X_i &\sim \text{LogN}(\mu_i, \tau_i) \\
\Delta &= \mu_B - \mu_A \\
i &\in \{A, B\}
\end{aligned}
\tag{2}$$

Где, μ и τ - параметры логнормального, А и В - оцениваемые группы, l и u - параметры-границы равномерного распределения, характеризующие степень нашего незнания.

α, β, τ, μ - априорные распределения параметров модели. X_i – функция правдоподобия логнормального распределения, дельта – оцениваемое распределение разности математических ожиданий каждой из групп. Отметим, что наблюдаемые данные здесь не используются, хотя, как правило, это и не приводит к переобучению. Модель полностью можно записать в виде программы, используя библиотеку PyMC3 [1].

Вторым шагом является Байесовский вывод – нахождение апостериорного распределения параметров, используя наблюдаемые данные. Для этого предлагается использовать алгоритм Метрополиса-Хастинга (МН), предварительно произведя оценку апостериорного максимума для каждого из параметров и использовав её как стартовые значения, чтобы ускорить сходимость к апостериорному распределению и снизить негативный эффект от случайного блуждания на ранних итерациях МН.

На выходе будем иметь распределения математических ожиданий для каждой из групп и распределение их разности (рис. 3.)

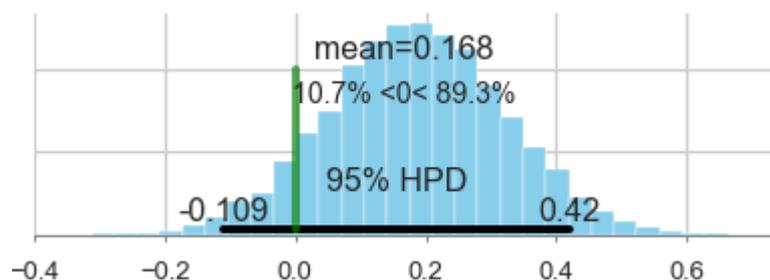


Рисунок 3 - Распределение разницы между апостериорными математическими ожиданиями групп, наблюдаемых данных.

В результате, можно сделать вывод о том, что группа В лучше группы А с такой вероятностью, какая доля распределения дельты их мат. ожиданий больше нуля. Для

гистограммы на рисунке 3 такая вероятность будет равна 89%. На практике такого значения достаточно, для принятия решения о том, что группа В лучше группы А.

В статье была предложена разработанная вероятностная модель, позволяющая найти достоверную разницу между апостериорными параметрами двух исследуемых групп. Модель может быть в дальнейшем улучшена, добавлением в неё механизма определения доли выбросов в данных методом Хоггса [7] или выбором другой функции правдоподобия, лучше аппроксимирующей данные.

Библиографический список

1. *Salvatier John, Wiecki Thomas V., Fonnesebeck Christopher*. Probabilistic programming in Python using PyMC3 // PeerJ Computer Science. — 2016. — apr. — Vol. 2. — P. E55.
2. *Bob Carpenter, Andrew Gelman, Matt Hoffman et al*. Stan: A Probabilistic Programming Language // Journal of Statistical Software. — 2016. — Vol. VV, no. li.
3. *Dustin Tran, Alp Kucukelbir, Adji B. Dieng et al*. Edward: A library for probabilistic modeling, inference, and criticism — 2016. — oct.
4. *Asmussen, S. R.* (2003). "Steady-State Properties of GI/G/1". Applied Probability and Queues. Stochastic Modelling and Applied Probability. 51. pp. 266–301.
5. *Blei David M*. Build, Compute, Critique, Repeat: Data Analysis with Latent Variable Models // Annual Review of Statistics and Its Application. —2014. — jan. — Vol. 1, no. 1. — P. 203–232.
6. *Meredith M., Kruschke J*. Bayesian Estimation Supersedes the t-Test. – 2015.
7. *Hogg D. W., Bovy J., Lang D*. Data analysis recipes: Fitting a model to data //arXiv preprint arXiv: 1008.4686. – 2010.

PROBABILISTIC MODELING OF HEAVY-TAILED DISTRIBUTIONS

Bagaev Ivan V., Kanishchev Ilya S.

Vyatka State University, 36, Moskovskaya st., Kirov, 610000, Russia,
ivan.bagaev1993@gmail.com

Abstract. Modern probabilistic programming allow to solve different tasks by building models and Bayesian Inference. One of this tasks is approximation of parameters of different probability distribution. In this article, we explain our approach to estimate difference between two groups, which of them has heavy-tailed distribution. This task is very common for marketing research, for example, estimation A/B test results. Article explains main concepts of building probabilistic model, choosing the target distribution and priors for parameters. As result, we have probabilistic model that can be used for robust estimate difference between two groups with heavy tailed distribution. As program tool, we use PyMC3, Python Probabilistic Programming and Bayesian modeling framework.

Keywords: Bayesian Inference, Probabilistic Modeling, Heavy-Tailed distributions, hypothesis testing, MCMC, PyMC3, Python

ПОСТРОЕНИЕ «УСПЕШНОЙ» ПРОГНОЗИРУЮЩЕЙ НЕЙРОСЕТИ

Гусев Андрей Леонидович, Окунев Александр Анатольевич
Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, alguseval@mail.ru

Рассмотрена проблема возможности формулировки достаточных условий для построения «успешной» прогнозной нейронной сети, т.е. ошибка которой не превосходит наперёд заданное число ε . Предлагается сформулировать критерий «успешности» основанный на использовании исследования модулей коэффициентов корреляции между прогнозируемым показателем и определяющими показателями. Интервал, на котором определён прогнозируемый показатель, необходимо разделить на несколько интервалов по определенным правилам. Для каждого интервала необходимо найти модули коэффициентов корреляции определяющих показателей с прогнозируемым показателем. Затем из полученных модулей коэффициентов корреляции для каждого интервала необходимо найти максимальный модуль. Далее из всех максимальных модулей коэффициентов по всем интервалам найти минимальный модуль коэффициента. Достаточным условием построения «успешной» прогнозной нейросети будет выполнение условия того, что минимальный модуль коэффициента будет не меньше, чем эмпирически установленное некоторое значение $r(\varepsilon)$.

Ключевые слова: нейронная сеть, прогноз показателей, коэффициент корреляции, качество прогнозирования.

При решении задачи прогнозирования [1, 2] исследователь выдвигает гипотезу о том, что показатель y может быть спрогнозирован по вектору определяющих показателей (x_1, x_2, \dots, x_m) . Обычно для построения прогнозной нейросети в распоряжении исследователя имеются N наблюдений, каждое из которых состоит из $(m+1)$ показателя: $(x_1, x_2, \dots, x_m, y)$. Можно ли заранее предсказать «успешность» или «не успешность» построения такой нейросети? Под «успешной» нейросетью будем подразумевать нейросеть, средняя ошибка которой не превосходит наперёд заданное число ε . Ошибка для одного наблюдения обычно вычисляется в соответствии с требованиями предметной области, в которой рассматривается прогнозируемый показатель.

Наверняка определить успешность построения прогнозной нейросети невозможно. Однако предсказать «успешность» с вероятностью близкой к единице возможно, то есть сформулировать достаточные условия построения «успешной» нейросети. Для этого необходимо проанализировать прогнозируемый показатель. Сначала нужно интервал между минимальным и максимальным значениями показателя y среди N наблюдений разделить на

несколько равных интервалов. Число интервалов может быть R , которое равно целой части числа $N/10$, что гарантирует в среднем 10 значений показателя y на каждом интервале. Выбор числа интервалов может быть сделан из каких-либо других соображений, но необходимо произвести разбиение на интервалы (может быть и не равные между собой) так, чтобы в любом из интервалов было не менее 5% всех наблюдений. При малом количестве наблюдений интервалы можно построить так, чтобы в каждый интервал попало не менее пяти наблюдений.

Теперь для каждого из полученных интервалов необходимо выделить группу наблюдений (наблюдения определяются по принадлежности показателя y этому интервалу) и проделать следующие вычисления. Для каждого из определяющих показателей по группе наблюдений найти линейный коэффициент корреляции с прогнозируемым показателем r_{y,x_i} , $i = \overline{1, m}$, среди которых определить максимальный по модулю коэффициент корреляции $r_{\max, j}$ для j -ого интервала $j = \overline{1, R}$. Далее нужно найти коэффициент $r_{\max, \min}$ - минимальный коэффициент корреляции из всех максимальных коэффициентов по всем R интервалам. Эмпирически можно установить значение r , которое будет зависеть от ϵ , такое, что в случае если $r_{\max, \min} \geq r$, то можно с вероятностью близкой к единице утверждать, что может быть построена «успешная» прогнозная нейросеть.

Таким образом, «успешность» прогнозной нейросети, в конечном счете, тесно связана с минимальным из всех максимальных коэффициентов корреляции по интервалам. Поэтому для определения возможной «успешности» при построении прогнозной нейросети нужно производить разбиение на интервалы, исходя из здравого смысла.

Библиографический список

1. Гусев А.Л. Непрерывный статистический контроль при управлении. / Гусев А.Л. // Createspace, 2012. – 128 с.
2. Гусев А.Л. Нейронные сети и прогноз. Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Всероссийской научно-практической конференции (г. Пермь, 17–19 мая 2016 г.) / Гусев А.Л. // ПГНИУ. – Пермь, 2016. – С. 60-62.

TRAINING «SUCCESSFULL» FORECASTING NEURAL NETWORK

Andrey L. Gusev, Alexander A. Okunev

Perm State University, 614990, Russia, Perm, Bukireva Str. 15, alguseval@mail.ru

Problem of ability to formulate sufficient criterion of trained forecasting neural network success is discussed in this paper. Neural network is successful if its error is less than a preassigned number ε . The criterion is based on usage of absolute values of correlation coefficients between the predicted factor and determining factors. Range of the predicted factor must be divided into several intervals according to certain rules. It is necessary to find absolute values of correlation coefficients between determining factors with the predicted factor per interval. After that, maximal correlation coefficient absolute value is found per interval. Further, it is necessary to choose the minimal value of the maximal absolute values. The sufficient criterion of neural network success can be formulated as follows: minimal absolute value is not greater than $r(\varepsilon)$ which is found empirically.

Keywords: neural network, factor forecasting, correlation coefficient, forecasting quality

ОБ ОДНОМ ПОДХОДЕ К ПОСТРОЕНИЮ СТРУКТУРЫ БАЗЫ ЗНАНИЙ ЭКСПЕРТНОЙ СИСТЕМЫ

Игошин Владимир Аркадьевич, Игошин Михаил Владимирович

ИП “Технологии Инженерии Знаний”

614002, Россия, г. Пермь, ул. Чернышевского, д.5, кв.45

igoshin-va@perm.ru, m.v.igoshin@gmail.com

В статье даётся описание подхода к построению структуры базы знаний экспертной системы для решения задачи в узкой предметной области, в которой, в зависимости от значений входных параметров-фактов, требуется по запросу получить ответ или консультацию специалиста-эксперта. Подробно описывается состав входящих в базу знаний объектов и их взаимосвязей, представление знаний в виде правил и технология их ввода, а также возможность дополнительного включения видео - и аудио - информации, изображений и ссылок в виде url-адресов. Показывается общая схема обработки запроса и поиска ответа с объяснением получения результата, которая может быть практически использована при разработке экспертной системы.

Ключевые слова: база знаний, инструментальные средства создания баз знаний, экспертная система.

Одним из важных направлений в развитии интеллектуальных информационных систем являются технологии создания баз знаний и экспертных систем, берущие своё начало ещё в 80-ых годах прошлого столетия, но которые далеко не исчерпали свои возможности и постоянно совершенствуются. В классическом понимании база знаний (БЗ) (английское knowledge base) - это база данных, которая содержит и накапливает информацию о знаниях специалистов-экспертов в некоторой предметной области [1]. Экспертная система (ЭС) – это интеллектуальный информационный сервис, который обрабатывает запросы к БЗ и выдаёт ответы с пояснением получения результата в форме близкой к той, в какой это сделал бы сам специалист-эксперт, знания которого хранятся в этой базе знаний [1].

В данной статье описывается подход к построению структуры базы знаний, который на практике реализован в программе *Конструктор базы знаний* [2], входящей в программный комплекс инструментальных средств создания баз знаний и экспертных систем.

База знаний, созданная с помощью программы *Конструктор базы знаний*, содержит следующие объекты: *факты, выражения, выводы и правила*. Каждый объект имеет своё уникальное имя, описание и набор характеризующих его свойств.

Факт – это параметр или объект предметной области, который имеет свои значения. В зависимости от типа, значения факта могут быть в текстовом виде, целыми или дробными числами, календарными датами или временем суток. На рис. 1 показаны примеры фактов с разными типами значений.

день	температура воздуха	давление	дата рождения	время суток
текстовый	целое число	дробное число	значение даты	значение времени
солнечный	-10	1.8	27.01.1948	00:00
пасмурный	0	2.5	18.04.1981	12:00
дождливый	10	12.63	16.02.2017	23:59:59

Рис. 1. Примеры фактов

Выражение – это арифметическое выражение или формула, имеющая некоторый предметный смысл. Членами выражения могут быть факты с не текстовым типом значения, другие выражения и встраиваемые функции, от которых определяется зависимость выражения. Значением выражения может быть целое или дробное число, дата или время. Встраиваемая в выражение функция имеет такой синтаксис:

$$Fun \{par_1; par_2; \dots par_n\}$$

где *Fun* – имя функции, а *par_1, par_2, ... par_n* – параметры, которыми могут быть факты, выражения, встраиваемые функции, целые и дробные числа, значение даты или времени. Значением функции, как и выражения, может быть целое или дробное число, дата или время. Встраиваемые функции выбираются из библиотеки и по видам подразделяются на арифметические, тригонометрические, вычислительные, функции для работы с датами и временем. Выражения не являются обязательными объектами, их

необходимость определяется потребностями предметной области, для которой создаётся база знаний.

Вывод – это параметр или объект предметной области, который имеет свои значения, зависящие от значений фактов, выражений или других выводов. Значения выводов находятся с помощью запросов к базе знаний. Тип значений у выводов всегда текстовый.

Представление знаний базируется на правилах, которые соответствуют их классическому определению в [1] и имеют такой вид:

ЕСЛИ *условие* ТО *значение*

где *условие* есть некоторое логическое условие, выполнение которого определяет конкретное *значение* вывода. Поэтому, в базе знаний каждому выводу соответствует своё правило, через которое устанавливается прямая зависимость вывода от фактов, выражений и других выводов, которые называются *аргументами* правила. Через аргументы-выводы определяется косвенная зависимость вывода правила от других фактов, выражений и выводов (рис. 2).

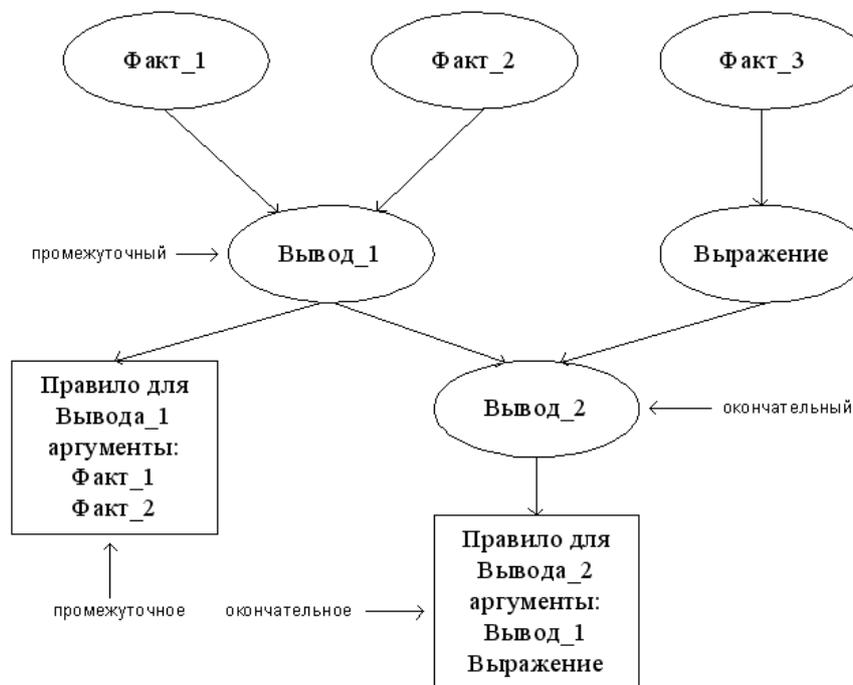


Рис. 2. Правила и зависимости выводов

Если вывод встречается в качестве аргумента правила, то такой вывод называется *промежуточным* и соответствующее ему правило будет тоже *промежуточное*. Если вывод не является аргументом в других правилах, то такой вывод называется *окончательным* и соответствующее ему правило также считается *окончательным*. На рис. 2 *Вывод_1* является промежуточным, а зависимый от него *Вывод_2* окончательным.

Каждое правило включает *логические утверждения* – экспертные заключения, которые по совокупности одновременного выполнения всех условий на значения аргументов, определяют возможные значения вывода этого правила:

ЕСЛИ *условие_арг_1* И *условие_арг_2* И ... И *условие_арг_N* ТОГДА *значение_1*

ЕСЛИ *условие_арг_1* И *условие_арг_2* И ... И *условие_арг_N* ТОГДА *значение_2*

...

ЕСЛИ *условие_арг_1* И *условие_арг_2* И ... И *условие_арг_N* ТОГДА *значение_K*

Например, утверждения правила *определение погоды* для определения значений вывода *погода* в летний день, в зависимости от выполнения условий на значения аргумента-факта *температура воздуха* могут выглядеть так:

Если температура воздуха выше 30 тогда погода жаркая

Если температура воздуха в диапазоне от 22 по 30 тогда погода тёплая

Если температура воздуха в диапазоне от 12 по 21 тогда погода прохладная

Если температура воздуха ниже 12 тогда погода холодная

Здесь следует отметить, что значением вывода в утверждении может быть список, состоящий из нескольких или всех его значений, и тогда утверждение примет такой вид:

ЕСЛИ *условие_арг_1* И *условие_арг_2* И ... И *условие_арг_N*

ТОГДА *значение_1* И *значение_2* И ... И *значение_M*

Возможные операторы условий на значения аргументов правила, в зависимости от их типов значений, приведены в таблице 1. Символ ‘+’ означает допустимость применения оператора.

Таблица 1. Операторы условий на значения аргументов правила

оператор условия	символ	текстовый	целый, дробный	дата, время
равно	=	+	+	+
не равно	≠	+	+	+
меньше	<		+	+
меньше - равно	≤		+	+
больше	>		+	+
больше - равно	≥		+	+
в диапазоне	in [-]		+	+
вне диапазона	out [-]		+	+
список значений	(;)	+	+	+
в списке значений	in (;)	+	+	+
вне списка значений	out (;)	+	+	+
любое значение	~	+	+	+
значение отсутствует	-	+	+	+

В программе *Конструктор базы знаний* тексты логических утверждений формируются автоматически по мере ввода в ячейки таблицы экранной формы условий на значения аргументов и соответствующих им значений вывода правила (рис. 3).

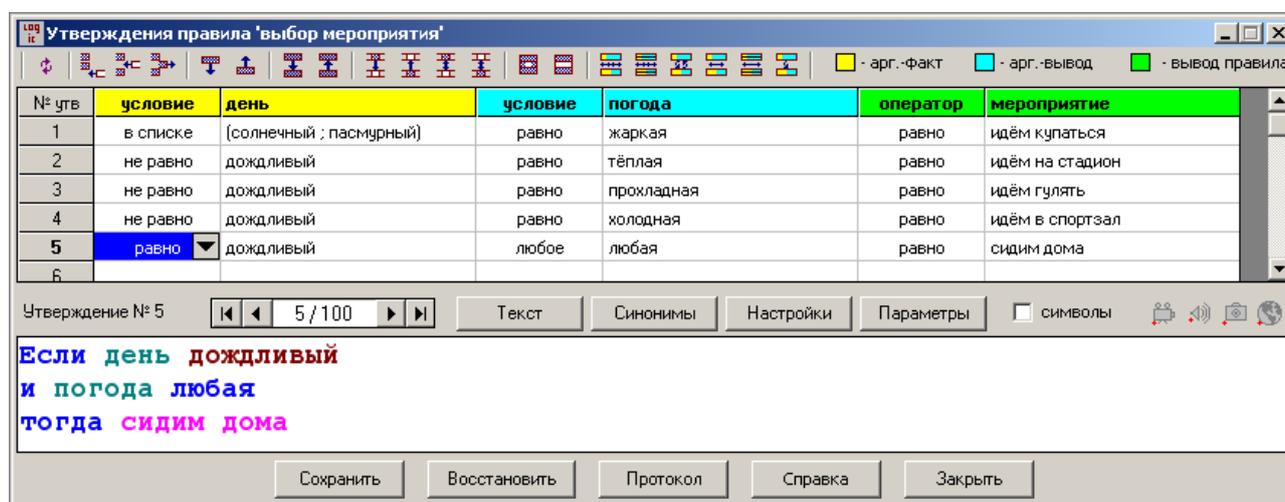


Рис. 3. Форма ввода логических утверждений правила

В процессе ввода, текст утверждений можно настраивать путём подбора для операторов условий и для оператора значения вывода правила слов синонимов, подходящих по смыслу к названиям аргументов и к названию вывода правила. Для более информативного восприятия отдельных элементов текста можно изменять их цвет, наклон и толщину, а также размер всего текста утверждения.

Чтобы получить значение нужного вывода для заданных значений фактов, к базе знаний выполняется запрос. На рис.4 показан пример схемы обработки запроса для получения значения *Вывода_4*.

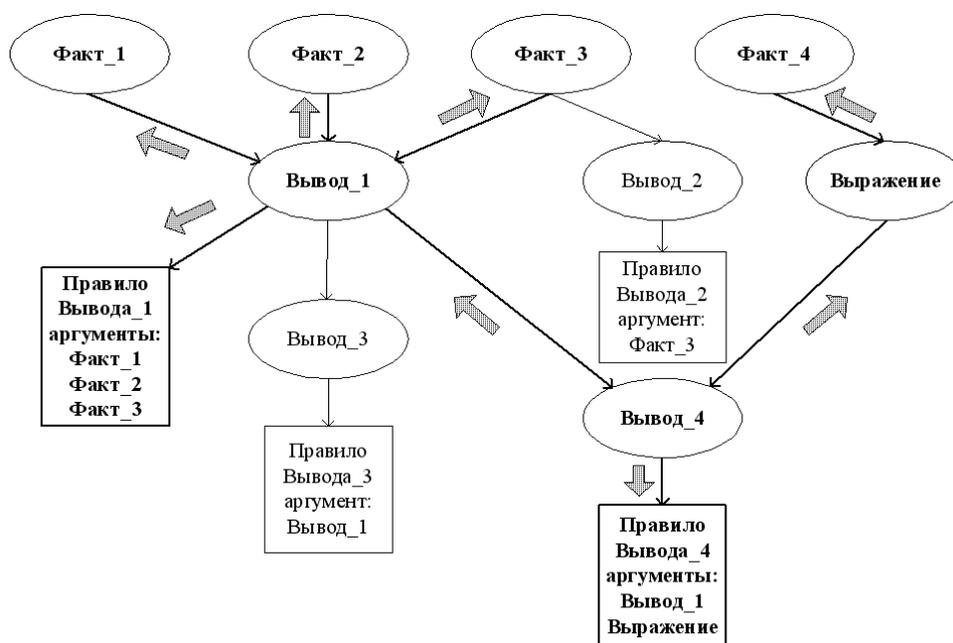


Рис. 4. Пример схемы обработки запроса для Вывода_4

Обработка запроса строится в такой последовательности:

1. По аргументам правила для *Вывода_4* выполняется рекурсивная восходящая процедура поиска тех фактов, от которых косвенно зависит *Вывод_4*. Такими фактами будут являться все четыре факта показанные на рисунке.
2. У пользователя запрашиваются исходные значения каждого из этих 4-ёх фактов, для которых требуется определить значение *Вывода_4*.
3. По полученным значениям *Факта_1*, *Факта_2* и *Факта_3* которые являются аргументами в правиле для *Вывода_1*, отыскивается значение этого вывода. Для этого просматриваются утверждения правила, и выбирается значение вывода из того утверждения, условиям которого удовлетворяют значения этих трёх фактов-аргументов.
4. Далее вычисляется значение *Выражения*, членом в котором является значение *Факта_4*.
5. В завершении определяется значение *Вывода_4*, для этого просматриваются утверждения правила и выбирается значение из того

утверждения, условиям которого удовлетворяют ранее полученные значения *Вывода_1* и *Выражения*.

Результат обработки запроса содержит значение *Вывода_4*, а также включает вычисленное значение *Выражения* и тексты логических утверждений, найденные при обработке двух правил, которые поясняют получение значения *Вывода_4*.

В процессе создания базы знаний к каждому её объекту можно прикрепить видео – и аудио – информацию, изображение или указать url-адрес. Дополнение такой информацией, например, логических утверждений, позволит полнее раскрыть их смысл, сделать более наглядными и убедительными для будущих пользователей базы знаний.

Рассмотренная структура базы знаний позволяет применять её для разработки экспертных систем при решении задач, в которых в зависимости от значений входных параметров-фактов, требуется получать ответы или консультации специалистов-экспертов.

Библиографический список

1. *Ф. Хейес-Рот, Д. Уотерман, Д. Ленат.* Построение экспертных систем // Москва «Мир» 1987.
2. *Игошин В.А., Игошин М.В.* Конструктор базы знаний (КоБаЗ) // Свидетельство о государственной регистрации программы для ЭВМ № 2016616641. Роспатент, заявка № 2016613710. Зарегистрировано в Реестре программ для ЭВМ 16 июня 2016г.

ABOUT ONE APPROACH TO CONSTRUCT THE STRUCTURE KNOWLEDGE BASE FOR EXPERT SYSTEM

Igoshin Vladimir A., Igoshin Mikhail V.

Individual Entrepreneur “Knowledge Engineering Technologies”

5 house, 45 quarter, Tchernyshevskogo st., Perm, 614002, Russia

igoshin-va@perm.ru, m.v.igoshin@gmail.com

The article describes the approach to building the structure of the knowledge base of an expert system to solve the problem in a narrow subject area, which, depending on the values of the input parameters of the facts required to get an answer or consult an expert. Describes in detail the composition included in the knowledge base of objects and their relationships, representation of knowledge in form of rules and technology for their input, as well as the opportunity to include additional video and audio information, images, and links in the form of URLs. Shows a general diagram of the processing of the request and searching for the answer with explanation of result, which can be practically used in the development of expert systems.

Keywords: knowledge base, tools for creation of knowledge bases, expert system.

АНАЛИЗ МЕТОДОВ БИНАРНОЙ КЛАССИФИКАЦИИ ДЛЯ ПРОГНОЗИРОВАНИЯ ПОСЛЕОПЕРАЦИОННЫХ ОСЛОЖНЕНИЙ У БОЛЬНЫХ ЖЕЛЧНО-КАМЕННОЙ БОЛЕЗНЬЮ

Горбаченко Владимир Иванович, Кузнецов Роман Николаевич, Кузнецова Ольга Юрьевна
Пензенский государственный университет, 440026, Россия, г. Пенза, ул. Красная, 40,
gorvi@mail.ru, nahab007@rambler.ru, ellekasandra@yandex.ru

Рассматривается задача бинарной классификации о принадлежности объекта, характеризующегося заданным вектором признаков, к одному из двух классов (наличие или отсутствие послеоперационных осложнений). Методам ROC-анализа проведен сравнительный анализ методов бинарной классификации.

Ключевые слова: прогнозирование послеоперационных осложнений, дискриминантный анализ, ROC-кривая, наивный байесовский классификатор, деревья решений, логистическая регрессия.

Задача бинарной классификации позволяет решить вопрос о принадлежности объекта к одному из двух классов. Пусть имеется конечное множество объектов $O = \{O_1 \dots O_n\}$, каждый из которых характеризуется m -мерным вектором признаков $(X_1 \dots X_m)$. Признаки являются числовыми данными (анализ крови). При этом для каждого представителя исходного множества известно, к какому классу он относится. Данные объекты образуют обучающую выборку. Необходимо построить алгоритм, способный определить для произвольного объекта из исходной выборки класс K_j , $j=1,2$ к которому следует отнести объект. Для решения сформулированной задачи могут быть использованы несколько методов классификации:

- Дискриминантный анализ.
- Деревья решений.
- Наивный байесовский классификатор.
- Логистическая регрессия.

Дискриминантный анализ. Для определения вероятности принадлежности объекта к одному из двух классов используют линейные функции [1]:

$$s_1(x) = q_0^1 + q_1^1 x_1 + \dots + q_m^1 x_m$$
$$s_2(x) = q_0^2 + q_1^2 x_1 + \dots + q_m^2 x_m,$$

где $q_1 \dots q_m$ – параметры (веса) регрессии, которые находятся, как правило, с помощью метода наименьших квадратов, $s(x)$ – «счет», который содержит достаточное количество информации для того, чтобы различать класс объекта. При этом выбирается тот класс, которому соответствует больший счет.

Деревья решений. Дерево решений представляет собой древовидный граф – структуру данных, состоящую из узлов принятия решений, соединенных друг с другом ребрами [2]. В дереве имеется один особый узел, именуемый корневым узлом. Другие особые узлы, находящиеся в конце любой цепочки подряд идущих ребер, называют листовыми узлами. Дерево строится на основании обучающей выборки, содержащей информацию о значениях входных переменных и соответствующих значениях прогнозируемого показателя. Узел принятия решений обеспечивает проверку условия на значение входной переменной, а каждое ребро обозначает один из возможных вариантов. Если корневому узлу соответствует всё множество данных, то в результате деления в узле принятия решений это множество разбивается на непересекающиеся подмножества. В каждом узле дерево решений выводит значение прогнозируемого показателя в зависимости от значений входных переменных. Чаще всего используются дихотомические деревья, когда из вершины выходит только две ветви. На сегодняшний день наиболее известным является алгоритм C4.5 – алгоритм построения деревьев с неограниченным количеством ветвей в узлах. Данный алгоритм использует теоретико-информационный подход [2]. Для выбора наиболее подходящего атрибута, предлагается следующий критерий:

$$Gain(X, T) = Info(T) - Info_x(T). \quad (1)$$

где $Info(T)$ – энтропия множества T , а

$$Info_x(T) = \sum_{i=1}^n \frac{|T_i|}{|T|} * Info(T_i),$$

Множества $T_1 \dots T_n$ получены при разбиении исходного множества T по проверке X . Выбирается атрибут, дающий максимальное значение по критерию (1).

Наивный байесовский классификатор. В основе байесовского подхода лежит принцип максимального использования имеющейся априорной информации о процессах, ее непрерывного пересмотра и переоценки с учетом получаемых выборочных данных [3, 4]. Применительно к задаче классификации используют так называемый наивный байесовский классификатор. В основе NBC (Naïve Bayes Classifier) лежит, теорема Байеса:

$$P(c|d) = \frac{P(d|c)P(c)}{P(d)},$$

$P(c|d)$ – апостериорная вероятность принадлежности к классу c для объекта d , $P(c)$ – априорная вероятность класса c , $P(d)$ – вероятность появления объекта d , $P(d|c)$ – вероятность появления объекта d в классе c .

Цель классификации состоит в том, чтобы понять к какому классу принадлежит объект, поэтому нам нужна не сама вероятность, а наиболее вероятный класс. Байесовский классификатор использует оценку апостериорного максимума (Maximum a posteriori estimation) для определения наиболее вероятного класса [4]. Грубо говоря, это класс с максимальной вероятностью.

$$C_{MAP} = \arg \max_{c \in C} P(c|d) = \arg \max_{c \in C} \frac{P(d|c)P(c)}{P(d)},$$

C_{MAP} – максимальная апостериорная вероятность класса.

Логистическая регрессия. Пусть y определяет принадлежность объекта к классу и принимает значение 1, если объект принадлежит классу K_1 , и значение 0, если объект принадлежит классу K_2 . Тогда делается предположение о том, что вероятность наступления события $y = 1$, равна [5]:

$$P\{y = 1 | x\} = f(z)$$

$$z = q^T x = q_0 + q_1 x_1 + \dots + q_m x_m,$$

где x – вектор-столбец независимых переменных $x_1 \dots x_m$, q – вектор-столбец параметров (коэффициентов регрессии) $q_1 \dots q_m$, $f(z)$ – логистическая функция (сигмоида, логит-функция):

$$f(z) = \frac{1}{1 + e^{-z}}.$$

Для оценки качества бинарной классификации прибегают в основном к методам ROC-анализа [6]. ROC-кривая, также известная как кривая ошибок, отображает соотношение между долей верных положительных классификаций от общего числа положительных классификаций (true positive rate) с долей ошибочных положительных классификаций от общего числа отрицательных классификаций (false positive rate) при варьировании порога решающего правила. Показатель AUC (площадь под ROC-кривой) дает количественную интерпретацию ROC-кривой. Считается, что чем выше показатель AUC, тем качественнее классификатор.

Для решения сформулированной задачи был использован статистический пакет StatSoft STATISTICA 10.0. Для сравнительного анализа результатов классификации была сформирована выборка, состоящая из 109 объектов, каждый из которых характеризуется 5 признаками (лейкоциты, нейтрофилы палочкоядерные, лимфоциты, общий билирубин, длительность оперативных вмешательств). Исходная выборка была разделена случайным образом на обучающую выборку (55%) и на тестовую выборку (45%). На рис. 1 изображены ROC-кривые моделей по данным контрольной выборки, а также показатель AUC для каждой модели (таблица 1).

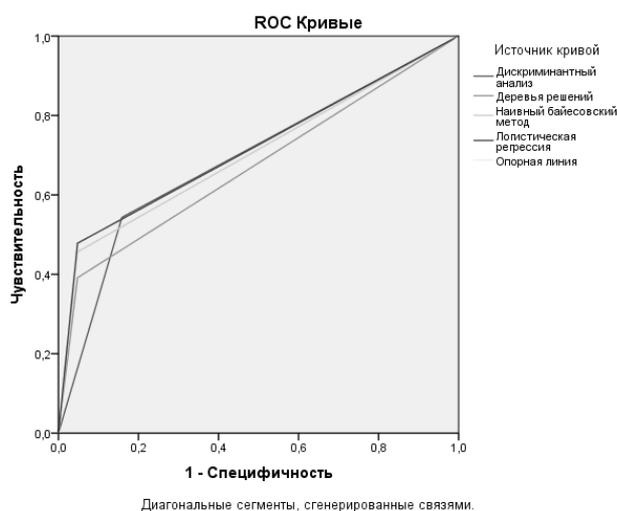


Рис. 1 - ROC-кривые: а) дискриминантный анализ, б) деревья решений, в) байесовский классификатор, г) логистическая регрессия

Таблица 1. Результаты классификации объектов различными моделями

Название модели	Показатель AUC	Верно классифицированные		Ошибочно классифицированные	
		количество	%	количество	%
дискриминантный анализ	0,692	78	71,56	31	28,44
деревья решений	0,672	78	71,56	31	28,44
наивный байесовский классификатор	0,704	81	74,31	28	25,69
логистическая регрессия	0,715	82	84,31	27	24,77

Результаты ROC-анализа, в том числе и показателя AUC показывают, что, на первый взгляд, расхождения моделей совершенно незначительны и сложно определить качество классификации. Однако при представлении результатов классификации пациентов о наличии или отсутствии послеоперационных осложнений в виде табл. 1, в которой отражено

количество верно и ошибочно классифицируемых пациентов, преимущество по точности классификации можно отдать методу логистической регрессии.

Библиографический список

1. Кобзарь, А.И. Прикладная математическая статистика / А.И. Кобзарь — М.: Физматлит, 2006. — 816 с.
2. Чубукова, И.А. Data Mining: учебное пособие. / И.А. Чубукова. – М.: Интернет–Университет Информационных Технологий; БИНОМ. Лаборатория знаний, 2006.
3. Наивный байесовский классификатор [Электронный ресурс] URL: <http://bazhenov.me/blog/2012/06/11/naive-bayes.html> (Дата обращения 26.05.2015).
4. Кубарев А.И., Поддубный В.В. Байесовская классификация с обучением на основе использования копула-функций // Информационные технологии и математическое моделирование (ИТММ-2013): Материалы XII Всероссийской научно-практической конференции с международным участием им. А.Ф. Терпугова (29-30 ноября 2013г.). – Томск: Изд-во Том. ун-та, 2013. – Ч.2. – С.126–130.
5. Айвазян С.А., Бухштабер В.М. Прикладная статистика: Классификация и снижение размерности: Справочное издание / С.А. Айвазян, В.М. Бухштабер, И.С. Енюков, Л.Д. Мешалкин / Под ред. С.А. Айвазяна. – М.: Финансы и статистика, 1989. – 608 с.
6. Паклин Н.Б., Орешков В.И. Бизнес-аналитика: от данных к знаниям // 5.6. Н.Б. Паклин, В.И. Орешков. – С.-Пб.: Питер, 2013.

ANALYSIS OF BINARY CLASSIFICATION METHODS TO PREDICT POSTOPERATIVE COMPLICATIONS IN PATIENTS WITH CHOLELITHIASIS

Gorbachenko Vladimir Ivanovich, Kuznetsov Roman Nikolaevich, Kuznetsova Olga Urevna
Penza state university, 40, Krasnaya street, Penza, 440026, Russia.
gorvi@mail.ru, nahab007@rambler.ru, ellekasandra@yandex.ru

It is considered the problem of binary classification of objects, described by the attributes vector, to any of two classes (the presence or absence of postoperative complications). It was performed a comparative analysis of binary classification methods using ROC-analysis method realized by means of StatSoft STATISTICA 10.0.

Key words: prediction of postoperative complications, discriminant analysis, ROC-curve, naive Bayes classifier, decision trees, logistic regression.

УДК 004.832.34

МЕТОД ГРУППОВОГО УЧЕТА АРГУМЕНТА В ЗАДАЧАХ ФОРМИРОВАНИЯ КЛАССИФИКАТОРОВ ДЛЯ ПРОГНОЗИРОВАНИЯ ПРОФЕССИОНАЛЬНЫХ ЗАБОЛЕВАНИЙ

Старцев Евгений Александрович, Ефремов Михаил Александрович
Юго-Западный государственный университет,
305040, Россия, г. Курск, ул. 50 лет Октября, 94, SFilist@gmail.com

Рассмотрены вопросы построения классификаторов на основе МГУА – моделей. Предложено на входе классификатора использовать дополнительный информативный признак, который формируется из исходного вектора информативных признаков на основе МГУА – моделирования. Нейронная сеть *NET* настраивается по обучающей выборке. После этого формируется совокупность моделей согласно алгоритму МГУА, реализующих скрытые связи между информативными признаками пространства. Модели ранжируются по адекватности описываемых ими связей. Выбирается наиболее адекватная модель, которая формирует дополнительный информативный признак. На основе исходной формируется новая обучающая выборка с дополнительным информативным признаком таким образом, чтобы дополнительный информативный признак не ухудшал качество классификации нейронной сети *NET*. Процесс формирования моделей (дополнительных признаков) может продолжаться до тех пор, пока ведение очередного дополнительного признака не приведет к улучшению качества классификации.

Ключевые слова: прогнозирование профессиональных заболеваний, классификатор, нейронные сети, МГУА-модели.

Исследования показали, что при построении решающих модулей по принятию решений по риску профессиональных заболеваний целесообразно вводить дополнительные информативные признаки, которые несут информации о скрытых связях между исходными признаками. Основным требованием к этим связям является то, что они должны отличаться у исследуемых альтернативных классов.

Таким образом, необходимо решить задачу, состоящую в обнаружении и моделировании некоторой закономерности

$$y = F(X), \quad (1)$$

связывающей множество информативных признаков $X = (x_1, x_2, \dots, x_N)$, используемых решающими модулями.

Поиск закономерностей осуществляется согласно обучающей выборке. При этом X – вектор экспериментальных данных, x_i ($i = \overline{1, N}$) – компоненты вектора X , определяемые посредством экспериментальных исследований и характеризующие каждое значение скаляра y_j ($j = \overline{1, M}$). Модель зависимости (1) должна хорошо аппроксимировать ее не только в точках y_j , но и в любой точке пространства, определяемого координатами x_i .

Особенность восстановления функциональных зависимостей состоит в том, что величина y_j является неизвестной величиной и определяется после выбора функциональной зависимости (1). Процесс моделирования включает два этапа: выбор подходящей модели и проверка адекватности модели на основе показателей качества классификации классификатора с дополнительным информативным признаком, формируемым посредством этой модели. На рисунке 1 представлена обобщенная структурная схема классифицирующего модуля, предназначенного для работы с дополненным на основе МГУА

– моделей пространством информативных признаков.

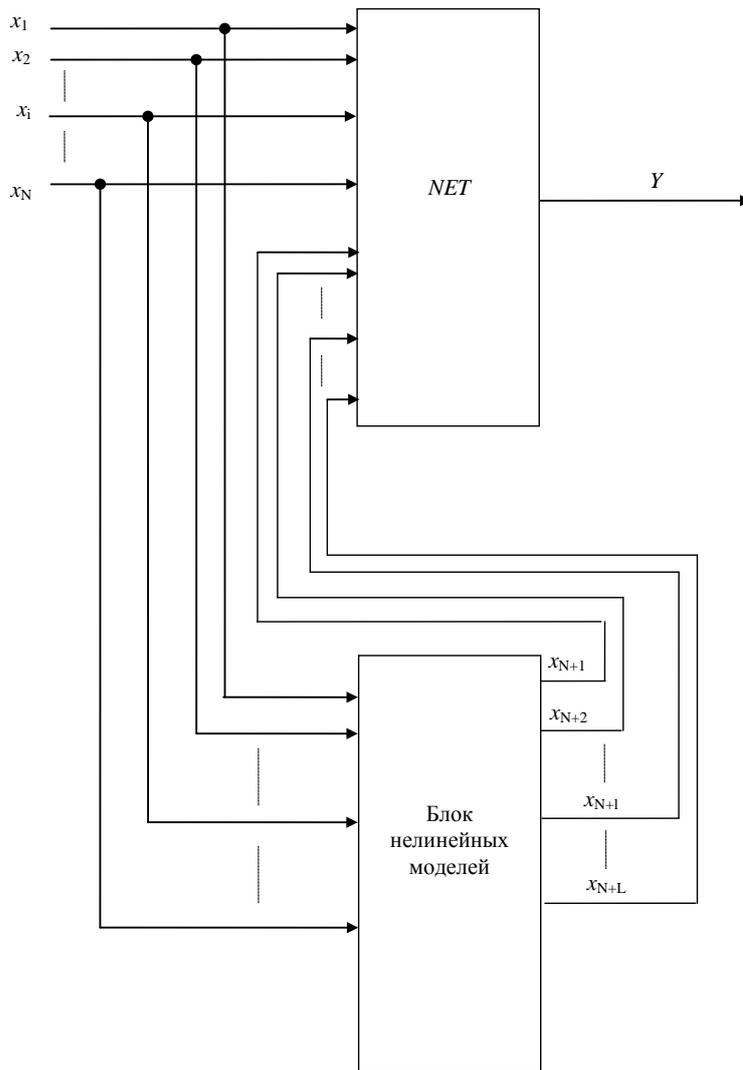


Рис. 1 - Обобщенная структурная схема классифицирующего модуля, предназначенного для работы с дополненным на основе МГУА – моделей пространством информативных признаков

Эта особенность заставляет сосредоточить внимание на правильном соотношении сложности приближающей функции с объемом обучающей выборки, так как имеющейся информации может не хватить для восстановления функции в точках y_j .

Представим полином, аппроксимирующий функцию (1), в общем виде

$$y = F(x_1, \dots, x_m), \quad (2)$$

В качестве такого полинома очень часто используется полином Колмогорова-Габора [1]:

$$y = \alpha_0 + \sum_{i=1}^m \alpha_i x_i + \sum_{i=1}^m \sum_{j=1}^m \alpha_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m \alpha_{ijk} x_i x_j x_k + \dots, \quad (3)$$

Эта сложная зависимость заменяется множеством простых функций:

$$y_1 = f(x_1, x_2); \quad y_2 = f(x_1, x_3), \dots, \quad y_s = f(x_{m-1}, x_m), \quad (4)$$

где $s = C_m^2$, причем функция f повсюду одинакова.

Очень часто в качестве функции f выбираются простые зависимости

$$y(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j \quad (5)$$

или

$$y(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j + a_4 x_i^2 + a_5 x_j^2, \quad (6)$$

связывающие только две переменные. Коэффициент этих зависимостей можно определить по МНК, имея соответственно 4 или 6 точек наблюдений в обучающей последовательности.

Среди моделей первого ряда выбираются несколько, например S^* наилучших, показавших хорошие результаты на проверочной выборке. Среди отобранных моделей остаются только те, которые «впитали» в себя нечто большее, чем хорошая аппроксимация в узлах интерполяции; они «угадывают» поведение функции (1) в области, не охваченной экспериментом. Во втором ряду алгоритма полученные на обучающей выборке значения y_i , соответствующие отобранным моделям, рассматриваются в качестве аргументов нового ряда:

$$z_1 = f(y_1, y_2); \quad z_2 = f(y_1, y_3); \dots; \quad z_{s^*} = f(y_{s^*-1}, y_{s^*}). \quad (7)$$

Здесь функция f остаются прежними и соответствуют соотношениям (5) или (6), но аргументами этих функций выступают переменные y_i . Коэффициенты новых моделей (7) находятся по МНК на точках той же обучающей последовательности. Новые модели проверяются на точках проверочной последовательности, и среди них выбирается S^* наилучших, которые используются в качестве аргументов следующего третьего ряда и т.д. Сложность полиномов возрастает от ряда к ряду. Так, например, во втором ряду будут получены полиномы, содержащие нелинейные члены вида $x_1^2, (x_1 x_3), (x_2 x_3), (x_1^2 x_3), (x_1^2 x_2 x_3)$ и т.д. Коэффициенты этих полиномов могут быть определены по тем же точкам обучающей последовательности и не требуют дополнительной информации, хотя их сложность все время возрастает. При этом число определяемых коэффициентов значительно превосходит число точек обучающей последовательности. Если бы не было внешнего дополнения, т.е. проверочной выборки, то алгоритмы МГУА благодаря сложности синтезируемых полиномов могли бы абсолютно точно аппроксимировать функцию (1) во всех точках обучающей выборки, но при этом не осталось бы никаких гарантий удовлетворенного поведения

восстанавливаемой функции на новых точках.

В схеме алгоритма МГУА имеются генераторы усложняющихся из ряда в ряд комбинаций и пороговые самоотборы лучших из них. Так называемое полное описание объекта

$$\varphi = f(x_1, x_2, x_3, \dots, x_m),$$

где f - некоторая элементарная функция. Например, степенной полином заменяется несколькими рядами «частных» описаний:

$$1\text{-й ряд селекции: } y_1 = f(x_1 x_2), y_2 = f(x_1 x_3), \dots, y_s = f(x_{m-1} x_m),$$

$$2\text{-й ряд селекции: } z_1 = f(y_1 y_2), z_2 = f_2(y_1 y_2), \dots, z_p = f(y_{s-1} y_s), \text{ где } s = c^2, p = c_s^2 \text{ и}$$

т.д.

Входные аргументы и промежуточные переменные сопрягаются попарно, и сложность комбинаций на каждом ряду обработки информации возрастает (как при массовой селекции), пока не будет получена единственная модель оптимальной сложности.

Из ряда в ряд селекции пропускается только некоторое количество самых регулярных переменных. Степень регулярности оценивается по величине среднеквадратичной ошибки (средней для всех выбираемых в каждом поколении переменных или для одной самой точной переменной) на отдельной проверочной последовательности данных. Иногда в качестве показателя регулярности используется коэффициент корреляции.

Ряды селекции наращиваются до тех пор, пока регулярность повышается. Как только достигнут минимум ошибки, селекцию, во избежание «инцухта», следует остановить. Практически рекомендуется остановить селекцию даже несколько раньше достижения полного минимума, как только ошибка начинает падать слишком медленно. Это приводит к более простым и более достоверным уравнениям [2].

Среди множества МГУА - моделей выбираем L наилучших, которые могут быть представлены в виде множества

$$\{f_\ell(X_k) = \tilde{y}\}, \quad (8)$$

где $X_k \subseteq X$, $X = (x_1, x_2, \dots, x_N)$ - множество информативных признаков используемых решающими модулями; $\ell = \overline{1, L}$.

Нейронная сеть *NET* настраивается по обучающей выборке. После этого формируется совокупность моделей согласно алгоритму МГУ, реализующих скрытые связи между информативными признаками пространства $X = (x_1, x_2, \dots, x_N)$. Модели ранжируются по

адекватности описываемых ими связей. Выбирается наиболее адекватная модель, которая формирует дополнительный информативный признак x_{N+1} , то есть на основе исходной, формируется новая обучающая выборка с дополнительным информативным признаком x_{N+1} . Выборка формируется таким образом, чтобы дополнительный информативный признак не ухудшал качество классификации нейронной сети *NET*.

Процесс формирования моделей (дополнительных признаков) может продолжаться до тех пор, пока ведение очередного дополнительного признака не приведет к улучшению качества классификации.

Библиографический список

1. *Васильев, В.И.* Взаимодополняемость метода группового учета аргументов (МГУА) и метода предельных/ А.В. Дедов, Г.А. Попов // Штучный интеллект. – 2001. - №1. – С. 29-42.
2. *Пидошва, Е.А.* Основные принципы метода группового учета аргументов и его перспективы/ Е.А. Пидошва, А.Б. Иващенко// Информационные управляющие системы и компьютерный мониторинг: материалы II Всеукр. науч.-техн. конф. студентов и мол. ученых, г. Донецк, 11-13 апр. 2011.- Донецк, 2011. - Т.1. - С. 129 -132.

ADAPTED TO STRUCTURE GIVEN QUALIFIERS IN PROBLEM OF THE FORECASTING OF THE PROFESSIONAL DISEASES

Startsev Evgeniy Aleksandrovich, Efremov Mihail Aleksandrovich

Southwestern State University, 305040, Russia, г. Kursk, st. 50 years of October, 94,
SFilist@gmail.com

The Considered questions of the building qualifier on base MGUA - a models. It Is Offered at the input qualifier to use additional информативный sign, which is formed from source vector информативных sign on base MGUA - modeling. Neyronnaya network NET tunes in on training sample. Hereon collection of the models is formed according to algorithm MGUA, realizing hidden relationship between информативными sign space. The Models are ranked on adequacy described by them relationships. It Is Chosen the most identical model, which forms additional информативный sign. On base source is formed new training sample with additional информативным by sign by so as additional информативный sign did not worsen the quality to categorizations нейронной network NET. The Process of the shaping the models (the additional sign) can last until conduct of the next additional sign will not bring about improvement quality to categorizations.

Keywords: risk forecasting of the professional diseases, qualifier, neurons to network, MGUA-models.

Научное издание

**ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ
В РЕШЕНИИ АКТУАЛЬНЫХ СОЦИАЛЬНЫХ
И ЭКОНОМИЧЕСКИХ ПРОБЛЕМ XXI ВЕКА**

Сборник статей по материалам
Второй всероссийской научно-практической конференции,
проводимой в рамках Пермского естественнонаучного форума
«Математика и глобальные вызовы XXI века»
(г. Пермь, 16–17 мая 2017 г.)

Издается в авторской редакции
Компьютерная верстка: *И. Н. Скачкова*

Подписано в печать 20.04.2017. Формат 60×84/16
Усл. печ. л. 14,36. Тираж 70 экз. Заказ 24

Издательский центр
Пермского государственного
национального исследовательского университета.
614990, г. Пермь, ул. Букирева, 15

ООО Учебный центр «ИНФОРМАТИКА».
614990, г. Пермь, ул. Букирева, 15

Спонсоры и партнеры:



МИНИСТЕРСТВО ОБРАЗОВАНИЯ
И НАУКИ ПЕРМСКОГО КРАЯ

**GALAGO
DIGITAL**

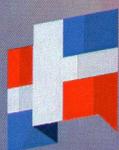
кноета



МОЗГОВО
инновационный центр



Ростелеком



Министерство
информационного
развития
и связи



АССОЦИАЦИЯ
"ИСТОРИЯ И
КОМПЬЮТЕР"

