



НАУКА

и глобальные вызовы
XXI века

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В РЕШЕНИИ АКТУАЛЬНЫХ СОЦИАЛЬНЫХ И ЭКОНОМИЧЕСКИХ ПРОБЛЕМ XXI ВЕКА

Сборник статей по материалам
Четвертой всероссийской научно-практической конференции,
проводимой в рамках Пермского естественнонаучного форума
«Математика и глобальные вызовы XXI века»

Часть I

г. Пермь, 21–23 мая 2019 г

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
Пермское отделение Научного совета РАН по методологии искусственного интеллекта

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В РЕШЕНИИ АКТУАЛЬНЫХ СОЦИАЛЬНЫХ И ЭКОНОМИЧЕСКИХ ПРОБЛЕМ XXI ВЕКА

Сборник статей по материалам
Четвертой всероссийской научно-практической конференции,
проводимой в рамках Пермского естественнонаучного форума
«Математика и глобальные вызовы XXI века»

(г. Пермь, 21–23 мая 2019 г.)

Часть I



Пермь 2019

УДК 004.8: 3
ББК 32.813 + 6/8
И868

Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Четвертой всерос. науч.-практ. конф. (г. Пермь, 21–24 мая 2019 г.) Ч. I. / Перм. гос. нац. исслед. ун-т. – Пермь, 2019. – 276 с.

ISBN 978-5-7944-3290-9 (ч. 1)
ISBN 978-5-7944-3289-3

В сборнике представлены материалы Четвертой всероссийской научно-практической конференции «Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века», которая проводилась 21–23 мая 2019 г. в г. Перми в рамках Пермского естественнонаучного форума «Математика и глобальные вызовы XXI века».

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

**УДК 004.8: 3
ББК 32.813 + 6/8**

*Печатается по решению кафедры прикладной математики и информатики
Пермского государственного национального исследовательского университета*

Редакционная коллегия

Кузнецов Андрей Геннадьевич, канд. техн. наук,
Левченко Елена Васильевна, д-р психол. 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

Ответственный редактор

Ясницкий Леонид Нахимович, д-р техн. наук,

*Сборник подготовлен при финансовой поддержке РФФИ: грант № 19-010-00307
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 978-5-7944-3290-9 (ч. 1)
ISBN 978-5-7944-3289-3

© ПГНИУ, 2019

Оглавление

ПЛЕНАРНЫЕ ДОКЛАДЫ	6
О НАУЧНОМ ПРИОРИТЕТЕ ПЕРМСКИХ УЧЕНЫХ В ОБЛАСТИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА	7
МАТЕМАТИЧЕСКИЕ МОДЕЛИ И АЛГОРИТМЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ДИАГНОСТИКЕ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ ПО ТЕРМОМЕТРИЧЕСКИМ ДАННЫМ	26
МЕТОДИЧЕСКИЕ ПРИЕМЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА	31
АЛГОРИТМ НАИВНОГО МЕТОДА БАЙЕСА В ЗАДАЧАХ БИНАРНОЙ КЛАССИФИКАЦИИ НА ПРИМЕРЕ НАБОРА ДАННЫХ SANTANDER С ПЛАТФОРМЫ KAGGLE	32
ОПЫТ ПРИМЕНЕНИЯ ДИФФЕРЕНЦИАЛЬНЫХ УРАВНЕНИЙ И НЕЙРОННЫХ СЕТЕЙ ДЛЯ РАСПОЗНАВАНИЯ ФИЗИЧЕСКИХ ЯВЛЕНИЙ НА ВИДЕОИЗОБРАЖЕНИЯХ	37
ГЕНЕТИЧЕСКИЙ АЛГОРИТМ ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ С ОДНИМ КРИТЕРИЕМ ОПТИМИЗАЦИИ ДЛЯ УПРАВЛЕНИЯ БЕСПИЛОТНЫМИ ЛЕТАТЕЛЬНЫМИ АППАРАТАМИ	44
СРАВНЕНИЕ МОДЕЛЕЙ КЛАССИФИКАЦИИ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ ГЛУБОКОГО ОБУЧЕНИЯ RESNET И VGG	50
ПОВЫШЕНИЕ КАЧЕСТВА ОБОБЩЕНИЯ НЕЙРОННОЙ СЕТИ С ПОМОЩЬЮ ДОБАВЛЕНИЯ ШУМА В ОБУЧАЮЩУЮ ВЫБОРКУ НА ПРИМЕРЕ ЗАДАЧИ ОПРЕДЕЛЕНИЯ ПРОЧНОСТИ БЕТОНА ПО СОСТАВУ ВХОДЯЩИХ В НЕГО КОМПОНЕНТОВ	57
МЕТОДЫ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ НЕЙРОСЕТЕВЫХ СИСТЕМ В УСЛОВИЯХ ОГРАНИЧЕННЫХ ОБЪЕМОВ ВЫБОРОК СО СЛОЖНЫМИ КОРРЕЛЯЦИОННЫМИ СВЯЗЯМИ	63
РОЛЬ ЭМОЦИЙ В АРХИТЕКТУРЕ ИСКУССТВЕННОГО АГЕНТА НА ПРИМЕРЕ КОНЦЕПЦИИ «НЕБРЕЖНЫХ КОГНИЦИЙ»	69
ЦИФРОВАЯ ЭКОНОМИКА	75
НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ РЫНКА СТОИМОСТИ АВТОМОБИЛЕЙ	76
ОПТИМИЗАЦИЯ АРХИТЕКТУРЫ НЕЙРОННОЙ СЕТИ ДЛЯ СОРТИРОВКИ МУСОРНЫХ ОТХОДОВ	82
НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ДЛЯ ПРОГНОЗИРОВАНИЯ УРОВНЯ ЗАНЯТОСТИ НАСЕЛЕНИЯ	84
ЭКОНОМИЧЕСКИЕ АСПЕКТЫ ВОСПРИЯТИЯ ЦИФРОВЫХ ТЕХНОЛОГИЙ НА ПРЕДПРИЯТИЯХ	89
САМОАДАПТИРУЕМАЯ НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ И ПРОГНОЗИРОВАНИЯ РЫНКОВ НЕДВИЖИМОСТИ НИЖНЕГО НОВГОРОДА И ПЕРМИ	93
ДИНАМИЧЕСКАЯ НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ ВТОРИЧНОГО РЫНКА ЖИЛОЙ НЕДВИЖИМОСТИ ГОРОДА ЕКАТЕРИНБУРГА	102
ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОЦЕНКИ СТОИМОСТИ КВАРТИР НА ПРИМЕРЕ РЫНКА НЕДВИЖИМОСТИ ПЕРМИ	112
ДИВЕРГЕНЦИЯ СЛОЖНОСТНОЙ РАЦИОНАЛЬНОСТИ СОЦИОТЕХНИЧЕСКИХ СИСТЕМ INDUSTRY 4.0: ЦИФРОФИЗИКА И НОВАЯ ИСКУССТВЕННОСТЬ	117

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ ЦЕН НА ЗОЛОТО.....	121
НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ ПОЛЬЗОВАТЕЛЬСКОГО СПРОСА И ОПТИМИЗАЦИЯ БИЗНЕСА В ОРГАНИЗАЦИЯХ ОБЩЕСТВЕННОГО ПИТАНИЯ	131
РАЗРАБОТКА И ПРИМЕНЕНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ОЦЕНКИ И ПРОГНОЗИРОВАНИЯ СТОИМОСТИ МОБИЛЬНЫХ ТЕЛЕФОНОВ НА ПРИМЕРЕ ВТОРИЧНОГО РЫНКА ПЕРМИ.....	136
АВТОМАТИЧЕСКОЙ КОНТРОЛЬ УРОВНЯ ОКАЗАНИЯ УСЛУГ ПРОДАВЦОМ- КОНСУЛЬТАНТОМ	145
НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ПРОГНОЗИРОВАНИЯ ПРОДАЖ ВИДЕОИГР В ПЕРВУЮ НЕДЕЛЮ ПОСЛЕ ВЫПУСКА	150
ЦИФРОВАЯ МЕДИЦИНА И ЦИФРОВОЕ ЗДРАВООХРАНЕНИЕ	155
ПРОГНОЗИРОВАНИЕ КОЭФФИЦИЕНТА ЕСТЕСТВЕННОГО ПРИРОСТА НАСЕЛЕНИЯ МЕТОДОМ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ.....	156
НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ ПРОДОЛЖИТЕЛЬНОСТИ ЖИЗНИ НАСЕЛЕНИЯ РЕГИОНОВ РОССИИ	162
НЕЙРОННАЯ СЕТЬ ГЛУБОКОЙ АРХИТЕКТУРЫ ДЛЯ ДИАГНОСТИКИ ПОСЛЕОПЕРАЦИОННЫХ ОСЛОЖНЕНИЙ АППЕНДИЦИТА	169
МЕТОД И АЛГОРИТМЫ СЕГМЕНТАЦИИ РЕНТГЕНОГРАММ МОЛОЧНОЙ ЖЕЛЕЗЫ	174
ВОЗМОЖНОСТИ ОРТОДОНТИЧЕСКОГО ЛЕЧЕНИЯ С ИСПОЛЬЗОВАНИЕМ КАПП НА ОСНОВЕ 3D МОДЕЛИРОВАНИЯ	179
РАННЯЯ ДИАГНОСТИКА ОСТРОГО КОРОНАРНОГО СИНДРОМА С ПОМОЩЬЮ НЕЙРОСЕТЕВОЙ ТЕХНОЛОГИИ.....	182
СИСТЕМА КОРРЕКЦИИ ФУНКЦИОНАЛЬНОГО СОСТОЯНИЯ ОРГАНИЗМА ЧЕЛОВЕКА НА ОСНОВЕ МЕДИЦИНСКОГО МОНИТОРИНГА ПАРАМЕТРОВ ВНУТРЕННИХ ОРГАНОВ	186
ЭФФЕКТИВНОСТЬ КЛАССИФИКАЦИИ И ВАРИАЦИИ ХАРАКТЕРНЫХ ОБЛАСТЕЙ ДВУМЕРНЫХ ТЕРМОМЕТРИЧЕСКИХ ПРИЗНАКОВ В ДИАГНОСТИКЕ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ.....	192
ИНТЕЛЛЕКТУАЛЬНАЯ ИНФОРМАЦИОННО-АНАЛИТИЧЕСКАЯ СРЕДА ДЛЯ МОНИТОРИНГА СОСТОЯНИЯ ОБУЧАЮЩИХСЯ.....	197
VI-RADS КЛАССИФИКАЦИЯ ТЕРМОМЕТРИЧЕСКИХ ДАННЫХ В ДИАГНОСТИКЕ МОЛОЧНЫХ ЖЕЛЕЗ	203
НЕЙРОННЫЕ СЕТИ В ДИАГНОСТИКЕ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ	208
НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ПРОДОЛЖИТЕЛЬНОСТИ ЖИЗНИ.....	213
ИНТЕРПРЕТАЦИИ МНОГОМЕРНЫХ ТЕРМОМЕТРИЧЕСКИХ ПРИЗНАКОВ В ДИАГНОСТИКЕ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ	218
БИОЭТИКА КАК ОСНОВА РАЗВИТИЯ СИСТЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В МЕДИЦИНЕ.....	223
НЕЙРОСЕТЕВАЯ СИСТЕМА ДИАГНОСТИКИ ЗЛОКАЧЕСТВЕННОГО ПЛЕВРАЛЬНОГО ВЫПОТА ПО ФОТОГРАФИЯМ ФАЦИЙ ПЛЕВРАЛЬНОЙ ЖИДКОСТИ, ПОЛУЧЕННЫХ МЕТОДОМ КЛИНОВИДНОЙ ДЕГИДРАТАЦИИ.....	228
НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ДИАГНОСТИКИ И ПРОГНОЗИРОВАНИЕ ГИПОТОНИИ.....	234

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ПРОГНОЗИРОВАНИЕ ОПАСНОСТИ ЗАБОЛЕВАНИЯ СЕРДЕЧНО-СОСУДЕСТОЙ СИСТЕМЫ	238
ПРОГНОЗИРОВАНИЕ КОЭФФИЦИЕНТА ЕСТЕСТВЕННОГО ПРИРОСТА НАСЕЛЕНИЯ РЕГИОНОВ РОССИИ ПРИ ПОМОЩИ НЕЙРОСЕТЕЙ.....	243
НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ РАСЧЁТА ДОЗИРОВКИ ИНСУЛИНА ДЛЯ БОЛЬНЫХ САХАРНЫМ ДИАБЕТОМ	248
ПОВЫШЕНИЕ КАЧЕСТВА ЛЕЧЕНИЯ ДИАБЕТИЧЕСКОГО МАКУЛЯРНОГО ОТЕКА НА ОСНОВЕ ТЕХНОЛОГИИ АВТОМАТИЧЕСКОГО ФОРМИРОВАНИЯ ПЛАНА КОАГУЛЯТОВ	252
ЦИФРОВАЯ ПРОМЫШЛЕННОСТЬ	258
СИСТЕМА СОРТИРОВКИ ПУСТЫХ КОНТЕЙНЕРОВ В АВТОМАТАХ ПО СБОРУ ИСПОЛЬЗОВАННОЙ ТАРЫ	259
НЕЙРОСЕТЕВОЙ АЛГОРИТМ РАСПОЗНОВАНИЯ БРАКА ОТЛИВОК НА РЕНГЕНОВСКИХ СНИМКАХ	264
ПРОГНОЗИРОВАНИЕ МАССОРАСХОДНЫХ ХАРАКТЕРИСТИК НЕФТЕПРОВОДА НА ОСНОВЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ.....	268
АНАЛИЗ И СИНТЕЗ НЕЧЕТКИХ РЕГУЛЯТОРОВ.....	272

ПЛЕНАРНЫЕ ДОКЛАДЫ

«Думаю она [Конференция] хорошо отображает тот факт, что ваша Пермская школа и ваша системная деятельность – лучшее, что есть в нашей стране в области многоплановой разработки проблем ИИ.»

Д.И.Дубровский, Сопредседатель Научного совета РАН по методологии искусственного интеллекта, д.ф.н., профессор.

УДК 004.89; 616.34

О НАУЧНОМ ПРИОРИТЕТЕ ПЕРМСКИХ УЧЕНЫХ В ОБЛАСТИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Ясницкий Леонид Нахимович

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

Обзор охватывает работы пермских ученых, в которых развиваются и применяются методы искусственного интеллекта в классическом понимании, т.е., моделирующие интеллектуальную деятельность человека путем имитации природных механизмов. Это экспертные системы, генетические алгоритмы, нейронные сети, нечеткая математика. Отмечается научный приоритет пермских ученых в области развития теоретических основ и практических приложений искусственного интеллекта.

Ключевые слова: научный приоритет, искусственный интеллект, нейронная сеть, экспертная система, генетический алгоритм, теория, практика, моделирование, прогнозирование, оптимизация, распознавание, обработка данных, извлечение знаний.

Своим появлением в Перми искусственный интеллект обязан организатору и научному руководителю первого в Перми вычислительного центра, созданного на базе Пермского государственного университета (позднее переименован в Пермский государственный национальный исследовательский университет), основателю кафедры прикладной математики Юрию Владимировичу Девингталю. В вычислительном центре им была сформирована исследовательская группа, занимавшаяся распознаванием образов. Его работы 1968 – 1976 гг. [16, 17] положили начало пермским исследованиям в области искусственного интеллекта.

В 1973 Л.Н.Ясницкий [78] предложил оригинальный метод точного аналитического решения краевых задач теории гармонических функций и

линейной теории упругости, впоследствии названный методом фиктивных канонических областей (ФКО) [72, 75, 87, 103-105]. Для реализации метода ФКО была создана интеллектуальная система, моделирующая знания, интуицию и опыт классических математиков XIX – XX веков [7, 56, 57, 62, 86, 88]. Развитию метода ФКО и его применению посвящена защищенная в 2006 году кандидатская диссертация С.Л. Гладкого [5]. Его программа REGIONS (<http://inec.pspu.ru/regions/>) является уникальной, не имеющей аналогов, экспертной системой, успешно примененной для прочностных расчетов и проектирования инженерных конструкций ответственного назначения [6, 7-12, 18, 23, 26, 42, 67, 71, 72, 77].

В 2001 г. выходит в свет книга Л.Н.Ясницкого «Введение в искусственный интеллект» [56], посвященная памяти Юрия Владимировича Девингталя. Книга является учебно-методическим пособием и охватывает широкий круг вопросов – от проблем творчества, сочинения стихов и музыкальных произведений до решения краевых задач математической физики. Впоследствии книга становится достаточно популярной и по данным eLIBRARY на три ее последних издания [57] зафиксировано более 300 цитирований.

В 2001 г. начинается проект создания нейросетевой системы диагностики авиационных двигателей. Работа выполняется в сотрудничестве с ОАО «Авиадвигатель». В ПГНИУ поставляются сведения о дефектах, обнаруженных при исследовании двигателей, прибывших в ремонт, а также комплекс полетных параметров, характеризующих работу двигателя за время эксплуатации на самолёте. Таким образом, формируются обучающие и тестирующие множества примеров, создается нейронная сеть, на вход которой подаются параметры двигателя в полете, а с выхода снимаются сведения о его дефектах.

Нейронная сеть обучается и проходит тестовые испытания на примерах, которых не было в обучающем множестве. Устраиваются дополнительные проверки. Ученым предоставляется комплекс полетных параметров авиадвигателя без указания сведений о его дефектах. Параметры подаются на вход нейронной сети, и она ставит диагнозы, которые сравниваются с результатами заводских исследований, полученными при разборке двигателя [29].

По одному из двигателей нейросеть ставит диагноз «Появление стружки в масле», совпадающий с результатами заводских исследований. Между тем экспертный анализ специалистами ОАО «Авиадвигатель» показал отсутствие изменения параметров двигателя (температура, давление и др.), которые могли бы быть вызваны появлением указанного дефекта. Следовательно, нейросеть, на вход которой подаются именно эти параметры двигателя, принципиально не должна ставить диагноз «стружка в масле». Но она его ставит, и оказывается права... Складывается впечатление, что нейронная сеть принимает правильные решения, используя информацию, недостаточную с точки зрения традиционной логики. В жизни это свойство мозга принято называть «интуицией» или «шестым чувством». В связи с

этим в работе [57] высказывается мнение, что нейронная сеть, выполненная «по образу и подобию» мозга, унаследовала от своего прототипа и это замечательное свойство.

Но специалисты ОАО «Авиадвигатель» предлагают более приземленные объяснения парадокса. По их мнению, нейросеть могла среагировать на изменения конфигурации деталей, вызванные загрязнением лопаток проточной части, приработкой деталей или на совокупность изменений параметров внешних условий и соответствующих изменений параметров, характеризующих техническое состояние двигателя.

Окончательно был сделан вывод о том, что нейросеть способна в неявном виде более точно определять индивидуальные характеристики двигателей, чем традиционные инженерные методы анализа параметров. Другой предполагаемой способностью нейросети является возможность выявления таких изменений параметров, которые не были предусмотрены специалистами при разработке традиционных алгоритмов диагностирования авиационных двигателей.

Впоследствии мы не раз наблюдали, как нейросети ставили правильные диагнозы и выполняли подтвердившиеся впоследствии прогнозы, объяснить которые в рамках традиционной логики было затруднительно, а термины «интуиция» и «шестое чувство нейронных сетей», впервые введенные в книге [57], стали употребляться многими авторами.

В 2003 г. появляется идея создания нейросетевого детектора лжи. Главный полиграфолог Пермского края полковник Аскольд Маркович Петров проводит экскурсию для пермских ученых. Его полиграфный аппарат системы «Эпос-7» безошибочно уличает всех желающих его обмануть. Ученые выражают свое восхищение, но Аскольд Маркович возражает. Оказывается, три года назад с помощью детектора лжи им было раскрыто преступление, и за него был посажен человек. А совсем недавно с повинной явился настоящий преступник. Оказывается, штатный детектор лжи, применяемый в МВД России, может ошибаться. Причем, довольно часто. Согласно паспортным данным погрешность заключений полиграфного аппарата Эпос-7 составляет 30%.

Причина низкой точности штатного детектора лжи обусловлена тем, что к разным людям, по-разному реагирующим на стрессовые ситуации, применяется одна и та же система решающих правил. Между тем известно, что у одних людей при ложном ответе дыхание учащается, а у других – наоборот замедляется. Аналогично ведут себя артериальное давление, частота сердечных сокращений и т.д. Учесть это обстоятельство и создать интеллектуальную систему, которая настраивалась на каждого конкретного человека и учитывала индивидуальные особенности его организма, позволила нейронная сеть, спроектированная и обученная благодаря долгой и кропотливой работе коллектива сотрудников Управления внутренних дел (УВД) Пермского края, ПГПУ и ПГНИУ [20, 37, 80, 81]. Наиболее результативной оказалась схема нейронной сети с комбинированным вводом параметров респондента и защищенная в кандидатской диссертации

З.И.Сичинавы. Данные об индивидуальных особенностях организма респондента в его нейронную сеть подавались с заранее составленной анкеты. Погрешность нейросетевого полиграфного аппарата в разных вариантах исполнения составила от 3,5 до 19,8 %, что значительно ниже погрешности штатных полиграфных аппаратов, применяемых в МВД и других госструктурах РФ.

В 2005 году это был первый в мире нейросетевой интеллектуальный детектор лжи [37].

Постепенно клеймо «лженауки» с искусственного интеллекта снимается не только на официальном уровне, а нейронные сети перестают называть «тупиковым научным направлением». Их включают в государственные образовательные стандарты вузов. В 2005 г. в ПГГПУ создается кафедра прикладной информатики, на базе которой открывается Пермское отделение Научного Совета РАН по методологии искусственного интеллекта (www.PermAi.ru). В план его работы вошли темы, уже ставшие традиционными. Это разработка систем искусственного интеллекта для решения задач диагностики сложных технических устройств [29, 67, 68], систем медицинской диагностики человека [63, 64, 65, 100-102], систем прогнозирования фондовых рынков [41], систем прогнозирования расхода электрической и тепловой энергии предприятиями бюджетной сферы [2], моделирование творческого процесса математика-профессионала, выполняющего решение краевых задач [7, 56] и др.

В 2007 году в книге [67], а также в статьях [79, 90] были опубликованы результаты уникальной попытки применения аппарата нейросетевого моделирования в области политологии – была спрогнозирована победа Д.Медведева за полтора года до президентских выборов 2008 г., когда его личность как политика еще была мало известна. В работах [79, 90], опубликованных в 2008 и 2010 гг., когда президент Д. Медведев был на вершине своей популярности, ему прогнозировалось снижение рейтинга, тогда как другому политику – В.Жириновскому, прогнозные кривые предсказали постепенный рост популярности, что и наблюдалось в последующие годы.

В 2012 г. факультет государственного управления Московского государственного университета им. М.В.Ломоносова перепечатал методику и результаты сбывшихся политических прогнозов пермских ученых в качестве вводной статьи в своем сборнике научных трудов [91].

В 2013 г. закончился финансируемый Правительством Пермского края и Группой компаний ИВС проект создания медицинской диагностической системы, выполняемый совместно с ПГМУ имени академика Е.А.Вагнера. Обученная на тысячах данных о реальных кардиологических больных, нейронная сеть с достаточно высокой точностью ставит диагнозы наиболее распространенных заболеваний сердечно-сосудистой системы [64]. Применение компьютерной диагностической системы на сегодняшний день наиболее актуально в отдаленных селах, где отсутствуют высококвалифицированные специалисты и медицинское

оборудование. Кроме того, по мнению авторитетных врачей-кардиологов, выявленные в результате исследования нейросетевой системы новые медицинские знания имеют как научное, так и практическое значение [63-65, 100-102].

К этому следует добавить, что в мире сейчас существуют сотни нейросетевых систем медицинской диагностики, однако только система, разработанная пермскими учеными, помимо диагностики, умеет выполнять долгосрочное прогнозирование развития заболеваний на 5, 10 и 15 лет вперед, а также управлять этими прогнозами – подбирать оптимальный образ жизни и лечения больных, желающих улучшить свои прогнозные показатели здоровья.

В 2014 году защищает докторскую диссертацию А.Л.Гусев. С помощью Нейропакета [33] и оригинальной методики функциональной предобработки входных сигналов [15] ему удалось разработать и внедрить меры по оптимизации деятельности Роспотребнадзора в области гигиенической безопасности населения некоторых регионов РФ [61, 66].

Пионерскими можно назвать работы, посвященные применению нейросетевых технологий для моделирования успеваемости студентов [38] и их будущей успешности [73], что позволяет оптимизировать траектории обучения студентов.

Пермскими учеными реализованы десятки проектов в самых различных областях. Результаты некоторых проектов, хотя и были в свое время опубликованы в научных журналах, выглядели весьма необычными и даже вызвали сомнения. Теперь же их можно считать признанными научной общественностью, а прогнозы, выполненные с помощью интеллектуальных систем, подтвердились произошедшими событиями либо выполненными экспериментами. Результаты некоторых проектов получили внедрение. Однако большинство из них являются инициативными, доведены только до демонстрационных прототипов и ждут своих потребителей. Это проекты создания интеллектуальных систем, позволяющих выявлять способности людей, например, способности к руководящей деятельности, к занятиям наукой и бизнесом [68, 82]. Такие программы способны также выявлять склонность человека к воровству, алкоголизму, наркомании [60], депрессии [31], к насилию и серийным убийствам [55] и т.п. В отличие от широко применяемых психологических тестов эти программы, в силу своей интеллектуальной базы, обучены на реальном жизненном опыте и используют выявленные из этого опыта закономерности, а потому объективны по своей природе и имеют более высокую точность.

В свое время в средствах массовой информации были опубликованы результаты наших прогнозов относительно Олимпиады–2014 (www.perm.aif.ru/society/people/1034930). Были также опубликованы [58] полученные в результате исследования математических моделей рекомендации по корректировке системы подготовки спортсменов, которые были доведены до сведения и учтены некоторыми российскими тренерами, например А.Н.Мишиным: <http://www.poisknews.ru/theme/infosphere/8916/>.

По этому поводу следует заметить, что спортивная тема у нас является сравнительно новой и выполняется пока как инициативная, без финансовой поддержки, причем главным образом силами студентов пермских вузов. И то, что опубликовано в СМИ, – это лишь небольшая часть всего, что можно сделать в области спортивной науки с помощью имеющихся у нас интеллектуальных инструментов.

Наиболее адекватные математические модели нам удалось получить для одиночных видов спорта, например, для фигурного катания, легкой атлетики [58, 70]. Такие модели можно использовать не только для прогнозов результатов будущих состязаний, но и для оптимизации программ подготовки спортсменов, обеспечивающих их наилучшие результаты. Могут также быть получены рекомендации по улучшению результативности спортивных команд [51].

Отметим, что нейросетевыми технологиями в настоящее время активно овладевают многие научные коллективы, как в России, так и за рубежом. Однако теоретическая база этих технологий пока что развита очень слабо, поэтому успех создания качественных нейросетевых математических моделей во многом зависит от опыта и интуиции их создателей. Каждая научная школа имеет свою историю, традиции, свои собственные наработки, методы, опыт, ноу-хау. И Пермское отделение Научного Совета РАН не является исключением. Его опыт, наработки и инструменты могут быть применены для создания интеллектуальных систем, предназначенных для оптимизации подготовки спортсменов, для разработки рекомендаций, учитывающих их индивидуальные параметры и особенности, которые человеческому глазу не заметны.

Необходимо отметить, что в Перми выполняются теоретические исследования, направленные на познание самой природы человеческого мышления с целью развития методологической и инструментальной баз искусственного интеллекта. Так, в работе [32] предложена модификация генетического алгоритма, расширяющая дарвиновское учение путем добавления факторов, действующих в социальной сфере – самосовершенствованием особей. В работе [43] предложен нейросетевой алгоритм выявления выбросов статистической информации. В работе [22] рассмотрены вопросы выбора оптимального количества обучающих примеров в задачах распознавания образов. В работах [13, 14] предложен метод повышения точности нейросетевых моделей путем удалением примеров из обучающего множества, выпадающих из общей закономерности. В работе [57] введено понятие и продемонстрировано на примере проявление свойства интуиции нейронных сетей.

В Перми созданы основы теории эмоциональных роботов [34-36]. Делаются попытки решения проблемы невербальности нейронных сетей [46], исследования границ их применимости [44], делаются прогнозы и обсуждаются вопросы прогнозирования будущего искусственного интеллекта [67, 83]. Делаются доклады и публикуются статьи, защищающие

приоритет Советской и Российской науки в области искусственного интеллекта [59, 76].

Немалый прогресс достигнут в разработке методики преподавания искусственного интеллекта в системе высшего образования. До 2000 г. из всех пермских вузов искусственный интеллект преподавался только в одном – на механико-математическом факультете Пермского государственного университета. Теперь методы построения интеллектуальных информационных систем изучаются практически во всех пермских вузах. Разработан лабораторный практикум (www.PermAi.ru), выпущены учебные пособия и учебники [57, 68], которыми пользуются студенты и преподаватели во многих городах России.

Цель одного из наших последних проектов – сделать изучение искусственного интеллекта доступным не только для студентов, но и для школьников [39]. С этой целью совместно с Издательством «БИНОМ. Лаборатория знаний» (Москва) создан элективный учебно-методический комплекс (<http://gazeta.lbz.ru/2012/1/1nomer.pdf>), предназначенный для преподавания искусственного интеллекта в старших классах общеобразовательных школ [69, 89].

Со временем проект создания научной школы искусственного интеллекта в Перми стал по-настоящему междисциплинарным. В его выполнение были вовлечены практически все пермские вузы и многие IT-фирмы, среди которых Российский государственный университет туризма и сервиса, Пермский государственный медицинский университет имени академика Е.А.Вагнера, Национальный исследовательский университет «Высшая школа экономики», Группа компаний «Информационно-вычислительные системы», Федеральный научный центр медико-профилактических технологий управления рисками здоровью населения, Пермский национальный исследовательский политехнический университет. Отсюда и разнообразие практических применений методов искусственного интеллекта. Благодаря такому сотрудничеству представители Пермской научной школы искусственного интеллекта имеют определенный приоритет. Они в числе первых продемонстрировали возможности применения методов искусственного интеллекта в таких областях как промышленность, экономика, политология, психология, педагогика, гигиена, спорт, криминалистика, экология, медицина.

Представители Пермской научной школы искусственного интеллекта:

- **первыми** применили методы искусственного интеллекта для решения краевых задач математической физики, выполнив прочностные расчеты ряда инженерных конструкций ответственного назначения (промышленность, 1973г.) [56, 75, 77, 78];

- **одними из первых** показали возможность применения нейронных сетей для диагностики авиационных двигателей, продемонстрировав свойство интуиции нейронных сетей (промышленность, психология, 2005г.) [57, 68];

- **первыми в России** создали нейросетевую систему оценки стоимости городских квартир и показали эффективность нейросетевых технологий для анализа рынка недвижимости (экономика, 2008г.) [53], в т.ч., с учетом меняющихся макроэкономических факторов (экономика, 2017г. [1, 92, 93];

- **одними из первых** применили аппарат нейросетевого моделирования для прогнозирования и предотвращения банкротства российских банков (экономика, бизнес, 2014г.) [74];

- **первыми** создали нейросетевую систему выявления предрасположенности подростков к наркомании, способную давать рекомендации по снижению этой зависимости (психология, 2015г.) [60];

- **первыми** показали возможность применения нейросетей в следственной практике для выявления серийных маньяков-убийц (криминалистика, 2015г.) [55];

- **одними из первых** показали возможность применения нейросетей для прогнозирования результатов спортивных состязаний и разработки рекомендаций по улучшению показателей спортсменов и спортивных команд (спорт, 2014) [51, 58, 70];

- **первыми** создали нейросетевой детектор лжи и показали его эффективность (психология, криминалистика, 2010г.) [80, 81, 84, 85];

- **первыми** создали и внедрили интеллектуальную систему оценки акмеологического потенциала студентов, способную прогнозировать их будущую успешность и подбирать наиболее оптимальные траектории обучения (психология, педагогика, 2014г.) [74];

- **первыми** создали основы математической теории эмоциональных роботов (психология, кибернетика, 2009г.) [34-36];

- **первыми** создали интеллектуальную медицинскую систему, способную не только ставить диагнозы заболеваний, но и прогнозировать их появление и развитие во времени, а также подбирать оптимальные курсы лечения и профилактики заболеваний (медицина, 2005) [57, 63-65, 100-102];

- **первыми** создали и внедрили в инструктивные материалы Роспотребнадзора интеллектуальную систему, позволяющую воздействовать на здоровье населения России посредством влияния на экологическую обстановку ее регионов (экология, гигиена, здравоохранение, 2010г.) [61, 66].

- **одними из первых** применили нейронные сети для прогнозирования результатов голосований и разработке рекомендаций по улучшению рейтинга политических деятелей (политология, 2008г.) [79, 90];

- **одними из первых** применили нейронные сети для прогнозирования и оптимизации кассовых сборов кинофильмов (кинематография, бизнес, 2017г.) [52].

- **одними из первых** применили нейронные сети для распознавания старопечатных текстов (лингвистика, 2011г.) [30];

- **первыми** применили нейронные сети для выявления способностей человека к бизнесу [82], к руководящей и научной деятельности [68] и показали возможность разработки на этой основе рекомендаций по усилению этих способностей (психология, 2010г.).

- **первыми** показали возможность применения нейронных сетей для подбора наиболее подходящих для клиента туристических маршрутов (туризм, 2010г.) [54].

- и т.д.

Многие из вышеназванных тем в наше время уже не кажутся новыми. Они активно продолжаются и развиваются другими исследователями.

С 2010 года на кафедре «Вычислительная математика и механика» ПНИПУ под руководством профессоров В.Ю.Столбова, М.Б.Гитмана и доцента А.В.Клюева ведутся научные разработки в области теории искусственного интеллекта и его приложений. Здесь следует отметить работы, посвященные применению методов компьютерного зрения для решения задач сегментации сложных объектов по их цифровым фотографиям. Разработаны алгоритмы визуализации границ зёрен, применяемые при решении задач сегментации сложных зёренных структур металлических сплавов и идентификации их параметров. Для вычисления градиента яркости в изображении при нахождении границ используется нелинейный оператор Ли и Харалика, который по сравнению с линейными методами Собеля, Прюитта и другими проявляет низкую чувствительность к шуму, что позволяет добиться наилучшей точности и производительности обработки фотографий микрошлифов [28, 47-50, 98, 99]. Предложен гибридный метод распознавания контуров на DICOM-изображении, включающий три основных этапа: размытие, выделение границ и сохранение границ. Данный подход был использован при решении задачи выделения границ печени человека, где условия работы были наиболее сложными ввиду наличия малоразличимых градаций серого на снимках и сильной неоднородности границ контуров распознаваемых объектов. Хотя многие известные методы выделения границ основываются на вычислении градиента изображения, они отличаются типами фильтров, применяемых для вычисления градиентов в различном направлении. Предлагаемый авторами подход использует несколько уже существующих методов выделения границ с определенными параметрами поиска контуров для достижения более точного результата распознавания DICOM-изображения [24, 25]. При этом обоснована наилучшая комбинация применяемых методов для решения задачи распознавания контура печени человека по DICOM-изображению.

В последние годы сотрудниками кафедры разрабатываются алгоритмы решения интеллектуальных задач на основе нейросетевых технологий. Предложены алгоритмы решения задач сегментации и классификации сложных объектов с помощью сверточных нейросетей глубокого обучения. Рассмотрены вопросы влияния данных обучающего множества на точность решения задач, исследованы различные архитектуры нейросетей и их возможности при решении задач в различных предметных областях [22, 40, 96, 97].

Отдельно можно рассмотреть работы сотрудников кафедры, посвященные методам решения интеллектуальных задач в области управления сложными социально-техническими системами. Предложены

методы комплексного оценивания эксплуатационных свойств функциональных материалов на основе теории нечетких множеств [27, 94, 95] и принятия коллективных решений в условиях неопределенности в производственных системах [3, 4]. Разработаны экспертные системы поддержки принятия решений в образовательных системах, основанные на мультиагентных технологиях [19] и генетических алгоритмах [45], а также при оценивании инновационных проектов на основе фреймовой модели представления знаний [95].

В 2018 году в Пермском национальном исследовательском политехническом университете под председательством профессора В.Ю. Столбова открыт диссертационный совет по специальностям: 05.13.01 – Системный анализ, управление и обработка информации; 05.13.10 – Управление в социальных и экономических системах. Совет ориентируется на кандидатские и докторские диссертации, преимущественно направленные на развитие и применение методов искусственного интеллекта.

Благодарности. Статья подготовлена при поддержке Российского фонда фундаментальных исследований: грант 19-010-00307.

Библиографический список

1. Алексеев А.О., Харитонов В.А., Ясницкий В.Л. Разработка концепции комплексного нейросетевого моделирования процессов массовой оценки и сценарного прогнозирования рыночной стоимости жилой недвижимости // Известия вузов. Инвестиции. Строительство. Недвижимость. 2018. Т. 8. № 1 (24). С. 11–22.
2. Бондарь В.В., Малинин Н.А., Ясницкий Л.Н. Нейросетевой прогноз потребления электроэнергии, анализ значащих факторов и разработка полезных рекомендаций // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2006. № 4. С. 10–17.
3. Вожаков А.В., Гитман М.Б., Столбов В.Ю. Модели принятия коллективных решений в производственных системах // Управление большими системами. 2015. Выпуск 58. С.161-17.
4. Вожаков А.В., Гитман М.Б., Столбов В.Ю. Алгоритм принятия управленческих решений на базе ситуационного центра промышленного предприятия // Автоматизация в промышленности. 2014. № 8. С.8-12
5. Гладкий С.Л. Развитие и применение метода фиктивных канонических областей // Дисс... канд. физ.-мат. наук. Пермь, 2007.
6. Гладкий С.Л., Семенова А.В., Степанов Н.А., Ясницкий Л.Н. Компьютерное моделирование и оптимизация процесса получения искусственно-керамических покрытий // Вестник Пермского государственного технического университета. Динамика и прочность машин. 2005. № 5. С.142–149.
7. Гладкий С.Л., Степанов Н.А., Ясницкий Л.Н. Интеллектуальное моделирование физических проблем. М.-Ижевск: НИЦ Регулярная и хаотическая динамика, 2006. 200 с.

8. Гладкий С.Л., Таланцев Н.Ф., Ясницкий Л.Н. Верификация численных расчетов методом фиктивных канонических областей // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2006. № 4. С.18–27.
9. Гладкий С.Л., Тарунин Е.Л., Ясницкий Л.Н. Применение метода фиктивных канонических областей в задачах электростатики // Вестник Пермского университета. Сер. Физика. 2011. № 3. С. 96–102.
10. Гладкий С.Л., Ясницкий Л.Н. Об оценке погрешности метода фиктивных канонических областей // Известия Российской академии наук. Механика твердого тела. 2002. № 6. С. 69–75.
11. Гладкий С.Л., Ясницкий Л.Н. Решение трехмерных задач теплопроводности методом фиктивных канонических областей // Вестник Пермского университета. Сер. Математика. Механика. Информатика. 2011. № 5. С. 41–45.
12. Горчаков А.И., Семенова А.В., Сыроватская Ю.В., Щербаков Ю.В., Ясницкий Л.Н. Влияние геометрических параметров микродугового оксидирования на равномерность покрытий, формируемых на алюминиевых сплавах // Физика и химия обработки материалов. 2004. № 1. С. 43–47.
13. Гусев А.Л. Выбор информационного пространства для построения нейронной сети, как модели управления, в условиях зашумленных и неполных данных // Нейрокомпьютеры: разработка, применение. 2011. № 7. С. 55–57.
14. Гусев А.Л., Окунев А.А. Методы сжатия информационного пространства при прогнозировании в условиях неполноты информации // В книге: Нейрокомпьютеры и их применение Тезисы докладов. 2017. С. 190–191.
15. Гусев А.Л., Черепанов Ф.М., Ясницкий Л.Н. Функциональная предобработка входных сигналов нейронной сети // Нейрокомпьютеры: разработка, применение. 2013. № 5. С. 19–21.
16. Девингталь Ю.В. Об оптимальном кодировании объектов при классификации их методами распознавания образов // Известия Российской академии наук. Техническая кибернетика. 1968. № 1. С. 162–168.
17. Девингталь Ю.В. Кодирование объектов при использовании разделяющей гиперплоскости для их классификации // Известия Российской академии наук. Техническая кибернетика. 1976. Вып. 1. С. 68–72.
18. Добрынин Г.Ф., Ясницкий Л.Н. Прочностные расчеты изоляторов // Стекло и керамика. 1994. № 7. С. 40–43.
19. Закирова Э.А., Столбов В.Ю. Мультиагентная система поддержки принятия решений при отборе студентов в магистратуру вуза // Системы управления и информационные технологии. 2014. №1.1.(55) С.146-151.

20. Зибатова А.Н., Петров А.М., Сичинава З.И., Сошников А.П., Ясницкий Л.Н. Интеллектуальный полиграф // Российский полиграф. 2006. № 1. С. 76-83.
21. Истомина Д.А., Гитман М.Б., Трефилов В.А. Фреймовая модель представления знаний для методик оценивания инновационных проектов // Нейрокомпьютеры: разработка, применение. 2018. №2. С. 12-22.
22. Каракулов И.В., Ключев А.В. Влияние размеров объекта обучающей выборки на качество сегментации методами искусственного интеллекта // Прикладная математика и вопросы управления. 2018. №3. С.89-99
23. Кирко И.М., Терровере В.Р., Ясницкий Л.Н. Новая оптимальная форма маховичного накопителя // Доклады Академии наук СССР. Техническая физика. 1989. Т. 307, № 6. С. 1373–1375.
24. Клестов Р.А., Столбов В.Ю. Гибридный метод распознавания контуров на изображении на основе технологий компьютерного зрения // Труды 27-й Международной конференции по компьютерной графике и машинному зрению «Графикон-2017» (Пермь, 24-28 сентября 2017 г.) / Пермь: Изд-во ПГНИУ. 2017. С.208-211.
25. Клестов Р.А., Столбов В.Ю. Разработка прототипа автоматизированной системы поддержки принятия решений при поиске контуров на изображениях формата DICOM // Материалы 11-й Всероссийской школы-конференции молодых ученых «УБС-2017» (Пермь, 4-8 сентября 2017 г.) / Пермь: Изд-во ПНИПУ, 2017. С. 599-607.
26. Клименко И.П., Ясницкий Л.Н. К расчету деформированного состояния втулки плунжерной пары методом фиктивных канонических областей // Известия вузов. Машиностроение. 1991. № 4–6. С. 32–34.
27. Ключев А.В., Гитман М.Б., Столбов В.Ю. Об одном подходе к решению задачи дискриминантного анализа микроструктур функциональных материалов по комплексу физико-механических характеристик // Прикладная математика и вопросы управления 2016. №4. С.63-85.
28. Ключев А.В., Столбов В.Ю., Шарыбин С.И. Визуализация сложных зеренных структур металлов и сплавов при идентификации их параметров // Научная визуализация. 2016. Т.8. №3. С. 95-101.
29. Конев С.В., Сичинава З.И., Ясницкий Л.Н. Применение нейросетевых технологий для диагностики неисправностей авиационных двигателей. Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2005. № 2 (2). С. 43–47.
30. Корниенко С.И., Айдаров Ю.Р., Гагарина Д.А., Черепанов Ф.М., Ясницкий Л.Н. Программный комплекс для распознавания рукописных и старопечатных текстов // Информационные ресурсы России. 2011. № 1 (119). С. 35–37.
31. Левченко Е.В., Митрофанов И.А., Ясницкий Л.Н. Нейросетевое моделирование феномена депрессии // В сборнике: Искусственный интеллект в решении актуальных социальных и экономических

- проблем XXI века. Сборник статей по материалам Третьей всероссийской научно-практической конференции, С. 139-143.
32. Мурашов Д.И., Ясницкий Л.Н. Социальный генетический алгоритм // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2006. № 4 (4). С. 53–60.
 33. Нейросимулятор 5.0 : Свидетельство Роспатент о государственной регистрации программы для ЭВМ № 2014618208 от 12.07.2014 г. / Черепанов Ф.М., Ясницкий Л.Н. (РФ).
 34. Пенский О.Г., Зонова П.О., Муравьев А.Н. и др. Гипотезы и алгоритмы математической теории исчисления эмоций: монография. Пермь: Перм. гос. ун-т, 2009. 152 с.
 35. Пенский О.Г. Математические модели эмоциональных роботов: монография. Пермь: Перм. гос. ун-т, 2010. 192 с.
 36. Пенский О.Г., Черников К.В. Основы математической теории эмоциональных роботов // Монография / Перм. Гос. Ун-т. Пермь, 2010. 256с
 37. Петров А.М., Ясницкий Л.Н. Возможности создания нейросетевого полиграфа. Вестник Пермского университета. Сер. Математика. Механика. Информатика. 2005. № 2. С. 43–47.
 38. Посохина К.А., Русаков С.В. Отбор информативных признаков, влияющих на отчисление студентов механико-математического факультета // В сборнике: Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века. 2018. С. 184-188.
 39. Семакин И.Г., Ясницкий Л.Н. Искусственный интеллект и школьный курс информатики // Информатика и образование. 2010. № 9. С. 48–54.
 40. Столбов В.Ю., Ключев А.В., Аристов Г.В. Распознавание микроструктуры материалов с применением сверточных нейросетей // В сборнике: Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века. Пермь: Изд-во ПГНИУ, 2016. С. 166-171.
 41. Тимошенко А.С., Ясницкий Л.Н. Препроцессинг, построение и выбор оптимальных нейросетевых моделей в прогнозировании временных рядов // Автоматизация и современные технологии. 2010. № 6. С. 16–22
 42. Томилов В.А., Клименко И.П., Ясницкий Л.Н. Стабилизация величины зазора плунжерной пары за счет упругих деформаций плунжера // Проблемы машиностроения и надежности машин. 1994. № 4. С. 109–113.
 43. Черепанов Ф.М., Ясницкий Л.Н. Нейросетевой фильтр для исключения выбросов в статистической информации // Вестник Пермского университета. Сер. Математика. Механика. Информатика. 2008. № 4. С. 151–155.
 44. Чечулин В.Л., Ясницкий Л.Н. Некоторые ограничения алгоритмически реализуемых нейронных сетей // Нейрокомпьютеры: разработка, применение. 2010. № 12. С. 3–6.

45. Чугунов А.П., Столбов В.Ю. Применение генетического алгоритма для решения задачи построения индивидуальных учебных планов в условиях сетевого взаимодействия вузов // Системы управления и информационные технологии. 2016. № 4. С.101-106.
46. Чуприна С.И., Гадиатулин Р. Rule-Mining: подход к автоматизированному извлечению онтологий // Proc. of the XIII-th International Conference «Knowledge-Dialogue-Solution» (KDS 2007), June 17–25, 2007, Varna (Bulgaria). Sofia, С. 445–451.
47. Шарыбин С.И., Ключев А.В., Столбов В.Ю. Сравнение методов распознавания образов в задачах поиска характерных зеренных микроструктур на фотографиях шлифов металлов и сплавов // Изв. вузов. Черная металлургия. 2012. № 9. С. 49-53.
48. Шарыбин С.И., Столбов В.Ю., Гитман М.Б., Барышников М.В. Разработка интеллектуальной системы распознавания сложных микроструктур на шлифах металлов и сплавов // Нейрокомпьютеры: разработка, применение. 2014. №.12 С.50-56.
49. Шарыбин С.И., Столбов В.Ю. Об одном подходе к решению задач анализа и классификации сложных микроструктур на шлифах металлов и сплавов // Прикладная математика и вопросы управления. – 2015. – №1. –С.89-99.
50. Шарыбин С.И., Столбов В.Ю. Система распознавания сложных мезоструктур металлов и сплавов // В сборнике: XII Всероссийское совещание по проблемам управления (ВСПУ-2014, ИПУ РАН, Москва). М.: ИПУ РАН, 2014. С.8489-8497
51. 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. 2015. № 5. С. 15-20.
52. Ясницкий Л.Н., Белобородова Н.О., Медведева Е.Ю. Методика нейросетевого прогнозирования кассовых сборов кинофильмов // Финансовая аналитика: проблемы и решения. 2017. Т. 10. № 4 (334). С. 449-463.
53. Ясницкий Л.Н., Бондарь В.В., Полещук А.Н., Федорищев И.Ф., Черепанов Ф.М. и др. Пермская научная школа искусственного интеллекта и ее инновационные проекты. 2-е изд. М.-Ижевск: НИЦ «Регулярная и хаотическая динамика», 2008. 75 с.
54. Ясницкий Л.Н., Бржевальская А.С., Черепанов Ф.М. О возможностях применения методов искусственного интеллекта в сфере туризма // Сервис plus. 2010. № 4. С. 111–115.
55. 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.

56. Ясницкий Л.Н. Введение в искусственный интеллект. Пермь: Изд-во Перм. ун-та, 2001. 143 с.
57. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Изд. центр «Академия», 2005. 176 с.
58. Ясницкий Л.Н., Внукова О.В., Черепанов Ф.М. Прогноз результатов олимпиады-2014 в мужском одиночном фигурном катании методами искусственного интеллекта // Современные проблемы науки и образования. 2014. № 1; URL: <http://www.science-education.ru/115-11339> (дата обращения: 25.12.2013).
59. Ясницкий Л.Н. Гильберт, Колмогоров, Арнольд, искусственный интеллект и современный кризис прикладной математики (К 70-летию со дня рождения В.И.Арнольда) // Вопросы искусственного интеллекта. 2008. № 1. С. 77–80.
60. Ясницкий Л.Н., Грацилёв В.И., Куляшова Ю.С., Черепанов Ф.М. Возможности моделирования предрасположенности к наркозависимости методами искусственного интеллекта // Вестник Пермского университета. Философия. Психология. Социология. 2015. № 1 (21). С. 61-73.
61. Ясницкий Л.Н., Гусев А.Л., Шур П.З. О возможностях применения нейросетевого математического моделирования для выявления целесообразных действий Роспотребнадзора // Вестник Пермского университета. Сер. Биология. 2010. № 3. С. 49–53.
62. Ясницкий Л.Н., Данилевич Т.В. Современные проблемы науки. М.: БИНОМ. Лаборатория знаний, 2008. 294 с.
63. 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.
64. 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. № 4. С. 77–86.
65. Ясницкий Л.Н., Думлер А.А., Черепанов Ф.М. Новые возможности применения методов искусственного интеллекта для моделирования появления и развития заболеваний и оптимизации их профилактики и лечения // Терапия. 2018. № 1 (19). С. 109–118.
66. Ясницкий Л.Н., Зайцева Н.В., Гусев А.Л., Шур П.З. Нейросетевая модель региона для выбора управляющих воздействий в области обеспечения гигиенической безопасности // Информатика и системы управления. 2011. № 3 (29). С. 51–59.
67. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы / Перм. ун-т. Пермь, 2007. 271 с.
68. Ясницкий Л.Н. Интеллектуальные системы : учебник. М.: Лаборатория знаний, 2016. 221 с.

69. Ясницкий Л.Н. Искусственный интеллект. Элективный курс: учеб. пособие. М.: БИНОМ. Лаборатория знаний, 2011. 240 с.
70. Ясницкий Л.Н., Киросова А.В., Ратегова А.В., Черепанов Ф.М. Методика нейросетевого прогнозирования результатов спортивных состязаний на примере чемпионата мира-2015 по легкой атлетике // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2014. № 3 (26). С. 90-97.
71. Ясницкий Л.Н. К расчету напряженного состояния эллипсоидальной оболочки постоянной и переменной толщины на основе решений теории упругости для сферических областей // Прикладная механика. 1989. Т. 25. № 6. С. 111–114.
72. Ясницкий Л.Н. Композиция расчетной области в методе фиктивных канонических областей // Известия Академии наук СССР. Механика твердого тела. 1990. № 6. С. 168–172.
73. Ясницкий Л.Н., Кузнецов А.Г., Селезнева С.М., Солохина А.Д., Тюлькина Д.В., Черепанов Ф.М. Применение нейросетевых технологий в изучении акмеологического потенциала студентов вуза // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2014. № 4 (27). С. 120-126.
74. Ясницкий Л.Н., Иванов Д.В., Липатова Е.В. Нейросетевая система оценки вероятности банкротства банков // Бизнес-информатика. 2014. № 3. С. 49-56.
75. Ясницкий Л.Н. Метод фиктивных канонических областей в механике сплошных сред. М.: Наука, ФИЗМАТЛИТ, 1992. 128 с.
76. Ясницкий Л.Н. О приоритете Советской науки в области нейроинформатики. В память о профессоре Александре Ивановиче Галушкине // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века. Сборник статей по материалам Второй всероссийской научно-практической конференции. 2017. С. 8-11.
77. Ясницкий Л.Н. Обзор работ по развитию и применению метода фиктивных канонических областей в научных и инженерных проблемах // Современные проблемы науки и образования. 2012. № 4; URL: <http://www.science-education.ru/104-6786> (дата обращения: 27.07.2012).
78. Ясницкий Л.Н. Об одном способе решения задач теории гармонических функций и линейной теории упругости // Прочностные и гидравлические характеристики машин и конструкций. 1973. С. 78–83.
79. Ясницкий Л.Н. О возможностях применения методов искусственного интеллекта в политологии // Вестник Пермского университета. Серия: Политология. 2008. № 2 (4). С. 147–155.
80. Ясницкий Л.Н., Петров А.М., Сичинава З.И. Сравнительный анализ алгоритмов нейросетевого детектирования лжи // Известия высших

- учебных заведений. Поволжский регион. Технические науки. 2010. № 1 (13). С. 64–72.
81. Ясницкий Л.Н., Петров А.М., Сичинава З.И. Технологии построения детектора лжи на основе аппарата искусственных нейронных сетей // Информационные технологии. 2010. № 11. С. 66–70.
82. Ясницкий Л.Н., Порошина А.М., Тавафиев А.Ф. Цвет глаз предпринимателя и успешность бизнеса. Нейросетевые технологии как инструмент для прогнозирования успешности предпринимательской деятельности // Российское предпринимательство. 2010. № 4-2. С. 8–13.
83. Ясницкий Л.Н. Поучительное прошлое, блестящее настоящее и сомнительное будущее искусственного интеллекта // В сборнике: Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века. 2018. С. 9-13.
84. Ясницкий Л.Н., Сичинава З.И. Нейросетевые алгоритмы анализа поведения респондентов // Нейрокомпьютеры: разработка и применение. 2011. № 10. С. 59–64.
85. Ясницкий Л.Н., Сичинава З.И., Черепанов Ф.М. Нейросетевой детектор лжи: принципы построения и опыт разработки. Saarbrücken (Germany): LAP LAMBERT Academic Publishing GmbH & Co. KG., 2012. 115 p.
86. Ясницкий Л.Н. Современный кризис прикладной математики и перспективы его преодоления // Вестник Пермского университета. Сер. Математика. Механика. Информатика. 2007. № 7. С. 192–197.
87. Ясницкий Л.Н. Суперпозиция базисных решений в методах типа Треффтца // Известия Академии наук СССР. Механика твердого тела. 1989. № 2. С. 95–101.
88. Ясницкий Л.Н. Удержаться «на плечах гигантов» (вводная статья) // Тр. семинара «Компьютерные методы в механике сплошной среды». 2006–2007 гг. / под ред. А.Л.Смирнова, Е.Ф.Жигалко. СПб.: Изд-во С.-Петербург. ун-та, 2008. С. 3–15.
89. Ясницкий Л.Н., Черепанов Ф.М. Искусственный интеллект. Элективный курс: Методическое пособие по преподаванию. М.: БИНОМ. Лаборатория знаний, 2012. 216 с.
90. Ясницкий Л.Н., Черепанов Ф.М. О возможностях применения нейросетевых технологий в политологии // Нейрокомпьютеры: разработка, применение. 2010. № 8. С. 47–53.
91. Ясницкий Л.Н., Черепанов Ф.М. Применение нейросетевых технологий в политологии (Вводная статья) // Нейрокомпьютерная парадигма и общество / под ред. Ю.Ю.Петрунина. М.: Изд-во Моск. ун-та, 2012. С. 13–25.
92. 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.

93. Alexeev A.O., Alexeeva I.E., Yasnitsky L.N., Yasnitsky V.L. Self-adaptive Intelligent System for Mass Evaluation of Real Estate Market in Cities // *Advances in Intelligent Systems and Computing*, 2019. Vol 850. Pp. 81-87.
94. Gitman M. B., Kluev A.V. and Stolbov V. Yu. Complex estimation of strength properties of functional materials on the basis of the analysis of parameters of grain-phase structure// *Strength of Materials*, Vol. 48, No. 6, July, 2016. Pp. 242-247.
95. Gitman I.M., Klyuev A.V., Gitman M.B. and Stolbov V.Yu. Multi-scale Approach for Strength Properties Estimation in Functional Materials // *ZAMM Zeitschrift fur Angewandte Mathematik und Mechanik*, 2018. Vol.98 No.6. Pp. 945-953.
96. Klestov R., Klyuev A., Stolbov V. About some approaches to problem of metals and alloys microstructures classification based on neural network technologies // *Advances in Engineering Research (AER)*. 2018. Vol. 157. Pp. 292-296.
97. Klyuev A., Klestov R., Bartolomey M., Rogozhnikov A. Recommendation System for Material Scientists Based on Deep learn Neural Network // *AISC*. 2018. Vol. 850. Pp. 224-231.
98. Sharybin S.I., Klyuev A.V., Stolbov V.Yu. Complex grain structure of metals and alloys // *Steel in translation*. Vol. 43. No 5. May 2013. Pp. 245-248.
99. Stolbov V.Yu., Gitman M.B. Sharybin S.L. Application of intelligent technology in functional materials quality assurance // *Materials Science Forum*. Vol. 870. 2016. Pp. 717-724.
100. Yasnitsky L.N., Bogdanov K.V., Cherepanov F.M., Makurina T.V., Dumler A.A., Chugaynov S.V., Poleschuk A.N. Diagnosis and Prognosis of Cardiovascular Diseases on the Basis of Neural Networks // *Biomedical Engineering*. 2013. T. 47. № 3. C. 160–163.
101. Yasnitsky L.N., Dumler A.A., Cherepanov F.M. The Capabilities of Artificial Intelligence to Simulate the Emergence and Development of Diseases, Optimize Prevention and Treatment Thereof, and Identify New Medical Knowledge // *Journal of Pharmaceutical Science and Research*. 2018. Vol. 10(9). Pp. 2192-2200.
102. Yasnitsky L.N., Dumler A.A., Poleshuk 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. T. 7. № 2. C. BM-095-15.
103. Yasnitsky L.N. Fictitious canonic regions method and boundary elements method // *Boundary Elements Communications*. 1995. V. 6. № 2. P. 62–63.
104. Yasnitsky L.N. Fictitious canonic regions method. Southampton-Boston: Computational Mechanics Publications, 1994. 120 p.
105. Yasnitsky L.N. The possibilities of error estimation in the boundary element type methods // *Boundary Elements Communications*. 1994. V. 5. № 4. P.181–182.

ON THE SCIENTIFIC PRIORITY OF THE PERM SCIENTISTS IN THE FIELD OF ARTIFICIAL INTELLIGENCE

Yasnitsky Leonid N.
Perm State University
Str. Bukireva, 15, Perm, Russia, 614990, yasn@psu.ru

The review covers the work of Perm scientists, which develop and apply the methods of artificial intelligence in the classical sense: modeling human intellectual activity by simulating natural mechanisms. These are expert systems, genetic algorithms, neural networks, fuzzy mathematics. The scientific priority of Perm scientists in the development of theoretical foundations and practical applications of artificial intelligence is noted.

Keywords: artificial intelligence, neural network, expert system, genetic algorithm, theory, practice, modeling, forecasting, optimization, recognition, data processing, knowledge extraction.

МАТЕМАТИЧЕСКИЕ МОДЕЛИ И АЛГОРИТМЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ДИАГНОСТИКЕ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ ПО ТЕРМОМЕТРИЧЕСКИМ ДАННЫМ

Лосев Александр Георгиевич

Волгоградский государственный университет,
400062, Россия, г. Волгоград, пр-т. Университетский, 100,
alexander.losev@volsu.ru

Исследование выполнено в рамках разработки фундаментальных основ ранней дифференциальной диагностики заболеваний молочных желез на основе метода микроволновой радиотермометрии с использованием математического моделирования и алгоритмов машинного обучения. Предлагаемая технология предполагает совместное использование специфических методов интеллектуального анализа термометрических данных и результатов моделирования пространственно-временных распределений температур внутри молочных желез, что существенно увеличит чувствительность и специфичность метода при скрининге и ранней дифференциальной диагностике.

Ключевые слова: микроволновая термометрия, математические модели, интеллектуальный анализ данных.

Создание методик медицинской диагностики, основанных на интеграции инженерных разработок, медицинских знаний, а также математического моделирования и методов машинного обучения, является в настоящее время крайне актуальной задачей. Одновременно отметим одну из наиболее сложных и актуальных задач медицины, которой является проблема ранней дифференциальной диагностики рака молочных желез. Одним из наиболее перспективных для повышения эффективности ранней дифференциальной диагностики видится метод микроволновой радиотермометрии [1]. Он основан на измерении собственного электромагнитного излучения тканей человека в микроволновом диапазоне длин волн и инфракрасном диапазоне, что позволяет неинвазивно выявлять температурные аномалии на глубине нескольких сантиметров.

В течение последних двух десятилетий данный метод получил распространение в различных областях медицины (маммология, онкология, флебология, хирургия и др.). Одновременно возник и ряд проблем. Одна связана с разработкой адекватных математических моделей теплообменных

процессов в молочной железе с учетом влияния теплофизических параметров внутренних тканей. Вторая заключается в разработке методов, алгоритмов и программных средств обработки, качественного и количественного анализа термометрической и другой медицинской информации о пациенте.

Первые попытки применения микроволновой радиотермометрии для диагностики рака молочной железы были предприняты в последней четверти 20-го века [2-3]. В данных работах были предложены и первые математические модели, описывающие температурные поля молочных желез в терминах решений уравнений с частными производными. Дальнейшие исследования показали, что в подобных моделях следует учитывать физико-химические свойства биотканей, выбор реологической модели крови, сложное внутреннее строение молочных желез и ряд других параметров (см., например, [4-5]). Приведем основные положения одной из предлагаемых математических моделей [5]. Она основана на построении и анализе поведения решений дифференциального уравнения

$$\rho(\vec{r})c_p(\vec{r}) \frac{\partial T}{\partial t}(\vec{r}, t) = \nabla(k(\vec{r})\nabla T(\vec{r}, t)) + Q_{\text{met}}(\vec{r}, t) + Q_{\text{car}}(\vec{r}, t) + Q_{\text{bl}}(\vec{r}, t) - Q_{\text{rad}}(\vec{r}, t), \quad (1)$$

определяющего динамику тепла. В ее рамках распределение температуры $T(\vec{r}, t)$ определяется коэффициентом теплопроводности $k(\vec{r})$, источниками тепла, обусловленными метаболическими процессами Q_{met} , раковыми образованиями Q_{car} , кровотоками Q_{bl} и радиационным охлаждением Q_{rad} . Плотность вещества $\rho(\vec{r})$ и удельная теплоемкость при постоянном давлении $c_p(\vec{r})$ считаются параметрами модели.

Одновременно, в ходе медицинских обследований и анализа данных микроволновой радиотермометрии специалистами был выявлен ряд качественных признаков рака молочной железы (см., например, [1], [5-7]). В том числе у пациенток с патологией отмечается наличие повышенной величины термоасимметрии между одноименными точками молочных желез; повышенный разброс температур между отдельными точками в пораженной молочной железе; повышенная 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 и некоторые другие. Появились и первые работы, посвященные анализу областей изменения функций, описывающих наличие аномалий поведения температурных полей внутри органов человека [5-7]. Также появились и первые исследования, посвященные применению методов интеллектуального анализа данных и разработки алгоритмов классификации в данной области [6-10]. Таким образом, созданы все предпосылки для создания эффективной консультативной интеллектуальной системы ранней дифференциальной диагностики рака молочной железы на основе данных термометрии.

Применяемая в настоящее время методика диагностики рака молочной железы на основе данных микроволновой радиотермометрии основана на оценке функционального состояния тканей путем измерения внутренней

температуры на глубине до 5 см. и температуры кожи. Обследование пациентки начинается с измерения температур в опорных точках, расположенных, первая – в центре грудной клетки сразу под и между молочными железами, вторая – непосредственно под мечевидным отростком. Далее измерения температур проводятся в 10 точках на каждой железе, и в аксиллярной области, после чего производится визуализация полученных данных, результаты которой выводятся на монитор [1], [5].

Сформулируем основные гипотезы поведения температурных полей молочных желез, на базе которых проводится анализ термометрических данных. Во-первых, это гипотеза «зеркальной» симметрии температурных полей правой и левой молочных желез здоровых пациенток. Она исходит из симметричного внутреннего строения парных органов человека. Следовательно, коэффициенты уравнения (1) и краевые условия для математических моделей правой и левой молочных желез в случае нормы отличаются незначительно. Как следствие у здоровых пациенток значения температур в зеркально симметричных точках должны отличаться незначительно. Данная гипотеза используется при анализе термометрических данных не только молочных желез, но практически всех парных органов человека [11]. Заметим, что в некоторых случаях у здоровых пациенток разность температур с симметричных точек может оказаться достаточно большой: до 2.5 градусов в РТМ-диапазоне и 3.5 градусов в ИК-диапазоне. Впрочем, у больных пациенток данный показатель может достигать до 6 градусов. Одновременно, далеко не у всех больных пациенток наблюдается значительная термоасимметрия.

Для анализа данных на предмет выполнения данной гипотезы предлагается использовать функционалы вида $TAS = \|T_L(\vec{r}) - T_R(\vec{r})\|$, где $T_L(\vec{r})$ и $T_R(\vec{r})$ – температуры в левой и правой молочных железах. В частности, возможно применение следующих величин: $p_1(T_L, T_R) = \max_{\vec{r} \in M} |T_L(\vec{r}) - T_R(\vec{r})|$, $p_2(T_L, T_R) = \max_{\vec{r} \in M} |\nabla(T_L(\vec{r}) - T_R(\vec{r}))|$, $p_3(T_L, T_R) = \max_{\vec{r} \in M} \|D^2(T_L(\vec{r}) - T_R(\vec{r}))\|$, $p_4(T_L, T_R) = \sup_{\Omega \subset M} \frac{1}{|\Omega|} \int_{\Omega} |T_L(\vec{r}) - T_R(\vec{r})| dr$, вариаций Харди, вариаций Арела и других норм, нолунорм и функционалов от функции температур.

Во-вторых, предполагается использование гипотезы о малом разбросе температур в здоровой молочной железе. Она основывается на отсутствии в случае нормы источников тепла, вызываемых метаболическими процессами и раковыми образованиями, симметрии источников тепла, вызываемых кровотоками и адекватными краевыми условиями. Для анализа данных с помощью данной гипотезы предполагается использование функционалов вида $TD = \|T(\vec{r}) - T_{type}(\vec{r})\|$, где, как и выше, предполагается использование норм, полунорм и других функционалов, вычисляемых как по всей области изменения, так и по различным ее подобластям. Под $T_{type}(\vec{r})$ – понимается некая функция, описывающая «типичное» распределение температур молочной железы. В данном случае наибольший интерес вызывает

определение величины $T_{\text{type}}(\vec{r})$. В некоторых случаях достаточно эффективным оказалось сравнение с нулем, т.е. $T_{\text{type}}(\vec{r}) = 0$. А именно, в ряде алгоритмов классификации использовались функционалы вида $p_1(T) = \text{osc}T(\vec{r})$, $p_2(T) = \max_{\vec{r} \in M} |\nabla T(\vec{r})|$, $p_3(T) = \max_{\vec{r} \in M} \|D^2T(\vec{r})\|$ и некоторые другие. В случае применения статистических моделей, возможно использование в качестве $T_{\text{type}}(\vec{r})$ математического ожидания, медианы, моды и некоторых других оценок среднего значения. Также возможно использование результатов численного моделирования на основе дифференциальных уравнений. Весьма высокую эффективность показало использование в качестве $T_{\text{type}}(\vec{r})$ температуры в «особо значимых» точках, например, при диагностике молочных желез, температуры в соске: $p_1(T) = \max_{\vec{r} \in M} |T(\vec{r}) - t_0|$.

Заметим, что наиболее существенным моментом данного подхода, является не только нахождение экстремумов указанных функционалов, но нахождение их точек экстремумов. Именно в данных точках наблюдается аномальное поведение температурных полей, и их индексация позволяет обосновать диагностическое решение на языке понятном пользователю, т.е. врачу-диагносту.

В ряде работ отдельные элементы предлагаемого подхода получили практическую реализацию. В наиболее удачных алгоритмах классификации (на основе нейронных сетей, генетических алгоритмов, логистической регрессии и др.) чувствительность и специфичность находились в диапазоне 80 – 90 процентов (см., например, [5-7], [10-11]), что для данного метода считается весьма высоким результатом.

Исследование выполнено при финансовой поддержке РФФИ, проект № 19-01-00358.

Библиографический список

1. S. Vesnin, A.K. Turnbull, J.M. Dixon, I. Goryanin. Modern Microwave Thermometry for Breast Cancer// Journal of Molecular Imaging & Dynamics. 2017. V. 7. Is. 2. DOI: 10.4172/2155-9937.1000136.
2. Barrett A.H., Myers P.C. Subcutaneous Temperature: A method of Noninvasive Sensing// Science. 1975. V. 190. P. 669—671.
3. Gautherie M. Temperature and Blood Flow Patterns in Breast Cancer During Natural Evolution and Following Radiotherapy// Biomedical Thermology. 1982. P. 21-64.
4. Polyakov M.V., Khoperskov A.V., Zamechnic T.V. Numerical Modeling of the Internal Temperature in the Mammary Gland// Lecture Notes in Computer Science. 2017. V. 10594 LNCS. P. 128-135.
5. 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 ВолГУ. Серия 1. Математика. Физика. 2015. № 6(31). С. 31-71.

6. Лосев А.Г., Левшинский В.В. Интеллектуальный анализ термометрических данных в диагностике молочных желез// Управление большими системами. 2017. №. 70. С. 113–135.
7. Лосев А.Г., Левшинский В.В. Интеллектуальный анализ данных микроволновой радиотермометрии в диагностике рака молочной железы// Математическая физика и компьютерное моделирование. 2017. Т. 20, № 5. С. 49–62.
8. Saniei E., Setayeshi S., Akbari M.E., Navid M. Parameter estimation of breast tumour using dynamic neural network from thermal pattern// Journal of Advanced Research. 2016. 7:6, p. 1045-1055.
9. Zadeh H.G., Montazeri A., Kazerouni I.A., Haddadnia J. Clustering and screening for breast cancer on thermal images using a combination of SOM and MLP// Computer Methods in Biomechanics and Biomedical Engineering: Imaging Visualization. 2017. 5:1, p. 68-76
10. Зенович А.В., Гребнев В.И., Примаченко Ф.Г. Алгоритмы классификации заболеваний парных органов на основе нейросетей и нечетких множеств // Математическая физика и компьютерное моделирование. 2017. Т. 20, № 6. С. 26–37.
11. Мазепа Е.А., Гришина О.В., Левшинский В.В., Сулейманова Х.М. Об унификации метода анализа данных микроволновой радиотермометрии// Математика и компьютерное моделирование. 2017. Т. 20. № 6. С. 38-50.

MATHEMATICAL MODELS AND ALGORITHMS OF ARTIFICIAL INTELLIGENCE IN DIAGNOSIS OF BREAST CANCER ON A THERMOMETRIC DATA

Losev Alexander G.
 Volgograd State University,
 400062, Russia, Volgograd, Universitetskiy pr., 100,
 alexander.losev@volsu.ru

The study was carried out within the framework of the development of the fundamentals of early differential diagnosis of breast diseases based on the microwave radio thermometry method using mathematical modeling and machine learning algorithms. Proposed technology involves the joint use of specific methods for the intelligent analysis of thermometric data and modeling of spatiotemporal temperature distributions within the mammary glands, which should increase the sensitivity and specificity of the method in screening and early differential diagnosis.

Keywords: microwave thermometry, mathematical models, data mining.

МЕТОДИЧЕСКИЕ ПРИЕМЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

АЛГОРИТМ НАИВНОГО МЕТОДА БАЙЕСА В ЗАДАЧАХ БИНАРНОЙ КЛАССИФИКАЦИИ НА ПРИМЕРЕ НАБОРА ДАННЫХ SANTANDER С ПЛАТФОРМЫ KAGGLE

*Багаев Илья Владимирович, Коломенская Мария Денисовна,
Шатров Анатолий Викторович*

Вятский государственный университет, 610000, Россия, г. Киров,
Московская, 36, avshatrov1@yandex.ru

Фактический результат многих алгоритмов бинарной классификации – оценка прогнозирования. Оценка указывает на уверенность системы в том, что данное наблюдение относится к положительному классу. Алгоритм метода наивного Байеса является одним из простейших вероятностных классификаторов. Он часто работает на удивление хорошо во многих реальных приложениях, несмотря на твердое предположение, что все признаки являются условно независимыми от класса. В процессе обучения этого классификатора с известной структурой, вероятности классов и условные вероятности рассчитываются с использованием обучающих данных, а затем значения этих вероятностей используются для классификации новых наблюдений. Чтобы принять решение о том, следует ли классифицировать наблюдение как положительное или отрицательное, мы интерпретируем оценку, выбирая порог классификации (отсечение) и сравнивая оценку с ним. Любые наблюдения с оценками выше порогового значения затем прогнозируются как положительный класс, а оценки ниже порогового значения – как отрицательный класс. Однако AUC не зависит от выбранного порога, и можно получить представление о производительности прогнозирования модели из метрики AUC, не выбирая порог.

Ключевые слова: наивный байесовский классификатор, модель гауссовых смесей, оценка плотности распределения, машинное обучение, классификация данных.

В работе рассматриваются три модели для байесовского классификатора: гауссов наивный байесовский классификатор, байесовская модель гауссовых смесей, наивный Байес с оценкой плотности распределения. Численные эксперименты проводятся на реальном бинарном классификационном наборе данных Santander, взятом с платформы Kaggle¹, где непрерывные признаки дискретизируются путем применения

перечисленных методов. Рабочие характеристики этих моделей сравниваются с полносвязной нейронной сетью и библиотеками, реализующими алгоритмы градиентного бустинга (англ. boosting — улучшение)² LightGBM, XGBoost и CatBoost [1]. Полученные результаты демонстрируют, что предложенные модели могут улучшить производительность наивного байесовского классификатора и конкурировать с популярными алгоритмами бустинга.

Эксперименты с данными Santander. Данные использовались при проведении соревнования «Santander Customer Transaction Prediction» на платформе Kaggle. В рамках этого соревнования необходимо определить, какие клиенты совершат конкретную транзакцию в будущем, независимо от суммы транзакции. Цель соревнования состояла в том, чтобы построить на основании анонимизированного набора данных, содержащего числовые непрерывные признаки и бинарный целевой столбец, наиболее эффективный классификатор. Задача состояла в том, чтобы спрогнозировать значение целевого столбца в тестовом наборе. Данные соответствуют 400000 записям, из которых 200000 с неизвестными метками были отведены для тестирования и подведения итогов соревнования. Данные транзакций имеют структуру, формализованную от 200 непрерывных признаков var0-var199.

Применим байесовский вывод к данным транзакций клиентов банка Santander, которые имеют двоичную целевую переменную и 200 непрерывных функций – факторов. Моделируем целевую переменную как неизвестный вектор Y , а признаки как матрицу X . Априорная вероятность $p_Y(y)$ отражает знания до наблюдения. В этой задаче величина Y имеет дискретное распределение Бернулли (только два класса), которую можно определить, задав положительную вероятность – долю положительного класса в данных. Вероятность $f_{X|Y}(x|y)$ моделирует распределение наблюдения с учётом известности меток классов. Апостериорная вероятность $p_{Y|X}(y|x)$ – обновленные знания о неизвестной целевой переменной после наблюдения. Метод оценки с помощью апостериорного максимума MAP (Maximum A Posteriori) выбирает класс с наибольшей апостериорной вероятностью. Для бинарной классификации это имеет тот же эффект, что и установка порога в 0.5 для положительной апостериорной вероятности. МНК (метод наименьших квадратов) $E[Y|X]$ выбирает среднее значение апостериорного распределения. Для бинарной классификации это просто положительная апостериорная вероятность $p_{Y|X}(1|x)$, которую необходимо спрогнозировать. Правило Байеса для этой проблемы имеет вид

² Бустинг (boosting) — это процедура последовательного построения композиции алгоритмов машинного обучения, когда каждый следующий алгоритм стремится компенсировать недостатки композиции всех предыдущих алгоритмов.

$$p_{Y|X}(y|x) = \frac{p_Y(y)f_{X|Y}(x|y)}{\sum_{y'} p_Y(y')f_{X|Y}(x|y')} \quad (3)$$

Здесь X представляет собой последовательность из 200 наблюдений X_0, X_1, \dots, X_{199} .

Таким образом, $p(y = 1)$ – априорная вероятность положительного класса. И $p(y = 0)$ также можно легко вычислить как $1 - p(y = 1)$. Проблема заключается в том, как рассчитать 200 других членов, то есть как рассчитать следующее: $p(x_i|y = 1)$, а также $p(x_i|y = 0)$. Есть два основных способа расчета этого. Первый способ сделать это – предположить, что i -й признак (x_i) следует гауссову распределению, например, нормальному распределению, и вычислить $p(x_i|y = 1)$ по функции плотности вероятности (PDF) нормального распределения.

Однако при проведении разведочного анализа можно ясно видеть, что не все 200 признаков следуют распределению Гаусса. Таким образом, предположение о гауссовом распределении может быть не лучшим выбором для оценки $p(x_i|y)$. Однако эта модель очень просто и эффективна – стоит рассмотреть её и использовать основные идеи в дальнейшем.

Мы предполагаем, что вероятностные распределения нормальны и независимы. Отсюда получаем гауссов наивный байесовский классификатор (гауссов означает нормальный, а наивный означает независимый):

$$p_{Y|X_0, X_1, \dots, X_{199}}(y|x_0, x_1, \dots, x_{199}) = \frac{p_Y(y) \prod_{i=0}^{199} f_{X_i|Y}(x_i|y)}{\sum_{y'=0}^1 p_Y(y') \prod_{i=0}^{199} f_{X_i|Y}(x_i|y')} \quad (2)$$

Классификатор уже реализован в библиотеке scikit-learn [1], поэтому мы можем использовать его сразу. Распределения признаков имеют разные среднее и стандартное отклонение, поэтому стоит их стандартизировать, чтобы они имели нулевое среднее значение и единичную дисперсию. Кроме того, у некоторых распределений признаков есть небольшие неровности слева или справа. Можно использовать квантильное преобразование, чтобы убрать небольшие неровности. В практике статистических исследований для качества бинарной классификации используется понятие ROC – кривой (Receiver Operation Characteristic) [2]. Чем выше проходит монотонно возрастающая кривая ROC, тем качество классификации лучше. Оценка AUC (Area Under Curve) представляет собой площадь под кривой ROC, при этом, чем ближе AUC к единице, тем оценка классификации лучше. На практике мы можем пропустить квантильное преобразование. Оказывается, что это преобразование обеспечивает лишь незначительное улучшение

производительности (0.001 AUC при перекрестной проверке), при том, что требуется значительно больше вычислений. При проведении оценки модели методом перекрестной проверки по пяти блокам, получаем $AUC = 0.889$, тогда как сложные настроенные алгоритмы бустинга [3] дают результаты около 0.902 для AUC. На практике – это незначительная разница.

Для реализации наивного Байеса с оценкой плотности распределения вводим оценку плотности ядра для вычисления плотности вероятности произвольного распределения признаков. В этом методе отбрасывается предположение, что все признаки распределены нормально. На перекрестной проверке получаем тоже очень впечатляющий результат $AUC = 0.895$, что иллюстрирует достоинство наивного байесовского классификатора с оценкой плотности распределения.

Теперь попытаемся снова улучшить гауссов наивный байесовский классификатор, заменив модель Гаусса более гибкой моделью гауссовых смесей. Апостериорная вероятность $p_Y(y)$ будет взята как отношение двух классов, а вероятность $f_{X_i|Y}(x_i|y)$ будет получена путем подгонки данных к модели гауссовых смесей.

Модель гауссовой смеси дает смесь нормальных распределений. Мы можем использовать `sklearn.mixture.GaussianMixture` [1], чтобы подогнать данные. Также необходимо стандартизировать признаки, данные с разными средними и отклонениями могут ухудшить возможность обучения модели гауссовой смеси. Существует два важных гиперпараметра: `n_components` – это число нормальных распределений, которые нужно смешать, и `reg_covar` – параметр регуляризации.

Мы будем использовать модель гауссовой смеси для оценки плотности вероятности функции $f_{X_i|Y}(x_i|y)$. Так как умножение большого количества малых чисел приведет к переполнению, логарифмируем выражение (2) и преобразуем произведения в суммы:

$$\begin{aligned} \ln p_{Y|x_0, x_1, \dots, x_{199}}(y|x_0, x_1, \dots, x_{199}) &= \ln p_Y(y) + \sum_{i=0}^{199} \ln f_{X_i|Y}(x_i|y) - \\ \ln \sum_{y'=0}^1 \exp(\ln p_Y(y') + \sum_{i=0}^{199} \ln f_{X_i|Y}(x_i|y)) & \end{aligned} \quad (3)$$

Для определения вероятностей необходимо выполнить обратное преобразование в формуле (3). Наивная байесовская гауссовая смесь показывает улучшение AUC до 0.899 по сравнению с гауссовым наивным байесовским методом, хотя для его обучения требуется немного больше времени. Преимущество этого метода в том, что он, как и метод с оценкой плотности распределения, более гибкий и не требует, чтобы данные были распределены нормально. Признаки также являются условно независимыми.

Какой бы метод исследователи ни использовали, цель состоит в том, чтобы иметь модель, которая является простой, легко вычисляемой и точной (очень хорошо описывающей реальные данные).

Библиографический список

1. Плас Дж. Вандер. Python для сложных задач: наука о данных и машинное обучение. — СПб.: Питер, 2018. — 576 с.
2. Hastie T., Tibshirani R., Friedman J.H. The Elements of Statistical Learning, 2nd edition. — Springer, 2009. — 533 p.
3. Никулин В.Н., Палешева С.А., Зубарева В.С. Об однородных ансамблях при использовании метода бустинга в приложении к несбалансированным данным // Вестник Пермского университета. Сер. Экономика. 2012. №1. С. 7-14.

ALGORITHM OF NAIVE BAYES METHODS IN BINARY CLASSIFICATION TASKS ON SANTANDER DATASET EXAMPLE FROM KAGGLE PLATFORM

Bagaev Ilya V., Kolomenskaya Mariya D., Shatrov Anatoly V.
Vyatka State University,
610000, Russia, Kirov, Moskovskaya str, 36, ilyabagaev1997@gmail.com,
avshatrov1@yandex.ru

The actual output of many binary classification algorithms is a prediction score. The score indicates the system's certainty that the given observation belongs to the positive class. Naive Bayes is among the simplest probabilistic classifiers. It often performs surprisingly well in many real world applications, despite the strong assumption that all features are conditionally independent given the class. In the learning process of this classifier with the known structure, class probabilities and conditional probabilities are calculated using training data, and then values of these probabilities are used to classify new observations. To make the decision about whether the observation should be classified as positive or negative, you will interpret the score by picking a classification threshold (cut-off) and compare the score against it. Any observations with scores higher than the threshold are then predicted as the positive class and scores lower than the threshold are predicted as the negative class. However, AUC is independent of the selected threshold, you can get a sense of the prediction performance of your model from the AUC metric without picking a threshold.

Key words: Naive Bayesian Classifier, Gaussian mixture model, Kernel Naive Bayes, machine learning, data classification.

ОПЫТ ПРИМЕНЕНИЯ ДИФФЕРЕНЦИАЛЬНЫХ УРАВНЕНИЙ И НЕЙРОННЫХ СЕТЕЙ ДЛЯ РАСПОЗНАВАНИЯ ФИЗИЧЕСКИХ ЯВЛЕНИЙ НА ВИДЕОИЗОБРАЖЕНИЯХ

Гладкий Сергей Леонидович

ООО «ВИПАКС», 614000, Россия, г. Пермь, ул. Краснова, 24,
lrndlrnd@mail.ru

В статье описан опыт использования дифференциальных уравнений совместно с нейронными сетями глубокого обучения для распознавания физических явлений, а именно, наличия огня или дыма, на видеоизображениях. Проведен анализ существующих методов детекции дыма и огня на видеоизображениях, их преимущества и недостатки. Предложены два новых подхода для повышения точности распознавания возгорания. Первый подход основан на использовании дифференциальных уравнений в частных производных для анализа характера движения, соответствующего распределению температур или плотности. Второй метод основан на использовании искусственных нейронных сетей глубокого обучения для классификации формы областей движения как огня или дыма. На основе предложенных методик разработано программное обеспечение для системы видеонаблюдения, позволяющее определять наличие возгорания в реальном времени.

Ключевые слова: искусственный интеллект, сверточная нейронная сеть, глубокое обучение, математическое моделирование, дифференциальные уравнения в частных производных, возгорание, видеонаблюдение, система безопасности.

Компьютерное зрение является одним из наиболее быстро растущих направлений разработки программного обеспечения. Методы анализа изображений становятся все более сложными, поскольку мощности цифровых процессоров постоянно растут [1, 2]. Анализ изображений так же становится более интеллектуальным, в нем все чаще используются методы искусственного интеллекта, в том числе, искусственные нейронные сети [3]. Наиболее успешно в области компьютерного зрения используются нейронные сети глубокого обучения. Они применяются, например, для распознавания образов и идентификации личности человека по лицу.

Компьютерное зрение может применяться для повышения безопасности таких объектов, как жилых зданий, торговых центров, складских помещений, промышленных предприятий. Одним из возможных способов повышения безопасности является осуществление детекции

возможного возгорания по видеоизображению. Все перечисленные типы объектов оснащаются датчиками дыма и огня, имеющих точность срабатывания 99.99%. Однако, данные датчики обладают и некоторыми недостатками. Например, время их срабатывания с начала инцидента может быть значительным – до нескольких минут. Детекция возгорания с помощью анализа видеоизображения имеет в этом смысле преимущество, поскольку наличие огня или дыма в кадре можно зафиксировать непосредственно после момента появления. Следует отметить также недостатки такой системы. Во-первых, возгорание должно быть в прямой зоне видимости системы видеонаблюдения. Во-вторых, точность современных методов обнаружения возгорания по видеоизображению в реальных условиях не превышает 70%.

Современные подходы к определению наличия возгорания на видеоизображениях, так или иначе, связаны с анализом трех составляющих: цвета, формы и характера движения дыма и огня. Например, цвет огня может быть приблизительно принят в диапазоне от темно-красного до желтого и почти белого с преобладанием красной цветовой компоненты. Здесь следует отметить, что, как цвет огня, так и цвет дыма, зависят от химического состава источника и, вообще говоря, могут быть практически любыми. При создании систем детекции возгорания по видеоизображениям разработчики ориентируются на реальные ситуации применения таких систем, соответственно, принятые допущения о цвете являются приемлемыми. В специальных ситуациях анализ цветовой составляющей может быть легко изменен. На рисунке 1 приведен пример выделения маски огня с помощью фильтра цвета.

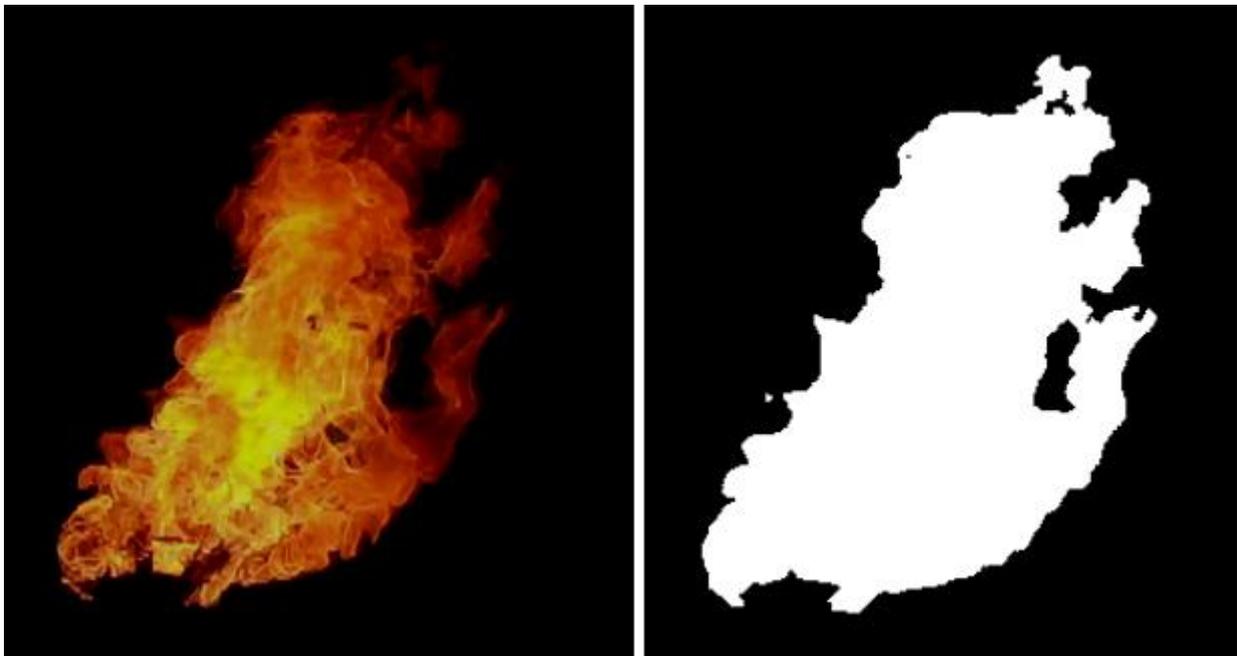


Рисунок 1. Маска огня, выделенная фильтром цвета

Анализ формы и характера движения огня и дыма проводится в предположении специальной установки камеры видеонаблюдения. В

преобладающем большинстве, учитывая специфику решаемой задачи, камеры для детекции возгорания устанавливаются почти горизонтально, под небольшим углом. В соответствии с такой установкой формулируются различные критерии для определения наличия на кадре огня или дыма по форме и характеру движения объектов. Например, очевидным критерием является то, что векторы движения дыма и огня будут иметь в этом случае преобладание положительной вертикальной составляющей.

Как отмечено ранее, одним из главных недостатков методов определения наличия возгорания на видеоизображениях является их низкая точность. Ошибки таких методов могут быть двух типов. Анализ существующих методов показал, что такая низкая точность обусловлена, в основном, упрощенными критериями соответствия формы и характера движения.

Для повышения точности определения характера движения предлагается использовать дифференциальные уравнения в частных производных [4-6]. Горение, как и большинство других физических процессов, описывается дифференциальными уравнениями, а именно, системой следующих уравнений: уравнение неразрывности, уравнение движения, уравнение энергии, уравнение состояния, уравнение переноса энергии и уравнение вязкости [7]. Одной из неизвестных функций, входящих в данные уравнения, является температура. Зная распределение функции температур, его можно проверить на удовлетворение дифференциальным уравнениям (используя конечно-разностную схему).

Очевидно, что моделирование на основе изображений полной системы дифференциальных уравнений горения невозможно. Уравнения должны быть упрощены с учетом некоторых физических предположений, например, отсутствие вязкости (горение происходит в воздухе). Таким образом, приходим к следующей системе уравнений:

$$\frac{\partial}{\partial t} T = -v \cdot \nabla (T) + c \cdot \nabla^2 (T)$$

$$\frac{\partial}{\partial t} v = -v \cdot \nabla (v) + k \cdot \nabla^2 (v)$$

Уравнения содержат неизвестные: температуру T и вектор скорости v . Зная температуру, вектор скорости может быть выражен из первого уравнения. Подставляя значение скорости во второе уравнение можно проверить, насколько распределение скоростей соответствует процессу горения.

Таким образом, проблема определения характера движения сводится к определению поля температур по изображению. Для решения данной проблемы предлагается использовать следующее: известно, что спектр излучения есть функция температуры; при горении, излучение включает видимый спектр; цвет на изображении есть функция длины волны. Таким образом, каждому цвету может быть поставлено в соответствие некоторое значение температуры. Для точного моделирования функции температуры по

цвету можно использовать тепловизор с синхронизированным изображением, где каждому пикселю поставлено в соответствие истинное значение температуры. В работе использовался приближенный подход, где функция температур была аппроксимирована по некоторой зависимости спектра излучения от температуры. Пример представлен на рисунке 2.

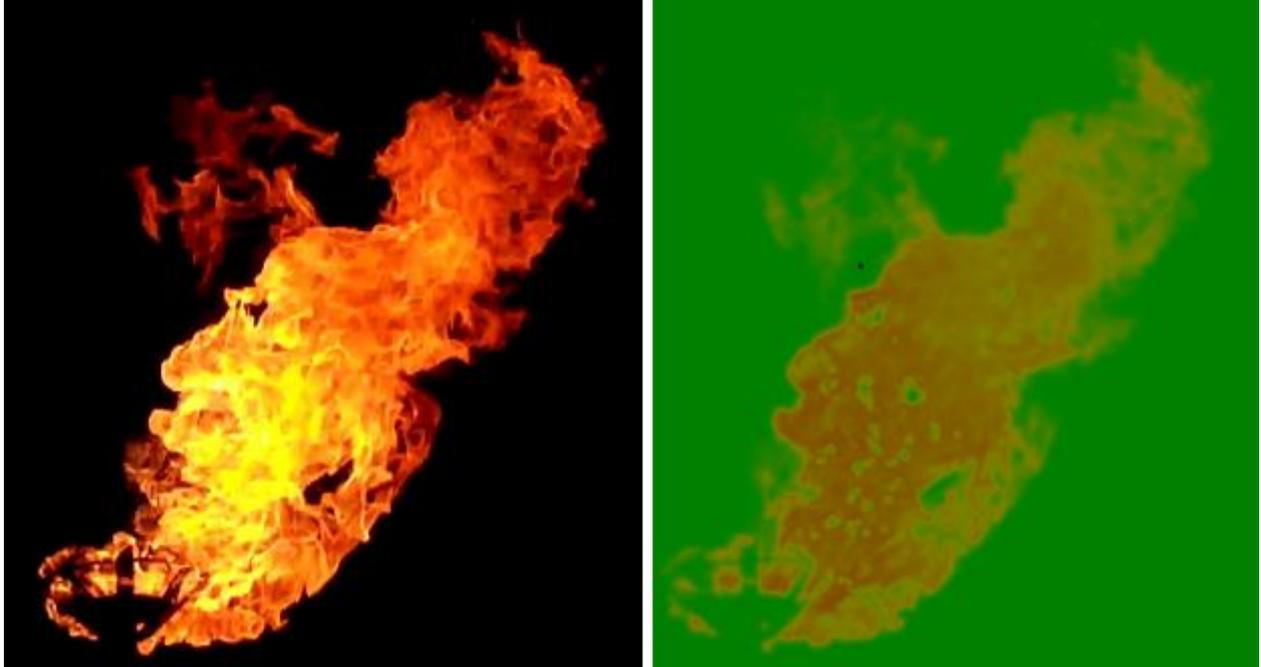


Рисунок 2. Распределение функции температур на одном кадре

Для повышения точности определения формы огня или дыма предлагается использование нейронной сети и технологии глубокого обучения. Для обучения нейронной сети создана выборка примеров форм объектов дыма и огня, а также формы других объектов, которые могут присутствовать на кадре (людей, машин) – отрицательные примеры формы, которые направлены на исключение ложных срабатываний. Создание выборки выполнено следующим образом: создан набор видеоизображений с наличием реальных случаев возгорания, а также набор видеоизображений без огня и дыма, но с наличием ‘ложных’ движущихся объектов, удовлетворяющих критерию цвета; по данным видеоизображениям, после анализа детектором движения, сгенерированы маски движущихся объектов; полученные маски обработаны цветовым фильтром; в результате получены изображения форм, использованные для обучения нейронной сети. На рисунке 3 приведен пример изображений формы огня на нескольких кадрах видеоизображения.



Рисунок 3. Изображения формы огня, используемые для обучения нейронной сети

Поскольку целью использования нейронной сети является распознавание огня только по форме, изображения для обучения представлены в оттенках серого, без учета цветных составляющих.

Для классификации изображений с наличием и без огня использовалась сверточная нейронная сеть, созданная в системе Caffe. Как известно, точность обучения сверточной нейронной сети значительно зависит от ее структуры. Причем методик проектирования сверточных сетей для решения данного класса задач фактически не существует. Структура сети, как правило, выбирается путем проведения экспериментов. На рисунке 4 представлена структура нейронной сети, использованная в работе.

Всего для обучения нейронной сети использовалось более 5000 изображений, для тестирования порядка 1700. Точность распознавания огня по тестовым изображениям составила 98.5%.

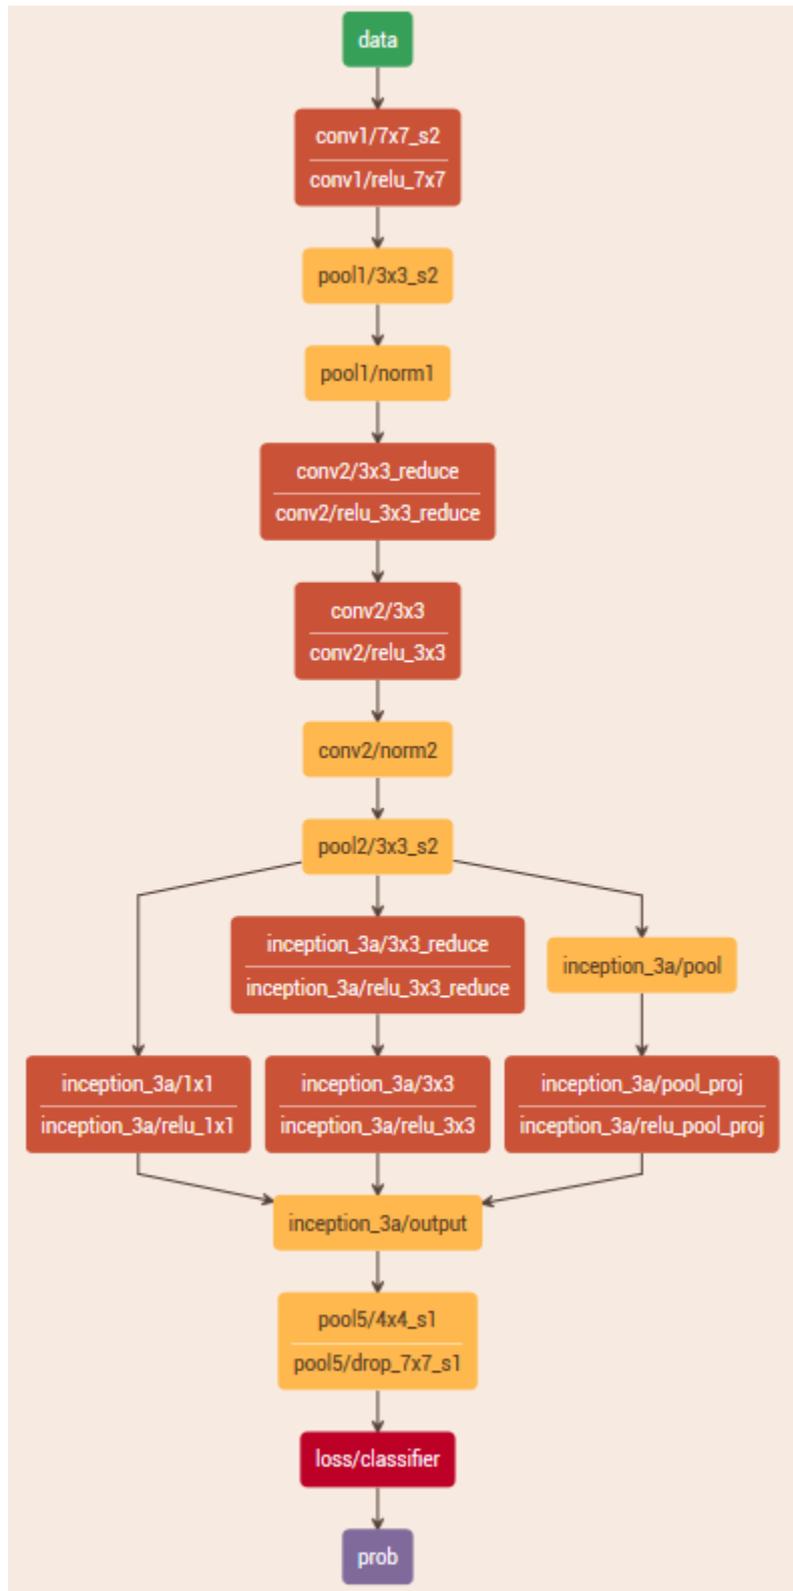


Рисунок 4. Структура сверточной нейронной сети

Таким образом, предложены два новых подхода, позволяющих повысить точность распознавания огня и дыма на видео изображениях. Первый подход основан на применении математических моделей дыма и огня как реальных физических процессов, описываемых дифференциальными уравнениями в частных производных. Второй подход основан на применении искусственных нейронных сетей и алгоритмов

глубокого обучения, которые, являются самыми эффективными инструментами классификации изображений. Предложенные алгоритмы реализованы в детекторах огня и дыма интеллектуальной системы видеонаблюдения DOMINATION компании ВИПАКС.

Библиографический список

1. Шапиро Л., Стокман Дж. Компьютерное зрение.: Пер. с англ. – 2-е изд. (эл.) – Москва: БИНОМ. Лаборатория знаний, 2013, 752 с.
2. Лукьяница А.А., Шишкин А.Г. Цифровая обработка видеоизображений. М.: «Ай-Эс-Эс Пресс», 2009. – 518с.
3. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176с.
4. Гладкий С.Л., Степанов Н.А., Ясницкий Л.Н. Интеллектуальное моделирование физических проблем. Москва–Ижевск: НИЦ «Регулярная и хаотическая динамика», 2006. – 200 с.
5. 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.
6. Тархов Д.А. Нейросетевые модели и алгоритмы. М: Радиотехника, 2014. – 352с.
7. Ladyzhenskaya O.A. The mathematical theory of viscous incompressible flow. New York: Gordon and Beach, 1969. – 224 pp.

AN EXPERIENCE OF USING DIFFERENTIAL EQUATIONS AND NEURAL NETWORKS FOR DETECTION OF PHYSICAL PROCESSES ON VIDEO DATA

Sergey L. Gladkiy

LLC «VIPAKS», Krasnova st., 24, Perm, Russia, 614000, lrndlrnd@mail.ru

This article describes an experience of using differential equations together with convolutional neural networks for identifying physical processes, specifically, fire and smoke, on video data. The existing methods of fire and smoke detection and their advantages and drawbacks have been analyzed. Two new approaches for increasing precision of smoke and fire detection suggested. The former approach uses partial differential equations for analyzing motion conforming to the temperature and density distribution. The later method based on using convolutional neural networks for fire and smoke shape classification in motion regions. The approaches used in the developed software for detecting possible fire and smoke on real-time video data.

Key words: artificial intelligence, convolutional neural network, deep learning, mathematical modeling, partial differential equations, fire detection, video surveillance systems.

ГЕНЕТИЧЕСКИЙ АЛГОРИТМ ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ С ОДНИМ КРИТЕРИЕМ ОПТИМИЗАЦИИ ДЛЯ УПРАВЛЕНИЯ БЕСПИЛОТНЫМИ ЛЕТАТЕЛЬНЫМИ АППАРАТАМИ

*Гридасов Олег Николаевич, Зейдан Зейнаб Усама, Мяснянкин Максим
Борисович, Филист Сергей Алексеевич*
Юго-Западный государственный университет,
305040, Россия, г. Курск, ул. 50 лет Октября, 94, SFilist@gmail.com

Предложен гибридный генетический алгоритм для синтеза системы управления беспилотного летательного аппарата с одним оптимизируемым критерием, отличающийся итерационным процессом последовательного увеличения числа элементов задержек входного и выходного сигнала, используемых в рекуррентной нейронной сети.

Ключевые слова: управление динамическими объектами, генетический алгоритм, оптимизируемый критерий, рекуррентная нейронная сеть.

Для управления динамическими объектами используют нейронные сети (НС) [1, 2]. Разработку генетического алгоритма (ГА) для обучения НС для системы управления беспилотным летательным аппаратом (БПЛА) начнем для одного оптимизируемого критерия по классическому ГА. Структурная схема этой НС представлена на рисунке 1. При настройке такой сети используем гибридный алгоритм, который предусматривает комбинацию алгоритмов генетического типа и вариационного алгоритма настройки НС.

Полагаем, что в процессе работы ГА необходимо получить максимальные значения параметров p и q (максимальные значения задержки по входному сигналу и выходному сигналу) нейронных сетей NET1 и NET2 и весовые коэффициенты на входе нейронной сети NET3 $w_1 w_2 w_3$.

Так как нейронная сеть в данном случае моделирует ПИД-регулятор, то модель ПИД-регулятора реализуется посредством рекуррентной нейронной сети с элементами задержки по входу и по выходу. Динамика модели этой нейронной сети описывается следующим уравнением:

$$y(n+1) = F(y(n), \dots, y(n-q+1), x(n), \dots, x(n-p+1)), \quad (1)$$

где $y(n), y(n-1), \dots, y(n-q+1)$ – значения выходного сигнала в предшествующие моменты времени, от которых зависит выход модели $y(n+1)$; $x(n), \dots, x(n-p+1)$ – текущее и предыдущее значение входного сигнала; F -некоторая нелинейная функция своих аргументов.

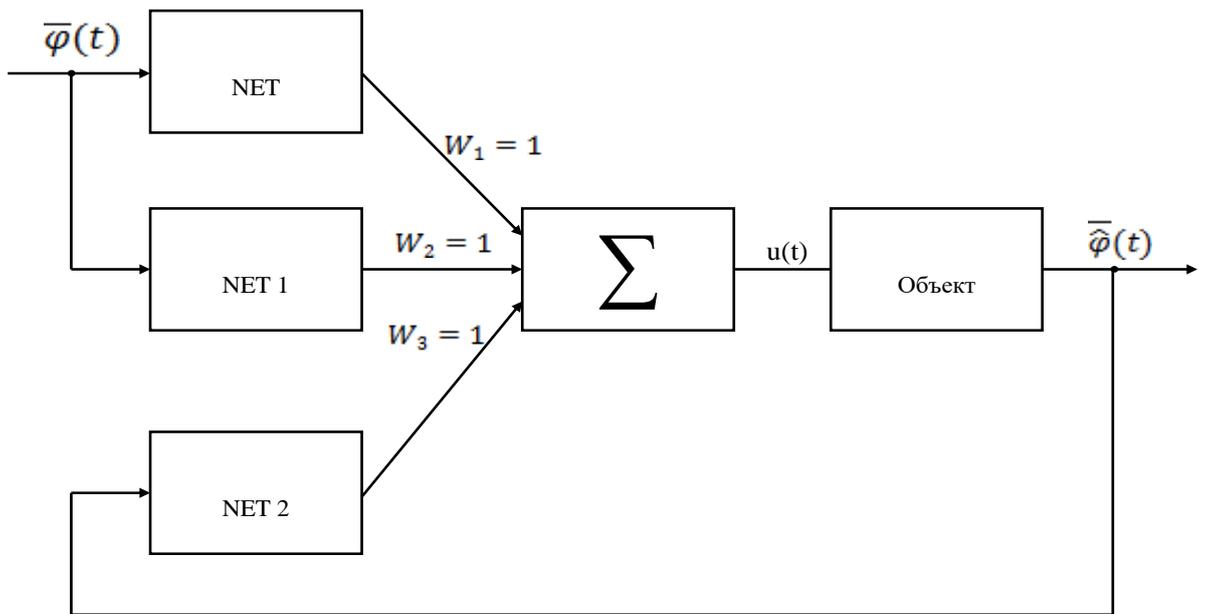


Рисунок 1. Структурная схема синтезируемой нейросети с одним оптимизируемым критерием

Для реализации модели (1) посредством НС в простейшей конфигурации, то есть в виде однослойного персептрона с линейной функцией активации, необходимо определить весовые коэффициенты однослойного персептрона, то есть множество

$$w_0, w_{11}, w_{12}, \dots, w_{1p}, w_{21}, w_{22}, \dots, w_{2q}. \quad (2)$$

НС настраивается по некоторому критерию, который необходимо минимизировать. В качестве такого критерия может быть принят минимум среднеквадратической ошибки, например, отклонения реальной траектории БПЛА от заданной или оптимальной:

$$J = \frac{1}{N} \sqrt{\sum_{n=0}^{N-1} ((x(n) - y(n))^2)} \rightarrow MIN, \quad (3)$$

где N- число дискретных отсчетов на траектории.

Таким образом, задача состоит в определении конкретных значений элементов упорядоченного множества (2), которые бы минимизировали функционал (3). Эта задача может быть решена посредством классического ГА, в котором (3) используется в качестве функции приспособленности, а в качестве генов хромосом популяции используются весовые коэффициенты множества (2). Весовые коэффициенты кодируются либо двоичным кодом, либо кодом Грея. Сформировав начальную популяцию из случайных комбинаций аллелей элементов множества (2), и путем формирования новых популяций посредством генетических операторов скрещивания и мутации, определяется хромосома, обеспечивающая минимизацию функционала (3).

Однако это справедливо при условии, что мощности подмножеств множества (2) известны. Но при синтезе рекуррентной НС, как правило, не

известны ни p , ни q . Следовательно, вариационный ГА для синтеза НС на основе рекуррентных НС использовать не представляется возможным.

Рассмотрим предложенный нами гибридный ГА, который позволяет преодолеть эти трудности.

На первом шаге сформируем популяцию путем случайного выбора параметров рекуррентной сети p , q и w_0 . Эту популяцию можно представить в виде таблицы 1. Кроме того, необходимо выбрать допустимые параметры оптимизируемого критерия. Это необходимо для селекции получаемых в результате использования генетических операторов особей.

Таблица 1 – Формат исходной популяции генетического алгоритма

p	q	w_0	$Jmin$	$Jmax$	σJ
p_1	q_1	w_{01}	$Jmin_1$	$Jmax_1$	σJ_1
p_2	q_2	w_{02}	$Jmin_2$	$Jmax_2$	σJ_2
...
p_n	q_n	w_{0n}	$Jmin_n$	$Jmax_n$	σJ_n
...
p_N	q_N	w_{0N}	$Jmin_N$	$Jmax_N$	σJ_N

Таблица 1 записана для N образцов (особей) в исходной популяции. Номер особи в популяции кодируется нижним индексом. Каждая особь исходной популяции дает свою производную исходную популяцию. В таблице 2 представлена производная исходная популяция для особи №1 из таблицы 1.

Таблица 2 записана для M образцов (особей) в исходной производной популяции. Номер особи в популяции кодируется верхним индексом.

Таблица 2 – Формат исходной производной популяции для особи №1 из исходной популяции таблицы 1

w_{11}^1	w_{12}^1	...	w_{1p1}^1	w_{21}^1	w_{22}^1	...	w_{2q1}^1	J^1
w_{11}^2	w_{12}^2	...	w_{1p1}^2	w_{21}^2	w_{22}^2	...	w_{2q1}^2	J^2
...
w_{11}^m	w_{12}^m	...	w_{1p1}^m	w_{21}^m	w_{22}^m	...	w_{2q1}^m	J^m
...

w_{11}^M	w_{12}^M	...	w_{1p1}^M	w_{21}^M	w_{22}^M	...	w_{2q1}^M	J^M
------------	------------	-----	-------------	------------	------------	-----	-------------	-------

Для каждой строки таблицы 1 формируется своя производная исходная популяция. В последнем столбце таблицы 2 записывается значение функции приспособленности для соответствующей особи, которая рассчитывается согласно (3).

Для каждой производной исходной популяции реализуется вариационный ГА [3]. Результатом работы этого алгоритма является создание родительского пула. Родительский пул характеризуется тремя показателями функции приспособленности: минимальное значение функции приспособленности $Jmin$, максимальное значение функции приспособленности $Jmax$ и среднее квадратическое отклонение σJ функции приспособленности в родительских пулах производных популяций. Эти значения записываются в три последних столбца таблицы 1 для соответствующей особи, производной популяцией которой являются особи таблицы 1.

Лицо, принимающее решение (ЛПР), анализирует третьи столбцы родительского пула таблицы 1 и по результатам этого анализа формирует из них базовый пул, каждая особь которого оптимизируется посредством гибридного ГА. Сущность гибридного ГА заключается в следующем. Из трех показателей функции приспособленности формируется оптимизируемый критерий JJ , например,

$$JJ = a_1 Jmin + a_2 Jmax - a_3 \sigma J, \quad (4)$$

где a_1 , a_2 , a_3 – эмпирически подбираемые положительные коэффициенты.

После этого приступают к последовательному варьированию параметров особей из базового пула таблицы 1 в следующей последовательности. Выполняется вариация параметра p первой базовой особи и переход к вариационному ГА согласно производному родительскому пулу таблицы 2. Анализируется критерий JJ родительской производной популяции первой особи. Если вариация p приводит к увеличению (уменьшению) критерия JJ , то продолжается его вариация в сторону увеличения (уменьшения) этого критерия.

Процесс циклического применения вариационного ГА и вариация параметра p повторяются, пока вариация этого параметра приводит к увеличению критерия JJ . Если критерий JJ больше не увеличивается, то в соответствующие столбцы записываются показатели $Jmin1$, $Jmax1$, $\sigma J1$ и осуществляются аналогичные процедуры «вариационный генетический алгоритм» для параметров q и w_0 . После этого возвращаемся к процедуре «вариация плюс классический генетический алгоритм» для параметра p и так до тех пор, пока вариации этих трех параметров прекратят вызывать увеличение (уменьшение) JJ . Затем осуществляем переход к следующей особи таблицы 1. Алгоритм заканчиваем после того, как в таблице 1 останется только одна особь.

Реализовать гибридный ГА можно различными способами. Способы отличаются правилами наращивания порядков задержек в нейронных сетях NET1 и NET2. Рассмотрим гибридный ГА, реализующий способ наращивания задержек по правилу «пока результат не станет хуже».

Сущность этого правила состоит в том, что задержки входного сигнала наращиваются до тех пор, пока оптимизируемый критерий не прекращает улучшаться. Тогда начинают наращивать задержки выходного сигнала до тех пор, пока оптимизируемый критерий не прекращает улучшаться. Затем переключаются на наращивания задержек во входном сигнале и так переключаются до тех пор, пока не будет достигнут требуемый критерий качества или не будет исчерпан допустимый предел задержек.

Алгоритм работает следующим образом. Задаются исходные параметры выполнения алгоритма. Причем априорно полагаем, что минимальное количество задержек по входу и по выходу равно единице. Затем формируем родительские пулы НС NET1 и NET2, а из родительских пулов выбирают НС с оптимальной структурой. Сравнивая заданную траекторию полета с реальной, получаем значение оптимизируемого критерия. Этот критерий сравнивается с предшествующим критерием.

Если он изменился в «правильную» сторону, то сравниваем его с допустимым критерием, и, если он меньше допустимого, то процесс оптимизации прекращаем. Если критерий не достиг требуемого значения, то в цикле выполняются предшествующие операции до тех пор, пока критерий не достигнет требуемого значения, или не изменится в «не правильную» сторону. В этом случае осуществляется отступ на шаг назад и переход на увеличение задержек по выходному сигналу.

Предложенный гибридный генетический алгоритм для синтеза системы управления с одним оптимизируемым критерием, отличающийся итерационным процессом последовательного увеличения числа элементов задержек входного и выходного сигнала, используемых в рекуррентной нейронной сети, позволяет управлять траекторией БПЛА с заданной точностью.

Библиографический список

1. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
2. Филист, С.А. Использование гибридных нейросетевых моделей для многоагентных систем классификации в гетерогенном пространстве информативных признаков / С.А. Филист, А.Г. Курочкин, В.В. Жилин и др. // Прикаспийский журнал: управление и высокие технологии. Научно-технический журнал. – 2015. № 3 (31).-С.85-95.
3. Аль-Баредда, А.Я.С. Алгоритмы синтеза оптимального управления в биотехнических системах реабилитационного типа на основе технологий нейронных сетей / А.Я.С. Аль-Баредда, А.Н. Брежнева, Р.А. Томакова // Системный анализ и управление в биомедицинских системах. – 2018. – Т. 17, №3. – с. 750 – 754.

GENETIC ALGORITHM FOR LEARNING THE NEURAL NETWORK WITH A SINGLE OPTIMIZATION CRITERION FOR MANAGING OF PILOTLESS AIRCRAFTS

Gridasov Oleg N., Zeidan Zeinab O., Myasnyankin Maxim B., Filist Sergey A.
Southwest state University

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

The proposed hybrid genetic algorithm for synthesis of control systems of unmanned aerial vehicle with a single optimization criterion, wherein the iterative process of sequentially increasing the number of delay elements the input and output signal used in recurrent neural networks.

Key words: management of dynamic objects, genetic algorithm, optimization criterion, recurrent neural network.

СРАВНЕНИЕ МОДЕЛЕЙ КЛАССИФИКАЦИИ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ ГЛУБОКОГО ОБУЧЕНИЯ RESNET И VGG

Клестов Роман Андреевич, Столбов Валерий Юрьевич

Пермский национальный исследовательский политехнический университет
614990, Россия, г. Пермь, Комсомольский пр-т, 29, valeriy.stolbov@gmail.com

В данной работе исследуются возможности искусственных нейронных сетей и глубокого машинного обучения в задаче предсказания физико-механических свойств функциональных материалов. Показано, что достаточно популярная глубокая нейронная сеть VGG с высокой точностью решает задачу классификации твердости металлического сплава на основе железа. Также продемонстрированы результаты обработки исходной информации глубокой нейронной сетью ResNet и представлено сравнение полученных результатов.

Ключевые слова: глубокие сети, машинное обучение, функциональные материалы.

В настоящее время, повсеместно, в лабораториях материаловедения ведутся работы над созданием новых функциональных материалов, способных выдерживать нагрузки при определенных условиях, продиктованных элементом конструкции, где предполагается их использовать. В такой работе крайне важным является анализ микроструктуры материалов, который, в большинстве случаев, сводится к анализу микрошлифов [1]. Микрошлиф – это образец со специально обработанной поверхностью для выявления микроструктуры материала/металла. Цифровые снимки поверхности микрошлифа получают с помощью оптического микроскопа в видимом диапазоне, электронного микроскопа или, например, с помощью атомно-силовой микроскопии.

Анализ микрошлифа позволяет получать более полную картину о состоянии материала и его свойствах на макро- и микроуровнях, а также позволяет контролировать целый спектр физико-механических свойств без проведения отдельных испытаний по каждому из них. Серьезным недостатком данного подхода является то, что для анализа требуется привлечение высококвалифицированных экспертов в области материаловедения и физики твёрдого тела. Также следует учитывать, что результат анализа носит субъективный характер. В настоящее время становится очевидным, что для повышения эффективности и объективности идентификации свойств материалов необходимо применять современные математические методы обработки данных и алгоритмы искусственного

интеллекта для решения задач классификации и идентификации микроструктуры материала.

Функциональные материалы строятся под определенную конструкцию детали машины или механизма. Именно поэтому объем производства таких материалов, в отличие от, например, конструкционных сталей, не столь велик. В таких условиях, крайне важным представляются временные и финансовые затраты на исследования и подготовку технологии производства такого рода материалов. Автоматизированный интеллектуальный анализ микрошлифов позволяет сократить эти затраты, но не может помочь в процессе подбора химического состава и способов термомеханической обработки, которые ведут к созданию функционального материала с заданными свойствами. Цель данной работы заключается в построении и обучении сверточной нейронной сети, способной прогнозировать физико-механические свойства материала по снимкам его микроструктуры.

Известны успехи в распознавании и пространственной локализации объектов методами машинного обучения на основе сверточных сетей, впервые предложенных Яном Лекуном [2]. С помощью миллионов предварительно классифицированных снимков, собранных в массивных базах данных аннотированных изображений, таких как ImageNet или COCO, и метода обратного распространения ошибки удалось достичь действительно впечатляющих результатов [3-5].

Современные методы применяются и в металловедении. В основном, решаются задачи классификации микроструктур. Например, в работе [6] исследуется задача классификации высокоуглеродистых сталей по их микроструктуре с помощью сети VGG-16. Для обучения, тестирования и валидации используется база снимков шлифов CMU-UHCS (Carnegie Mellon University Ultrahigh Carbon Steel), сделанных электронным микроскопом (база содержит 961 маркированный снимок, разбитый на 7 категорий). В [7] предпринята попытка классификации низкоуглеродистых сталей. Использовалось обучающее множество Material Engineering Center Saarland (MECS). В [8] выполнялось распознавание дендритных микроструктур на цифровых снимках микрошлифов. Обучающее множество было сформировано на основе микрофотографий проекта DoITPoMS (Dissemination of IT for the promotion of Materials Science) Кембриджского университета.

Сверточные сети успешно применяются в близких по смыслу задачах определения поверхностных дефектов. В работе [9] с помощью MPCNN (CNN с max-polling слоями подвыборки) поставлена и решена задача классификации поверхностных дефектов стальных труб, несколько позже, авторами [10] решена аналогичная задача классификации поверхностных дефектов стальных листов. В работах [11,12] исследуется способ детектирования дефектов на поверхности рельсов.

В качестве метода обучения сети был выбран традиционный метод стохастического градиентного спуска (SGD). Для устранения переобучения

использовались слои dropout. Для улучшения скорости сходимости применялся метод batch normalization (BN) [13].

Численные эксперименты с сетью VGG-16 проводились как с предобученной на ImageNet сети (сеть VGG-161), так и со случайным начальным распределением весов (сеть VGG-162). Сеть ResNet-20 была предобученной. Предобученные варианты сетей работали с входными изображениями размером 256x256 пикселей.

В качестве программной платформы для реализации сети была выбран фреймворк Keras в связке с библиотекой машинного обучения TensorFlow. Язык реализации Python.

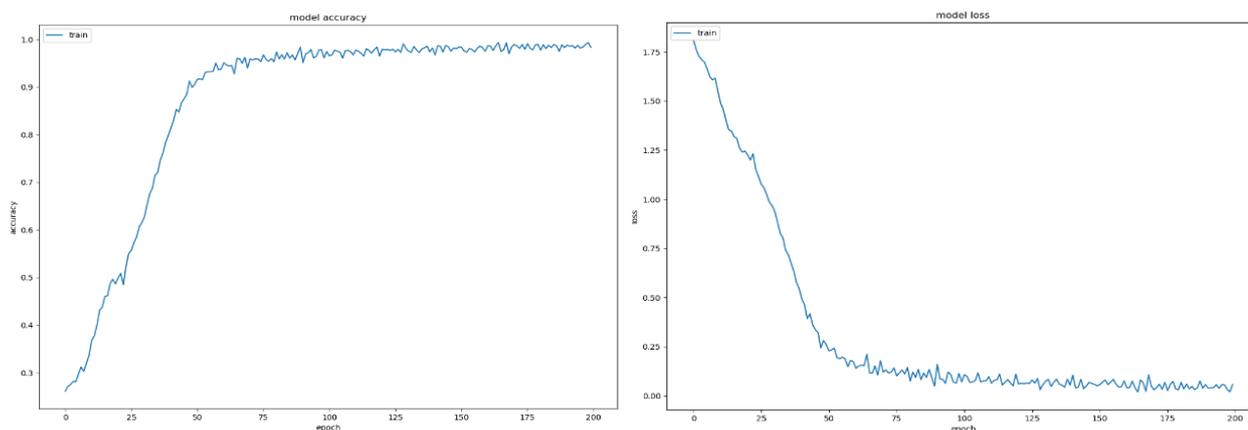
Обучение проводилось на аппаратной платформе со следующими характеристиками: CPU Intel Core i7, 1x GPU GeForce GTX 1080. Один вычислительный эксперимент занимал 12 часов. Обучение сети длилось не более 200 эпох. Расчёт точности приводился один раз в эпоху на тестовом множестве, сформированном из обучающего множества с помощью случайного выбора. Для оценки точности сети применялись критерии Top-1 и Top-3 (ошибкой считается ситуация, когда среди 3-х лучших вариантов нет правильного ответа).

Первая серия экспериментов проводилась на обучающем множестве, разбитом на классы только по микротвердости. В табл. 1 представлены классы микротвердости и распределение обучающего множества по ним.

Таблица 1. Распределение элементов обучающего множества по классам

Классы материалов по микротвердости	Количество снимков в обучающем множестве, шт.	Количество снимков в верификационном множестве, шт.
I класс, (0-2600 МПа)	940	240
II класс, (2600-2900 МПа)	1420	260
III класс, (2900-3200 МПа)	2620	640
IV класс, (3200-3500 МПа)	1480	360
V класс, (3500-5000 МПа)	1980	500

На рис. 1а представлен график изменения точности в процессе обучения VGG-161. На момент окончания обучения точность распознавания сети достигла значения 62.5% по Top-1. На рис. 1б представлена зависимость изменения функции ошибки от номера эпохи.



(а) (б)

Рисунок 1. Изменение показателей точности (а) и функции ошибки (б) при обучении нейросети VGG-16¹

Из рис. 1 видно, что процесс обучения типичен для такого рода задач, устойчиво сходится и каких-то особенностей не имеет.

Результаты показывают, что выбранный подход к исследованию задачи прогнозирования физико-механических свойств материалов, в целом, дает положительные результаты. В табл. 2 показан точность метода для разных классов материалов по микротвердости.

Таблица 2. Точность Top-1 сети VGG-16¹ по классам микротвердости

Классы микротвердости	Точность Top-1
I класс	0,75
II класс	0,5
III класс	0,8125
IV класс	0,5625
V класс	0,4375
Среднее	0,625

Вторая серия экспериментов проводилась с обучающим множеством, разбитым на 14 классов по микротвердости и временному сопротивлению разрушению при растяжении (пределу прочности). В таблице 3 представлены классы и количество снимков, относящихся к данному классу.

Таблица 3. Распределение элементов обучающего множества по классам

Номер класса	Диапазон микротвердости, МПа	Диапазон предела прочности, МПа	Количество снимков, шт.
0	2100-2444	660-830	66
1	2100-2444	831-1001	36
2	2445-2789	831-1001	160
3	2445-2789	1002-1171	47
4	2445-2789	1172-1342	32
5	2790-3134	831-1001	158
6	2790-3134	1002-1171	166
7	2790-3134	1172-1342	30
8	3135-3479	1002-1171	55
9	3135-3479	1172-1342	188
10	3480-3824	1002-1171	28
11	3480-3824	1172-1342	89
12	3825-4169	1343-1513	19
13	4170-4514	1343-1513	22

На данном множестве проводились расчеты с нейросетями VGG-161, VGG-162 и ResNet-20. Как показали расчеты, непредобученная сеть VGG-162 проявляет неустойчивость при обучении. Несколько раз приходилось останавливать расчет, из-за существенной деградации точности или аварии при обучении.

В таблице 4 показаны результаты обучения, выполненные по разным оценкам на обучающем и валидационном множествах.

Таблица 4. Результаты обучения сетей

Сеть	Точность на обучающем множестве		Точность на валидационном множестве	
	Top-1	Top-3	Top-1	Top-3
VGG-16 ¹	0.9751	0.9975	0.4704	0.8117
VGG-16 ²	0.9712	0.9970	0.5203	0.8142
ResNet-20	0.9593	0.9978	0.6243	0.8933

Определенной неожиданностью стало то, что несмотря на неустойчивость обучения, непредобученная сеть VGG-162 показала значительно более лучший результат Top-1 по сравнению с предобученной версией этой же сети. Это можно объяснить тем, что первые слои сверточной непредобученной сети смогли лучше приспособиться к специфическим изображениям микрошлифов. Предобученная сеть предварительно обучалась на очень большом и разнообразном множестве фотографий. Это улучшило

универсальные свойства сети VGG-161 (в особенности ее первых слоев), но ухудшило степень распознавания структур специального вида.

Как и предполагалось, сеть ResNet-20 показала лучший результат 89.3% по оценке Top-3. Показанная точность позволяет использовать обученную сеть в качестве ядра интеллектуальной системы комплексного оценивания прочностных свойств функциональных и конструкционных материалов [14].

Обученная сеть ResNet-20 содержит в рассматриваемом случае всего 67 слоев, среди которых присутствуют входные, сверточные (20), нормализационные, активационные, слои «max polling» и выходные слои (слои персептронов (1) и (2)). Общее количество нейронов в сети 11194510, среди них обучаемых – 11186702.

Следует отметить, что существенное улучшение результатов ResNet-20 было достигнуто при улучшении качества обучающего множества. Из него были исключены образцы снимков с кратностью увеличения $\times 40$. Во-первых, их количество было небольшим, во-вторых, снимки с такой кратностью присутствовали не во всех категориях. Было сделано предположение, что данные снимки ухудшают результаты обучения. Предположение подтвердилось, так как в результате обучения точность ResNet-20 выросла и достигла величины 92.1% по Top-3 и 66.2% по Top-1.

Исследование проводилось при финансовой поддержке Министерства науки и высшего образования РФ в рамках проекта RFMEFI58617X0055.

Библиографический список

1. Gitman M.B., Klyuev A.V., Stolbov V.Y., Gitman I.M. Complex Estimation of Strength Properties of Functional Materials on the basis of the Analysis of Grain-Phase Structure Parameters //Strength of Materials. Vol. 49. No.5. 2017. pp. 710-717
2. LeCun Y., Boser B., Denker J. S., Henderson D., Howard R. E., Hubbard W. and Jackel L. D. Backpropagation Applied to Handwritten Zip Code Recognition // Neural Computation. 1(4). 1989. pp. 541-551
3. Szegedy Ch., Liu W., Jia Y., Sermanet P., Reed S., Anguelov Dr., Erhan D., Vanhoucke V., Rabinovich A. Going deeper with convolutions // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). pp. 1-9 (2015)
4. He K., Zhang X., Ren Sh., Sun J. Deep Residual Learning for Image Recognition // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). pp.770-778 (2016)
5. Hu Jie, Shen Li, Sun G. Squeeze-and-Excitation Networks // ILSVRC 2017 image classification winner. arXiv:1709.01507 (2017)
6. DeCost B., Toby F., Holm Elizabeth A. Exploring the microstructure manifold: image texture representations applied to ultrahigh carbon steel microstructures // Acta Materialia. Vol. 133, pp. 20-40 (2017)

7. Azimi S. M., Britz D., Engstler M., Fritz M., Mücklich F. Advanced Steel Microstructure Classification by Deep Learning Methods. arXiv: 1706.06480 (2017)
8. Аристов Г.В., Ключев А.В. Распознавание и классификация микроструктуры металлов и сплавов с использованием глубоких нейронных сетей // Труды 27-ой Международной конференции по компьютерной графике и машинному зрению (GraphiCon 2017). С.180-183
9. Masci J., Meier U., Ciresan D., Schmidhuber J., Fricout G. Steel defect classification with Max-Pooling Convolutional Neural Networks // The 2012 International Joint Conference on Neural Networks (IJCNN), pp.1-6-131 (2012)
10. Zhou Shiyang, Chen Youping, Zhang Dailin, Xie Jingming, Zhou Yunfei Classification of surface defects on steel sheet using convolutional neural networks // Materiali in tehnologije, Vol.51, pp. 123 (2017)
11. Soukup D., Huber-Mork R. Convolutional Neural Networks for Steel Surface Defect Detection from Photometric Stereo Images // ISVC 2014: Advances in Visual Computing, pp. 668-677 (2014)
12. Faghih-Roohi S., Hajizadeh S., Nuñez A., Babuska R., De Schutter B. Deep convolutional neural networks for detection of rail surface defects. // Proceedings of the 2016 International Joint Conference on Neural Networks (IJCNN 2016), pp. 2584–2589 (2016)
13. Ioffe S. and Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. arXiv:1502.03167 (2015).
14. Шарыбин С.И., Столбов В.Ю., Гитман М.Б., Барышников М.В. Разработка интеллектуальной системы распознавания сложных микроструктур на шлифах металлов и сплавов // Нейрокомпьютеры: разработка, применение. 2014. №.12. С.50-56.

COMPARISON OF CLASSIFICATION MODELS BASED ON DEEP NEURAL NETWORKS SUCH AS RESNET AND VGG

Klestov Roman A., Stolbov Valeriy Yu.

Perm national research polytechnic university

614990, Russia, Perm, Komsomolsky avenue, 29, valeriy.stolbov@gmail.com

This paper explores the possibilities of artificial neural networks and deep machine learning in the problem of predicting the physical and mechanical properties of functional materials. It is shown that the quite popular deep neural network VGG with high accuracy solves the problem of hardness classification of a metal alloy based on iron. The results of processing by the deep neural network ResNet are also demonstrated and a comparison of the results obtained is presented.

Keywords: deep networks, machine learning, functional materials.

ПОВЫШЕНИЕ КАЧЕСТВА ОБОБЩЕНИЯ НЕЙРОННОЙ СЕТИ С ПОМОЩЬЮ ДОБАВЛЕНИЯ ШУМА В ОБУЧАЮЩУЮ ВЫБОРКУ НА ПРИМЕРЕ ЗАДАЧИ ОПРЕДЕЛЕНИЯ ПРОЧНОСТИ БЕТОНА ПО СОСТАВУ ВХОДЯЩИХ В НЕГО КОМПОНЕНТОВ

Румянцев Максим Александрович, Ясницкий Леонид Нахимович

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

Нейросетевые модели обучались как на исходных, незашумленных данных, так и на данных с добавлением различного уровня шума. Приведены результаты экспериментов по обучению нейронных сетей с добавлением различного уровня шума в обучающую выборку, а также представлено сравнение качества обобщения нейронных сетей, обученных на зашумленных и незашумленных данных.

Ключевые слова: искусственный интеллект, нейронные сети, добавление шума в обучающую выборку, борьба с переобучением нейронных сетей, увеличение объема выборки, прочность бетона, прогноз.

Бетон – это строительный материал, получаемый в результате формирования и затвердевания смеси, состоящей из вяжущего вещества (например, цемент), воды, мелких и крупных добавок. Каждый компонент смеси вносит определенное влияние на свойства бетона после затвердевания. Перед постройкой объектов, в состав которых входит бетон, определяется его необходимая прочность и долговечность. Для достижения нужных значений качества бетона подбираются компоненты бетонной смеси, причём желательно, чтобы затраты на эти компоненты были минимальными. Представленная в статье нейросетевая модель способна по составу компонентов, входящих в бетонную смесь, определять прочность на сжатие готового бетона как на момент его затвердевания, так и через заданное время его эксплуатации.

Для построения нейросетевой модели использовались данные, содержащие информацию о составе компонентов, входивших в бетонную смесь, возраст бетона и его прочность на сжатие на момент проведения лабораторных замеров [1]. Всего имелось 1030 примеров, у каждого из которых было 9 атрибутов:

1. Масса цемента (кг) в кубическом метре бетонной смеси.
2. Масса доменного (кг) шлака в кубическом метре бетонной смеси.
3. Масса зольной пыли (кг) в кубическом метре бетонной смеси.
4. Масса воды (кг) в кубическом метре бетонной смеси.
5. Масса суперпластификатора (кг) в кубическом метре бетонной смеси.
6. Масса крупных заполнителей (камни, щебень) (кг) в кубическом метре бетонной смеси.
7. Масса мелких заполнителей (песок) (кг) в кубическом метре бетонной смеси.
8. Возраст бетона (дни).
9. Прочность бетона на сжатие (МПа).

Первые восемь атрибутов выступали в качестве входных данных нейронной сети, девятый атрибут – в качестве выходных данных. Проектирование, обучение и тестирование нейронной сети производилось в пакете STATISTICA 12 по методике [2]. Нейронная сеть имела восемь входов, один скрытый слой и один выход. Полученная относительная ошибка обучения составила 12.63%, а тестирования – 13.61%. Выборка из результатов тестирования нейронной сети представлена на рисунке 1. Значимость параметров представлена на рисунке 2.

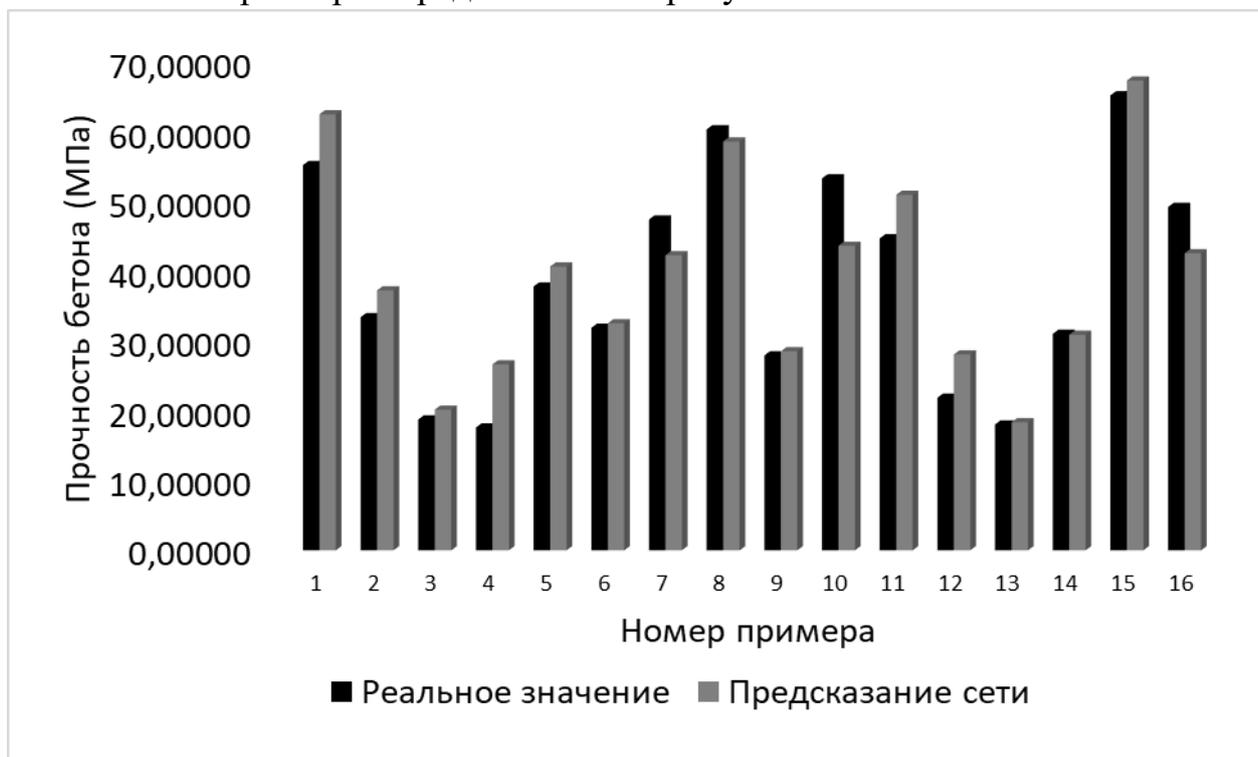


Рисунок 1. Сопоставление реальных значений прочности с результатами нейросети на тестовых примерах

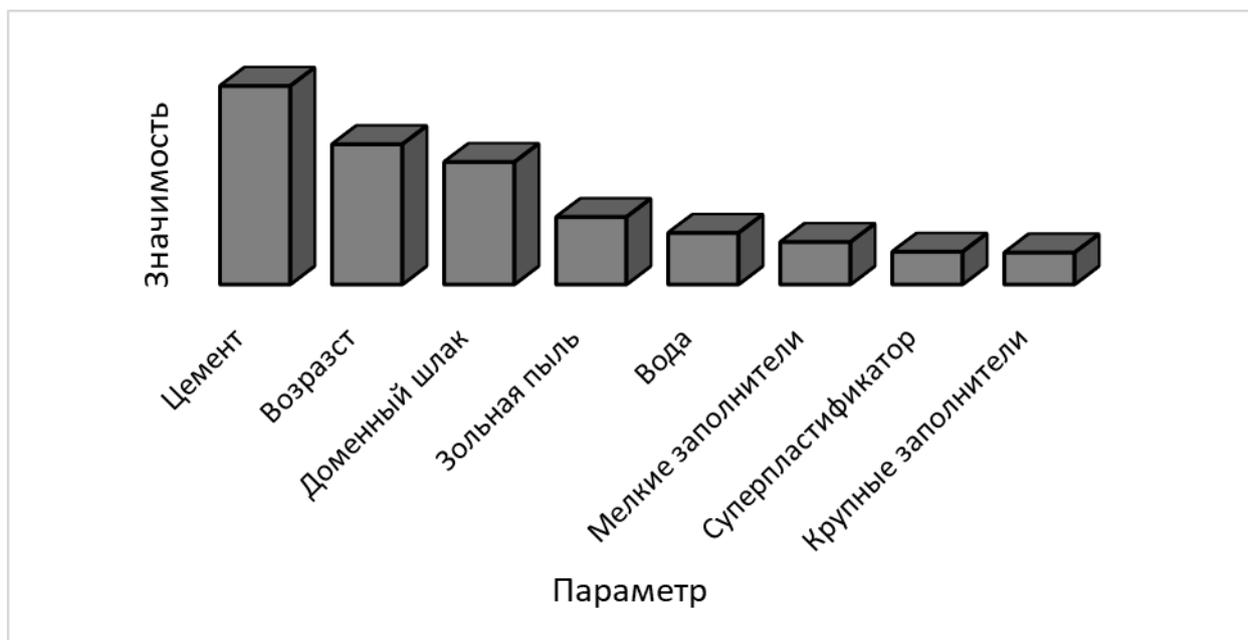


Рисунок 2. Значимость входных параметров нейронной сети

Как видно из графика, наиболее сильно на прочность бетона влияют масса цемента в одном кубическом метре бетонной смеси, возраст бетона и масса доменного шлака в одном кубическом метре смеси.

Так как объем исходных данных был невелик, было принято решение увеличить объем имеющейся выборки путем добавления в нее шума ко входным сигналам (к первым восьми атрибутам). Метод добавления шума применяется не только для увеличения объема исходной выборки (особенно этот метод полезен в случаях, когда большую выборку собрать сложно или невозможно), но и для улучшения обобщающей способности сети – шум вырабатывает нечувствительность нейронной сети к небольшим вариациям входных сигналов, из-за чего сеть меньше подвержена переобучению [3, 4]. А у переобученной сети, как известно, способности к обобщению нет, из-за чего её использование не несет никакой практической пользы.

На текущий момент нет строгих теорем, связанных как с определением точного количества шума, которого можно добавить к исходным данным, так и с допустимым уровнем шума. Эти параметры необходимо определять экспериментально для каждой задачи. Например, в работе [5] решалась задача классификации: по ГИС-данным определялось, есть ли в определенном квадрате местности залежи золота, или нет. Первоначальная точность классификации составляла 67.9%, однако после добавления случайного $\pm 40\%$ шума в обучающую выборку и повторного обучения нейросетевой модели, точность классификации увеличилась до 72.8%. В работе [6] решалась задача классификации опухолей на снимках УЗИ молочных желез. Цель состояла в том, чтобы отличить злокачественные опухоли от доброкачественных. После добавления гауссовского шума с нулевым математическим ожиданием к обучающей выборке, качество классификации было улучшено (в лучшем варианте площадь под ROC-кривой, использовавшаяся в задаче в качестве метрики качества

классификации, увеличилась на 0.03). При этом, происходил экспериментальный перебор объема добавляемого шума для нахождения такого его количества, при добавлении которого результат классификации оказывался наилучшим.

Для чистоты эксперимента было решено варьировать как уровень добавляемого шума, так и его количество. Это реализовывалось следующим образом: исходная обучающая выборка целиком копировалась (при этом в разных экспериментах копия могла быть как одна, так и несколько – таким образом варьировался объем добавляемого шума: размер обучающей выборки удваивался, утраивался и т.д.); к каждому примеру в скопированной выборке добавлялся шум: например, если допустимый уровень добавляемого шума равнялся $\pm 5\%$, то в каждом примере значения каждого атрибута принимали новое значение, лежащее на промежутке от 95% до 105% от исходного, таким образом в рамках одного примера значения каждого атрибута могли измениться на разное число процентов, но это значение не превышало допустимый уровень добавляемого шума. После того, как все примеры скопированной выборки зашумлялись, она объединялась с исходной обучающей выборкой и вместе они использовались как новое обучающее множество. Тестовое множество оставалось неизменным как при обучении нейронных сетей на незашумленных данных, так и на зашумленных.

Для определения оптимального количества и уровня добавляемого шума в данной задаче было проведено двенадцать экспериментов. Объем исходной обучающей выборки за счет добавления шума удваивался, утраивался и учетверялся. При этом уровень добавляемого шума был равен $\pm 5\%$, $\pm 10\%$, $\pm 15\%$ и $\pm 20\%$. Эти цифры не взяты с потолка, ход эксперимента регламентировался двумя правилами: если при увеличении объема добавляемого шума ошибка тестирования начинала расти, то больше количество добавляемого шума не увеличивалось; если при увеличении уровня добавляемого шума ошибка тестирования начинала расти, то больше уровень шума не увеличивался.

В результате было получено еще двенадцать нейросетевых моделей, обученных на данных с добавлением объема шума разного объема и уровня. Наименьших значений ошибок удалось достичь при добавлении $\pm 10\%$ уровня шума, объем которого равен объему исходной обучающей выборки (удвоенная обучающая выборка): относительная ошибка обучения составила 11.42%, а ошибка тестирования – 11.98%. На рисунке 3 представлен график зависимости значения относительной ошибки тестирования от объема и уровня шума во входных данных.

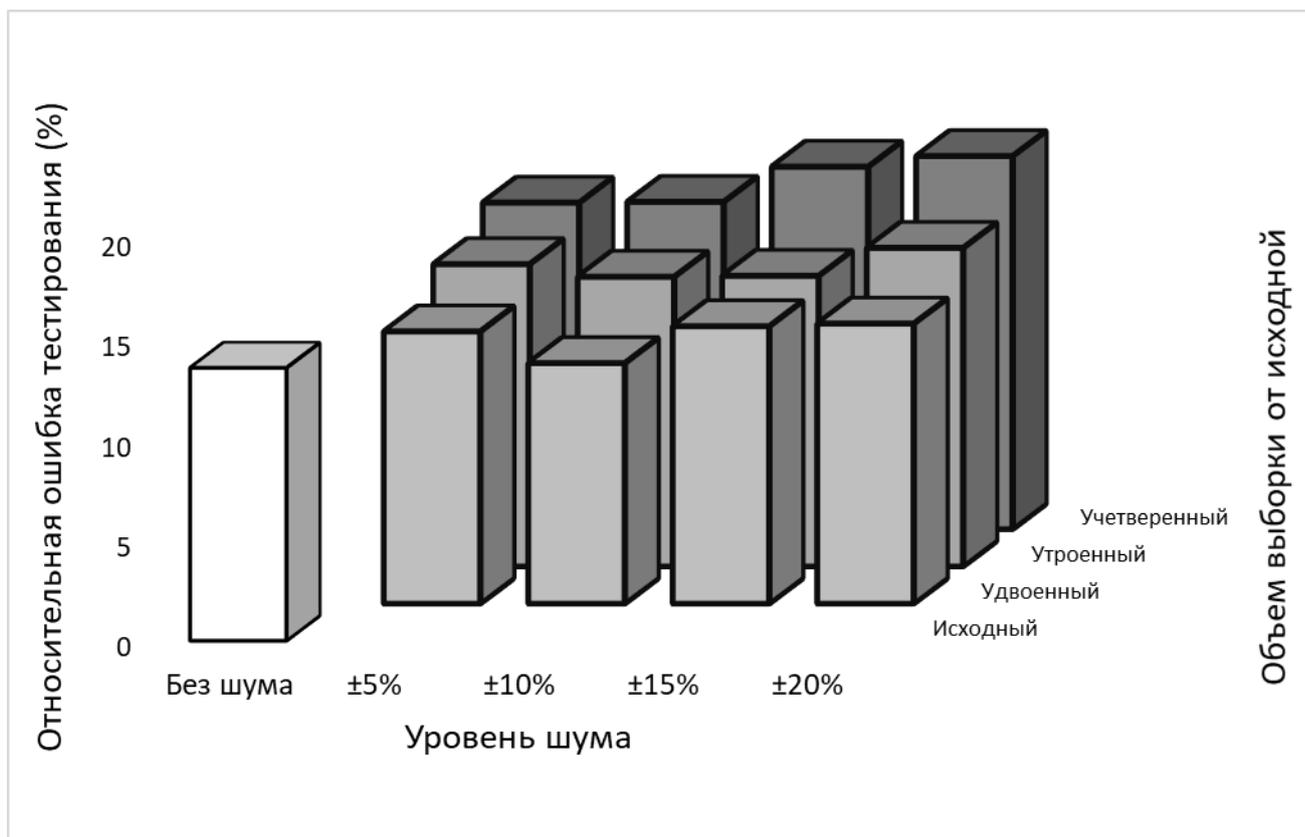


Рис. 3. Размер относительной ошибки тестирования в зависимости от уровня шума в обучающей выборке

Как видно из графика, чем больше шума с заданным уровнем добавлялось к обучающей выборке, тем выше была ошибка тестирования. При этом при заданном объеме добавляемого шума наименьшая ошибка тестирования достигалась тогда, когда его уровень был на уровне $\pm 10-15\%$, при увеличении уровня шума ошибка также начинала возрастать.

Таким образом, за счет использования метода добавления шума к обучающей выборке, ошибку обобщения нейросетевой модели удалось уменьшить на 12%. Поэтому, можно заключить, что использование этого метода вполне способно улучшить качество обобщения модели, однако его существенным недостатком является то, что заранее неизвестно количество и уровень шума, с помощью которого можно уменьшить ошибку тестирования модели, из-за чего этот метод применяется нечасто.

Библиографический список

1. Machine Learning Repository [Электронный ресурс] [Режим доступа: <https://archive.ics.uci.edu/ml/datasets/Concrete%2BCompressive%2BStrength>] [Проверено: 16.03.2019].
2. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005, 176 с.
3. Осовский С. Нейронные сети для обработки информации / Пер. с польского И.Д. Рудинского. М.: Финансы и статистика, 2002. – 344 с.

4. Train Neural Networks With Noise to Reduce Overfitting [Электронный ресурс] [Режим доступа: machinelearningmastery.com/train-neural-networks-with-noise-to-reduce-overfitting] [Проверено: 16.03.2019].
5. Brown, W.M., Gedeon, T.D., Groves, D.I. Use of noise to augment training data: a neural network method for mineral-potential mapping in regions of limited known deposit examples // Natural Resources Research. – 2003. – №12(2). С. 141-152.
6. Zur, R.M., Jiang, Y., Pesce, L.L., Drukker K. Noise injection for training artificial neural networks: A comparison with weight decay and early stopping // Medical Physics. – 2009. – №36(10). С. 4810-4818.

IMPROVING THE QUALITY OF THE GENERALIZATION OF A NEURAL NETWORK BY ADDING NOISE TO A TRAINING SAMPLE ON THE EXAMPLE OF THE PROBLEM OF DETERMINING THE CONCRETE COMPRESSIVE STRENGTH BY COMPOSITION OF COMPONENTS INCLUDED IN THE CONCRETE MIX

Rumyantsev Maksim A., Yasnitsky Leonid N.

Perm State University,

614990, Russia, Perm, Bukireva st., 15, rummaksim@gmail.com

Neural network models were trained both on the initial, pure data, and on data with addition of various levels of noise. There are presented results of experiments on the training of neural networks with the addition of different levels of noise in the training sample, comparison of the quality of generalization of neural networks trained on noisy data and clean data.

Keywords: artificial intelligence, neural networks, adding noise to the training sample, neural networks overfitting, increasing sample size, concrete compressive strength prediction.

МЕТОДЫ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ НЕЙРОСЕТЕВЫХ СИСТЕМ В УСЛОВИЯХ ОГРАНИЧЕННЫХ ОБЪЕМОВ ВЫБОРОК СО СЛОЖНЫМИ КОРРЕЛЯЦИОННЫМИ СВЯЗЯМИ

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 описаны методы, позволяющие повысить эффективность применения нейросетевых систем, применяемых в областях, для которых сложно собрать большой объем данных для формирования обучающей выборки.

Ключевые слова: аномальные наблюдения, выбросы, информативность, система диагностики, нейронная сеть, нейросетевая модель.

Введение. В настоящее время появляется всё большее количество информационных систем, использующих в своей основе нейросетевые модели. Для создания нейросетевых моделей необходимо иметь качественную выборку данных для обучения и тестирования нейронной сети, но, в силу большого числа факторов, отрицательно влияющих на качество выборки, это становится непростой задачей. Одним из путей решения указанной проблемы является использование выборок большого объема и нейронных сетей глубокого обучения. Но не во всех задачах возможно собрать достаточный объем данных, а сети глубокого обучения, в большинстве своем, предназначены для анализа данных большой размерности. В этом случае необходимо иметь возможность извлекать как можно больше информации из имеющегося набора данных при помощи нейросетевых архитектур, предназначенных для обработки небольших объемов данных. Однако, чем меньше набор данных, тем большее отрицательное влияние на него оказывают такие факторы как наличие аномальных наблюдений, недостаток или большое количество входных параметров.

Кроме того, в практике нейросетевого моделирования часто встречаются задачи, характеризующиеся наличием сильных внутрисистемных связей между входными параметрами, что является препятствием создания

качественных нейросетевых моделей, в том числе предназначенных для прогнозирования процессов, развивающихся во времени.

Примерами таких задач являются персонифицированная диагностика, прогнозирование развития и лечение заболеваний, при решении которых должны в максимальной степени учитываться особенности каждого конкретного человека, при том, что собрать большой объем обучающей выборки довольно сложно, а входные параметры связаны между собой сложными корреляционными зависимостями, не имеющими строгого математического описания.

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]. Нейросетевые модели, составляющие основу интеллектуальной системы, обучены на статистической информации, сформированной с помощью данных о 1000 пациентах отделения неотложной кардиологии ГАУЗ ПК ГKB №4 г. Перми. Данная система показала свою адекватность и высокую степень достоверности выставляемых диагнозов, что было достигнуто благодаря применению описанных далее методов повышения эффективности нейросетевых систем.

Выявление аномальных наблюдений. Для выявления аномальных наблюдений в обучающем множестве с малым количеством наблюдений, нами был предложен метод, основанный на методе анализа удаленных остатков, который заключается в поочередном исключении примеров из обучающего множества, и последующей оценке изменения погрешностей ИНС, обученной на этих обучающих выборках, при прочих равных условиях [3-5], но вместо регрессионной модели используется нейросетевая модель.

На основе данного метода поочередного исключения примеров возможно реализовать ряд алгоритмов для выявления аномальных наблюдений, которые отличаются процедурой анализа влияния удаления каждого из примеров на показатели нейросетевой модели, полученные в результате работы алгоритма. Ниже приведены два таких алгоритма, которые назовем: «Анализ ошибки обучения» (Алгоритм 1) и «Анализ ошибки обобщения» (Алгоритм 2).

Алгоритм 1 основывается на том факте, что при отсутствии аномальных наблюдений в обучающем множестве процесс обучения будет иметь лучшую сходимость, и средняя среднеквадратичная ошибка обучения, вычисляемая после завершения процесса обучения по формуле:

$$E(L_p) = \frac{1}{Q_L J} \sum_{q=1}^{Q_L} \sum_{j=1}^J (y_{qj} - d_{qj})^2 \quad (1)$$

будет меньше, по сравнению с тем же показателем на множестве, в котором этот пример присутствует.

Здесь: L_p – обучающее множество с исключенным p -м примером; y_{qj} – значение j -го выходного сигнала ИНС для q -го обучающего примера; d_{qj} – желаемое значение j -го выходного сигнала для q -го обучающего примера; J – число нейронов в выходном слое; Q_L – количество примеров в обучающем множестве;

Как показал опыт, Алгоритм 1 хорошо работает на небольших обучающих множествах, в которых встречается не больше одного аномального примера. Для выборок, содержащих более ста элементов, предлагается применять **Алгоритм 2**. Идея этого алгоритма основана на том факте, что если p -й пример является аномальным, то после обучения сети на множестве, не содержащем этого примера, среднеквадратичная ошибка обобщения сети на этом примере

$$e_p = \frac{1}{J} \sum_{j=1}^J (y_{pj} - d_{pj})^2 \quad (2)$$

Здесь: y_{pj} – значение выходного сигнала ИНС для p -го обучающего примера; d_{pj} – желаемое значение выходного сигнала для p -го обучающего примера.

Если в обучающей выборке помимо примера с номером p имеются и другие аномальные наблюдения, то, несмотря на это, ошибка (2) для p -го аномального наблюдения по-прежнему будет больше ошибок примеров без аномалий.

Вычисление информативности входных параметров. Наличие данных об относительной информативности каждого из входных параметров позволяет использовать сокращенный набор входных параметров, а также позволяет упростить структуру ИНС. Для решения этой задачи часто используется метод вычисления корреляции Пирсона, который хорошо подходит для описания линейных зависимостей или близких к ним, ранговые коэффициенты корреляции Фехнера, Кендалла, Спирмена, множественной ранговой корреляции, чувствительные только лишь к упорядоченным значениям переменных. Кроме того, для этих целей применяется коэффициент детерминации R^2 , и его модификации (скорректированный, обобщенный), которые решают часть проблем присущих стандартным методам, но требуют построения адекватной регрессионной модели, что не всегда возможно в задачах, в которых применяется аппарат искусственных нейронных сетей (ИНС).

Для вычисления информативности входных параметров, в условиях малых выборок предложен метод, основанный на анализе нейросетевой модели [5]. Идея предлагаемого метода основывается на том факте, что при замене значений значимого входного параметра на псевдослучайные числа качество нейросетевой модели значительно падает.

Алгоритм, реализации данного метода выглядит следующим образом: на первом шаге ИНС обучается на исходном множестве L обучающих примеров. В результате обучения будет получена нейросетевая модель H .

На втором шаге вычисляется средняя среднеквадратичная ошибка модели на обучающем множестве $e = E(L)$. Данное значение ошибки используется в качестве эталона для сравнения с ошибками, полученными при дальнейших изменениях обучающего множества. На следующем шаге алгоритма выполняется цикл по всем параметрам исходного обучающего множества с целью определения меры его влияния на конечный результат. Предположим, что параметр x_i несёт большую информативность для модели, т.е. какая-либо значащая часть вариации на обучающем множестве объясняется этим параметром, тогда отсутствие этого параметра или искусственная рандомизация его значений во входных векторах повлечет утерю этой доли информативности и увеличение необъясненной вариации, т.е. ошибки E_i , вычисленной на обучающем $E(L)$ или тестовом $E(T)$ множестве. Под рандомизацией параметра x_i предлагается использовать как можно менее коррелированную случайную величину, желательно имеющую то же, или похожее распределение $x_i = \tilde{X}$. Чтобы получить такую случайную величину было предложено использовать значения параметра x_i , перемешанные в случайном порядке.

К преимуществам данного метода по сравнению с другими методами вычисления силы зависимости переменных (например, [6, 7]) относятся: более точная оценка силы зависимости для нейросетевых моделей в условиях ограниченных объемов выборок со сложными корреляционными связями.

Прогнозирование процессов со сложными корреляционными связями между входными параметрами. Обученную и протестированную нейросетевую модель возможно использовать для исследования закономерностей предметной области. Например, изменяя какой-либо один или несколько входных параметров, например возраст, вес, привычки и др., как в случае нейросетевой модели медицинской диагностики, и 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 внутренние корреляционные связи, 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.

Первый метод повышения точности прогнозирования, названный *методом экспертной коррекции*, для решения данной проблемы использует Европейскую шкалу «SCORE», предназначенную для расчёта риска смерти от сердечно-сосудистого заболевания в будущие периоды жизни пациента,

для корректировки результатов прогнозирования, выдаваемых нейросетевой моделью [1, 2, 8].

Анализ усредненных данных этой шкалы, показал, что за пятилетний период от 50 до 55 лет риск смерти от заболевания ССС для среднестатистического пациента увеличивается в приблизительно в $\lambda \approx 1,6$ раза, за десятилетний срок от 50 до 60 лет – в 2,7 раза, за пятнадцатилетний срок от 50 до 65 лет – в 4,3 раза.

Недостаток данного метода состоит в том, что он опирается на усреднённые статистические данные и не учитывает индивидуальные особенности конкретного пациента.

Для устранения этого недостатка предлагается использовать идею метода скользящего окна, который обычно применяется при прогнозировании временных рядов [8]. Для применения данного метода необходимо иметь множество наблюдений за изменением состояния объекта во времени. В случае медицинской диагностики такими наблюдениями являются данные о повторных посещениях больным лечащего врача, которые назовем историческими.

Суть метода заключается в следующем: пусть имеется история наблюдения за одним пациентом на протяжении T временных интервалов. Каждое такое наблюдение представляет собой пару векторов, аналогичных тем, что использовались для обучения и тестирования нейронной сети в предыдущих главах (\bar{x}_t, \bar{d}_t) , где: \bar{x}_t – входные параметры за t -й временной интервал; \bar{d}_t – выходные параметры за t -й временной интервал, $t \in [1, T]$. Сформируем из них примеры обучающего множества, беря в качестве входных параметров значения показателей пациента \bar{x}_t , а в качестве выходных значений – диагнозы за следующий временной интервал \bar{d}_{t+1} . Таким образом мы получим следующее множество из $T-1$ элемента: $\left[(\bar{x}_1, \bar{d}_2), (\bar{x}_2, \bar{d}_3), \dots, (\bar{x}_{t-1}, \bar{d}_t), \dots, (\bar{x}_{T-1}, \bar{d}_T) \right]$ на основе истории одного пациента. Повторив эту операцию для всех данных, получим множество примеров, которое применимо для обучения и тестирования нейросетевой модели, предназначенной для прогнозирования развития заболевания на один временной интервал вперед.

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* 2015. 7(2): BM-095-15, 8 pages.
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. Черепанов Ф.М., Ясницкий Л.Н. Нейросетевой фильтр для исключения выбросов в статистической информации // Вестник Пермского университета. Математика. Механика. Информатика. – Пермь: Изд. Пермского ун-та, – 2008. – Вып.4 (20). – С.151-155.
4. Черепанов Ф.М. Выявление аномальных наблюдений в обучающем множестве посредством нейросетевой модели // Проблемы информатики в образовании, управлении, экономике и технике: Сб. ст. Международной научно-технической конф. – Пенза – 13-14 ноября 2014 г. – Приволжский Дом Знаний – 2014. – с. 210.
5. Черепанов Ф.М. Симулятор нейронных сетей для вузов // Вестник Пермского университета. Математика. Механика. Информатика. – Вып.3(11). – Пермь: Изд. Пермского ун-та, – 2012. – С.98-105.
6. Olden, J.D. An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data / J.D. Olden, M.K. Joy, R.G. Death // Ecological Modelling. – 2004. – Т. 178. – № 3-4. – С. 389-397.
7. Kemp, S.J. An approach for determining relative input parameter importance and significance in artificial neural networks / S.J. Kemp, P. Zaradic, F. Hansen // Ecological Modelling. – 2007. – Т. 204. – № 3-4. – С. 326-334.
8. Cherepanov F.M., Yasnitsky L.N., Dumler A.A. The Capabilities of Artificial Intelligence to Simulate the Emergence and Development of Diseases, Optimize Prevention and Treatment Thereof, and Identify New Medical Knowledge // Journal of Pharmaceutical Science and Research. 2018. Vol. 10(9). pp. 2192-2200

ETHODS TO IMPROVE THE EFFICIENCY OF NEURAL NETWORK SYSTEMS IN CONDITIONS OF LIMITED VOLUME VOLUMES WITH COMPLEX CORRELATION CONNECTIONS

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 methods that make it possible to increase the efficiency of using neural network systems used in areas for which it is difficult to collect a large amount of data to form a training sample.

Key words: abnormal observations, outliers, informative, diagnostic system, neural network, neural network model.

РОЛЬ ЭМОЦИЙ В АРХИТЕКТУРЕ ИСКУССТВЕННОГО АГЕНТА НА ПРИМЕРЕ КОНЦЕПЦИИ «НЕБРЕЖНЫХ КОГНИЦИЙ»

Шиллер Александра Викторовна,

Московский государственный университет имени М. В. Ломоносова,
119192, Россия, г. Москва, Ломоносовский просп., 27, к.4,
shiller.a@gmail.com

В статье описан подход к созданию архитектуры искусственного агента, названный концепцией «небрежных когниций». Данная концепция опирается на теории воплощенного сознания и исследования роли эмоций в интеллектуальной деятельности субъекта. Предлагается новый подход к архитектуре искусственных агентов, включающей в себя использование четырех механизмов – байесовских статистических подходов, моделирования эмоций, системы принятия решений и неиерархических информационных стратегий.

Ключевые слова: воплощенные когниции, эмоции, когнитивно-аффективная архитектура, моделирование эмоций

В последнее время можно наблюдать усиление запроса со стороны компьютерных наук к природному пониманию рациональности, однако, разрабатываемые в русле этих наук подходы до этого не предлагали использовать аффективно-когнитивную модель для создания ИИ. Генетические алгоритмы, роевой интеллект, нейроморфный интеллект, эволюционистское вычисление (evolutionary computation), искусственные нейронные сети, эпигенетическая и эволюционная робототехника пытаются использовать одну или ограниченный набор когнитивных стратегий, которые естественным образом вовлечены в некоторые процессы или возникают во время культурной кооперации (индукция, абдукция, дедукция, герменевтическое рассуждение, рассуждение по аналогии...). Даже искусственно воплощенные подходы пытаются использовать только малое число когнитивных стратегий для обработки информации.

Архитектуры с использованием категоризации являются более хорошим примером подходов, преодолевающих эти ограничения, хотя их реализация не подходит в качестве фундаментального подхода для искусственного мышления. Архитектуры LIDA, CogAff или CLARION действительно являются знаковыми для развития искусственных когнитивных систем, но они не включают в себя ошибки, смещения или путаницу как фундаментальные характеристики когнитивных систем.

Некоторые из более ранних подходов не рассматривают [1, 6] реальную значимость ситуативности когнитивных процессов, которая включает в себя экологическое соответствие между телом и разумом и значимые компоненты окружающей среды (другие агенты, сообщества, объекты, физические состояния).

Можно заключить, что существующие в настоящее время методы комбинирования знаний и подходов к рассуждению подвержены влиянию классических формальных и статистических подходов к пониманию когнитивных/информационных процессов.

Для создания новой автономной и креативной программы ИИ необходимо учесть преимущества воплощения разнообразных когнитивных стратегий, которые подразумевают естественное рассуждение (неточное) или даже ошибочные аргументативные процессы. Богатство и превосходство человеческого знания в своей основе состоит в несогласованности большинства процессов рассуждения как глобального набора истин, а также в учете экстракогнитивной роли факторов, направляющих поведение. Среди таких факторов можно отметить, например, вклад мутантного гена DRD4-7r или «гена путешественника», очень разнообразное и сложное управление человеческим мозгом с помощью нейротрансмиттеров, которое объясняет личностные черты/настроение/аттитюды, роль зеркальных нейронов, и еще множество «маленьких» аспектов, которые определяют как происходят когнитивные процессы. Такой холистский, целостный подход является крайне идеалистичным вариантом, и он не создан в настоящее время, также, как и не учитывается ключевая роль «ошибочных» способов аргументации.

Стоит отметить, что на сегодняшний день более перспективным является использование отдельных хорошо разработанных теорий для отдельных участков архитектуры модели искусственного агента. Также стоит учитывать культурно-специфичные и противоположные друг другу определения логических аксиом, характерных для Востока и Запада. Это ставит важный вопрос – нужно ли учитывать культурную специфику при создании искусственных агентов? И если ответ положителен, то насколько различны будут такие искусственные агенты?

Под воплощением понимается физическая реализация связанных с телесностью переменных у физических машин; например, функциональные аспекты биомимикрирующего нейрокомпьютинга или роль эмоций, которая должна пониматься как целостный процесс, включающий не только набор нейронов, но и общую картину работы мозга в отдельном теле при ситуативном сценарии. Это подразумевает учет мультимодальной природы эмоций, учет всех сфер – когнитивной, аффективной, объектной (внешний окружающий мир), абстрактной, поведенческой и физиологической [5].

Проблемы возникают, когда мы полагаем, что такая богатая реализация когнитивных техник у человека связана с присутствием некоторых «слабостей» и нарушений рассуждений как минимум со стороны «идеальной ситуации». Но именно поэтому, как это ни парадоксально, необходимо создание подхода «неточного ИИ», преимуществом которого будет

смещение разнообразных эвристик для того, чтобы произвести адекватный ответ. Опять же понятие «адекватности» прямо относится к существованию оптимальных взаимоотношений между контекстом, информацией и решением. Здесь система с необходимостью будет вынуждена принять решение среди нескольких вариантов, относящихся к текущему состоянию, которое не всегда будет подразумевать принятие лучшего решения, но просто более адекватного этому богатому набору переменных, которые охватывают морфологические, социальные, культурные и ситуативные состояния [4].

Этот подход должен включать в себя реализацию следующих механизмов:

Баесовские статистические подходы. Из-за того, что невозможно придерживаться только одного подхода в методологии статистики при реальном научном исследовании, некоторые формы Баесианства кажутся наилучшим способом выполнять статистические вычисления для широкого круга проблем. Баесовские статистические методы показали себя хорошо применимыми для некоторых высокотеоретических и связанных с телесностью вычислений (зрение, мультимодальная селекция, моделирование эмоций). Обучение на опыте и добавление уже известного в анализ последующих ситуаций кажется наилучшим методом с эволюционистской точки зрения, принимая во внимание необходимость адаптации к новым или изменяющимся условиям окружающего мира.

Моделирование эмоций. Вторым механизмом такого подхода является создание в каком-либо виде архитектуры эмоций. Хотя достоверно известно, что некоторые чисто символические программы, использующие неестественные рассуждения, достигли или достигают впечатляющих результатов (классические экспертные системы, или улучшенные как Deep Blue, Watson, AlphaGo), соединяющие машинное обучение, глубокое обучение и другие техники, но, в то же время ясно, что такие системы не могут работать в нормальной человеческой среде и что их архитектуры существуют в специфических вычислительных условиях. С точки зрения филогенетики именно эмоциональные механизмы позволяют базовым биологическим системам оценивать и адаптировать свои решения к собственным физическим структурам. В то же время, неврологические данные показывают, что эмоциональные механизмы добавляют богатство и разнообразие абстрактным рассуждениям, и это было использовано некоторыми исследователями при разработке мимикрирующих под биологические эмоциональных искусственных когнитивных систем [3]. Здесь нужно отметить, что автор не подразумевает создание человекоподобной эмоциональной системы, которая пригодна только для взаимодействия человек-машина, вместо этого кажется важной разработка искусственной системы, способной интенционально оценить информацию и переадаптировать свои стратегии согласно динамическому состоянию системы. При этом может возникнуть проблема черного ящика –

разработчики не будут в итоге понимать полностью механизмы работы такого искусственного агента.

Система принятия решений. Нужно отметить, что эмоциональная архитектура является результатом соединения когнитивной и физиологической модальностей (а также ряда других модальностей), которые, в конце концов, приводят к появлению сложной, смешанной картины реальности. При этом важно помнить, что только культурно-специфичное рассуждение является подлинно экологически-ситуативным. С точки зрения системного подхода физические и психофизиологические компоненты определяют и изменяют те способы, с помощью которых некоторый объект ориентируется в мире. Именно этим можно объяснить, в том числе личные и коллективные действия, поэтому роль таких компонентов важно учитывать и помнить о необходимости различных семантических и синтаксических структур, а также собственно системы принятия решений при разработке архитектур искусственных агентов [2].

Неиерархические информационные стратегии. Наконец, при рассмотрении разных способов обращения с информацией, некоторые эвристики могут быть совмещены или соединены с разными этапами оценки данных. Наиболее важным является создание связи предыдущих разделов подхода с неиерархической рекурсией различных процессов (абдуктивных, индуктивных, дедуктивных, аналогий, разных форм статистических процессов, даже протекающих под влияниями или в «неточных» подходах). Естественное рассуждение должно пониматься за пределами статистических количественных контекстов, потому что такие рассуждения должны быть способны на качественный анализ. На примере естественного человеческого рассуждения мы можем наблюдать большой набор вариаций между этими состояниями (переходы от количественных к качественным состояниям). Некоторые иррациональные черты, например, вера или интуиция, противопоставленные точным доказательствам, показывают свою состоятельность даже в случаях научных открытий и драматических сломов научных парадигм.

Сравнительный анализ исторических достижений в когнитивных науках, а также существование разных способов создания систем ИИ представляют отличный материал для размышления над новыми возможными достижениями и подходами в этой области. С одной стороны, достижения в области исследования механизмов человеческого мышления и рассуждения способствовали созданию и определению новых подходов, способствующих реальному пониманию этих феноменов, причем без классического и сверхидеалистического взгляда на процесс мышления. С другой стороны, история ИИ и робототехники показывает все за и против экстремально символических моделей, но использующие такие стратегии подходы все еще реализуются без каких-либо изменений. Благодаря исследованиям процессов естественного рассуждения, их логическим, статистическим и вычислительным преимуществам появились и были реализованы новые инструменты и возможные методологии. Все это

согласуется с мнением ведущих ученых и разработчиков систем ИИ о том, что грядет 3 волна ИИ, потому что все предыдущие подходы не достигли тех целей, которые ставились перед ними, хотя и были успешны в некоторых областях [7].

В этой статье предлагается новое понятие аффективно-когнитивной сферы или «небрежных когниций». Эта идея отражает и объясняет реальные и многогранные когнитивные процессы, которые сопровождают человеческую деятельность. Люди не только обладают разными когнитивными и аргументативными процессами с разными сценариями, но и могут соединять их друг с другом во время протекания события или цепочки событий. Рассуждения, кроме наличия классических символических и логических элементов, включают в себя убеждения, предварительные оценки значимости данных или правдоподобности некоторой методологии, исследовательское поведение, ограниченное социальными нормами, и многие другие аспекты. Естественное человеческое рассуждение экспериментальное, оппортунистское, подверженное влияниям и очень креативное благодаря его сложной природе и вовлеченности ряда сопутствующих процессов, например, эмоционального сопровождения. Следовательно, при создании стратегий рассуждения в искусственных агентах следует включать этот смешанный подход для того, чтобы сделать агентов более правдоподобными и реалистичными, а также для достижения реального прогресса в области моделирования искусственных агентов.

Библиографический список

1. Anagnostopoulos C., Hadjiefthymiades S., “Situational computing: an innovative architecture with imprecise reasoning”, *Journal syst. Software*, vol. 80, no. 12 spec. issue, pp. 1993-2014, 2007
2. Beuls K., Steels L., Agent-based models of strategies for the emergence and evolution of grammatical agreement, *PLoS One*, vol. 8, no. 3, 2013
3. Bridges M. and co., *Agent and multiagent systems: technologies and applications*, vol. 38, 2015
4. Douglas M., *Thought styles: critical essays on good taste*, London: SAGE Publications, 1996
5. Hudlicka E., From Habits to Standards: Towards Systematic Design of Emotion Models and Affective Architectures, from book “Emotion Modeling: Towards Pragmatic Computational Models of Affective Processes”, pp.3-23, 2014
6. Kanal J., Perlis D., “Uniform accountability for multiple models of reasoning”, *Int. journal Approx. Reasoning*, vol/ 2, no. 3, pp. 233-246, 1988
7. Voss P., The third wave of AI, 2017 (<https://becominghuman.ai/the-third-wave-of-ai-1579ea97210b>)

THE ROLE OF EMOTION IN THE ARCHITECTURE OF AI AGENT ON THE EXAMPLE OF THE “CASUAL COGNITIONS”

Shiller, Alexandra V., Moscow M.V. Lomonosov State University
119192, Russia, Moscow, Lomonosovsky avenue, 27.4,
shiller.a@gmail.com

The article describes an approach to creating an artificial agent architecture, called the concept of “casual cognitions.” This concept is based on the theory of embodied consciousness and the studies of the role of emotions in the intellectual activity of the subject. A new approach to the architecture of artificial agents is proposed, including the use of four mechanisms – Bayesian statistical approaches, emotion modeling, decision-making systems and non-hierarchical information strategies.

Key words: embodied cognition, emotions, cognitive-affective architecture, modeling of emotions.

ЦИФРОВАЯ ЭКОНОМИКА

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ РЫНКА СТОИМОСТИ АВТОМОБИЛЕЙ

Александрова Екатерина Игоревна

Пермский государственный национальный исследовательский университет,
механико-математический ф-т, КМБ
614990, Россия, г. Пермь, ул. Букирева, 15, kaaate11@gmail.com

В статье описан опыт разработки и применения нейросетевой системы для прогнозирования стоимости подержанных автомобилей немецкого производства (Mercedes-Benz, BMW, Audi, Volkswagen, Opel). Определены параметры, которые в большей степени влияют на стоимость автомобилей. Приведены компьютерные эксперименты с целью выявления закономерностей автомобильного рынка.

Ключевые слова: стоимость автомобилей, немецкие автомобили, прогнозирование, рекомендации, нейронная сеть.

Оценка стоимости подержанных автомобилей является актуальной проблемой на сегодняшний день как для продавцов, так и для потенциальных покупателей автомобилей, поэтому существует большое количество фирм и онлайн-сервисов для бесплатной или платной оценки стоимости автомобилей таких, как CarPrice, Auto.ru, AutoMama, AutoDrom и другие. Стоит отметить, что применение математического аппарата нейронных сетей для создания интеллектуальной системы оценки и исследования автомобильного рынка впервые было произведено представителями Пермской научной школы искусственного интеллекта [1].

В настоящей работе для выявления наиболее значимых параметров и множества автомобилей были проанализированы данные с сайтов по продаже подержанных автомобилей такие как Avito, Drom.ru, Юла и другие. Таким образом, для прогнозирования стоимости автомобиля были отобраны данные по 100 немецким автомобилям (Mercedes-Benz, BMW, Audi, Volkswagen, Opel) по следующим параметрам:

- марка автомобиля,
- год выпуска,
- пробег (км),
- класс автомобиля,
- мощность двигателя (л.с.),
- объем двигателя (л),
- КПП,
- тип двигателя,

- привод,
- наличие автоматического климат-контроля,
- количество владельцев по ПТС.

Для прогнозирования использован метод нейросетевого моделирования [2, 3] и нейросимулятор [4].

Обучение нейронной сети проводилось на 90 примерах, тестирование на 10 примерах. В итоге, погрешность тестирования составила 4,5%.

В результате тестирования были получены результаты, представленные на рисунке 1. По диаграмме видно, что результат нейронной сети имеет большее отклонение для примера 6 (автомобиль Opel Astra, 2007 года выпуска). Скорее всего это связано с тем, что Opel находится в наименьшей ценовой категории по сравнению с другими немецкими автомобилями.

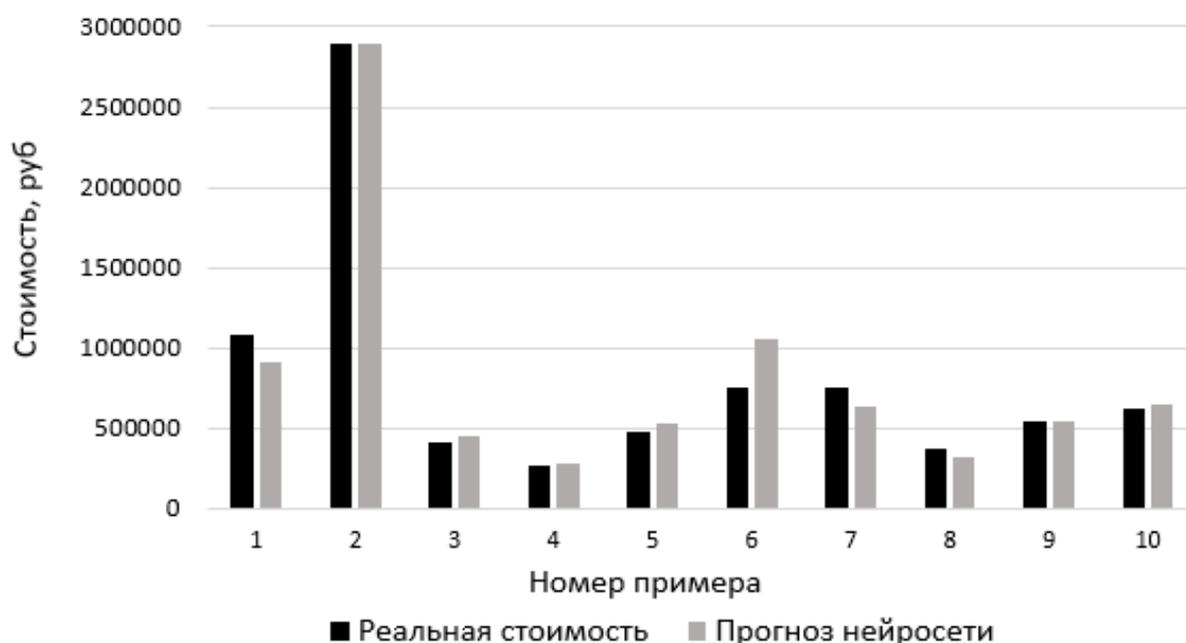


Рисунок 1. Результаты тестирования

Согласно проведенным исследованиям на стоимость немецкого автомобиля в большей степени влияют марка автомобиля, характеристики двигателя (тип и объем) и привод. Степень влияния разных факторов представлена на рисунке 2.

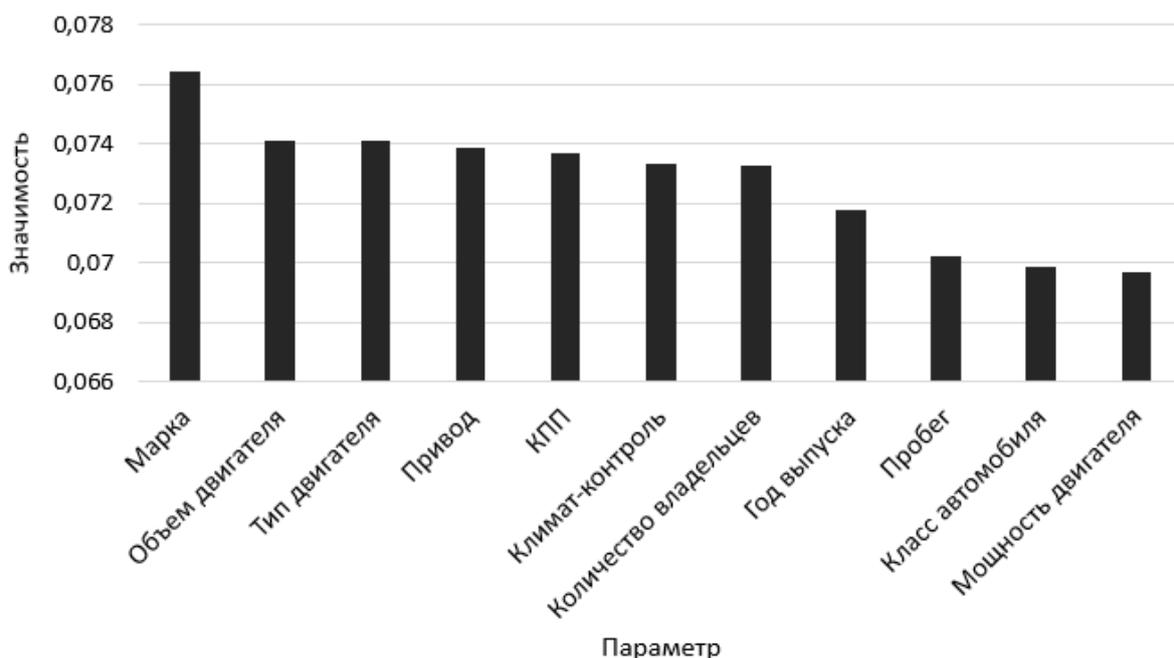


Рисунок 2. Значимость параметров

В ходе исследования были проведены эксперименты для автомобиля со следующими параметрами:

- марка автомобиля: BMW,
- год выпуска: 2009,
- пробег (км): 99000,
- класс автомобиля: D,
- мощность двигателя (л.с.): 272,
- объем двигателя (л): 3
- КПП: автомат,
- тип двигателя: бензин,
- привод: полный,
- наличие автоматического климат-контроля: есть,
- количество владельцев по ПТС: 2.

Для наглядного представления динамики изменения стоимости автомобиля в зависимости от значимых параметров было проведено сценарное прогнозирование методом замораживания входных параметров [3]. Зависимость стоимости автомобиля от различных параметров представлена на рисунках 3 – 6 (реальный автомобиль выделен серым цветом).

Как видно из рисунка 3, больше всего ценятся автомобили марки Mercedes-Benz, а меньше всего – Opel. Если бы рассматриваемый автомобиль BMW с теми же характеристиками выпускал Mercedes-Benz, то его стоимость возросла бы на 11%, в то время как, при выпуске такого же автомобиля компанией Opel его цена уменьшилась бы на 27%.

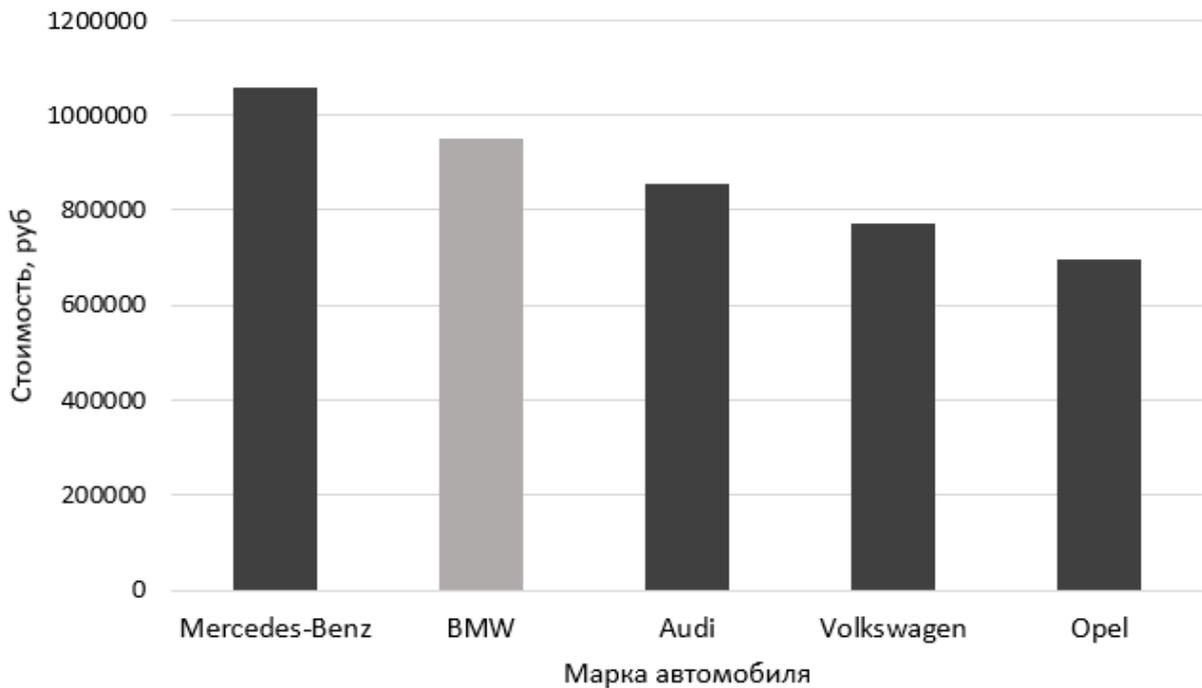


Рисунок 3. Зависимость стоимости автомобиля от марки автомобиля

На графике рисунка 4 можно увидеть, что стоимость автомобиля прямо пропорциональна объему двигателя и возрастает равномерно.

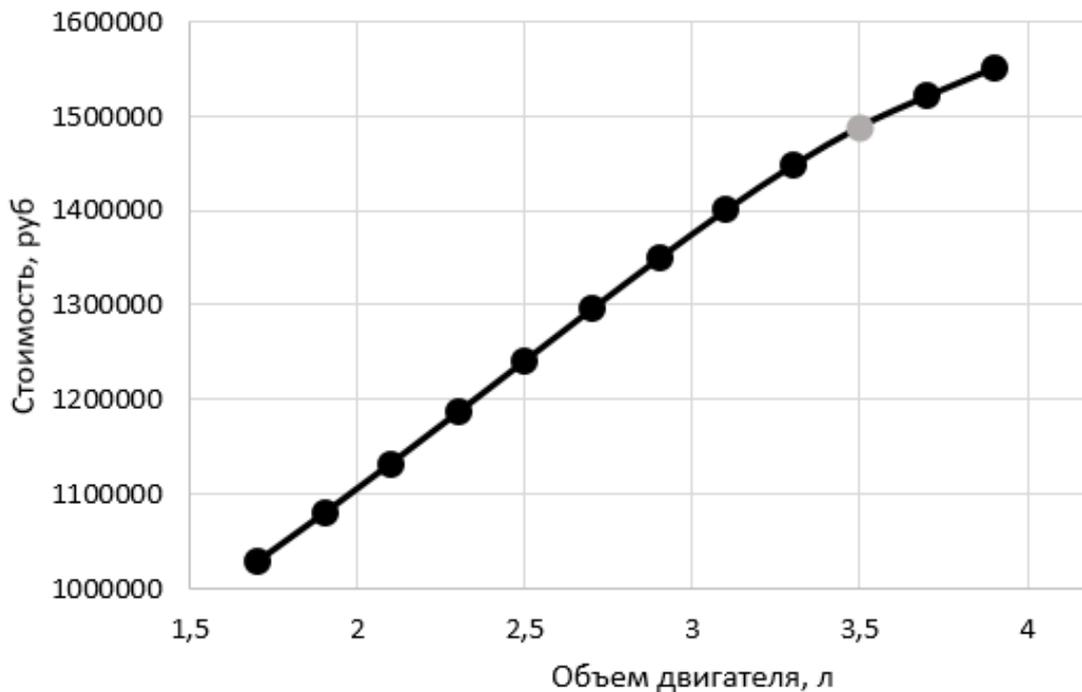


Рисунок 4. Зависимость стоимости автомобиля от объема двигателя

Как видно из рисунка 5, большей стоимостью обладает автомобиль на дизельном топливе. Если бы в рассматриваемом автомобиле BMW с теми же характеристиками был изменен тип двигателя на дизельный, то его стоимость возросла бы на 31%.

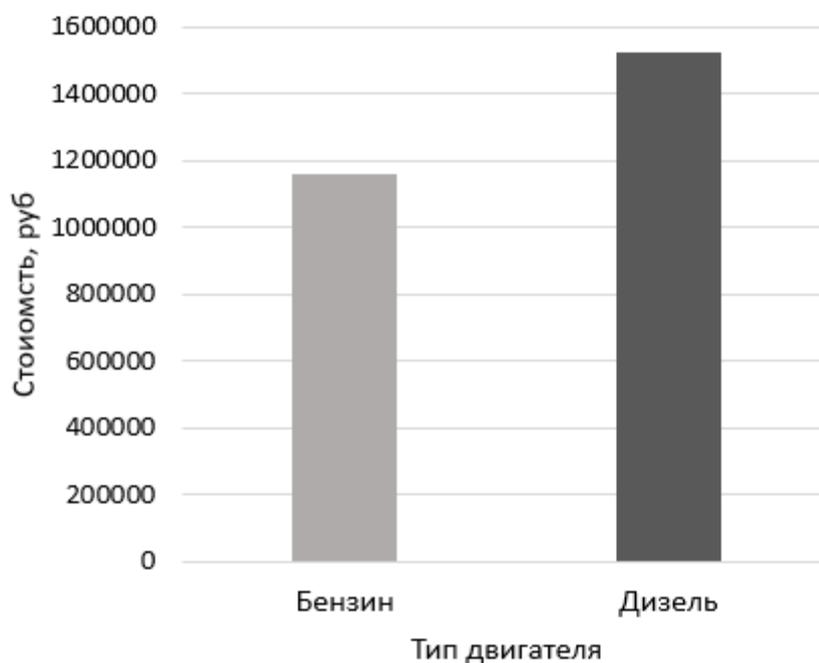


Рисунок 5. Зависимость стоимости автомобиля от типа двигателя

На рисунке 6 можно увидеть, что автомобиль с полным приводом будет стоить дороже, а с передним – дешевле. Если в рассматриваемом автомобиле BMW с теми же характеристиками изменить привод на передний, то его цена уменьшилась бы на 50%.

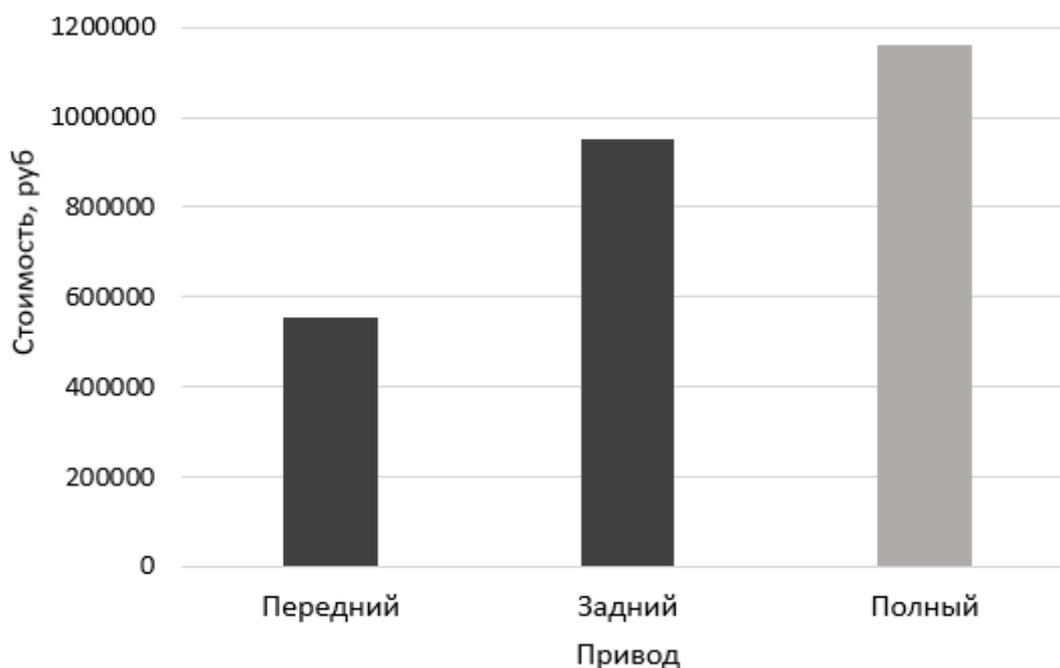


Рисунок 6. Зависимость стоимости автомобиля от типа привода

Исходя из полученных данных, можно сделать вывод, что в большей степени на стоимость автомобиля влияют не его технические характеристики, а марка автомобиля.

Таким образом, метод нейросетевого моделирования можно использовать как для объективной оценки стоимости автомобилей, так и для исследования автомобильного рынка, что может представлять интерес для всех участников этого рынка.

Библиографический список

1. Ясницкий Л.Н, Бондарь В.В., Бурдин С.Н. и др. Пермская научная школа искусственного интеллекта и ее инновационные проекты. – Москва-Ижевск: НИЦ «Регулярная и хаотическая динамика», 2008. 75 с.
2. Ясницкий Л. Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. 176 с.
3. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
4. Нейросимулятор 5.0 : Свидетельство о государственной регистрации программы для № 2014618208 от 12.07.2014 г. / Черепанов Ф.М., Ясницкий Л.Н. (РФ).

NEURAL NETWORK MODELING OF LIFE DURATION

Aleksandrova Ekaterina I.

Perm State University

614990, Russia, Perm, street Bukireva, 15, kaaate11@gmail.com

The article describes the experience of the development and application of the neural network system for predicting the cost of used cars of German production (Mercedes-Benz, BMW, Audi, Volkswagen, Opel). The parameters that have a greater effect on a car price have been determined. Set out an experiment that reflects the changes in the cost of cars depending on the relevant parameters.

Key words: car price, German cars, forecasting, recommendations, neural network.

ОПТИМИЗАЦИЯ АРХИТЕКТУРЫ НЕЙРОННОЙ СЕТИ ДЛЯ СОРТИРОВКИ МУСОРНЫХ ОТХОДОВ

Ахметзянов Кирилл Раисович, Южаков Александр Анатольевич

Пермский национальный исследовательский политехнический университет,
614990, Пермский край, г. Пермь, Комсомольский проспект, д. 29,
kirill94a@mail.ru, uz@at.pstu.ru

В статье представлены результаты экспериментов по поиску архитектуры нейронных сетей для классификации пластиковых бутылок, алюминиевых банок и прочих предметов. Эта нейронная сеть является частью умного контейнера по сортировке и сбору отходов. В этом контейнере в качестве вычислительного устройства используется микрокомпьютер RaspberryPi, поэтому при проектировании нейронной сети необходимо учитывать ограничение вычислительных мощностей этого устройства. Умный контейнер должен правильно сортировать как ровные бутылки и банки, так и мятые. В статье приведены результаты ранее проводимых экспериментов с нейронными сетями AlexNet, SqueezeNet и MobileNet. Но недостаток этих сетей является необходимость создания большой обучающей выборки для их обучения. И для распознавания мятых бутылок и банок необходимо создать выборку со всеми возможными мятостями бутылок и банок, на что потребуются колоссальное количество времени. Поэтому на обучение искомой сети должно требоваться маленькая обучающая выборка. Поиск архитектуры производился для оригинальной нейронной сети (идея построения которой предложена в статье) с помощью алгоритма гиперпараметрической оптимизации и ручного перебора архитектур. К разрабатываемой нейронной сети предъявляются следующие требования: высокая скорость обработки информации, малое количество требуемой памяти, высокое качество распознавание предметов при различных освещениях, фонах, углах наклонах и геометрических деформациях.

Ключевые слова: классификация объектов, нейронные сети, сверточные нейронные сети, компьютерное зрение, сортировка отходов, RaspberryPi.

OPTIMIZATION OF NEURAL NETWORK ARCHITECTURE FOR WASTE SORTING

Akhmetzyanov Kirill R.

Perm National Research Polytechnic University
614000, Russia, Perm, Komsomol prospect, 29, kirill94a@mail.ru

Yuzhakov Alexander A.

Perm National Research Polytechnic University
614000, Russia, Perm, Komsomol prospect, 29, uz@at.pstu.ru

In this work we present the results of experiments on the search for neural network architecture for the classification of plastic bottles, aluminum cans and other objects. This neural network is part of a smart container for sorting and collecting waste. In this container, RaspberryPi microcomputer is used as a computing device, so when designing a neural network, it is necessary to take into account the limitation of the computing power of this device. A smart container must sort correctly both flat and crushed bottles and cans. We show the results of previously conducted experiments on the object classification using neural networks AlexNet, SqueezeNet and MobileNet. However, the disadvantage of these networks is the need to create a large training set for their training. Moreover, for the recognition of crushed bottles and cans, it is necessary to create a set with all the possible crushing of bottles and cans, which will require a huge amount of time. Therefore, a small set sample should be required to train the network being searched for. The search for the architecture was carried out for the original neural network (approach to the development of which was proposed in the article) using the hyperparametric optimization algorithm and manual search of architectures. The developed neural network must meet the following requirements: high speed of image processing, a small amount of required memory, high accuracy rate of object recognition under various lighting, backgrounds, angles and geometric deformations.

Key words: object classification, neural networks, convolutional neural networks, computer vision, waste sorting, RaspberryPi.

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ДЛЯ ПРОГНОЗИРОВАНИЯ УРОВНЯ ЗАНЯТОСТИ НАСЕЛЕНИЯ

Базанова Мария Валерьевна

Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15,
bazanova.mariya.v@gmail.com

В статье описан опыт разработки и применения нейросетевой системы для прогнозирования уровня занятости населения. Нейросети были построены с помощью Нейросимулятора и библиотеки Keras. Представлено сравнение полученных результатов.

Ключевые слова: уровень занятости населения, прогнозирование, нейронная сеть, библиотека Keras.

Для построения модели прогнозирования уровня занятости были отобраны следующие показатели: среднедушевые денежные доходы, уровень безработицы, среднее время поиска работы безработными, распределение численности населения по величине среднедушевых денежных доходов, охват детей дошкольным образованием, объем платных услуг на душу населения и другие.

Модель, построенная в Нейросимуляторе [1], показала наилучшие результаты при использовании функции гиперболического тангенса для входного, выходного слоев и скрытого слоя, на котором находятся 3 нейрона. В качестве алгоритма обучения был выбран алгоритм упругого распространения.

После обучения была запущена проверка нейросети на проверочном множестве, чтобы высчитать среднюю ошибку модели. Для того, чтобы можно было сравнить результаты двух моделей, ошибка модели вычислялась по следующей формуле:

$$\text{Ошибка} = \frac{|Y - Y_n|}{Y} 100\% \quad (1)$$

где Y – реальное значение выходного параметра; Y_n – полученное прогнозное значение.

Ошибка была оценена по следующему принципу: модель считаем пригодной для построения прогноза, если ошибка не более 5%, при этом точные результаты достигаются при значении ошибки меньше 3%.

Ошибка модели, построенной в Нейросимуляторе, относительно реального значения равна 2,66%. Данную модель считаем пригодной для прогнозирования.

Далее было проведено исследование значимости параметров с помощью встроенной функции Нейросимулятора. Полученные результаты, отсортированные по убыванию, представлены на рисунке 1.

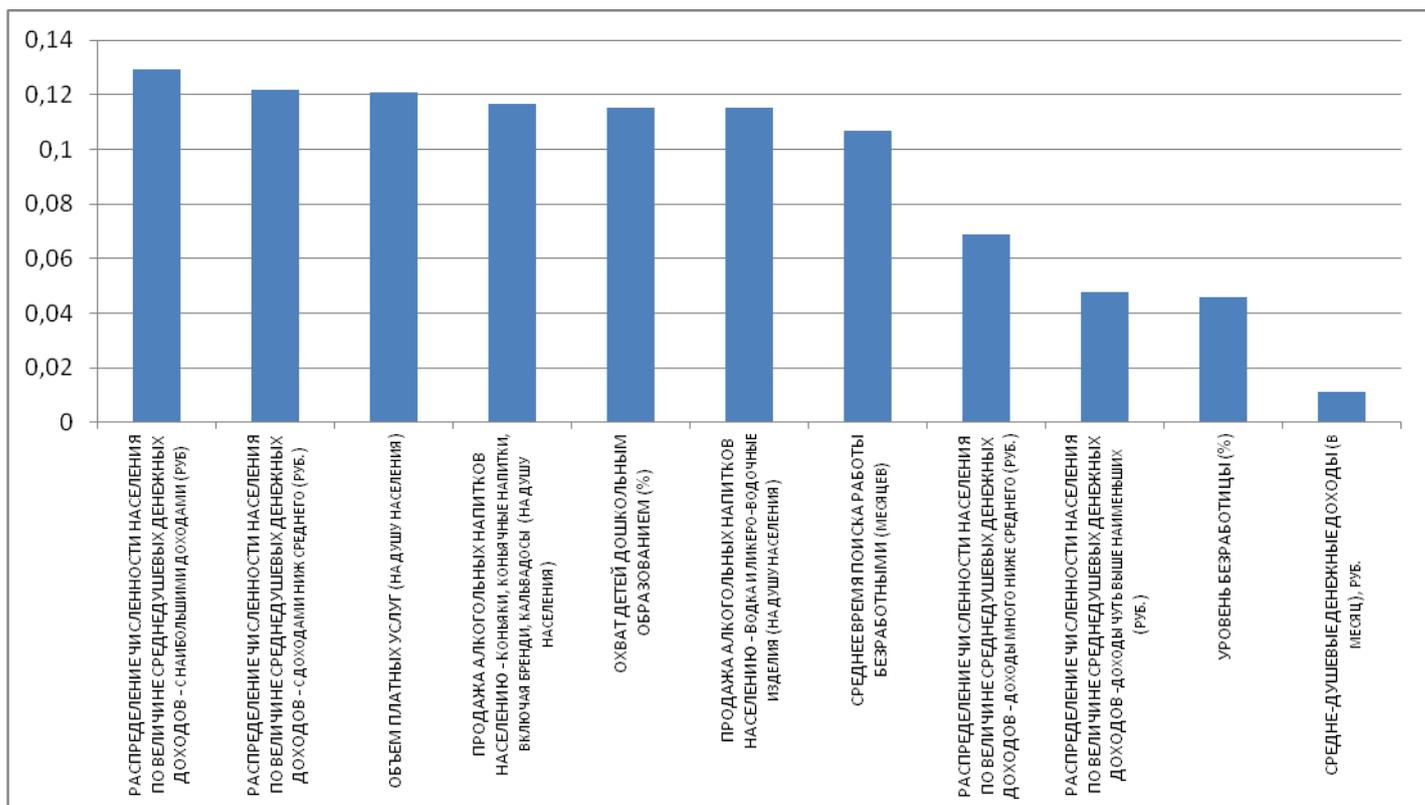


Рисунок 1 Значимость параметров

Разработанную математическую модель также можно использовать для исследования закономерностей предметной области. Например, изменяя какой-либо один или несколько входных параметров наблюдать за поведением выходного параметра. Этот метод исследования математических моделей называется «методом замораживания», поскольку все остальные входные параметры остаются неизменными [2].

Было проведено исследование для трех параметров, отмеченных как самые значимые, а именно:

- Распределение численности населения по величине среднедушевых денежных доходов – с наибольшими доходами (в % от общей численности населения субъекта),
- Распределение численности населения по величине среднедушевых денежных доходов – с доходами ниже среднего (в % от общей численности населения субъекта)
- Объем платных услуг на душу населения, руб.

Изменяя данные параметры поочередно от минимального до максимального значения с некоторым шагом при прочих неизменных, возможно отследить следующие зависимости прогнозируемого параметра (Рисунки 2-4). Для построения прогноза были выбраны данные по

Чукотскому автономному округу за 2015 год. Маркером на графиках отмечено реальное значение параметра в данном регионе.

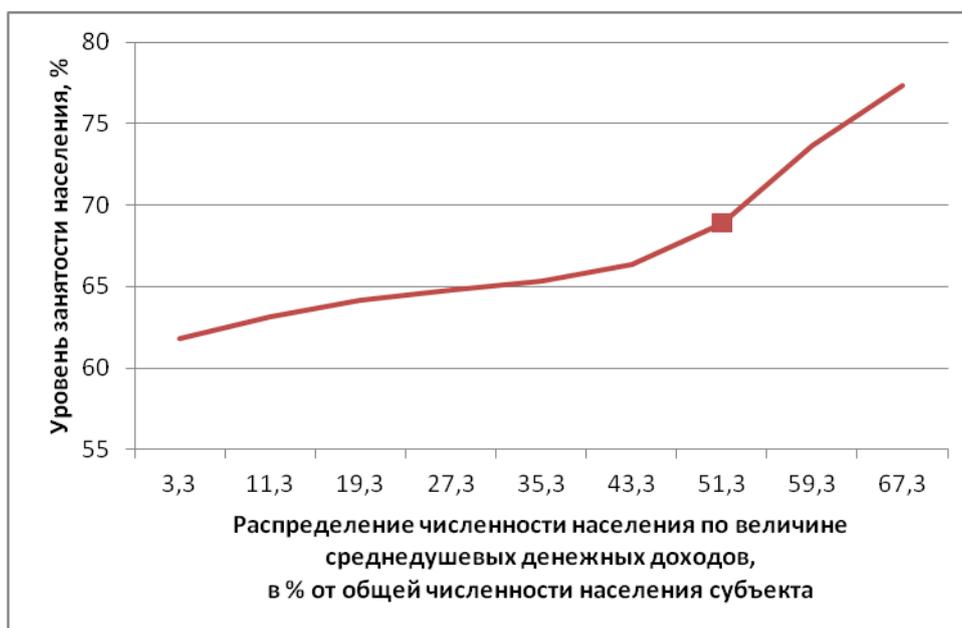


Рисунок 2. Зависимость уровня занятости населения от распределения численности населения по величине среднедушевых денежных доходов – с наибольшими доходами (в % от общей численности населения субъекта)

Таким образом, было выяснено, что между уровнем занятости населения и распределением населения с наибольшими доходами прослеживаются прямая зависимость.



Рисунок 3 Зависимость уровня занятости населения от распределения численности населения по величине среднедушевых денежных доходов – с доходами ниже среднего (в % от общей численности населения субъекта)

Прогноз нейросети показывает, что при увеличении числа людей с доходами ниже среднего уровень занятости поднимается до некоторой критической точки, а затем уменьшается.



Рисунок 4 Зависимость уровня занятости населения от объема платных услуг на душу населения, руб.

Также сначала прямая, а затем обратная зависимости просматривается между уровнем занятости населения и объемом платных услуг на душу населения.

Для создания второй модели прогнозирования была написана программа на языке Python с использованием библиотеки Keras. Keras — открытая нейросетевая библиотека, написанная на языке Python. Она нацелена на оперативную работу с сетями глубокого обучения, при этом спроектирована так, чтобы быть компактной, модульной и расширяемой. Эта библиотека содержит многочисленные реализации широко применяемых строительных блоков нейронных сетей, таких как слои, целевые и передаточные функции, оптимизаторы, и множество инструментов для упрощения работы с изображениями и текстом. В Keras есть Sequential API, позволяющий построить модели глубокого обучения [3].

Для чистоты эксперимента модель строилась на тех же данных и с использованием функции активации «гиперболический тангенс». После установки всех необходимых параметров и выбора оптимизатора, который даёт наилучший результат, была рассчитана итоговая ошибка модели по формуле (1). Ошибка составила 2.98%.

Полученные результаты ошибки относительно реального значения говорят о том, что модель, построенная при помощи нейросимулятора, выдает более точный прогноз, чем модель, построенная в библиотеке Keras. Ниже для более наглядного сравнения представлена диаграмма реальных и

полученных значений прогнозируемого параметра для проверочного множества (Рисунок 5).

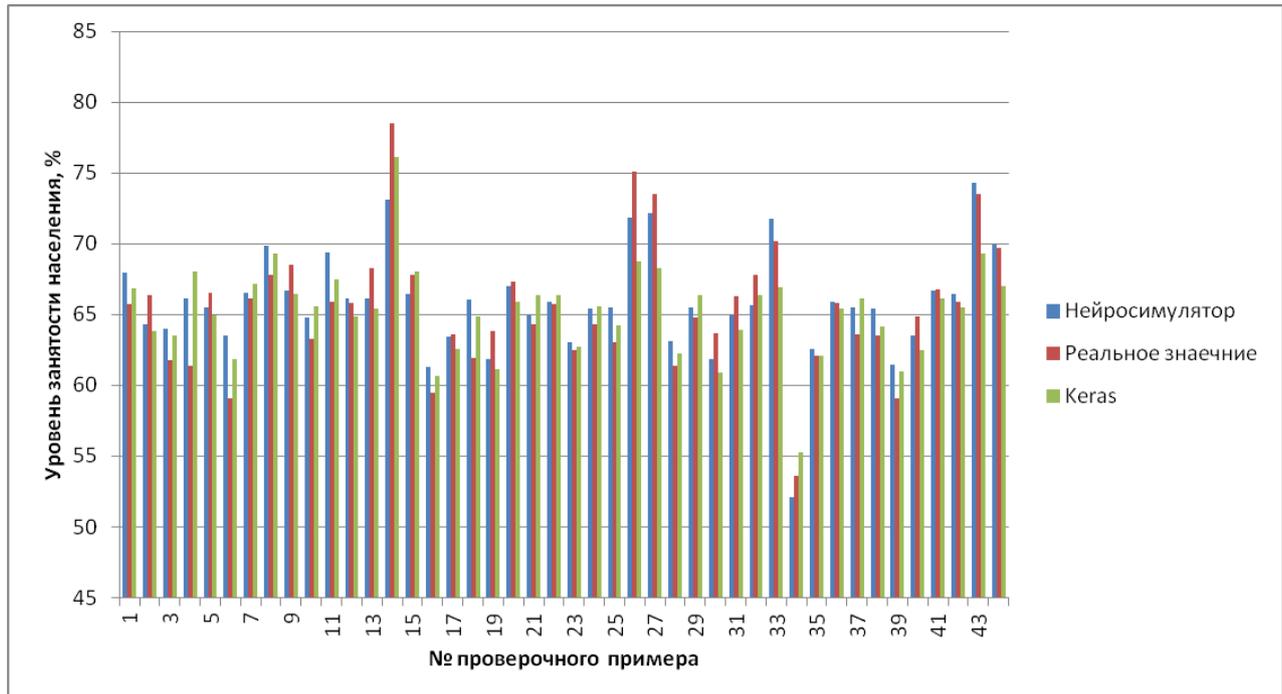


Рисунок 5 Сравнение полученных результатов

Библиографический список

1. Нейросимулятор 5.0: свидетельство о государственной регистрации программы для № 2014618208 от 12.07.2014 г. / Черепанов Ф.М., Ясницкий В.Л. (РФ)
2. Думлер А. А., Чугайнов С. В., Черепанов Ф. М., Ясницкий Л. Н. Нейросетевое моделирование диагностики и прогнозирования развития сердечно-сосудистых заболеваний – 2018.
3. Keras Documentation [электронный ресурс]. URL: <https://keras.io> (дата обращения 30.03.2019).

NEURAL NETWORK MODELING TO PREDICT THE EMPLOYMENT LEVEL

Bazanova Mariya V.
Perm State University
614990, Russia, Perm, street bukireva, 15, bazanova.mariya.v@gmail.com

The article describes the experience of developing and using the neural network system for predicting such an important social indicator as the level of employment. The neural networks were built using a neurosimulator and the Keras library. Presents a comparison of the results.

Keywords: employment rate, forecasting, neural network, Keras library.

ЭКОНОМИЧЕСКИЕ АСПЕКТЫ ВОСПРИЯТИЯ ЦИФРОВЫХ ТЕХНОЛОГИЙ НА ПРЕДПРИЯТИЯХ

Бартов Олег Борисович, Третьякова Елена Андреевна

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15
bartov@inbox.ru , E.A.T.pnrpu@yandex.ru

В статье описаны модели, согласно которым цифровые технологии либо принимаются, либо отвергаются предприятиями. В рамках рассмотрения классической модели восприятия цифровых технологий на предприятиях ставятся вопросы о понятии полезности цифровых технологий и субъективности простоты их использования. Для решения поставленных вопросов предлагается применение и дальнейшее развитие расширенной модели восприятия цифровых технологий на предприятиях.

Ключевые слова: Цифровая экономика, восприятие цифровых технологий, полезность цифровых технологий, простота цифровых технологий, управление цифровыми технологиями.

Можно найти достаточно много причин, по которым на предприятиях принимается решение об инвестировании в цифровые технологии с последующим их внедрением. Среди таких причин можно выделить потребность в снижении издержек, потребность в создании дифференцированного товара или услуги, улучшение уровня обслуживания или, в предельном случае, необходимость выживания предприятия в бизнес-среде.

Однако практика показывает, что при изначально благих намерениях ожидаемые результаты внедрения цифровых технологий далеко не всегда совпадают с результатами действительными. По данным статистики за 2011-2015 годы в среднем менее 30% проектов в мире, связанных с внедрением информационных систем, обеспечивающих функционирование цифровых технологий, завершаются успешно [1]. При этом показатель успешного завершения подобного рода проектов в странах Европы и Азии еще меньше – 25% и 22% соответственно.

Объяснить подобную статистику можно при помощи классической модели восприятия цифровых технологий, представленной на рисунке 1, которая была предложена Ф. Дэвисом из Массачусетского технологического института [2].

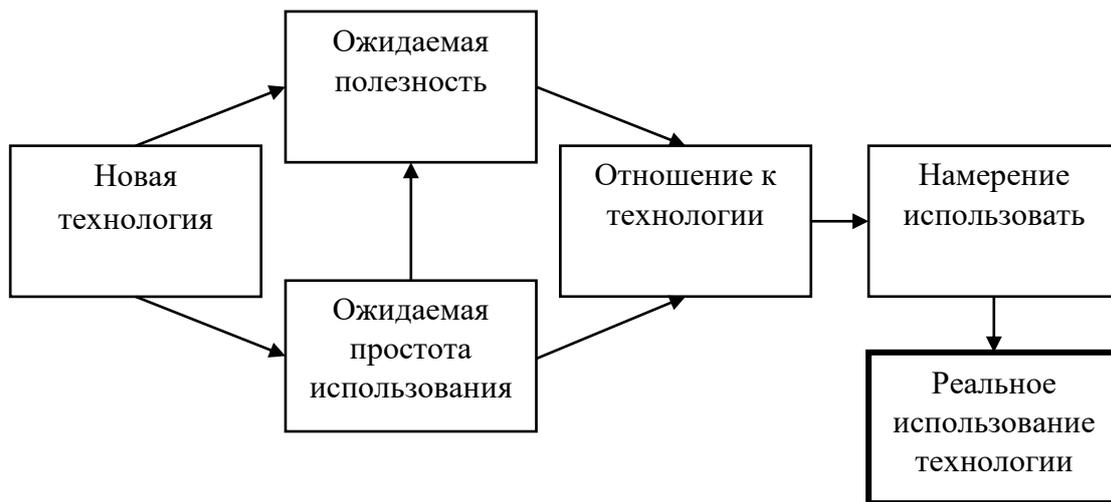


Рисунок 1. Классическая модель восприятия цифровых технологий

Ожидаемая полезность в классической модели восприятия цифровых технологий определяется степенью веры в то, что цифровая технология улучшит производительность предприятия. Ожидаемая простота использования, в свою очередь, определяется также степенью веры, но уже в то, что использование технологии не будет требовать дополнительных усилий. Отношение к потенциально внедряемой технологии формируется имплицитно, после чего сформированное отношение трансформируется в намерение использовать технологию, реализуемое, в свою очередь, уже в реальное использование технологии.

Поскольку цифровые технологии, в большей своей части, являются не первичными технологиями, а улучшением существующих, то имеет смысл говорить не об общей полезности, которую получают предприятия в результате внедрения, а о предельной полезности, когда дополнительной единицей потребленного блага является процесс цифровизации. Предельная полезность, в таком случае, определяется в виде изменения общей полезности в результате внедрения реализуемой технологии. В таком случае возникает вопрос о восприятии полезности: в какой мере переносится впечатление при увеличении полезности в виде внедрения цифровой технологии на воспоминание о предыдущем улучшении [3]?

Понятие ожидаемой простоты использования ставит еще один вопрос относительно оценки этой простоты. Если в случае с определением полезности можно опираться на экономические законы, в частности, на закон Госсена или общеизвестный закон спроса [4], то определение простоты и необходимых усилий носит гораздо более специфичный характер, поскольку зависит от контекста внедрения. Отдельно следует отметить, что оценку издержек вряд ли можно отнести к оценке простоты использования.

Частичный ответ на поставленные вопросы может дать расширенная модель восприятия цифровых технологий, построенная на основе классической модели Ф. Дэвиса, в рамках которой были учтены дополнительные особенности восприятия через раскрытие факторов

восприятия полезности, а также прояснение имплицитного перехода от отношения к технологии к намерению ее использовать. Модель представлена на рисунке 2 [5].

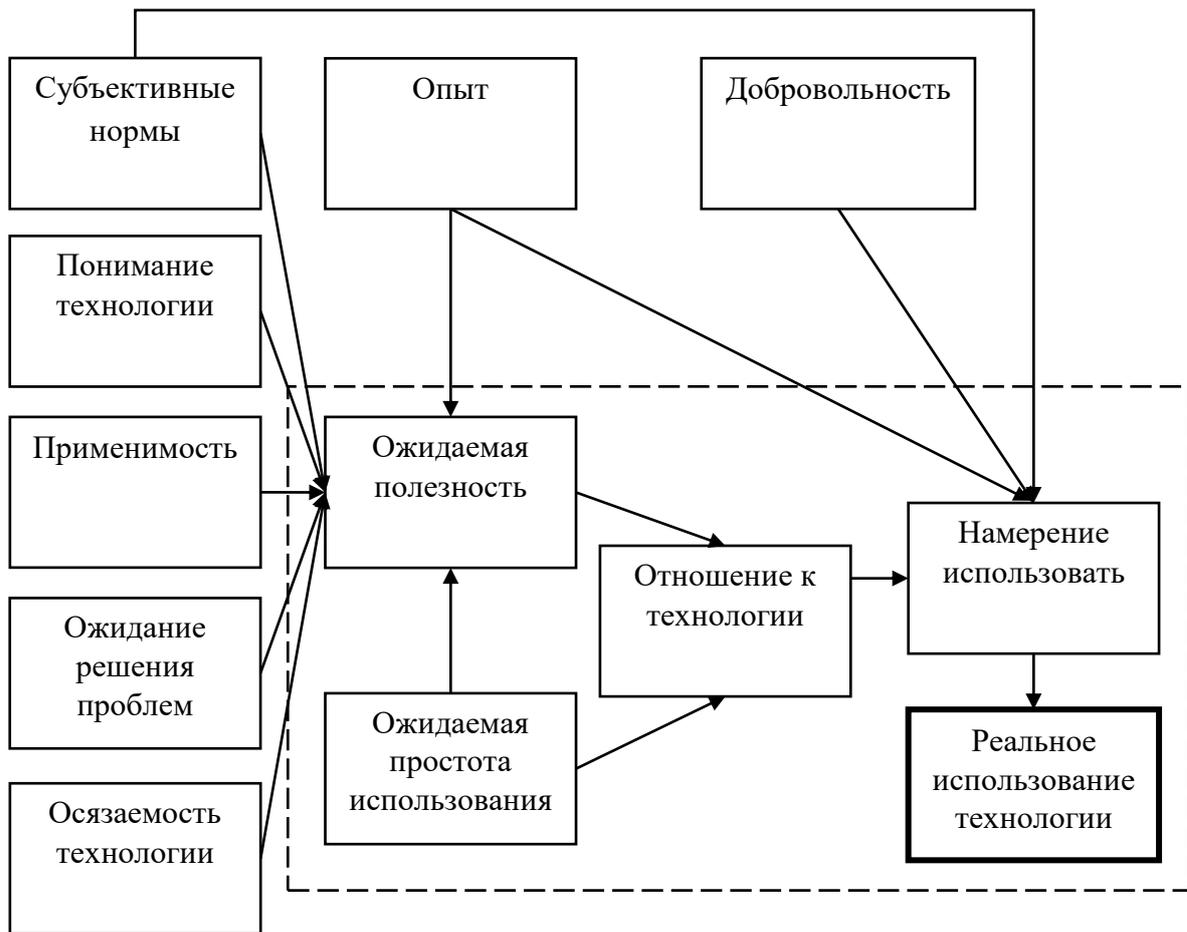


Рисунок 2. Расширенная модель восприятия цифровых технологий

Фактор субъективных норм, определяющий субъективное восприятие того, что является важным и полезным, оказывает двойное воздействие – на ожидаемую полезность и намерения использовать цифровую технологию. Согласно расширенной модели предварительное понимание цифровой технологии, осознание возможности ее применить, представление о цифровой технологии как о средстве решения проблем, а также ее осязаемость с возможностью предварительной демонстрации повысят ожидаемую полезность. Дополнительно ожидаемую полезность определит опыт использования цифровых технологий, поскольку будет снята часть неопределенности в отношении будущего внедрения. Опыт также окажет влияние на намерение использовать цифровую технологию, которое может оказаться отрицательным даже несмотря на ожидаемую полезность в случае, когда данный опыт является отрицательным опытом внедрения подобной технологии. Отдельно следует отметить добровольность внедрения, поскольку директивные распоряжения могут оказать значительное влияние на конечное намерение использовать цифровую технологию.

Для получения более полных ответов требуется развивать расширенную модель восприятия цифровых технологий. Развитие модели следует вести через учет специфики конкретного объекта, на котором требуется запускать процессы цифровизации. Таким образом, для каждого конкретного предприятия необходимо разрабатывать свою модель восприятия цифровых технологий, сопряженную с его стратегией, уже существующим уровнем цифровизации, а также состоянием его внутренней и внешней среды.

Библиографический список

1. The Standish Group International, Inc. Chaos report. 2015.
2. F.D. Davis, Perceived usefulness, perceived ease of use, and user acceptance of information technologies // MIS Quarterly 13 (3), 1989, pp. 319–340.
3. И.У. Зулькарнай. Предельная полезность и полезность единицы блага в условиях ограниченной рациональности индивидов // Известия уфимского научного центра РАН №1, 2012, С. 51-57.
4. В.М. Мелкумян. К обоснованию исходных теорем теории потребительского спроса // Вестник Самарского муниципального института управления №2, 2015, С. 124-132.
5. V. Venkatesh, F.D. Davis. A theoretical extension of the technology acceptance model: four longitudinal field studies // Management Science 46 (2), 2000, pp. 186-204.

ECONOMIC ASPECTS OF DIGITAL TECHNOLOGIES PERCEPTION IN ENTERPRISES

Bartov Oleg B., Tretyakova Elena A.
Perm State University,
614990, Russia, Perm, street Bukireva, 15
bartov@inbox.ru, E.A.T.pnrpu@yandex.ru

The article describes the models according to which digital technologies are either accepted or rejected by enterprise. Within the scope of the classical model consideration of digital technologies acceptance in enterprises, questions are raised about the concept of the digital technologies' usefulness and the subjectivity of their ease of use. To solve these problems, it is proposed to use and develop the extended model of digital technologies perception in enterprises.

Keywords: Digital economy, perception of digital technologies, usefulness of digital technologies, simplicity of digital technologies, management of digital technologies.

САМОАДАПТИРУЕМАЯ НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ И ПРОГНОЗИРОВАНИЯ РЫНКОВ НЕДВИЖИМОСТИ НИЖНЕГО НОВГОРОДА И ПЕРМИ

Гилязов Игорь Гаязович

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15

Алексеев Александр Олегович, Ясницкий Виталий Леонидович

Пермский национальный исследовательский политехнический университет
614990, Россия, г. Пермь, Комсомольский пр-т, 29
yasn@psu.ru

В статье представлено описание разработки нейросетевой системы для оценки объектов жилой недвижимости и прогнозирования рынков Нижнего Новгорода и Перми. Система позволяет прогнозировать цену квартир по макроэкономическим, географическим и строительным показателям. Благодаря использованию макроэкономических параметров система не теряет актуальность со временем. Предложен и протестирован оригинальный способ определения городских локальных экономических центров с использованием тепловых карт ценового зонирования.

Ключевые слова: искусственный интеллект, нейросетевые технологии, вторичный рынок квартир, оценка стоимости, прогнозирование, жилая недвижимость, тепловая карта.

Введение. В самых первых работах, которые затрагивали тему оценки объектов недвижимости с помощью нейронных сетей [1-3], была показана перспективность этого направления. Но у представленных моделей был один общий недостаток – они становились неактуальными с течением времени за счет изменения различных экономических параметров.

Первой работой, в которой исследователи подняли вопрос актуальности во времени, можно назвать работу [4]. В ней были взяты во внимание некоторые экономические параметры, такие, как инфляция, ВВП, средняя заработная плата и т. д. Однако представленные модели годились только для выявления общих закономерностей и трендов рынка недвижимости, но не для массовой оценки.

Авторам работ [5-9] удалось достичь вышеупомянутую актуальность во времени (самоадаптируемость к меняющейся экономической ситуации), при этом модели имели приемлемую для оценки жилой недвижимости точность. Данная работа является продолжением этого направления с применением современных технологий для более тщательного сбора данных

обучения нейронной сети. В работе применяются технология web-scraping для автоматизированного сбора данных с Интернет-ресурсов и технология построения тепловых карт для определения локальных ценовых центров города.

В открытых ресурсах не имеется общедоступной, некоммерческой базы данных объектов недвижимости города Нижний Новгород за несколько лет. Представляется возможным собрать данные с Интернет-ресурсов только за последний год. Но, в нашем распоряжении имелись данные по городу Пермь за промежуток с 2008 по 2018 года. Было принято решение объединить их с данными по Нижнему Новгороду, относящемуся к 2018 году, введя в качестве дополнительного параметра индекс, указывающий нейронной сети на принадлежность квартиры городу: Перми или Нижнему Новгороду.

В результате анализа работ [1-9] были выделены следующие параметры, которые максимально влияют на стоимость квартиры. Это: X1 – общая площадь, X2 – количество комнат, X3 – этаж, X4 – количество этажей в доме, X5 – сумма расстояний до локальных центров, X6 – год постройки дома, X7 – тип стен дома, X8 – ставка рефинансирования, X9 – средняя заработная плата по городу, X10 – ВВП, X11 – РТС, X12 – курс доллара к рублю, X13 – цена нефти (Brent), X14 – ввод жилья в городе, X15 – выданные кредиты, X16 – идентификатор города. Выходной параметр D1 – стоимость квартиры.

Для определения локальных ценовых центров, где стоимость квартир является максимальной, были построены так называемые тепловые карты ценового зонирования, представленные на рисунках 1 и 2 – для Перми и для Нижнего Новгорода. Квартиры, вошедшие на карты, подобраны так, что они имеют приблизительно одинаковые строительными показателями и относятся к одному и тому же временному (экономическому) периоду.

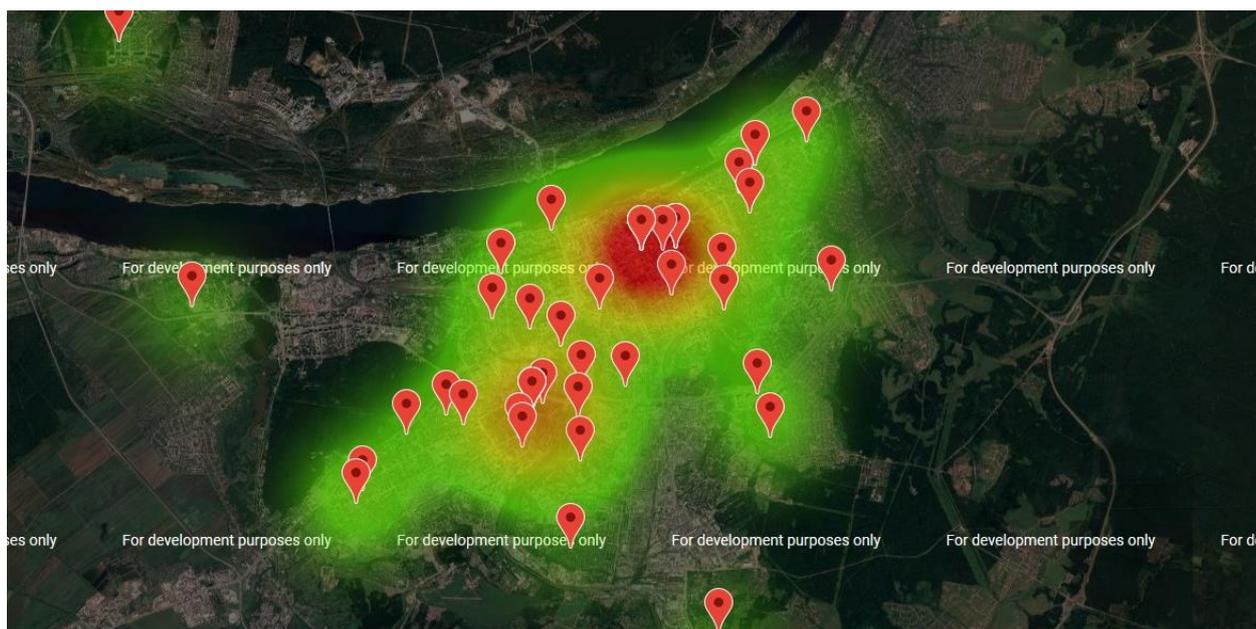


Рисунок 1. Тепловая карта ценового зонирования квартирного рынка города Пермь

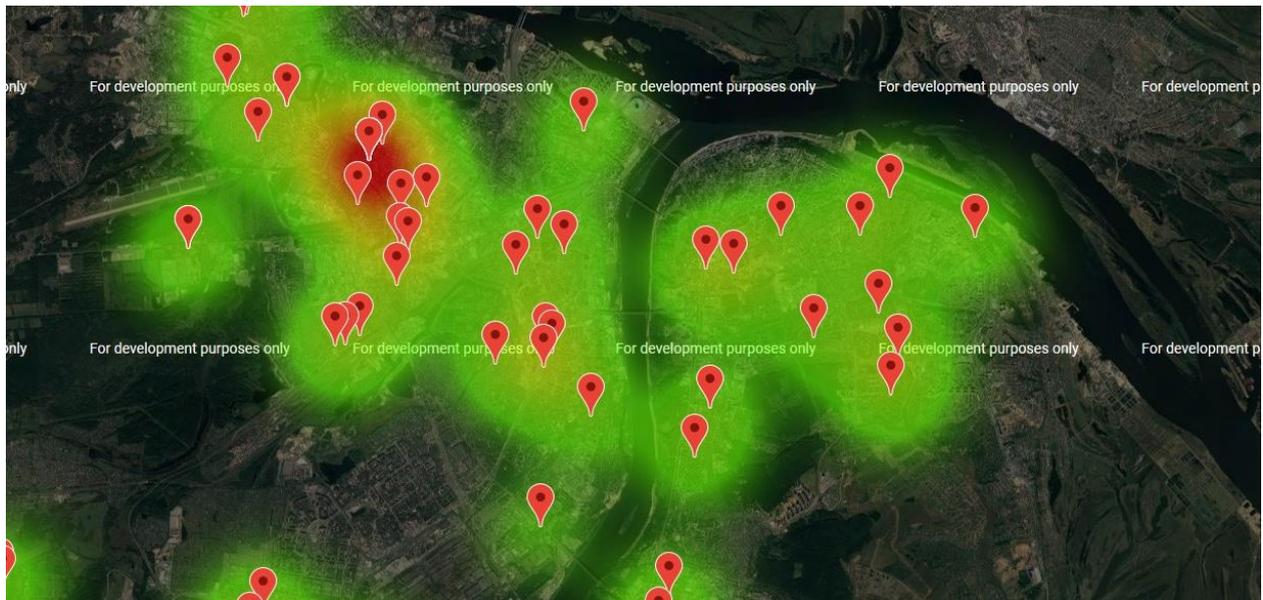


Рисунок 2. Тепловая карта ценового зонирования квартирного рынка города Нижний Новгород

С использованием координат ценовых центров городов, был получен новый параметр – расстояние до городского ценового центра. Пренебрегая неровностью Земной поверхности, были произведены расчеты по формуле расстояния между двумя точками:

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

Так как площади городов Пермь и Нижний Новгород не одинаковы, то значения данного показателя нельзя сравнивать между собой для квартир не из одного города: они имеют разную размерность. Для этого было произведено нормирование: значения для города Пермь приводились к значениям для города Нижний Новгород. Площадь Перми на апрель 2019 года составляет $S_{Пермь} = 803 \text{ км}^2$, площадь Нижнего Новгорода $S_{НН} = 460 \text{ км}^2$. Коэффициент k , на который был умножен параметр d для значений города Перми:

$$k = \frac{S_{НН}}{S_{Пермь}} = \frac{460}{803} = 0,573$$

Итоговое множество для нейросети содержит данные по городу Пермь, предоставленные профессиональной оценочной компанией, и данные по городу Нижний Новгород, собранные с помощью программы-парсера с Интернет-ресурсов. Было проведено исследование на выбросы.

Для проектирования искусственной нейронной сети была использована программа «Нейросимулятор 5» [10]. Итоговое множество составило 5098 примеров, из которых 3464 – квартиры города Нижний Новгород и 1634 – квартиры города Пермь. Множество было разбито на обучающее и тестирующее в пропорции 95% и 5% соответственно. Таким образом, множество тестирования составило 268 примеров. Средняя ошибка тестирования составила 8,28%, что можно назвать неплохим результатом. На

рисунке 3 представлена гистограмма, демонстрирующая разницу между исходными значениями выходного параметра и прогнозируемого нейронной сетью.

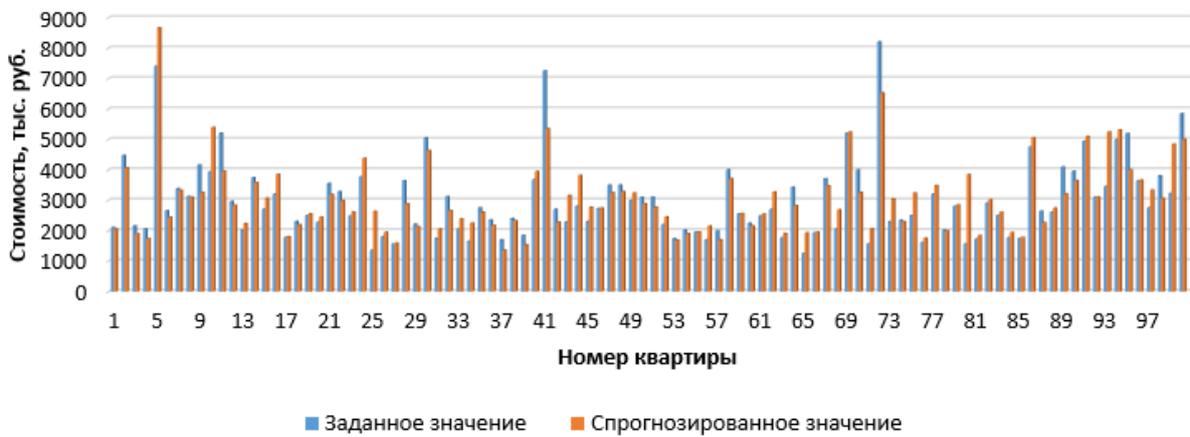


Рисунок 3. Результат тестирования нейронной сети

На рисунке 4 представлена гистограмма, показывающая распределение значимости параметров.

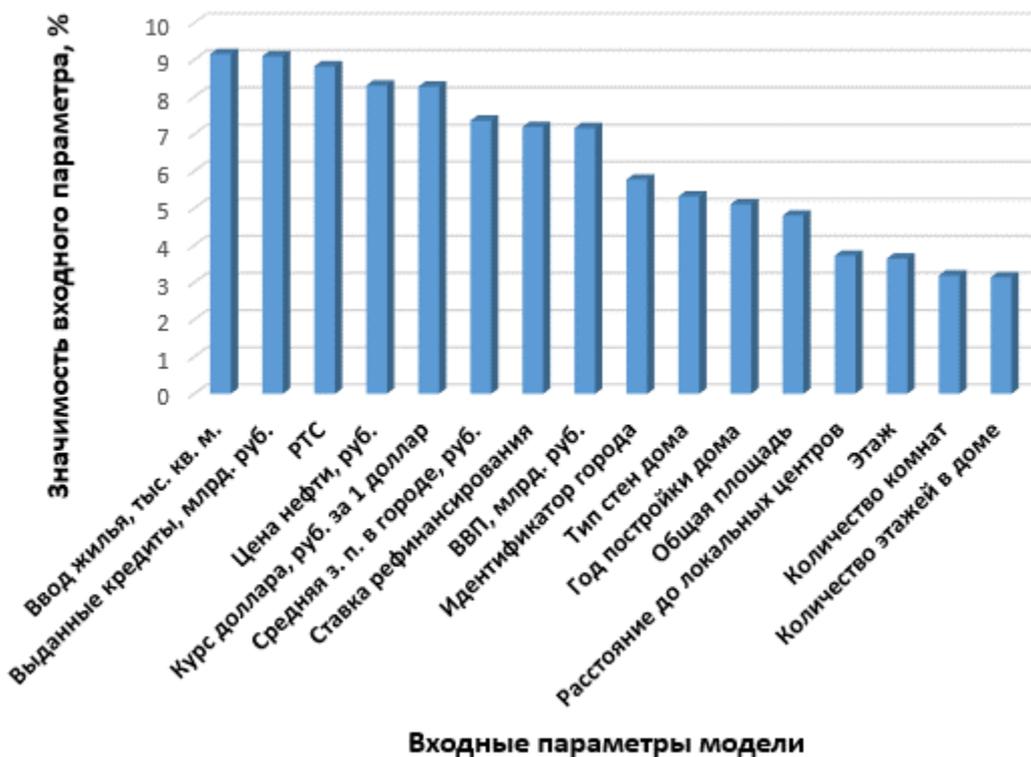


Рисунок 4. Значимость параметров

Самыми значимыми входными параметрами оказались макроэкономические. Первый из них – параметр ввода жилья в городе. После макроэкономических – параметр идентификатора города, параметр типа стен и параметр года постройки, только после них – параметр общей площади квартиры.

Таким образом, была спроектирована самоадаптируемая к экономической ситуации нейросеть, предназначенная для оценки квартирных рынков одновременно двух городов: Нижний Новгород и Пермь.

Далее было выполнено исследование жилищного рынка Нижнего Новгорода. Исследование производилось с помощью метода «замораживания». Его суть – в изменении значения одного из параметров и фиксации всех остальных. С его помощью можно понять, как именно исследуемый параметр влияет на значение выходного параметра. Было выбрано 5 квартир с разными характеристиками:

1. 1-комнатная квартира с общей площадью 33,3 кв.м. на 8 этаже 9-этажного кирпичного дома, год постройки: 1975, адрес: г. Нижний Новгород, ул. Исполкома, 6;
2. 2-комнатная квартира с общей площадью 46 кв.м. на 3 этаже 9-этажного панельного дома, год постройки: 1980, адрес: г. Нижний Новгород, ул. Верхнепечерская, 1;
3. 3-комнатная квартира с общей площадью 69,5 кв.м. на 6 этаже 10-этажного панельного дома, год постройки: 1995, адрес: г. Нижний Новгород, ул. Горная, 19;
4. 4-комнатная квартира с общей площадью 78,4 кв.м. на 10 этаже 12-этажного кирпичного дома, год постройки: 1972, адрес: г. Нижний Новгород, ул. Адмирала Васюнина, 11;
5. 5-этажная квартира с общей площадью 104 кв.м. на 5 этаже 6-этажного кирпичного дома, год постройки: 1938, адрес: г. Нижний Новгород, проспект Октября, 21.

На рисунке 5 показана зависимость стоимости квартир от количества комнат. Результаты показывают, что при неизменных остальных параметрах, при увеличении количества комнат стоимость квартир имеет незначительную тенденцию к снижению.

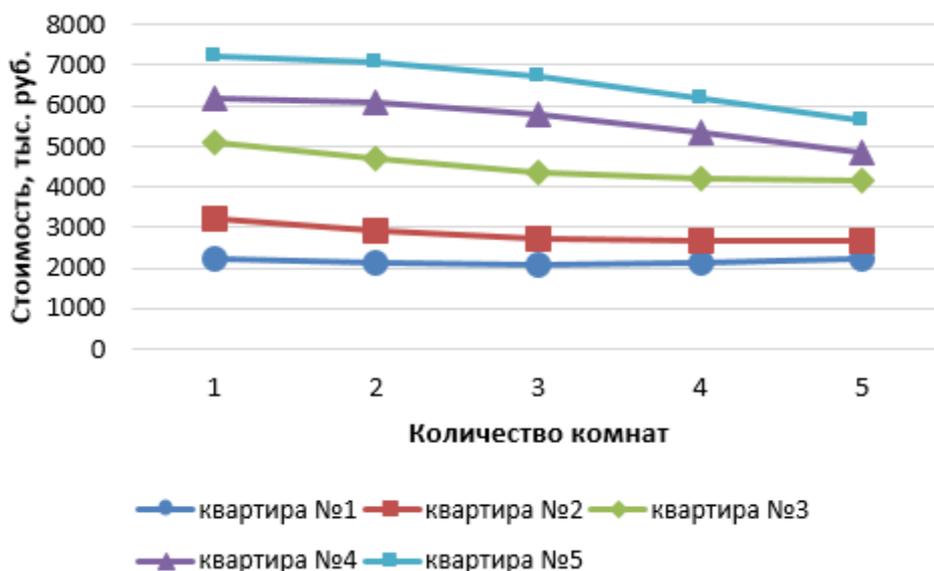


Рисунок 5. Зависимость стоимости квартир от количества комнат

На рисунке 6 показана зависимость стоимости квартир от этажности здания. Результаты показали, что при неизменных остальных параметрах, при увеличении этажности здания стоимость всех рассмотренных квартир возрастает, причем указанная зависимость носит экспоненциальный характер.

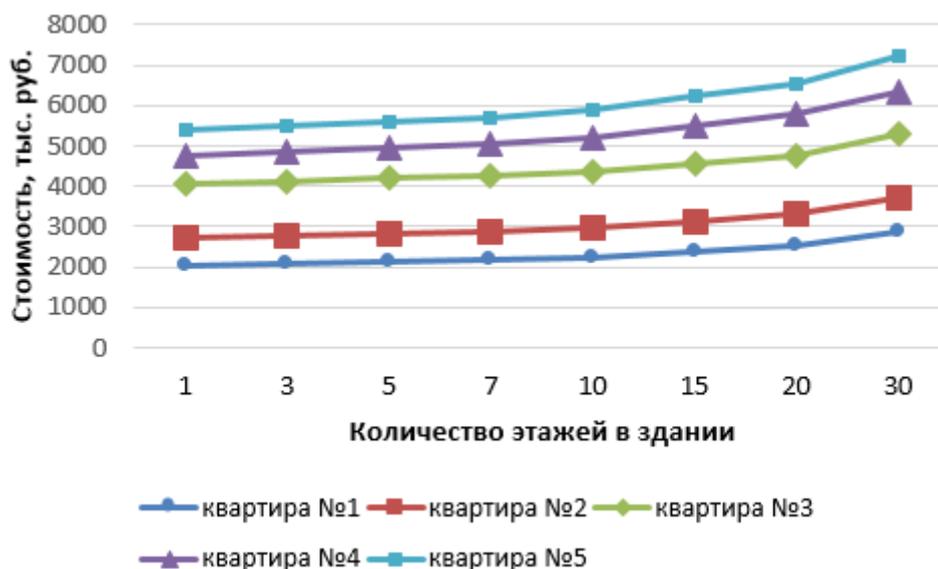


Рисунок 6. Зависимость стоимости квартир от количества этажей в доме

Далее аналогичным способом проведено исследование зависимостей стоимости квартир от макроэкономических показателей. Так как значимость всех макроэкономических параметров получилась примерно одинаковая – были взяты наименее и наиболее значимые из макроэкономических параметров. Это курс доллара и средняя заработная плата соответственно.

На рисунке 7 показана зависимость стоимости квартир от курса доллара. Как видно из рисунка, при неизменных остальных параметрах, при с увеличением курса доллара к рублю стоимость квартир возрастает, и судя по характеру графика, можно сказать, что линейно.

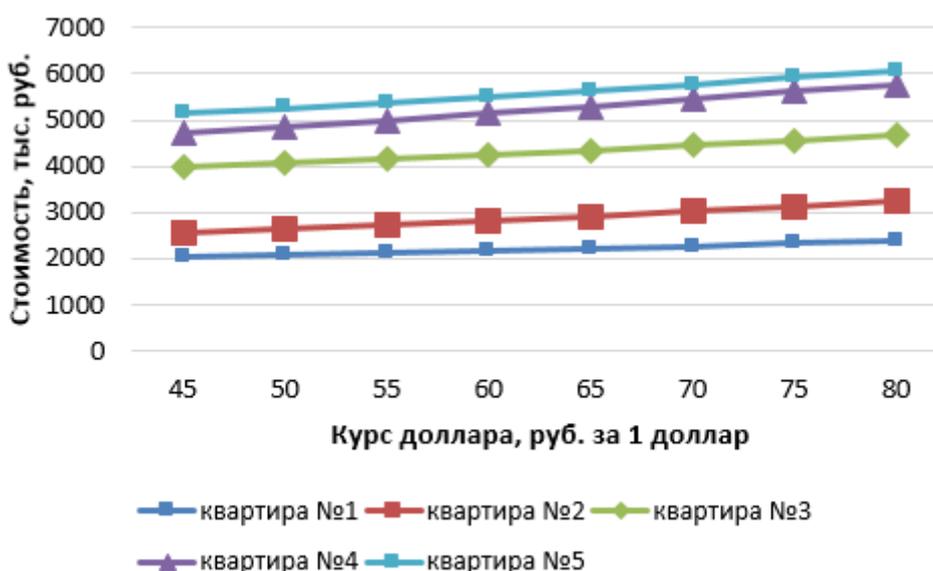


Рисунок 7. Зависимость стоимости квартир от курса доллара к рублю

На рисунке 8 показана зависимость стоимости квартир от средней заработной платы в городе. Результаты показали, что при неизменных остальных параметрах, при увеличении средней заработной платы стоимость квартир возрастает, и опять же, можно сказать, что линейно.

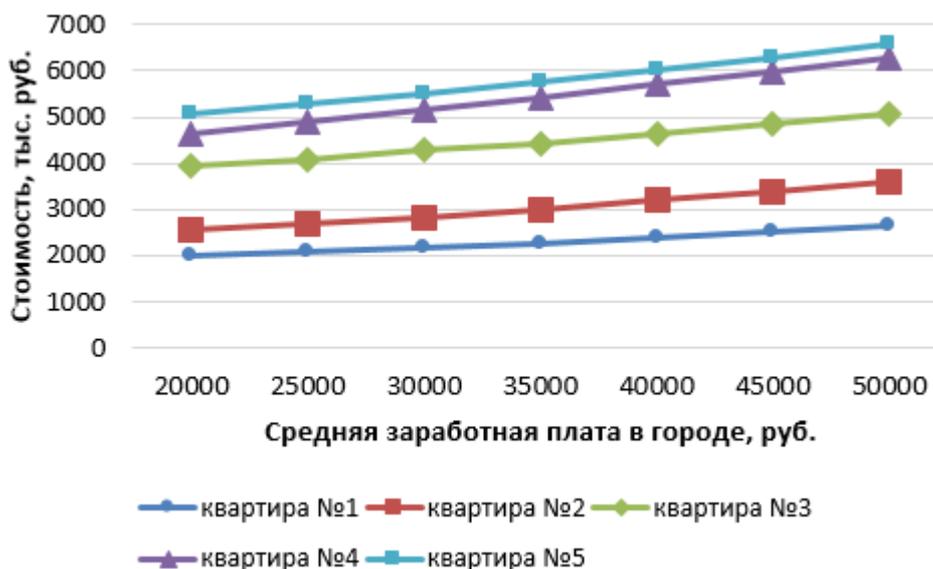


Рисунок 8. Зависимость стоимости квартир от средней заработной платы в городе

Заключение. Построена нейросетевая система, предназначенная для оценки стоимости объектов жилой недвижимости Нижнего Новгорода и Перми. В отличие от существующих, предложенная модель содержит помимо строительных, еще и макроэкономические параметры. Благодаря этому, модель не чувствительна к постоянно изменяющейся экономической обстановке в стране и в мире. Кроме того, предложен и опробован оригинальный способ учета географического фактора: ценовой центр городов установлен путем построения тепловой карты, выполняющей функцию ценового зонирования города. На основании представленной модели было проведено исследование на предмет выявления факторов, максимально влияющих на образование цены. Проведены исследования жилищного рынка города Нижний Новгород: построены зависимости стоимости квартир от некоторых строительных и макроэкономических факторов. Модель может быть полезна в отрасли недвижимости, например, для риелторов и оценщиков. С помощью предложенной методики могут быть построены аналогичные самоадаптируемые оценочно-прогностические системы других городов в других странах.

Благодарности. Работы выполнены при поддержке гранта РФФИ 19-010-00307.

Библиографический список

1. Tay D. P., Ho D. K. Artificial intelligence and the mass appraisal of residential apartments // Journal of Property Valuation and Investment. 1991. Vol. 10, no 2. P. 525–540.
2. Evans A., James H., Collins A. Artificial neural networks: An application to residential valuation in the UK // Journal of Property Valuation and Investment, 1991, no 11(2), pp. 195–204.
3. Borst R.A. Artificial neural networks in mass appraisal // Journal of Property Tax Assessment & Administration, 1995, Vol. 1, no 2, pp. 5–15.
4. Becker C., Morrison A.R. Urbanization in transforming economies // Handbook of Regional and Urban Economics, 1999, Vol. 3, pp. 1673–1790.
5. Guan J., Zurada J., Levitan A.S. An adaptive neuro-fuzzy inference system based approach to real estate property assessment // Journal of Real Estate Research, 2008, Vol. 30, no 4, pp. 395–422
6. Mao Y.H., Zhang M.B., Yao, N.B. Hangzhou housing demand forecasting model based on BP neural Network of Genetic Algorithm Optimization (Conference Paper) // Applied Mechanics and Materials, 2014, Vol. 587-589, pp. 37–41.
7. Kontrimas V., Verikas A. The mass appraisal of the real estate by computational intelligence // Applied Soft Computing Journal, 2011, Vol. 11, no 1, January, pp. 443–448.
8. 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.
9. 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
10. 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.

**SEMIADAPTIVE NEURAL NETWORK EVALUATION SYSTEM
AND FORECASTING REAL ESTATE MARKETS
NIZHNY NOVGOROD AND PERM**

Gilyazov Igor G.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990, yasn@psu.ru

Alekseev Alexander O., Yasnitsky Vitaly L.

Perm national research Polytechnic University

614990, Russia, Perm, Komsomolsky PR-t, 29

The article describes the development of a neural network system for the evaluation of residential real estate and forecasting the markets of Nizhny Novgorod and Perm. The system allows you to predict the price of apartments on macroeconomic, geographical and construction indicators. Due to the use of macroeconomic parameters, the system does not lose relevance over time. The original method of definition of the city local economic centers with use of thermal maps of price zoning is offered and tested.

Keywords: artificial intelligence, neural network technologies, secondary market of apartments, valuation, forecasting, residential real estate, heat map.

ДИНАМИЧЕСКАЯ НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ ВТОРИЧНОГО РЫНКА ЖИЛОЙ НЕДВИЖИМОСТИ ГОРОДА ЕКАТЕРИНБУРГА

*Корекова Мария Анатольевна, Нилидина Елизавета Анатольевна,
Ясницкий Леонид Нахимович*

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

В статье представлено описание разработки динамической нейросетевой системы для оценки жилой недвижимости города Екатеринбурга. Система позволяет прогнозировать цену квартир по трем категориям показателей: макроэкономическим, географическим, строительным. Система обладает свойством самоадаптации к изменяющимся макроэкономическим показателям. Предложен и опробован оригинальный способ зонирования городских территорий.

Ключевые слова: искусственный интеллект, нейросетевые технологии, вторичный рынок квартир, самоадаптация, оценка стоимости, прогнозирование, жилая недвижимость.

В современном мире почти каждый человек обеспокоен приобретением или продажей своего жилья, но не каждый понимает, как оценивается та или иная квартира.

Многие зарубежные исследователи [1-3] посвятили свои работы данной теме, в которых показали, что применение искусственного интеллекта в задачах оценки стоимости недвижимости эффективнее, чем использование классических регрессионных моделей. При этом, в своих работах авторы используют лишь географические и строительные параметры, не учитывая экономические. Такие системы называются статическими, т.к. они не позволяют учитывать неизбежное изменение цен во времени.

В работах [4-8] была предпринята попытка создания динамических систем, которые помимо статических параметров, содержат еще и динамически меняющиеся экономические параметры: ВВП, цена нефти, курс доллара, ввод жилья в регионе, выданные ипотечные кредиты и др. Поэтому разработанные в [4-8] модели обладают механизмом самоадаптации к меняющейся экономической обстановке. Настоящее исследование является непосредственным продолжением указанных работ и отличается от них более полным и тщательным сбором статистической информации, рассчитанным на то, что следующим этапом будет разработка модели, объединяющей несколько городов РФ, обладающей свойством самоадаптации не только к экономической обстановке, но и к регионам.

Кроме того, здесь предложен и опробован оригинальный способ зонирования городских территорий.

В настоящей работе в результате анализа литературных данных [1-8], были выбраны показатели, которые в наибольшей степени влияют на цену квартир: X1 – тип дома, X2 – тип стен, X3 – наличие балкона или лоджии, X4 – количество комнат, X5 – этаж, X6 – этажность дома, X7 – общая площадь квартиры, X8 – жилая площадь, X9 – площадь кухни, X10 – месяц продажи, X11 – сезон года, X12 – расстояние до первого центра, X13 – расстояние до второго центра, X14 – расстояние до третьего центра, X15 – расстояние до четвертого центра, X16 – ВВП, X17 – цена на нефть, X18 – курс доллара. Выходной параметр D – цена квартиры.

Особенностью данной работы является то, что помимо основных входных параметров, были включены расстояния до городских центров, имеющих наиболее высокие стоимости квартир: X12, X13, X14, X15. Для определения местоположения таких элитных городских центров из общего множества квартир были выбраны однотипные двухкомнатные квартиры с общей площадью 60 кв.м., и их координаты были нанесены на карту города, которая затем была раскрашена следующим образом: места расположения наиболее дорогих квартир были окрашены в красный цвет, который постепенно изменялся по мере снижения стоимости квартир от красного к зеленому. Таким образом, на карте города Екатеринбурга было выявлено четыре элитных центра, как показано на рисунке 1. Расстояния от оцениваемых квартир до этих элитных центров и были приняты в качестве дополнительных входных параметров нейросетевой модели.

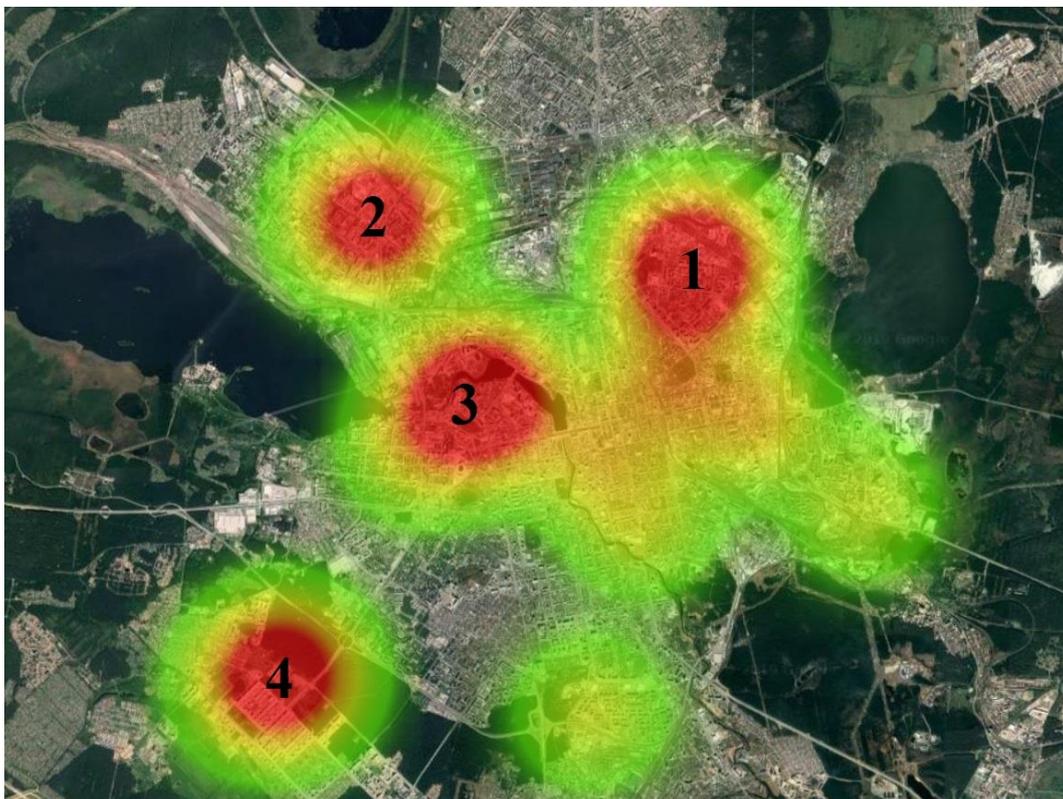


Рисунок 9. Ценовые зоны квартир на карте г. Екатеринбурга

Множество для обучения и тестирования нейросети было составлено на основе данных, взятых из газет города Екатеринбурга. Данное множество составило 3662 примера.

Проектирование нейросети было выполнено в программе «Нейросимулятор 5»[9] по методике [10]. В результате оптимизации, была спроектирована нейронная сеть с восемнадцатью входными нейронами, одним выходным и одним скрытым слоем с двумя сигмоидными нейронами.

Для проверки адекватности построенной сети, было использовано тестирующее множество, состоящее из 547 примеров. Средняя ошибка тестирования составила 17,9%. На рисунке 2 представлена гистограмма, показывающая разницу между фактической и прогнозируемой нейросетью стоимостью 10 квартир, выбранных из тестирующего множества случайным образом.

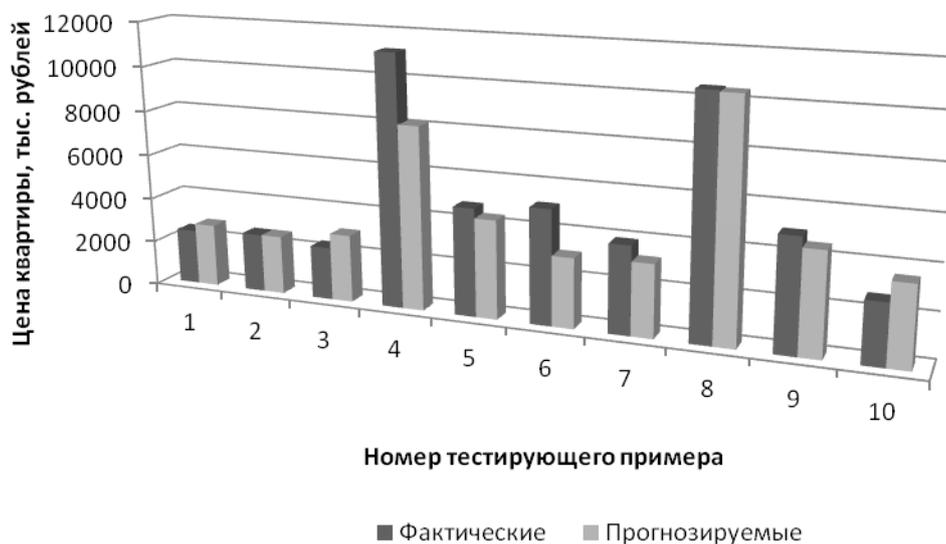


Рисунок 10. Результат тестирования нейронной сети

Судя по изображенным на рисунке 2 результатам, нейросеть можно признать адекватной и использовать для анализа квартирного рынка города Екатеринбурга.

Далее с помощью программы «Нейросимулятор 5» была вычислена значимость параметров. Результат представлен на рисунке 3.

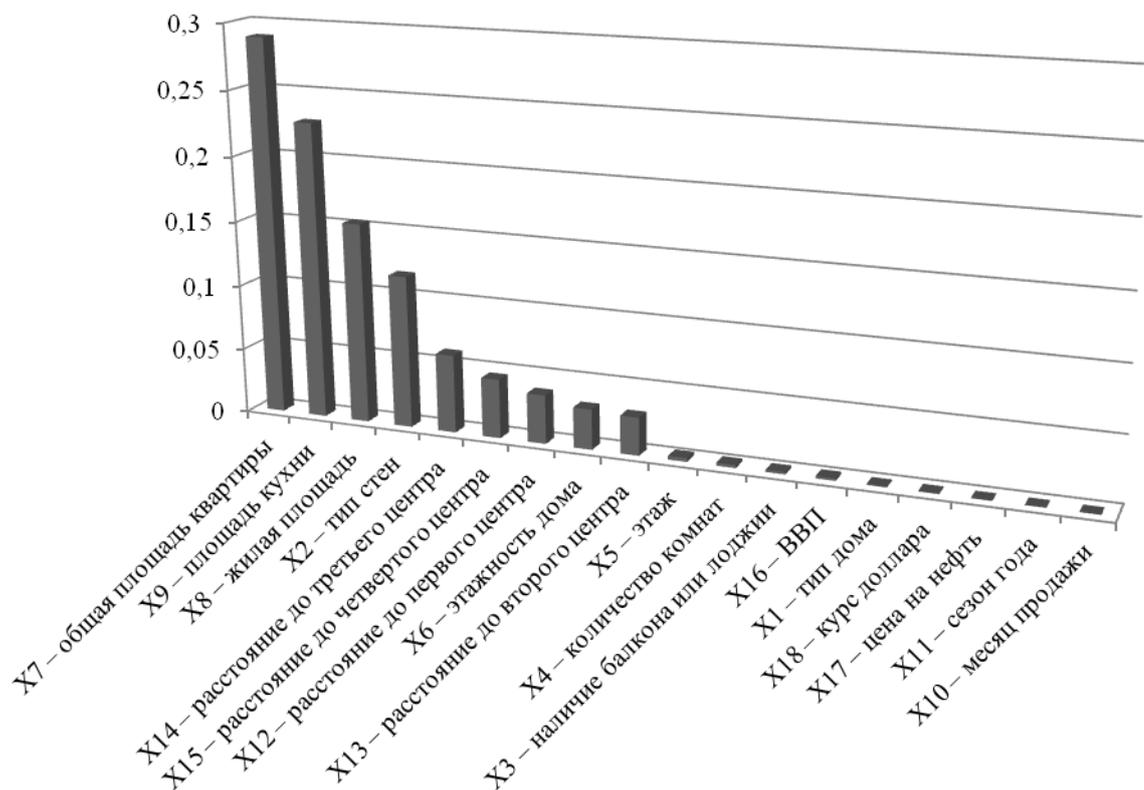


Рисунок 11. Значимость входных параметров нейросетевой модели

Из рисунка 3 видно, что наибольшую значимость имеют параметры: общая площадь квартиры, площадь кухни, жилая площадь. Далее идут тип стен, расстояние до третьего и четвертого центров и т.д.

Для анализа квартирного рынка были выбраны несколько квартир, различающихся количеством комнат и характеризующихся параметрами, представленными в таблице 1.

Таблица 1
Характеристики квартир, выбранных для сценарного прогнозирования

Квартиры	X 1	X 2	X 3	X 4	X 5	X 6	X7	X8	X9	X1 0	X1 1	X1 2	X1 3	X1 4	X1 5	X16	X1 7	X1 8
1-комнатная	7	6	5	1	8	26	20	15, 2	10, 2	4	4	9,3 3	12, 5	8,4 3	9,3 6	1895 0	51, 1	62, 6
2-комнатная	1	1	0	2	1	5	40	30	6	1	1	4,2 3	4,4 1	6,3 7	11, 5	1895 0	30, 8	77, 9
3-комнатная	2	1	1	3	1	10	60	49	11, 6	3	3	3,6 9	4,0 7	5,7 6	11 11	1895 0	49, 5	59, 7
4-комнатная	2	1	6	4	11	14	10 0	72	16	4	4	7,0 4	8,9 9	4,9 2	6,0 7	1895 0	51, 1	62, 6

На рисунках 4-10 показаны зависимости между некоторыми параметрами квартиры и их стоимостями, полученными путем сценарного прогнозирования методом вариаций входных параметров (замораживания) [10].

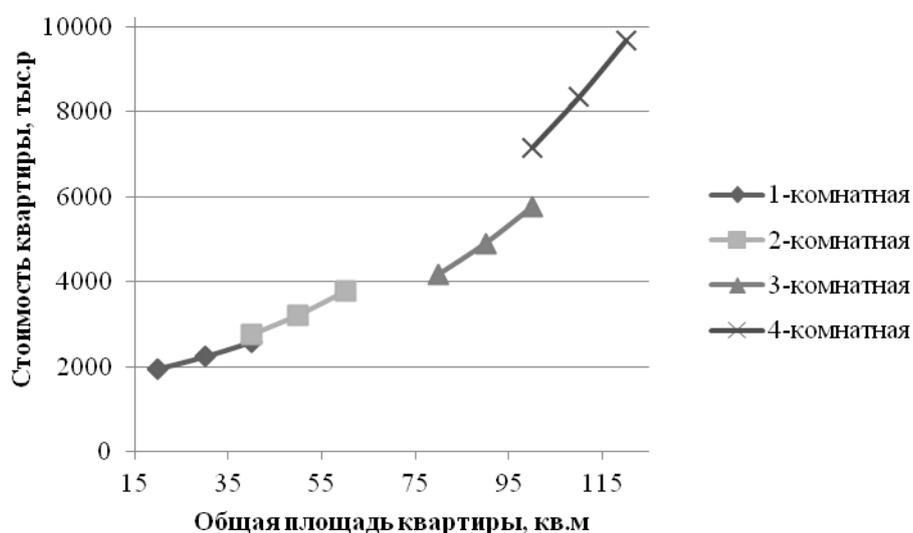


Рисунок 12. Зависимость стоимости квартир Екатеринбурга от общей площади

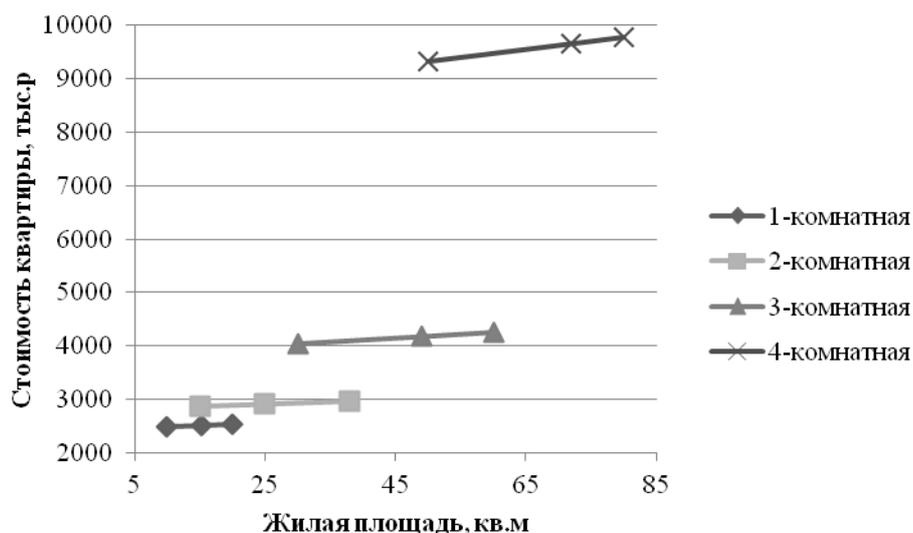


Рисунок 13. Зависимость стоимости квартир Екатеринбурга от жилой площади

Как видно из графиков, изображенных на рисунках 4 и 5, с виртуальным увеличением общей и жилой площади квартир, их стоимость увеличивается, что не противоречит здравому смыслу.

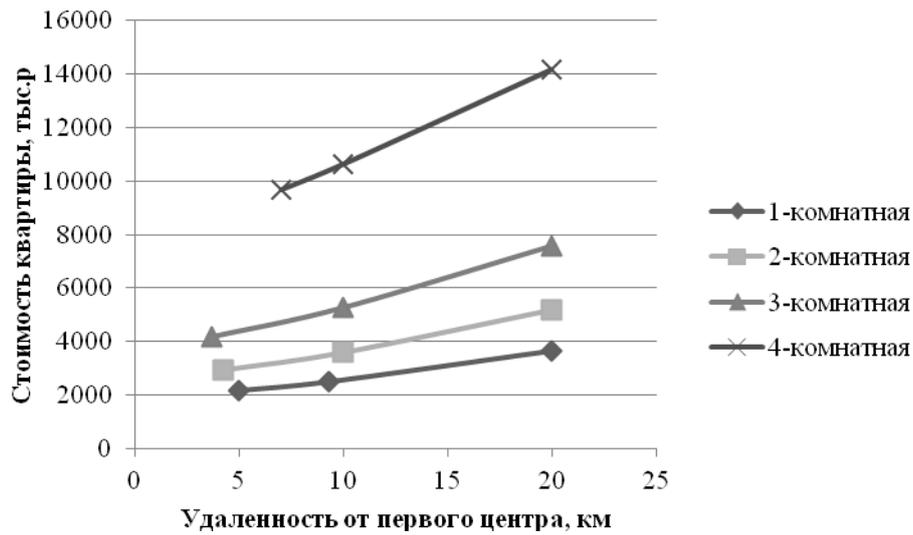


Рисунок 14. Зависимость стоимости квартир от расстояния до первого центра

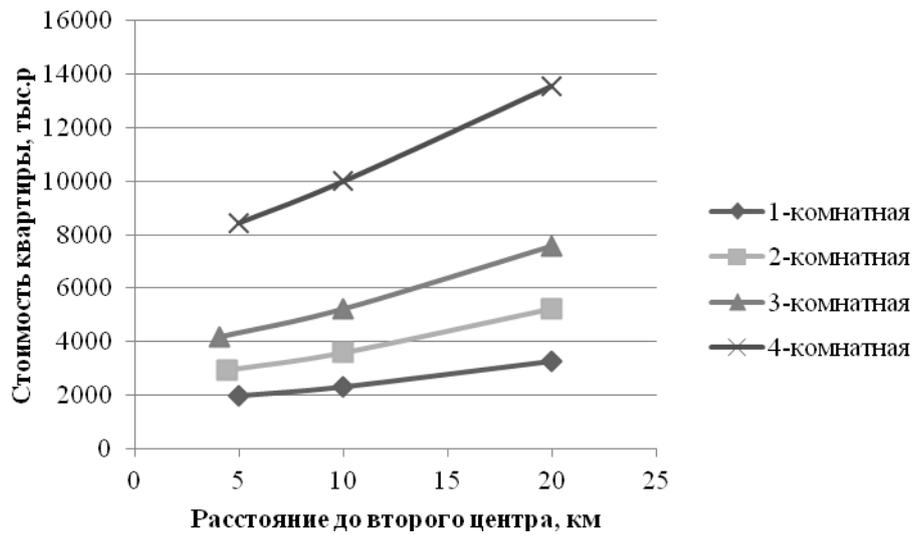


Рисунок 15. Зависимость стоимости квартир от расстояния до второго центра

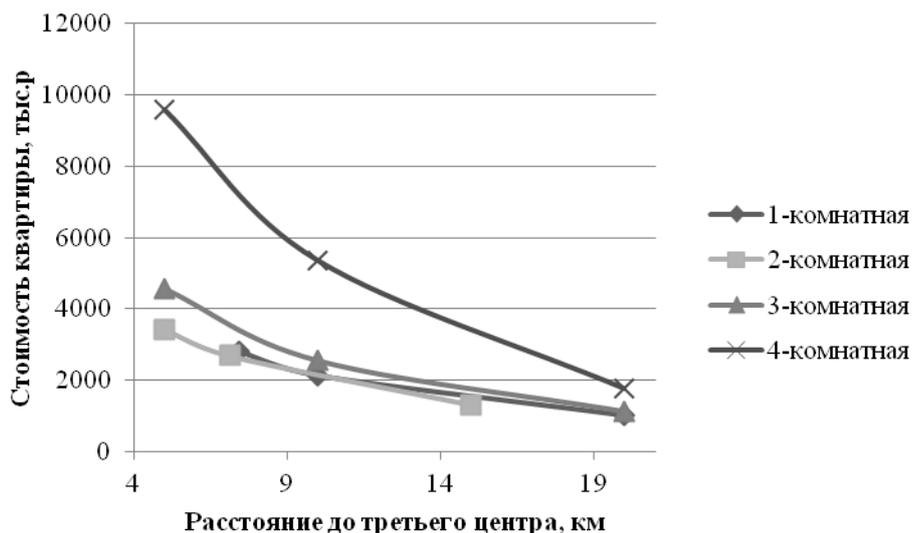


Рисунок 16. Зависимость стоимости квартир от расстояния до третьего центра

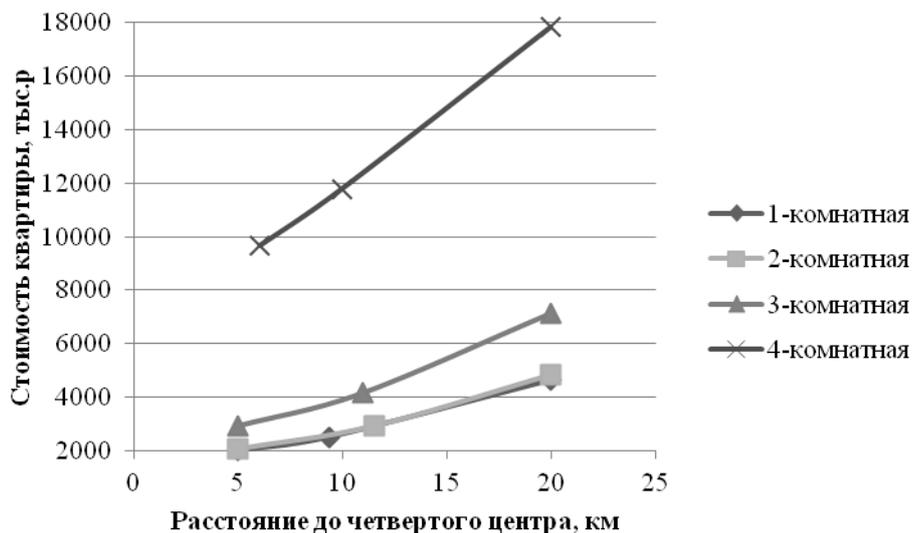


Рисунок 17. Зависимость стоимости квартир от расстояния до четвертого центра

По рисункам 6 – 9 видно, что с виртуальным удалением исследуемых квартир 3-го центра их стоимость падает, тогда как с удалением от 1-го, 2-го и 4-го центра стоимость квартир, наоборот, увеличивается. Полученные зависимости объясняются тем, что 3-й центр города Екатеринбурга является культурно-административным, тогда как остальные три центра – промышленными.

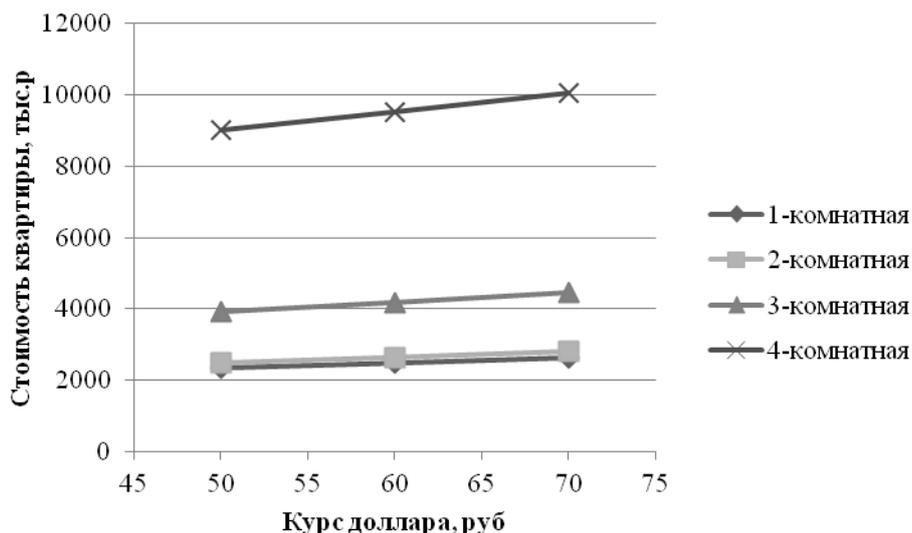


Рисунок 18. Зависимость стоимости квартир Екатеринбурга от курса доллара

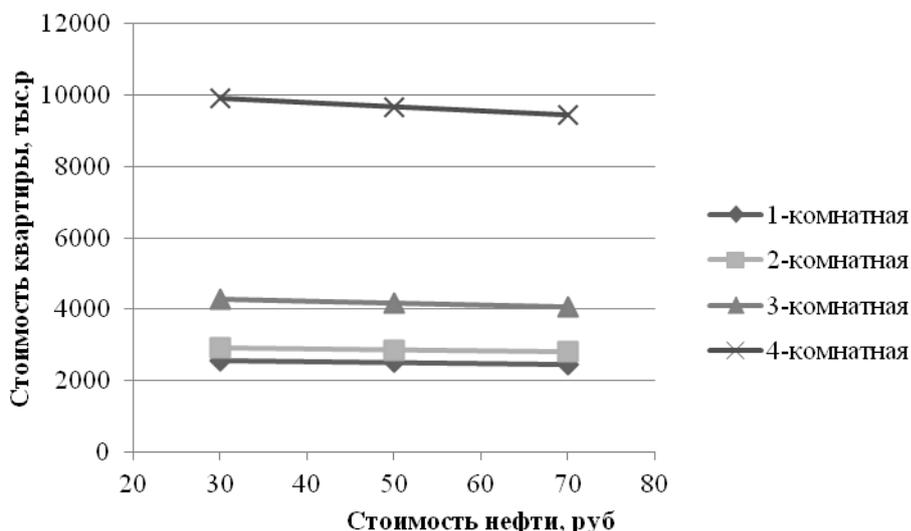


Рисунок 19. Зависимость стоимости квартир Екатеринбурга от цены на нефть

Как видно из зависимостей, изображенных на рисунках 10 и 11, с виртуальным увеличением курса доллара стоимость квартир увеличивается, а с увеличением цен нефти – уменьшается, причем эти тенденции в большей степени проявляются для более дорогих 4-х комнатных квартир.

Заключение. Создана система нейросетевого оценивания стоимости квартиры по трем категориям показателей: строительным, географическим, макроэкономическим. Проведены исследования рынка жилой недвижимости г.Екатеринбурга: методом сценарного прогнозирования построены зависимости стоимости одно- двух- трех- и четырехкомнатных квартир от общей и жилой площади, расстояния до четырех центров города Екатеринбурга, от текущего курса американского доллара и цены на нефть. Поскольку в качестве входных параметров учтены некоторые

макроэкономические показатели, разработанная система обладает свойством самоадаптации к изменяющемуся состоянию мировой экономики.

Благодарности. Работа выполнена при поддержке Российского фонда фундаментальных исследований (грант 19-010-00307).

Библиографический список

1. Tay D. P., Ho D. K. Artificial intelligence and the mass appraisal of residential apartments // *Journal of Property Valuation and Investment*. 1991. Vol. 10, no 2. P. 525–540.
2. Evans A., James H., Collins A. Artificial neural networks: An application to residential valuation in the UK // *Journal of Property Valuation and Investment*. 1991. no 11(2). P. 195–204.
3. Borst R.A. Artificial neural networks in mass appraisal // *Journal of Property Tax Assessment & Administration*. 1995. Vol. 1, no 2. P. 5–15.
4. Alexeev A.O., Alexeeva I.E., Yasnitsky L.N., Yasnitsky V.L. Self-adaptive Intelligent System for Mass Evaluation of Real Estate Market in Cities // *Advances in Intelligent Systems and Computing*. 2019. Vol. 850, pp. 81-87.
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. 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.
7. 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» = PermUniversityHerald. Economy*. 2016. № 2(29). С. 54–69. doi: 10.17072/1994–9960–2016–2–54–69.
8. Ясницкий В.Л. Нейросетевое моделирование процессов массовой оценки и сценарного прогнозирования рыночной стоимости жилой недвижимости. Автореферат диссертации к.э.н. 2018.
9. 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.
10. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.

DYNAMIC NEURAL NETWORK SYSTEM FOR ESTIMATION OF THE SECONDARY MARKET OF RESIDENTIAL REAL ESTATE OF THE CITY OF YEKATERINBURG

Korekova Mariya A., Nilidina Elizabeth, A., Yasnitsky Leonid N.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990, yasn@psu.ru

The article describes the development of a dynamic neural network system for assessing residential real estate in the city of Yekaterinburg. The system allows people to predict the price of apartments in three categories of indicators: macroeconomic, geographical, and construction. The system has the property of self-adaptation to changing macroeconomic indicators. An original method of zoning urban areas has been proposed and tested.

Keywords: artificial intelligence, neural network technologies, secondary apartment market, self-adaptation, cost estimation, forecasting, residential real estate.

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОЦЕНКИ СТОИМОСТИ КВАРТИР НА ПРИМЕРЕ РЫНКА НЕДВИЖИМОСТИ ПЕРМИ

Кукаркин Илья Андреевич, Сухов Александр Олегович

Национальный исследовательский университет «Высшая школа экономики»,
614070, г. Пермь, ул. Студенческая, д. 38, ASuhov@hse.ru

В работе описан подход к применению нейронных сетей для оценки стоимости жилой недвижимости города Перми. Для обучения и тестирования нейронной сети использовались данные оценочной компании Перми. Разработанная модель учитывает как статические параметры квартир, так и динамические макроэкономические показатели. Модель может быть использована для вычисления стоимости квартиры, выявления закономерностей и наиболее влияющих на стоимость факторов, характерных для жилой недвижимости города Перми, а также для прогнозирования изменений стоимости квартир.

Ключевые слова: оценка недвижимости, прогнозирование стоимости квартир, нейронная сеть, искусственный интеллект.

Введение. Оценка недвижимости сложный процесс, поскольку стоимость недвижимости зависит от множества параметров: площадь, район расположения, этаж, материал стен, ставка рефинансирования и др. До недавнего времени стоимость всех объектов жилой недвижимости устанавливалась государством «раз и навсегда». Согласно главе 32 налогового кодекса Российской Федерации «Налог на имущество физических лиц» налоговая база должна определяться как кадастровая (приближенная к рыночной) [2]. Данные изменения в правилах формирования налога на недвижимость инициировали проведение множества исследований в направлении автоматизации оценки стоимости недвижимости [1-4].

Кроме того, поскольку российский рынок недвижимости постоянно развивается и становится более сбалансированным, то информационные технологии позволяют не только изучить его поведение, но и выполнить прогнозирование стоимости объектов жилой недвижимости.

В рамках данной работы рассматривается подход к применению искусственных нейронных сетей для оценки и прогнозирования стоимости квартир на примере рынка недвижимости города Перми.

Рынок квартир РФ зависит не только от статических параметров квартир (жилая площадь, количество комнат, этажность дома и др.), но и от различных макроэкономических показателей, которые меняются с течением времени (ставка рефинансирования, ВВП, курс доллара и др.). Как показано в

[2, 3], добавление экономических параметров в модель оценки недвижимости делает ее независимой от постоянно меняющейся экономической ситуации в мире, стране и регионе.

Целью построения модели является получение оценки стоимости квартиры в Перми.

Входные и выходные данные. В качестве входных параметров нейронной сети были выбраны: жилая площадь (кв. м.), площадь кухни (кв. м.), количество комнат, этаж расположения, этажность дома, местоположение, год постройки, материал стен, ставка рефинансирования в РФ, средняя зарплата в Перми (руб.), ВВП в РФ (млрд. руб.), индекс РТС, курс доллара (руб./доллар), цена нефти марки Brent (руб./баррель), объем ввода жилья в Перми, объем выданных ипотечных кредитов в Перми (млрд. руб.). Выходной параметр модели – стоимость квартиры (руб.).

Для формирования множества примеров обучающей и тестовой выборки были получены данные оценочной компании Перми ООО «КСИ Консалтинг» с 2008 по 2018 год. Таким образом, в множество примеров были включены данные различных экономических состояний РФ: кризис (2008–2009 гг.), восстановление после кризиса (2010–2012 гг.), замедление роста (2013 г.), кризис (2014–2016 гг.), восстановление после кризиса (2017–2018 гг.). В течение этого десятилетнего периода ставка рефинансирования менялась от 7,25 до 12%, средняя зарплата в Перми – от 14740 до 26500 руб., ВВП – от 38800 до 93800 млрд. руб., котировки РТС – от 535 до 2044, курс доллара США – от 23,3 до 77,9 рублей, цена нефти марки Brent – от 1790 до 5515 руб., объем ввода жилья – от 200 до 530 тыс. кв. м., объем выданных ипотечных кредитов – от 4,5 до 46,4 млрд. руб.

В отличие от таких городов, как Москва и Екатеринбург, которые имеют кольцевую планировку, город Пермь разделен широкой рекой, вдоль которой он вытянут. Для добавления в модель параметра «местоположение» каждому микрорайону города Перми была дана экспертная оценка стоимости квартир в зависимости от удаленности микрорайона от центра города. Определение ценовых зон и принадлежности микрорайонов к ним было проведено сертифицированным оценщиком Российского общества оценщиков недвижимости и директором компании ООО «КСИ Консалтинг». Всего было выделено 7 ценовых зон.

Полученное множество примеров из 1769 записей было разделено на обучающее и тестовое. Поскольку рекомендуемый объем тестового множества – не менее 10%, было получено 1569 записей в обучающей выборке и 200 записей в тестовой.

Реальная стоимость квартир была также получены из данных оценочной компании ООО «КСИ Консалтинг».

Проектирование и обучение нейронной сети. Для построения модели был выбран многослойный персептрон, в качестве алгоритма обучения сети – алгоритм упругого распространения.

Для тестирования полученной сети была использована тестовая выборка из 200 записей. В результате тестирования было получено значение

среднеквадратичного отклонения равное 6%, что является достаточно хорошим результатом. Коэффициент детерминации, который показывает, насколько входные параметры описывают весь объем данных, получился равным 81%.

Исследование и прогнозирование. Поскольку построенная модель адекватно отражает предметную область, ее можно использовать для изучения закономерностей рынка недвижимости Перми. Применим метод «замораживания», который для исследования зависимости стоимости квартиры от конкретного параметра позволяет зафиксировать все параметры и менять только один – исследуемый. Для выполнения экспериментов были выбраны четыре квартиры, имеющие различные параметры:

- Однокомнатная квартира с жилой площадью 16,4 кв. м., площадью кухни 8,7 кв. м., расположенная на втором этаже десятиэтажного панельного дома, дом находится в Мотовилихинском районе и был построен в 2015 году.
- Двухкомнатная квартира с жилой площадью 27 кв. м., площадью кухни 9,2 кв. м., расположенная на шестом этаже шестиэтажного кирпичного дома, дом находится в Дзержинском районе и был построен в 2017 году.
- Трехкомнатная квартира с жилой площадью 43,8 кв. м., площадью кухни 11,9 кв. м., расположенная на девятом этаже девятнадцатиэтажного панельного дома, дом находится в Мотовилихинском районе и был построен в 2018 году.
- Четырехкомнатная квартира с жилой площадью 55,4 кв. м., площадью кухни 11,1 кв. м., расположенная на двенадцатом этаже двадцатиэтажного панельного дома, дом находится в Орджоникидзевском районе и был построен в 2016 году.

Оценка квартир осуществлялась на момент состояния рынка недвижимости в конце 2018 года.

В результате проведенных экспериментов были выявлены следующие закономерности.

1. Стоимость всех типов квартир изменяется незначительно при изменении параметра «местоположение» в интервале от 3 до 7, т.е. для квартир, расположенных в отдаленных микрорайонах Перми. Заметное возрастание стоимости можно наблюдать для всех типов квартир, у которых параметр «местоположение» изменяется в интервале от 1 до 2, т.е. для квартир, расположенных ближе к центру города. В этом случае цены для одно-, трех- и четырехкомнатных квартир возрастают по экспоненте.

2. Стоимость всех типов квартир равномерно возрастает при увеличении жилой площади. Зависимость стоимости квартир от жилой площади практически линейная. Наибольшая скорость возрастания стоимости у четырехкомнатной квартиры. Одно- и двухкомнатная квартиры при уменьшении площади до 15 кв. м. практически равны в стоимости.

3. Стоимость всех типов квартир равномерно возрастает при увеличении площади кухни. Наибольшая скорость возрастания стоимости у

четырёхкомнатной квартиры, затем у трехкомнатной, две оставшихся квартиры имеют примерно одинаковую скорость возрастания.

4. Стоимость всех типов квартир равномерно возрастает при увеличении этажа расположения квартиры.

5. Стоимость всех типов квартир увеличивается с увеличением количества этажей в доме. Это можно объяснить тем, что большинство зданий до 5 этажей были построены до 1980 года, а дома с количеством этажей больше 10 являются новыми и стоимость квартир в них значительно выше. Наименьшую зависимость от количества этажей в здании имеет однокомнатная квартира, ее стоимость практически не меняется. В то время как остальные три типа квартир имеют рост стоимости начиная с двухэтажного здания, который уменьшается к шестнадцатиэтажному зданию.

6. Стоимость всех типов квартир возрастает практически линейно в зависимости от года постройки. Скорости возрастания всех типов квартир сопоставимы.

7. Стоимость квартир с материалом стен «шлакоблок», «газобетон», «монолит» практически одинаковая. Стоимость квартир с материалом стен «панель» ниже стоимости квартир из других материалов. Стоимость квартир с материалом стен «кирпич» выше стоимости квартир из других материалов.

В следующей серии экспериментов будет рассмотрено влияние динамических факторов на стоимость квартир.

8. Изменение объема выданных ипотечных кредитов отражается на стоимости квартир каждого типа в разной степени. Стоимость одно- и четырехкомнатных квартир практически не изменятся при любом изменении объемов кредитования. В то время как двух- и трехкомнатные квартиры существенно дешевеют при увеличении объемов выданных кредитов.

9. Изменение средней зарплаты в Перми сказывается на стоимости всех типов квартир. Например, для двухкомнатной квартиры прогнозируемые изменения в стоимости при увеличении средней зарплаты на 20% составят 9,2%.

10. Изменение ВВП отразится на всех типах квартир. Зависимости всех типов квартир от ВВП схожи, различаются они лишь в скорости возрастания. Например, для трехкомнатной квартиры прогнозируемые изменения в стоимости при увеличении ВВП на 28% составят 32,5%.

11. С увеличением индекса РТС стоимость всех типов квартир, кроме четырехкомнатной, будет уменьшаться.

12. Изменение курса доллара отразится примерно в одинаковом объеме на стоимости всех типов квартир. При возрастании курса доллара стоимость квартир будет снижаться. Однако однокомнатная квартира потеряет в стоимости меньше, чем остальные.

13. Изменение параметров «цена нефти», «объем ввода жилья», «ставка рефинансирования» слабо влияет на изменение стоимости всех типов квартир.

Заключение. Предложена модель оценки жилой недвижимости города Перми, учитывающая как статические показатели квартир, так и

динамически меняющиеся макроэкономические показатели. С помощью метода «заморозки» на основе созданной модели исследовано влияние статических и динамических параметров на стоимость квартир.

Модель может быть полезна для риелторов, оценщиков и экспертов рынка недвижимости. Для других стран и городов с помощью предлагаемой методики могут быть выполнены аналогичные исследования и прогнозы.

Благодарности. Работы были инициированы темой гранта РФФИ 19-010-00307.

Библиографический список

1. Грибовский С.М., Сивец С.А. Математические методы оценки стоимости недвижимого имущества. М.: Финансы и статистика, 2014. 368 с.
2. 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. Экономика. 2016. № 2(29). С. 54-69.
3. 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.
4. Zhang H., Gao S., Seiler M.J., Zhang Y. Identification of real estate cycles in China based on artificial neural networks // Journal of Real Estate Literature. 2015. Vol. 23. No 1. P. 67-83.

APPLYING OF NEURAL NETWORKS FOR EVALUATING THE COST OF APARTMENTS ON THE EXAMPLE OF PERM REAL ESTATE MARKET

Kukarkin Ilya A., Sukhov Alexander O.

National Research University Higher School of Economics

614070, Russian Federation, Perm, Studencheskaya, 38, ASuhov@hse.ru

The paper describes the approach to the applying of neural networks for evaluating the cost of apartments in Perm city. For training and testing of the neural network data from the Perm evaluating company was used. The developed model takes into account static apartment parameters and dynamic macroeconomic indicators. The model can be used to calculate the cost of apartments and to predict changes in the apartments cost.

Key words: real estate valuation, apartment cost forecasting, neural network, artificial intelligence.

ДИВЕРГЕНЦИЯ СЛОЖНОСТНОЙ РАЦИОНАЛЬНОСТИ СОЦИОТЕХНИЧЕСКИХ СИСТЕМ INDUSTRY 4.0: ЦИФРОФИЗИКА И НОВАЯ ИСКУССТВЕННОСТЬ

Лещёв Сергей Валерьевич

Национальный исследовательский ядерный университет «МИФИ»
115409, Россия, г. Москва, Каширское ш., 31, leshev.sergey@yandex.ru

Статья посвящена цифровой трансформации социальности и сопутствующим преобразованиям представлений о коммуникациях, компьютеринге, рациональности. Обосновывается представление об интерфейсах взаимодействия как наиболее существенном методологическом сдвиге от физических, социальных, экономических сущностей к их коммуникационному взаимодействию. Искусственный интеллект и новые формы компьютеринга рассматриваются как матрицы преобразования рациональности сложных социотехнических систем.

Ключевые слова: искусственный интеллект, цифровая трансформация, когнитивная инженерия, НБИКС-парадигма, нейроинтерфейсы, конвергентные технологии, киберфизические системы.

Цифровая трансформация экономики и общества 21 века преобразует привычные научные, методологические, технологические и философские ориентиры. Изменяются представления о компьютеринге как таковом (большие данные, облачные вычисления, туманный компьютеринг, озера данных, машинное обучение), а также интердисциплинарные корреляции в области нано-био-инфо-когно-социогуманитарного измерения индивидуальной, экономической, технологической действительности [1, 10]. Киберфизические среды, фиджитал, компьютерное моделирование, биоинформатика, молекулярный компьютеринг, искусственно-интеллектуальные помощники задают новый вектор цифрофизического осмысления «компьютерной естественности». Возникает новая экология существования, столь сложная, что каждое следующее вопрошание о тех или иных сущностях – научных, экономических, технологических – становится вопросом «доступа к сущности», т.е. вопросом опосредования общения между различными коммуникационными системами и уровнями коммуникации. В цифровую эпоху сущности уступают ведущую роль медиумам коммуникации, интерфейсам взаимодействия [3, 7, 9].

Понимаемые в самом широком смысле, социотехнические системы, определяющие инфогенезис и инфотектонику в качестве актуального коммуникационного облика цифрового мира [6], вводят современного философа в очередной круг размышлений о сути рациональности,

когнитивности, интеллекта. Электронная культура, фундаментальное оразумнивание сред обитания («умное окружение», интернет вещей, проникающий компьютеринг, киберреальность, rfid-метки) и НБИКС-технологии, предлагающие многообразные интеллектуальные системы информационного процессинга, по сути, определяют становление новой когнитивной экологии социального пространства, новых форм экологического единства человека и техники [1, 2, 4, 8]. Когнитивность обретает новые измерения и формулы существования. Нейрокомпьютерные интерфейсы, кибернетические организмы, нейронные сети, робототехнические системы, искусственно-интеллектуальные агенты и системы больших данных, первоначально лишь аранжирующие инфраструктурные потребности ИКТ-комплекса, постепенно трансформируют природный и социальный миры.

Глобализационные процессы, интенсифицируемые все более глубоким инфо-нанотехнологическим проникновением в реальность, многообразными формами компьютеринговой индустрии и революционными информационно-коммуникационными решениями позволяют говорить о современной социальной, культурной, технической и научной реальностях в терминах многоплановой коммуникационной медиатизации. Первичным морфологическим паттерном любой (техно-научной, социо-политической, нейро-компьютерной) коммуникации становятся интеракционные интерфейсы, с порою неразличимыми в них, синергетически сплавленными моментами полярных областей развития и сфер духовности. В первую очередь, упоминания заслуживает колоссальный глобализационный социо-онтологический фреймворк, обладающий на данный момент всё ещё непредставимым, и, однако, уже инженерно прорисовываемым абрисом потенциального воздействия на все сферы социальности: Industry 4.0 (Промышленность 4.0).

Предполагающая небывалую степень интеграции многообразных феноменов человеческого существования – субъекта и объекта, спроса и предложения, креативности и компьютеринга, иерархии и гетерархии – Промышленность 4.0 позволяет рассуждать о тайных истоках и устьях истечения рациональности, потребляемой и растворяющейся в социо-инженерных, технонаучных экосистемах нейро-компьютерного, межмашинного, объект-объектного взаимодействия. Смещение порядка и хаоса, детерминированности и сложности становятся столь непредсказуемыми, что перед ответственным философом науки возникает целый пул проблем медиа-критического осмысления разумности и социальности как таковой. По сути дела, в данном отношении необходимо говорить о диссипативной рациональности, обнаруживающей социотехнические, киберфизические лакуны виртуализируемой онтологии социума и формирующей новые регионы социопсихического, субъект-объектного, реально-виртуального бытия.

Рациональность систем проникающего компьютеринга (UbiComp), окружающего интеллекта (AmI, AmE), интернета вещей, еще недавно

подлежащие дефинитивному оформлению в терминах искусственно-интеллектуальной «ограниченной рациональности» (Г. Саймон), сегодня погружается в океан автореферентной киберфизической связности всего и вся, преобразующей разумно-искусственно-интеллектуально-витальные, углеродно-кремниевые конститuenty магического круга социотехнических систем soft-hard-wetware в новую онтологическую когерентную метакоммуникацию природного и искусственного – everywhere [5]. Все действительное становится, если ещё и не разумным – то уже рациональным, причем меру подобной сложностной рациональности уже не вправе задавать устаревшие метафизические рамки разумности, либо интерфейсы intersubjectivity. И искусственный интеллект информационных систем, и искусственная реальность, нанотехнологически порождаемая из бездны межатомных взаимосвязей, и коррелятивная каузальность, возникающая в системах больших данных из лакун связности неструктурированных данных, и биологически нововозникающая жизнь синтетической бактерии (К. Венгер, 2009) – все подобные формы искусственности невозможно более считать лишь «сопровождающими» природу: симулякры становятся харизматичнее действительности в своей естественности.

В круге перечисленных «новых искусственностей» можно говорить о рассеянии, диссипации рациональности в каждой коммуникационной матрице и о дивергенции, расхождении когнитивно-рационального облика цифровой эпохи. Системы диссипативной рациональности очевидным образом предполагают новую, сложностную рекогносцировку технонаучного ансамбля компетенций, знаний, навыков, умений, в первую очередь задействованную в процессах инновационного реинжиниринга промышленности, образования, компьютеринга. В этом отношении, корректнее обозначать нарождающиеся киберфизические, реально-виртуальные онтологии, коммуникации и структуры экосистемами сложностной рациональности, в пределах которых открытая и закрытая рациональность более не противопоставлены друг другу полярно, но взаимопределяют меру системной «развоплощенности» технонаучной коммуникации в киберфизических онтологиях и социотехнических медиасредах. В подобной тематизации, сформулированное Ю.Хабермасом противопоставление экспертной культуры и публичной сферы реконструируется вслед за сложностным апгрейдом как понятия рациональности в философии науки, так и ее феноменом на новом витке технологических преобразований социальности.

Библиографический список

1. Castells M. The Information Age: Economy, Society, and Culture. Volume I: The Rise of the Network Society. Oxford: Blackwell. 2000. 595 P.
2. Roco M.C., Bainbridge W.S., editors. Converging technologies for improving human performance. Nanotechnology, biotechnology, information technology and cognitive science. Arlington, Virginia: National Science Foundation (NSF) / Department of Commerce (DOC). 2002.

3. McLuhan M. *Understanding Media: The Extensions of Man*. McGraw-Hill, New York, NY, 1964.
4. Coenen M. *Konvergierende Technologien und Wissenschaften. Der Stand der Debatte und politischen Aktivitäten zu «Converging Technologies»*. – Berlin: TAB. 2008. S.264.
5. Greenfield A. *Everyware: The Dawning Age of Ubiquitous Computing* / Alan Greenfield. Berkeley, CA: New Riders. 2006. 267 p.
6. Leshchev S.V. *The Infogenesis and Infotectonics of Electronic Culture: New Horizons of Information Technologies // Scientific and Technical Information Processing*. 2015. Vol. 42. No. 3. Pp. 135–139.
DOI: 10.3103/S014768821503003X
7. Лещёв С.В. *Интерфейсы социальной экологии: от технологической конвергенции к интернету вещей // Философские науки*. 2014. №11. С.106-113.
8. Лещёв С.В. *НБИК-конвергенция: стратегемы дифференцированного и синтетического развития нано-, био-, инфо- и когнитивных технологий // Полигнозис*. 2014. № 1–2 (46). С. 70–77.
9. Лещёв С.В. *Интерфейс-модальность: вторичная когнитивность инфо-биогебеза // Биомедицинская радиоэлектроника*. 2016. № 4. С.69-70.
10. Лещёв С.В. *НБИК-контексты виртуализации: искусственный интеллект и большие данные // Полигнозис*. 2015. № 1-2 (48). С.56-60.

A COMPLEX RATIONALITY’S DIVERGENCE OF SOCIOTECHNICAL SYSTEMS «INDUSTRY 4.0»: DIGITAL PHYSICS AND A “NEW ARTIFICIALNESS”

Leshchev Sergey V.

National Research Nuclear University MEPHI,
115409, Russia, Moscow, Kashirskoe shosse, 31, leshev.sergey@yandex.ru

The article is devoted to the digital transformation of sociality and the corresponding transformations of ideas about communication, computing and rationality. The idea of interaction interfaces as the most significant methodological shift from physical, social, economic entities to their communication interactions is presented. Artificial intelligence and new forms of computing are considered as matrices of transformation of rationality of complex socio-technical systems.

Key words: artificial intelligence, digital transformations, cognitive engineering, NBICS-paradigm, neurointerfaces, converging technologies, cyberphysical systems

НЕЙРОСЕТЕВАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ ЦЕН НА ЗОЛОТО

Масленникова Дарья Юрьевна

Пермский государственный национальный исследовательский
университет, КМБ. Россия, г. Пермь, 614990, ул. Букирева, 15,
maslennikova-dasha@mail.ru

Разработана экономико-математическая модель прогнозирования цен на золото, основанная на показателях экономических котировок. Из исследования модели было выяснено, что наиболее значимыми параметрами формирования цены являются ставка рефинансирования, уровень инфляции и цена на нефть Brent. Наименьшую значимость имеют цены на евро и доллар.

Ключевые слова: золото; котировки; евро; доллар; нефть; курс валют; биржа; финансы; драгоценные металлы; инвестиции; прогноз; модель; нейронная сеть.

Введение

Нестабильность экономической среды за последние годы сформировала острую потребность в выработке методов прогнозирования экономических показателей. Проблема прогнозирования котировок, в частности – цен на драгоценные металлы, остается достаточно актуальной, т.к. прогноз котировок в современных условиях необходим для грамотного инвестирования. Грамотный анализ текущей экономической ситуации и прогноз цен позволяет более эффективно управлять финансами.

Целью настоящей работы является создание компьютерной программы прогнозирования курса цен на золото, основанной на закономерностях российской действительности, отраженных в финансовой отчетности ЦБ РФ.

Перспективным инструментом для выявления скрытых в статистической информации закономерностей и построения на их основе математических моделей являются нейросетевые технологии. Нейрокомпьютерные и нейросетевые технологии – это одна из наиболее эффективных стратегий искусственного интеллекта. Они наследуют от своего прототипа – мозга, его полезные свойства: способность извлечения знаний из статистических данных, способность обобщения их в виде законов и закономерностей предметных областей, свойство интуиции [1], как способность делать правильные прогнозы и принимать верные решения в тех случаях, когда обычная логика оказывается бессильной. Как убедительно показывает опыт использования нейросетей ([2, 3], www.PermAi.ru), хорошо спроектированные и правильно обученные нейронные сети способны

самостоятельно выявлять закономерности практически любых предметных областей и строить адекватные математические модели в промышленности, в экономике и бизнесе, в политологии, в криминалистике, в медицине, в экологии, в исторических науках, спорте и др.

Математическая постановка задачи

При постановке задачи в качестве входных параметров нейросетевой математической модели были выбраны критерии, которые являются наиболее широко распространенными, включенными в официальные показатели ЦБ РФ [4] и, в то же время, доступными. Всего было использовано 12 входных параметров:

x_1 – Цена золота сегодня;

x_2 – День недели;

x_3 – Курс доллара на сегодняшний день;

x_4 – Динамика курса доллара по сравнению с предыдущим днем;

x_5 – Курс евро на сегодняшний день;

x_6 – Динамика курса евро по сравнению с предыдущим днем;

x_7 – Курс нефти Brent на сегодняшний день;

x_8 – Динамика курса нефти Brent по сравнению с предыдущим днем;

x_9 – Курс нефти WTI на сегодняшний день;

x_{10} – Динамика курса нефти WTI по сравнению с предыдущим днем;

x_{11} – Текущая ставка рефинансирования;

x_{12} – Текущий уровень инфляции;

d_1 – Цена золота завтра.

Среди входных параметров модели имеются качественные и количественные факторы. Такие качественные показатели как динамика курса доллара, евро, нефти Brent и нефти WTI показывают зависимость курса на текущий день в зависимости от прошлого дня, выросла цена или упала по сравнению со вчерашним днем. Если цена выросла, то в таком случае использовалось значение «1», в противном случае – «-1». Также был использован показатель дня недели. Данный показатель был зашифрован: понедельник соответствует значению «1», вторник – «2», среда – «3», четверг – «4», пятница – «5», суббота «6». Показатель «7» (воскресение) отсутствует, так как в этот день обычно нет данных о котировках валют и нефти. Остальные количественные показатели, такие как цена золота сегодня, курс евро, доллара, нефти Brent и нефти WTI, текущая ставка рефинансирования и текущий уровень инфляции, представляют собой вещественные числа.

Выходная переменная у принимает значение, равное прогнозируемой цене золота на завтрашний день, в зависимости от параметров текущего дня.

В качестве источника информации для обучения нейронных сетей были использованы данные финансовой отчетности с сайта Центрального банка Российской Федерации, официальные валютные и нефтяные котировки [4].

На основании этой информации было сформировано множество, содержащее 1182 примеров. Все множество примеров разбито на обучающее, использованное для обучения сети, и тестирующее, предназначенное для проверки ее прогностических свойств. Естественно, что примеры тестирующего множества при обучении сети не использовались.

Проектирование, оптимизация, обучение, тестирование нейронной сети и эксперименты над нейросетевой математической моделью выполнялись с помощью нейропакета [2]. Оптимальная структура нейронной сети представляла собой персептрон [3], имеющий двенадцать входных нейронов, один скрытый слой с четырьмя нейронами и один выходной нейрон. В качестве активационных функций нейронов скрытого слоя и выходного нейрона использовалась функция гиперболического тангенса. После обучения, прогностические свойства сети проверялись на тестирующих примерах, и среднеквадратичная ошибка тестирования нейронной сети составила 1,5 %.

Обучение и тестирование нейронных сетей проводилось согласно методике, принятой в Пермской научной школе искусственного интеллекта ([2-3], www.PermAi.ru).

3. Исследование предметной области

После проверки разработанной нейросетевой математической модели на адекватность и точность, ее можно использовать для исследования предметной области. Эта задача решалась путем проведения виртуальных компьютерных экспериментов, в ходе которых вычисления с помощью нейронной сети производились при изменении одного из входных параметров, в то время как остальные параметры «замораживались», т.е. сохранялись неизменными. В процессе исследования нейросетевой модели решались задачи выявления закономерности котировок. Мы пользовались тем, что обученная нейросетевая модель реагирует на изменение входных параметров и ведет себя так же, как вела бы себя сама предметная область.

Первый вопрос, на который можно получить ответ с помощью модели – выявить значимость входных параметров, т.е. – степень их влияния на результат моделирования – цену золота (рис.1). Объективную оценку такого влияния можно получить, например, по методике с помощью той же нейронной сети путем поочередного исключения входных параметров и наблюдения за погрешностью ее тестирования. Чем выше оказывается погрешность тестирования, тем значимее соответствующий исключенный параметр. Построенная таким способом гистограмма приведена на рисунке 1. Высота столбцов соответствует погрешности тестирования, полученной при исключенном входном параметре, подписанном под столбцом, поэтому ее можно интерпретировать как значимость этого параметра.

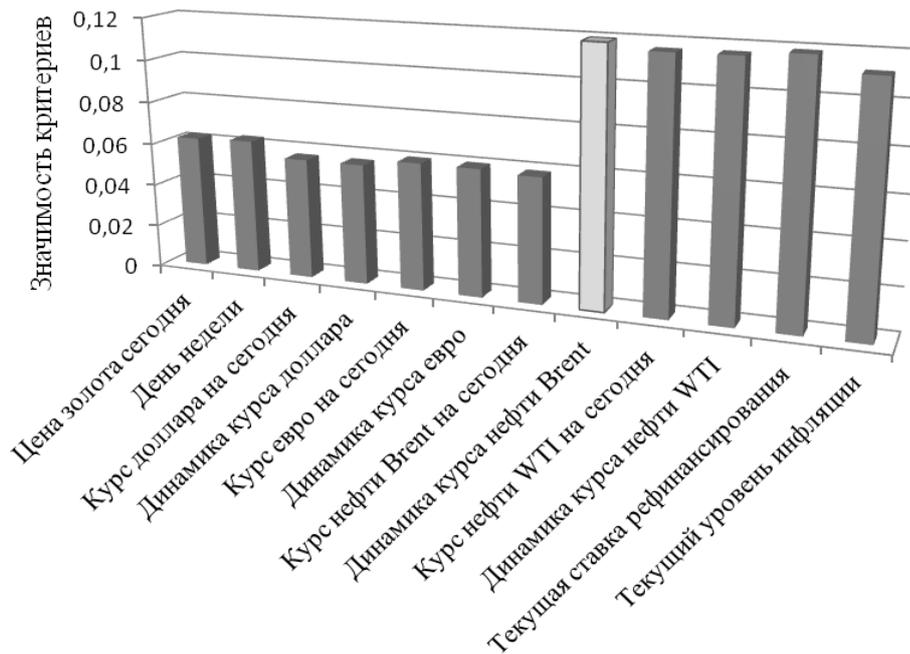


Рисунок 1. Значимость параметров построенной нейросети

Как видно из рисунка, наиболее значимыми параметрами являются – динамика курса нефти Brent, текущая ставка рефинансирования, курс и динамика нефти WTI, текущий уровень инфляции.

При сравнении действительных цен на золото и прогнозируемых возникают достаточно небольшие отклонения (рис.2), поэтому можно сделать вывод о том, что прогнозируемое значение достаточно точно определяется обученной нейросетью, т.к. погрешность тестирования составляет 1,5%.

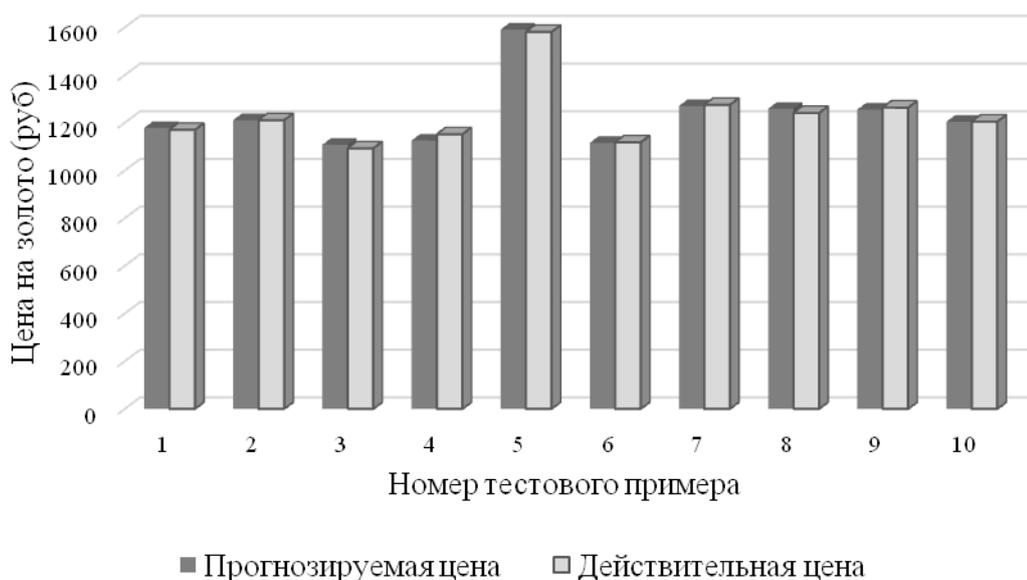


Рисунок 2. Сравнение действительных и прогнозируемых цен на золото

3.1. Исследование влияния курса нефти Brent

Рассмотрим следующие показатели, приведенные в таблицах 1,2.

Таблица 1. Параметры котировок

Цена золота сегодня	День недели	Курс доллара на сегодняшний день	Динамика курса доллара	Курс евро	Динамика курса евро	Курс нефти Brent
1108,10	2	64,5	1	70,75	1	50,44

Таблица 2. Параметры котировок. Продолжение

Динамика курса нефти Brent	Курс нефти WTI	Динамика курса нефти WTI	Текущая ставка рефинансирования	Текущий уровень инфляции	Цена золота завтра
1	43,08	-1	8,25	0,40	1117,45

По данным таблицы построим анализ влияния курса нефти Brent. Исследование проведем методом замораживания: все параметры остаются прежними, но изменяется исследуемый параметр с определенным шагом. По результатам исследований нейросетевой математической модели, приведенным на рис. 3, можно сделать вывод о том, что при повышении цены на нефть Brent происходит снижение цены на золото. На рисунке 3 и на всех последующих серым цветом выделяется действительное значение входного параметра, черным выделены прогнозируемые значения рассматриваемого параметра. Исследования в разделах 3.2-3.8 происходит аналогично пункту 3.1.

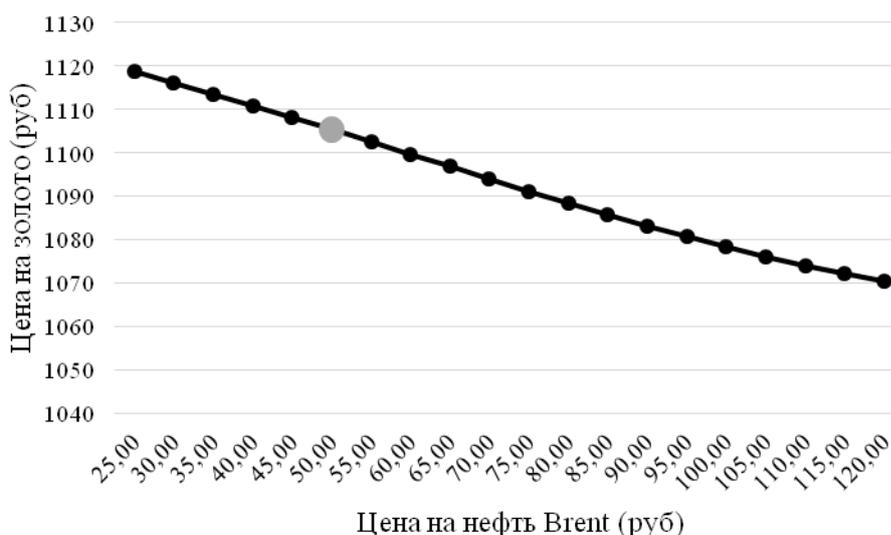


Рисунок 3. Влияние курса нефти Brent на курс золота

3.2. Исследование влияния динамики курса нефти Brent

Исходя из результатов нейросетевой модели, изображенных на рисунке 4, можно сделать вывод о том, что при падении курса нефти Brent (по сравнению с предыдущим днем) происходит повышение цены на золото. Если наблюдается рост курса нефти Brent, то цена на золото снижается.

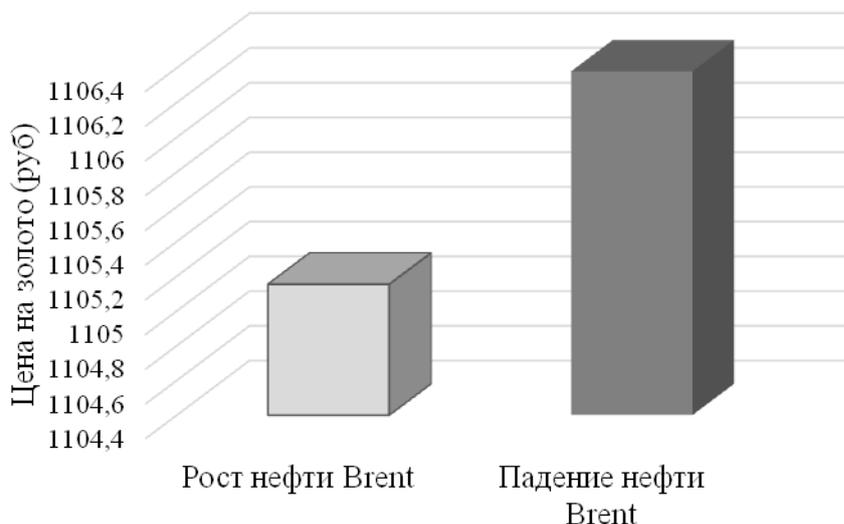


Рисунок 4. Влияние динамики курса нефти Brent на курс золота

3.2. Исследование влияния курса нефти WTI

По результатам нейросетевой модели, изображенным на рисунке 5, можно заметить, что если цена на нефть находится в диапазоне от 25 до 70 рублей, то цена на золото достаточно стабильна, не наблюдается резких скачков цены. Если же цена на нефть WTI превышает 70 рублей, то наблюдается достаточно стабильный рост цены на золото.

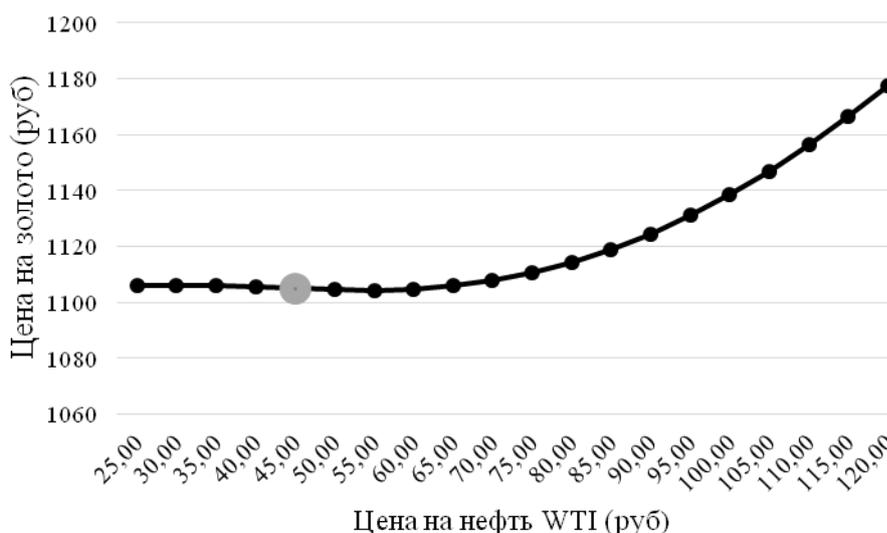


Рисунок 5. Влияние курса нефти WTI на курс золота

3.3. Исследование влияния динамики курса нефти WTI

На рисунке 6 приведены результаты данных исследований. При падении курса нефти WTI (по сравнению с предыдущим днем) происходит

повышение цены на золото. Если наблюдается рост курса нефти WTI, то цена на золото снижается. Исходя из этого можно сказать о том, что динамика курса нефти WTI влияет на курс золота аналогично динамике курса нефти Brent.

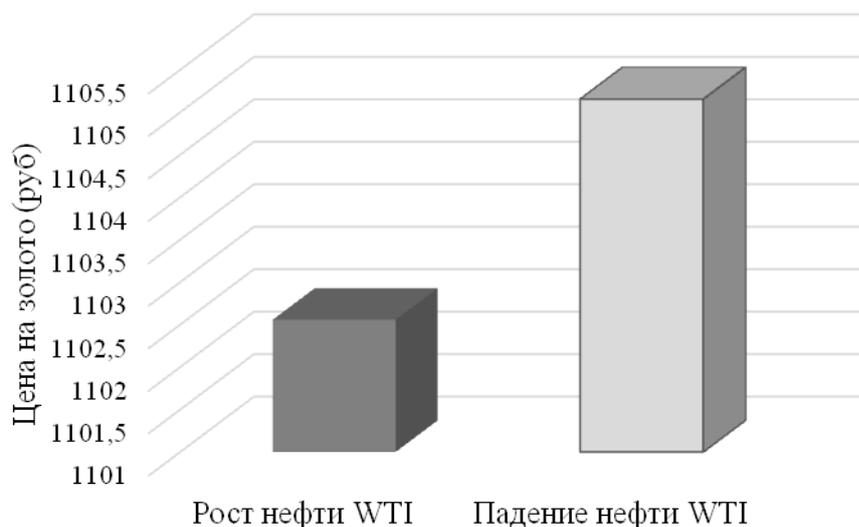


Рисунок 6. Влияние динамики курса нефти WTI на курс золота

3.4. Исследование влияния ставки рефинансирования

Результаты исследования влияния ставки рефинансирования на курс золота изображены на рисунке 7. При увеличении ставки рефинансирования происходит стабильное повышение курса золота.

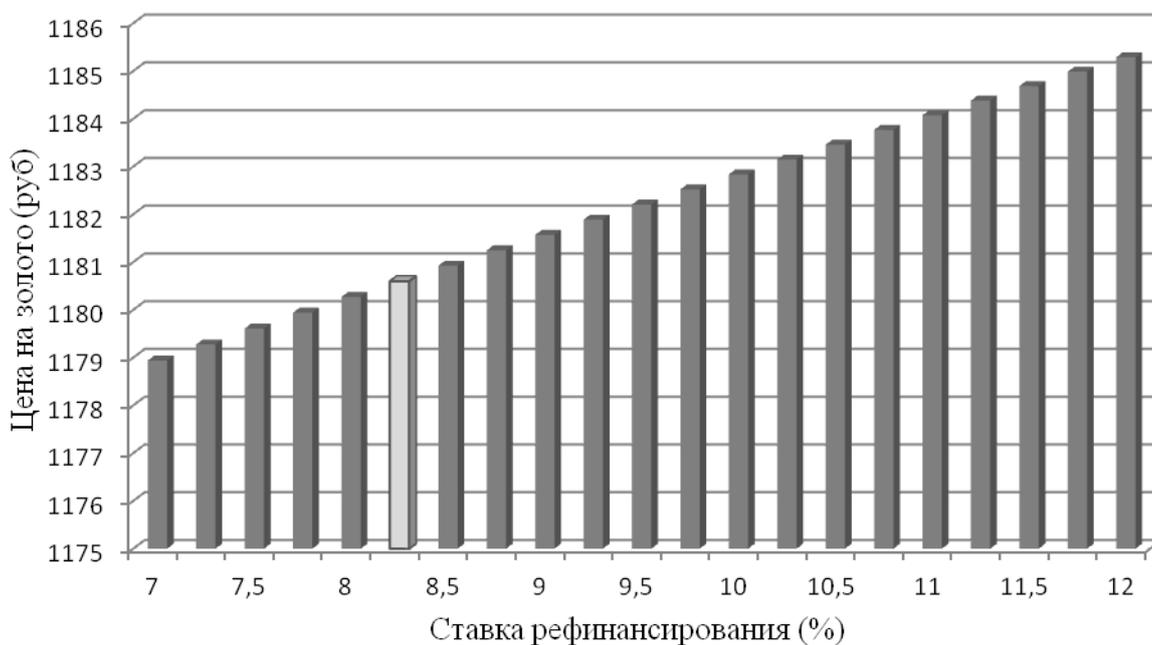


Рисунок 7. Влияние ставки рефинансирования на курс золота

3.5. Исследование влияния уровня инфляции

Результаты исследования влияния уровня инфляции на курс золота приведены на рисунке 8. Сделаем вывод о том, что при повышении уровня инфляции происходит снижение цены на золото.

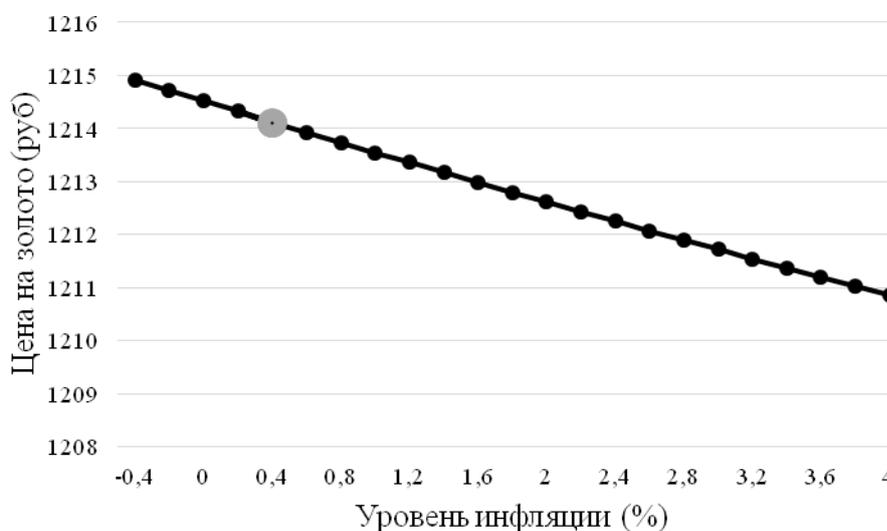


Рисунок 8. Влияние уровня инфляции на курс золота

3.6. Исследование влияния дня недели

Исследование влияния дня недели на курс золота приведено на рисунке 9. Исходя из результатов вычисления нейросети, можно сказать о том, что в начале недели цена на золото ниже, чем в конце недели. Наблюдается плавный рост курса от начала недели к концу недели.

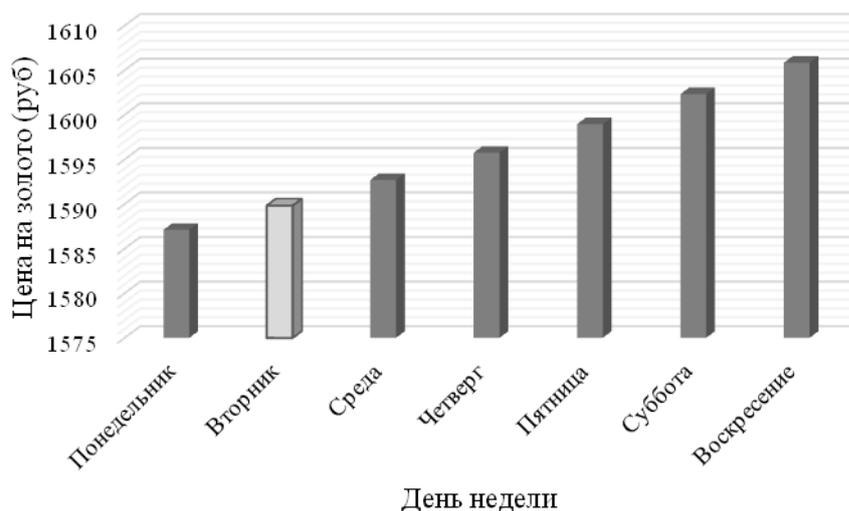


Рисунок 9. Влияние дня недели на курс золота

3.7. Исследование влияния курса доллара

Аналогично проанализируем зависимость курса золота от курса доллара, основываясь на результатах обученной нейросети, показанных на рисунке 10. При повышении курса доллара наблюдается снижение курса золота.

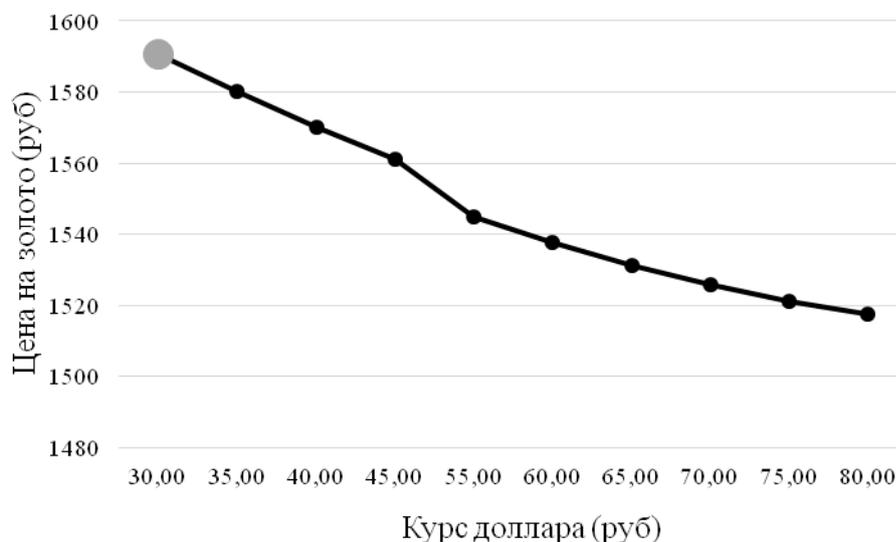


Рисунок 10. Влияние курса доллара на курс золота

3.8. Исследование влияния курса евро

Рассмотрим результаты исследования влияния курса евро на курс золота, приведенные на рисунке 11. Можно сделать вывод о том, что при повышении курса евро наблюдается повышение курса золота.

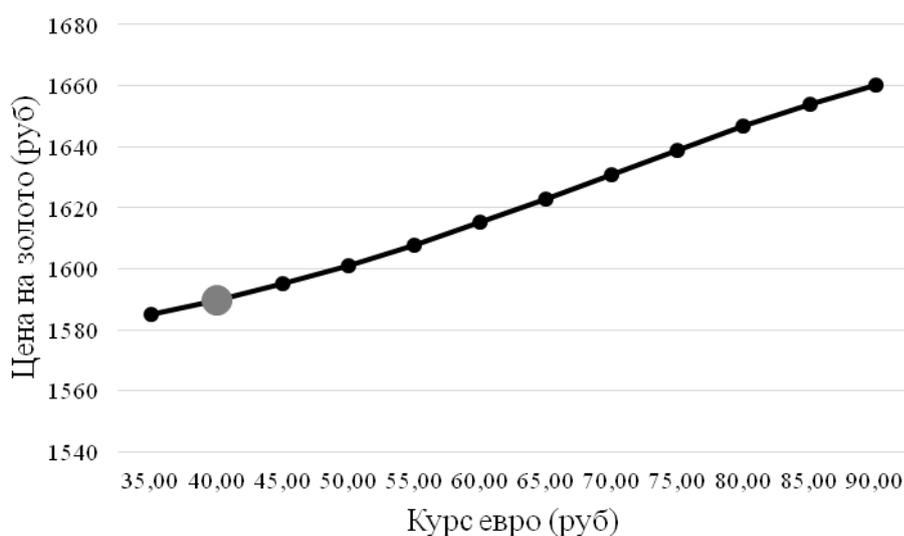


Рисунок 11. Влияние курса евро на курс золота

4. Заключение

Применение метода нейросетевого моделирования позволило создать систему, с высокой точностью оценивающую цену золота на завтрашний день по двенадцати входным параметрам. С помощью вычислительных экспериментов над разработанной математической моделью выявлен ряд закономерностей исследуемой предметной области.

Вычислительные эксперименты позволили установить, что курс золота, в основном, зависит от курсов нефти Brent и WTI. Влияние динамики курса нефти Brent и WTI на курс золото аналогично – при росте динамики цена на золото снижается, при падении динамики курса цена на золото повышается.

Также важную роль играет ставка рефинансирования и уровень инфляции: при увеличении ставки рефинансирования происходит стабильное повышение курса золота, при повышении уровня инфляции наоборот наблюдается снижение цены на золото.

Также на курс золота влияет день недели: в начале недели цена на золото ниже, чем в конце недели. В меньшей степени цена на золото зависит от курсов валют: при повышении курса доллара наблюдается снижение курса золота, при повышении курса евро наблюдается повышение курса золота.

Сделаем некоторые рекомендации исходя из проведенных исследований курсов нефти. При высокой цене нефти Brent и росте курса по сравнению с предыдущим днем, цена на золото снижается. Если цена на нефть Brent низкая и падает по сравнению с предыдущим днем, то цена на золото будет повышаться. Если цена на нефть WTI превышает 70 рублей и при этом динамика курса падает по сравнению со вчера, то цена на золото стабильно повышается. Если цена на нефть WTI не превышает 70 рублей и наблюдается рост динамики курса, то курс золота падает.

Созданная интеллектуальная система прогнозирования котировок на золото может быть использована для оценки курса на завтрашний день, а также для поддержки принятия решений при инвестировании.

Список литературы

1. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56.
2. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
3. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы. Пермь: Пермский университет, 2007. 271с.
4. Данные экономических показателей [Электронный ресурс] / Электронные текстовые данные. Режим доступа: <https://www.cbr.ru> – (Дата обращения: 15.03.2019).

NEURAL NETWORK FOR PREDICTING GOLD PRICES

Maslennikova Daria Y.

Perm State National Research University
614990, Russia, Perm, street Bukireva, 15,
maslennikova-dasha@mail.ru

The subject of the study is the course of gold prices. An economic-mathematical model for predicting gold prices has been developed. The model is based on indicators of economic quotes. From the study of the model, it was found that the most important parameters of price formation are the refinancing rate, the rate of inflation and the price of Brent oil. The least significant are the prices of the euro and the dollar.

Keywords: gold; quotes; euro; dollar; oil; exchange; finance; precious metals; investments; forecast; model; neural network.

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ ПОЛЬЗОВАТЕЛЬСКОГО СПРОСА И ОПТИМИЗАЦИЯ БИЗНЕСА В ОРГАНИЗАЦИЯХ ОБЩЕСТВЕННОГО ПИТАНИЯ

Першин Илья Дмитриевич

Национальный исследовательский университет «Высшая школа экономики – Пермь»

614060, Россия, г. Пермь, бульвар Гагарина, д. 37а, bkmz.59@gmail.com

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 прогнозирования и выявления закономерностей в области общественного питания. Обнаруженные в результате проведенного исследования закономерности не являются противоречивыми, а созданная нейронная сеть используется для оптимизации бизнеса.

Ключевые слова: общественное питание, прогнозирование спроса, рекомендации, нейронная сеть.

В статье [1] описана методика и одна из первых попыток применения математического аппарата искусственных нейронных сетей для оптимизации и повышения эффективности бизнеса. В настоящей работе данная методика применена в сфере общественного питания.

В бизнесе общественного питания, важно уметь прогнозировать и уметь оценивать влияние тех или иных параметров блюда на пользовательский спрос этого блюда. Часто за счёт неумелого подхода к оценке изменений параметров блюда происходит чрезмерная заготовка ингредиентов, из-за чего неиспользованные ингредиенты могут испортиться или же может происходить нехватка ингредиентов, что может привести к потере клиентов. Оба этих сценария ведут к затратам.

На спрос блюда влияют факторы, влияющие на известность организаций общественного питания и на востребованность того или иного блюда [2]. Было решено проводить прогнозирование на периоды длительностью в месяц.

Для того чтобы включить артикул блюда в выборку, и он не оказывал бы влияния на прогноз, артикул был закодирован двоичным кодом. Так как была сделана выгрузка по 42 анализируемым блюдам потребовалось 6 бит для кодировки. Аналогичная операция была проведена с категорией блюда (7 категорий, 3 бита). Так как на популярность заведения влияет маркетинг не

только за прогнозируемый месяц, параметр маркетинга был выбран при помощи скользящего окна продолжительностью в 2 месяца.

- артикул;
- средняя месячная температура;
- категория;
 - 1 – 1-е;
 - 2 – 2-е;
 - 3 – холодная закуска;
 - 4 – горячая закуска;
 - 5 – холодные напитки;
 - 6 – горячие напитки;
 - 7 – разное;
- масса(г)/объём(мл);
- стоимость блюда;
- сезонность ингредиентов;
 - 1 – почти невозможно достать в магазинах;
 - 2 – достать в магазинах возможно, но цена повыше;
 - 3 – без проблем можно достать в магазине;
- затраты на маркетинг в этом месяце;
- затраты на маркетинг в предыдущем месяце.

В результате нейросеть прогнозирует такие параметры как:

- количество заказов на данное блюда в наблюдаемом месяце;
- пиковая нагрузка – максимальное количество блюд, купленных за день в наблюдаемом месяце;
- чистая прибыль организации в наблюдаемый месяц.

При проектировании модели нейронной сети использовалась Формула Арнольда – Колмагорова – Хехт-Нильсена [3, 4].

Обучения проводилось при помощи данных полученных из сети кафе быстрого питания «Шаурма от души».

Наиболее влияющими параметрами являются: сумма, потраченная на маркетинг в этом и предшествующем месяце, поэтому будет построен прогноз для блюд с артикулом 69 (001001) и 7 (000001) с изменением параметров затрат на маркетинг, начиная с 0 заканчивая 100000 с шагом в 2000:

При прогнозе для блюда с артикулом 69 (001001) было выявлено, что у блюд с высоким спросом: количество заказов растёт вплоть до уровня затраты на маркетинг равного 22000, после этого почти не изменяется; пиковая нагрузка растёт вплоть до уровня затраты на маркетинг равного 42000, после этого почти не изменяется; для валовой прибыли было выявлено оптимальное количество денег, затраченных на маркетинг находится в промежутке 2000 – 24000 (см. рис. 1).

При прогнозе для блюда с артикулом 7 (000001) было выявлено, что у блюд с низким спросом: количество заказов и пиковая нагрузка гиперболически растут; для валовой прибыли было выявлено оптимальное

количество денег, затраченных на маркетинг, находится в промежутке 4000 – 26000 (см. рис. 1).

При прогнозе для блюда с артикулом 73 (001101) было выявлено, что у блюд с умеренным спросом: количество заказов и пиковая нагрузка прямо пропорционально сумме потраченной на прибыль; для валовой прибыли было выявлено оптимальное количество денег, затраченных на маркетинг, находится в промежутке 8000 – 18000 (см. рис. 1).

При прогнозе для блюда с артикулом 203 (011111) было выявлено, что у блюд с низким спросом: количество заказов и пиковая нагрузка гиперболически растут; для валовой прибыли было выявлено оптимальное количество денег, затраченных на маркетинг, находится в промежутке 16000 – 36000 (см. рис. 1).

Таким образом было выявлено, что оптимальная сумма, потраченная на маркетинг, находится в промежутке 16000 – 18000.

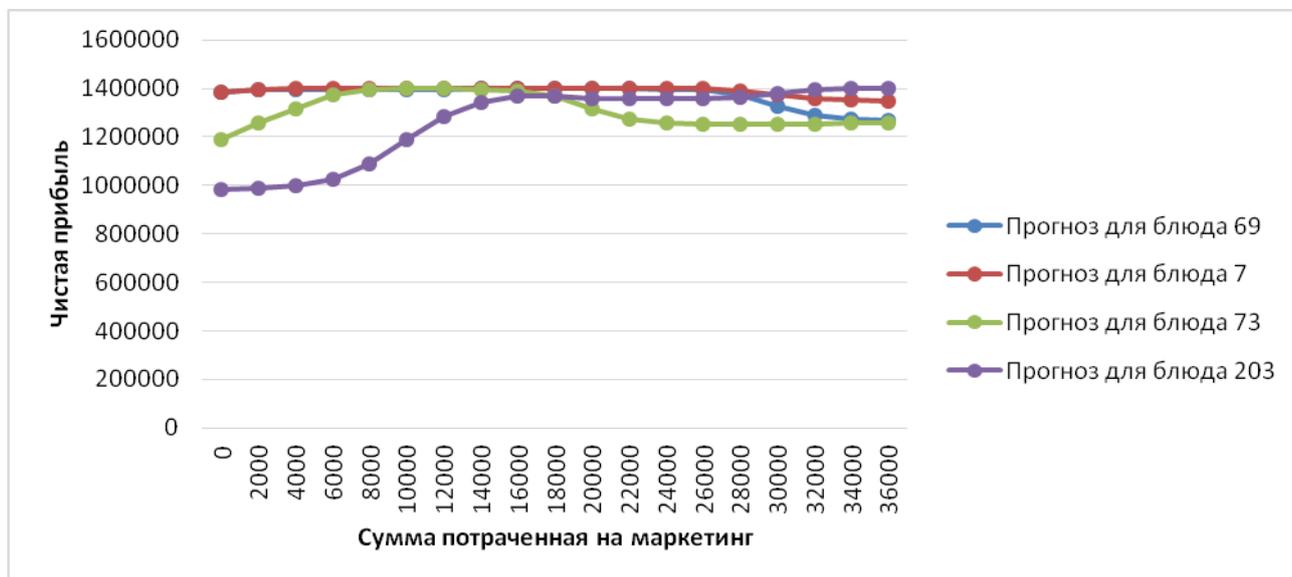


Рисунок 1. Прогноз чистой прибыли, зависящий от маркетинга

Так же параметрами, оказывающими влияние на успешность бизнеса являются: масса и объём блюда, поэтому далее построен прогноз для блюд с артикулом 69 (001001) с изменением параметров массы, начиная с 550 заканчивая 640 с шагом в 5. Было выявлено, что у блюд с высоким спросом количество заказов, пиковая нагрузка и чистая прибыль растут прямо пропорционально массе/объёму (см. рис. 2, 3, 4). Таким образом было решено увеличить массу блюда, для проверки прогноза.

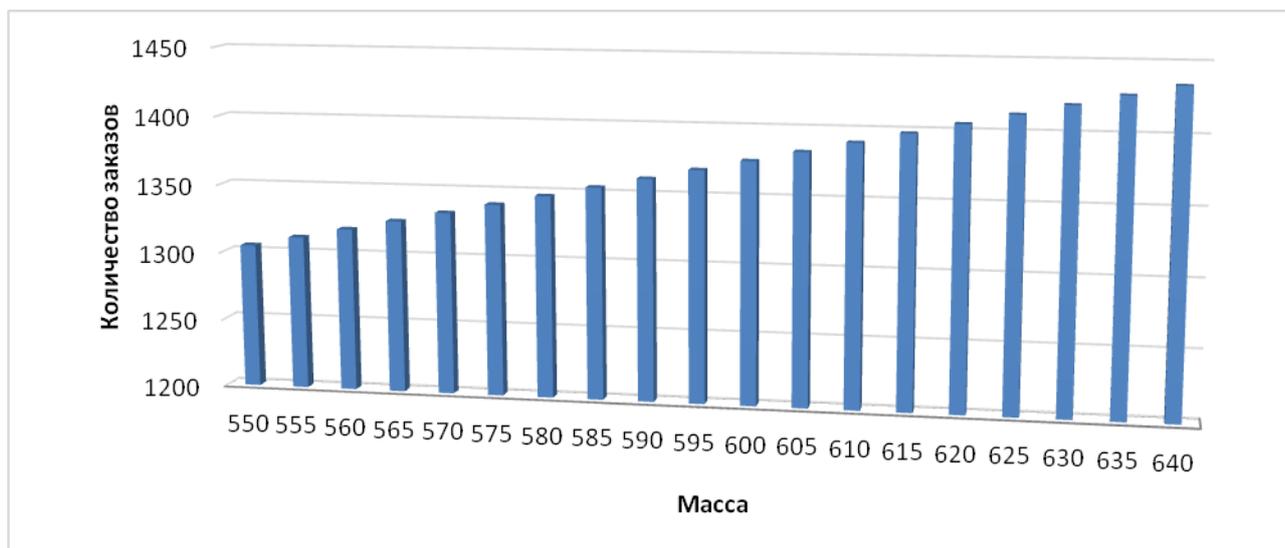


Рисунок 2. Прогноз количества заказов, зависящий от массы

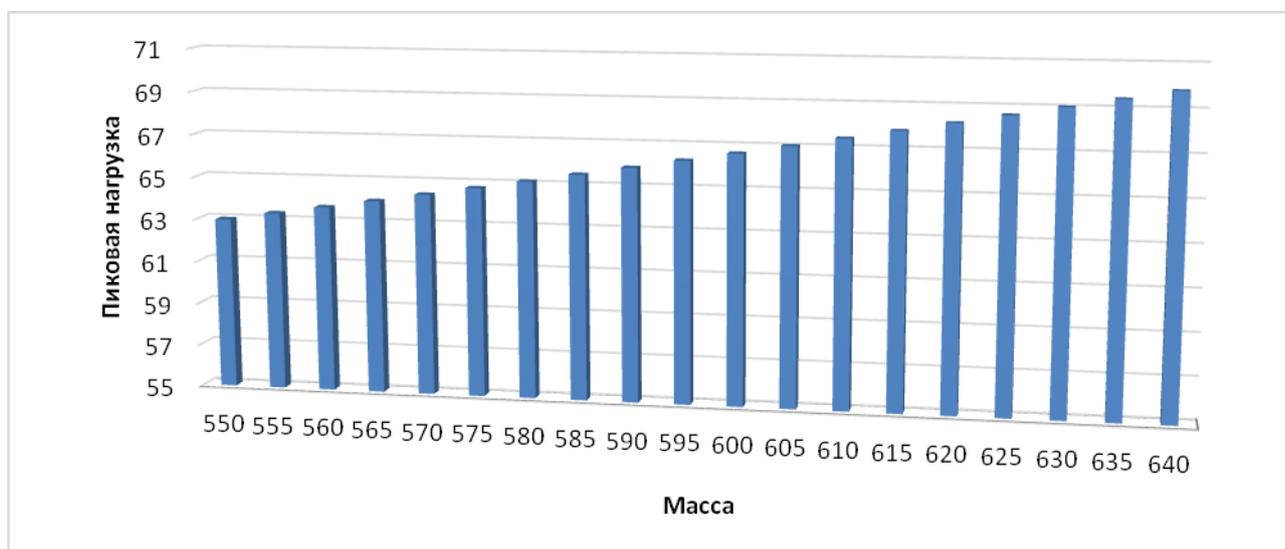


Рисунок 3. Прогноз пиковой нагрузки, зависящий от массы

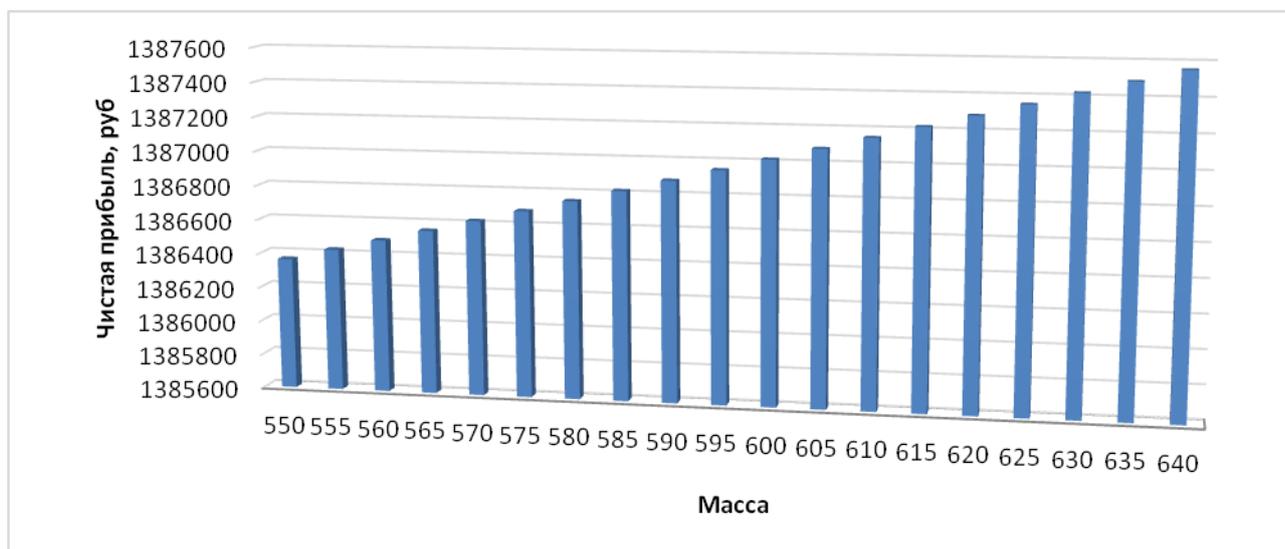


Рисунок 4. Прогноз чистой прибыли, зависящий от массы

Проверка была проведена при помощи выгрузки статистики продаж за месяц, прошедший с момента начала реализации нейросети (Ноябрь 2018). По данным этой выборки было доказано, что нейросеть предсказывает результаты близкие к реальным.

Заключение. Результаты сценарного прогнозирования, выполненного с помощью обученной нейронной сети методом «замораживания» [3, 4] не противоречат имеющимся наблюдениям за реально действующим бизнесом. Созданная нейросетевая система используется в практике ведения бизнеса в качестве поддержки принятия решений по его оптимизации.

Библиографический список

1. Ясницкий Л.Н., Порошина А.М., Тавафиев А.Ф. Нейросетевые технологии как инструмент для прогнозирования успешности предпринимательской деятельности // Российское предпринимательство. 2010. № 4-2. С. 8-13.
2. Сорокин С.В., Грицай А.А., Варанкин Д.А. Прогнозирование потребительского спроса с использованием нейронных сетей и генетической оптимизации. 2012. <http://nauka21vek.ru/archives/33218>
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

Pershin Ilya D.

National Research University Higher School of Economics
614060, Russia, Perm, bulvar Gagarina, d. 37a, bkmz.59@gmail.com

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 prognosis identify patterns in the public catering. The regularities discovered as a result of the research are not contradictory.

Key words: public catering, forecasting user demand, recommendations, neural network.

РАЗРАБОТКА И ПРИМЕНЕНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ОЦЕНКИ И ПРОГНОЗИРОВАНИЯ СТОИМОСТИ МОБИЛЬНЫХ ТЕЛЕФОНОВ НА ПРИМЕРЕ ВТОРИЧНОГО РЫНКА ПЕРМИ

Самойлов Аркадий Юрьевич

Пермский государственный национальный исследовательский университет,
КМБ. 614990, Россия, г. Пермь, ул. Букирева, 15, arksam@list.ru

Разработана экономико-математическая модель массовой оценки мобильных телефонов вторичного рынка города Перми, учитывающая характеристические и эксплуатационные особенности. Из исследования модели было выяснено, что наиболее значимыми параметрами формирования цены являются количество мегапикселей основной камеры и объём встроенной памяти. Наименьшую значимость имеют год выпуска и модель мобильного устройства.

Ключевые слова: мобильные телефоны, оценка стоимости, прогнозирование, нейронная сеть.

Введение

За последние годы прогресс в сфере мобильных технологий существенно вырос. Мобильные телефоны являются основным средством коммуникации людей. Устройства, обладающие большим спектром возможностей, всё чаще заменяют компьютеры и ноутбуки. В настоящее время покупателю на рынке мобильных устройств представлен огромный выбор смартфонов. Но не стоит забывать, что с ростом возможностей мобильного увеличивается и цена устройства. Также за последние годы вырос вторичный рынок мобильных устройств. В продаже на этом рынке оказываются не только использованные товары, но также и абсолютно новые, например, приобретённые в другой стране [1]. Вторичный рынок позволяет приобрести товар, аналогичный товару из магазина, за меньшую стоимость. Помимо этого, рынок позволяет продать бывшее в употреблении устройство.

Практика показывает, что для выполнения оценки стоимости мобильных устройств на вторичном рынке занимает у человека, желающего приобрести мобильный телефон, порядка 1-3 часов. Автоматизация данного процесса позволит значительно сократить потраченное время, учесть значительное количество факторов оценки и снизить уровень субъективности. Проанализировав существующие методы оценки и прогнозирования, в качестве метода для построения модели была выбрана нейронная сеть, которые в свою очередь позволяют учитывать неявные факторы формирования стоимости продукции. Нейронная сеть имитирует деятельность и структуру нервной системы человека. Она способна к

обучению и исправлению ошибок [2]. Нейросеть программируется для решения следующих задач: сортировать, предсказывать и распознавать события и объекты. Многие крупные интернет – магазины используют нейросети для персональных рекомендаций, общение с клиентом с помощью чат-ботов. Сети лежат в основе многих современных систем синтеза речи.

Целью данной работы является исследование и разработка методики создания нейросетевых экономико-математических моделей для оценки и прогнозирования стоимости мобильных устройств на вторичном рынке г. Перми.

Из поставленной цели вытекают следующие задачи:

- 1) предварительный отбор факторов, влияющих на стоимость мобильных телефонов;
- 2) подготовка обучающей выборки для нейронной сети;
- 3) определение оптимального типа и характеристик нейронной сети;
- 4) анализ полученных данных.

Формулировка математической модели и ее тестирование

В качестве входных параметров модели массовой оценки вторичного рынка мобильных телефонов города Перми, были включены факторы, выражающие характеристики мобильного устройства (модель, год выпуска, диагональ экрана, количество ядер процессора, частота работы процессора, объем оперативной и встроенной памяти, количество мегапикселей основной и фронтальной камер, наличие или отсутствие в мобильном устройстве функции NFC, ёмкость аккумулятора) и эксплуатационные особенности устройства (дефекты корпуса, дефекты экрана, было устройство в ремонте или нет, срок эксплуатации мобильного телефона предыдущим владельцем).

Выходная переменная модели d соответствует прогнозируемой цене мобильного устройства, исходя из указанных параметров [3].

Примеры для обучения и тестирования нейронной сети формировались на основе данных полученных с вторичного рынка мобильных телефонов (Avito) г. Перми за 2019 год. Всего было собрано и обработано данных о 120 объектах. Из этого множества 110 примеров использовались для обучения и 10 для тестирования модели. Оптимальная структура нейронной сети представляет собой персептрон без скрытых слоев, имеющий 15 входных и 1 выходной параметр.

Один из результатов тестирования на десяти примерах, представлен на рисунке 1 в графическом виде. Из данного графика видно, что оценка, выполненная нейронной сетью, отличается от фактической стоимости телефонов, незначительно. Стоит отметить, что данные использованные для тестирования нейронной сети, не используются в обучении модели сети. На рисунке 2 представлена диаграмма рассеяния на тестовом множестве.

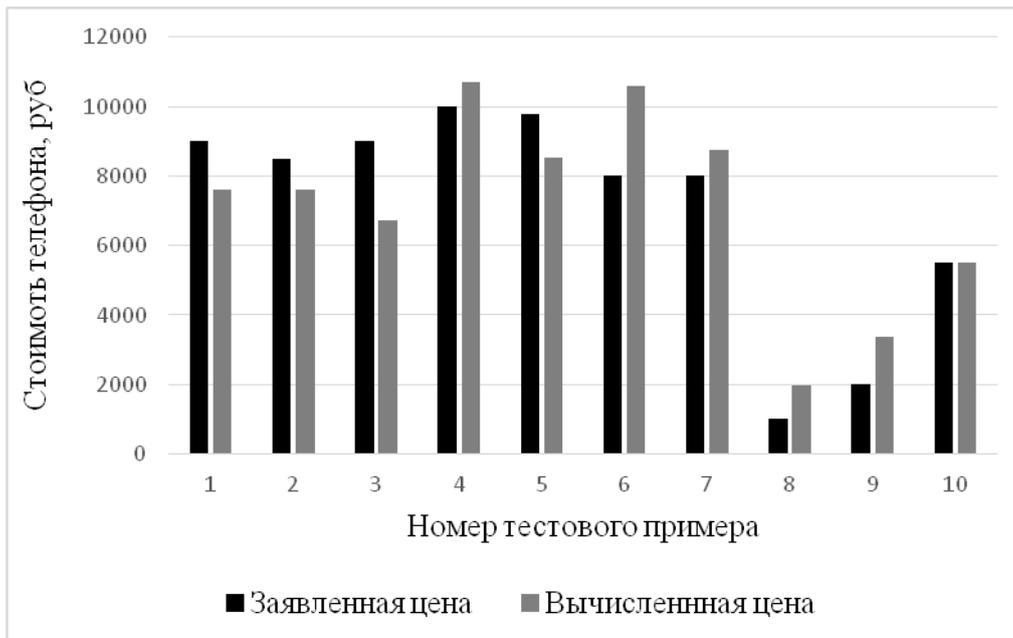


Рисунок 1. Пример тестирования сети: сопоставление заявленных и оцененных с помощью нейросети стоимостей мобильных телефонов

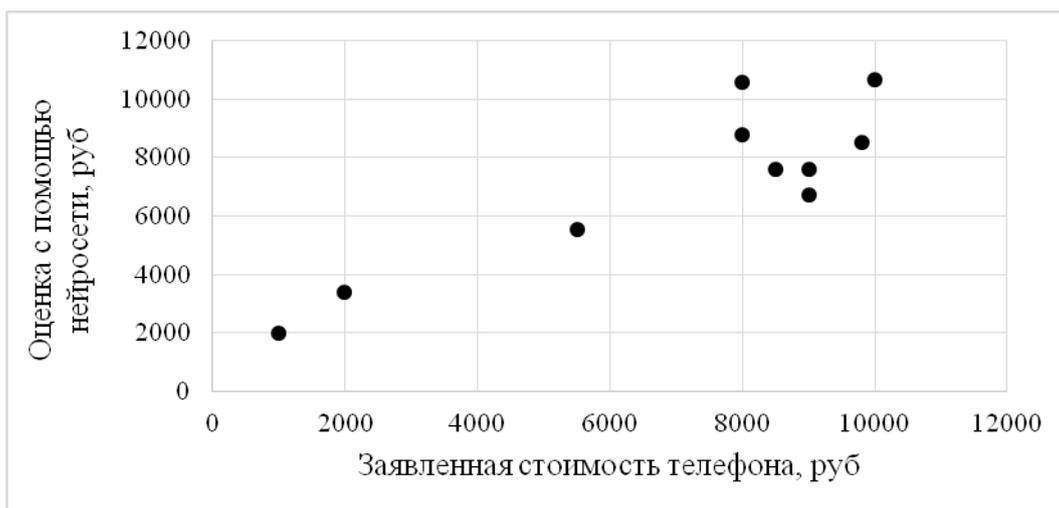


Рисунок 2. Диаграмма рассеяния

Вычислительные эксперименты и обсуждение результатов

После проверки работы нейронной сети на тестовых примерах доказана адекватность построенной математической модели нейронной сети. Следовательно, можно приступать к исследованию. Обученная модель реагирует на изменение входных параметров. Исследуем с помощью данной модели зависимости прогнозируемой величины от входных параметров модели.

В первую очередь необходимо оценить степень значимости её входных параметров на результат моделирования. Исключая поочерёдно параметры и наблюдением за погрешностью тестирования. В результате получаем следующие значения (расположенные в порядке убывания значимости).

- Количество мегапикселей основной камеры 16.8 %

- Объём встроенной памяти 15.1 %
- NFC 11.7 %
- Количество мегапикселей фронтальной камеры 11.1 %
- Был/не был в ремонте 6.3 %
- Срок эксплуатации 6.2 %
- Дефекты экрана 6.1 %
- Дефекты корпуса 6 %
- Ёмкость аккумулятора 5.9 %
- Объём оперативной памяти 5.2 %
- Диагональ экрана 3.1 %
- Частота работы процессора 2.8 %
- Количество ядер процессора 2.3 %
- Год выпуска модели 0.7 %
- Модель 0.7 %

Для более удобного представления рассмотрим полученные данные на рисунке 3. Из представленной гистограммы видно, что наиболее важным параметром при формировании цены мобильного телефона является количество мегапикселей основной камеры устройства и достигает почти 17 %. Наименее важными характеристиками являются модель и её год выпуска, значимость которых не достигает и 1 %. К особенности можно отнести практически одинаковую значимость (порядка 6 %) у входных параметров, относящихся к эксплуатационным особенностям устройства, таким как дефекты экрана и корпуса, срок использования предыдущим владельцем и находилось устройство в ремонте или нет.

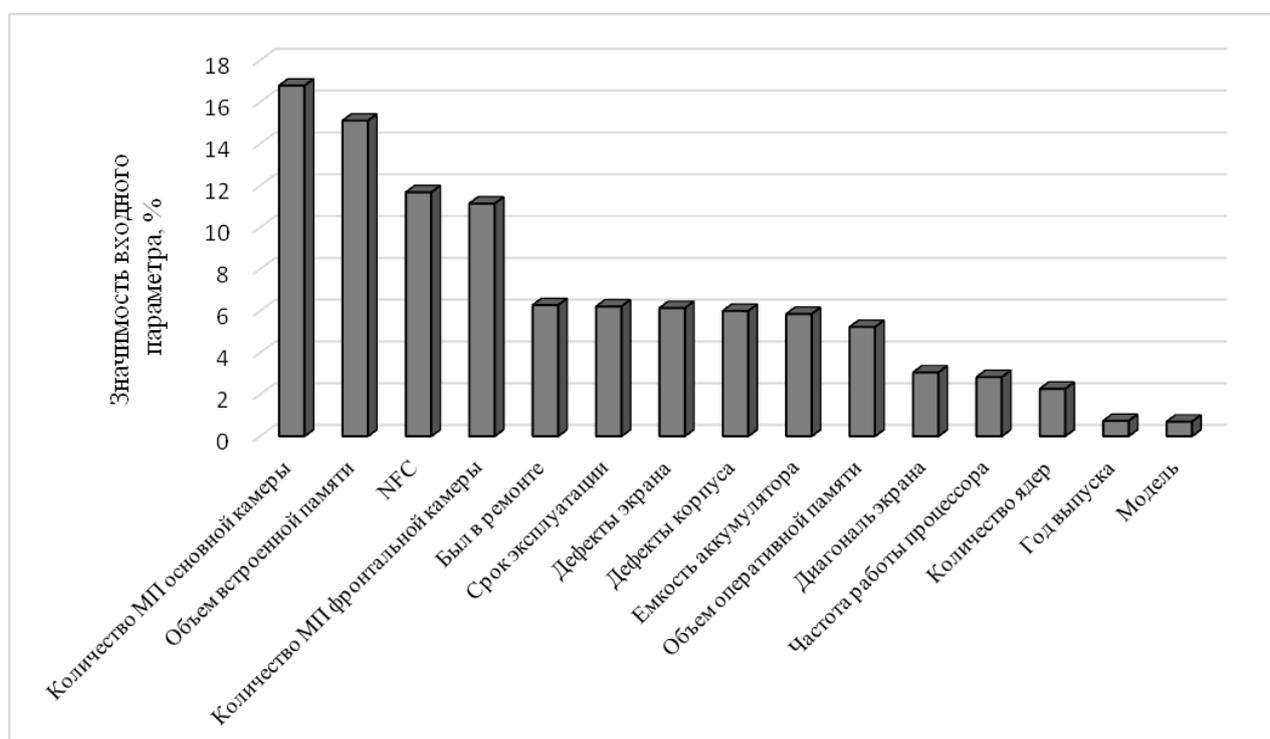


Рисунок 3. Значимость входных параметров, вычисленная с помощью нейронной сети

Рассмотрим наиболее важные параметры в индивидуально.

Количество мегапикселей основной камеры. Исходя из заданных значений мегапикселей камеры, с помощью смоделированной нейронной сети получены результаты, представленные в таблице 1 и на рисунке 4. В данных экспериментах, входной параметр – количество мегапикселей основной камеры варьировался, принимая значения 5, 12, 13, 16 и 20. Остальные значения входных параметров остаются фиксированными. Эксперимент проводился для трёх случайно выбранных моделей мобильных телефонов. Видно, что компьютерные эксперименты выявили практически линейную зависимость между параметрами и тенденция роста цены с увеличением мегапикселей сохраняется при изменении моделей мобильных устройств, что говорит об адекватности построенной модели нейронной сети.

Таблица 1 – Формирование цены при изменении количества Мп основной камеры

Мп	Телефон 1, руб	Телефон 2, руб	Телефон 3, руб
5	7665.9	6990.6	10169.4
12	8005.7	7301.3	10601.7
13	8055.4	7346.8	10664.6
16	8206.2	7485.0	10854.8
20	8411.3	7673.1	11112.3

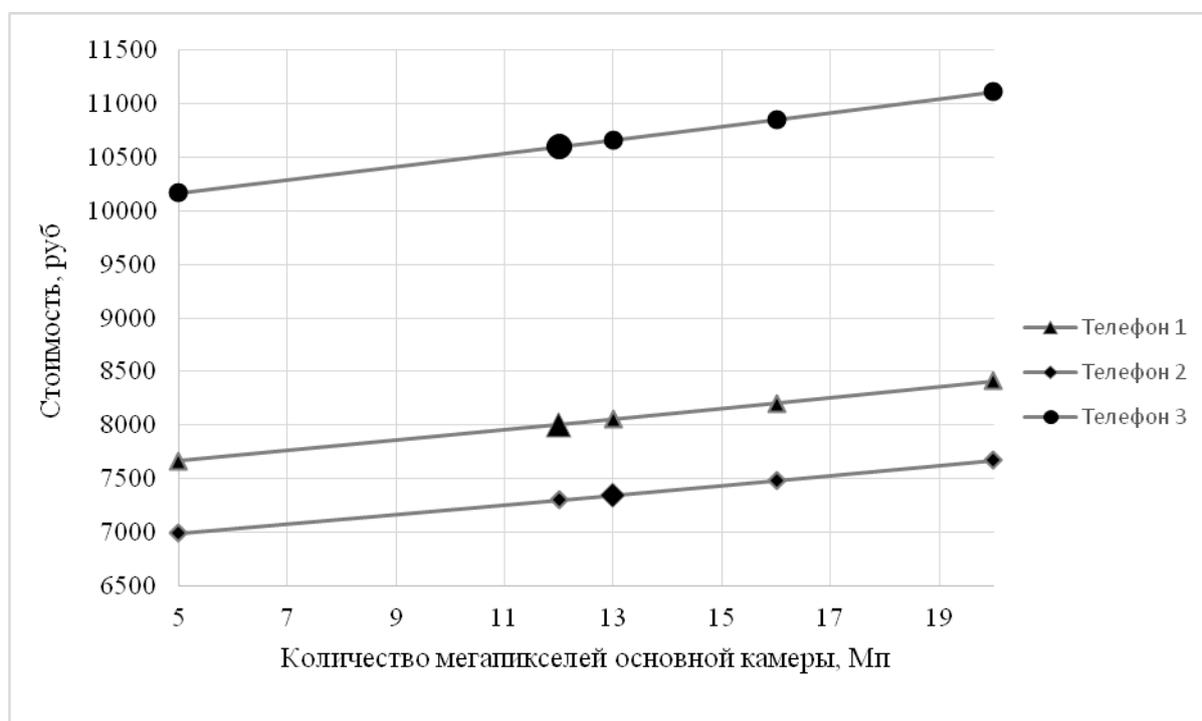


Рисунок 4. Зависимость стоимости мобильного телефона от количества мегапикселей основной камеры

Аналогичным образом рассмотрим следующий параметр – *объём встроенной памяти мобильного телефона*. Стоит отметить, что в отличие от выше описанного входного параметра, из рисунка 5 видно, что линейная

зависимость между параметрами отсутствует. Также заметим, что при изменении объёма памяти с 6 до 16 Гб, цена изменяется лишь на 10 %, тогда как разница в цене между 64 и 128 Гб достигает 70 %.

Таблица 2 – Формирование цены при изменении количества Мп основной камеры

Память, Гб	Телефон 1, руб	Телефон 2, руб	Телефон 3, руб
6	6153.9645	5617.7784	8246.5443
16	6808.2336	6209.9509	9115.5836
32	8005.7403	7301.3136	10664.5767
64	10982.7058	10057.2719	14297.4203
128	18821.3432	17620.0958	22595.3059

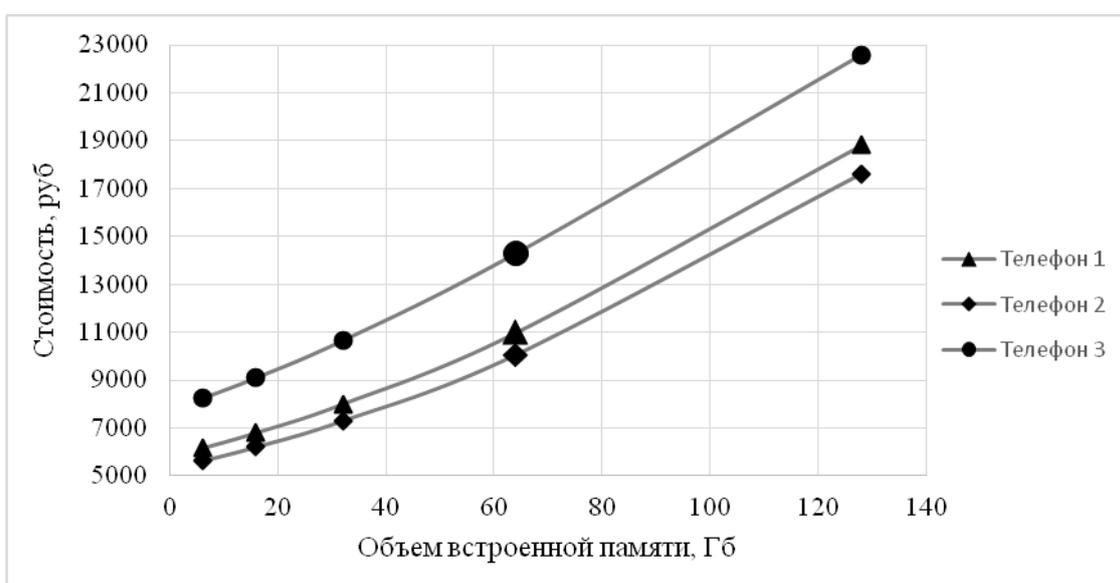


Рисунок 5. Зависимость стоимости мобильного телефона от объёма встроенной памяти

Следующий параметр — это *наличие или отсутствие функции NFC*. Технология беспроводной передачи данных на малом расстоянии (как правило, не превышающая 10 см). Из полученных результатов видно, что наличие в телефоне NFC незначительно увеличивает стоимость мобильного телефона. В среднем наличие этой функции даёт прирост цены на 10 %.

Таблица 3 – Формирование цены при наличии или отсутствии NFC

Пример	Нет NFC, руб	Есть NFC, руб
1	8005.7403	8763.0429
2	6665.8105	7301.3136
3	9770.7207	10664.5767
4	7918.1893	8668.015

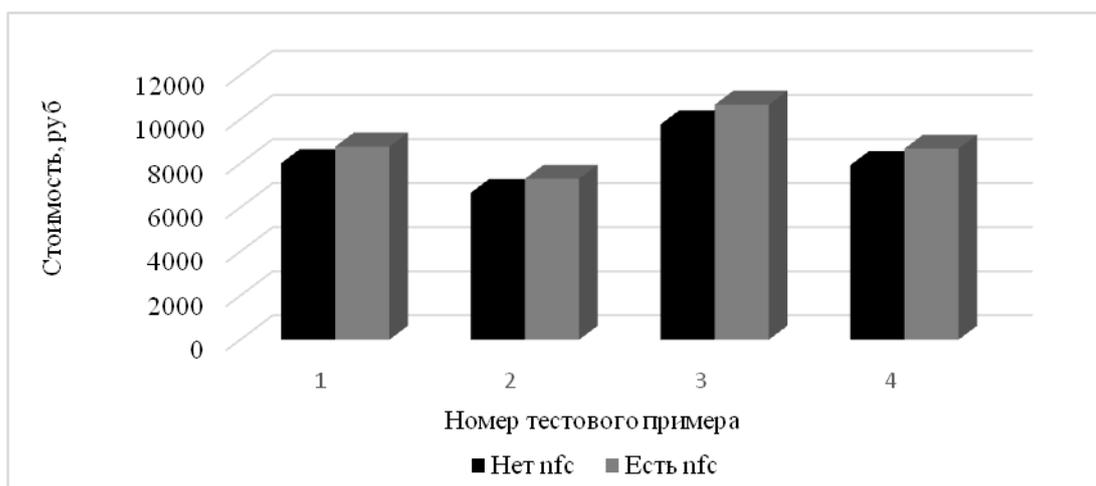


Рисунок 6. Зависимость стоимости мобильного телефона от наличия или отсутствия NFC

Рассмотрим параметры, принадлежащие эксплуатационным особенностям мобильного телефона. В компьютерных экспериментах выясним, как изменяется цена при наличии каких-либо повреждений мобильного телефона, а также при комбинации дефектов. В таблице 4 представлены получившиеся значения. Например, строка «Ремонт, корпус» в графе повреждения означает, что телефон находился в ремонте (по каким-либо причинам) и имеет дефект корпуса (с которым и продаётся мобильный телефон). Заметим, что наличие одного из повреждений: был в ремонте, повреждение экрана или дефект корпуса, уменьшает цену устройства примерно на 35 %. Если телефон имеет две эксплуатационные особенности, например, дефект корпуса и экрана, то стоимость телефона сокращается на 55 % по сравнению с мобильным устройством без особенностей. Если телефон обладает тремя рассмотренными особенностями, то разница в цене достигает 70 %.

Таблица 4 – Формирование цены при наличии повреждений устройства

Повреждения	Телефон 1, руб	Телефон 2, руб	Телефон 3, руб
Нет	8005.7	7301.3	10664.6
Ремонт	5072.8	4645.5	6773.8
Экран	5177.2	4739.1	6918.0
Корпус	5513.9	5041.3	7380.3
Ремонт, экран	3411.5	3166.6	4416.9
Ремонт, корпус	3601.9	3335.2	4693.0
Экран, корпус	3667.5	3393.3	4787.8
Ремонт, экран, корпус	2580.9	2434.0	3193.7

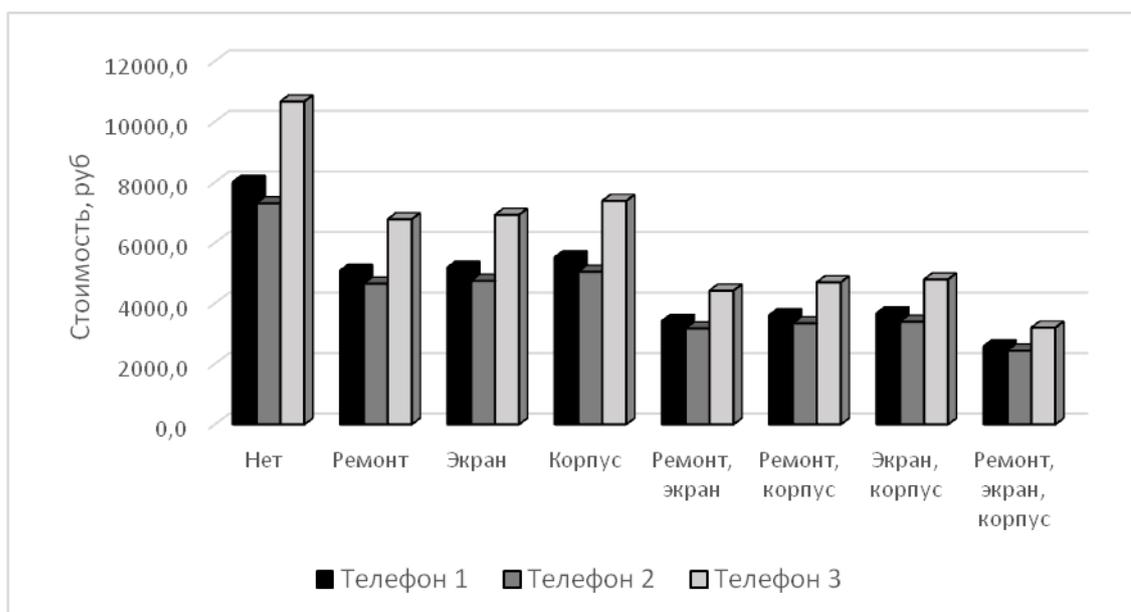


Рисунок 7. Зависимость стоимости мобильного телефона от повреждения мобильного телефона

Заключение

Предложена модель нейронной сети с 15 входными и 1 выходным параметрами способная прогнозировать стоимость мобильных телефонов на примере вторичного рынка г. Пермь. Данная модель учитывает характеристические и эксплуатационные особенности телефонов. С помощью модели было исследовано влияние характеристик и особенностей эксплуатации на стоимость устройства. В частности, было показано, что наиболее значимыми параметрами при прогнозировании цены являются количество мегапикселей основной камеры и объём встроенной памяти. Наименее важными факторами при формировании цены являются модель и год выпуска устройства. Наличие в телефоне функции NFC увеличивает стоимость всего на 10 %.

Предложенная модель может использоваться для прогнозирования объективной цены мобильного устройства при желании купить или продать устройство на вторичном рынке. Модель нейронной сети позволяет значительно сократить затраченное время покупателя/продавца на поиск и анализ информации о стоимости мобильных телефонов.

Библиографический список

1. Воронина Ю. Россияне переходят на смартфоны из секонд-хенда // Российская газета – Федеральный выпуск. 2016. N 7024 (156)
2. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. 176 с.
3. 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.

**DEVELOPMENT AND APPLICATION OF THE NEURAL NETWORK
MODEL OF EVALUATION AND FORECASTING THE COST OF
MOBILE TELEPHONES ON THE EXAMPLE OF THE SECONDARY
MARKET OF PERM**

Samoilov Arkady Y.

Perm State National Research University
614990, Russia, Moscow Perm, ul. Bukireva, 15, arksam@list.ru

Developed economic – mathematical model of mass valuation of mobile phones of Perm city secondary market, taking into account the characteristics and operational features. Model study, it was found that the most significant pricing parameters are the number of megapixel main camera and the amount of internal memory. The lowest relevance are release year and model of your mobile device.

Keywords: mobile phones, cost estimation, forecasting, neural network.

АВТОМАТИЧЕСКИЙ КОНТРОЛЬ УРОВНЯ ОКАЗАНИЯ УСЛУГ ПРОДАВЦОМ-КОНСУЛЬТАНТОМ

*Ульев Андрей Дмитриевич, Розалиев Владимир Леонидович,
Орлова Юлия Александровна, Алексеев Алексей Владимирович*

Волгоградский государственный технический университет,
400005, Россия, г. Волгоград, проспект им. В.И. Ленина, д. 28,
vladimir.rozaliev@gmail.com

В статье представлен метод распознавания продавцов-консультантов на основе каскада нейросетей и уточняющих алгоритмов, а также рассмотрены методы контроля поведения продавца-консультанта и анализа его взаимодействия с покупателем. Проведен краткий обзор систем с похожими функциональными характеристиками. Представлено описание предлагаемой методики, показаны полученные результаты и пути улучшения.

Ключевые слова: нейронная сеть, искусственный интеллект, распознавание позы человека, мониторинг поведения.

Современная эпоха характеризуется переходом от экономики производителей к экономике потребителей. В условиях ужесточения конкуренции в сфере торговли и оказания услуг особое значение приобретают клиентоориентированные сервисы.

Обеспечение должного качества оказания услуг становится основной задачей рыночной стратегии развития бизнеса. Для повышения качества обслуживания предлагается разработка и внедрение программного продукта для контроля за деятельностью продавцов консультантов посредством анализа их работы с использованием оборудования для видеофиксации.

Работа программного продукта основана на алгоритме Pose Estimator [1] [2], который позволяет определить позу человека, уточняющих алгоритмах, а также вспомогательных нейросетях, которые помогают идентифицировать продавца-консультанта, а также определить качество оказываемых им услуг.

Предлагаемая методика. Для решения поставленной проблемы мы предлагаем использовать каскад из двух нейросетей:

- Быстрая нейронная сеть FastPoseEstimator, обученная на архитектуре mobilenet.
- Алгоритм стабилизации «ключевых» точек, позволяющий определить те точки туловища, которые не смогла распознать нейросеть.
- Нейронная сеть для определения характера поведения продавца-консультанта в магазине.

Первый этап, использование нейросети «Fast Pose Estimation». Основной задачей нейронной сети является установление позы человека путем непараметрического представления, названного разработчиками Part Affinity Fields (PAFs), для дальнейшего определения местоположения униформы продавца консультанта (фирменная футболка, кепка и т.д.).

Входными данными для алгоритма «PoseEstimator» является графическое изображение продавца-консультанта, на выходе – изображение с выделенными частями тела человека.

Результат работы данной нейросети Вы можете увидеть на рисунке 1.



Рисунок 1. Результат работы нейросети Pose Estimator

Второй этап работы, алгоритм стабилизации «ключевых» точек туловища человека. Скелет строится от начальной точки, находящейся под горлом, далее распознаются глаза, плечи и таз. Таким образом ключевой для построения является точка под шеей, далее будем называть ее начальной.

Необходимо определить доминирующий цвет футболки продавца. Для повышения качества работы предлагается следующий алгоритм нахождения недостающих «ключевых» точек, основанный на информации о структуре строения человека. Рассмотрим один из вариантов нахождения недостающей «ключевой» точки туловища.

Если было распознано только одно плечо человека, второе плечо можно достроить путём отложения равного отрезка от проекции начальной точки на нормаль точки найденного плеча в сторону не найденного плеча размером, равным размеру расстояния от проекции точки на нормаль точки найденного плеча до точки найденного плеча.

Таким образом, используя информацию о структуре строения человека возможно определить примерное расположение недостающих точек плечей, точек таза.

Третий этап, определение доминантного цвета на участке униформы. Основной задачей данного этапа является установление доминантного цвета на участке униформы человека для определения его в группу продавцов-

консультантов или группу покупателей. В рамках данного алгоритма на вход поступает изображение от «Pose Estimator» с вершинами частей тела человека. На основе которых происходит выделение необходимого участка одежды человека. Пример представлен на рисунке 2 [2] [3] [4].



Рисунок 2. Выделение участка одежды продавца-консультанта

Для реализации определения доминантного цвета в установленной области предлагается использовать метод k -средних.

Обучение внешнему виду продавцов консультантов. При отнесении человека к группе продавцов или покупателей необходимо учесть условия разности освещенности помещения в разное время суток. Таким образом распознанный цвет формы может варьироваться.

Для решения этой проблемы необходимо обучить систему всем возможным цветам, которые могут быть «считаны» с одежды продавца-консультанта.

Оператор программного продукта в начале работы с программой должен запустить режим обучения, с помощью которого устанавливаются преобладающие цвета униформы случайно движущегося по магазину продавца-консультанта.

На основе преобладающих цветов одежды продавца формируется «средний доминирующий цвет», который является опорной точкой в формировании цветового диапазона для отнесения к группе продавцов-консультантов.

Обзор аналогов. Стоит отметить, что готовых программных продуктов, позволяющих решить рассмотренную в этой статье проблему нет. Аналогичные программные продукты выполняют лишь часть задач.

В качестве аналогов может выступить работа с GPS-трекерами. Данные системы работают на основе определения геолокации. Для реализации такого решения необходимо каждого сотрудника оснастить отдельным GPS трекером, данные с которых с некоторым интервалом времени будут поступать на сервер. Однако, указанное выше решение имеет ряд минусов:

1. Решение экономически затратное, поскольку необходимо закупить GPS трекеры для всего персонала.

2. Нельзя исключать ситуацию, при которой продавец может отдать свой GPS-трекер напарнику, чтобы обмануть систему.

3. Такое решение не является универсальным. При идентификации продавцов-консультантов через камеру возможно расширить функционал, определять уровень и время взаимодействия продавца с покупателем и многое другое.

Также к аналогам относятся системы подсчета количества посетителей на видеопотоке. Данные системы также имеют ряд недостатков, главным из которых является невозможность определения продавцов-консультантов и качества оказываемых ими услуг.

Заключение. С целью усовершенствования технологического процесса детектирования продавца консультанта возможна разработка дополнительного функционала.

Для более точного определения продавца консультанта возможен анализ сразу нескольких элементов униформы (например, желтая футболка и черные штаны).

Также возможно выявить дополнительные факторы, позволяющие определить качество работы продавца магазина, такие как представление товара покупателям, не остановившихся у стеллажа с товаром, а проходящим мимо.

В данный момент ведется работа по идентификации продавца-консультанта на основе его антропометрических данных, цвета волос, характера походки.

Таким образом, разработанный программный продукт позволит качественно улучшить работу продавца-консультанта и, как следствие, приведет к улучшению клиентоориентированности бизнеса. На рисунке 3 представлен пример работы программы.

Эта работа является продолжением работы [5] [6], где были рассмотрены особенности и возможности определения пост-смыслового смыслового отличительного признака.

Благодарности. Работа выполнена при частичной поддержке РФФИ (гранты 18-07-00220, 18-47-342002, 18-47-340006, 19-07-00020).

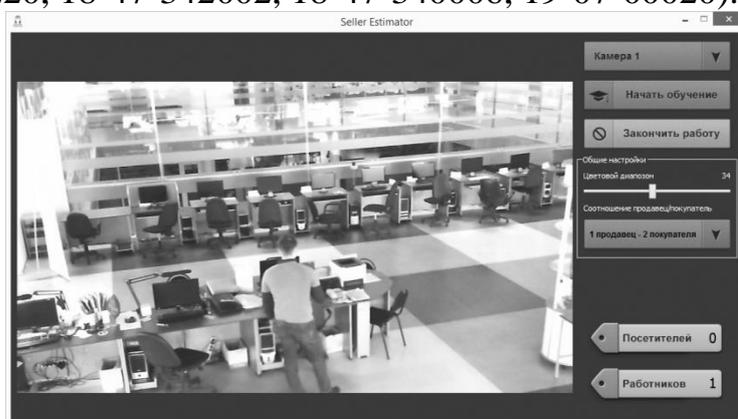


Рисунок 3. Пример работы программы при распознавании сотрудника магазина

Библиографический список

1. Cao, Z., Simon, T., Wei, S.-E., & Sheikh, Y. (2016). Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields. CoRR, abs/1611.08050. Retrieved from <http://arxiv.org/abs/1611.08050>
2. Zhe Cao (2017). Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields // Robotics Institute Carnegie Mellon University. Pittsburgh, Pennsylvania. Retrieved from <http://www.ri.cmu.edu/wp-content/uploads/2017/04/thesis.pdf>
3. U. Iqbal and J. Gall (2016). Multi-person pose estimation with local joint-to-person associations. In ECCV Workshops, Crowd Understanding. Retrieved from <https://arxiv.org/pdf/1608.08526.pdf>
4. E. Insafutdinov, L. Pishchulin, B. Andres, M. Andriluka, and B. Schiele (2016). Deepcrut: A deeper, stronger, and faster multi-person pose estimation model. Retrieved from <https://arxiv.org/pdf/1605.03170.pdf>
5. Розалиев В.Л., Орлова Ю.А. Определение движений и поз для идентификации эмоциональных реакций человека. [Recognition of gesture and poses for the definition of human emotions]. 11-ая Международная конференция по распознаванию образов и анализу изображений: новые информационные технологии (PRIA-11-2013), Самара, 23-28 сентября 2013 г.: Труды конференции [11th International Conference of Pattern Recognition and Image Analysis: New Information Technologies (PRIA11-2013), Samara, September 23-28, 2013 : Conference Proceedings] 2013, №2, стр. 713-716
6. Бобков А.С., Розалиев В.Л. Фазификация данных, описывающих движение человека. [Fuzzification of data describing the movement of a person]. Открытые семантические технологии для проектирования интеллектуальных систем (OSTIS-2011): матер. стазher. nauchno-tekhnich. konf. (Minsk, 10-12 fevralya 2011 g.) [Open semantic technologies for the design of intelligent systems (OSTIS-2011) : mater. intern. scientifictechn. conf. (Minsk, Feb. 10-12. 2011)], 2011, стр. 483-486

AUTOMATIC LEVEL CONTROL THE PROVISION OF SERVICES BY THE SELLER-CONSULTANT

Ulyev Andrey Dmitrievich, Rozaliev Vladimir Leonidovich,
Orlova Yulia Aleksandrovna, Alexeev Alexey Vladimirovich,
Volgograd State Technical University, 400005, Russia,
Volgograd, prospect them. V. I. Lenin, d. 28, vladimir.rozaliev@gmail.com

The article presents the method recognition of sales consultants on the basis of a neural network to determine the posture and clarifying algorithms, also methods of monitoring the behavior of the seller-consultant and analysis of its interaction with the buyer. A brief review of the analog systems is given. The description of the proposed method is presented, the obtained results and ways of improvement are shown.

Key words: neural network, artificial intelligence, human posture recognition, behavior monitoring.

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ПРОГНОЗИРОВАНИЯ ПРОДАЖ ВИДЕОИГР В ПЕРВУЮ НЕДЕЛЮ ПОСЛЕ ВЫПУСКА

Юрков Михаил Александрович

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, mishayur1997@mail.ru

Представлено описание разработки нейросетевой системы для прогнозирования продаж видеоигр в первую неделю после выхода. Система позволяет спрогнозировать продажи видеоигры по тринадцати входным параметрам, таким как размер бюджета, страна разработчика игры, год выпуска, возрастное ограничение и т.д. Также система обладает возможностью выявления тенденции изменения количества продаж в зависимости от входных параметров.

Ключевые слова: искусственный интеллект, нейросетевые технологии, прогнозирование, оценка продаж, видеоигры, компьютерные игры.

В настоящее время видеоигры вносят значительный вклад в мировую экономику ввиду большого успеха продаж основных игровых систем и игр вроде Call of Duty: Black Ops, заработавшая в течение первых 5 дней продаж более \$600 млн, что стало мировым рекордом пятидневных продаж среди фильмов, книг и компьютерных игр.

На начальном этапе существования компьютерных игр стоимость разработки была минимальной, поэтому это был прибыльный бизнес. Игры разрабатывались единственным программистом или небольшой группой в течении нескольких месяцев, иногда года.

В настоящее время стоимость разработки может достигать десятков миллионов долларов. По мере развития компьютерных технологий, увеличивался и размер групп разработчиков, так как увеличивающаяся сложность графики и программирования в целом требовала все большего штата специалистов. Большинство профессионально выполненных видеоигр разрабатываются в течение нескольких лет.

Прогнозирование продаж игр в первую неделю, исходя из хода разработки – это очень актуальная тема, сейчас выходит множество видеоигр, и по первой неделе продаж, как правило, можно определить, окупится игра или нет. Данная нейросетевая система может помочь разработчикам понять, какую игру лучше разрабатывать, чтобы увеличить продажи.

При поиске подобных работ были найдены две аналогичные работы по кассовым сборам кинофильмов [1, 2]. Однако в этих работах рассматривается кино индустрия, а также высчитывается общая прибыль фильмов. Мы же

рассматриваем количество проданных копий видеоигры за первую неделю после выпуска, что отличается от общей прибыли видеоигры.

Для проектирования системы необходимо определить входные параметры, с помощью которых будут прогнозироваться продажи видеоигры. После анализа доступной информации о видеоиграх, были определены критерии, влияющие на продажи видеоигры: X1 – страна, X2 – Бюджет игры, X3 – Год выпуска, X4 – Возрастное ограничение, X5 – Наличие мультплеера, X6 – Открытый мир, X7 – шутер, X8 – Экшн, X9 – РПГ (ролевая игра), X10 – ФПС (шутер от первого лица), X11 – Приключение, X12 – Стелс, X13 – Является ли игра продолжением серии. Выходной параметр D – Продажи видеоигры в течении первой недели после выхода.

Для обучения нейронной сети было сформировано множество примеров, основанных на реальных данных о продажах видеоигр. Множество формировалось на основании данных о играх, собранных с различных сайтов. С сайта Wikipedia [3] была взята информация о возрастном ограничении, жанре, дате выпуска, стране разработчика и является ли игра продолжением серии. Данные о продажах в первую неделю после выхода брались с сайта о продажах видеоигр [4]. На этом сайте есть данные об играх начиная с 2005 года, поэтому игры в множестве взяты начиная с 2005 года. Данные о бюджетах игр брались с двух статей о бюджете видеоигр [5, 6].

Обучающее множество примеров состоит из 66 примеров. В него входят видеоигры разных жанров, с различными годами выпуска и бюджетами. Обучающее множество имеет малый размер, так как бюджеты большинства игр не раскрываются компаниями, а этот показатель очень важен для прогнозов.

Проектирование нейронной сети было осуществлено с помощью библиотеки «Keras» [7] для Python. Была определена модель персептрона с тринадцатью входными параметрами, одним выходным параметром и одним скрытым слоем с тремя нейронами.

Также проектирование нейронной сети проводилось в программе «Нейросимулятор 5» [8] по методике [9]. Структура персептрона – тринадцать входных параметров, один выходной и один скрытый слой с тремя нейронами.

Для проверки результатов обученной нейросети было использовано тестирующее множество, состоящее из 8 примеров. В результате тестирования было обнаружено, что средняя относительная ошибка при использовании библиотеки «Keras» была значительно меньше, чем при использовании «Нейросимулятора 5». Средняя относительная ошибка при использовании «Keras» равна 42%, а при использовании «Нейросимулятора 5» 69%.

Исходя из результатов тестирования, в дальнейшем будет использоваться модель спроектированная в «Keras».

График, отображающий разницу между спрогнозированной стоимостью и действительной, представлен на рисунке 1. Средне-относительная ошибка работы обученной нейронной сети на тестируемом множестве составляет 42%, это можно назвать неплохим показателем, учитывая малый размер обучающего множества.

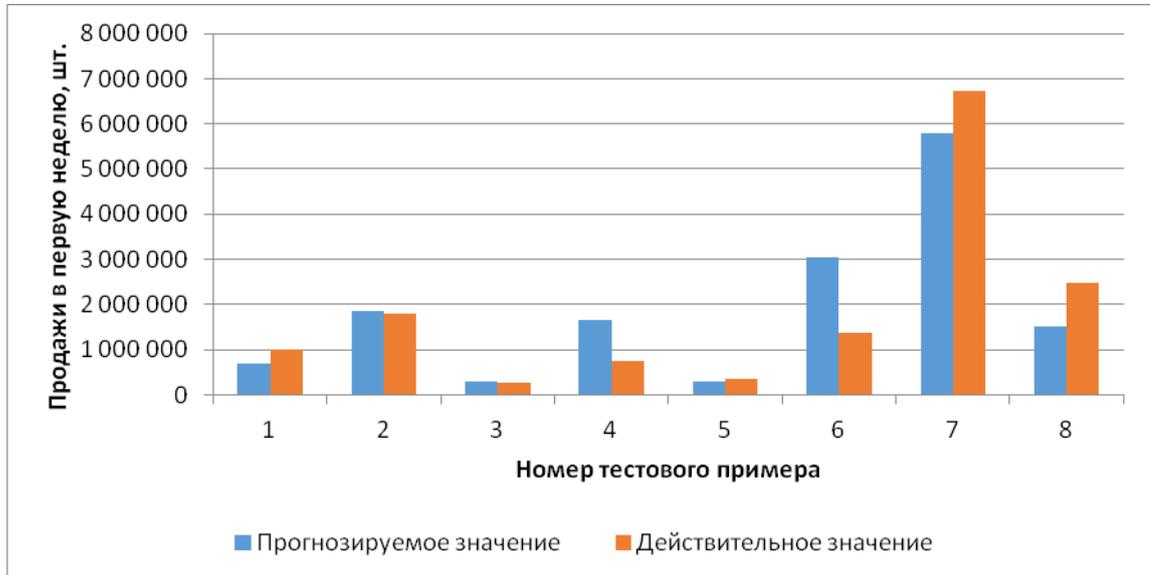


Рисунок 1. Результаты тестирования нейронной сети

После проверки работы сети на тестовых примерах, и проверена адекватность работы построенной нейросетевой модели, приступаем к её анализу.

Используя «Нейросимулятор 5», получаем данные о значимости параметров (рис. 2).

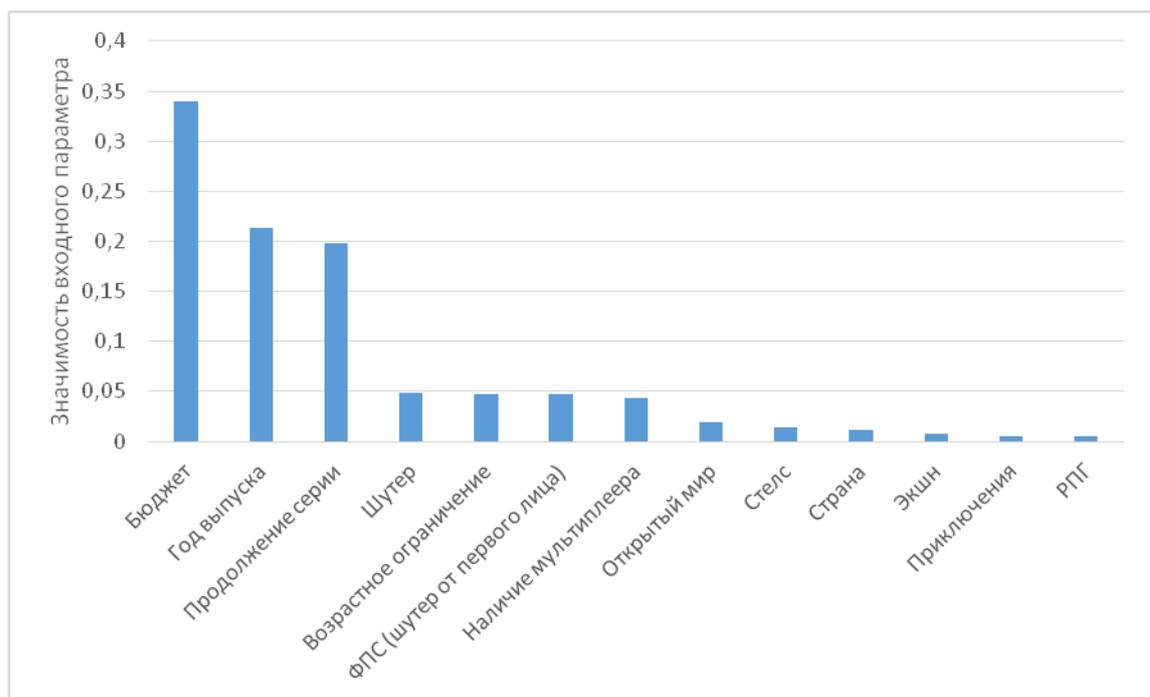


Рисунок 2. Значимость входных параметров

Исходя из полученных данных, выяснилось, что наибольшее влияние на продажи оказывают такие параметры, как: «Бюджет», «Год выпуска», «Продолжение серии»

На рисунке 3 можно увидеть, как бюджет влияет на продажи видеоигры в первую неделю, при прочих равных параметрах. Здесь использована методология сценарного прогнозирования методом замораживания, предложенная в [10].

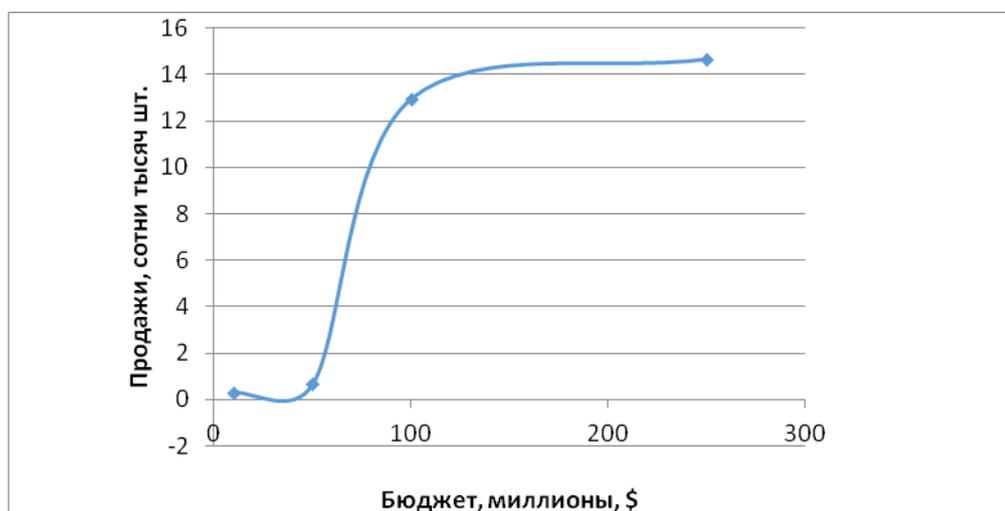


Рисунок 3. Зависимость продаж от бюджета

По графику видно, что при увеличении бюджета, возрастает количество проданных копий видеоигры.

Далее на рисунке 4 продемонстрирована зависимость продаж от года выпуска.

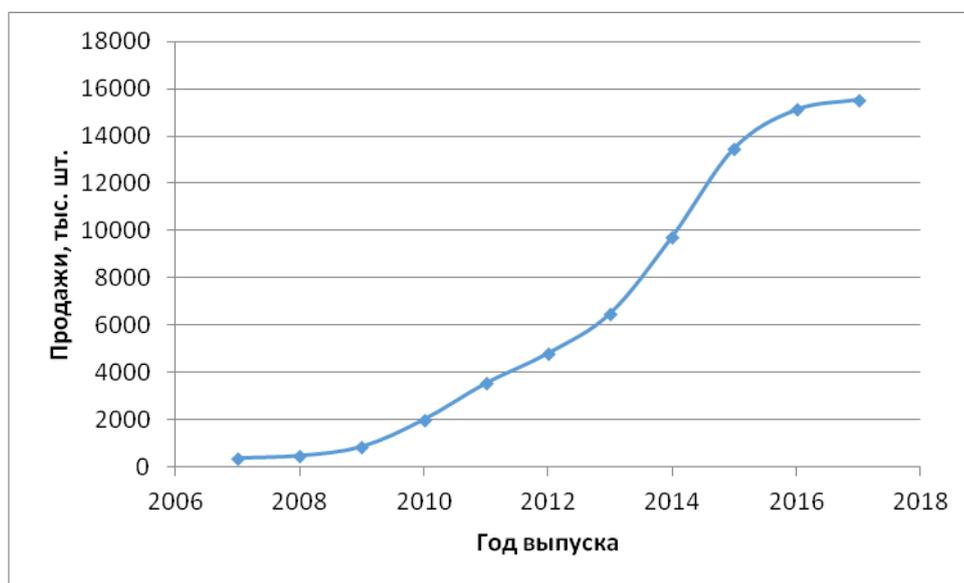


Рисунок 4. Зависимость продаж от года выпуска

По этому графику можно заметить, что видеоигры, выпущенные в последние года, будут продаваться большим числом копий.

Заключение. В процессе работы по созданию нейросетевой системы были выявлены характеристики, которые влияют на продажи видеоигры в первую неделю после выпуска. Эти данные могут использоваться

разработчиками видеоигр, для увеличения количества проданных копий своей видеоигры.

Библиографический список

1. Ясницкий Л.Н., Плотников Д.И. Экономико-математическая нейросетевая модель для оптимизации финансовых затрат в кинобизнесе // Фундаментальные исследования. – 2016. – № 11-2. – С. 339-342
2. Ясницкий Л.Н., Белобородова Н.О., Медведева Е.Ю. Методика нейросетевого прогнозирования кассовых сборов кинофильмов // Финансовая аналитика: проблемы и решения. 2017. т. 10. Вып. 4. С. 449–463.
3. Википедия Свободная энциклопедия [Электронный ресурс]. – URL: <https://ru.wikipedia.org/wiki/> (дата обращения: 17.02.2019)
4. VGCharts [Электронный ресурс]. – URL: <http://www.vgchartz.com/gamedb/> (дата обращения: 19.02.2019)
5. Kotaku [Электронный ресурс]. – URL: https://kotaku.com/how-much-does-it-cost-to-make-a-big-video-game-1501413649?utm_campaign=Socialflow_Kotaku_Facebook&utm_source=Kotaku_Facebook&utm_medium=Socialflow (дата обращения: 18.02.2019)
6. Википедия. Свободная энциклопедия [Электронный ресурс]. – URL: www.en.m.wikipedia.org/wiki/List_of_most_expensive_video_games_to_develop (дата обращения: 18.02.2019)
7. Keras [Электронный ресурс] – URL: <https://keras.io/> (дата обращения: 11.02.2019)
8. Нейросимулятор 5.0 : свидетельство о государственной регистрации программы для № 2014618208 от 12.07.2014 г. / Черепанов Ф.М., Ясницкий В.Л. (РФ).
9. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
10. Ясницкий Л.Н. Нейронные сети – инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48-56.

NEURAL NETWORK MODELING FORECASTING THE VALUE OF VIDEO GAMES FOR THE FIRST WEEK AFTER THE RELEASE

Yurkov Michael Aleksandrovich

Perm State University 614990, Russia, Perm, 15 Bukireva str.,

mishayur1997@mail.ru

This article describes the development of a neural network system for forecasting video game sales in the first week after release. The system allows you to predict sales of a video game by thirteen input parameters, such as budget size, country of the game developer, year of production, age limit, etc. The system also has the ability to detect trends in the number of sales, depending on the input parameters.

Key words: artificial intelligence, neural network technologies, forecasting, sales evaluation, video games, computer games.

ЦИФРОВАЯ МЕДИЦИНА И ЦИФРОВОЕ ЗДРАВООХРАНЕНИЕ

ПРОГНОЗИРОВАНИЕ КОЭФФИЦИЕНТА ЕСТЕСТВЕННОГО ПРИРОСТА НАСЕЛЕНИЯ МЕТОДОМ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ

Боталова Анастасия Александровна

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

В статье описан опыт разработки и построения нейронной сети для прогнозирования коэффициента естественного прироста населения с помощью нейропакета «Nsim» (Нейросимулятор 5.0) и библиотеки Keras. Также представлен анализ значимости показателей и оценка влияния параметров на прогнозируемый показатель.

Ключевые слова: прирост населения, прогнозирование, нейронная сеть, Keras, искусственный интеллект.

Для прогнозирования коэффициента естественного прироста были выбраны следующие показатели:

1. Общие коэффициенты рождаемости;
2. Общие коэффициенты смертности;
3. Коэффициенты младенческой смертности;
4. Ожидаемая продолжительность жизни при рождении.
5. Возрастной состав населения (население моложе трудоспособного);
6. Возрастной состав населения (население старше трудоспособного);
7. Распределение среднегодовой численности занятых по видам экономической деятельности;
8. Состав занятого населения по возрастным группам (средний возраст);
9. Состав занятого населения по возрастным группам(50-59);
10. Структура социальных выплат, пособия и социальная помощь;
11. Общая площадь жилых помещений, приходящаяся в среднем на одного жителя;
12. Предоставление гражданам помещений (Удельный вес семей, состоящих на учете в качестве нуждающихся в жилых помещениях);
13. Наличие квартирных телефонных аппаратов сети общего пользования (Городское население);
14. Изменения численности населения;
15. Состав занятого населения по группам (15-19).

Данные были взяты из базы данных Росстата [1].

Для того чтобы определить адекватность модели, была применена формула 1. По этой формуле считается ошибка модели, которая позволит в дальнейшем сравнить результаты прогнозирования коэффициента естественного прироста населения с помощью нейропакета «Nsim» (Нейросимулятор 5.0) и библиотеки Keras. Ошибка прогноза должна быть менее 4%. Такой критерий ошибки был установлен в ходе исследования.

$$\text{Ошибка} = \frac{|Y - Y'|}{Y} * 100\%, \quad (1)$$

где Y – реальное значение выходного параметра, а Y' – полученное прогнозное значение.

Были найдены наилучшие параметры для обучения сети на Нейросимуляторе [2] :

- количество входных нейронов: 15;
- количество выходных нейронов: 1;
- количество скрытых слоев: 3;
- количество нейронов на 1 слое: 1;
- количество нейронов на 2 слое: 1;
- количество нейронов на 3 слое: 5;
- функция активации: Тангенс гиперболический;
- алгоритм обучения: Упругого распространения.

В обучающую выборку были взяты данные за 13 лет по территориям.

При данной структуре нейросети ошибка, вычисленная по формуле (1), составила 2,6%. Полученная ошибка является приемлемой и говорит об адекватности построенной модели.

На рисунке 1 представлена диаграмма, показывающая прогнозные результаты модели и реальные значения.

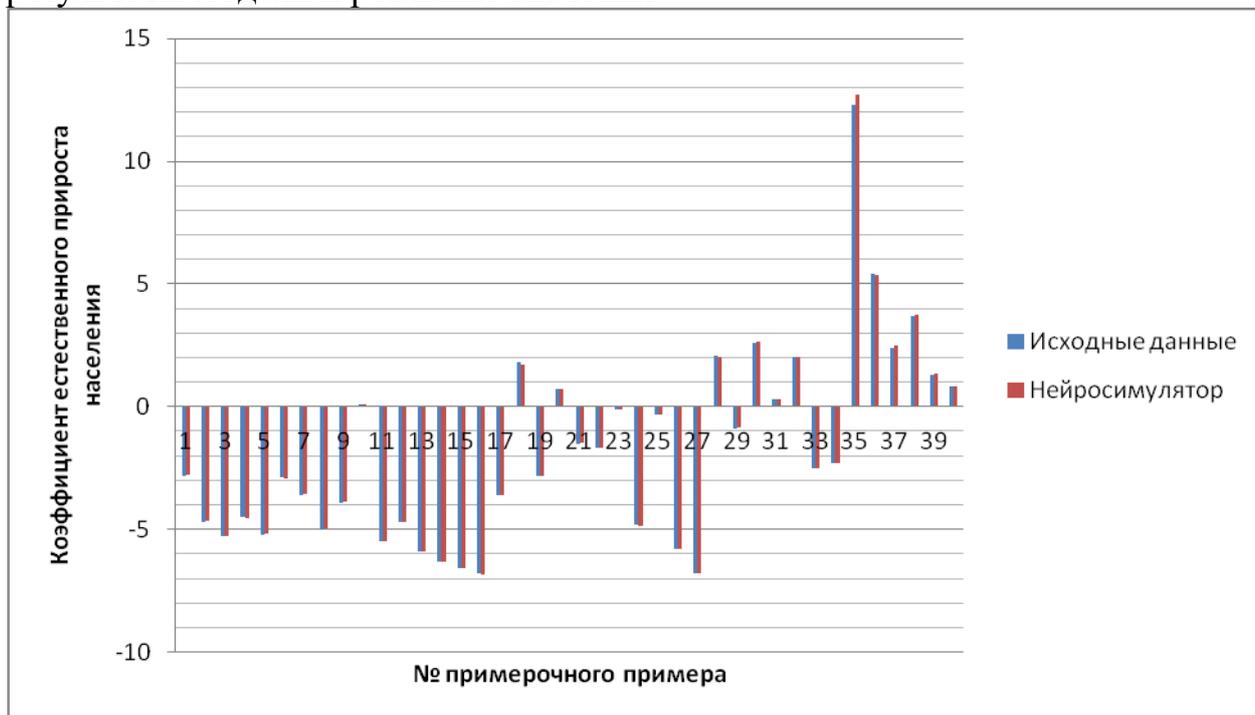


Рисунок 1. Исходные данные и Нейросимулятор

Далее было произведено исследование параметров на их значимость. Для этого, воспользовавшись встроенной функцией в Нейросимуляторе, была получена диаграмма на рисунке 2. Параметры на рисунке отсортированы по убыванию.

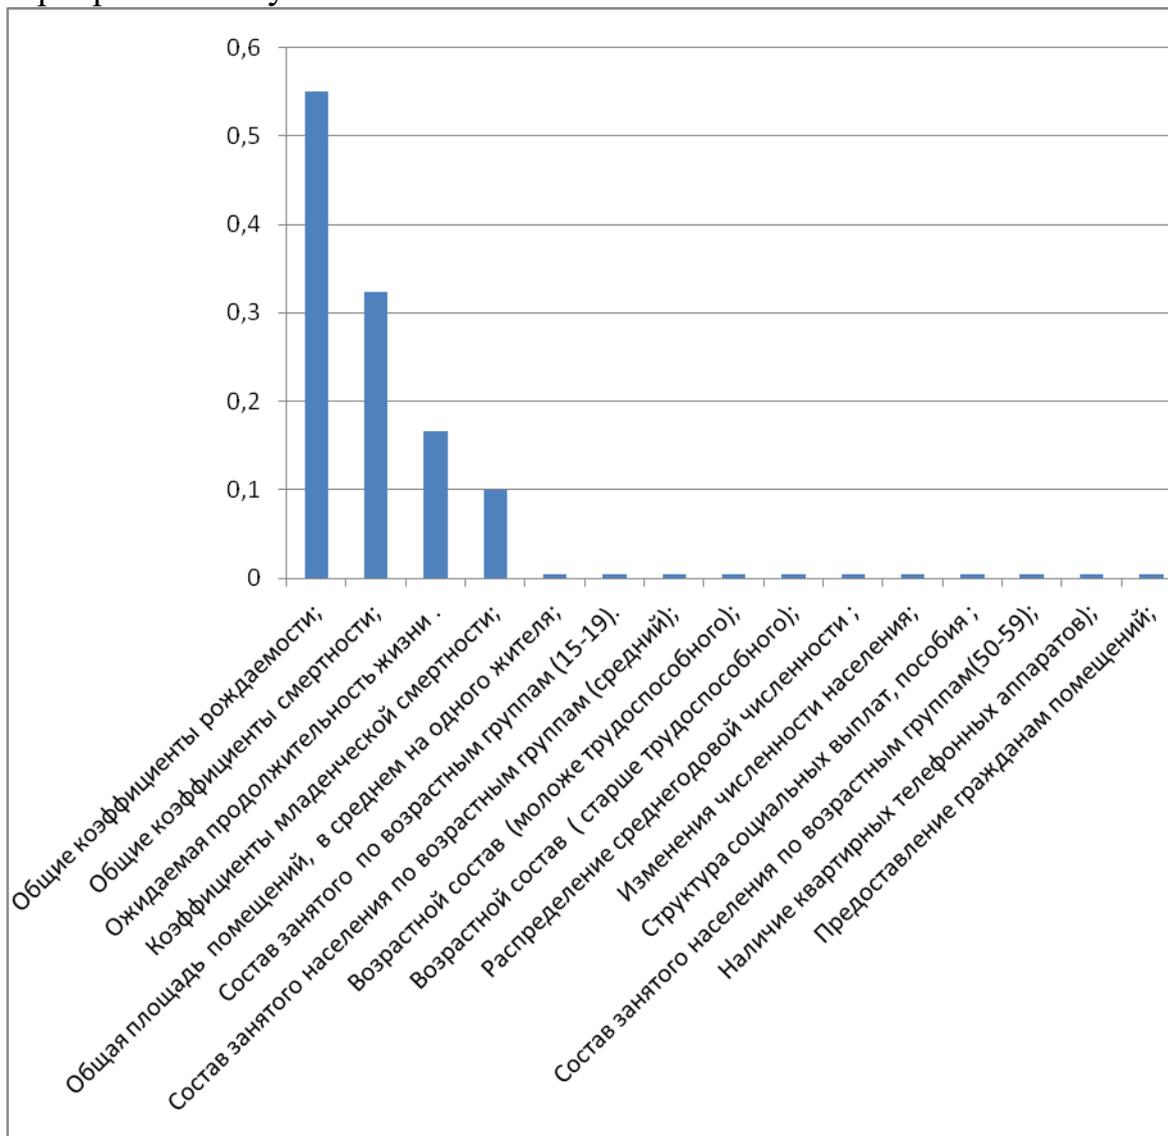


Рисунок 2. Значимость параметров

В рамках исследования был использован «метод замораживания». Данный метод позволяет изучить закономерности предметной области. Суть метода заключается в изменении одного входного параметра и наблюдении за выходным параметром. Исследование проведено для трех параметров:

1. Общие коэффициенты смертности;
2. Коэффициенты младенческой смертности;
3. Ожидаемая продолжительность жизни при рождении.

Исследование проводилось для Белгородской области. Маркером обозначено реальное значение прогнозируемого показателя.

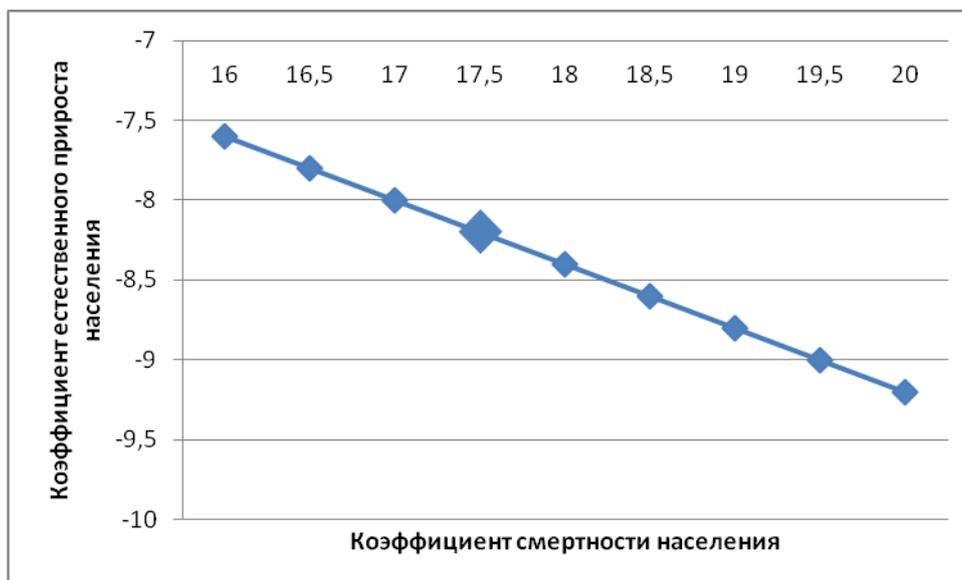


Рисунок 3. Влияние коэффициента смертности населения

Как видно из диаграммы на рисунке 3, система определила, что уменьшение коэффициента естественного прироста связано с увеличением коэффициента смертности.

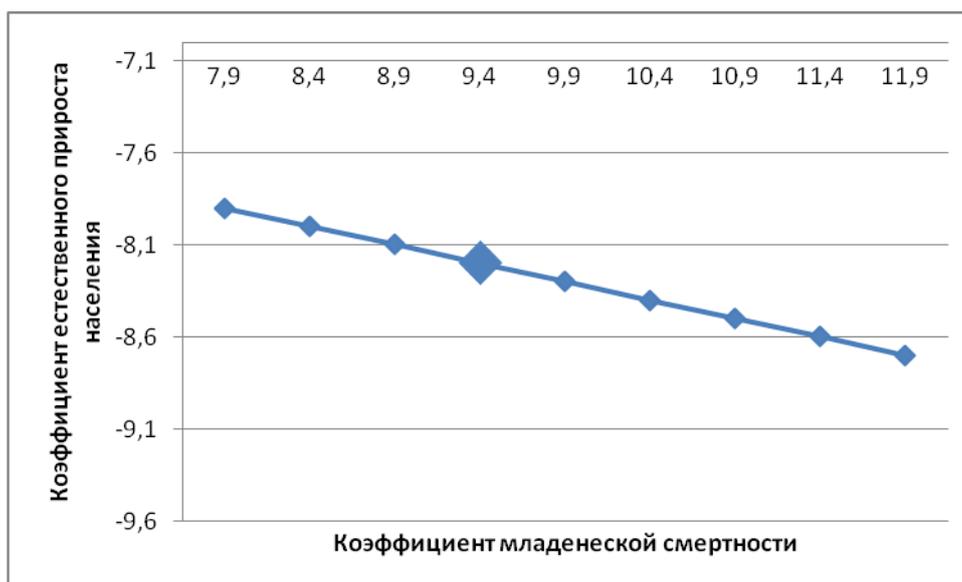


Рисунок 4. Влияние коэффициента младенческой смертности

Как видно из диаграммы на рисунке 4, уменьшение коэффициента естественного прироста связано с увеличением коэффициента младенческой смертности.



Рисунок 5. Влияние продолжительности жизни при рождении

Увеличение коэффициента естественного прироста связано с увеличением продолжительности жизни при рождении.

Для того чтобы построить следующую модель, была написана программа на языке программирования Python с использованием библиотеки Keras. Keras — это библиотека для Python с открытым исходным кодом, которая позволяет легко создавать нейронные сети [3]. Ошибка считалась по формуле (1). Ошибка прогноза модели составила 3,5%. Эта ошибка говорит об адекватности модели.

На рисунке 6 представлена диаграмма сравнения исходных данных и результатов в библиотеке Keras.

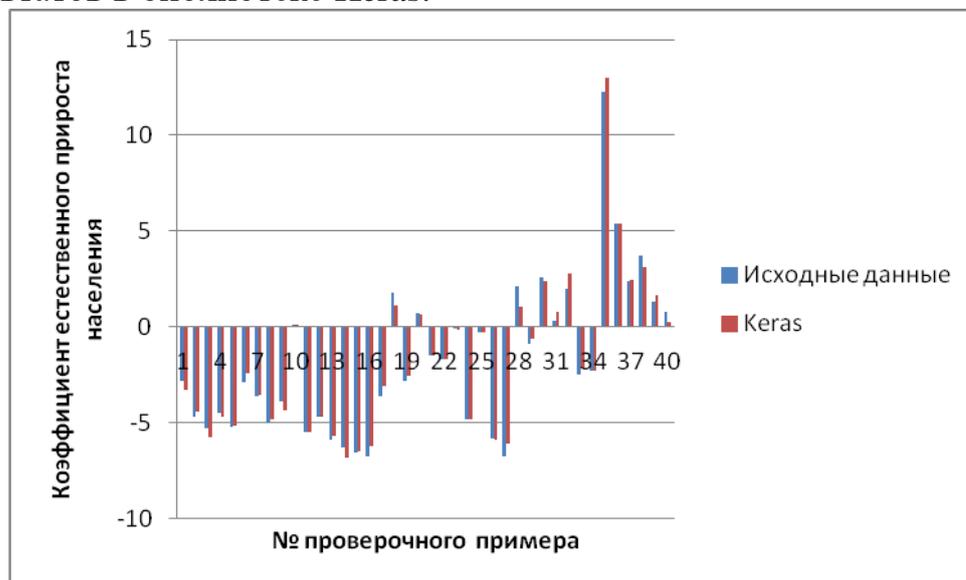


Рисунок 6. Исходные данные и Keras

Таким образом, можно сделать вывод о том, что модель в Нейросимуляторе дает прогноз точнее, чем модель в библиотеке Keras для показателя коэффициента естественного прироста населения. Ошибка

прогноза в Нейросимуляторе составила 2,6%, а ошибка прогноза модели в библиотеке Keras составила 3,5%.

Библиографический список

1. Федеральная служба государственной статистики. Регионы России. Социально-экономические показатели. 2017, стр. 1-1404.
2. Нейросимулятор 5.0: Свидетельство о государственной регистрации программы для № 2014618208 от 12.07.2014 г. / Черепанов Ф.М., Ясницкий Л.Н. (РФ)
3. Keras Documentation [электронный ресурс]. URL: <https://keras.io> (дата обращения 01.04.2019).

FORECASTING THE COEFFICIENT OF NATURAL GROWTH OF THE POPULATION BY THE METHOD OF NEURAL NETWORK MODELING

Botalova Anastasia A.

Perm State University

614990, Russia, Perm, street bukireva, 15, nastya.bt@gmail.com

The article describes the experience of developing and building a neural network to predict the factors of natural population growth using the neuropacket “Nsim” (Neurostimulator 5.0) and the Keras library. Also presented an analysis of indicators.

Keywords: population growth, forecasting, neural network, artificial Intelligence, Keras.

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ ПРОДОЛЖИТЕЛЬНОСТИ ЖИЗНИ НАСЕЛЕНИЯ РЕГИОНОВ РОССИИ ²⁵

Галкина Татьяна Андреевна

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

В статье представлено описание разработки и применения нейросетевых технологий для прогнозирования продолжительности жизни регионов России. Система позволяет прогнозировать продолжительность жизни по социально-экономическим показателям, таким как реальные доходы населения, численность врачей всех специальностей, число больничных коек, индексы промышленного производства, число легковых автомобилей и др.

Ключевые слова: нейросетевые технологии, прогнозирование, здоровье, продолжительность жизни.

В настоящее время рост продолжительности жизни в России увеличивается. За последнее десятилетие ожидаемая продолжительность жизни увеличилась более чем на 5 лет и продолжает расти. За январь-декабрь 2017 года, по оценкам Росстата ожидаемая продолжительность жизни составила 72,68 лет (рост на 0,81 лет по сравнению с 2016 годом – 71,87 лет), у мужчин – 67,58 лет (рост на 1,08 лет, в 2016 году – 66,50 лет), у женщин – 77,62 лет (рост на 0,56 лет, в 2016 году – 77,06 лет) [1].

Однако уровень здоровья населения в России продолжается оставаться в критическом состоянии, поэтому важно не только уметь прогнозировать продолжительность жизни, но и исследовать причины, которые на нее влияют.

В последнее время для изучения вопросов продолжительности жизни населения регионов России начали применять современные методы математической статистики и искусственного интеллекта. Так, в работе [5] применение нейросетевых технологий позволило построить математическую модель, адекватно отражающую связь между управляющими воздействиями Роспотребнадзора по обеспечению гигиенической безопасности и их влиянием на смертность населения регионов Российской Федерации. В [6] нейросетевые технологии применены для разработки систем ранней диагностики и выявления рисков возникновения опасных для жизни видов сердечно-сосудистых заболеваний. В [7] создана интеллектуальная система, выявляющая причины и позволяющая выработать рекомендации по снижению наркозависимости, в [8] – депрессивных расстройств.

В настоящей статье приведены результаты исследований, которые осуществлялись в несколько этапов.

На первом этапе была собрана официальная статистическая информация, отражающая явления и процессы, произошедшие в экономической и социальной жизни Российской Федерации. Данные взяты с сайта Федеральной службы государственной статистики (Росстат) [2].

Второй этап: проектирование и обучение нейросети. Нейросетевая модель создается при помощи специальной программы «Нейросимулятор 5» [3], которая представляет собой полноценный симулятор полносвязных нейронных сетей, по методике [4].

Входные параметры, с помощью которых прогнозируется продолжительность жизни: X1 – Регион, X2 – Год, X3 – Число больничных коек, X4 – Численность врачей всех специальностей, X5 – Мощность амбулаторно-поликлинических организаций, X6 – Улавливание загрязняющих атмосферу веществ, отходящих от стационарных источников, X7 – Индексы промышленного производства, X8 – Реальные доходы населения, X9 – Число собственных легковых автомобилей на 1000 человек населения, D1 – ожидаемая продолжительность жизни. Входные параметры подобраны по смыслу и по коэффициенту корреляции.

На рисунке 1 представлена спроектированная нейронная сеть. Модель с одним скрытым слоем. Количество нейронов на скрытом слое – 1. Функция активации – Тангенс гиперболический.

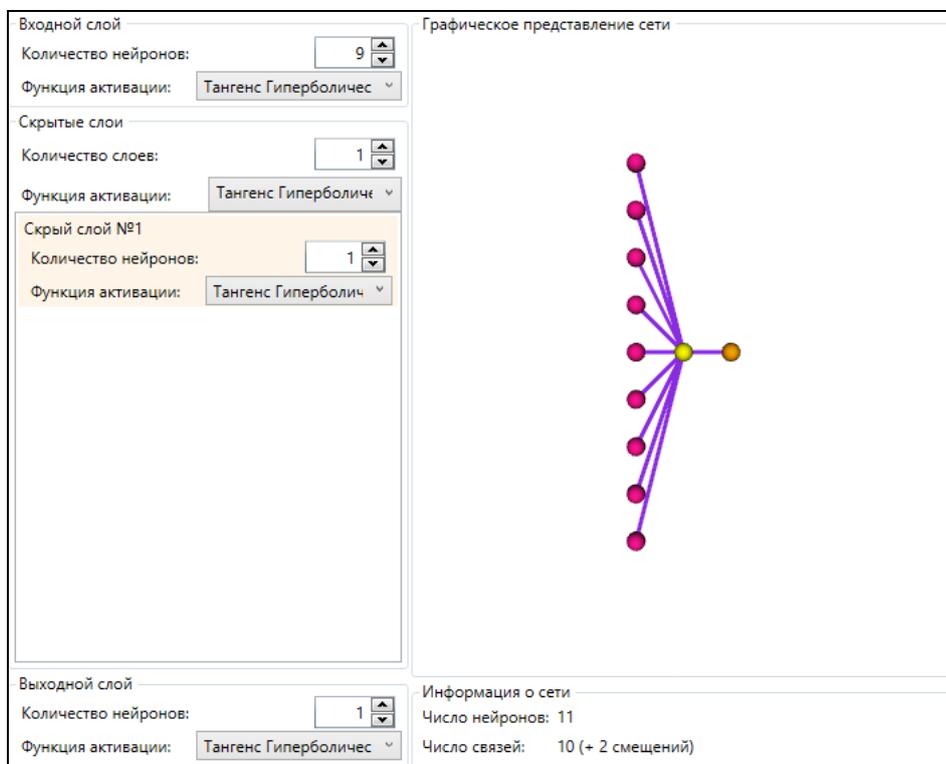


Рисунок 20. Проектирование сети

Третий этап: тестирование и проверка нейросети на адекватность.

График, отображающий разницу между действительной продолжительностью жизни и спрогнозированной, представлен на рисунке 2.

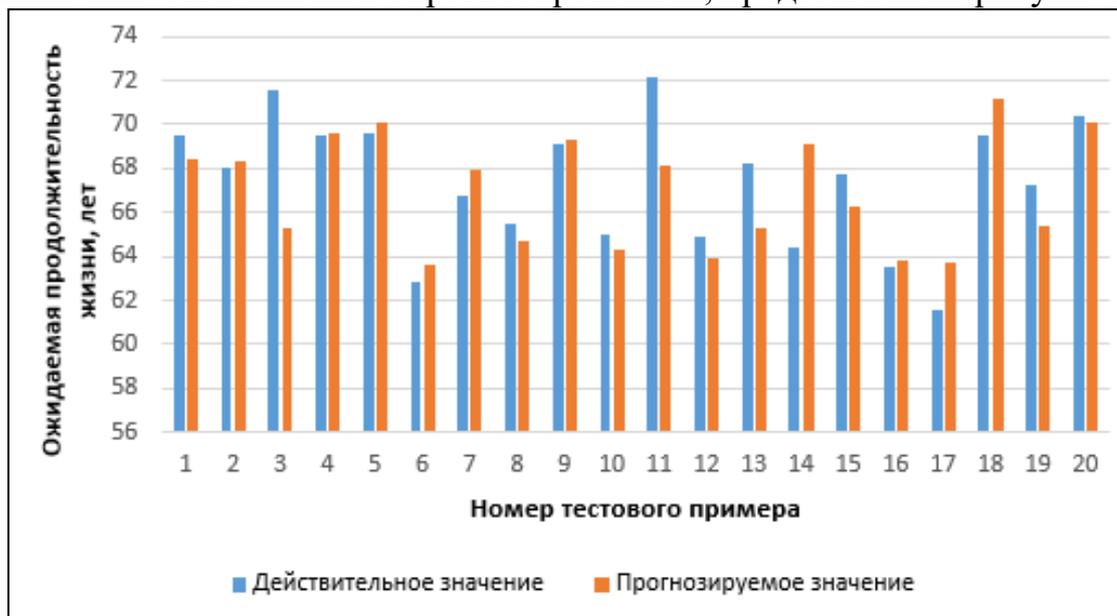


Рисунок 21. Результаты тестирования нейронной сети

Средняя ошибка нейронной сети – 2.5%. Следовательно, сеть пригодна для прогнозирования.

На рисунке 3 можно увидеть значимость входных параметров.

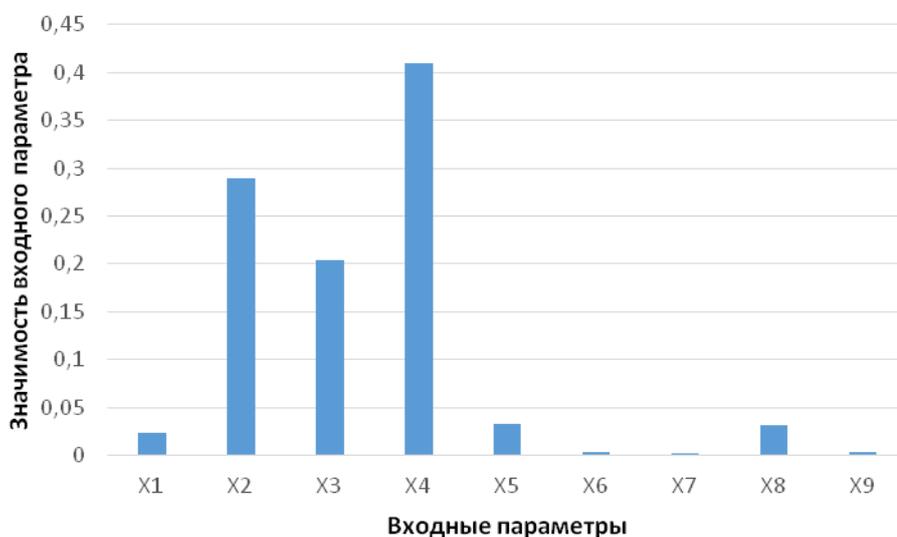


Рисунок 22. Значимость входных параметров.

Исходя из полученных данных, выяснилось, что наибольшее влияние на продолжительность жизни в значительной степени влияют такие параметры, как: «Численность врачей всех специальностей» и «Число больничных коек».

Далее в процессе исследования была выявлена динамика ожидаемой продолжительности жизни при изменении только одного показателя.

На рисунках 4-6 представлено, как меняется продолжительность жизни в Омской области. Продолжительность жизни в Омской области равняется

70,7 лет. На рисунках маркер, отображающий значение продолжительности жизни в Омской области, отображается крупнее.

На рисунке 4 можно заметить, что с увеличением промышленного производства продолжительность жизни постепенно уменьшается.

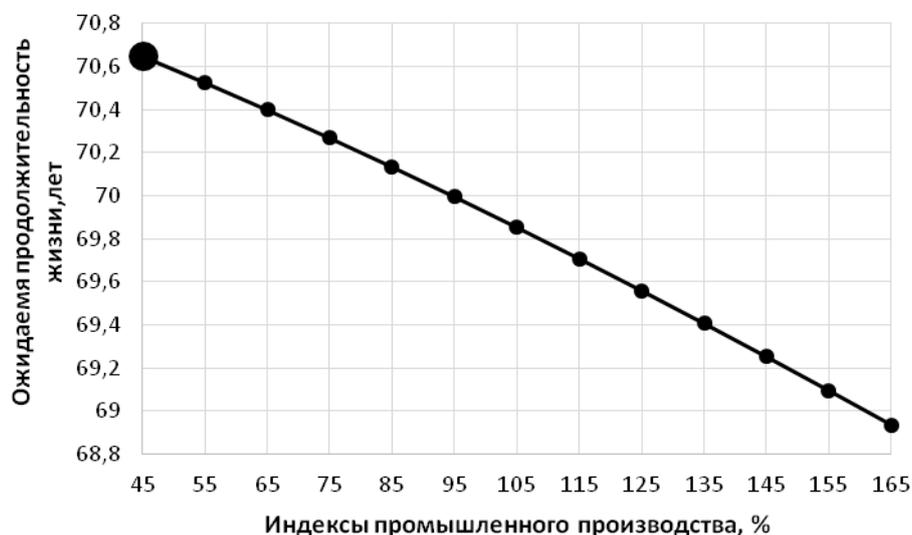


Рисунок 23. Изменение ожидаемой продолжительности жизни при увеличении индексов промышленного производства

На рисунке 5 заметно, что при улавливании параметра «улавливание загрязняющих атмосферу веществ», продолжительность жизни наоборот уменьшается, а не увеличивается. Данный парадоксальный факт, естественно, нуждается в объяснении. Здесь он приводится потому, что аналогичные закономерности уже наблюдались авторами работы [5].

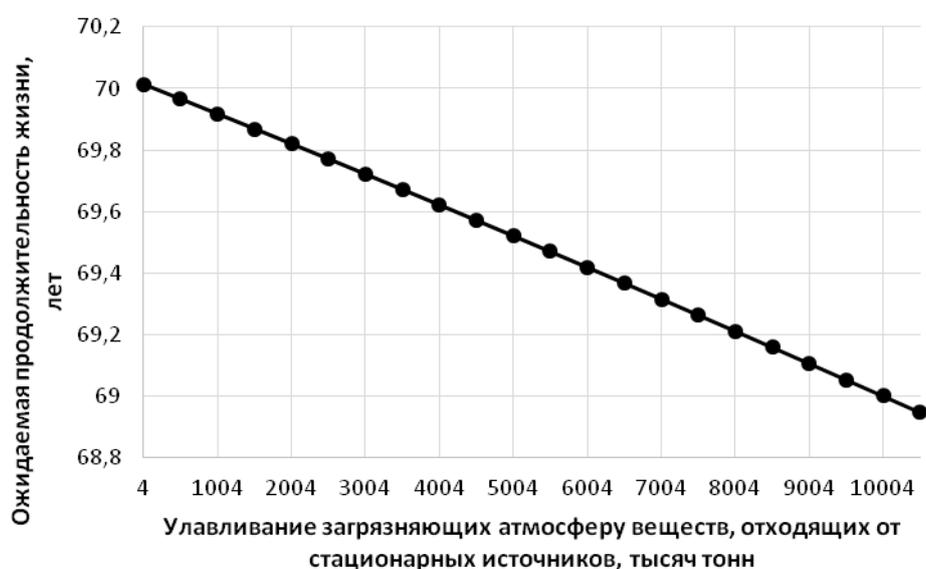


Рисунок 24. Изменение ожидаемой продолжительности жизни при улавливании загрязняющих атмосферу веществ, отходящих от стационарных источников

На рисунке 6 видно, что при увеличении доходов населения продолжительность жизни увеличивается.

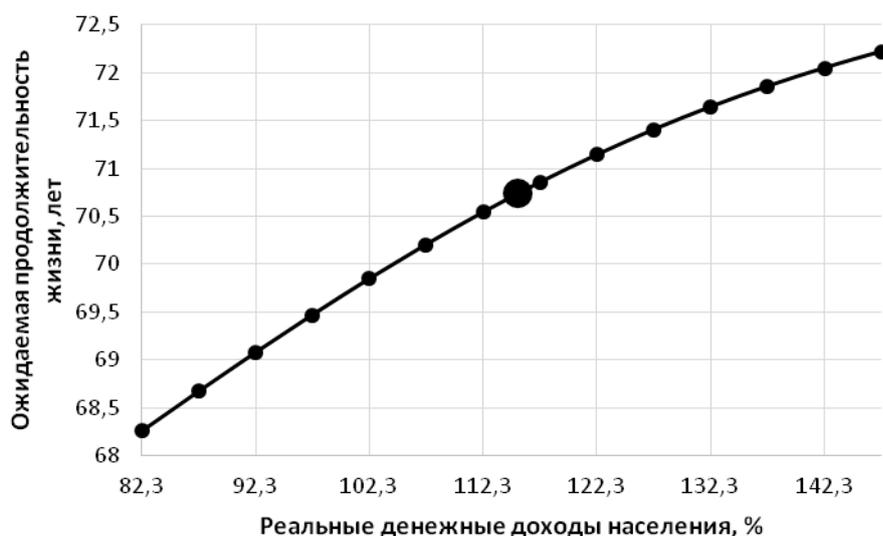


Рисунок 25. Изменение ожидаемой продолжительности жизни при увеличении реальных доходов населения

На рисунке 7 заметно, как уменьшается продолжительность жизни при увеличении количества автомобилей.

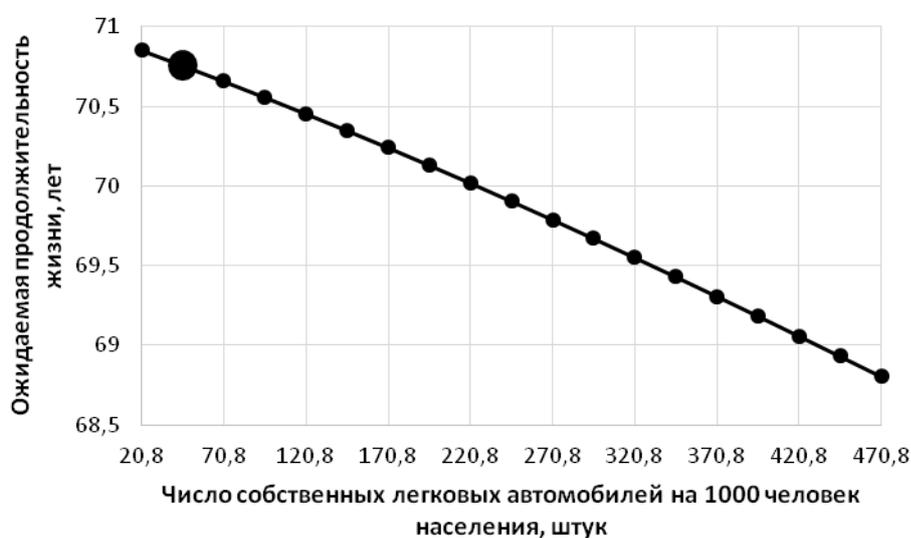


Рисунок 26. Изменение ожидаемой продолжительности жизни при увеличении число собственных легковых автомобилей на 1000 человек населения

На рисунке 8 продолжительность жизни значительно увеличивается при увеличении врачей всех специальностей. Однако, как видно на этом рисунке, при чрезмерном увеличении количества врачей наступает насыщение, т.е. продолжительность жизни населения перестает увеличиваться.

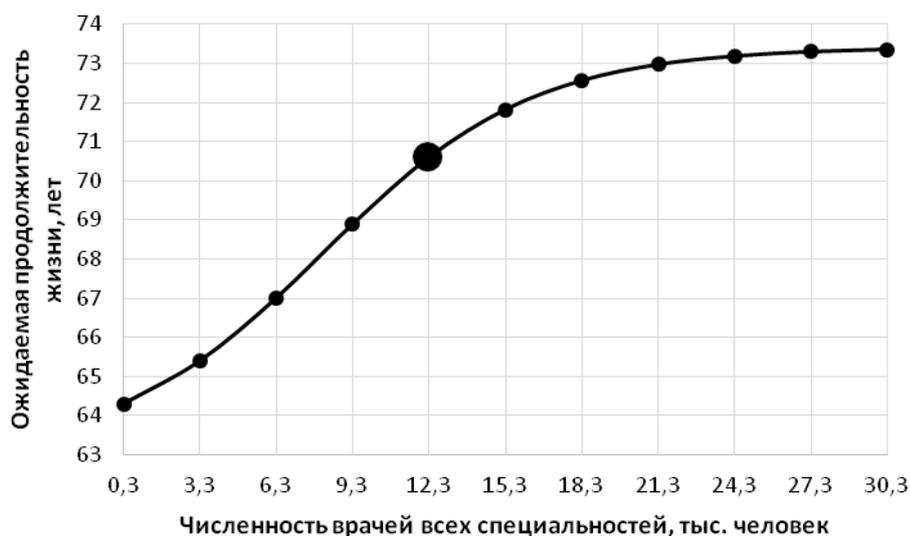


Рисунок 27. Изменение ожидаемой продолжительности жизни при увеличении врачей всех специальностей

Заключение. Построенная прогнозная модель, работает адекватно, выявляет интересные закономерности и пригодна для дальнейшего использования.

Библиографический список

1. Министерство здравоохранения Российской Федерации. Об итогах работы министерства здравоохранения Российской Федерации в 2017 году и задачах на 2018 год, 2018. С.9
2. Федеральная служба государственной статистики. Регионы России. Социально-экономические показатели. [Электронный ресурс]. – URL: http://www.gks.ru/bgd/regl/b18_14p/Main.htm (дата обращения: 01.04.2018)
3. 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.
4. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.
5. Ясницкий Л.Н., Зайцева Н.В., Гусев А.Л., Шур П.З. Нейросетевая модель региона для выбора управляющих воздействий в области обеспечения гигиенической безопасности // Информатика и системы управления. – 2011. – № 3 (29). – С.51-59.
6. Yasnitsky L.N., Dumler A.A., Poleshuk A.N., Bogdanov S.V., Cherepanov F.M. Artificial neural networks for obtaining new medical knowledge: diagnostics and prediction of cardiovascular disease progression // Biology and Medicine. 2015. Т. 7. № 2. С. ВМ-095-15.
7. Ясницкий Л.Н., Грацилёв В.И., Куляшова Ю.С., Черепанов Ф.М. Возможности моделирования предрасположенности к наркозависимости методами искусственного интеллекта // Вестник Пермского университета. Философия. Психология. Социология. 2015. № 1 (21). С. 61-73.

8. Левченко Е.В., Митрофанов И.А., Ясницкий Л.Н. Нейросетевое моделирование феномена депрессии // В сборнике: Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века. Сборник статей по материалам Третьей всероссийской научно-практической конференции, С. 139-143.

NEURAL NETWORK PREDICTION OF LIFE EXPECTANCY OF THE POPULATION

Galkina Tatyana A.
Perm State University

614990, Russia, Perm, street bukireva, 15, tanechkaga@gmail.com

The article describes the development and application of neural network technologies to predict life expectancy. The system makes it possible to predict life expectancy by socio-economic indicators, such as real incomes of the population, the number of doctors of all specialties, the number of hospital beds, industrial production indices, the number of cars, etc.

Key words: neural network technologies, forecasting, health, life expectancy.

НЕЙРОННАЯ СЕТЬ ГЛУБОКОЙ АРХИТЕКТУРЫ ДЛЯ ДИАГНОСТИКИ ПОСЛЕОПЕРАЦИОННЫХ ОСЛОЖНЕНИЙ АППЕНДИЦИТА

*Горбаченко Владимир Иванович, Савенков Константин Евгеньевич,
Соломаха Анатолий Анатольевич*

Пензенский государственный университет,
440026, Россия, г. Пенза, ул. Красная, 40, gorvi@mail.ru,
sav1996k@gmail.com, anatoly.solomakha@yandex.ru

В статье проведено исследование нейронных сетей прямого распространения глубокой архитектуры. Для выбора признаков предложен метод, обеспечивающий стабильную метрику качества работы сети и основанный на использовании минимального межквартильного размаха F1-меры. Для повышения точности классификации предложено применение повышающего (overcomplete) автоэнкодера.

Ключевые слова: нейронная сеть глубокой архитектуры, отбор признаков, повышающий автоэнкодер.

Известны нейросетевые модели диагностики острого аппендицита [1–2], но отсутствуют нейросетевые модели диагностики послеоперационных осложнений острого аппендицита. Эксперименты с классическими многослойными перцептронами показали низкую точность диагностики и склонность сетей к переобучению. Это объясняется большим количеством нелинейно связанных между собой признаков, характеризующих состояние пациента. Причем наборы признаков, характеризующих пациентов с различными состояниями, могут различаться достаточно слабо. Поэтому принято решение исследовать сети прямого распространения глубокой архитектуры. Основным преимуществом таких сетей является способность улавливать очень сложные нелинейные зависимости в данных.

Для обучения и тестирования сети использована зарегистрированная база данных по острому аппендициту [3]. Для подготовки данных, исследования сети, отбора признаков и оценки результатов обучения использована библиотека Scikit-Learn [4]. В качестве библиотеки для реализации архитектуры нейронной сети была выбрана библиотека Keras [5]. Библиотека Keras является надстройкой над фреймворком TensorFlow [4] и значительно облегчает использование такого сложного инструмента.

В данной задаче нейронная сеть решает задачу классификации: наличие/отсутствие осложнения. Для отбора признаков был выбран признак, дающий лучшее значение качества модели, среди остальных. Затем, к нему, путем полного перебора, добавлялись остальные признаки. В качестве

метрики, оценивающей качество классификатора использована F1-мера (F1-score), являющаяся средним гармоническим точности и специфичности [6]. Процесс обучения нейронной сети носит случайный характер, так как для инициализации весов используется случайный алгоритм, во время обучения обучающая выборка перемешивается случайным образом. Для выбора признаков, обеспечивающих стабильную метрику качества работы сети, предлагается использовать порядковую статистику F1-меры и минимальный межквартильный размах. Признаки были нормализованы и закодированы.

В результате экспериментов была построена сеть, состоящая из 4 слоев. Слои 1–3 используют функцию активации ReLU (Rectified Linear Unit) – положительная линейная функция активации, или жесткий максимум (max) [7]

$$f(s) = \max(0, s) = \begin{cases} 0, & s < 0, \\ s, & s \geq 0, \end{cases}$$

где s — взвешенная сумма. В выходном слое используется асимметричной логистической функции активации

$$f(s) = \frac{1}{1 + \exp(-s)},$$

где s — взвешенная сумма.

Для повышения точности классификации предлагается для преобразования входных признаков применить повышающий (overcomplete) автоэнкодер. В отличие от известных применений автоэнкодеров, служащих для понижения размерности признаков, предлагаемый автоэнкодер производит нелинейное преобразование входа в пространство большей размерности. Согласно теореме Ковера [8] это повышает вероятность линейного разделения признаков, поэтому после такого преобразования классификатор работает лучше. Можно считать, что повышающий автоэнкодер выявляет скрытые признаки.

Для избежание проблемы переобучения применен популярный прием регуляризации для глубоких нейронных сетей — метод «прореживания» (dropout) нейронов [9]. Идея dropout состоит в том, что на каждом обучающем примере каждый нейрон с некоторой вероятностью, одинаковой для каждого слоя сети, исключается из сети. В обученной сети присутствуют все нейроны, но выход каждого нейрона умножается на вероятность, с которой нейрон оставался при обучении. Вероятности исключения нейронов каждого слоя были подобраны экспериментально. Для начальной инициализации весов использовался метод Ксавье [7]. Для обучения автоэнкодера применялся метод adadelta [10]. Классификатор обучался методом Adam [11]. При обучении классификатора применялся метод callback библиотеки Keras [12]. Данный подход применяется для того, чтобы на каждой итерации работать с лучшей моделью и в результате иметь хорошую модель. В случае, если на текущей итерации значение выбранной метрики оценки качества модели изменилось в худшую сторону, то модель сохранит параметры с предыдущей итерации, а не изменит их на новые.

Используя предложенный ранее метод был произведен отбор значащих признаков. В качестве основных были взяты признаки из списка:

- Пол;

- *Возраст;*
- *Основной диагноз;*
- *Гемоглобин (до операции);*
- *Эритроциты (до операции);*
- *Лейкоциты (до операции);*
- *Нейтрофилы палочкоядерные (до операции);*
- *Лимфоциты (до операции).*

По результатам эксперимента в качестве основного признака был выбран *основной диагноз*. Затем, путем полного перебора комбинаций, была выбрана наиболее значащая для модели машинного обучения комбинация признаков: *Основной диагноз; Пол; Возраст (категор.); Эритроциты (до операции)*.

В таблице 1 отображены значения метрик качества модели для обучающего и тестового набора данных, которые составляют 85% и 15% всей выборки, соответственно.

Таблица 1. Результаты обучения модели на отобранной комбинации признаков

Метрика	Значения метрики	
	Обучающий набор (85%)	Тестовый набор (15%)
Точность ¹	0.91	1.00
Чувствительность	0.68	0.90
Специфичность	0.97	1.00
F1-мера	0.78	0.95
Вероятность ошибки первого рода	0.32	0.00
Вероятность ошибки второго рода	0.03	0.10
Площадь под ROC кривой	0.82	0.95

На рисунке показаны ROC-кривые.

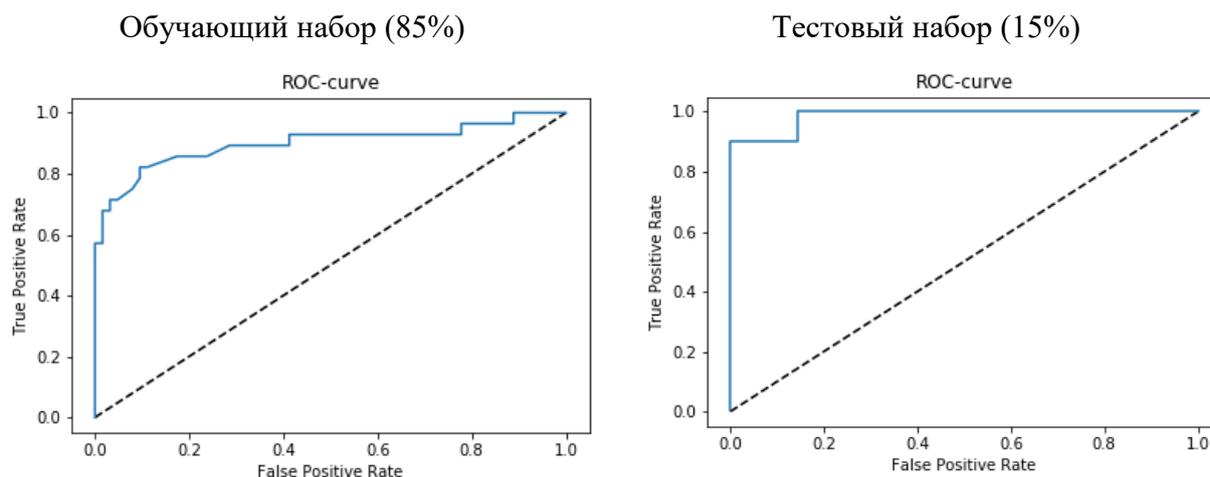


Рисунок 1. ROC-кривые обучающего и тестового наборов

¹ Под точностью понимается значение метрики precision (прецизионность) [6] — точность предсказания положительного исхода.

Значения метрик для тестового набора высоки (более 0.90), что свидетельствует о высоком качестве классификатора.

Эксперименты проводились на компьютере с процессором Intel Pentium B940 @ 2x 2GHz с 4096MB оперативной памяти под управлением операционной системы Ubuntu 18.04.2 LTS (Bionic Beaver) с версией ядра x86_64 Linux 4.15.0-45-generic. В качестве языка реализации был выбран Python, с версией 3.6.7. Использовались следующие библиотеки: Scikit-Learn версии 0.19.2; TensorFlow версии 1.5.0; NumPy версии 1.14.5; Keras версии 2.2.4.

Время обучения расширяющего автокодировщика составило 34 секунды. Классификатор обучился за 16 секунд.

Библиографический список

1. Prabhudesai S.G., Gould S., Rekhraj S., Tekkis P.P., Glazer G., Ziprin P. Artificial neural Networks: Useful Aid in Diagnosing Acute Appendicitis. // World Journal of Surgery. 2008. Vol. 32. No 2. pp. 305–309. DOI: 10.1007/s00268-007-9298-6.
2. Park S.Y., Kim S.M. Acute appendicitis diagnosis using artificial neural networks // Technology and health care: official journal of the European Society for Engineering and Medicine. 2015. Vol. 23. No. s2. pp. s559–s565. DOI: 10.3233/THC-150994
3. Клинико-лабораторные параметры больных острым аппендицитом / П. А. Ващенко, А. А. Соломаха, В. И. Горбаченко, А. О. Хазратов // Свидетельство о государственной регистрации базы данных № 2014621431. Дата государственной регистрации в Реестре баз данных 10 октября 2014 г.
4. Жерон О. Прикладное машинное обучение с помощью Scikit-Learn и TensorFlow: концепции, инструменты и техники для создания интеллектуальных систем. СПб.: ООО «Альфа-книга», 2018. 688 с.
5. Шолле Ф. Глубокое обучение на Python. СПб.: Питер, 2018. 400 с.
6. Брюс П., Брюс Э. Практическая статистика для специалистов Data Science. СПб.: БХВ-Петербург, 2018. 304 с.
7. Glorot X., Bordes A., Bengio Y. Deep Sparse Rectifier Neural Networks // Proceedings of the 14th International Conference on Artificial Intelligence and Statistics. 2011. Vol. 15. pp. 315–323.
8. Cover T. M. Geometrical and Statistical Properties of Systems of Linear inequalities with Applications in Pattern Recognition // IEEE Transactions on Electronic Computers. 1965. Vol. EC-14. No. 3. pp. 326–334. DOI: 10.1109/PGEC.1965.264137.
9. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting // Journal of Machine Learning Research. 2014. No. 15. pp. 1929–1958.
10. Zeiler M.D. ADADELTA: An Adaptive Learning Rate Method. 2012. [Электронный ресурс]. URL: <https://arxiv.org/abs/1212.5701> (дата обращения 01.04.2019)

11. Kingma D.P., Ba J.L. Adam: A Method for Stochastic Optimization // International Conference on Learning Representations. 2015.
[Электронный ресурс]. URL: <https://arxiv.org/pdf/1412.6980.pdf> (дата обращения 01.04.2019)
12. Keras: The Python Deep Learning library. Usage of callbacks.
[Электронный ресурс]. URL: <https://keras.io/callbacks/> (дата обращения 27.02.2019)

NEURAL NETWORK OF DEEP ARCHITECTURE FOR DIAGNOSIS OF POSTOPERATIVE COMPLICATIONS OF APPENDICITIS

Gorbachenko Vladimir I.
Penza State University,
440026, Russia, Penza, st. Krasnaya, 40, gorvi@mail.ru

Savenkov Konstantin E.
Penza State University,
440026, Russia, Penza, st. Krasnaya, 40, sav1996k@gmail.com

Solomakha Anatoly A.
Penza State University,
440026, Russia, Penza, st. Krasnaya, 40, anatoly.solomakha@yandex.ru

The article investigated deep feedforward neural networks. To select features, a method has been proposed that provides a stable metric of network quality and is based on using the minimum interquartile range of the F1-score. To improve the classification performance, the use of an overcomplete autoencoder has been proposed.

Keywords: neural network of deep architecture, feature selection, overcomplete autoencoder.

МЕТОД И АЛГОРИТМЫ СЕГМЕНТАЦИИ РЕНТГЕНОГРАММ МОЛОЧНОЙ ЖЕЛЕЗЫ

Дабагов Анатолий Рудольфович

АО «Медицинские технологии Лтд»

105264, Москва, 10-я Парковая ул., д. 20, кв.64, dar@mtl.ru

Кондрашов Дмитрий Сергеевич, Малютина Ирина Алексеевна,

Филист Сергей Алексеевич

Юго-Западный государственный университет,

305040, Россия, г. Курск, ул. 50 лет Октября, 94, SFilist@gmail.com

В статье представлено развитие метода сегментации изображений, основанного на последовательном разбиении изображения на квадранты. Перед очередным делением предшествующих квадрантов осуществляется модификация их границ и классификация их на «делимые» и «не делимые». Отнесение квадранта к материнскому осуществляется на основе критерия однородности. Проведена модификация известного яркостного критерия однородности, которая позволила привести значения порога в диапазон 0...1. Программная реализация процесса сегментации рентгенограмм показала устойчивость и управляемость процесса сегментации при различных порогах критерия однородности.

Ключевые слова: рентгенограмма молочной железы, сегментация изображения, предиктор однородности, алгоритм.

Поиск морфологических образований на рентгенограмме молочной железы, обусловленных онкологическими заболеваниями, не является тривиальной задачей [1]. Для ее решения используется метод сегментации, заключающейся в разбиении рентгенограммы на блоки, состоящие из четырех не пересекающихся областей – квадрантов, по технологии сверху-вниз, и слиянии блоков в сегменты снизу-вверх. Для каждого из вновь полученных квадрантов определяется их статус, согласно которому квадрант получает статус «материнского» блока и продолжает делиться на квадранты следующего иерархического уровня (переходит на следующий иерархический уровень – вниз), или статус «не делимого» блока, при этом блок остается на текущем иерархическом уровне. Перед определением статуса квадранта осуществляют модификацию границ квадрантов внутри блока путем оптимизации критерия однородности квадрантов по показателю однородности яркости квадрантов. Предиктор P1 отражает однородность блока по яркости и определяет условие делимости блока. Формирование иерархических уровней заканчивается, когда на текущем иерархическом уровне присутствуют только «неделимые» блоки. После этого начинается

перемещение блоков снизу вверх, сущность которого заключается в объединении смежных блоков при выполнении условия

$$P1(R_i \cup R_j) \leq (P1(R_i)) \text{AND} (P1(R_j)), j = 1, \dots, n ; i \neq j \quad (1)$$

где R_i и R_j – смежные блоки, n – число смежных блоков на текущем уровне у блока R_i .

После завершения этой процедуры изображения разбивается на N однородных по яркости блоков. Для каждого из этих блоков определяют предиктор $P2$, который отражает свойства морфологических образований на рентгенограмме, обусловленных онкологическими заболеваниями. Предиктор $P2$ может быть, как скаляром, так и вектором. Предиктор отражает однородность блока по текстуре и определяет условие принадлежности блока к искомому классу

$$P2(R_i) = \text{TRUE}, i = 1, \dots, N. \quad (2)$$

Для проверки условия (2) предиктор блока R_i подают на обучаемый классификатор, который проверяет условие (2). При выполнении условия (2) блок R_i бинаризуется (закрашивается определенным цветом или принимает значения самой высокой или самой низкой градации яркости).

На начальном этапе реализации метода необходимо сегментировать рентгенограмму на однородные блоки, однородность которых определяется предиктором $P1$. Вначале выбирается вычислительная процедура определения критерия, а затем его пороговое значение $P1_{\text{доп}}$. При выборе порогового значения необходимо учитывать, что оно может быть различно для различных выделяемых сегментов. Критерии однородности носят эмпирический характер и могут выбираться на основе яркостных характеристик или текстурных характеристик [2]. Например, яркостной критерий однородности вычисляется согласно выражению [3]

$$\max_{P \in R} |f(P) - m| < T, \quad (3)$$

где m – среднее значение яркостей пикселей $f(P)$ в каскадном окне R , которое вычисляется по формуле

$$m = \frac{1}{N} \sum_{P \in R} f(P), \quad (4)$$

где N – число пикселей в каскадном окне.

Согласно методу начинаем анализ изображения с верхнего уровня, то есть с исходного. Блоки изображения классифицируются на «делимые» («материнские») и «не делимые». Если блок получает статус «делимого», то он делится на четыре квадранта с переводом их на следующий, более низкий иерархический уровень. Если блок получает статус «неделимого», то он остается на текущем уровне. Процесс деления блоков на квадранты продолжается до тех пор, пока на текущем уровне не останется ни одного «делимого» блока или «делимые» блоки при их делении на квадранты станут меньше предельно допустимого размера.

Так как число уровней декомпозиции заранее неизвестно, то организуется итерационный процесс с параметром цикла i , который наращивается на единицу при каждом переходе на очередной иерархический уровень. Первый иерархический уровень – это само исходное изображение.

После выделения блоков осуществляется оптимизация их границ. Если критерий однородности требует дальнейшего деления блока (принято решение о неоднородности блока согласно (3)), то в результате деления из блока-предка получаем четыре квадранта потомков. Однородность в этих квадрантах может быть улучшена путем продвижения вертикальной границы вдоль горизонтальной оси и горизонтальной границы вдоль вертикальной оси. Каждое такое передвижение границ сопровождается вычислением критерия однородности в каждом квадранте, так как продвижение любой из границ сопровождается изменением критерия (3) в каждом квадранте-потомке. Границы квадратов деформируются, если процесс смещения границ приводит к уменьшению левой части (3), то есть к повышению однородности квадратов с новыми границами. В противном случае границы оставляем без изменения.

На рисунке 1 представлены сегментированные рентгенограммы молочной железы на различных иерархических уровнях.

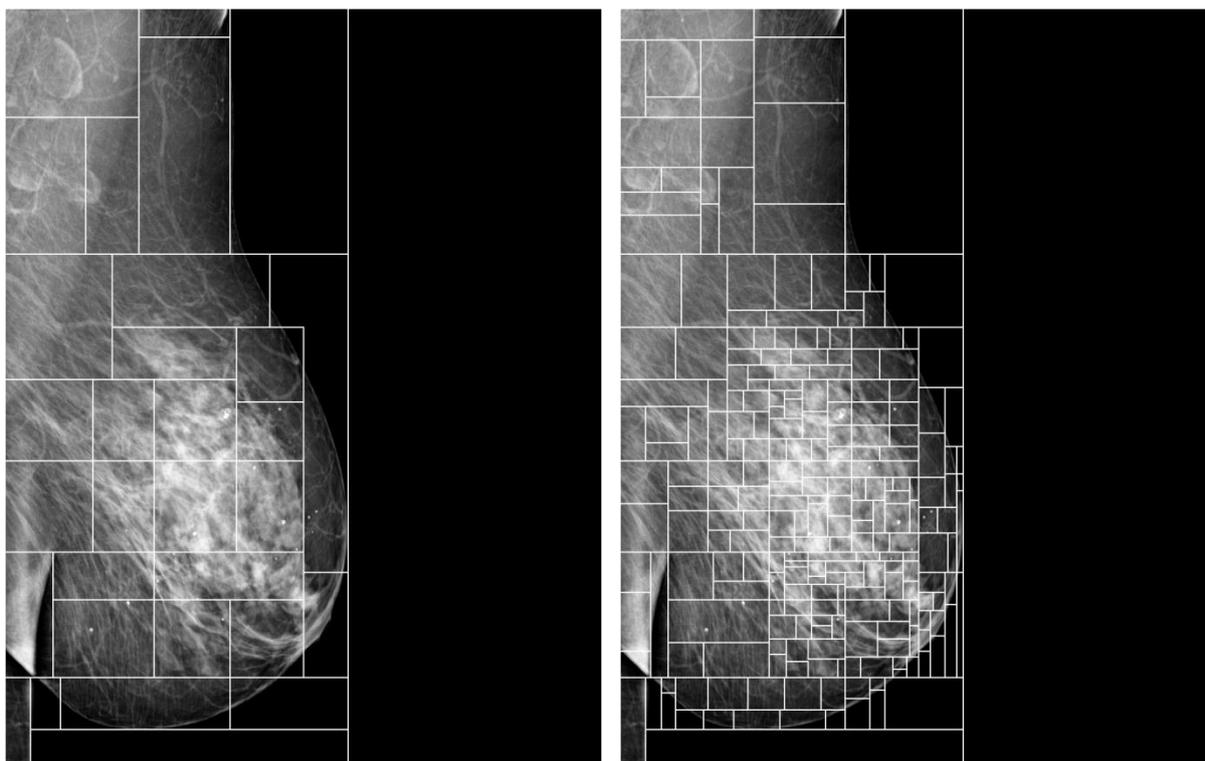


Рисунок 1. Два иерархических уровня сегментации рентгенограммы

На втором этапе сегментации рентгенограмм необходимо укрупнить блоки, то есть присоединить более мелкие блоки на нижних уровнях к более крупным на верхних уровнях, поэтому этот этап назовем проходом снизу вверх. Просмотр блоков по уровням целесообразен, так как он позволяет упростить поиск смежных блоков. Смежные блоки являются претендентами на объединение (укрупнение) исходя из критерия $P1$. Определив число смежных блоков K организуем цикл по параметру k , в котором

рассматриваем варианты попарного объединения этого блока со всеми остальными смежными блоками. Для принятия решения по объединению блока определяется предиктор $P1$ для объединенного блока. Если выполняется условие

$$P1(W_{ij} \cup W_{i\ell_k}) \leq (P1(W_{ij}))AND(P1(W_{i\ell_k})), \quad (5)$$

то блок $W_{i\ell_k}$ поглощает блок W_{ij} . Это приводит к уменьшению числа блоков на иерархическом уровне.

Таким образом, просматриваются все блоки уровня i . Параметр r хранит число оставшихся необъединенных блоков на уровне i и после просмотра всех блоков уровня его значение добавляется переменной N .

На рисунке 2 показана блочная структура рентгенограммы молочной железы после выполнения алгоритма, реализующего движение снизу вверх.

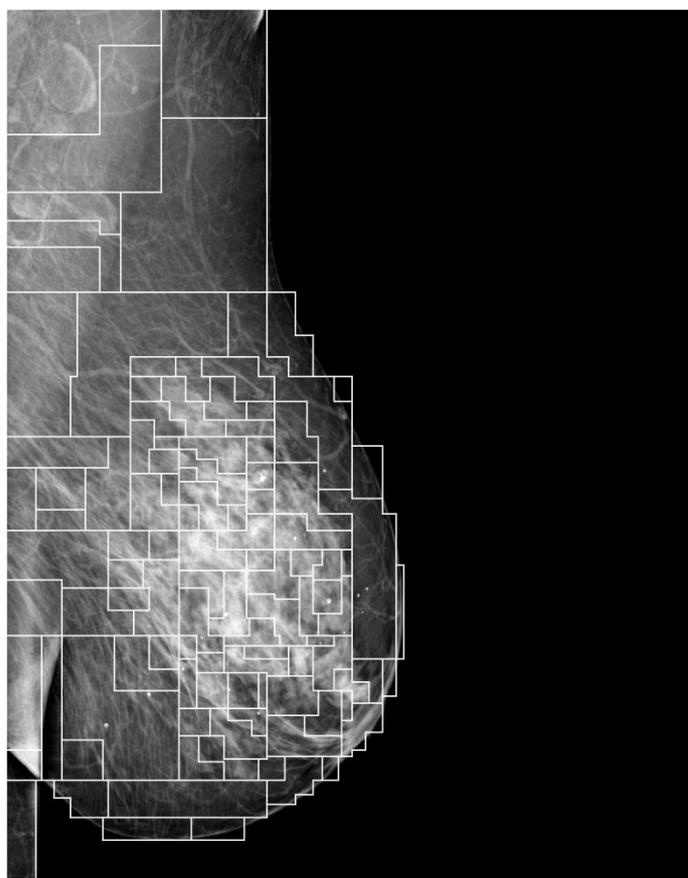


Рисунок 2. Сегментированная рентгенограмма после выполнения алгоритма «снизу вверх»

На следующем (третьем) этапе необходимо классифицировать полученные на втором этапе блоки этой рентгенограммы. Задача алгоритма классификации – цветом или полутоном выделить блоки, полученные на предыдущем этапе, которые соответствуют морфологическим образованиям на рентгенограмме, обусловленным патологией. Формируем множество A «нулевых» пикселей, которое соответствует изображению исходной рентгенограммы. Например, если блоки с патологией будем кодировать полутоном 255, то пиксели множества A кодируем полутоном 0. Если принято решение, что блок W_n содержит патологические морфологические

образования, то в множестве A все пиксели с координатами, попадающими внутрь блока W_n , принимают значение 255. После просмотра всех блоков выводится множество A в виде бинарного изображения.

Анализ экспериментальных результатов по обработке изображений рентгенограмм молочной железы с онкологическими образованиями показал эффективность предложенного метода выделения патологических сегментов рентгенограмм молочной железы с морфологическими образованиями, обусловленными онкологическими заболеваниями.

Библиографический список

1. Филист, С.А. Формирование признакового пространства для задач классификации сложноструктурируемых изображений на основе спектральных окон и нейросетевых структур / С.А. Филист, К.Д. Али Кабус, А.А. Кузьмин//Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. – 2016. -4 (67). – С. 56-68.
2. Wilkie, J.R. Comparison of radiographic texture analysis from computed' radiography and bone densitometry systems / J.R. Wilkie, M.L. Giger, M.R. Chinander Med. Phys. – 2004. – Vol. 31. – Pp. 882-891.
3. Павлидис Т. Алгоритмы машинной графики и обработки изображений: Пер. с англ. – М.: Радио и связь, 1986. – 400 с.

METHOD AND ALGORITHMS OF SEGMENTATION OF BREAST GEL X-RAYS

Dabagov Anatoly R.

AO Medical Technologies Ltd.

105264, Russia, Moscow, 10th Parkovaya Str. 20, apt.64, dar@mtl.ru

Kondrashov Dmitry S., Malyutina Irina A., Filist Sergey A.

Southwestern State University

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

The article presents the development of the method of image segmentation, based on the sequential splitting of the image into quadrants. Before the next division of the preceding quadrants, their boundaries are modified and classified into “divisible” and “not divisible”. The assignment of the quadrant to the maternal is based on the criterion of homogeneity. A modification of the known brightness uniformity criterion was carried out, which allowed the threshold values to be in the range of 0 ... 1. The software implementation of the segmentation process of the radiograph showed the stability and controllability of the segmentation process at different thresholds of the homogeneity criterion.

Key words: breast x-ray, image segmentation, homogeneity predictor, algorithm.

ВОЗМОЖНОСТИ ОРТОДОНТИЧЕСКОГО ЛЕЧЕНИЯ С ИСПОЛЬЗОВАНИЕМ КАПП НА ОСНОВЕ 3D МОДЕЛИРОВАНИЯ

Данилова Марина Анатольевна, Александрова Лариса Игоревна
Пермский государственный медицинский университет им. академика
Е.А. Вагнера, 614000, Россия, г. Пермь, Петропавловская, д. 26,
alexandrova_lar@mail.ru

Козлова Елизавета Васильевна
АО «Медси 2», 123022, Россия, г. Москва, Красная Пресня, д. 16,
respectroxy@mail.ru

В статье представлены отдельные результаты ортодонтического лечения с использованием капп на основе 3D моделирования. Проведен сравнительный анализ результатов лечения пациентов с применением элайнеров и эджуайс-техники.

Ключевые слова: элайнеры, каппы, 3D моделирование.

На сегодняшний день одним из передовых направлений цифровой медицины являются аддитивные технологии. Современная диагностика в ортодонтии представляется сложной без 3D цефалометрии, позволяющей иметь точнейшие индивидуальные расчёты всех плоскостей, углов и расстояний. Полученные параметры используются Cad/Cam системами, применяемыми для создания ортодонтических элайнеров.

Для индивидуального 3D моделирования плана лечения и изготовления элайнеров стоматолог ортодонт отправляет в лабораторию 3D Smile (г. Москва) сверхточные двуслойные оттиски зубных рядов верхней и нижней челюсти. В лаборатории полученные оттиски сканируют и проводят виртуальное 3D моделирование плана лечения по рецепту врача. При этом точность расчета перемещения каждого зуба измеряется в микронах, что обеспечивает точное запрограммированное перемещение каждого зуба и гарантированный результат лечения. Таким образом, результат лечения и его длительность спрогнозированы заранее.

После согласования плана лечения с пациентом производится сверхточная 3D печать комплекта элайнеров, который направляется ортодонту для начала лечения.

Целью нашего исследования было оценить биометрические показатели лечения с использованием элайнеров 3D Smile у пациентов со скученным положением зубов во фронтальном отделе нижней челюсти.

Для этого мы проводили оценивали результаты лечения 30 человек в возрасте от 18 до 25 лет с использованием элайнеров 3D Smile и сравнивали

полученные параметры с результатами лечения пациентов с использованием эджуайс-техники. Все показатели определялись по следующей схеме: до начала лечения и через 6 месяцев от начала лечения.

Биометрическое исследование проводилось с использованием методики Пона, измерением пропорциональности зубных рядов по методу Герлаха, проведением анализ количества места в зубном ряду по методике Нансе [3,4].

Обработка результатов исследования проводилась с использованием пакетов прикладных программ Microsoft Office® 365 (Microsoft Corporation, Seattle, USA), Microsoft Excel и SPSS Statistics 17.0.

Результаты проведённого исследования показали, что до лечения показатели нормы для верхней и нижней челюсти отличались от показателей, полученных у пациентов группы исследования, и были больше, как в отношении ширины зубных рядов на уровне резцов, клыков и моляров, так и в отношении длины переднего участка и общей длины зубных дуг. Данные различия были статистически значимыми ($p \leq 0,05$).

При изучении пропорциональности зубных рядов было выявлено, что в среднем центральный сегмент был меньше боковых в среднем на 9 мм, все различия боковых сегментов находились в пределах 3% их длины, что говорило об отсутствии дисгармонии в данных областях. У всех пациентов группы исследования был выявлен дефицит места в зубном ряду, который в среднем составил 3,5 мм.

Эффективность лечения с использованием элайнеров, оцененная в динамике (через 6 месяцев), показала, что параметры верхней и нижней зубной дуги улучшились – увеличилась её ширина и длина ($p \leq 0,01$) и достигли значений нормы. Через 6 месяцев баланс места в зубном ряду становится нейтральным.

Важным критерием эффективности проводимого ортодонтического лечения является динамическая оценка биометрических показателей верхней и нижней зубной дуги [3,4]. Проведенное исследование продемонстрировало, что лечение с помощью элайнеров 3D Smile показывает высокие результаты при оценке данных показателей.

Библиографический список

1. Гвоздѐва Л.М., Данилова М.А., Александрова Л.И. Оценка эффективности ортодонтического лечения с использованием элайнеров. *Dental Forum*. 2018; 4: 17.
2. Гвоздѐва Ю.В., Царькова О.А., Данилова М.А. Оценка гармоничности профиля лица у детей при различных видах миофункциональных нарушений / *Казанский медицинский журнал*. 2010; 2: 173-176.
3. Данилова М.А., Александрова Л.И., Сирина Н.В. Анализ отдельных результатов раннего ортопедического лечения детей с врождёнными расщелинами верхней губы и нѐба/ *Dental Forum*. 2017; № 4: 22-23.
4. Данилова М.А., Царькова О.А., Фанакин В.А., Патлусова Е.С. Структурно-функциональные особенности жевательной мускулатуры

у детей в возрастном аспекте. Уральский медицинский журнал. 2015; 8(131): 82-86.

THE POSSIBILITIES OF ORTHODONTIC TREATMENT WITH THE USE OF ALIGNERS BASED ON 3D MODELING

Danilova Marina A., Alexandrova Larisa I.

Perm State Medical University n. a. academician E.A.Wagner
614000, Russia, Perm, Petropavlovskaya, d. 26, alexandrova_lar@mail.ru

Kozlova Elizabeth V.

Company «Medci 2», 123022, Russia, Moscow, Krasnaya Presnya, d. 16,
respectroxy@mail.ru

The article presents some results of the orthodontic treatment with the use of aligners based on 3D modeling. Comparative analysis of the results of treatment of patients with the use of aligners and edgeways technology is carried out.

Key words: aligners, mouth guard, 3D modeling.

РАННЯЯ ДИАГНОСТИКА ОСТРОГО КОРОНАРНОГО СИНДРОМА С ПОМОЩЬЮ НЕЙРОСЕТЕВОЙ ТЕХНОЛОГИИ

Думлер Андрей Артурович

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 ранней диагностики острого коронарного синдрома, относящегося к одной из главных проблем современной медицины. Обнаруженные методом математического моделирования закономерности и следующие из них выводы при их повсеместном внедрении способны оптимизировать выявление данного состояния и ускорить оказание медицинской помощи.

Ключевые слова: система диагностики, острый коронарный синдром, инфаркт миокарда, нестабильная стенокардия, нейронная сеть.

Острый коронарный синдром (ОКС) – термин, обозначающий любую группу признаков и симптомов, позволяющих подозревать инфаркт миокарда (ИМ) или нестабильную стенокардию (НС) с высоким риском развития ИМ [1]. ОКС является непосредственной угрозой жизни пациента и повод для его немедленной госпитализации. Ежегодно до 2,5 миллионов пациентов в мире госпитализируются с этим диагнозом. В индустриально развитых странах заболеваемость ОКС составляет 6 на 10000 населения [2].

Для обеспечения наилучших результатов лечения очень важны действия, которые будут производиться после первого контакта пациента с сотрудниками, имеющими медицинское образование (врачи и фельдшера скорой помощи, поликлиники) и сроки, в которые эти действия будут произведены. Это значит, сотрудники первичного медицинского звена должны быть вооружены технологиями, позволяющими наиболее быстрое выявление ОКС.

Для оптимизации диагностики ОКС нами был использован ресурс нейротаке «Нейросимулятор-5.0» [4].

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. Нейронные сети, составляющие основу интеллектуальной системы, обучены на статистической информации, сформированной с помощью данных о пациентах отделения неотложной кардиологии ГАУЗ ПК ГKB №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 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.

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 систем, предназначенных для ранней диагностики, прогнозирования появления и развития заболеваний во времени, нами использованы экспертные знания международной шкалы SCORE, метод «скользящего окна», а также ряд специфических приемов, являющихся ноу-хау разработчиков [4-7].

Система была обучена на примере 1200 пациентов с ОКС, находящихся на лечении в Отделении неотложной кардиологии ГАУЗ ПК ГКБ№4 г.Перми. Диагноз каждого пациента был верифицирован всеми доступными методами. В обучающее множество вошли пациенты с ИМ (различных клинических форм и локализаций) и НС. Перед нейросетевым анкетированием каждый пациент дал информированное согласие на исследование.

Для серии компьютерных экспериментов были выбраны 100 больных, перенесших ОКС, диагноз которых был впоследствии конкретизирован. 50 пациентов страдали ИМ, 50 – НС. Нами была запущена нейронная сеть, выполняющая «Самостоятельное обследование» клиента, из расчета, что им будет пользоваться работник первичного медицинского звена, не вооруженный сложным медицинским оборудованием.

В результате исследований, выявлена средняя степень точности постановки диагнозов. Выяснилось, что данная интеллектуальная сеть достаточно эффективна в выявлении инфаркта миокарда – 87,0%. Хуже выявлялась стенокардия нестабильная – 64,5%. Фоновое заболевание – гипертоническая болезнь – 74,2%. Осложнение ИМ – острая левожелудочковая недостаточность подтверждена в 74,2%. За 100-процентный результат принято заключение врача-эксперта, подкрепленное лабораторными и инструментальными методами обследования.

Заключение. Приведенные результаты компьютерных экспериментов позволяют нам рекомендовать нейросеть в варианте «Первичное обследование» как методику ранней диагностики ОКС, прежде всего для медицинских работников первичного звена.

Библиографический список

1. Кардиология: национальное руководство/ под ред. Ю.Н.Беленкова, Р.Г.Оганова. – М., : ГЭОТАР-Медиа, 2011. – 1232 с.
2. Приказ МЗ РФ от 01.07.2015 405 ан.
3. Нейросимулятор 5.0 : Свидетельство Роспатент о государственной регистрации программы для ЭВМ № 2014618208 от 12.07.2014 г. / Черепанов Ф.М., Ясницкий Л.Н. (РФ).
4. Yasnitsky L.N., Dumler A.A., Poleshchuk A.N., Bogdanov S.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, 8 pages.
5. 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.
6. Ясницкий Л.Н., Черепанов Ф.М. Нейроэкспертная система диагностики, прогнозирования и управления рисками сердечно-сосудистых заболеваний // *Прикладная математика и вопросы управления*. 2018. № 3. С. 107-126. DOI: 10.15593/2499-9873/2018.3.08.
7. Yasnitsky L.N., Dumler A.A., Cherepanov F.M. The Capabilities of Artificial Intelligence to Simulate the Emergence and Development of Diseases, Optimize Prevention and Treatment Thereof, and Identify New Medical Knowledge // *Journal of Pharmaceutical Science and Research*. 2018. Vol. 10(9). Pp. 2192-2200

EARLY DIAGNOSTICS OF ACUTE CORONARY SYNDROME USING NEURAL NETWORK TECHNOLOGY

Dumler, Andrey A.

Perm State Medical University n. a. academician E.A. Wagner
614000, Russia, Perm, Petropavlovskaya, d. 26, ivan.ivanovskii.2000@mail.ru

Yasnitsky Leonid N.

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

Cherepanov Fyodor M.

Perm State Humanitarian-Pedagogical University,
614000, Russia, Perm, Pushkin str, 42, fe-c@yandex.ru

The article describes the experience of the development and application of the neural network system for the early diagnosis of acute coronary syndrome, which is one of the main problems of modern medicine. The regularities found by the method of mathematical modeling and the conclusions that follow from them, with their universal introduction, are capable of optimizing the detection of this condition and speeding up the provision of medical care.

Key words: diagnostic system, acute coronary syndrome, myocardial infarction, unstable angina, neural network.

СИСТЕМА КОРРЕКЦИИ ФУНКЦИОНАЛЬНОГО СОСТОЯНИЯ ОРГАНИЗМА ЧЕЛОВЕКА НА ОСНОВЕ МЕДИЦИНСКОГО МОНИТОРИНГА ПАРАМЕТРОВ ВНУТРЕННИХ ОРГАНОВ

Подмастерьев Константин Валентинович

Орловский государственный университет имени И.С. Тургенева
302026, Орел, ул. Комсомольская, д. 95, asms-orel@mail.ru

*Забанов Денис Станиславович, Савинов Денис Юрьевич,
Мирошников Андрей Валерьевич*

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

В статье рассматриваются вопросы построения систем управления терапевтическими воздействиями. Предложена схема мета-анализа для выбора контролируемых медико-биологических параметров, в качестве которых предложено использовать параметры внутренних органов человека. Рассмотрен пример системы управления магнитотерапией простатита, иллюстрирующий предложенные методы и алгоритмы управления в живых системах.

Ключевые слова: мета-анализ, суррогатные маркеры, система управления эффективностью терапевтического воздействия.

Темп современной жизни зачастую не оставляет времени на прохождение диагностики и лечение в медицинских учреждениях. Поэтому наиболее актуальны разработки в области создания систем управления, позволяющих оперативно производить измерения функциональных параметров и коррекции состояния организма человека в процессе его жизнедеятельности. С этой целью необходима иметь не только эффективные средства восстановления нарушенной поливариантной системы, но и совокупность медико-биологических сигналов и данных, позволяющих эффективно управлять этим процессом.

Для мониторинга восстановления нарушений поливариантной системы необходимо выбрать мишень – медико-биологический параметр, обладающий наибольшей чувствительностью к лекарственному препарату или экзогенному фактору, и совокупность клинических или эпидемиологических показателей, позволяющих оценить уровень здоровья в экспериментальной группе или промышленном кластере. На рисунке 1 представлена структурная схема мета-анализа, предназначенная для поиска таких показателей [1].

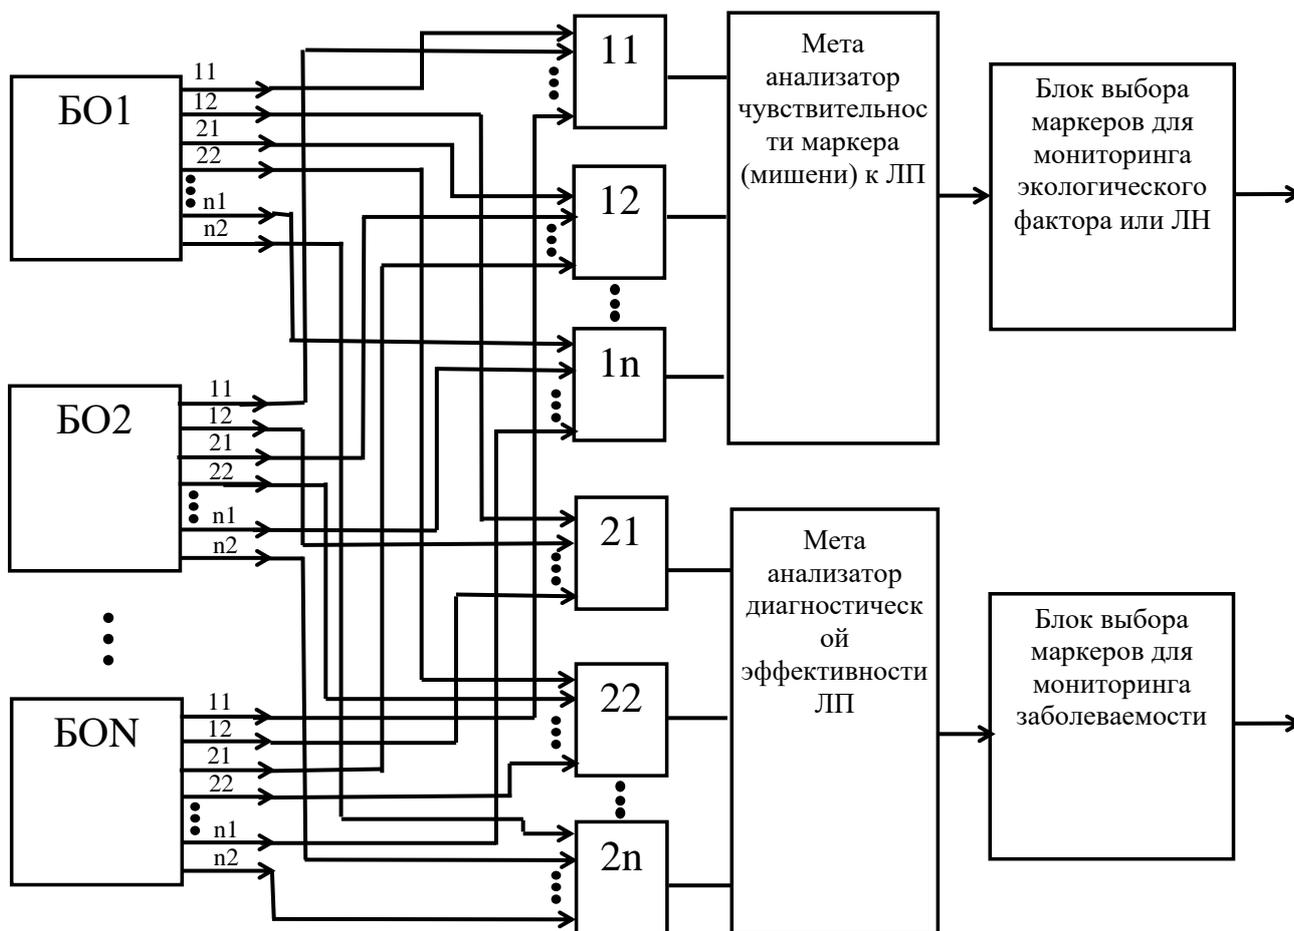


Рисунок 1. Структурная схема мета-анализа для выбора маркеров (мишеней) для лекарственных препаратов (ЛП) и выбора маркеров эффективности лекарственных назначений (ЛН) или побочных реакций (ПР)

Блоки БО1...БОН подвергаются воздействию одного и того же лекарственного препарата (плана лечения) или одного и того же экзогенного фактора. Блоки 11...1n являются классификаторами, обученными на классификацию маркера, а блоки 21...2n – классификаторы, обученные на классификацию степени тяжести или уровня заболеваемости исследуемой патологии.

Алгоритм мета-анализа для оценки эффективности лекарственных назначений или побочных реакций включает следующие основные шаги. Шаг 1. Выбирается маркер (мишень) или маркеры, обладающие чувствительностью к заболеванию или побочной реакции, включенному в мета-анализ. Шаг 2. Выбирается совокупность экспериментальных выборок с пациентами, проходящими лечение исследуемой патологии исследуемым лекарственным препаратом. Шаг 3. Синтезируется решающее правило по определению эффекта лекарственного назначения или побочной реакции на основе клинических показаний. Шаг 4. Синтезируется решающее правило по определению эффекта лекарственного назначения или побочной реакции на основе выбранных маркеров. Шаг 5. Определяем контрольные (реперные)

точки по определению эффективности лекарственных назначений или побочных реакций. Шаг 6. Вычисляется эффект лекарственного назначения или побочную реакцию для каждого пациента в каждой обучающей выборке в текущей реперной точке по клиническим показателям. Шаг 7. Вычисляется эффект лекарственного назначения или побочную реакцию для каждого пациента в каждой обучающей выборке в текущей реперной точке по выбранному маркеру. Шаг 8. Если не пройдены все реперные точки, то вернуться к Шагу 6. Шаг 9. Определяются статистические показатели в экспериментальных выборках, по которым строим многомерные модели влияния лекарственного назначения на выбранные маркеры эффективности лекарственных назначений или побочных реакций. Шаг 10. Вычисляется достоверность полученных моделей.

Мета-анализ, проведенный по представленному алгоритму, показал, что для осуществления управления терапевтическим процессом в качестве индикаторов целесообразно выбрать медико-биологические показатели внутренних органов человека, как наиболее чувствительные к нарушению гомеостаза и наименее чувствительные к изменению параметров внешней среды.

Рассмотрим в качестве примера интеллектуально управляемой терапии систему мониторинга магнитотерапии простатита [2]. Магнитотерапия заключается в том, что при лечении больных простатитом, включающем курсовое воздействие электромагнитным излучением на предстательную железу после эндоректального ввода индуктора (аппликатора) и последующей коррекции параметров этого излучения в зависимости от динамики изменения показателей микроциркуляций (суррогатных маркеров) в окрестности предстательной железы в качестве показателей микроциркуляций используют информативные признаки, получаемые с фотоэлектрического датчика и датчика температуры, установленных на поверхности корпуса аппликатора.

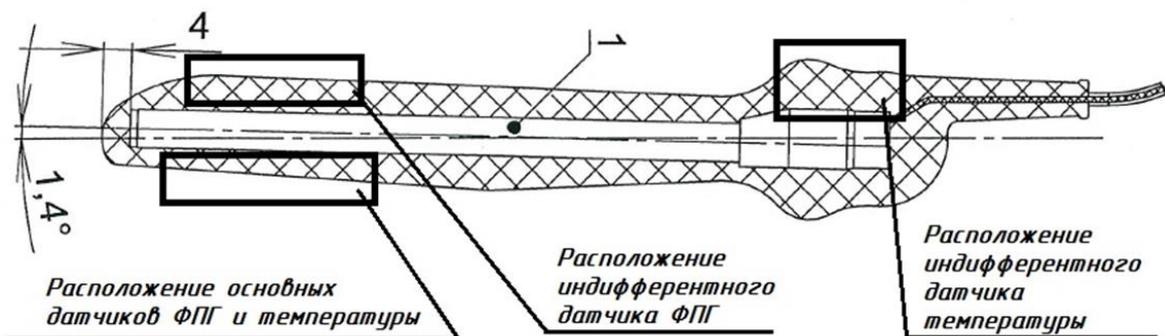
Основная задача управляемой магнитотерапии состоит в том, чтобы выделить из информативных признаков те составляющие, которые обусловлены воздействием магнитного поля на биоматериал. В таком случае у врача появится возможность путем подбора параметров магнитного поля влиять на эти информативные признаки, а, следовательно, контролировать терапевтический эффект.

При магнитотерапии простатита использовался аппликатор аппарата УЛП-01-ЕЛАТ. Фотография аппликатора аппарата УЛП-01-ЕЛАТ представлена на рисунке 2а. На аппликаторе имеется технологическое плато, которое было использовано для установки инфракрасного излучателя и приемника инфракрасного излучения. Датчик размещен вдоль области аппликатора, указанной на рисунке 2б, приблизительно по центру данного скоса, при этом не имеет значения последовательность «фототранзистор-светодиод» или «светодиод-фототранзистор» относительно концевой части аппликатора.

Аппликатор рисунок 2а после ректального ввода устанавливается в окрестности предстательной железы, снимается фотоплетизмосигнал посредством пары светодиод-фотодиод, установленной на плато аппликатора (рисунок 2б), определяются статистические параметры информативных признаков, и по их показателям корректируется терапевтическое магнитное поле.



а)



б)

Рисунок 2. Фотография аппликатора аппарата УЛП-01-ЕЛАТ (а) и схема расположения датчиков регистрации ФПГ и температуры на аппликаторе (б)

На рисунке 3 представлена структурная схема системы мониторинга медико-биологических показателей внутренних органов человека при лечении предстательной железы. Выходные напряжения датчиков фотоплетизмограммы достаточно сильно подвержены влиянию двигательных помех, что вызывает необходимость в разработке методики съема информации с аппликатора с медицинской стороны и конструктивного усовершенствования аппликатора с технической стороны, поэтому в системе используются два канала фотоплетизмосигнала и два датчика температуры.

При магнитоуправляемой терапии контролируются не сами информативные признаки, величины которых могут быть обусловлены как конституцией пациента, так и сопутствующими заболеваниями, а динамика изменения выделенных показателей.

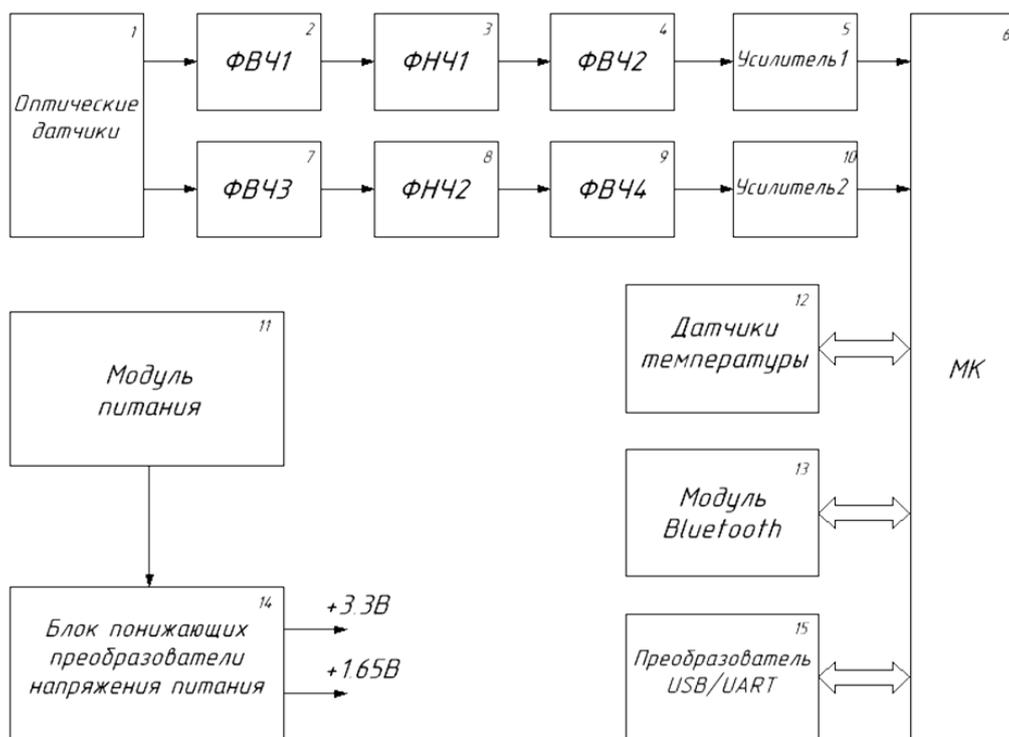


Рисунок 3. Структурная схема системы мониторинга медико-биологические показатели внутренних органов человека при лечении предстательной железы

В качестве показателей, которые контролируются в процессе магнитотерапии, выбраны статистические параметры информативных признаков. Коррекция функционального состояния реализована посредством нейросетевых классификаторов [3].

Библиографический список

1. Филист, С.А. Нейросетевые модели для мета-анализа медико-экологических данных / С.А. Филист, А.Г. Курочкин, В.В. Протасова, А.Н. Шуткин // Нейрокомпьютеры: разработка, применение. – 2015. № 6. – С.42-48.
2. Филист, С.А. Магнитотерапия простатита с биологической обратной связью по оптическому каналу связи / С.А. Филист, Д.С. Забанов, А.А. Трифонов // Физика и радиоэлектроника в медицине и экологии: Доклады XIII – й межд. Научн. конф. Книга 1 – Владимир: 2018. С. 147-153.
3. Филист, С.А. Разработка и исследование метода и алгоритмов для интеллектуальных систем классификации сложноструктурируемых изображений/ С.А. Филист, В.С. Белых, М.А. Ефремов // Известия Юго-Западного государственного университета. Серия: Управление,

вычислительная техника, информатика. Медицинское приборостроение. 2016. № 2 (19). – С. 12-24.

METHOD AND ALGORITHMS OF SEGMENTATION OF BREAST GEL X-RAYS

Podmaster'ev Konstantin V.
Orlovskiy State University imeni I.S. Turgeneva
302026, Orel, ul. Komsomol'skaya, d. 95, asms-orel@mail.ru

Zabanov Denis S., Savinov Denis Y., Miroshnikov Andrey V.
Southwestern State University
305040, Russia, Kursk, street 50 years of October, 94, SFilist@gmail.com

The article deals with the construction of management systems for therapeutic effects. A meta-analysis scheme has been proposed for the selection of controlled biomedical parameters, for which it is proposed to use the parameters of human internal organs. An example of a prostatitis magnetotherapy control system is considered that illustrates the proposed methods and control algorithms in living systems.

Key words: meta-analysis, surrogate markers, therapeutic effects management system.

ЭФФЕКТИВНОСТЬ КЛАССИФИКАЦИИ И ВАРИАЦИИ ХАРАКТЕРНЫХ ОБЛАСТЕЙ ДВУМЕРНЫХ ТЕРМОМЕТРИЧЕСКИХ ПРИЗНАКОВ В ДИАГНОСТИКЕ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ

Зенович Андрей Васильевич, Петренко Александр Юрьевич
Волгоградский государственный университет,
400062, Россия, г. Волгоград, пр-т. Университетский, 100,
zenovich@rambler.ru, kkamikadzee@yandex.ru

В данной работе рассматривается задача ранней диагностики онкологических заболеваний молочных желез методом комбинированной термометрии. Предложена технология формирования двумерных признаков диагностики методом сужающихся эллипсов. Полученные таким образом признаки использованы для диагностики пациентов методом логистической регрессии. Вычислительные эксперименты показали, что эффективность алгоритма составляет 85-86%. Исследуется взаимное влияние чувствительности и специфичности друг на друга. Предложены вариации характерных областей двумерных признаков, позволяющие при фиксированной чувствительности добиваться максимальной специфичности, и наоборот.

Ключевые слова: микроволновая термометрия, алгоритмы диагностики, интеллектуальный анализ данных

Проблема ранней диагностики онкологических заболеваний молочных желез – одна из важнейших задач современной медицины. Одним из популярных и быстроразвивающихся методов решения данной проблемы является метод комбинированной (радио и инфракрасной) термометрии, позволяющий на ранней стадии определить температурную аномалию, соответствующую опухоли (см [1],[2]). Достоинствами метода является его неинвазивный характер и отсутствие облучения в процессе исследования. Обследование пациентки заключается в измерении температуры в РТМ и ИК диапазонах в большом количестве точек молочной железы. Методика обследования подробно изложена в [1]. По результатам обследования каждому пациенту ставится в соответствие вектор из 44 температур.

Попытки классификации на основе только температурных данных не являются достаточно эффективными. Для повышения эффективности диагностики используются математические модели медицинских качественных температурных признаков. Медиками найдены [5] следующие качественные признаки онкологических заболеваний молочной железы: наличие повышенной величины термоасимметрии между одноименными точками молочных желез; повышенный разброс температур между отдельными точками в пораженной молочной железе; повышенная разница

температур сосков; повышенная температура соска в пораженной молочной железе по сравнению со средней температурой молочной железы с учетом возрастных изменений температуры; повышенная разница кожной и глубинной температур и некоторые другие. Каждый медицинский признак можно моделировать, изучая области изменения некоторых функций от вектора температур. Известно (см. [1],[3]) около полутора тысяч таких моделирующих функций, на которых можно основывать алгоритмы классификации, разработаны технологии построения минимальных наборов признаков на основе данных функций (см. [1]) и способы получения из набора функций одной моделирующей функции, достаточно полно описывающей соответствующий медицинский признак (см. [1],[2]).

Взаимное влияние медицинских признаков друг на друга можно моделировать, строя двумерные признаки. Для этого берутся две функции, описывающие различные медицинские признаки. Каждому пациенту из обучающей выборки ставится в соответствие точка на плоскости, координатами которой являются значения двух наших функций на температурном векторе пациента. Возникает геометрическая задача построения минимальной выпуклой области, внутри которой находятся все (или подавляющее большинство) точек, отвечающих здоровым пациентам. Если такая область построена, то при диагностике считаем не попавшего в эту область пациента больным. Мерой эффективности признака будем считать среднее геометрическое чувствительности (доли верно диагностированных больных) и специфичности (доли верно диагностированных здоровых).

В качестве фигуры, приближающей выпуклую область, будем брать эллипс. Сначала строим основной эллипс, внутри которого лежат все здоровые пациенты из обучающей выборки, пользуясь для этой цели известным алгоритмом Хачияна. Далее будем сужать данный эллипс, пока не достигнем максимальной эффективности. Для этого последовательно выбрасываем точки, соответствующие здоровым пациентам, проводим эллипс, включающий все оставшиеся, а потом варьируем его полуоси. Из полученного двухпараметрического семейства эллипсов выбираем эллипс с наибольшей эффективностью.

С помощью данного алгоритма авторами был получен набор из 15 обобщенных двумерных признаков. В работе [4] приведены результаты вычислительных экспериментов, показывающих, что лучшие такие признаки дают эффективность около 80%.

Данный набор признаков был использован для построения классификатора методом логистической регрессии. Проводились вычислительные эксперименты, позволяющие оценить эффективность данного классификатора. Обучающая выборка состояла из 115 здоровых и 62 больных раком пациенток. Эффективность оценивалась с учетом кросс – валидации. Проводилась К-блочная проверка эффективности алгоритма. Выборка делилась на К частей, после чего на (К-1)-й части проходило обучение алгоритма, а на оставшейся части алгоритм тестировался с целью

оценки реальной эффективности. Результаты вычислительных экспериментов приведены в таблице 1. Было взято $K=10$, средняя эффективность алгоритма составила 86%.

Таблица 1. Оценка эффективности классификатора

Номер эксперимента	Специфичность	Чувствительность	Эффективность
1	0.88	0.73	0.80
2	1.0	0.88	0.94
3	0.83	0.86	0.85
4	0.88	0.9	0.89
5	0.86	1.0	0.93
6	0.8	1.0	0.89
7	0.73	1.0	0.86
8	0.66	1.0	0.82
9	1.0	0.71	0.85
10	0.75	0.72	0.74

Рассматривалась задача использования полученных двумерных признаков для создания классификатора, настраиваемого медиком. Зачастую при осмотрах различных групп пациентов врачу может понадобиться задавать различный уровень чувствительности классификатора. Например, если проводится профилактический осмотр группы студенток, логично задать высокий порог чувствительности, чтобы гарантированно определить пациентку даже с небольшими подозрениями на раковую опухоль с целью дальнейшего обследования пациентки другими методами диагностики (маммографией и т.п.). Если же проводится обследование группы пожилых пациенток, зачастую необходимо понизить порог чувствительности, тем самым повышая специфичность, чтобы людей с возрастными изменениями и небольшими температурными аномалиями классификатор отнес к здоровым.

С целью создания такого классификатора проводились вычислительные эксперименты, при которых задавалось пороговое значение чувствительности и при данном значении вычислялась максимальная специфичность. На рисунке 1 изображен график зависимости специфичности от чувствительности для одного из двумерных признаков.

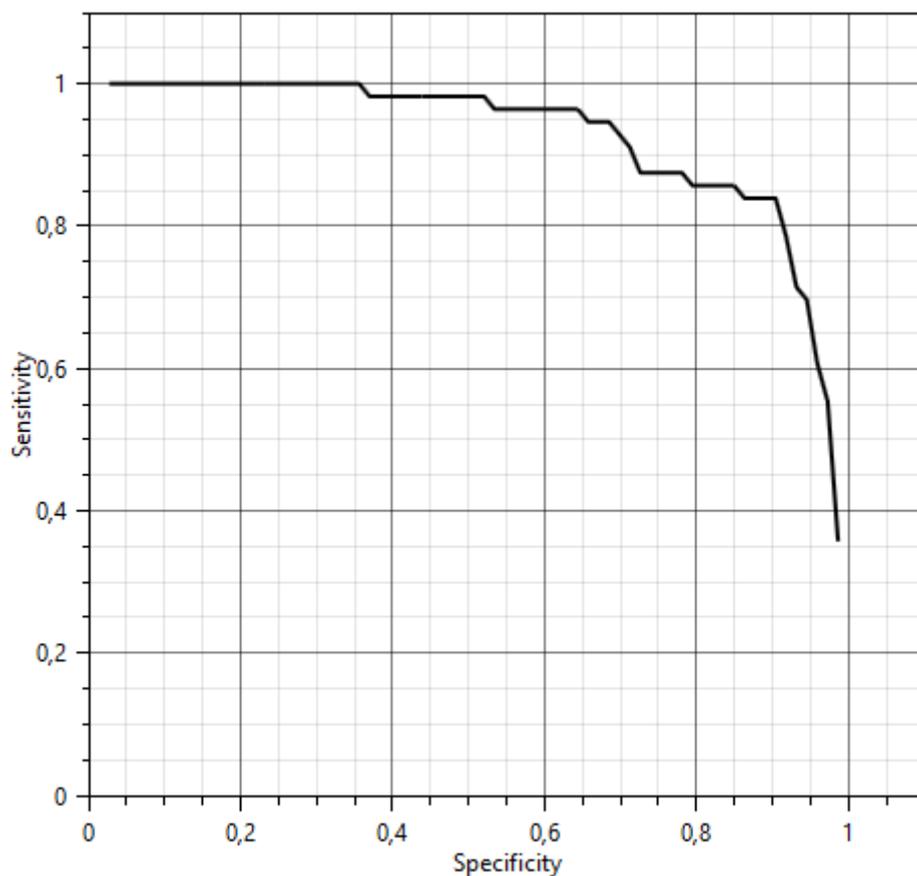


Рисунок 1. Зависимость чувствительности от специфичности

Видно, что на графике есть достаточно большая область изменения чувствительности (60-90%), при которой достигается достаточно высокая специфичность. Данный эффект позволяет использовать двумерные признаки при создании настраиваемого классификатора.

Исследование выполнено при финансовой поддержке РФФИ, проект № 18-47-34004.

Библиографический список

1. Лосев А. Г. Интеллектуальный анализ термометрических данных в диагностике молочных желез / А. Г. Лосев, В. В. Левшинский // Управление большими системами. 2017. №. 70. С. 113–135.
2. Лосев А. Г. Интеллектуальный анализ данных микроволновой радиотермометрии в диагностике рака молочной железы / А. Г. Лосев, В. В. Левшинский // Математическая физика и компьютерное моделирование. 2017. Т. 20, № 5. С. 49–62.
3. Зенович А. В. Алгоритмы классификации заболеваний парных органов на основе нейросетей и нечетких множеств / А. В. Зенович, В. И. Гребнев, Ф. Г. Примаченко // Математическая физика и компьютерное моделирование. 2017. Т. 20, № 6. С. 26–37.
4. Зенович А.В. Алгоритмы формирования двумерных признаков диагностики заболеваний молочных желез методами комбинированной радиотермометрии / А.В. Зенович, Н.А. Батулин, Д.А. Медведев, А.Ю.

Петренко // Математическая физика и компьютерное моделирование. 2018. Т. 21. № 4. С. 44 – 56.

5. Лосев А.Г., Левшинский В.В. Интеллектуальный анализ данных микроволновой радиотермометрии в диагностике рака молочной железы // Математическая физика и компьютерное моделирование. Волгоград, 2017, Т.20, №5. С.49-62.

NEURAL NETWORKS IN THE DIAGNOSIS OF BREAST CANCER

Zenovich Andrey Vasilyevich

Volgograd State University,
400062, Russia, Volgograd, Universitetskiy pr., 100,
zenovich@rambler.ru

Petrenko Aleksandr Yur'yevich

Volgograd State University,
400062, Russia, Volgograd, Universitetskiy pr., 100,
kkamikadzee@yandex.ru

In this paper, we consider the problem of early diagnosis of oncological diseases of the mammary glands by the method of combined thermometry. A technology for the formation of two-dimensional signs of diagnosis by the method of narrowing ellipses is proposed. The signs obtained in this way were used to diagnose patients by the method of logistic regression. Computational experiments have shown that the efficiency of the algorithm is 85-86%. The mutual influence of sensitivity and specificity on each other is investigated. Variations of the characteristic regions of two-dimensional features are proposed, which allow for maximum specificity to be achieved at a fixed sensitivity, and vice versa.

Keywords: microwave thermometry, diagnostic algorithms, data mining

ИНТЕЛЛЕКТУАЛЬНАЯ ИНФОРМАЦИОННО-АНАЛИТИЧЕСКАЯ СРЕДА ДЛЯ МОНИТОРИНГА СОСТОЯНИЯ ОБУЧАЮЩИХСЯ

*Истомина Татьяна Викторовна, Петрунина Елена Валерьевна,
Никольский Анатолий Евгеньевич*

Московский государственный гуманитарно-экономический университет
107150, Россия, г. Москва, ул. Лосиноостровская, 49,
petrunina@mggeu.ru

В статье описан опыт разработки интеллектуальной информационно-аналитической среды для мониторинга состояния обучающихся, связанных, прежде всего, с нарушениями функционирования нервной, опорно-двигательной и сердечно-сосудистой систем. Представлена обобщенная структура интеллектуальной информационно-аналитической среды, позволяющей анализировать разнородные слабоструктурированные данные. Сформирована обобщенная информационная модель представления результатов мониторинга состояния различных функциональных систем обучающихся на примере описания кардиальных событий. Для практической реализации предложено применить нейро-нечеткие алгоритмы, с использованием процедуры перехода от инвариантности параметров по времени к их инвариантности по группе студентов.

Ключевые слова: интеллектуальные методы анализа, информационно-аналитическая среда, мониторинг состояния обучающихся, функциональные системы.

Одной из главных причин внезапной смертности и инвалидизации в настоящее время являются последствия нервных, опорно-двигательных и сердечно-сосудистых заболеваний. Этим объясняется актуальность решения задач, связанных с повышением эффективности профилактики этих заболеваний, особенно, у обучающихся с различными функциональными нарушениями. Такие задачи относятся к классу интеллектуальных и интенсивно решаются отечественными и зарубежными учеными, но исследования далеки от завершения. Сложность решения данной проблемы связана с необходимостью анализа больших слабоструктурированных данных, требующего применения современных интеллектуальных методов, математического моделирования и модульно-графического программирования, а также интенсивного междисциплинарного взаимодействия квалифицированных специалистов в области медицины, программирования и биомедицинской инженерии [1].

Анализ современного состояния исследований в данной области показал актуальность создания на основе применения современных когнитивных и конвергентных подходов интеллектуальной информационно-аналитической среды (ИИАС) для мониторинга состояния обучающихся,

связанных с нарушениями функционирования нервной, опорно-двигательной и сердечно-сосудистой системы (ССС), разработки специализированных алгоритмов интеллектуального анализа, позволяющих находить скрытые закономерности в разнородных данных и формировать индивидуализированные рекомендации по корректировке учебного процесса и профилактике заболеваний.

Ранняя комплексная профилактика заболеваний включает сочетание методов двигательной, когнитивной, дыхательной и эмоционально-личностной коррекции, совместно воздействующих на формирование каждой функциональной системы, при этом необходима разработка профилактических методик, адаптированных для особенностей лиц с различными нозологиями.

Для решения задачи слежения за состоянием студентов и построения рекомендаций по индивидуальной траектории обучения и профилактике заболеваний разрабатываются дополнительные средства Data Mining, ориентированные на создание интеллектуальной информационно – аналитической среды, обеспечивающие индивидуальный подход к обследуемому и повышающие информативность визуального представления данных и эффективность профилактики и прогнозирования опасных состояний.

Для решения задач данного класса целесообразно использовать следующие фундаментальные подходы:

- классические вероятностно-статистические методы;
- методы нечеткой математики;
- нейросетевые методы;
- методы экспертных оценок;
- семантические и когнитивные методы.

При этом наиболее эффективными для данных исследований являются: теория нечетких множеств, теория искусственных нейронных сетей, а также когнитивные технологии.

На основе онтологического подхода [2] была создана обобщенная структура ИИАС, схема которой приведена на рисунке. Каждая представленная на рисунке элементарная ячейка представляет собой сервисно-ориентированное приложение (технология SOA), взаимосвязана с остальными элементами ИОС и реализует определенные функции системы и содержит онтологическое описание. Однородные функциональные группы ИИАС выделены определенной цветовой текстурой, что отражает особенности их назначения и применения.

Наиболее важным представляется мониторинг заболеваний ССС, нередко приводящих к внезапной смерти, поэтому разработке методики кардиологического обследования студентов уделено особое внимание. При анализе результатов обследований применяются геометрические аналогии отображения структуры данных, использующие термины многомерных пространств и придающие наглядность задачам прогнозирования возможных кардиальных событий [3].



Рисунок. Обобщенная структура ИИАС

Для прогноза развития событий, характеризующих состояние организма, множество осей n -мерного метрического пространства R_n представим множеством $\Omega\{x_{i,j}\}$, элементы которого $x_{i,j} \in \Omega$ интерпретируют медицинские физиологические показатели, где $i = \overline{1, r}$, $j = \overline{1, s_i}$, r – число методов обследования, s_i – число регистрируемых параметров в каждом методе. Рассматриваемые показатели в силу своей природы всегда содержат случайные составляющие, интерпретируемые множеством $\tilde{\Omega}\{\varepsilon(x_{i,j})\}$.

Множество $\Omega\{x_{i,j}\}$ образует пространство варьируемых параметров $R_\Omega \subset R_{\Omega, \tilde{\Omega}}$ или метрическое пространство состояний с размерностью, равной числу показателей $n = \sum_{i=1}^r s_i$. Все компоненты пространства считаем независимыми, т. е. изменение каждого показателя $x_{i,j}$ не связано с любым другим показателем, поэтому оси пространства образуют ортогональный базис. Поскольку варьируемые параметры имеют различные физическую природу и размерности, то структура описания данных мониторинга неоднородна по пространству R_Ω .

На промежутке прогнозирования Δt множество показателей Ω разделяется на три подмножества $\Omega_q \subset \Omega$, где $q = \overline{1, 3}$:

- Ω_1 – постоянные показатели, для которых на Δt справедливо высказывание, «если сегодня есть, то завтра обязательно есть», например, показатель – «отягощенная наследственность»;

- Ω_2 – условно постоянные показатели, для которых на Δt справедливо высказывание, «если сегодня нет, то завтра может быть» или «если сегодня есть, то завтра может не быть», например, показатель – «курение»;
- Ω_3 – переменные показатели, для которых на интервале наблюдения T_n может быть определен эмпирический закон изменения во времени.

Показателям $x_{i,j,k} \in \Omega_1$ на промежутке прогнозирования Δt присваиваются постоянные значения из интервала $[0,1]$, а показатели $x_{i,j,k} \in \Omega_2$ интерпретируются случайными величинами из интервала $[0,1]$, подчиняющимися нормальному закону распределения (практически задаются с помощью датчика случайных чисел). Все пространство R_Ω разбивается на подпространства $R_{\Omega_k} \subset R_\Omega$, соответствующие возможным событиям (где k – число событий, включающих различные нарушения ССС). Конкретное состояние в момент времени t_l периода наблюдения $T_n = \{t_l\}$, где $l = \overline{1, p}$, p – число обследований, интерпретируется вектором состояния $\vec{\Psi}_l = \{x_{i,j}(t_l)\}$, длина которого $\Lambda(\Psi_l)$ может быть выбрана в качестве прогнозирующей функции. В процессе прогноза могут рассматриваться отдельные компоненты $\vec{\Psi}_{i,l} = \{x_{i,j}(t_l)\}$ вектора состояния $\vec{\Psi}_l$. Эти компоненты с выходов сенсорных систем, данные анкетирования и результаты обследований, а также их длины $\Lambda(\Psi_l)$ используются для оценки прогностических возможностей разных функциональных методов мониторинга состояния обучающихся.

Аналогичным образом в пространстве состояний представляются нарушения функционирования опорно-двигательной и нервной систем.

Структура функциональных событий в общем случае представляется двумя составляющими, отражающими процесс изменения состояния обучающегося и случайные влияющие факторы. Наибольший интерес для использования представляют информационные модели вида:

$$\Lambda(t) = \mu(d, \bar{\alpha}, \bar{\beta}, t) + \begin{cases} \varepsilon_\mu(t), \\ \varepsilon_\sigma(t), \\ \varepsilon_k(t), \\ \varepsilon_{\sigma, A_r, E_k}(t) \end{cases} \quad \text{или} \quad \Lambda(t) = \mu_{\text{АН, ДДИ}}(d, \bar{\alpha}, \bar{\beta}, t) + \begin{cases} \varepsilon_\mu(t), \\ \varepsilon_\sigma(t), \\ \varepsilon_k(t), \\ \varepsilon_{\sigma, A_r, E_k}(t) \end{cases},$$

где $\mu(d, \bar{\alpha}, \bar{\beta}, t)$ – квазидетерминированная составляющая, характеризующая изменение математического ожидания длины вектора состояния;

$\mu_{\text{АН, ДДИ}}(d, \bar{\alpha}, \bar{\beta}, t)$ – квазидетерминированная составляющая, характеризующая изменение математического ожидания длины вектора состояния;

$\varepsilon_\mu(t)$ – случайная составляющая, характеризующая изменения относительно математического ожидания;

$\varepsilon_\sigma(t)$ – случайная составляющая, характеризующая изменения относительно дисперсии;

$\varepsilon_k(t)$ – случайная составляющая, отражающая наличие корреляционных связей в прогнозируемом процессе:

$\varepsilon_{\sigma, A_k, E_k}(t)$ – случайная составляющая, характеризующая нестационарность процесса относительно дисперсии, асимметрии и эксцесса одновременно.

В качестве практической реализации целесообразно применить нейронечеткие алгоритмы с обучением, с использованием процедур перехода от инвариантности параметров по времени к их инвариантности по группе студентов. Инвариантность параметров α_j , β_j по времени позволяет брать для обучения числовые ряды, начинающиеся с любого момента времени, а сам числовой ряд $\{x_1, x_2, \dots, x_N\}$ может также начинаться с произвольного момента времени $t_i \in T_n$.

Представленная обобщенная информационная модель позволяет описывать взаимосвязь факторов разных уровней. Предложенная архитектура ИИАС может быть использована для различных приложений, например, для решения задач превентивной и персонализированной медицины и в экологии [3].

В целом, применение комплексирования современных методов, моделей и технологий сбора и формирования больших баз данных позволяет формировать системы информативных признаков по результатам мониторинга состояния обучающихся, создавать интеллектуальные алгоритмы определения и распознавания нечетких зон их патологических изменений, а также производить динамическую визуализацию разнородных слабоструктурированных данных, создавать и апробировать индивидуализированные рекомендации для профилактики опасных состояний у обучающихся МГГЭУ с различными нозологиями.

Библиографический список

1. Истомина Т.В., Филатов И.А., Сафронов А.И., Пучиньян Д.М., Кондрашкин А.В., Истомин В.В., Загребин Д.А., Карпицкая С.А. Многоканальный сетевой анализатор биопотенциалов для дистанционного управления реабилитацией больных с постуральным дефицитом. – Медицинская техника. – М.: Союз общественных объединений Международное научно-техническое общество приборостроителей и метрологов, 2014. – № 3. – С. 9-14.
2. Никольский А.Е. Онтологическая модель инклюзии. // Естественные и технические науки. 2017, – № 5 (107). – С.189-194.
3. Татарченко И.П., Позднякова Н.В., Шевырев В.А., Соловьева Е.В. Компьютерная система прогнозирования кардиальных событий при ишемической болезни сердца. Монография. I часть. – Пенза, 2006. – 112 с.
4. Коновалова О.Е., Коновалов А.В., Истомина Т.В. Применение муравьиного алгоритма для определения зон с минимальным риском заболевания // XXI век: итоги прошлого и проблемы настоящего плюс. – 2017.– №01(35). – С.16-21.

NTELLIGENT INFORMATION-ANALYTICAL ENVIRONMENT FOR MONITORING STATUS OF STUDENTS

Istomina Tatiana V., Petrunina Elena V., Nikolskiy Anatoliy E.
Moscow State University of Humanities and Economics
107150, Russia, Moscow, Losinistrovskaya Str. 49, petrunina@mggeu.ru

The article describes the experience of developing an intellectual information and analytical environment for monitoring the state of students associated primarily with disorders of the nervous, musculoskeletal and cardiovascular systems. The generalized structure of the intellectual information-analytical environment, which allows to analyze heterogeneous semi-structured data, is presented. The generalized information model of the results of monitoring of the state of different functional systems of students on the example of the description of cardiac events is formed. For practical realization it is offered to apply neuro-fuzzy algorithms, with use of procedure of transition from invariance of parameters on time to their invariance on group of students.

Key words: smart analysis, information-analytical environment, monitored students, functional system.

BI-RADS КЛАССИФИКАЦИЯ ТЕРМОМЕТРИЧЕСКИХ ДАННЫХ В ДИАГНОСТИКЕ МОЛОЧНЫХ ЖЕЛЕЗ

Левшинский Владислав Викторович

Волгоградский государственный университет, 400062, Россия, г. Волгоград,
проспект Университетский, д. 100, v.levshinskii@volsu.ru

В работе выполняется конструирование пространства интерпретируемых признаков в термометрических данных. Выполнено построение алгоритма и приведены результаты бинарной классификации термометрических данных молочных желез, размеченных и сгруппированных в соответствии со шкалой BI-RADS.

Ключевые слова: микроволновая радиотермометрия, интеллектуальный анализ данных, задача классификации.

Разработка эффективных, дешевых и безопасных методов ранней диагностики рака молочных желез является одной из актуальных задач современности. Весьма перспективным в этом плане видится метод микроволновой радиотермометрии, заключающийся в измерении кожных (ИК) и глубинных (РТМ) температур определенных точек молочных желез и последующей регистрации температур в виде числовых данных. Известно, что температурные аномалии предшествуют структурным изменениям в железе [3], поэтому задачей специалиста, по сути, является выявление аномалий в данных обследования.

Сложность применения метода при массовых обследованиях обусловлена несколькими факторами, наиболее значимым из которых является недостаток медицинского персонала, прошедшего специальную подготовку. Из этого фактора следует и другой – недостаточная эффективность методов обработки данных обследования, ведь поиск аномалий только по значениям температур в точках, когда как сами специалисты отмечают, что, прежде всего, следует рассматривать различные их отношения [3], – процесс достаточно долгий и сложный. Все это подчеркивает необходимость разработки интеллектуальной системы, предназначенной для интерпретации и анализа данных обследования. Создание подобных систем подразумевает применение и разработку методов математического и компьютерного моделирования, интеллектуального анализа данных и машинного обучения.

На текущем этапе исследований определенный интерес также представляет возможность классификации данных по международной системе BI-RADS (Breast Imaging Reporting And Data System; система описания и обработки данных лучевых исследований молочной железы) [2].

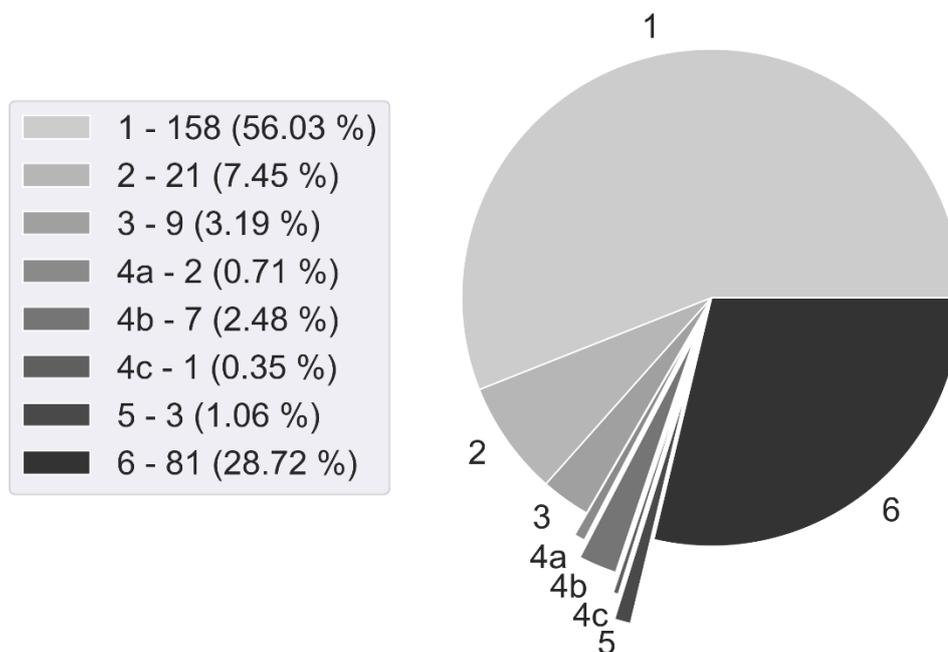


Рисунок 1. Количество пациенток каждого класса

В работе рассматривался набор термометрических данных, предоставленных онкологическими центрами. Каждая пациентка была отнесена к той или иной категории BI-RADS на основе данных анамнеза, диагноза и результатов обследований прочими методами (например, маммография). Категория 0 (требуется дополнительное обследование) была исключена. Таким образом был сформирован набор данных 282 пациенток. Количество пациенток каждого из классов представлено на рис. 1.

Каждая категория характеризуется определенной вероятностью наличия злокачественных новообразований, начиная от 1 и 2 (вероятность равна 0) и заканчивая 6 (наличие подтверждено). Класс 2 отличается от класса 1 наличием структурных изменений (доброкачественное новообразование).

Исходное признаковое пространство содержит 44 значения кожных и глубинных температур в определенных точках молочных желез и опорных точках, расположенных в нижней части грудной клетки. На их основе выполняется синтез новых признаков, характеризующих те или иные особенности поведения температурных полей молочных желез. В формальном виде признаковое описание можно представить следующим образом:

$$(1) x^i = (T_{0,r}^{i,mw}, \dots, T_{9,r}^{i,mw}, T_{0,r}^{i,ir}, \dots, T_{9,r}^{i,ir}, T_{0,l}^{i,mw}, \dots, T_{9,l}^{i,mw}, T_{0,l}^{i,ir}, \dots, T_{9,l}^{i,ir}, T_{0,p}^{i,mw}, T_{1,p}^{i,mw}, T_{0,p}^{i,ir}, T_{1,p}^{i,ir}),$$

где $T_r^{i,mw} = (T_{0,r}^{i,mw}, \dots, T_{9,r}^{i,mw})$ и $T_r^{i,ir} = (T_{0,r}^{i,ir}, \dots, T_{9,r}^{i,ir})$ – соответственно значения глубинных и кожных температур точек 0,...,9 правой железы, аналогично, но с индексом 1, определены температуры левой железы, а

$T_{0,p}^{i,mw}, T_{1,p}^{i,mw}, T_{0,p}^{i,ir}, T_{1,p}^{i,ir}$ – соответственно глубинные и кожные температуры в опорных точках $T1$ и $T2$, i – индекс объекта в наборе.

В ходе интеллектуального анализа данных было рассмотрено множество различных отношений температур, учтены знания экспертов и выдвинуто несколько гипотез о поведении температурных полей [5]:

1. Гипотеза о малой дисперсии температур в здоровом органе, утверждает, что высокий разброс значений температур сигнализирует о наличии отклонений от нормы. Здесь также учитываются и так называемые внутренние градиенты – отношения кожных и глубинных температур, а также разброс значений температур относительно опорных точек и соска (точка 0). В качестве характеристик, описывающих подобный эффект, предлагаются, например, функционалы вида:

a. $p_1(T) = \max_{t \in T \setminus \{T_0\}} |T_0 - t|$, и, в случае для (1):

$$f_1(x^i) = p_1(T_r^{i,mw}), f_2(x^i) = p_1(T_l^{i,mw}) \text{ и т.д.}$$

b. $f_3(x^i) = p_2(T_l^{i,g})$, где $p_2(T) = \max_{t \in T} |t|$, а $T_l^{i,g} = T_l^{i,mw} - T_l^{i,ir}$ – внутренние градиенты температур левой железы;

2. Гипотеза о зеркальной симметрии температурных полей в здоровом органе утверждает, что повышенная разница значений температур (или прочих характеристик, например, средних значений температур в подобластях) в соответствующих точках правой и левой желез сигнализирует о наличии отклонении от нормы. В качестве характеристик, описывающих степени симметрии температурных полей, предлагаются, например, функционалы вида $f_4(x^i) = p_3(T_r^{i,mw}, T_l^{i,mw})$, где $p_3(T_1, T_2) = p_2(T_1 - T_2)$;

Всего предложено 50 обобщенных характеристик, особенность которых в том, что они согласованы со знаниями экспертов и интерпретируемы. Исходное признаковое пространство преобразуется и содержит значения представленных функционалов, а не просто значения температур.

Применение более общих форм тех или иных характеристик, например, максимум разностей температур соска и точек железы вместо отдельной разности для каждой точки, позволяет сжать признаковое пространство (50 признаков вместо 900, предложенных в [5]), что значительно снижает время обучения алгоритмов, и, в перспективе, также должно минимизировать ошибку отбора. Безусловно, те или иные закономерности могут быть различными для, например, точек внешних и внутренних квадрантов железы, однако представленное пространство обобщенных признаков находится все еще не в завершённой форме и периодически пополняется.

Учитывая сильную несбалансированность классов в наборе, задача многоклассовой классификации не рассматривалась, а классы были разделены на две группы, в соответствии с которыми была выполнена бинарная классификация. К первой группе были отнесены пациентки с

категориями 1 и 2, поскольку у них нулевая вероятность наличия злокачественной опухоли. Во вторую группу были отнесены все остальные.

На основе логистической регрессии и информативных закономерностей (или простых правил) [4] был построен алгоритм взвешенного голосования. Выбор такого алгоритма обусловлен его простотой и полной интерпретируемостью вывода.

Оценка алгоритма выполнялась методом вложенной перекрестной проверки (nested cross-validation) [1], в соответствии с которой исходный набор данных 5 раз делился на настроечный и тестовый наборы в соотношении 80 к 20. Далее настроечный набор делился на обучающий и проверочный наборы в соотношении 80 к 20, для каждой комбинации возможных параметров выполнялось построение алгоритма на обучающем наборе и проверка на проверочном. Определялся набор параметров, с которыми алгоритм имеет лучшую среднюю оценку на проверочных наборах, выполнялось переобучение алгоритма на всем настроечном наборе и оценка на тестовом. Итоговой оценкой считалась средняя оценка по всем тестовым наборам.

В качестве меры эффективности алгоритма использовалась *G*-мера, определяемая как $G = \sqrt{Spec \cdot Sens}$, где $Sens = \frac{TP}{TP+FN}$ – чувствительность (полнота), $Spec = \frac{TN}{TN+FP}$ – специфичность, *TP* – истинно положительные результаты, *FN* – ложноотрицательные результаты, *FP* – ложноположительные результаты и *TN* – истинно отрицательные результаты.

В таблице 1 представлены средние оценки эффективности классификации тестовых наборов.

Таблица 1. Эффективность алгоритма взвешенного голосования

Критерий	Среднее значение	Стандартное отклонение
G-mean	0.749	0.056
Sens	0.724	0.082
Spec	0.778	0.063

Полученные результаты демонстрируют эффективность бинарной классификации по группам BI-RADS простым алгоритмом взвешенного голосования. В дальнейших исследованиях предполагается дополнение набора данных и построение алгоритмов многоклассовой классификации. В целом, представленное признаковое пространство в термометрических данных позволяет строить достаточно эффективные алгоритмы классификации, а значительная часть признаков может быть применена и в диагностике других органов либо частей тела. Так, например, все признаки, характеризующие степень симметрии, могут быть применены в исходном виде без каких-либо изменений и в диагностике венозных заболеваний.

Исследование выполнено при финансовой поддержке РФФИ, проект № 19-01-00358 А.

Библиографический список

1. Cawley G. C., Talbot N. L. C. On Over-fitting in Model Selection and Subsequent Selection Bias in Performance Evaluation // Journal of Machine Learning Research. 2010. No 11. Pp. 2079-2107.
2. Zare Mehrjardi M. Bi-RADS for: mammography and ultrasound (2013 updated version) // Breast Imaging CME 1st, Tehran, Iran 2015. DOI: 10.13140/RG.2.2.24908.82562/1
3. Вайсблат А.В., Веснин С.Г., Конкин М.А., Лащенко А.В., Тихомирова Н.Н. Использование микроволновой радиотермометрии в диагностике рака молочной железы [Электронный ресурс]. – 2000. – URL: <http://resltd.ru/rus/literature/cancer.htm> (дата обращения: 9.04.2019).
4. Воронцов К.В. Лекции по логическим алгоритмам классификации [Электронный ресурс] – URL: <http://www.ccas.ru/voron/download/LogicAlgs.pdf> (дата обращения: 9.04.2019).
5. Лосев А.Г., Левшинский В.В. Интеллектуальный анализ термометрических данных в диагностике молочных желез // Управление большими системами: сборник трудов. – М., 2017. – Т. 70 – С. 113-135.

BI-RADS THERMOMETRIC DATA CLASSIFICATION IN THE DIAGNOSTICS OF MAMMARY GLANDS

Levshinskii, Vladislav V.

Volgograd State University

400062, Russia, Volgograd, pr-t Universitetskiy, d. 100, v.levshinskii@volsu.ru

The paper constructs an interpretable feature space for radiothermometric data. We present the results of applying a binary classification algorithm based on synthesized features to determine group of BI-RADS categories by a breast radiothermometric data.

Key words: microwave radiothermometry, data mining, classification problem.

НЕЙРОННЫЕ СЕТИ В ДИАГНОСТИКЕ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ

Лосев Александр Георгиевич, Медведев Денис Андреевич
Волгоградский государственный университет,
400062, Россия, г. Волгоград, пр-т. Университетский, 100,
alexander.losev@volsu.ru, dnsmedvedev@gmail.com

В работе предложен способ разработки и анализ тестирования нейронной сети, предназначенной для диагностики рака молочной железы по данным микроволновой радиотермометрии. Показана эффективность комбинированного использования признакового пространства, основанного на медицинских знаниях, и результатов анамнеза.

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

Одной из актуальных задач современности является разработка эффективных методов ранней диагностики онкологических заболеваний молочной железы. В последние годы достаточную популярность приобрел метод микроволновой радиотермометрии, основанный на измерении кожных (ИК) и глубинных (РТМ) температур пациентки и последующем анализе термометрических данных. Обследование молочных желез начинается с измерения температуры в РТМ и ИК диапазонах в 9 точках на молочной железе, в аксиллярной области и 2-х опорных точках в центре грудной клетки пациента. В результате каждой пациентке ставится в соответствие вектор (t_0, \dots, t_{43}) , состоящий из 44 температур.

В настоящее время микроволновая радиотермометрия в основном применяется врачами-практиками, и большинство публикаций посвящены сравнительному анализу данного диагностического способа с более традиционными. При этом, несмотря на то, что данные термометрии носят объективный характер, постановка диагноза на их основании по-прежнему зависит от искусства врача и во многом носит субъективный характер. Сложность восприятия информации, возникающая у медицинского персонала без специальной длительной подготовки, значительно снижает потенциальную возможность использования термометрической аппаратуры в ранней дифференциальной диагностике. Данное обстоятельство нивелирует потенциальную возможность широкого использования термометрического оборудования. Одной из причин этого является недостаточное использование методов математического и компьютерного моделирования, возможностей

современных информационных технологий и, прежде всего, алгоритмов искусственного интеллекта.

В целом, указанная выше проблема не является особенностью микроволновой радиотермометрии. Применение современного медицинского оборудования, решая одни проблемы, во многих случаях порождает другие. Зачастую трудности диагностики возникают не из-за дефицита информации, а из-за недостаточной эффективности методов ее обработки. В какой-то мере решение указанных проблем обеспечивает создание систем интерпретации и анализа медицинских данных.

Таким образом, актуальной задачей является создание экспертной системы, обеспечивающей высокую чувствительность и специфичность диагностики и одновременно обладающей возможностями обоснования предполагаемого диагностического решения. Особую сложность в данной проблеме вызывает нахождение высокоинформативных признаков заболеваний. Как отмечается большинством специалистов, на будущее качество алгоритмов классификации влияют качественный и количественный составы пространства информационных признаков.

В процессе обследований врачами-диагностами было выявлено несколько качественных признаков рака молочной железы. Для каждого из них были предложены математические формализации (см, например, [1, 2]). При построении классификаторов было предложено все моделирующие функции разбить на следующие группы:

1. Группа функций, характеризующая асимметрию температурных полей молочных желез. Например, $|t_i - t_{(i+20)}|$, $|t_j - t_{(j+20)}|$, где $i=0, \dots, 9$ и $j=10, \dots, 19$
2. Группа функций, характеризующих повышенный разброс температур в пораженной молочной железе.
3. Группа функций, характеризующих повышенное значение температуры соска в пораженной молочной железе (радиальный градиент). Например, $t_0 - t_i$, $t_{10} - t_{i+10}$, $t_{20} - t_{i+20}$, $t_{30} - t_{i+30}$, где $i=1, \dots, 9$.
4. Группа функций, характеризующих соотношение кожной и глубинной температур (внутренний градиент). Например, $t_i - t_{i+10}$, $t_{i+20} - t_{i+30}$, где $i=1, \dots, 9$.
5. Группа функций, характеризующих изменение внутреннего градиента в радиальном направлении. Например, $(t_0 - t_{10}) - (t_i - t_{i+10})$, где $i=1, \dots, 8$, $(t_{20} - t_{30}) - (t_j - t_{j+10})$, где $j=21, \dots, 28$.

В данной работе исследуются возможности использования нейронных сетей в диагностике онкологических заболеваний молочных желез по данным микроволновой радиотермометрии. Рассматривался срез данных по совмещенному датчику, состоящий из 109 объектов класса «Здоровые» и 96 объектов класса «Рак». В качестве архитектуры нейронной сети был выбран многослойный персептрон. Последний слой сети будет состоять из двух нейронов. Первый нейрон относит пациента к классу «Здоровые», второй к классу «Рак». В качестве функции активации последнего слоя была выбрана функция $\text{softmax}(x)_i = \frac{\exp(x_i)}{\sum_{j=1}^n \exp(x_j)}$ [3]. Для минимизации эффекта

переобучения использовались два метода: Dropout [3] и ранняя остановка обучения [3].

В качестве меры эффективности классификатора использовалась величина $G = \sqrt{Spec \cdot Sens}$. Здесь $Sens = \frac{TP}{TP+FN}$, где TP – количество объектов класса «Рак», которые были классифицированы как «Рак», FN – количество объектов класса «Рак», которые не были классифицированы как «Рак», и $Spec = \frac{TN}{TN+FP}$, где TN – количество объектов класса «Здоровые», которые не были классифицированы как «Рак», FP – количество объектов класса «Здоровые», которые были классифицированы как «Рак».

В первом варианте классификатора в качестве входного слоя сети использовался вектор из 44 температур. Количество слоев, количество нейронов в слоях и метод оптимизации подбирались методом случайного поиска [3]. Обозначим за M количество скрытых слоев, за N_i количество нейронов i-го скрытого слоя. В таблице 1 приведен пример параметров, отобранных случайным поиском.

Таблица 1. Подбор параметров

M	N ₁	N ₂	N ₃	N ₄	N ₅	N ₆	N ₇	Метод оптимизации	Sens	Spec
7	100	90	50	60	40	30	20	RMSprop[3]	74.09	83.56
4	85	60	40	20	-	-	-	Adam[3]	73.33	83.64
5	60	30	60	40	20	-	-	Adam	73.89	79.91

Для получения корректной оценки модели использовалась K-блочная перекрестная проверка. Исходная выборка разбивалась на K блоков. Из K блоков один оставлялся для тестирования модели, а остающиеся K-1 блока использовались как тренировочный набор. Процесс повторялся K раз, и каждый из блоков использовался один раз как тестовый набор. Для K=10 эффективность классификатора равна 78.62 %.

Во втором варианте классификатора в качестве входных векторов использовались значения функций от вектора температур, моделирующих известные медицинские признаки рака молочных желез. Так как моделирующих функций довольно много (около 1000), то был построен минимизирующий набор путем разбиения функций на кластеры алгоритмом k-means. Результат кластеризации изображен на рисунке 1. Для визуализации кластерной структуры использовался метод понижения размерности t-SNE.

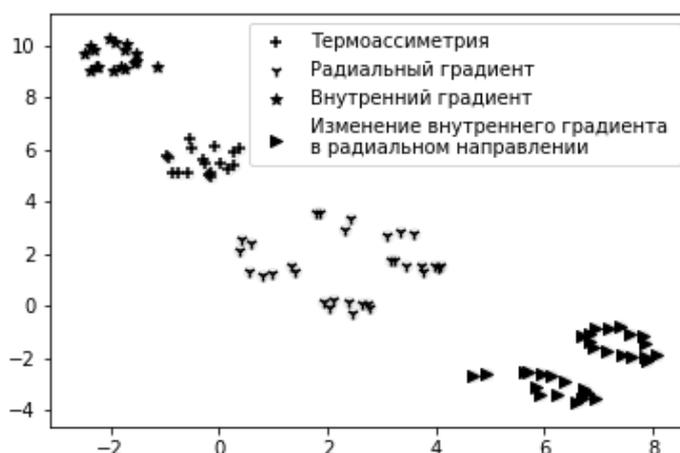


Рисунок 1. Кластеры

Полученные кластеры совпали с группами, моделирующими определенные медицинские признаки, поэтому из каждого кластера были выбраны функции, которые адекватно описывают весь кластер. Подобрать архитектуру сети и обучив ее, получили результаты, отраженные в таблице 2.

В третьем варианте классификатора дополнительно использовались следующие результаты анамнеза: возраст, рост, вес, диаметр молочной железы, количество точек боли. Результаты классификации отражены в таблице 2.

Таблица 2. Результаты диагностики

Входной вектор	Sens	Spec	G
Значения температур	83.56 %	74.09%	78.62 %
Значения функций	79.11%	84.27%	81.64%
Результаты анамнеза и значения функций	82.45 %	86.33%	84.36 %

Заметим, что нейронные сети на основе данных микроволновой радиотермометрии использовались для диагностики заболеваний молочных желез [4]. Предложенные в данном исследовании параметры, а также комбинированное использование в первом слое моделирующих функций и результатов анамнеза, позволило увеличить эффективность классификатора более чем на 10 процентов по сравнению с ранее предложенным вариантом.

Исследование выполнено при финансовой поддержке РФФИ, проект № 19-01-00358.

Библиографический список

1. Левшинский В.В., Лосев А.Г., Интеллектуальный анализ термометрических данных в диагностике молочных //Управление большими системами. 2017. № 70. С. 113–135.
2. Левшинский В.В., Лосев А.Г., Интеллектуальный анализ данных микроволновой радиотермометрии в диагностике рака молочной

железы//Математическая физика и компьютерное моделирование.
2017. Т. 20, № 5. С. 49-62.

3. Гудфеллоу Я., Бенджио И., Курвилль А., Глубокое обучение. М.: ДМК Пресс, 2017. 652 с.
4. Зенович А.В., Гребнев В.И., Примаченко Ф. Г., Алгоритмы классификации заболеваний парных органов на основе нейросетей и нечетких множеств // Математическая физика и компьютерное моделирование. 2017. Т. 20, № 6. С. 26–37.

NEURAL NETWORKS IN THE DIAGNOSIS OF BREAST CANCER

Losev Alexander G.

Volgograd State University,
400062, Russia, Volgograd, Universitetskiy pr., 100,
allosev59@gmail.com

Medvedev Denis A.

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

In this paper, a method for the development and analysis of testing a neural network designed for the diagnosis of breast cancer according to microwave radiometry is proposed. The efficiency of combined use of the feature space based on medical knowledge and the results of anamnesis is shown.

Keywords: microwave thermometry, neural networks, data mining.

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ПРОДОЛЖИТЕЛЬНОСТИ ЖИЗНИ

Мазеина Надежда Николаевна

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

В статье описан опыт разработки и применения нейросетевой системы для прогнозирования продолжительности жизни человека. Определены параметры, которые в большей степени влияют на продолжительность жизни. Проведены виртуальные компьютерные эксперименты методом сценарного прогнозирования.

Ключевые слова: продолжительность жизни, старение, прогнозирование, рекомендации, нейронная сеть.

Согласно исследованиям [1] на продолжительность жизни влияют не только генетические данные, но и образ и условия жизни человека. Основными методами продления жизни, доступными каждому человеку считают качественное ограниченное питание и умеренные физические нагрузки.

Помимо этого нельзя не отметить, что средняя продолжительность жизни отличается в разных странах и в разные годы, это, в частности, обусловлено развитием медицины [2]. На организм человека все сильнее влияет экология. Городская среда способствует таким заболеваниям как химическая астма, киршский синдром и другие [3]. Также продолжительность жизни зависит от пола, в исследованиях [1] было обнаружено, что баланс “женских” и “мужских” гормонов влияет на процесс старения. Введение мужского полового гормона (тестостерона) уменьшает продолжительность жизни, а женского (эстрадиола) увеличивает. Изменение соотношения этих гормонов влияет на развитие возрастной патологии – атеросклероза, опухолей.

Одним из перспективных методов прогнозирования жизни и смертности населения является нейросетевое моделирование. Впервые такие исследования были проведены Гусевым А.Л., Ясницким Л.Н. [4-6].

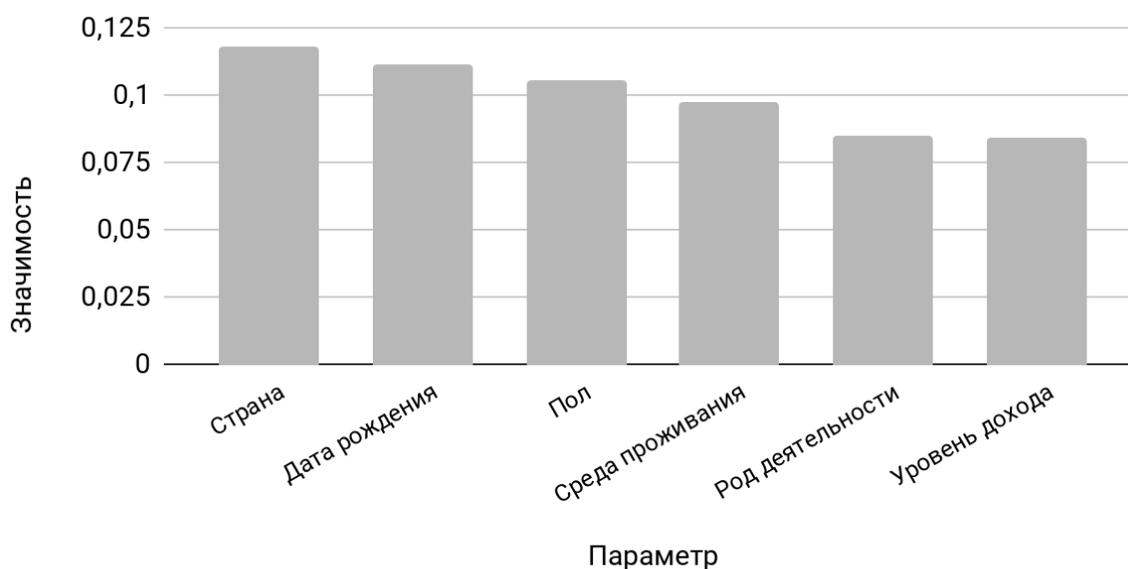
В представленной работе для прогнозирования продолжительности жизни человека был использован метод нейросетевого моделирования, описанный [7, 8] и нейросимулятор [9]. Данные для обучения нейронных сетей были отобраны в открытой энциклопедии “Википедия” [10] по 100 людям по следующим параметрам:

- дата рождения,

- пол,
- страна проживания,
- категория профессиональной деятельности (умственная, физическая),
- уровень дохода (уровень дохода человека определяет его питание и уровень доступной ему медицины),
- среда проживания (городская, сельская).

Обучение нейронной сети проводилось на 80 примерах, тестирование на 15 примерах. В результате погрешность тестирования составила 34%.

Согласно проведенным исследованиям на продолжительность жизни в большей степени влияют страна, дата рождения и пол. Степень влияния разных факторов представлена на рисунке 2.



Рис

унок 2. Значимость параметров.

В ходе исследования был проведен виртуальный эксперимент для человека со следующими параметрами:

- дата рождения: 25.03.1996 г.
- пол: женский,
- страна: Россия,
- деятельность: умственная,
- уровень дохода: средний,
- место проживания: город

В результате прогнозируемая продолжительность жизни равна 98 лет.

Будем варьировать значимые параметры для определения характеристик, которые позволят увеличить продолжительность жизни. Зависимость продолжительности жизни от различных параметров представлена на рисунках 3 – 6. Черным цветом выделены действительные (не варьированные) результаты.

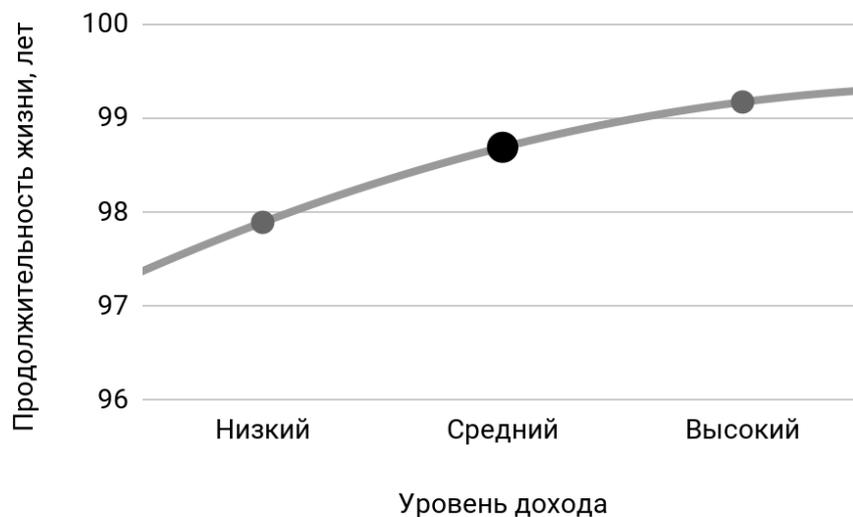


Рисунок 3. Зависимость продолжительности жизни от уровня дохода.

По рисунку 3 видно, что уровень дохода влияет на продолжительность жизни, но незначительно.

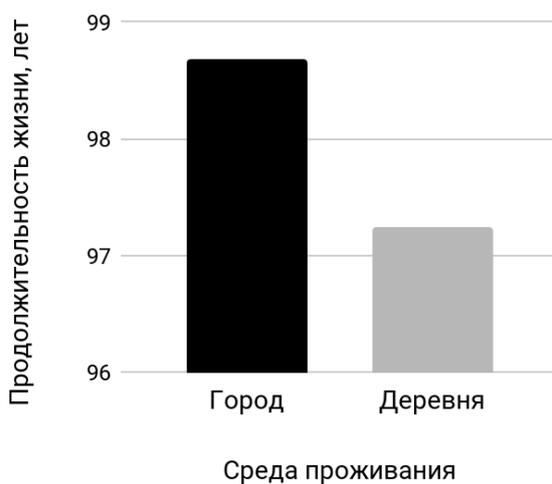


Рисунок 4. Зависимость продолжительности жизни от среды проживания.

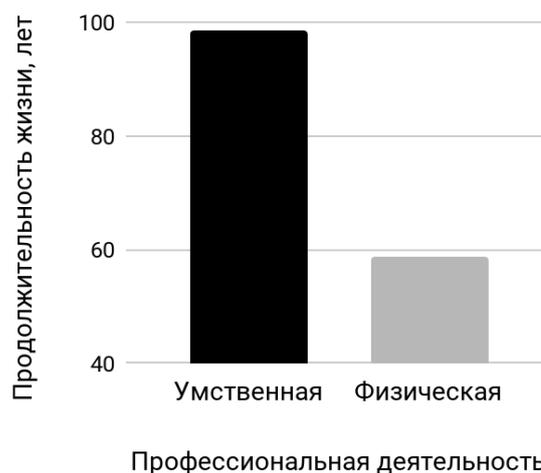


Рисунок 5. Зависимость продолжительности жизни от типа профессиональной деятельности.

Как следует из гистограммы рисунка 4, если бы рассматриваемый человек переехал из города в деревню, его прогнозируемая продолжительность жизни уменьшилась бы на полтора года. Мы видим, что, несмотря на то, что в городе экологическая среда хуже, продолжительность жизни там больше. Это можно объяснить более высоким уровнем медицинской и скорой медицинской помощи в городе. Физический труд уменьшил бы продолжительность жизни примерно на 40%.

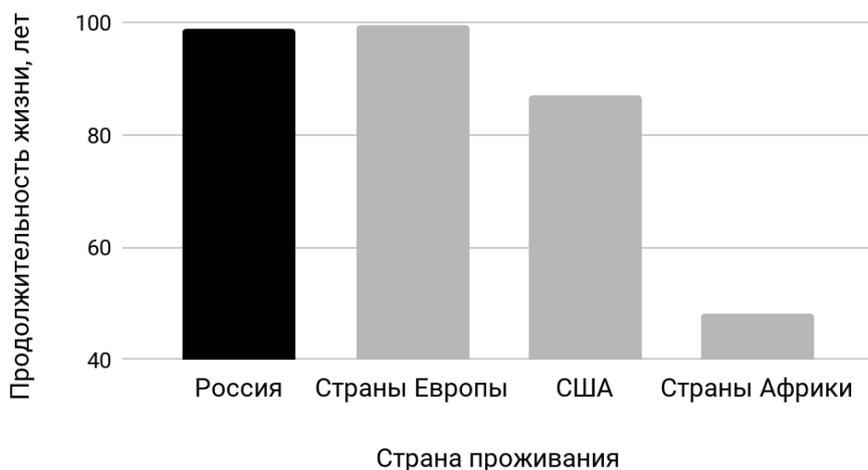


Рисунок 6. Зависимость продолжительности жизни от страны проживания.

Как видно из рисунка 6, если бы рассматриваемый человек жил не в России, а в странах Европы, его прогнозируемая продолжительность жизни бы практически не изменилась. Если бы он жил в США, его прогнозируемая продолжительность жизни упала бы до 87 лет. Продолжительность жизни в России оказалась большей чем в США. Это можно объяснить тем, что обучение производилось на данных прошлого века, когда Россия (СССР) по уровню развития и жизни не отставала от США. Прогнозируемая продолжительность жизни в Африке составила менее 48 лет, что согласуется с существующей ситуацией – высокой заболеваемостью, низким уровнем жизни и т.д.

Исходя из полученных данных, для того, чтобы жить долго, желательно иметь профессию, связанную с умственным трудом, иметь высокий доход, проживать в одном из городов Европы или России. Не только медицина, но и нейросетевое моделирование может помочь людям продлить свою активную жизнь

Библиографический список

1. В.В.Фролькис. Старение и увеличение продолжительности жизни. Ленинград: Наука. 1998. 239с.
2. О.М. Карпенко, В.М. Карпенко, В.Н. Голуб. Исследование влияния на продолжительность жизни населения различных социально-экономических факторов // Экономический вестник университета. Сборник научных трудов ученых и аспирантов. 2016г.
3. Экологические болезни. [Электронный ресурс] [Режим доступа: <http://www.prinas.org/news/2025>] [Доступ: 28.03.2019].
4. Гусев А.Л., Ясницкий Л.Н. Возможности нейросетевого прогнозирования продолжительности жизни социально-биологических систем // XIII Всероссийская научная конференция «Нейрокомпьютеры и их применение». (Москва. 17 марта 2017г.) Тезисы докладов. – М.: ГБОУ ВПО МГГПУ, 2015. – С. 114.

5. Гусев А.Л., Ясницкий Л.Н. Астрология под призмой нейронных сетей // Символ науки. 2017. Т. 3. № 3. С. 17-24.
6. Ясницкий Л.Н., Зайцева Н.В., Гусев А.Л., Шур П.З. Нейросетевая модель региона для выбора управляющих воздействий в области обеспечения гигиенической безопасности // Информатика и системы управления. – 2011. – № 3 (29). – С.51-59.
<https://cloud.mail.ru/public/7LCo/SHBzV9hGk>
7. Ясницкий, Л. Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. 176 с.
8. Ясницкий Л.Н. Интеллектуальные системы. М.: Лаборатория знаний, 2016. 221 с.
9. Нейросимулятор 5.0 : свидетельство о государственной регистрации программы для № 2014618208 от 12.07.2014 г. / Черепанов Ф.М., Ясницкий Л.Н. (РФ)
10. Категория: Персоналии по алфавиту // Википедия. Свободная энциклопедия. [Электронный ресурс] [Режим доступа: https://ru.wikipedia.org/w/index.php?title=Категория:Персоналии_по_алфавиту&from=Б] [Доступ: 11.03.2019]

NEURAL NETWORK MODELING OF LIFE DURATION

Mazeina Nadezhda N.

Perm State University

614990, Russia, Perm, street Bukireva, 15, mazeinadya@gmail.com

The article describes the experience of the development and application of the neural network system for predicting the duration of human life. The parameters that have a greater effect on life expectancy have been determined. Set out an experiment that reflects the favorable factors for the extension of human life.

Key words: life expectancy, aging, forecasting, recommendations, neural network.

ИНТЕРПРЕТАЦИИ МНОГОМЕРНЫХ ТЕРМОМЕТРИЧЕСКИХ ПРИЗНАКОВ В ДИАГНОСТИКЕ РАКА МОЛОЧНОЙ ЖЕЛЕЗЫ¹⁷

*Мазепа Елена Алексеевна, Петренко Александр Юрьевич,
Сулейманова Хеди Мовладовна*

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

Работа посвящена проверке гипотезы об однородности двух независимых групп данных здоровых и больных пациенток. Устанавливается статистически достоверное различие термометрических данных в группе больных и здоровых пациенток по различным видам величин, характеризующим аномалии температурных полей молочных желез. Для решения поставленной задачи в работе применен критерий Манна-Уитни, который не требует нормального распределения данных и позволяет установить однородность двух выборок.

Ключевые слова: проверка статистических гипотез, анализ данных, непараметрические критерии, двумерные признаки, микроволновая радиотермометрия.

Одной из актуальных задач медицины и информационных технологий является разработка и внедрение эффективных систем поддержки принятия решений, которые, используя методы интеллектуального анализа данных, помогают специалистам в задачах постановки диагнозов, прогнозирования развития заболеваний и т. д. В настоящее время трудности диагностики возникают не из-за дефицита информации, а из-за недостаточной эффективности методов ее обработки. В какой-то мере решение указанных проблем обеспечивает создание систем интерпретации и анализа медицинских данных.

В течение нескольких лет в результате обследований, проводившихся в ряде онкологических центров России, была создана база термометрических данных. Она включает в себя информацию о молочных железах пациенток в возрасте от 17 до 88 лет. Данные были разбиты на два контрольных класса: «Здоровые» – температурные данные здоровых молочных желез здоровых пациенток (115 пациенток), «Больные» – температурные данные больных молочных желез больных пациенток раком (62 пациентки). Группы пациенток так же разделяются на подгруппы по диапазону измерения температур: RTM-диапазоне (внутренние температуры) и IR-диапазоне (кожные температуры).

Методика измерения: обследование пациентки проводится в горизонтальном положении, обнаженной по пояс, руки под головой. Обследование начинается с измерения температур в опорных точках T1 и T2, 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.

В ходе исследований и анализа данных микроволновой радиотермометрии, специалистами был выявлен ряд качественных признаков рака молочной железы. В частности, у пациенток с патологией отмечаются следующие качественные признаки: наличие повышенной величины термоасимметрии между одноименными точками молочных желез; повышенный разброс температур между отдельными точками в пораженной молочной железе; повышенная разница температур сосков; повышенная температура соска в пораженной молочной железе по сравнению со средней температурой молочной железы с учетом возрастных изменений температуры; повышенная разница кожной и глубинной температур и некоторые другие.

Попытки построения алгоритмов классификации предназначенных для диагностики рака молочной железы, на основе только данных температур, не дают достаточной эффективности, чтобы было отмечено и врачами. В связи с этим перешли к рассмотрению функций, описывающих качественные признаки. Данные признаки строятся путем количественного моделирования качественных признаков заболевания, выявленных маммологами [1].

Для анализа данных на предмет выполнения той или иной гипотезы предлагается использовать различные функционалы, например: $TAS = \|Tl(\vec{r}) - Tr(\vec{r})\|$, где $Tl(\vec{r})$ и $Tr(\vec{r})$ - температуры в левой и правой молочных железах (гипотеза «зеркальной» симметрии температурных полей правой и левой молочных желез здоровых пациенток). При этом предполагается применение самых разных типов функционалов, в том числе различных норм ($C(\Omega)$, $C^1(\Omega)$, $C^2(\Omega)$ и др.), полунорм и т.п., причем вычисляемых как по всей области изменения, так и по различным ее подобластям. Для проверки гипотезы о невысоком разбросе температур в здоровой молочной железе предполагается использование функционалов вида $\|T(\vec{r}) - T_{type}(\vec{r})\|$, где также предполагается использование различных норм. Под $T_{type}(\vec{r})$ - понимается некая функция, описывающая «типичное» распределение температур молочной железы.

Таким образом, появилась идея моделирования многомерных, в частности двумерных, признаков заболеваний. Все множество функций, описывающих качественные признаки заболеваний, было объединено посредством использования C-нормы в набор из 6 функций:

- Повышенное значение разности температур между одноименными точками правой и левой молочных желез (Thermoassimetry_RTМ, Thermoassimetry_IR):

$$\max_{j=0,\dots,8} |t_j - t_{j+20}|, \max_{j=0,\dots,8} |t_j - t_{j+20}|;$$

- Повышенная разность температур соска и температур отдельных точек молочной железы (Increased_Temperature_t0_RTM, Increased_Temperature_t0_IR):

$$\max_{j,k} |t_j - t_k|, j = 0,10,20, \max_{j,k} |t_j - t_k|, j = 10,20,30; k = j + 1, \dots, j + 8;$$

- Признаки, характеризующие соотношение кожной и глубинной температур (Inner_Gradient):

$$\max_{j,k} |t_{j+k} - t_{j+k+10}|, j = 0,10,20,30; k = 1, \dots, 8;$$

- Признаки, базирующиеся на физико-математических моделях поведения температурных полей (Second_Derivative):

$$\max_{j,k} \left| \begin{array}{l} (t_j - t_{j+10}) - \frac{(t_{j+k} - t_{j+k+10}) + (t_{j+k+1} - t_{j+k+10+1}) + (t_{j+k+2} - t_{j+k+10+2})}{3}, \\ (t_j - t_{j+10}) - \frac{(t_{j+7} - t_{j+7+10}) + (t_{j+8} - t_{j+10+8}) + (t_{j+1} - t_{j+10+1})}{3}, \\ (t_j - t_{j+10}) - \frac{(t_{j+8} - t_{j+8+10}) + (t_{j+1} - t_{j+10+1}) + (t_{j+2} - t_{j+10+2})}{3} \end{array} \right|$$

$$j=0,20; k=1,\dots,6.$$

Выбирая пары из полученных шести функций, получаем 15 двумерных признаков. Для каждого признака получены двумерные выборки в группах «здоровые» и «больные». Возникает вопрос: можно ли считать данные выборки по здоровым и больным пациенткам, полученными из одной и той же генеральной совокупности (выборки однородны) или они получены из различных генеральных совокупностей (выборки неоднородны)?

Каждое наблюдение выборки представляет собой точку на двумерной плоскости. В этой плоскости строится система вложенных эллипсов. Подробное описание построения таких эллипсов приведено в [2]. Далее варьируя коэффициенты сжатия полуосей эллипсов, найденных по алгоритму [2] от 0.1 до 3 с шагом 0.1, получаем n – эллипсов. Данные наблюдений для групп «здоровые» и «больные» шкалируются. При попадании значения функции в первый эллипс, ему присваивается номер 1, если точка не попадает в первый, но попадает во второй – присваиваем номер 2 и т.д. (см. Рисунок 1). Полученные наборы шкалированных данных проверяются на однородность.

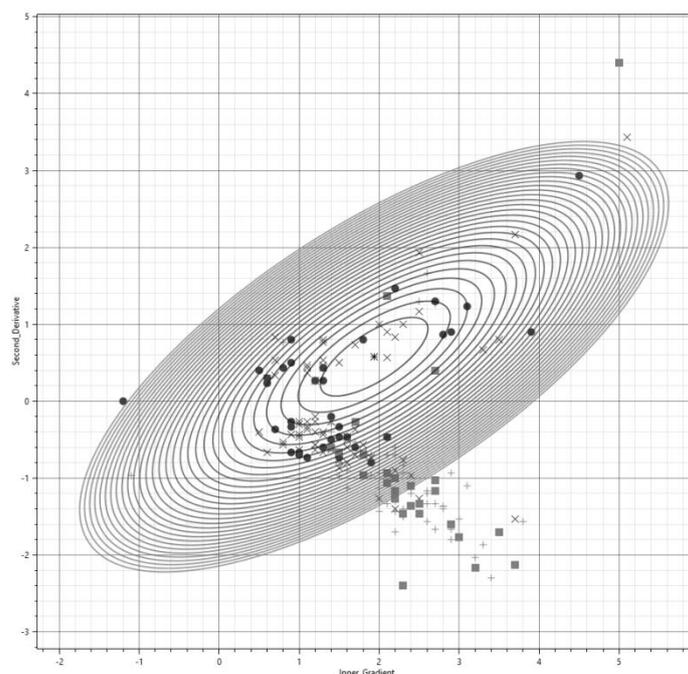


Рисунок 1. Построение эллипса для функции Inner_Gradient&Second_Derivative

Далее для проверки гипотезы однородности двух выборок применяется непараметрический метод Манна-Уитни, не требующий определенного распределения данных. В нем не используются параметры генеральной совокупности, такие как: среднее арифметическое и стандартное отклонение, как для критериев, требующих нормального распределения. Осуществляется ранжирование абсолютных значений, что позволяет сглаживать эффект выскакивающих величин и скошенности распределения.

В качестве первоначальной гипотезы H_0 , используется гипотеза об однородности данных и гипотеза H_1 в противном случае. Результаты критерия для некоторых пар функций представлены ниже (Таблица 1).

Таблица 1. Результаты вычислений T-критерия Манна-Уитни

Пары функций	Гипотеза H_1
Thermoassimetry_IR_sign&Increased_Temperature_t0_IR	4,3
Increased_Temperature_t0_IR&Inner_Gradient	4,8
Inner_Gradient&Second_Derivative	8,8

Все наблюдаемые значения критерия не попали в область $(-1,96; 1,96)$ принятия основной гипотезы об однородности H_0 , что позволяет сделать вывод о том, что данные «здоровых» и «больных» пациенток имеют достоверное различие для исследуемых двумерных признаков.

ПРИМЕЧАНИЕ

Исследование выполнено при финансовой поддержке РФФИ и Администрации Волгоградской области, проект «Управление качеством классификации в диагностике рака молочной железы по многомерным данным микроволновой радиотермометрии» № 18-47-340004 р_а.

Библиографический список

1. Левшинский В.В., Лосев А.Г., Интеллектуальный анализ данных микроволновой радиотермометрии в диагностике рака молочной железы//Математическая физика и компьютерное моделирование. 2017. Т. 20. № 5. С. 49–62.
2. Зенович А.В., Батулин Н.А., Медведев Д.А., Петренко А.Ю. Алгоритмы формирования двумерных признаков диагностики заболеваний молочных желез методами комбинированной радиотермометрии// Математическая физика и компьютерное моделирование. 2018. Т. 21. № 4. С. 44 – 56.

INTERPRETATION MULTIDIMENSIONAL THERMOMETER SIGNS IN THE DIAGNOSIS OF BREAST CANCER

Mazepa Elena A.

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

Petrenko Alexander Y.

Volgograd State University, 400062, Russia, г. Volgograd,
prospekt Universitetskiy, 100, kkamikadzee@yandex.ru

Suleymanova Khedi M.

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

The work is devoted to testing the hypothesis of the homogeneity of two independent groups of data of healthy and sick patients. A statistically significant difference in thermometric data is established in the group of patients and healthy patients for various types of quantities that characterize the anomalies of the temperature fields of the mammary glands. To solve the problem, we used the Mann-Whitney criterion, which does not require a normal distribution of data and allows us to establish the homogeneity of the two samples.

Keywords: verification of statistical hypotheses, data analysis, non-parametric criteria, two-dimensional features, microwave radiothermometry.

БИОЭТИКА КАК ОСНОВА РАЗВИТИЯ СИСТЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В МЕДИЦИНЕ

Мишланов Виталий Юрьевич

Пермский государственный медицинский университет им. академика
Е.А. Вагнера, 614000, Россия, г. Пермь, Петропавловская, д. 26,
permmed@hotmail.com

Зуев Андрей Леонидович

Институт механики сплошных сред УрО РАН
614000. Россия. ул. Академика Королева, 1, г. Пермь, Пермский край

Файзрахманов Рустам Абубакирович

Пермский национальный исследовательский политехнический университет
614990, Пермский край, г. Пермь, Комсомольский проспект, д. 29

Биоэтика – наука о взаимоотношениях между людьми и формировании взаимодействия человека с инновационными технологиями, такими как применение компьютеров в клинической диагностике, искусственный интеллект, трансплантация органов, редактирование генома и т.д., становится основой для быстрых технологических перемен в жизни человека и направлена на его безопасное существование в условиях быстро меняющегося мира. Внедрение новых технических разработок часто сопряжено с изменением мироощущения врача и пациента. Многие, по-прежнему, доверяют только личному контакту с врачом, другие видят преимущество новых компьютерных и мобильных устройств, применения элементов искусственного интеллекта. От решения этой задачи зависит скорость перемен в обществе, технологический прорыв, безопасность и благосостояние человека. В статье приведены примеры современных технологий с использованием элементов искусственного интеллекта в медицине, определены ближайшие перспективы развития.

Ключевые слова: биоэтика, искусственный интеллект, диагностика, мониторинг, клинические рекомендации, персонифицированная медицина.

Актуальность

Стремительное развитие новых технологий стало неотъемлемой частью нашей жизни. Большинство технологических процессов, так или иначе, связаны с жизнедеятельностью человека или направлены на его развитие, здоровье и продолжительность жизни. Этот процесс связан с адаптацией мироощущения, социальных связей, законодательной базы и других сторон

индивидуальных возможностей человека и общественных отношений к новым условиям. С этим связано возникновение нового учения, получившего название биоэтика. Термин биоэтика предложил в 1970 г. R. Van Potter (Р. Ван Поттер). По его мнению, биоэтика является наукой выживания, так как ее главная черта формирование рационального поведения человека в условиях меняющегося мира [1]. Существует и точка зрения, что биоэтика представляет собой систему этического контроля конкретных вопросов, возникающих по причине развития биологических и медицинских технологий, а также науку, посвященную исследованию социальных проблем, вызванных научно-техническим прогрессом в области биологии и медицины [2].

Одной из актуальных задач биоэтики является определение взаимоотношений человека с системами искусственного интеллекта, которые способны влиять на его собственное здоровье, т.е. являются медицинскими технологиями. Такие системы призваны помогать врачу или любому человеку в диагностике состояния организма, выборе средств и методов укрепления здоровья. Но недоверие к новым технологиям основано на предполагаемых ошибках в работе машины и непонимании ее структуры, а также механизмов реализации функций. Попробуем перечислить наиболее распространенные аппаратные комплексы в настоящее время.

Современные интеллектуальные технологии в медицинской практике

Искусственный интеллект незаметно в течение последних десятилетий проник практически во все инструментальные диагностические системы, применяемые в медицине. Аппараты ультразвуковой, компьютерной томографии, магнитной резонансной томографии, электрокардиографы, спирометры и другие оснащены программами решения алгоритмической задачи или интеллектуальными системами сравнения образов с эталонами. Совпадение с эталоном позволяет принять предварительное заключение, предназначенное для врача в качестве подсказки. Предполагается, что окончательное решение принимает только врач.

Глобальных систем обработки множества предварительных результатов обследования больного в настоящее время не существует, но ряд систем находятся сейчас в стадии многолетних многоцентровых и масштабных клинических испытаний. Возможно, препятствием для создания таких систем является чрезмерно большой объем информации, требующий работы суперкомпьютеров или специальных стратегий, созданных веками применения медицинских диагностических приемов [3].

Каждая система искусственного интеллекта, претендующая на роль инструмента диагностического процесса или лечебной программы должна пройти строгую систему клинических испытаний в соответствии с принципами доказательности в медицине, что завершается созданием соответствующих клинических рекомендаций или включением разработанной системы в уже существующие клинические рекомендации, согласованные с министерством здравоохранения [4].

В последние годы в Европейских и некоторых других странах получили развитие средства мобильной медицины с использованием смартфонов и других мобильных устройств, позволяющие обеспечить мониторинг состояния больного в удаленных территориях и невозможности посещения офиса врача по причине соматических нарушений [5, 6, 7]. В ходе крупных исследований было показано, что наилучшие результаты по снижению числа обострений и выживаемости больных хроническими заболеваниями дают реабилитационные программы в период 2 месяцев после стационарного лечения, т.е. после тяжелого обострения заболевания. В реализации этих программ большое внимание уделяется мониторингу состояния больного человека, обучению его способам правильного использования медицинских приборов, формированию рационального поведения, выполнению упражнений лечебной физкультуры и физической тренировки. Эти задачи часто решаются с применением средств мобильной медицины, в том числе с использованием искусственного интеллекта. Такая кооперация человека и программы искусственного интеллекта помогает оказать помощь жителям удаленных территорий, тяжелым больным пациентам, требующим ежедневной корректировки программы реабилитации в зависимости от состояния здоровья.

Мониторинг клинического состояния пациента, вопросы предварительной доврачебной диагностики, телемедицины и формирования регистров больных с целью планирования развития медицинской службы предлагается решать с помощью интерактивных опросников. Лучшие варианты опросников предложены еще в период, предшествующий развитию электронной медицины. Такие опросники прошли систему клинических испытаний и считаются валидными. К сожалению, в большинстве случаев опросники имеют узкую направленность, предназначены для динамического наблюдения больных каким-либо конкретным заболеванием. Но внедрение автоматизированных опросников в практику работы медицинских центров составляет сейчас одно из центральных направлений в профилактической медицине [7, 8, 9, 10, 11].

Искусственный интеллект и доказательная медицина

Развитие систем помощи принятия решения в медицинской практике стало необычайно популярным в последние десятилетия, предложены сотни вариантов решения различных клинических задач. Фильтром отбора лучших «искусственных помощников» является хорошо известная система «мер и весов», называемая медициной, основанной на доказательствах. Основу принципов доказательности составляют хорошо спланированные многотысячные, многоцентровые клинические исследования. Система доказательной базы позволяет исключить влияние субъективного фактора разработчика нового продукта и других заинтересованных лиц в получении определенных результатов. Большое внимание в системе доказательности играет количество включенных пациентов и формирование контрольных групп. Необходимо включить больных обоих полов, различного возраста с

разными сопутствующими клиническими проблемами, что позволит далее правильно сформулировать выводы исследования и распространить рекомендации на соответствующие группы больных или здоровых лиц [12].

Применение методов доказательной медицины предусматривает наличие определенной инфраструктуры медицинской науки в обществе, систему общественных организаций, этического и научного комитетов, команды независимых экспертов и общественных наблюдателей.

Обсуждение и перспективы развития

Биоэтика становится главной наукой развития современного общества, она включает знания организации научной деятельности и условия применения новых знаний на практике. В перспективе эта система знаний должна способствовать быстрому научно-технологическому прогрессу. Возможно, наилучшие перспективы развития получит то общество, в котором инфраструктура научного процесса и развития биоэтики станут приоритетом социальной жизни.

Библиографический список

1. Potter V.R. 'Bioethics, the Science for Survival'. Perspectives in Biology and Medicine 1970; 14: 127–53.
2. Мак Интайр Р.Б., Стигманн Г.В., Айсман Б.; Федоров В.Д., Кубышкин В.А. ред. Алгоритмы диагностики и лечения в хирургии. М. ГЭОТАР-Медиа 2009: 744 с.
3. Чучалин А.Г., Черешнев В.А., Мишланов В.Ю., Мишланов Я.В., Никитин А.Э., Шубин И.В. Биоэтика, искусственный интеллект и медицинская диагностика.- Пермь, 2019.- 208 с.
4. Федеральный закон РФ от 25 декабря 2018 года N 489-ФЗ «О внесении изменений в статью 40 Федерального закона «Об обязательном медицинском страховании в Российской Федерации» и Федеральный закон «Об основах охраны здоровья граждан в Российской Федерации» по вопросам клинических рекомендаций»
5. Cerdan J., Catalan-Matamoros D., Berg S.W. Online communication in a rehabilitation setting: Experiences of patients with chronic conditions using a web portal in Denmark. Patient education and counseling 2017; 100(12): 2283-2289.
6. Chrvala C.A., Sherr D., Lipman R.D. Diabetes self-management education for adults with type 2 diabetes mellitus: A systematic review of the effect on glycemic control. Patient Education and Counseling 2016; 99 (6): 926-943.
7. Vitacca M., Montini A., Comini L. How will telemedicine change clinical practice in chronic obstructive pulmonary disease? Ther Adv Respir Dis 2018; 12: 1-19.
8. GOLD 2018. https://goldcopd.org/wp-content/uploads/2017/11/GOLD-2018-v6.0-FINAL-revised-20-Nov_WMS.pdf. Available 26.08.2018.

9. Jones P.W., Forde Y. ST. George's respiratory questionnaire for COPD patients (SGRQ-C) Manual. St George's, University of London. London SW17 0RE UK 2012: 16.
10. Juniper E.F., Svensson K., Mork A.-C., Stahl E. Measurement properties and interpretation of three shortened versions of the asthma control questionnaire. *Respiratory Medicine* 2005; 99(5): 553-558.
11. Someya F., Nakagawa T. Application of the COPD Assessment Test (CAT) to Patients with Interstitial Lung Disease. *Health* 2014; 6: 2562-2569.
12. Флетчер Р., Флетчер С., Вагнер Э. Клиническая эпидемиология: Основы доказательной медицины. М. Медиа Сфера 1998: 352 с.

BIOETHICS AS A BASIS FOR THE DEVELOPMENT OF ARTIFICIAL INTELLIGENCE SYSTEMS IN MEDICINE

Vitaly Yu. Mishlanov

Perm State Medical University n. a. academician E.A. Wagner
614000, Russia, Perm, Petropavlovskaya, 26
permmed@hotmail.com

A.L. Zuev

The Institute of Continuous Media Mechanics UB RAS
Academician Korolev Str., 1, Russia, Perm, Perm region, 614000

R. A. Fayzrakhmanov

Perm National Research Polytechnic University
614990, Perm Krai, Perm, Komsomolsky Prospect, 29

Bioethics – the science of the relationship between people and the formation of human interaction with innovative technologies, such as the use of computers in clinical diagnosis, artificial intelligence, organ transplantation, genome editing, etc., to become the basis for rapid technological changes in human life and is aimed at its safe existence in a rapidly changing world. The introduction of new technical solutions is often associated with a change in the attitude of the doctor and the patient. Many still trust only personal contact with the doctor, while others take advantage of new solutions based on the use of artificial intelligence systems. This question influences the speed of change in society, a technological breakthrough, the safety and welfare of man. The article gives examples of modern technologies using elements of artificial intelligence in medicine, defines the nearest prospects of development.

Key words: bioethics, artificial intelligence, diagnostics, monitoring, clinical recommendations, personalized medicine

**НЕЙРОСЕТЕВАЯ СИСТЕМА ДИАГНОСТИКИ
ЗЛОКАЧЕСТВЕННОГО ПЛЕВРАЛЬНОГО ВЫПОТА
ПО ФОТОГРАФИЯМ ФАЦИЙ ПЛЕВРАЛЬНОЙ ЖИДКОСТИ,
ПОЛУЧЕННЫХ МЕТОДОМ КЛИНОВИДНОЙ ДЕГИДРАТАЦИИ**

Митрофанов Игорь Андреевич, Ясницкий Леонид Нахимович
Пермский государственный национальный исследовательский университет
614990, Россия, г. Пермь, ул. Букирева, 15
yasn@psu.ru

Плаксин Сергей Александрович, Фаршатова Лилия Ильдусовна
Пермский государственный медицинский университет им. академика
Е.А. Вагнера, 614000, Россия, г. Пермь, Петропавловская, д. 26

В статье описан опыт разработки и применения сверточных нейронных сетей для диагностики наличия онкологического заболевания у человека на основе изображений высушенной капли плевральной жидкости.

Ключевые слова: онкология, плевральный выпот, нейронная сеть, диагностика.

Актуальность. На сегодняшний день наблюдается прогрессирующий рост числа случаев синдрома плеврального выпота [1, 2]. Природа заболеваний, сопровождающихся пропотеванием жидкости в плевральную полость, весьма разнообразна. Она включает в себя широкую группу заболеваний, связанных с патологией органов грудной клетки, почек, сердечно-сосудистой системы. Общеизвестны трудности в осуществлении дифференциальной диагностики плевральных выпотов. Инвазивные методы, направленные на гистологическую верификацию диагноза, технически сложны и сопряжены с риском осложнений. Поэтому разработка новых доступных малотравматичных способов диагностики остается актуальной задачей.

Материал и методы. Были обследованы 163 пациента, которые находились на лечении в торакальных отделениях Пермской краевой клинической больницы и городской клинической больницы №4 г. Перми с плевральными выпотами разной природы. Для исследования были взяты фации, полученные методом клиновидной дегидратации, и представляющие из себя пленки, образовавшиеся после высыхания капли плевральной жидкости объемом 10 μ l, нанесенных на обезжиренное предметное стекло. У каждого пациента пипеткой дозатором формировали 5 фаций диаметром от 3 мм до 6 мм. После этого проводили фотосъемку фации на предметном стекле фотоаппаратом Canon EOS 650 с адаптером для макросъемки через объектив с увеличением 4x микроскопа Levenhuk Rainbow 2L Plus.

По этиологическому фактору обследованные пациенты были разделены на 10 групп, относящихся к различным вариантам воспалительных, опухолевых и трансудативных выпотов. Слишком малое число наблюдений в каждой группе ограничило возможности автоматизированной обработки данных. Для решения этой проблемы все больные были разделены на две группы – онкологические (злокачественный плевральный выпот, 65 человек) и все другие заболевания (98 пациентов). Такой подход был обусловлен приоритетностью и важностью выявления в первую очередь злокачественных опухолей, представляющих наибольшую угрозу здоровью пациента.

Исходные изображения были обрезаны по кругу как можно ближе к периметру фации. В результате были получены квадратные изображения, которые впоследствии были сжаты до размера 150x150 пикселей. Пример обрезки изображения представлен на рисунке 1.

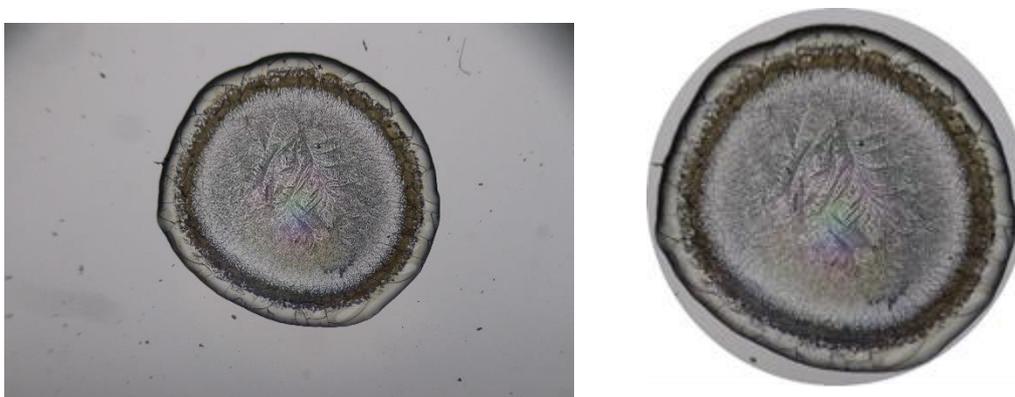


Рисунок 1. Исходное изображение высушенной капли плевральной жидкости до и после обрезки

Исходное множество, состоящее из 339 изображений, обрезанных по кругу, было разделено на обучающее и тестирующее в соотношении 70:30. Таким образом, количество изображений в обучающей выборке составило 236, а в тестирующей – 103.

Для увеличения количества изображений в обучающем множестве в него были добавлены копии исходных изображений, повернутых на определенное количество градусов с заданным шагом. Необходимость такого подхода обусловлена несколькими причинами: во-первых, сверточные нейронные сети требуют больших массивов данных для обучения, во-вторых, фация плевральной жидкости перед фотографированием может быть расположена произвольным образом. Подача повернутого изображения на вход нейронной сети дает ей дополнительную информацию для обучения.

Было рассмотрено несколько значений шага для поворота изображений: 5, 10, и 30 градусов. Для того, чтобы выбрать оптимальное значение, на каждом наборе данных были обучены несколько нейронных сетей, а затем среди них выбраны лучшие. Лучшие результаты были достигнуты при повороте с шагом 10 градусов. Дальнейшее уменьшение угла

поворота не только не приводит к росту точности, но и увеличивает время обучения.

После этого была предпринята попытка улучшить результаты обучения на изображениях, повернутых с шагом 10 градусов, за счет аугментации данных путем применения к изображениям случайных комбинаций преобразований – поворота, зуммирования, сдвига, отражения по вертикали и горизонтали – с помощью функций, реализованных в Keras, однако от этого качество обучения не улучшилось.

Таким образом, в результате предобработки изображений исходное обучающее множество, состоящее из 236 фотографий, было увеличено до 8496 путем обрезки клеток по кругу как можно ближе к их периметру и создания копий исходных изображений, повернутых с шагом 10 градусов.

В качестве архитектуры нейронной сети была выбрана сверточная сеть. Для ее обучения была использована библиотека Keras. В качестве структуры сверточной сети была выбрана сеть VGG16 [3], состоящая из 16 слоев, 13 из которых отвечают за выделение характерных признаков изображения, а 3 – за классификацию объекта.

Сверточные нейронные сети содержат достаточно большое количество весовых коэффициентов, которые необходимо определить путем обучения. Сверточный блок сети VGG16 содержит 14714688 весов, поэтому собранного множества изображений недостаточно для обучения всей сверточной сети с нуля. Для решения этой проблемы была использована технология переноса обучения [4], заключающаяся в применении нейронной сети, обученной на наборе изображений из одной области, к другой.

Таким образом, нами была выбрана структура нейронной сети, состоящей из сверточного блока сети VGG16 с весами, обученными на наборе данных ImageNet, одного скрытого полносвязного слоя, выполняющего роль классификатора, и выходного слоя, веса которых были обучены на изображениях капель плевроальной жидкости. Все веса, кроме тех, что содержатся в сверточном блоке, определялись в процессе обучения.

Обучение нейронной сети проводилось с помощью сервиса Google Colaboratory [5], представляющего собой сервис облачных вычислений на базе GPU Nvidia Tesla K80. Такой подход позволяет сократить время обучения в несколько раз по сравнению со временем обучением на GPU ноутбука.

Для выбора оптимальных параметров сети осуществлялся их частичный перебор. В качестве функций активации скрытого и выходного слоев использовались сигмоида, гиперболический тангенс, softplus, softsign, softmax, в качестве алгоритмов обучения – Adam, Adamax, RMSprop, Adadelta, Nadam, количество нейронов на скрытом слое устанавливалось в пределах от 8 до 256, значение Dropout – от 0.5 до 0.75. Обучение происходило путем комбинации случайных значений этих параметров и выбора наилучшей сети с точки зрения точности классификации изображений из тестирующего множества.

В качестве метрики качества использовалась доля правильно классифицированных изображений, в качестве функции ошибки – бинарная кросс-энтропия.

В результате обучения была получена сеть, имеющая 89% точность на тестирующем множестве со следующими параметрами:

- Количество нейронов на скрытом слое – 16;
- Функция активации скрытого слоя – softmax;
- Функция активации выходного слоя – softplus;
- Алгоритм обучения – Adamax;
- Dropout – 0.67.

Исследуя ответы на тестирующем множестве, состоящем из 103 фотографий, было выявлено, что сеть поставила 7 ложных диагнозов и не обнаружила онкологию в 4 случаях. По полученным ответам была построена ROC-кривая. Площадь под ROC-кривой составила 0,941. Вычисленные чувствительность и специфичность модели составили 0,875 и 0,915 соответственно.

Демонстрационный прототип. Обученная нейронная сеть была использована для создания демонстрационного прототипа интеллектуальной системы диагностики злокачественного плеврального выпота. Демонстрационный прототип имеет следующие функции: загрузка и обрезка изображений, диагностика загруженных изображений обученной нейронной сетью, экспорт результатов в Excel-файл.

При запуске интеллектуальной системы отображается рабочее окно, содержащее список ранее обрезанных изображений. Если обрезанных изображений нет, список будет пустой. Скриншот рабочего окна демонстрационного прототипа после запуска представлен на рисунке 2.

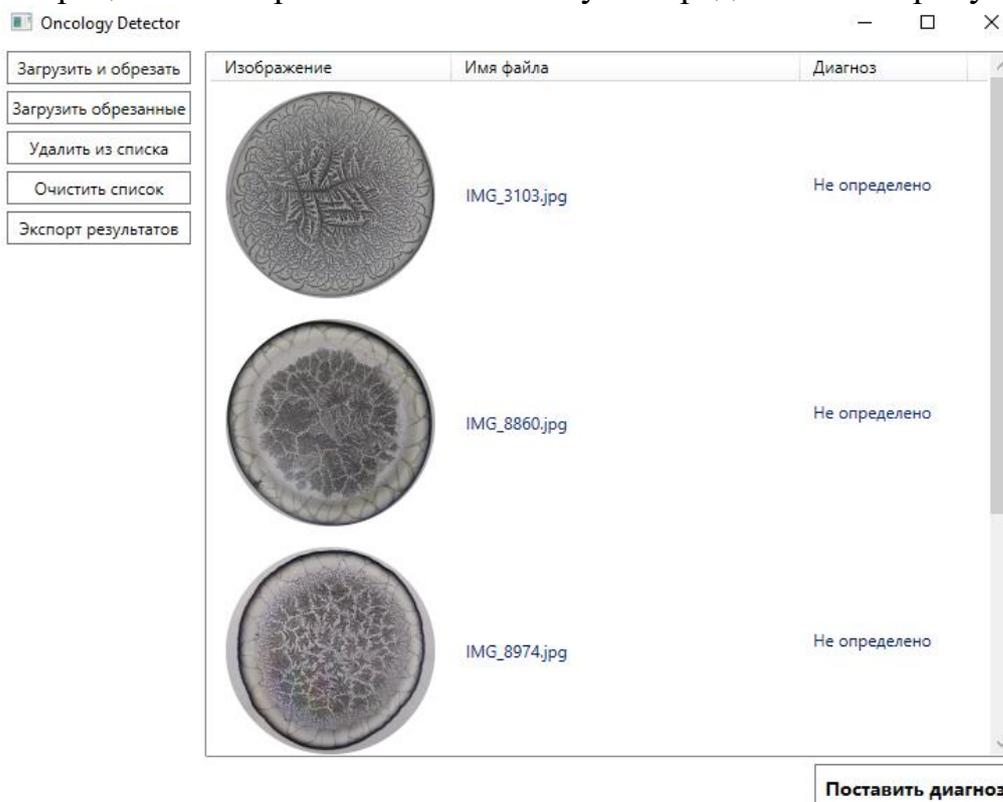


Рисунок 2. Внешний вид рабочего окна демонстрационного прототипа интеллектуальной системы

После нажатия на кнопку «Загрузить и обрезать» и выбора изображения с фацией открывается окно, предоставляющее интерфейс для обрезки фации по кругу, как этого требует нейронная сеть.

После завершения загрузки изображений и нажатия кнопки «Запуск» в рабочем окне запустится диагностика, по завершению которой в этом же окне будет выдан результат. На рисунке 3 изображен скриншот рабочего окна демонстрационного прототипа в момент диагностики фаций плевральной жидкости трех пациентов. Как видно из рисунка, у первого пациента интеллектуальная система обнаружила злокачественный выпот с вероятностью 71%, у второго – онкопатологию с вероятностью 84%, у третьего пациента признаков онкологии не обнаружено с вероятностью 83%.

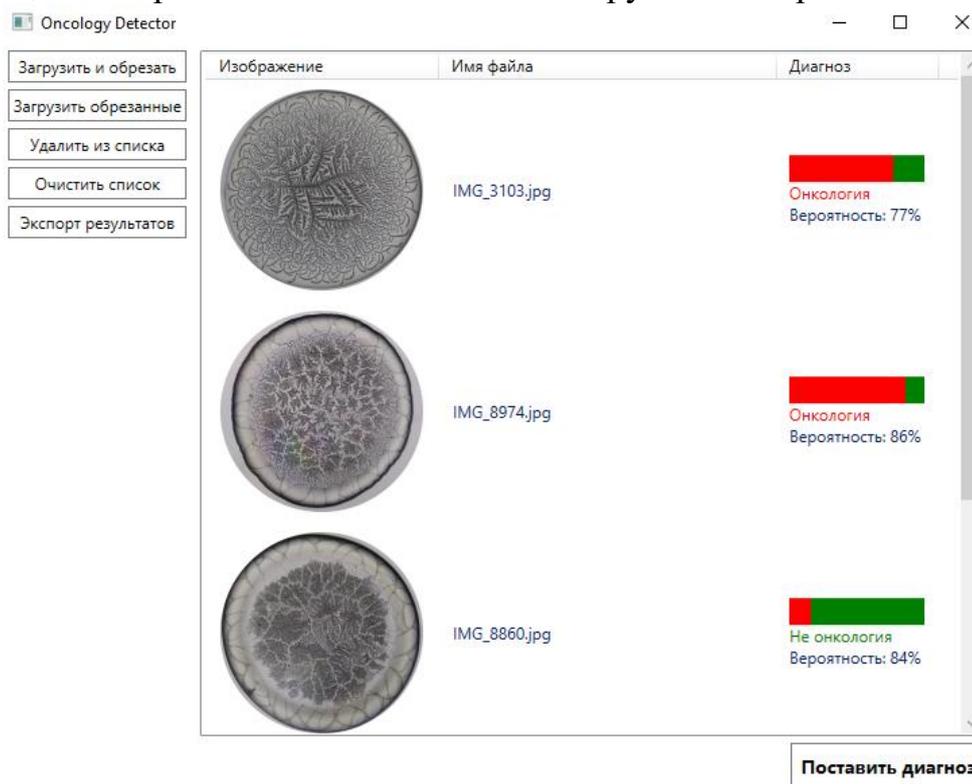


Рисунок 3. Внешний вид рабочего окна демонстрационного прототипа интеллектуальной системы в момент диагностики

После завершения диагностики имеется возможность сохранить результаты в файл путем нажатия на кнопку «Экспорт результатов».

Заключение. Проведенное исследование показало возможность использования автоматического анализа изображений фаций плеврального выпота, полученных клиновидной дегидратацией, с помощью сверточных нейронных сетей для выявления злокачественной патологии плевры простым малотравматичным способом. Точность диагностики будет постоянно увеличиваться благодаря способности сверточных нейронных сетей к самообучению с накоплением числа наблюдений. Достигнутые результаты ограничены малым количеством данных и не всегда высоким качеством анализируемых изображений.

Увеличение числа обследованных пациентов способно не только повысить эффективность диагностики онкопатологии, но и использовать

разработанный прототип нейронной сети для распознавания других заболеваний, вызывающих плевральный выпот.

Использование нейросетевых методов при диагностике онкологических заболеваний позволит существенно экономить время и стоимость обследований пациентов, что, в свою очередь, позволит повысить выявляемость злокачественных новообразований, а значит и эффективность их лечения.

Библиографический список

1. McCracken D.J. Malignant pleural effusions: management options / D.J. McCracken, J.M. Porcel, N.M. Rahman // *Semin Respir Crit Care Med.* – 2018. – Vol. 39, №6. – P. 704-712. 201.
2. Management of benign pleural effusions using indwelling pleural catheters: a systematic review and meta-analysis / M. Patil, S.S. Dhillon, K. Attwood et al. // *Chest.* – 2017. – Vol. 151, №3. – P. 626-635.
3. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition // *Proc. International Conference on Learning Representations.* – 2015. P. 1-14.
4. SPan S.J., Yang Q. A Survey on Transfer Learning // *IEEE Transactions on Knowledge and Data Engineering.* – 2010, 22, 1345-1359.
5. Colaboratory [электронный ресурс]. URL: <https://colab.research.google.com/> (дата обращения 13.02.2019).

NEURAL NETWORK SYSTEM FOR DIAGNOSIS OF MALIGNANT PLEURAL EFFUSION BY PHOTOGRAPHS OF FACIES PLEURAL FLUID OBTAINED BY THE METHOD OF WEDGE DEHYDRATION

Mitrofanov Igor A., Yasnitsky Leonid N.

Perm state University, 15, Bukireva str., Perm, Russia, 614990,
yasn@psu.ru

Plaksin Sergei A., Farshatova Lily I.

Perm state medical University. academician's
E. A. Wagner, 614000, Russia, Perm, Petropavlovsk, 26

The article describes the experience of the development and application of convolutional neural networks for the diagnosis of cancer in humans based on images of dried drops of pleural fluid.

Key words: Oncology, pleural effusion, neural network, diagnostics.

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ДИАГНОСТИКИ И ПРОГНОЗИРОВАНИЕ ГИПОТОНИИ

Русаков Сергей Владимирович, Лузина Екатерина Юрьевна

Пермский государственный национальный исследовательский университет,
614990, Россия, г. Пермь, ул. Букирева, 15, kateluzina59@gmail.com

В статье описан опыт разработки и применения системы двух нейропакетов для диагностики, прогнозирования и выявления новых знаний в области такого заболевания сердечно-сосудистой системы, как гипотония. Артериальная гипотензия может привести к развитию более тяжёлой сердечно-сосудистой патологии, может осложнить течение беременности и родов. В связи с этим представляется важным раннее выявление признаков дезадаптации или напряжения регуляторных систем и снижения адаптационных возможностей организма.

Ключевые слова: прогнозирование заболевания, гипотония, нейронная сеть, Python, Keras, Нейросимулятор.

Артериальная гипотензия (АГ) – это снижение артериального давления (АД) более, чем на 20% от нормальных значений. В абсолютных цифрах систолическое АД меньше 90 мм рт. ст. или среднее АД меньше 60 мм рт.ст. АД считается низким при уровне меньшем 100/60 мм рт.ст. для мужчины и меньшем 95/60 мм рт.ст. для женщины, но в покое оно встречается как вариант нормы и у здоровых лиц, у спортсменов и жителей высокогорья. АГ признается патологической в тех случаях, когда она сопровождается клинической симптоматикой и снижением качества жизни, а также бытовой и профессиональной активности. В работе [1] отмечается, что нормы, классификация и диагностические стандарты для АГ разработаны недостаточно.

В работах [2, 3] были успешно применены методы нейронных сетей для прогнозирования сердечно-сосудистых заболеваний, что говорит о целесообразности применения таких методов в области медицины.

Для прогнозирования гипотензии было решено применять методы искусственного интеллекта, в частности, нейронные сети. Были применены две реализации нейронных сетей: пакет «Нейросимулятор5», а также была написана программа на языке программирования Python с использованием библиотек Keras и Pandas.

Множество данных для выполнения работы были предоставлены кандидатом медицинских наук, доцентом Пермской медицинской академии Т.Ю. Агафоновой.

Исследуемая выборка включает показатели здоровья 73 девушек от 18 до 33 лет, у 47 из которых диагностирована гипотония. При построении нейросетевой модели использовались следующие параметры: сердечный индекс, напряжение сдвига позвоночной артерии, напряжение сдвига легочной артерии, напряжение сдвига заднебольшеберцовой артерии, скорость восстановления позвоночной вены, скорость восстановления легочной вены, скорость восстановления заднебольшеберцовой вены. Все показатели были взяты у пациентов после физической нагрузки.

Множество примеров было разбито на обучающее, состоящее из 47 примеров, использованное для обучения сети, и тестирующее множество, состоящее из 25-ти примеров, предназначенное для проверки ее прогностических свойств. Оптимальная структура нейронной сети, изображенная на рисунке 1 представляла собой персептрон, имеющий семь нейронов, два скрытых слоя с тремя и двумя нейронами и один выходной нейрон.

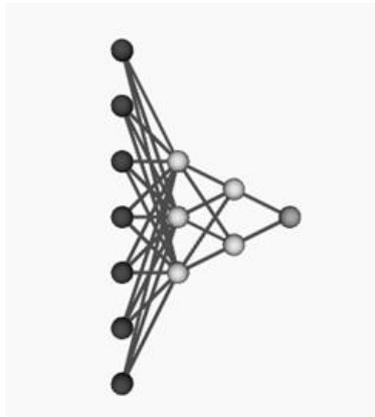


Рисунок 1. Структура нейронной сети, спроектированной в пакете «Нейросимулятор5»

Ошибка нейронной сети полученной таким путем была вычислена по формуле среднеквадратичной ошибки $MSE = \frac{1}{N} \sum_{i=0}^N (\hat{y}_i - y_i)^2$ и составила **7,6%**.

Далее, средствами нейропакета «Нейросимулятор 5» были выявлены наиболее значимые параметры. И для обучающего множества, и для тестирующего значимыми параметрами оказались следующие: сердечный индекс, напряжение сдвига заднебольшеберцовой артерии, скорость восстановления легочной вены. Самым значимым параметром является напряжение сдвига заднебольшеберцовой артерии. Зависимость вероятности гипотонии от напряжения сдвига заднебольшеберцовой артерии представлено на рисунке 2. Как можно заметить, если напряжение сдвига заднебольшеберцовой артерии превышает 50, то вероятность гипотонии резко возрастает.

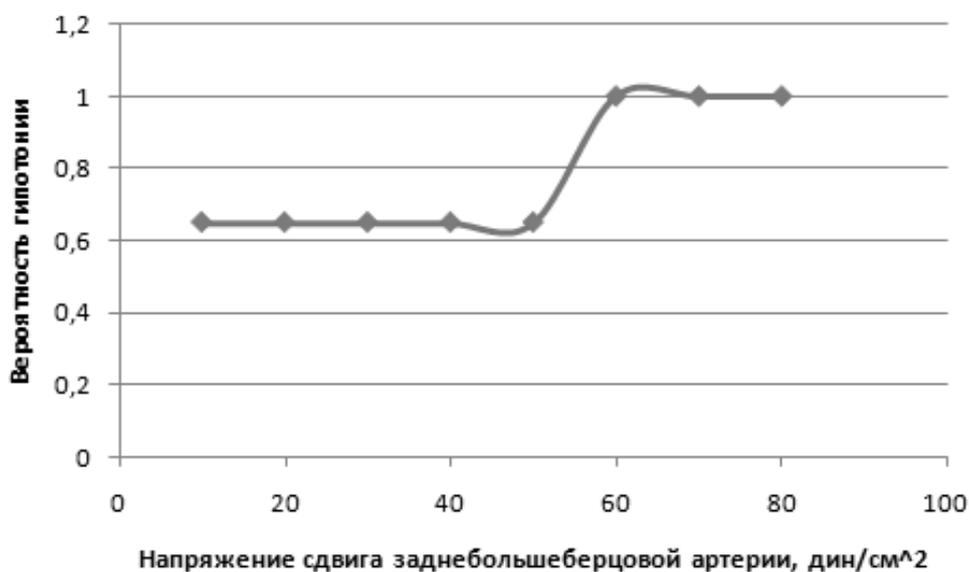


Рисунок 1. Зависимость вероятности гипотонии от напряжения сдвига заднеболюшеберцовой артерии

Также была проверена адекватность сети, представленная с помощью диаграммы сравнения реальных результатов, результатов полученных с помощью нейросимулятора и результатов, полученных с помощью программы на языке Python, о которой речь пойдет далее. Диаграмма сравнения представлена на рисунке 3.

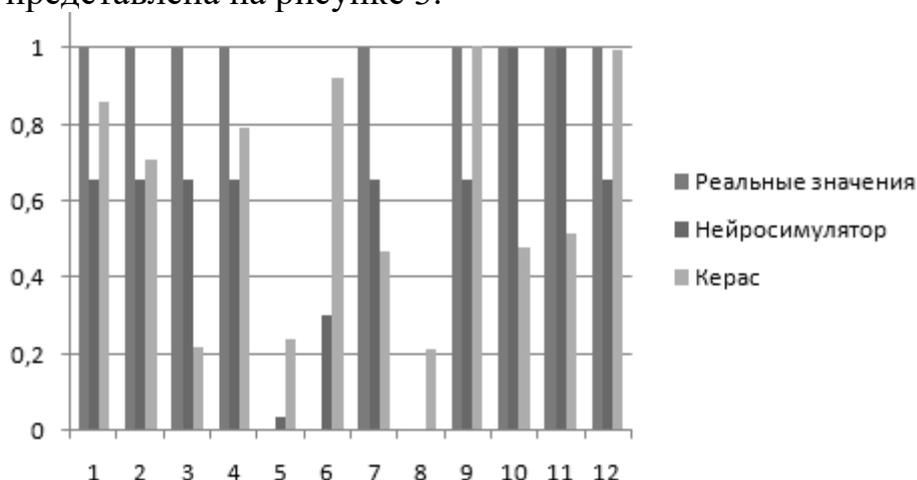


Рисунок 3. Сравнение результатов, полученных в Нейросимуляторе и с помощью программы, использующей библиотеку Keras

Для получения результатов с использованием библиотеки Keras была написана программа на языке Python. Программа была написана по аналогии с программой, представленной в работе [4]. Для разделения множества значений на обучающее и тестовое была использована библиотека Pandas, в которой задается общее множество значений, и отношение, в котором это множество нужно разделить, в данной работе использовалось значение 15%.

Ошибка, полученная с помощью программы, была вычислена так же по формуле среднеквадратической ошибки и составила 20,85% .

Заключение. Как можно видеть на диаграмме, ни результаты, полученные в Нейросимуляторе, ни с использованием Keras, нельзя считать достоверными, так как, можно заметить что ошибка в обоих случаях имеет существенное значение – 7,6% и 20,85%. Однако, наблюдается, что и нейросимулятор и Keras в большинстве случаев показывают результат, приближенный к реальным значениям, но Нейросимулятор справляется лучше на 13,25%.

Библиографический список

1. Кудрявцева Е.Н. Особенности кардиальной и церебральной гемодинамики, социально-психологической адаптации и качества жизни молодых женщин с идиопатической артериальной гипотензией: дис. Пермь, канд. мед. наук. Перм. гос. мед. университет им. ак. Е. А. Вагнера, Пермь, 2016.
2. 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(279). С. 42-44.
3. Овчинкин О.В., Овчинкина Т.В., Павлов О.Г. Персональное моделирование заболеваний сердечнососудистой системы с применением нейронных сетей и инструментальных средств // Вестник новых медицинских наук. 2011. №4. С. 41.
4. Онлайн курс «Программирование глубоких нейронных сетей на Python» [электронный ресурс] <https://www.asozykin.ru/courses/nnpython>

NEURAL NETWORK MODELING TO DIAGNOSE AND PREDICT THE HYPOTENSION

Luzina Ekaterina Y.

Perm State University

614990, Russia, Perm, street bukireva, 15, kateluzina59@gmail.com

The article describes the experience of developing and using the system of two neuropackets for diagnosing, predicting and identifying new knowledge in the field of such diseases of the cardiovascular system, like hypotension. Hypotension can lead to the development of more severe cardiovascular pathology, may complicate the course of pregnancy and childbirth. In this regard, it is important to early identify signs of maladaptation or tension of regulatory systems and reduce the adaptive capacity of the organism.

Key words: disease prognosis, hypotension, neural network, Python, Keras, neurosimulator.

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ПРОГНОЗИРОВАНИЕ ОПАСНОСТИ ЗАБОЛЕВАНИЯ СЕРДЕЧНО-СОСУДИСТОЙ СИСТЕМЫ

Субботин Евгений Андреевич

Пермский государственный национальный исследовательский университет,
ПМИ, 614990, Россия, г. Пермь, ул. Букирева, 15, subbotinjenay@mail.ru

В статье описан опыт разработки нейросетевой системы для прогнозирования опасности заболевания сердечно-сосудистой системы. Система позволяет спрогнозировать опасность ССС. В качестве входных параметров используются пол, полные года, тип боли в груди, артериальное давление в покое, уровень холестерина, уровень сахара в крови, результаты электрокардиографии в покое и др. Всего 13 входных параметров.

Ключевые слова: система прогнозирования заболевания сердечно-сосудистой системы, нейронные сети, искусственный интеллект.

В современном мире все больше находят применение нейронные сети в разных областях нашей жизни. Представителями Пермской научной школы искусственного интеллекта проводятся работы по применению метода нейросетевого моделирования в здравоохранении [1-4].

В 1990 году Вильям Бакст из Калифорнийского университета в Сан-Диего использовал нейронную сеть – многослойный персептрон – для распознавания инфаркта миокарда у пациентов, поступающих в приемный покой с острой болью в груди. Так или иначе, уже сейчас можно констатировать, что нейронные сети превращаются в инструмент кардиодиагностики – в Англии, например, они используются в четырех госпиталях для предупреждения инфаркта миокарда.

В настоящей статье предпринята попытка на базе нейронных сетей разработать систему для прогнозирования заболевания сердечно-сосудистой системы. Данными для обучения такой сети послужил датасет, собранный Венгерским институтом кардиологии в Будапеште [5].

Данный датасет имеет множество из 304-х примеров для обучения с 13-ю входными параметрами. В датасете присутствуют параметры, такие как пол, полные года, тип боли в груди, артериальное давление в покое, уровень холестерина, уровень сахара в крови, результаты электрокардиографии в покое, максимальная частота сердечных сокращений, стенокардия, вызванная физической нагрузкой, депрессия ST, вызванная физическими упражнениями относительно отдыха, наклон пика сегмента ST, количество крупных сосудов (0-3), окрашенных с помощью флюороскопии, ЧСС.

Проектирование, оптимизация, обучение, тестирование нейронной сети, также эксперименты над нейросетевой мат. моделью выполнялись с помощью программы «Нейросимулятор 5» [6], а также библиотеки Keras и TensorFlow. Структура нейронной сети представляет собой персептрон, имеющий 13 входных нейронов из датасета, 1 скрытый слой с 3-мя нейронами и 1 выходной нейрон.

На входном слое использовалась функция активации relu. Также в модели был использован скрытый слой из 3-х нейронов, функция активации которого – сигмоида. Между входным слоем и скрытым слоем находится dropout(0.2), который с шансом 20% не использует нейрон для формирования весов, что позволяет предотвратить переобучение сети.

Relu: $f(x) = \max(x, 0)$

Sigmoid: $f(x) = \frac{1}{1+e^{-x}}$

Для обучения нейронной сети было сформировано множество примеров (247 шт.), основанное на датасете. Также были составлены тестирующее множество, состоящие из 27-ми примеров и валидирующее множество для проверки из 30-ти примеров, не участвовавших в обучении нейронной сети.

После обучения прогностические свойства нейронной сети проверялись на примерах валидирующего множества. Результат представлен на гистограмме (Рисунок 1).

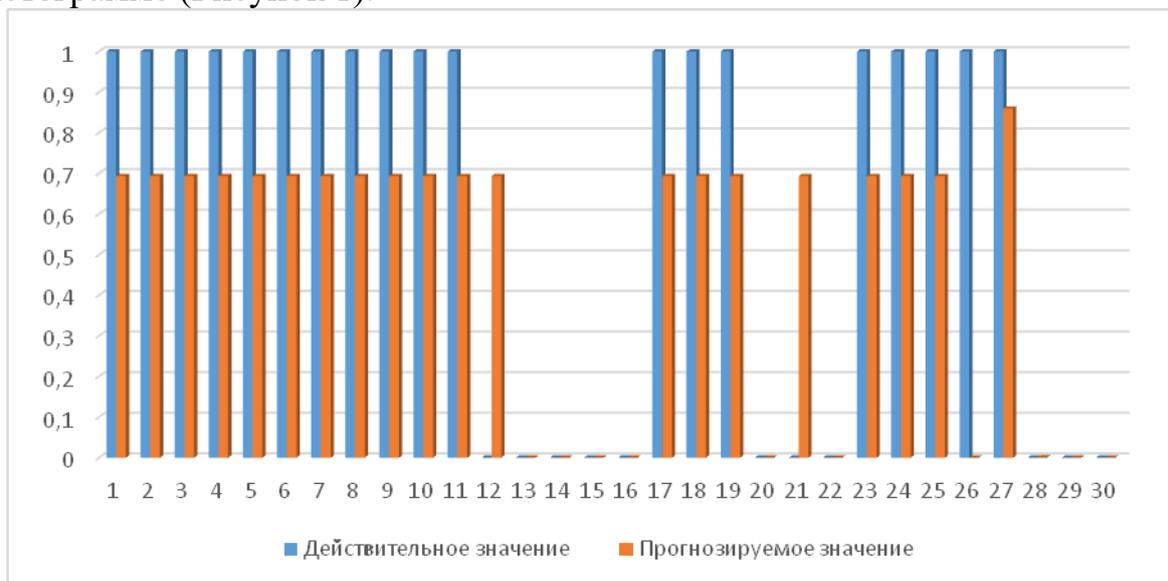


Рисунок 1. Проверка модели

Как видно из рисунка 1, нейросеть ошиблась в трех случаях из тридцати. Это примеры: 12, 21 и 26. Дополнительные тестирования нейронной сети не зафиксировали значительного увеличения погрешности. Таким образом, мы пришли к выводу, что нейронная сеть усвоила закономерности моделируемой предметной области.

Было проведено исследование влияния уровня холестерина на человека 59 лет; без боли в груди; артериальным давлением 164; с повышенным сахаром в крови; нормальным результатом кардиографии; максимальным

сердцебиением 100 уд/мин в покое; без стенокардии под нагрузкой; депрессия ST, вызванная физическими упражнениями относительно отдыха, со значением 1.0; наклон пика упражнений сегмента ST = 0 (наклон вверх); количество крупных сосудов, окрашенных с помощью флюороскопии равно 1; ЧСС – зафиксирован дефект. Результат приведен ниже (Рис. 2).



Рисунок 2. Зависимость опасности заболевания ССС от уровня холестерина

Как видно из графика холестерин не влияет на состояние пациента.

С теми же параметрами было протестировано влияние параметра Slope – наклон пика сегмента ST. Результат представлен на рисунке 3.

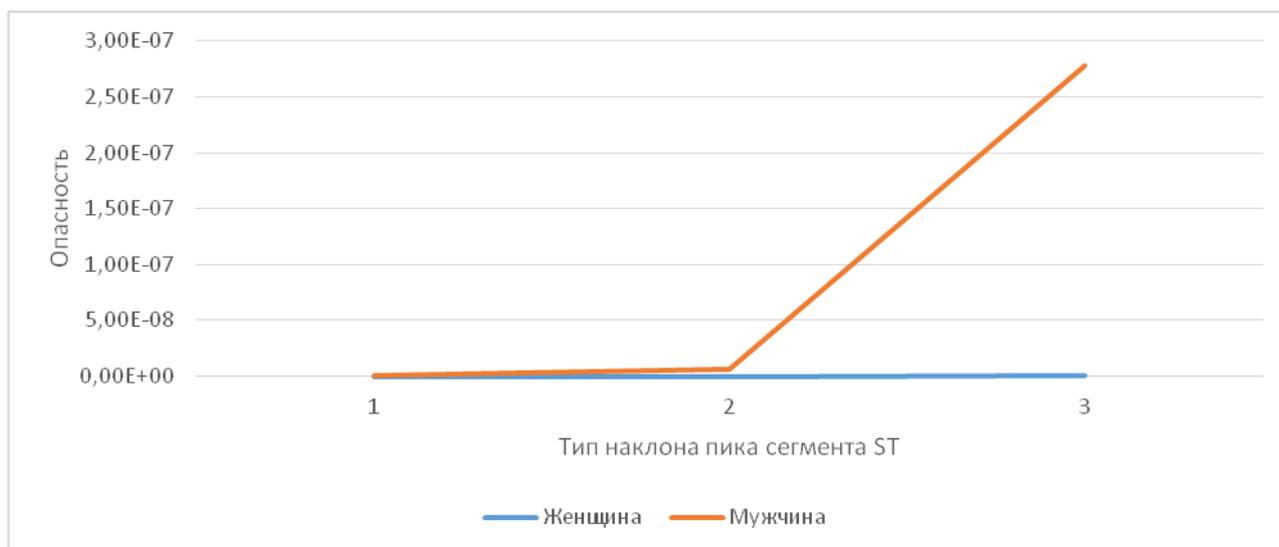


Рисунок 3. Зависимость опасности заболевания ССС от типа наклона пика сегмента ST

Наклон пика имеет сильное влияние на состояние пациента. Где 0 – наклон вверх, 1 – плоский, 2 – наклон вниз. При наклоне пика ST вниз у мужчины опасность заболевания ССС возрастает.

Также было исследовано влияние возраста на опасность ССС для мужчин и женщин. Результат представлен ниже (Рисунок 4).

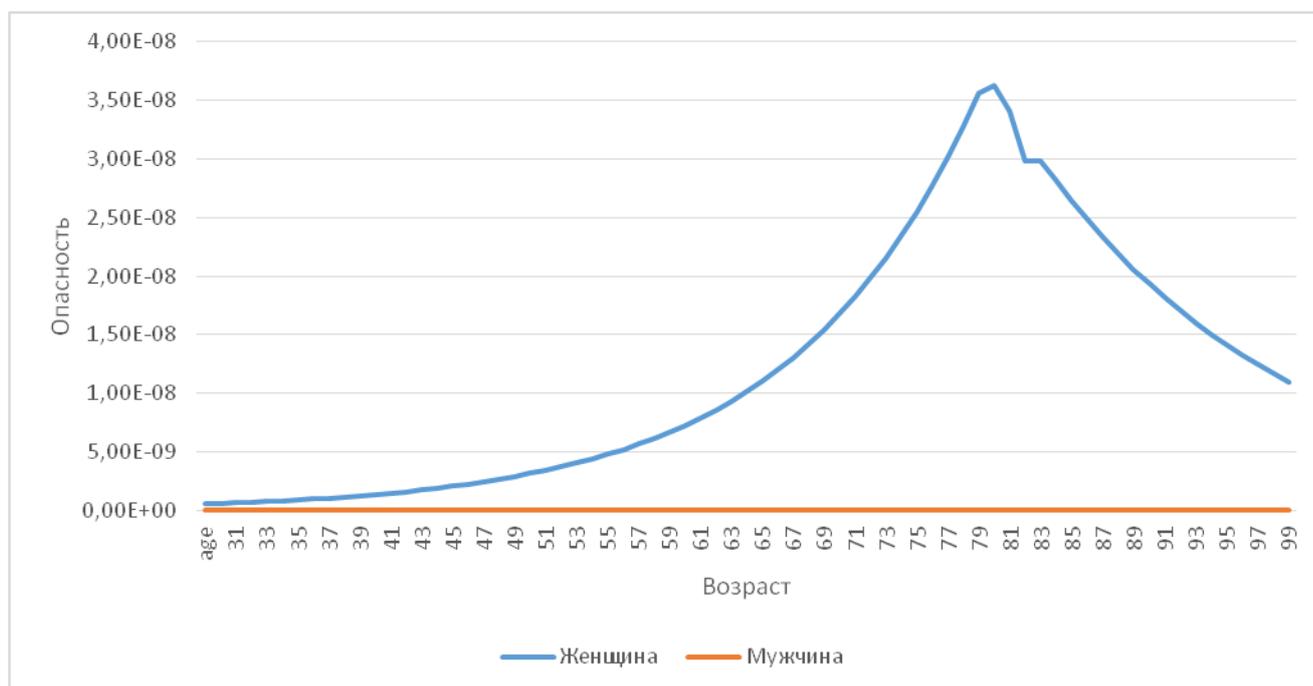


Рисунок 4. Зависимость опасности заболевания ССС от возраста

Заключение. Разработана нейросетевая модель, с помощью которой выполнен прогноз заболевания сердечно-сосудистой системы. Показана возможность применения нейросетевых технологий в сфере здравоохранения, в частности кардиологии.

Библиографический список

1. Yasnitsky L.N., Dumler A.A., Poleshchuk A.N., Bogdanov S.V., Cherepanov F.M. Artificial Neural Networks for Obtaining New Medical Knowledge: Diagnostics and Prediction of Cardiovascular Disease Progression // *Biology and Medicine* 2015. Т. 7. № 2. С. BM-095-15.
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., Зайцева Н.В., Гусев А.Л., Шур П.З. Нейросетевая модель региона для выбора управляющих воздействий в области обеспечения гигиенической безопасности // *Информатика и системы управления*. – 2011. – № 3 (29). – С. 51-59.
4. 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.
5. Kaggle [Электронный ресурс]. – URL: <https://www.kaggle.com/ronitf/heart-disease-uci> (дата обращения: 01.04.2019)

6. Нейросимулятор 5.0 : свидетельство о государственной регистрации программы для № 2014618208 от 12.07.2014 г. / Черепанов Ф.М., Ясницкий В.Л. (РФ).

NEURAL NETWORK MODELING PREDICTION OF RISK OF CARDIOVASCULAR DISEASE

Subbotin Evgeniy Andreevich

Perm State University 614990, Russia, Perm, 15 Bukireva str., student@mail.ru

The article describes the experience of developing a neural network system for predicting the risk of cardiovascular disease. The system makes it possible to predict the danger of cardiovascular disease. As input parameters used gender, full year, type of chest pain, resting blood pressure, cholesterol, blood sugar level, resting electrocardiographic results, etc. A total of 13 input parameters.

Key words: cardiovascular disease prognosis system, neural networks, artificial intelligence.

ПРОГНОЗИРОВАНИЕ КОЭФФИЦИЕНТА ЕСТЕСТВЕННОГО ПРИРОСТА НАСЕЛЕНИЯ РЕГИОНОВ РОССИИ ПРИ ПОМОЩИ НЕЙРОСЕТЕЙ

Теплых П. Д.

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

В статье представлено описание разработки нейросетевой системы для прогнозирования коэффициента естественного прироста регионов России при помощи нейросимулятора Nsim (Нейросимулятор 5.0) и библиотеки Keras на Python. Результаты работы позволяют сравнить точность разработанных систем. Обе системы позволяют спрогнозировать коэффициент естественного прироста по одиннадцати входным параметрам, таким как численность безработных, среднедушевые денежные доходы, заболеваемость на 1000 человек населения и т.д. Также система обладает возможностью выявления тенденции изменения коэффициента естественного прироста в зависимости от входных параметров

Ключевые слова: искусственный интеллект, нейросетевые технологии, коэффициент естественного прироста, прогнозирование, Keras.

Демографическая ситуация, т.е. состояние воспроизводства населения, в настоящее время привлекает к себе все большее внимание властных структур и общественности на федеральном и региональном уровне. Это обусловлено тем, что демографический фактор в значительной степени определяет перспективы развития любого общества. В подавляющем большинстве российских регионов демографическую ситуацию можно охарактеризовать как неблагоприятную [1].

Важнейшей составляющей экономики является человеческий капитал, поэтому каждый член общества представляет собой социальную ценность высшего порядка. Прогнозирование поможет приблизительно узнать возможный эконометрический рост субъекта, как и страны, в будущем, о чем говорится в книге [2].

Для проектирования системы необходимо определить входные параметры, с помощью которых будет прогнозироваться коэффициент естественного прироста автотранспорта. После анализа литературы были определены критерии, влияющие на цену автомобиля: X1 – Численность безработных, X2 – Среднедушевые денежные доходы населения, X3 – Выпуск бакалавров, специалистов, магистров, X4 – Выпуск квалифицированных рабочих и служащих, X5 – Заболеваемость на 1000

человек населения, X6 – Численность зрителей театров и число посещений музеев на 1000 человек населения, X7 – Выбросы загрязняющих веществ в атмосферный воздух, отходящих от стационарных источников, X8 – Использование свежей воды, X9 – Стоимость фиксированного набора потребительских товаров и услуг, X10 – Средние цены на первичном рынке жилья, X11 – Средние цены на вторичном рынке жилья. Выходной параметр D – Коэффициент естественного прироста на 1000 человек населения. Выбор большинства показателей обусловлен работами [3, 4].

Обучающее множество примеров было составлено на основе реальных данных, полученных из официального источника – сайта Росстата [5]. Данное множество состоит из 728 примеров, в него входят показатели различных российских регионов.

Проектирование нейронной сети в программе «Нейросимулятор 5» [6] было осуществлено по методике [7]. Была определена структура перцептрона с одиннадцатью входными параметрами, одним выходным параметром и одним скрытым слоем с тремя нейронами на нём. В данной модели выбор пал на количество итераций, равное 6000 в модели при использовании функции гиперболического тангенса для входного, выходного слоев и скрытого слоя, на котором находятся 3 нейрона. Данная модель показала наилучшие результаты. В качестве алгоритма обучения был выбран алгоритм упругого распространения.

Для проверки результатов обученной нейросети было использовано тестирующее множество, состоящее из 40 примеров. График, отображающий разницу между действительной стоимостью и спрогнозированной, представлен на рисунке 1. Вычисленная погрешность полученных результатов на тестирующем множестве составляет 9,51%. Данное значение ошибки можно считать приемлемым.

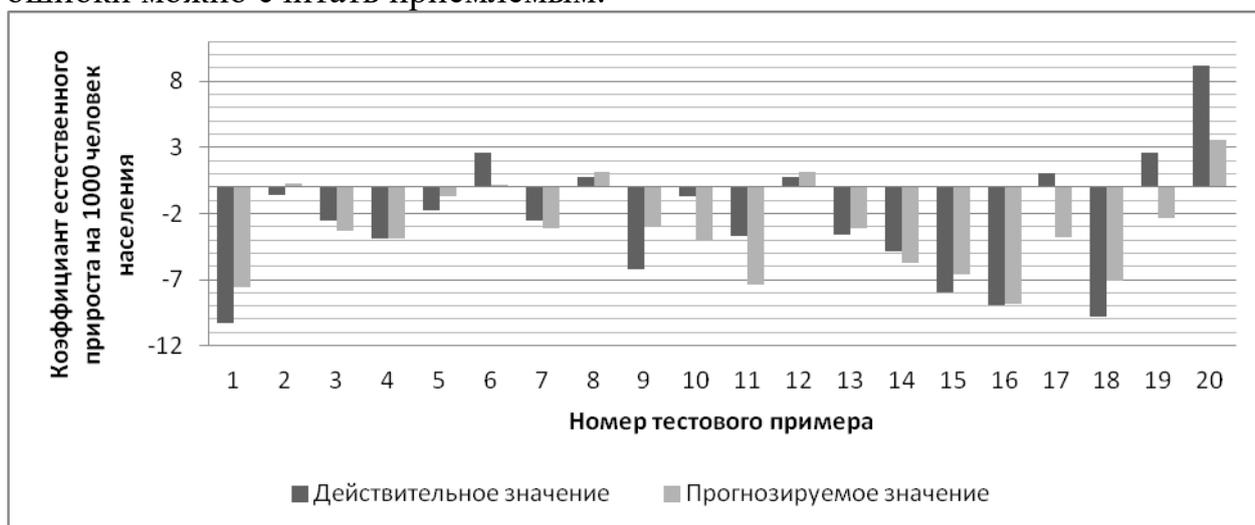


Рисунок 28. Результаты тестирования нейронной сети

Проанализируем полученную сеть используя «Нейросимулятор 5», получаем данные о значимости параметров (рисунок 2).

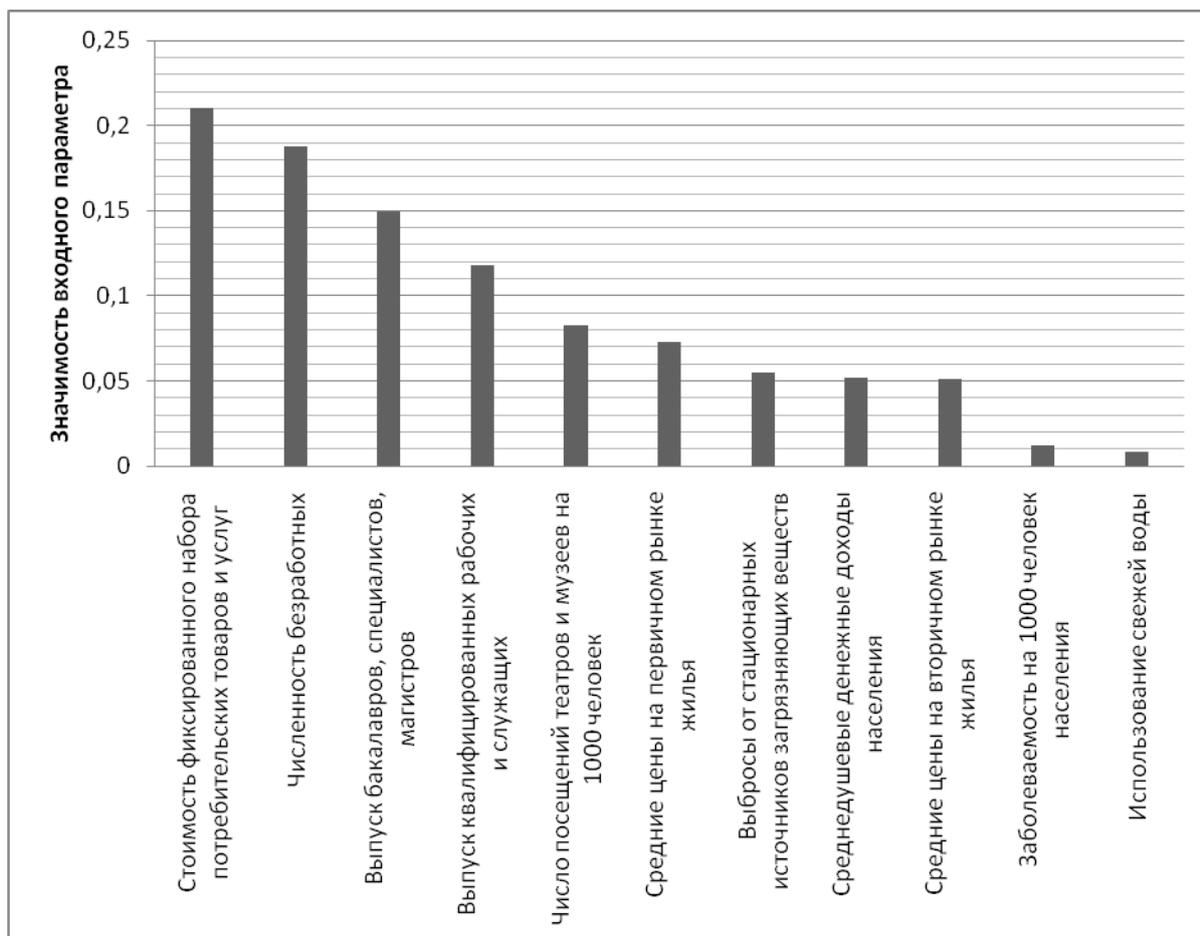


Рисунок 29. Значимость входных параметров

Исходя из полученных данных, выяснилось, что наибольшее влияние на коэффициент естественного прироста имеет параметр: «Стоимость фиксированного набора потребительских товаров и услуг». Рассмотрим тенденции изменения коэффициента естественного прироста в зависимости от этого параметра.

На рисунке 3 представлены тенденции изменения коэффициента естественного прироста в зависимости от изменения стоимости фиксированного набора потребительских товаров и услуг при прочих равных параметрах, взятых из значений по Пермскому краю за 2016 год.

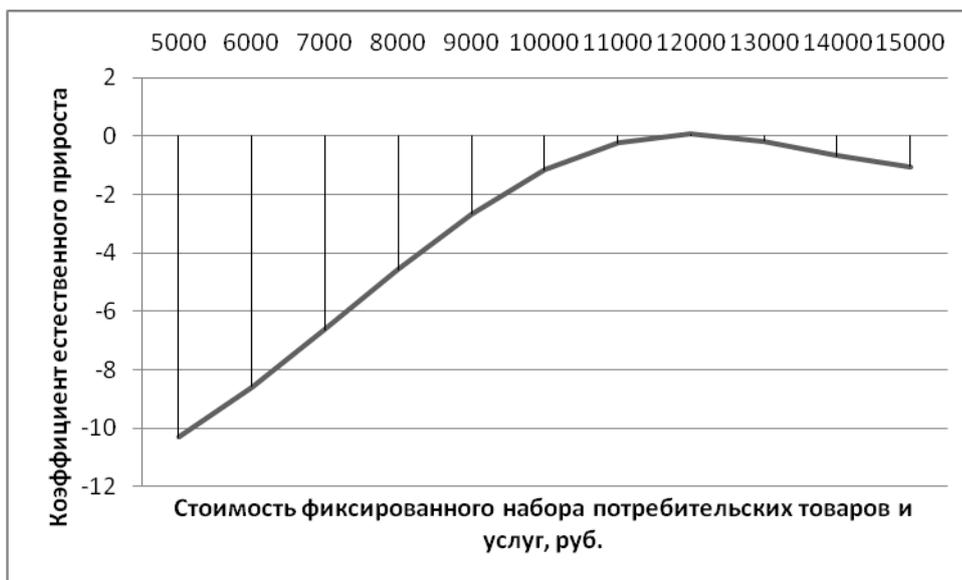


Рисунок 30. Зависимость коэффициента естественного прироста от стоимости фиксированного набора потребительских товаров и услуг

По графику можно заметить, что при увеличении стоимости фиксированного набора потребительских товаров и услуг увеличивается коэффициент естественного прироста.

В качестве второй технологии построения системы применялась нейронная сеть с использованием готовой библиотеки Keras, для этого была написана программа на языке Python.

График, отображающий разницу между действительной стоимостью и спрогнозированной, представлен на рисунке 4. Вычисленная погрешность полученных результатов на тестирующем множестве составляет 3,58%. Данное значение ошибки можно считать приемлемым.

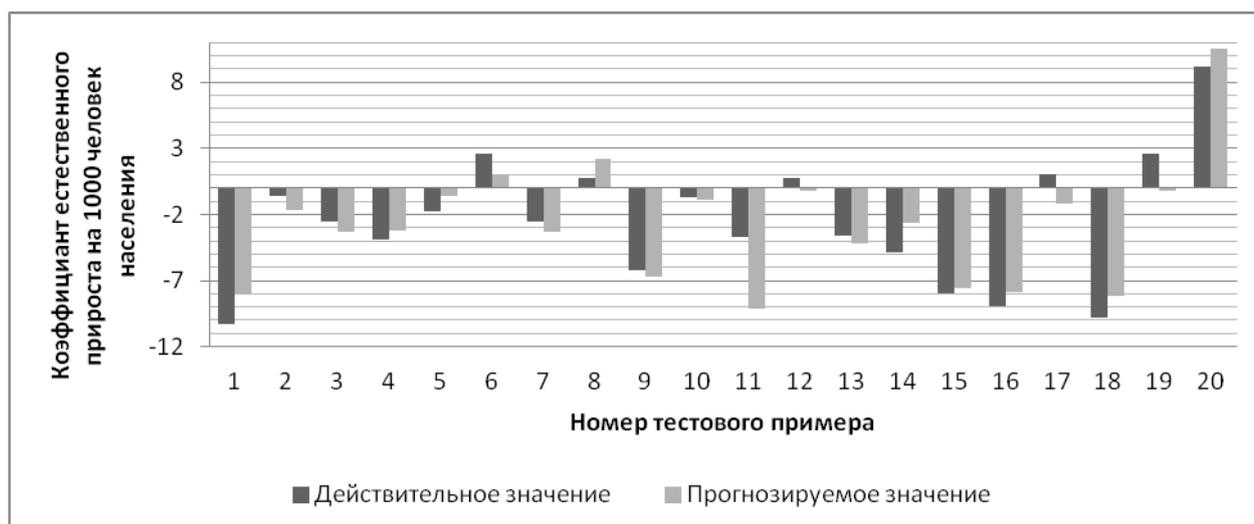


Рисунок 4. Результаты тестирования сети с использованием библиотеки Keras

Заключение. В ходе выполнения работы были применены две технологии для прогнозирования коэффициента естественного прироста. В качестве результата были получены приемлемые ошибки прогнозирования:

ошибка Нейросимулятора равна 9,51%. ошибка в Keras 3,58%. На их основе можно сделать вывод, что для прогнозирования данного показателя применение программы с использованием библиотеки Keras дает меньшее значение ошибки, по сравнению с Нейросимулятором.

Библиографический список

1. Реутова М. Н. Факторы естественного прироста населения белгородской области: социологический анализ, 2010. № 14 (85). Выпуск 13.
2. Порошина Л. А. Эконометрика: учебное пособие для студентов экономических специальностей вузов региона. – Хабаровск: Издательство ТОГУ, 2011. – 86 с.
3. Астапчик О.В. Статистический анализ влияния социально-экономических факторов на естественный прирост населения в регионах России.
4. Михайлов А.А. Влияние экономических факторов на уровень естественного прироста населения.
5. Федеральная служба государственной статистики. Регионы России. Социально-экономические показатели. 2017, стр. 1-1404.
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 2014 г.
7. Ясницкий Л.Н. Введение в искусственный интеллект. М.: Издательский центр «Академия», 2005. – 176 с.

NATURAL GROWTH RATE OF THE RUSSIAN REGIONS WITH THE HELP OF NEURAL NETWORKS

Теплых Полина Д.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990, pteplich@gmail.com

This article describes the development of a neural network system for predicting the natural growth rate of Russian regions using the Nsim neurosimulator (Neurosimulator 5.0) and the Keras library in Python. The results of the work allow us to compare the accuracy of the developed systems. Both systems make it possible to predict the rate of natural increase in eleven input parameters, such as the number of the unemployed, the average per capita cash income, the incidence per 1000 population, etc. The system also has the ability to detect trends in the coefficient of natural increase depending on input parameters.

Key words: artificial intelligence, neural network technologies, natural growth rate, forecasting, Keras.

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ РАСЧЁТА ДОЗИРОВКИ ИНСУЛИНА ДЛЯ БОЛЬНЫХ САХАРНЫМ ДИАБЕТОМ

Чусовлянкин Алексей Александрович

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

Работа посвящена применению искусственных нейронных сетей для расчета дозировки инсулина. Решаемая задача является оптимизационной в многомерном дискретном пространстве. Необходимо вычислить дозу инсулина для больного сахарным диабетом. Дозировка инсулина может зависеть от различных персональных характеристик пациента. На сегодняшний день не существует общепризнанного алгоритма для расчета дозировки инсулина. Пациент вручную определяет дозу инсулина исходя из личной накопленной статистики и рекомендаций врача.

Ключевые слова: нейросети, сахарный диабет, дозы инсулина.

Введение. Сегодня диабетом страдает более 450 миллионов человек на планете, это примерно 6 % населения земного шара. Данное заболевание актуально в наши дни так как, по прогнозам, к 2040 году, по расчетам международной федерации диабета, этот диагноз будет у 642 миллионов человек [1,2]. На сегодняшний день некоторые больные сахарным диабетом вычисляют необходимую дозировку инсулина вручную, бессистемно. Для того, чтобы решить данную проблему, предлагается использовать нейронные сети, которые являются наиболее эффективным инструментом интеллектуального анализа данных [3,4]. Ранее автором были рассмотрены методы классификации и регрессионного анализа для расчета дозировки, которые показали среднюю относительную погрешность от 20% до 50% для разных пациентов [5,6].

В работе для решения данной задачи предлагается использовать искусственные нейронные сети. Для работы алгоритма необходимы данные из дневника самоконтроля пациента, который содержит информацию об уровне глюкозы в крови, дозировке инсулина и количестве употребленных хлебных единиц в определенные часы.

Проектирование. Задача нейросети – на основе полученных данных о пациенте вычислять единственный параметр: дозировку инсулина. Известны следующие входные параметры (которые получены из дневника самоконтроля):

- 1) текущий уровень глюкозы в крови до еды (от 1,5 до 20,0);
- 2) количество употребленных хлебных единиц (ХЕ) во время еды (от 0 до 20);

- 3) время введения дозы инсулина (от 0:00 до 23:59);
- 4) доза инсулина (от 0 до 20);
- 5) уровень глюкозы через 3-4 часа после еды (от 1,5 до 20,0).

Разработка нейросети выполнена с помощью интерактивной оболочки Python. Используются библиотеки Tensorflow, Keras, Sklearn. Наиболее качественные результаты по прогнозированию дозы инсулина были продемонстрированы на нейросетях с двумя скрытыми слоями. На первом слое предлагается использовать от 4 до 8 нейронов с выпрямленной линейной функцией активации (rectified linear unit), которая позволяет приблизить нелинейные зависимости [5]. На втором слое используется 2 нейрона с функцией softplus. Обучение нейросети проходит с помощью оптимизатора adam (adaptive moment estimation). Следует отметить, что для каждого пациента необходимо заново запускать нейросеть, поэтому объемы входных данных относительно небольшие (от 20 до 70 записей), что позволяет нейросети обучиться за 100 эпох.

Тестирование нейросети было проведено на основе дневников самоконтроля 4 пациентов с записями за 3-4 недели. Исходные данные были разделены на две выборки – для обучения алгоритмов и для прогнозирования в отношении два к одному. Проводится сравнение результатов нейросети с градиентным спуском для регрессии. Результаты прогнозирования доз инсулина представлены в табл. 1.

Таблица 1. Результаты прогнозирования

Пациент	Объем выборки и для обучения	Нейросети			Градиентный спуск		
		Сред. кв. откл.	Сред. отн. погр. (%)	Кол-во точных дозировок (%)	Сред. кв. откл.	Сред. отн. погр. (%)	Кол-во точных дозировок (%)
№1	22	3,2	11,8	54	3,5	22,2	36
№2	34	1,5	25,6	39	1,3	31,4	38
№3	45	5,9	17,8	35	11,8	27,7	22
№4	68	1,7	13,7	35	1,5	12,7	26

Результаты демонстрируют среднюю относительную погрешность от 35% до 54%, что подтверждают применимость нейросетей к данной задаче. Следует отметить, что в предыдущих работах для некоторых пациентов методы классификации и регрессионного анализа демонстрирует точность прогнозирования хуже, чем нейросети [5,6]. При исследовании зависимостей дозы инсулина от входных параметров было обнаружено, что для большинства пациентов доза инсулина зависит от уровня глюкозы и объема пищи линейно. Данные факты подтверждают практики врачей [8]. Также следует отметить нелинейную зависимость дозы инсулина от времени суток для некоторых пациентов (рис.1), что подтверждает работа про регрессионный анализ [7].

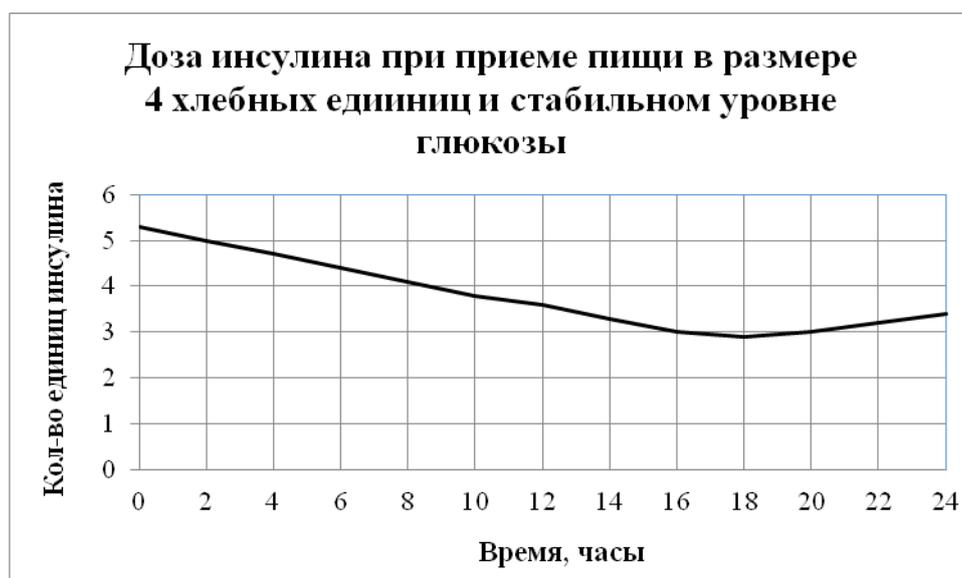


Рисунок 1. Зависимость дозы инсулина от времени суток при приеме пищи в размере 4 хлебных единиц и стабильном уровне глюкозы

В заключение необходимо отметить, что в рамках данного исследования разработана нейросеть с двумя скрытыми слоями, которая рассчитывает дозу инсулина на основе накопленной статистике пациента. Анализ работы алгоритмов показал применимость подхода к данной задаче, поскольку средняя относительная погрешность ниже, чем у сравниваемого алгоритма градиентного спуска. Надежность полученных результатов требует проверки на других пациентах. Практическая значимость работы состоит в том, что предложенный подход можно внедрить в приложение, которое позволило бы пациенту получать рекомендацию по расчету дозировки инсулина без обращения к врачу.

Библиографический список

1. IDF DIABETES ATLAS [Электронный ресурс] // Seventh edition International. Diabetes Federation. URL: <http://www.idf.org/about-diabetes/facts-figures> (Дата обращения: 24.03.2018).
2. Definition, diagnosis and classification of diabetes mellitus and its complications / Part 1: Diagnosis and classification of diabetes mellitus. World Health Organization, Geneva, 1999. Report Number: WHO/NCD/NCS/99.2.
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.
5. Чусовлянкин А. А. Алгоритмы расчета дозировки инсулина для больных сахарным диабетом / А. А. Чусовлянкин, В. В. Морозенко // Математика и междисциплинарные исследования – 2017. Материалы Всеросс. науч.-практ. конф. молодых ученых с международным участием, Т. 1. – Пермь: ПГНИУ, 2017. – С. 224-229.

6. Чусовлянкин А. А. Алгоритм k-ближайших соседей для расчета дозировки инсулина // SCM'2017. Сборник докладов международной конф. по мягким вычислениям и измерениям. – СПб.: ЛЭТИ, 2017. – С. 591-593.
7. Соколов Е. Семинары по нейронным сетям [Электронный ресурс] // MachineLearning. URL: http://www.machinelearning.ru/wiki/images/1/1e/Sem07_ann.pdf (Дата обращения: 24.03.2018).
8. Кадомский Ю. Точная инсулинотерапия сахарного диабета 1 типа. Практика точного расчета дозы инсулина [Электронный ресурс] // Библиотека Диа-Клуба. URL: <http://juri.dia-club.ru/index.php> (Дата обращения: 24.03.2018).

NEURAL NETWORK MODELING TO CALCULATE INSULIN DOSAGE FOR DIABETICS

Chusovliankin Aleksei A.

Higher School of Economics – National Research University, st. Studencheskaya,
38, Perm, Russia, 614070, lixich@mail.ru

Abstract. The article is devoted to neural network for calculating insulin dosage. For a patient with diabetes it is required to calculate find a dosage constantly. The development of neural network with high-quality precision would help maintain glucose levels in the norm. Nowadays, patients calculate the dose of insulin manually based on the accumulated statistics and recommendations of their doctors. The scientific novelty is that a new approach is proposed for calculating the dose of insulin.

Key words: neural network, diabetes, insulin dose.

ПОВЫШЕНИЕ КАЧЕСТВА ЛЕЧЕНИЯ ДИАБЕТИЧЕСКОГО МАКУЛЯРНОГО ОТЕКА НА ОСНОВЕ ТЕХНОЛОГИИ АВТОМАТИЧЕСКОГО ФОРМИРОВАНИЯ ПЛАНА КООГУЛЯТОВ

Широканев Александр Сергеевич, Ильясова Наталья Юрьевна

Институт систем обработки изображений – филиал ФНИЦ
«Кристаллография и фотоника» РАН, Молодогвардейская 151, Самара,
Россия, 443001
ilyasova.nata@gmail.com

В работе предложена технология автоматического формирования плана коагулятов для эффективного лечения диабетического макулярного отёка. Технология включает два ключевых этапа формирования плана коагулятов: выделение зоны лазерного воздействия, равномерная расстановка коагулятов в выделенную область. Выделение зоны воздействия осуществляется на основе совмещения разнородных данных, полученных при помощи ОКТ, и изображений глазного дна, а также применении метода сегментации на основе отобранных текстурных признаков. Ранние исследования показали, что для 4 классов изображений (экссудаты, толстые сосуды, тонкие сосуды и здоровые участки) оптимальным размером окна фрагментации является 12. Были также предложены 7 алгоритмов расстановки коагулятов для реализации второго этапа технологии. Исследование показало, что наиболее эффективное лечение обеспечивается алгоритмами, основанными на гексагональном и адаптивно-границном способах заполнения коагулятами зоны воздействия.

Ключевые слова: лазерная коагуляция, глазное дно, изображения глазного дна, текстурные признаки, интеллектуальный анализ данных, отбор признаков.

Сахарный диабет (СД) является одним из самых распространенных неинфекционных заболеваний в мире и достиг масштабов эпидемии, как в развивающихся странах, так и в большинстве развитых стран [1]. По данным Международной диабетической федерации к началу 2015 года в мире насчитывалось более 400 млн пациентов с сахарным диабетом (СД) [2]. Кроме того, количество людей с нарушением толерантности к глюкозе, которые с высокой долей вероятности могут пополнить группу больных с СД, во всём мире составляет 530 млн человек [2].

При СД происходит изменение кровеносных сосудов сетчатки, которое приводит к нарушению обеспечения сосудов сетчатки кислородом. Такое

состояние зрительной системы ведёт к появлению диабетической ретинопатии (ДРП). Одним из наиболее тяжелых осложнений ДРП, приводящих к слепоте, является макулярный отёк [3] (Рисунок 1).

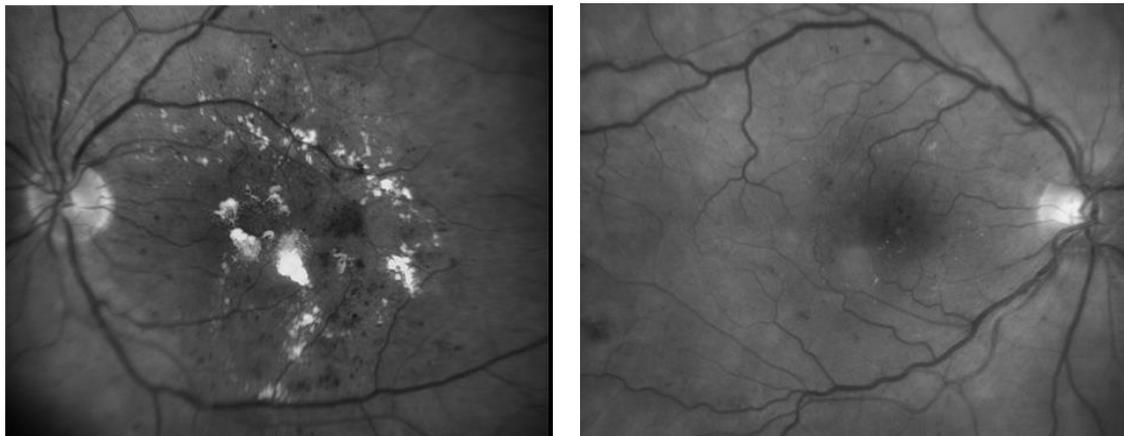


Рисунок 1. Пример диагностического изображения глазного дна без патологий (слева) и с патологией (справа)

Наиболее предпочтительно оптимальное расположение коагулятов в зоне макулярного отёка на максимально равных друг от друга расстояниях и исключения попадания их на сосуды. Если расстановку производить вручную по одному коагуляту, то оптимальность их расположения будет субъективна, а на планирование будет потрачено больше времени [4]. Для автоматизации процедуры лазерной коагуляции необходимо провести сегментацию изображения с целью выделения основных областей. Таким образом, разработка информационной технологии отбора признаков для проведения сегментации изображения глазного дна, с целью последующего автоматического заполнения коагулятами зоны отёка в настоящее время является актуальной задачей.

Предложена технология формирования плана коагулятов, основанная на сегментации изображения глазного дна с использованием текстурных признаков и применении алгоритмов расстановки коагулятов. На рисунке 2 представлены фрагмент изображения с экссудатами и изображения с расставленными коагулятами в выделенной наилучшим способом сегментации области.

Для автоматизации процедуры лазерной коагуляции необходимо провести сегментацию изображения на указанные области интереса. Для того чтобы провести более точную сегментацию в работе [5] была предложена технология формирования набора эффективных признаков на основе анализа текстурных свойств указанных классов изображений с использованием дискриминантного анализа.

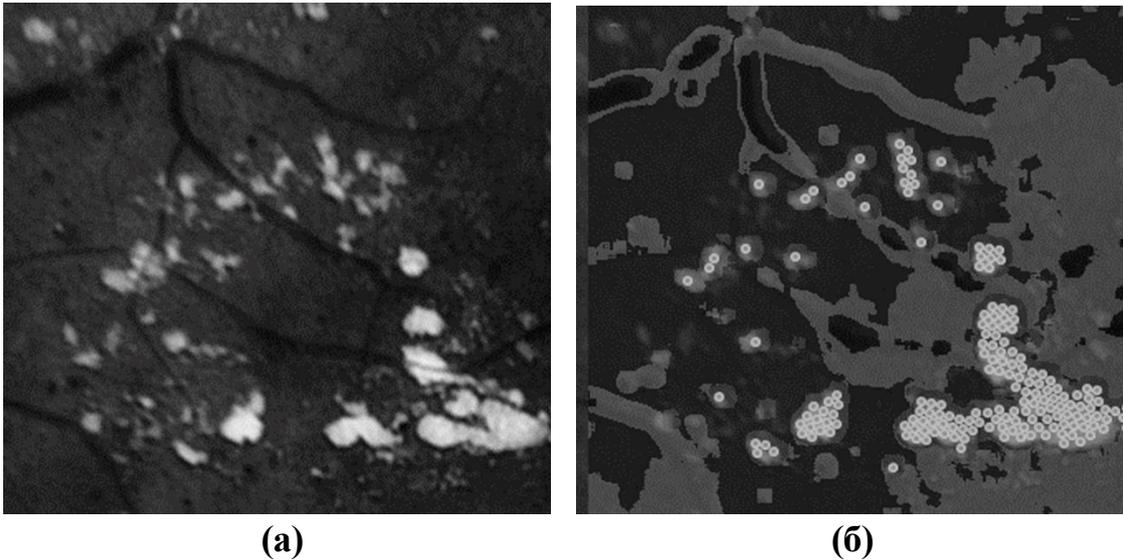


Рисунок 2. Результаты заполнения коагулятам выделенных областей интереса: а) зона экссудат; б) результат заполнения коагулятами

Экспериментальные исследования технологии отбора признаков проводились на выборках, сформированных при анализе 132600 фрагментов, содержащих различные классы изображений. Для каждой из сформированных выборок были рассчитаны и отобраны по критерию разделимости наиболее информативные текстурные признаки. Рассматривались наборы признаков, полученные при объединении от 1 до 6 информативных признаков для каждой пары классов при попарном отборе и до 30 наиболее информативных признаков по критерию разделимости при общем способе отбора признаков.

На рисунке 3 представлена общая схема системы, включающей следующие шаги: совмещение данных, полученных с помощью ОКТ, с изображением глазного дна, сегментация изображения глазного дна, формирование карты отклонения толщины исследуемой сетчатки от нормы, выделение области интереса, в которую будут расставлены коагуляты, на основе выделения зон с патологией на карте высот и исключения запрещённых зон, расстановка коагулятов в выделенную область интереса.

Для формирования карты отклонения от нормы необходимо получить карту высот сетчатки, наложенную на изображение глазного дна. На изображении ОКТ выделение патологических зон осуществляется врачом вручную. Врач ориентируется на смоделированную карту высот здоровой сетчатки и карту высот сетчатки пациента, полученной при помощи ОКТ. Затем врач вручную расставляет ключевые точки на изображениях глазного дна и ОКТ, чтобы совместить их. Наложение патологических зон на изображение глазного дна осуществляется на основе аффинного преобразования, вычисляемого по расставленным ключевым точкам изображений.



Рисунок 3. Технология формирования плана коагулятов с использованием разработанных методов сегментации изображений глазного дна и расстановки коагулятов

Сегментация позволяет выделить запрещённые области на изображении глазного дна, которые исключаются из области с высокими отклонениями от нормы. В выделенную область интереса расставляются коагуляты одним из предложенных алгоритмов. В работе [6] были предложены 7 алгоритмов расстановки коагулятов в заданную область интереса, различающимися формируемыми картами коагулятов: квадратная, гексагональная, волновая, упорядоченная, граничная, адаптивно граничная, случайная. Квадратная карта является близким аналогом заполнения области интереса коагулятами на основе квадратных паттернов. Адаптивно-граничная карта обладает высокой вычислительной сложностью. Самой низкой вычислительной сложностью обладает упорядоченная карта [6]. Программная система будет позволять в интерактивном режиме выбирать нужный алгоритм расстановки коагулятов из предложенных 7. Предложенная система на этапе подготовки к операции формирует оптимальный план по изображению глазного дна пациента. Врач на основе полученной картины осуществляет серию микроожогов.

Заключение. В работе представлена технология отбора эффективных признаков с использованием различных цветовых подпространств для проведения сегментации изображений глазного дна. Технология позволила осуществить интеллектуальный анализ признаков для решения задачи выделения областей интереса, содержащих 4 класса объектов (экссудаты, здоровые участки, толстые, тонкие сосуды) для проведения операции лазерной коагуляции.

Благодарности. Работа выполнена при частичной поддержке Министерства образования и науки РФ в рамках реализации мероприятий Программы повышения конкурентоспособности Самарского Университета среди ведущих мировых научно-образовательных центров на 2013–2020 годы; грантов РФФИ № 15-29-03823, № 16-41-630761, № 17-01-00972, № 18-

37-00418, в рам-ках госзадания по теме № 0026-2018-0102 «Оптоинформационные технологии получения и обработки гиперспектральных данных».

Библиографический список

1. Дедов, И.И. Распространенность сахарного диабета 2 типа у взрослого населения России (исследование NATION) [Текст] / И.И. Дедов, М.В. Шестакова, Г.Р. Галстян // Сахарный диабет, 2016. – Т. 19, № 2. – С. 104–112.
2. Zhang, X. Prevalence of diabetic retinopathy in the United States, 2005–2008 [Text] / X. Zhang, J.B. Saaddine, C.F. Chou [et al.] // JAMA, 2010. – Vol. 304. – P. 649–656.
3. Doga, A.V. Modern diagnostic and treatment aspects of di-abetic macular edema [Text] / A.V. Doga, G.F. Kachalina, E.K. Pedanova, D.A. Buryakov // Ophthalmology, Diabetes, 2014. – No.4. – P. 51-59.
4. Замыцкий, Е.А. Анализ интенсивности коагулятов при лазерном лечении диабетического макулярного отека на роботизированной лазерной установке NAVILAS [Текст] / Е.А. Замыцкий, А.В. Золотарев, Е.В. Карлова, П.А. Замыцкий // Саратовский научно-медицинский журнал, 2017. – Т. 13, № 2. – С. 375–378.
5. Ilyasova, N.Yu. Regions of interest in a fundus image se-lection technique using the discriminative analysis meth-ods [Text] / N.Yu. Ilyasova, R.A. Paringer, A.V. Kupriyanov // Lecture Notes in Computer Science (in-cluding subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 2016. – No.9972. – P.408-417.
6. Ilyasova, N. Coagulate map formation algorithms for laser eye treatment [Text] / N. Ilyasova, D. Kirsh, R. Paringer, A. Kupriyanov, A. Shirokanev, E. Zamycky // 3rd Interna-tional Conference on Frontiers of Signal Processing, ICFSP 2017. – P. 120-124.

IMPROVING THE QUALITY OF TREATMENT OF DIABETIC MACULAR EDEMA BASED ON TECHNOLOGY OF COAGULATE PLAN AUTOMATIC FORMATION

Shirokanev Alexander Sergeevich, Ilyasova Nataly Yurievna

IPSI RAS – branch of the FSRC «Crystallography and Photonics» RAS,

Molodogvardejskaya street 151, Samara, Russia, 443001

ilyasova.nata@gmail.com

In this paper, the technology of coagulate plan automatic formation for the effective treatment of diabetic macular edema is proposed. The technology includes two key stages in the coagulate plan formation: the selection of a laser impact zone, the uniform placement of coagulates in a selected area. The impact zone selection is carried out based on the combining of heterogeneous data

obtained using OCT and fundus images, and using the segmentation method based on selected textural characteristics. Early studies have shown that the optimal size of the fragmentation window is 12 for 4 classes of images (exudates, thick vessels, thin vessels and healthy areas). 7 coagulate localization algorithms were also proposed to implement the second stage of the technology. The study showed that the most effective treatment is achieved by algorithms based on hexagonal and adaptive-boundary ways of filling the impact zone with coagulates.

Key words: laser coagulation, fundus, fundus images, textural features, data mining, feature selection.

ЦИФРОВАЯ ПРОМЫШЛЕННОСТЬ

СИСТЕМА СОРТИРОВКИ ПУСТЫХ КОНТЕЙНЕРОВ В АВТОМАТАХ ПО СБОРУ ИСПОЛЬЗОВАННОЙ ТАРЫ

*Кокоулин Андрей Николаевич, Тур Александр Игоревич,
Князев Александр Игоревич, Южаков Александр Анатольевич*

Пермский национальный исследовательский политехнический университет
614000, Россия, г. Пермь, Комсомольский пр-кт. 29, a.n.kokoulin@at.pstu.ru

В статье описываются результаты разработки подсистемы оптического распознавания автомата по приёму тары на основе IoT и нейронных сетей. Автоматы (Reverse vending machines, RVM) должны выполнять функции распознавания и приема контейнеров (тары) – бутылок ПЭТ и алюминиевых банок, обладать низкой себестоимостью и стоимостью обслуживания. Для снижения себестоимости автомата была предпринята попытка отказаться от дорогостоящей электроники за счет использования систем оптического распознавание объекта на основе нейронных сетей. Для этого были выбраны и обучены некоторые из наиболее популярных сетей, таких как LeNet, MobileNet, проведены сравнительные тесты и сделаны выводы о целесообразности их использования.

Ключевые слова: автомат по приёму тары, искусственная нейронная сеть, сверточная нейронная сеть, переработка бытовых отходов.

Reverse vending machine (дословно «обратный торговый автомат», автомат по приёму тары, RVM) – это автоматизированный способ сбора, сортировки и обработки использованной тары (бутылки ПЭТ и алюминиевые банки) [1].

Большинство автоматов используют следующие методы проверки тары: контроль материала контейнера (ИК-спектрометрия), контроль формы контейнера, контроль штрих-кода. Эти процедуры контроля делают попытки мошенничества совершенно невозможной, но, в то же время, делают RVM слишком дорогостоящим [2,5]. Благодаря современным технологиям компьютерного зрения мы можем разработать еще один вид эффективных и недорогих RVM, имеющих схожую функциональность и высокую защиту от мошенничества. Это актуально для российской действительности, потому что у нас не закреплено на законодательном уровне возвращение стоимости контейнера после ее использования. Прибыль владельца RVM измеряется стоимостью переработанного пластика и металла, и, при больших расходах на логистику, она будет очень мала [5]. Мы разработали иной метод идентификации, основанный на распознавании объектов нейронными сетями микроконтроллером Raspberry Pi.

Сегодня сверточные нейронные сети считают самым мощным классификатором изображения в области машинного зрения [4,5]. В нашей работе нейронные сети спроектированы как скрипт, который загружается после срабатывания датчика появления контейнера в отсеке идентификации и получения снимка от установленной там камеры. Наиболее быстрый каскадный классификатор Naag не даёт требуемой точности, поэтому мы изучили другие решения обнаружения объектов, которые бы показывали стабильные положительные результаты [3,4]. Список рассмотренных методов и фреймворков был ограничен из-за особенностей и возможностей контроллеров IoT. Следует отметить, что наша цель заключается в классификации изображения внутри RVM тремя возможными классами: бутылкой из ПЭТ, банки из алюминия и «попыткой мошенничества» (все, что не соответствует бутылкам из ПЭТ и банкам из алюминия). Мы принимаем во внимание, что банки или бутылки можно согнуть или помять, тем самым изменив их форму.

Реализация подсистемы распознавания тары в разрабатываемой RVM. Для каждой сети [5] мы подготовили несколько моделей. Одна из моделей содержала 6 классов: ПЭТ-бутылки, банки, стеклянные бутылки, огонь, рука человека, различный мусор. Мы полагали, что точность распознавания должна быть лучше, если мы вручную разделим все возможные объекты на классы, которые настолько разнообразны, насколько это возможно. Результаты показаны в таблице 1.

С другой стороны, мы создали и исследовали парные модели для LeNet, SqueezeNet и MobileNet, каждая из которых обучается по двум классам: «ПЭТ-бутылки – не ПЭТ-бутылки» и «банки – не банки». В ходе тестов было выявлено, что такой подход показывает лучшие результаты, чем 6-классовое приложения на тех же образцах тестирования (табл. 2).

Таблица 1
Исследование сети для 6 классов

6 кл.	Образец	ПЭТ					Банки					Другое					Общая правильность
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
	Правильность	1	1	1	1	1	0	0	1	1	0	1	1	1	1	1	
	%	91	92	85	86	91	82	67	63	69	53	55	83	98	93	98	80%

Таблица 2
Исследование двух сетей для двух классов

LeNet (can)	Образец	ПЭТ					Банки					Другое					Общая правильность
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
	Правильность	1	1	1	1	1	0	0	1	1	1	1	1	1	1	1	
	%	98	96	96	91	58	84	99	99	88	74	72	99	96	99	99	87%
LeNet (pet)	Образец	ПЭТ					Банки					Другое					Общая правильность
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
	Правильность	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	
	%	91	76	69	67	99	70	92	64	88	58	98	99	98	98	98	93%

Для поиска варианта реализации сети распознавания, оптимального по соотношению качества и быстродействия, сети были реализованы на языках C++ и Python и были проведены эксперименты. Наилучшие результаты по

быстродействию и потреблению памяти показала реализация MobileNet на C++.

Нейронные сети так же позволяют реализовать дополнительный функционал, позволяющий сотрудничать с производителями, заинтересованными в утилизации тары из-под их конкретных продуктов.

Штриховой код содержит информацию о товаре и его производителе. Самый распространенный – это 13 разрядный европейский код EAN-13 (пример представлен на рисунке 1). Первая группа, состоящая из семи цифр, означают страну изготовителя или продавца продукта. Первые пять цифр второй группы — наименование товара, его потребительские свойства, размеры, массу, цвет. Последняя цифра второй группы — контрольная, используемая для проверки правильности считывания штрих-кода сканером.

Задача считывания штрих-кода может заключаться либо в распознавании цифр под модулями (штрих единичной толщины), либо самих модулей. Это может быть реализовано как путем использования специализированных библиотек (Zbar), так и нейронных сетей. На рисунке 1 приведен пример распознавания штрих-кода библиотекой Zbar. Полученная последовательность проверяется на соответствие в базе штрих-кодов. В случае обнаружения совпадения, автоматом принимается решение о выдаче дополнительного вознаграждения.

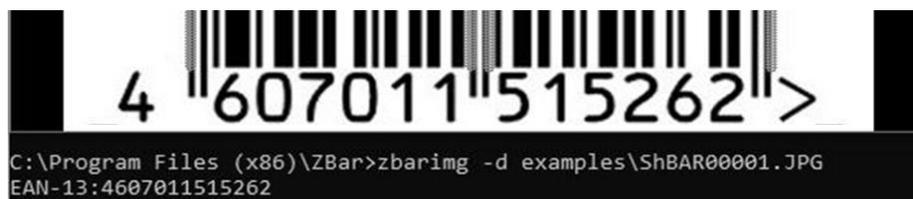


Рисунок 1. Пример распознавания штрих-кода EAN-13.

Иной подход можно реализовать в нейронных сетях. На данный момент существует уже много решений позволяющих считывать печатные символы. Преимуществом такого решения будет возможность считывать поврежденные штрих-коды, восстанавливая нераспознанные символы с некоторой степенью вероятности. Восстановленная таким образом информация может считаться верной, если результат распознавания нейронной сетью имеет отметку о высокой вероятности, и при совпадении суммы знаков распознанного штрих-кода с контрольным числом в конце кода.

Однако, подобные решения очень требовательны к качеству считываемого изображения – не должно быть лишних деталей, штрих-код должен быть расположен в фокусе, быть достаточно большим. Данную проблему можно решить, предложив пользователю автомата помещать тару в тароприемник, соблюдая строгую ориентацию штрих-кода по отношению к камере. А для того, чтобы убрать лишние детали с изображения, необходимо определить точное местоположение штрих-кода. Данный подход называется иерархическим. Он предполагает, что вначале с помощью нейронной сети

будет обнаружен штрих-код, а потом будет произведено получение информации записанной в нём.

На первом этапе распознавания, нейронная сеть ищет объект со сходными внешними признаками (светлый «прямоугольник» с контрастными штрихами внутри) и разворачивает его на требуемый угол так, чтобы «прямоугольник» был ориентирован горизонтально, а штрихи в нём – вертикально. Но данный подход значительно увеличивает ресурсоёмкость проекта и время выполнения управляющего скрипта. Поэтому логично вместо нейронной сети использовать быстрый алгоритм, который может допускать ошибки, так как на этом этапе выполняется грубый поиск объекта на изображении. Таким алгоритмом можно считать поиск на основе каскадов Хаара.

Второй этап можно реализовать с помощью уже рассмотренной библиотеки Zbar. В данном случае не придётся проводить дополнительных операций со штрих-кодом (библиотека способна считывать перевёрнутые штрих-коды), а затраты ресурсов IoT будут минимальными. Однако, в случае повреждения штрих-кода на деформированных бутылках из ПЭТ и банках, считывание будет невозможным, что не будет способствовать положительному отношению пользователей. Для устранения данного недостатка можно применить нейронную сеть, которая будет обучена считывать цифру каждого модуля из штрих-кода, а также распознавать печатные цифры дублирующие информацию под модулями. Благодаря полученной избыточности шансы распознать слабо повреждённый штрих-код значительно возрастают. В случае сильного повреждения (когда не получается считать один или несколько модулей и соответствующие им печатные цифры) можно применить аналитический алгоритм, позволяющий по контрольной цифре восстановить нечитаемую часть. Такой вариант почти гарантированно восстанавливает повреждение одного модуля (кроме последнего – контрольного).

Данный подход актуален для условий ограниченных вычислительных ресурсов IoT. Происходит экономия ресурсов памяти, т.к. наиболее ресурсоемкая часть (распознавание штрих-кода) выполняется не над большим изображением этикетки, а над её отдельными фрагментами. Недостатком данного подхода является необходимость затраты дополнительного времени на вращение тары и увеличение требуемого объёма памяти. Поэтому он рассматривается только как вариант одной из модификации RVM.

Выводы. Результатом проделанной работы стала оценка нескольких подходов к распознаванию и классификации изображений и их применение для распознавания и сортировки пустых контейнеров по форме и штрих-коду в RVM. Самое точное решение было обработано CNN MobileNet. Авторы провели исследование, как предварительная обработка изображения и улучшение данных наборов обучения и тестирование могли влиять на точность распознавания и после нескольких экспериментов пришли к выводам, что использование двух моделей LeNet каждого из 2 классов более

эффективно, чем одиночная модель из 3-6 классов, а предварительная обработка обучающих образов (резкость) может улучшить распознавание только для модели банок, состоящей из двух классов, но в тоже время уменьшает точность для аналогичной модели ПЭТ бутылок.

Библиографический список

1. Reverse vending 101: a beginner's guide [Электронный ресурс]. – 2011. – Режим доступа: <https://www.tomra.com/en/collection/reverse-vending/reverse-vending-news/2017/how-does-a-reverse-vending-machine-work/> – Дата обращения 30 марта 2019.
2. Cost of a Deposit Return Reverse Vending Machine [Электронный ресурс]. – Режим доступа: <http://www.zerowastescotland.org.uk/sites/default/files/reverse%20v%20-%20CFE%20response.pdf>– Дата обращения 30 марта 2019.
3. Rosebrock A. Practical Python and OpenCV + Case Studies [Электронный ресурс]. – 2016. – Режим доступа: <https://www.pyimagesearch.com/2016/11/20/Python-OpenCV/>– Дата обращения 30 марта 2019.
4. Iandola F. Forrest, Han Song, Moskewicz W. Mattewet. al. SqueezeNet: MobileNet-level accuracy with 50x fewer parameters and <0.5 Mb model size, ICLR'17 conference proceedings, p.207-212, 2017.
5. Kokoulin A. N., Tur A. I., Yuzhakov A. A. Convolutional Neural Networks Application in Plastic Waste Recognition and Sorting // Proceedings of the 2018 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (2018 ElConRus)

DEVELOPMENT OF THE SYSTEM FOR SORTING EMPTY CONTAINERS IN REVERSE VENDING MACHINE

Kokoulin A.N., Tur A.I., Knyazev A.I., Yuzhakov A.A

Perm National Research Polytechnic University, Perm, Russia

614000, Russia, Perm, Komsomolsky prosp., d. 29, a.n.kokoulin@at.pstu.ru

In this paper we describe the results in development of reverse vending machine on the basis of IoT and artificial neural networks. These automatic machines can perform recognition of containers – bottles of PET and aluminum jars. These machines are developed on the basis of IoT controllers. To lower the prime cost we do not use the expensive electronics, instead of this we use the visual recognition of objects by neural networks. Some of the most popular networks were considered and tested: LeNet, SqueezeNet, MobileNet.

Key words: reverse vending machine, convolutional neural network, recycling.

НЕЙРОСЕТЕВОЙ АЛГОРИТМ РАСПОЗНОВАНИЯ БРАКА ОТЛИВОК НА РЕНГЕНОВСКИХ СНИМКАХ

*Митрофанов Игорь Андреевич
Голдобин Максим Алексеевич, Морозов Андрей Александрович
Ясницкий Леонид Нахимович*

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

Подобрана архитектура и произведена оптимизация сверточной нейронной сети, предназначенной для распознавания бракованных лопаток авиационных и газотурбинных двигателей.

Ключевые слова: брак, качество, нейронная сеть, архитектура, искусственный интеллект.

Как известно [1], важнейшими узлами авиационного и газотурбинного двигателя, определяющими его срок службы и эксплуатационные характеристики, являются турбины высокого и низкого давления, к основным деталям которых относятся рабочие и сопловые лопатки. Поэтому приоритетной задачей является обеспечение качества лопаток, в частности – отсутствие внутренних трещин. Трещин обычно выявляют путем визуального просмотра рентгеновских снимков. Пример такого снимка приведен на рисунке 1. Однако визуальный просмотр рентгеновских снимков больших партий лопаток занимает много времени, требует напряженной работы контролеров и не надежен вследствие влияния человеческого фактора.

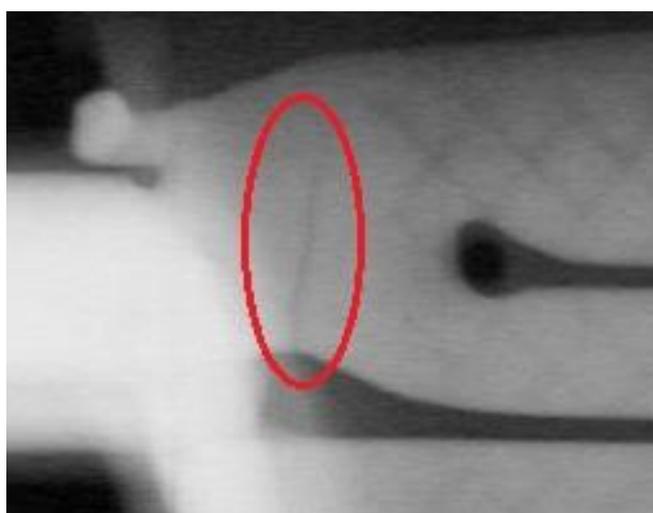


Рисунок 1. Пример рентгеновского снимка турбинной лопатки, имеющей дефект в виде трещины

С целью решения данной проблемы нами была предпринята попытка построения нейронной сети, предназначенной для распознавания трещин на рентгеновских снимках лопаток. Для обучения нейронной сети было отобрано 175 снимков, из них 73 снимка содержали трещины (рис. 1) и 102 – без трещин. Все множество было разбито на обучающее и тестирующее в соотношении 70:30. Все изображения вручную были приведены к единому размеру. Для проектирования, обучения и тестирования нейронной сети была использована библиотека Keras [2], являющаяся надстройкой над библиотекой TensorFlow [3]. Обучение нейронной сети проводилось с помощью сервиса Google Colaboratory [4], предоставляющего для вычислений графический ускоритель Nvidia Tesla K80.

Структура сверточной нейронной сети была подобрана экспериментальным путем и включала два сверточных слоя с нейронами, имеющими в качестве функции активации гиперболический тангенс, скрытый полносвязный слой с 512 сигмоидными нейронами и выходной слой с двумя нейронами с функцией активации SoftMax. Функция SoftMax имеет вид:

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{k=1}^N e^{z_k}}$$

где z_i – значение на выходе i -го нейрона, N – количество нейронов в слое.

Функция активации SoftMax на выходном слое позволяет получать вероятность принадлежности изображения к каждому классу, поскольку сумма выходов равна 1.

Для предотвращения переобучения был использован популярный прием прореживания сетей dropout [5], суть которого заключается в том, что каждый нейрон с заданной вероятностью исключается из сети во время обучения. Вероятность исключения нейронов задается сразу для всего слоя. Обученная сеть включает в себя все нейроны, однако функция активации каждого нейрона домножается на вероятность его исключения при обучении. Вероятность исключения нейронов также была подобрана экспериментальным путем.

В качестве алгоритма обучения был использован Adam [6]. При обучении были использованы callback'и – методы, позволяющие автоматически выполнять некоторые действия при достижении сетью определенного состояния. В частности, был использован callback, позволяющий останавливать обучение сети в том случае, если на протяжении заданного времени не происходит улучшения ее способности к обобщению, что существенно экономит время, избавляя от необходимости дожидаться завершения всех эпох, и callback, сохраняющий веса сети в том случае, если сеть достигает лучшей обобщающей способности по сравнению с предыдущими эпохами, что позволяет получать состояние сети не только на момент завершения обучения, но и на его промежуточных стадиях.

В результате обучения была получена нейронная сеть, точность которой на обучающем множестве составила 88%, на тестирующем – 85%. Метрики качества сети, рассчитанные на тестирующем множестве, представлены в таблице 1.

Таблица 1. Метрики качества, рассчитанные на тестирующем множестве

Название	Значение
Доля верно классифицированных изображений	0,85
Площадь под ROC-кривой	0,85
Чувствительность	0,86
Специфичность	0,84

На рисунке 2 представлена ROC-кривая, построенная на основе тестирующего множества.

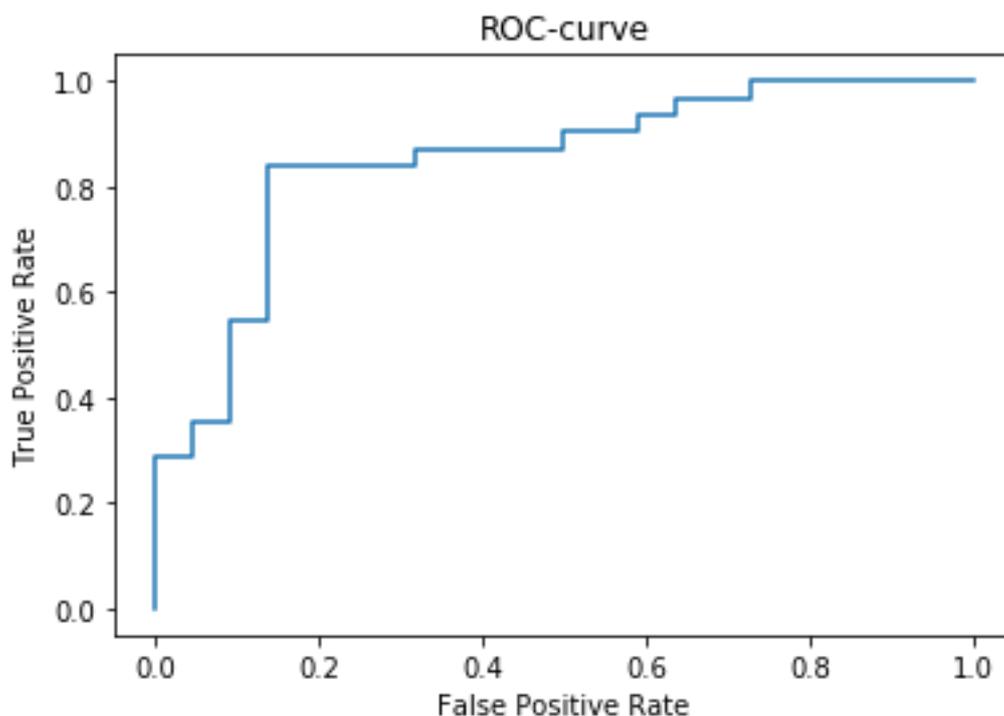


Рисунок 2. ROC-кривая, построенная на основе тестирующего множества

Учитывая небольшой размер обучающей выборки, полученный результат можно считать довольно высоким, доказывающим возможность применения сверточных нейронных сетей для распознавания брака изделий на основе рентгеновских снимков.

Библиографический список

1. Испытания, обеспечение надежности и ремонт авиационных двигателей и энергетических установок: Учеб. пособие / Ю.С. Елисеев,

- В.В. Крымов, К.А. Малиновский, В.Г. Попов, Н.Л. Ярославцев. – М.: Изд-во МАИ, 2005. – 540 с.
2. Keras Documentation [электронный ресурс]. URL: <https://keras.io/> (дата обращения 23.04.2019).
 3. TensorFlow [электронный ресурс]. URL: <https://www.tensorflow.org/> (дата обращения 23.04.2019).
 4. Colaboratory [электронный ресурс]. URL: <https://colab.research.google.com/> (дата обращения 23.04.2019).
 5. N. Srivastava et al. Dropout: A Simple Way to Prevent Neural Networks from Overfitting // Journal of Machine Learning Research. – 2014, 15, 1929-1958.
 6. D. P. Kingma, J. Ba. Adam: A Method for Stochastic Optimization. arXiv preprint arXiv:1412.6980, 2014.

NEURAL NETWORK ALGORITHM FOR RECOGNITION OF DEFECTIVE BLADES OF AIRCRAFT ENGINES BASED ON RADIOGRAPH

Mitrofanov Igor A
Perm state University, 15, Bukireva str., Perm, Russia, 614990,
mirolubov@list.ru

Goldobin, Maxim A., Morozov Andrei A.
JSC «UEC-Perm engines», 614990, Perm, GSP, Komsomolsky PR., 93.

Yasnitsky Leonid N.
Perm state University, 15, Bukireva str., Perm, Russia, 614990,
yasn@psu.ru

The architecture and optimization of convolutional neural network designed for recognition of defective aircraft and gas turbine engines blades were selected.

Key words: marriage, quality, neural network.

ПРОГНОЗИРОВАНИЕ МАССОРАСХОДНЫХ ХАРАКТЕРИСТИК НЕФТЕПРОВОДА НА ОСНОВЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

Сысолин Михаил Сергеевич

Пермский государственный национальный исследовательский университет,
ПМИ. 614990, Россия, г. Пермь, ул. Букирева, 15, smikhails00@gmail.com

В статье представлено описание разработки нейросетевой системы для прогнозирования массорасходных характеристик нефтепровода двумя способами: с помощью Нейросимулятора и библиотеки Encog. Выявление какой способ даст более эффективный результат. Системы должны были научиться прогнозировать количество воды, поступающее на конечную точку, на основе информации по шести станциям.

Ключевые слова: искусственный интеллект, нейросетевые технологии, прогнозирование, нефтепровод, массорасходные характеристики.

На рисунке 1 изображена принципиальная схема нефтепровода – смесь со станций №1-6 поступает на конечную – №7. Важно заметить, что по нефтепроводу идет именно смесь – нефти и воды, так как именно вода помогает выкачивать нефть из скважин.

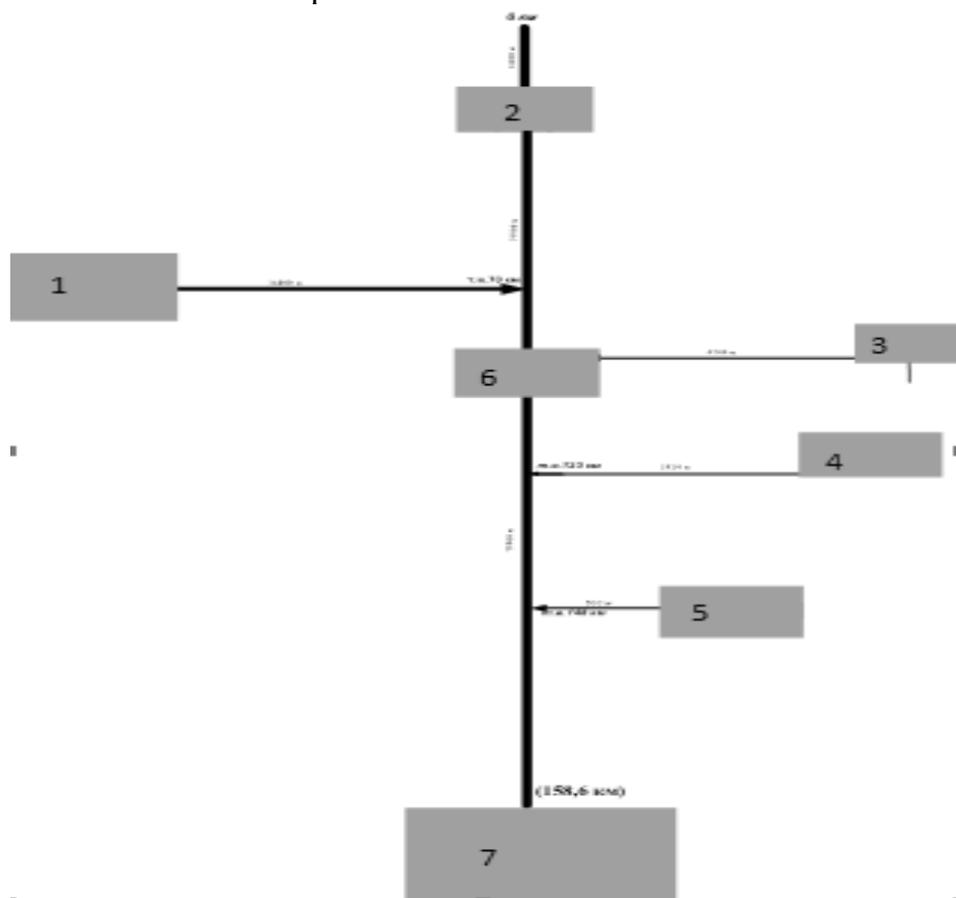


Рисунок 5. Принципиальная схема нефтепровода

По ходу постепенного решения задачи были выявлены множество особенностей и проблем.

Первым, пожалуй, здесь стоит упомянуть тот факт, что скважины, №1-6, представленные на принципиальной схеме выше, не единственные, кто задействован в этом трубопроводе. Помимо них существует стороннее предприятие, которое также закачивает нефть в данный трубопровод. А вот каком месте происходит врезка – неизвестно.

Как правило, в начале освоения скважины нефть вытекает сама ударными темпами. Но постепенно этот процесс сходит на нет и приходится прибегать к физическим и химическим законам, а именно «выдавливать» нефть из скважины с помощью воды, так как плотность у последней выше. Отсюда и происходит тот процесс смешения воды и нефти. На выходе каждой скважины мы получаем смесь с определенным процентом обводненности, при прохождении через трубопровод данные смеси перемешиваются уже между собой и мы получаем абсолютно иной процент обводненности.

Согласно [1] вязкость – это свойство жидкостей оказывать сопротивление перемещению одной части жидкости относительно другой. Значение вязкости зависит от природы жидкости, т.е. от ее химического строения и молекулярного веса. Величина вязкости входит во все гидродинамические расчеты, связанные с движением нефти, в том числе в расчеты, связанные с миграцией нефти в залежи и т.д. Для определения вязкости нефти и нефтепродуктов существует большое число разнообразных приборов, называемых вискозиметрами.

Продолжая тему особенностей системы построения данного нефтепровода нужно упомянуть о «бегунке» который запускают по нефтепроводу каждые 4 дня с целью очистки стенок труб от загрязнений. Данный бегунок позволяет не останавливать процесс нефтеперекачки.

Согласно [2], все факторы, влияющие на энергоэффективность работы нефтепроводов, можно разделить на несколько групп:

1. Группа факторов, характеризующих перекачиваемую нефть.
2. Группа факторов, характеризующих профиль трассы нефтепровода.
3. Группа факторов, характеризующих ЛЧ ТУ и ее технологическую схему.
4. Группа факторов, характеризующих транспортную работу.
5. Группа факторов, характеризующих насосно-силовое оборудование.
6. Группа факторов, характеризующих использование режимов из карты технологических режимов и зависящих от методики планирования посуточного графика движения нефти (ПГДН).

Исходные данные представлены за один месяц – август, посуточно.

Задача решалась двумя способами: первый – с помощью Нейросимулятора [3], второй – с помощью среды разработки Visual Studio, языка программирования C# и специального пакета надстроек – Encog [4].

На первоначальном этапе были доступны ежедневные данные за август 2018 года по нефтепроводу. На вход нейросети подавалось 72 входа и 1

выход. 72 входа это – данные за три дня по шести станциям откачки нефти, у каждой из которой фиксировалось 4 показателя – общий объем откачки, масса нефти, объем воды, обводненность. Выход – количество воды, пришедшей на третий день на конечной пункт.

Самой лучшей моделью в Нейросимуляторе, которую удалось построить, оказалась изображенная на рисунке 2.

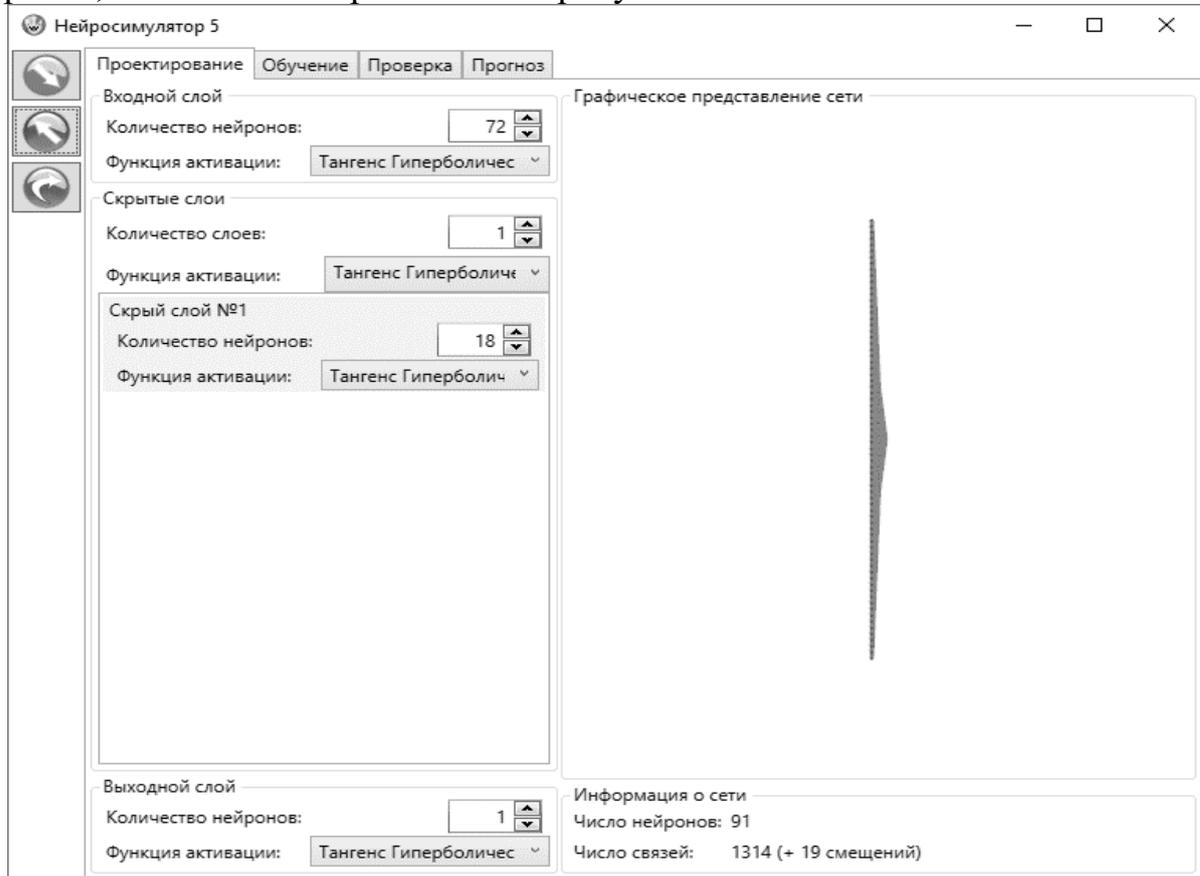


Рисунок 6. Модель, построенная в Нейросимуляторе

Как видим, у этой модели 72 входа, 1 выход, 1 скрытый слой с 18-ю нейронами. Ошибка тестирования составила 21,5%.

Самая лучшая модель с помощью пакета надстроек Encog представлена на рисунке 3.

```
var network = new BasicNetwork();
network.AddLayer(new BasicLayer(new ActivationTANH(), true, 72));
network.AddLayer(new BasicLayer(new ActivationTANH(), true, 18));
network.AddLayer(new BasicLayer(new ActivationTANH(), true, 12));
network.AddLayer(new BasicLayer(new ActivationTANH(), false, 1));
network.Structure.FinalizeStructure();
network.Reset();
```

Рисунок 7. Модель, построенная в пакете Encog

У этой модели 72 входа, 1 выход, 2 скрытых слоя: первый с 18-ю нейронами, второй – с 12-ю. Ошибка тестирования составила 25,4%.

Схематично представим сравнение результатов:

Таблица 2. Сравнение результатов

Дата	Идеал	Ней-р	% ош. Ней-р	Encog	% ош. Encog
24.08.2018	1875,24	2054,95	9,58331	2526,408	34,7245
25.08.2018	1809,84	2544,88	40,61353	2136,689	18,05953
26.08.2018	2776,28	3109,129	11,98901	2692,24	3,027081
27.08.2018	2410,44	2648,364	9,870563	2445,7	1,46279
28.08.2018	4210,64	2324,356	44,79803	2130,193	49,40928
30.08.2018	851,06	954,6471	12,17154	1242,02	45,93797
Ср. значение	-	-	21,5043	-	25,4369

Как показала практика, в данном конкретном случае лучший результат смог показать Нейросимулятор (стоит оговориться, что ошибка даже 21,5% очень высока, но с другой стороны был очень скудный набор данных, всего 22 для обучения и 6 для тестирования). Но Encog удобен в свою очередь тем, что позволяет автоматизировать поиск наилучшей нейросети.

В дальнейшем будет продолжено построение нейросети но уже на более объемных данных, переданных заказчиком.

Библиографический список

1. Федорова А.Э., институт «ТатНИПИнефть». Прогнозирование кинематической вязкости для нефти Татарстана. 2017, стр. 1-6.
2. Гольянов А.И., Гольянов А.А., ООО «НИИ Транснефть», г. Москва. Факторы, влияющие на энергоэффективность работы нефтепроводов. XI международная учебно-научно-практическая конференция «Трубопроводный транспорт – 2016». Стр. 47-49.
3. Нейросимулятор 5.0 : Свидетельство Роспатент о государственной регистрации программы для ЭВМ № 2014618208 от 12.07.2014 г. / Черепанов Ф.М., Ясницкий Л.Н. (РФ).
4. Heaton J. Heaton Research, Inc. St. Louis, MO, USA. Encog 3.3: Quick Start Guide. 2018, p. 1-61.

PREDICTION OF MASS DISPOSAL CHARACTERISTICS OF OIL PIPELINE BASED ON NEURAL NETWORK TECHNOLOGIES

Sysolin Mikhail S.

Perm State University

Str. Bukireva, 15, Perm, Russia, 614990, smikhails00@gmail.com

This article describes the development of a neural network system for predicting the mass-consumption characteristics of an oil pipeline in two ways: using a neurostimulator and the Encog library. Identifying which method will give a more effective result. Systems had to learn how to predict the amount of water entering the end point, based on information from six stations.

Key words: artificial intelligence, neural network technologies, forecasting, oil pipeline, mass transfer characteristics.

АНАЛИЗ И СИНТЕЗ НЕЧЕТКИХ РЕГУЛЯТОРОВ

Хижняков Юрий Николаевич, Южаков Александр Анатольевич

Пермский национальный исследовательский политехнический университет
614000, Россия, г. Пермь, Комсомольский пр. д. 26, luda@at.pstu.ru

В статье описан опыт разработки и применения нечетких регуляторов для управления недетерминированными объектами (авиационным двигателем в условиях неопределенности с целью повышения надежности эксплуатации летательных аппаратов). Рассмотренные разработки регуляторов на основе нечеткой логики отвечают требованиям систем реального времени.

Ключевые слова: авиационный двигатель, фаззификатор, база знаний, дефаззификатор, синапсы, алгоритмы, термы, сигмоидные функции принадлежности, сингтон, пропорции.

В настоящее время особый интерес проявляется к управлению недетерминированных объектов. К таким объектам относятся роботы с их вербальным описанием, машины переменного тока (синхронные генераторы, асинхронные двигатели, синхронные компенсаторы), которые представлены уравнениями Парка-Горева, авиационные двигатели, представленные эталонными моделями с переменными коэффициентами, линии электропередач и теплопередач, представленные дифференциальными уравнениями в частных производных и т.д.

Применение для автоматического управления и регулирования линейных регуляторов (П-, ПИ-, ПИД-, РИПИД-) не представляется возможным, так как они предполагают знание передаточных функций детерминированных объектов регулирования, где отсутствуют неопределенности, связанные с переменной калорийностью сжигаемого топлива, переменными параметрами окружающей среды для летательных аппаратов, износ регулирующей аппаратуры, не точное описание датчиков и регулирующих органов, переменные коэффициенты усиления и постоянных времени регулируемого объекта при длительной эксплуатации и т.д.

Для управления недетерминированными объектами широко используются нечеткие регуляторы и нейронные сети. Ниже нейронные сети не рассматриваются, хотя их достоинство не умоляется. Недостатком нейронных сетей является их непрозрачность управления. Нечеткие регуляторы, обладая прозрачностью управления, являются также адаптивными как и нейронные сети после их обучения. Основные компоненты нечеткого регулятора: фаззификатор, база знаний и дефаззификатор.

Рассмотрим вариант построения нечеткого регулятора с применением модифицированного метода наименьших квадратов. На рисунке 1 показана структурная схема нечеткого регулятора недетерминированного объекта (авиационный двигатель).

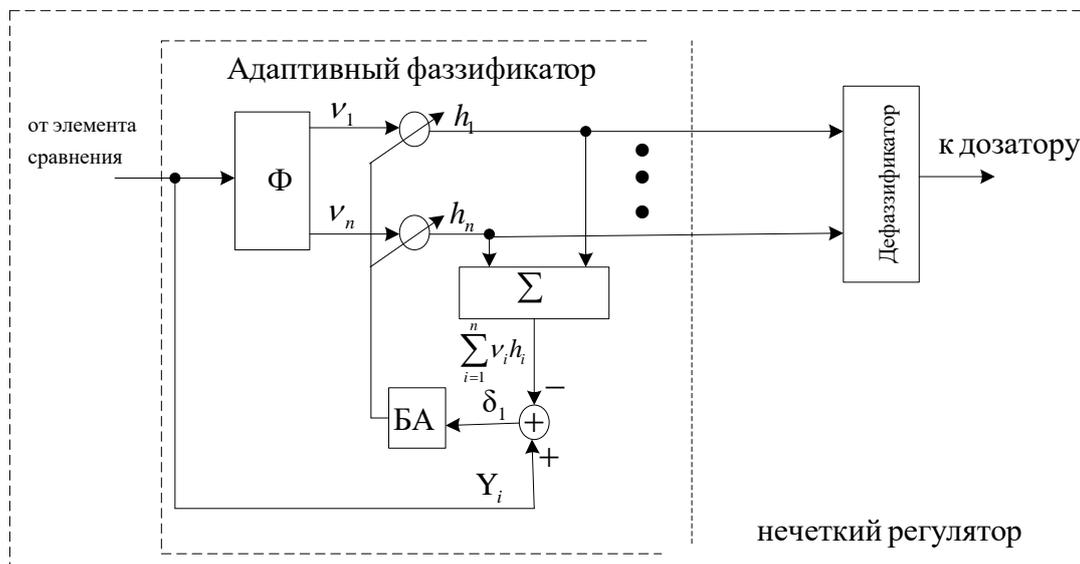


Рисунок 1. Структурная схема нечеткого регулятора: $v_1 \dots v_n$ – степени принадлежности активированных функций принадлежности фаззификатора; $\sum_{i=1}^n v_i h_i$ – выход сумматора h_1, \dots, h_n – синапсы

Для формирования алгоритма блока адаптации зададим термножество фаззификатора из пяти линейных терм, расположенных на нормированном интервале $-1 \dots +1$. Далее проведем разбивку на равные интервалы, как показано на рисунке 2. Вычисление текущих значений степеней принадлежности выполним на синглтонной базе. Запишем функционал согласно методу наименьших квадратов

$$F = (h_1 v_1 + h_2 v_2 + h_3 v_3 + h_4 v_4 + h_5 v_5 - Y_i)^2$$

После дифференцирования функционала по каждому параметру (синапсу) и приравнявая нулю полученных производных, получим систему алгебраических уравнений

$$h_1 = \frac{Y_i - h_2 v_2}{v_1}; \quad h_2 = \frac{Y_i - h_1 v_1 - h_3 v_3}{v_2};$$

$$h_3 = \frac{Y_i - h_1 v_1 - h_2 v_2 - h_4 v_4}{v_3}; \quad h_4 = \frac{Y_i - h_1 v_1 - h_2 v_2 - h_3 v_3 - h_5 v_5}{v_4}; \quad h_5 = \frac{Y_i - h_1 v_1 - h_2 v_2 - h_3 v_3 - h_4 v_4}{v_5}.$$

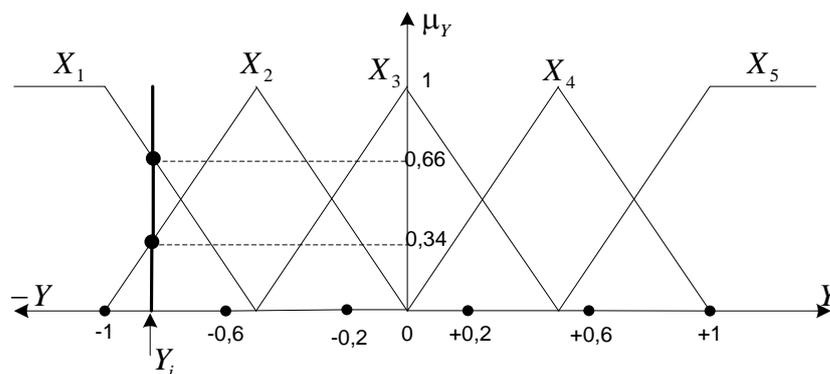


Рисунок 2. Разбиение нормированного интервала на пять интервалов, где $v_1 = 0,66$; $v_2 = 0,34$; $Y_i = 0,76$

Данная система алгебраических уравнений лежит в основе блока алгоритма адаптации (см. рисунок 1).

Сравнительный анализ алгоритма Уидроу–Хоффа и модифицированного метода наименьших квадратов показывает, что адаптация с помощью рекуррентной формулы требует большого числа итераций по сравнению с адаптацией, связанной с решением алгебраических уравнений, за счет чего повышается быстродействие настройки регулятора [1, 2, 3]. Недостаток метода – применим только для линейных терм. Дефаззификация выполнена по методу разности площадей [5].

Дальнейшее повышение быстродействия достигается применением метода последовательного обучения [1, 2, 3]. Суть метода заключается в применении рекуррентной формулы, выведенной на базе импульсной характеристики

$$h_{j+1} = h_j + C(x_j - x_{jm}) \frac{u_j}{u_j^T u_j}, \text{ при } 0 < C < 1,$$

где h_j – коррекция синапса на предыдущем шаге итерации; h_{j+1} – коррекция синапса на последующем шаге итерации; x_j – текущее значение выхода фаззификатора; x_{jm} – предыдущее значение выхода фаззификатора; u_j – текущее значение входа фаззификатора; T – операция транспонирования, C – скорость обучения.

Достоинством варианта адаптации нечеткого регулятора с применением метода последовательного обучения является обучение за одну итерацию и снимаются ограничения на линейность терм по отношению к методу модифицированного метода наименьших квадратов. Дефаззификация выполняется по методу разности площадей [5].

Другим вариантом построения нечеткого регулятора является вариант с заменой синглтона пропорцией и термами входа и выхода с равными основаниями, отличающийся заменой нормированного интервала $-1 \dots +1$ на нормированный интервал $0 \dots +1$ [4]. Дефаззификация выполняется по методу разности площадей [5].

Разработан новый нечеткий регулятор с применением трапециевидных функций принадлежности в фаззификаторе на базе сигмоидных функций и базой знаний, отличающийся тем, что singleton, предназначенный для формирования степеней принадлежности, заменен на трапециевидные функции, изменяемые пропорционально текущему отклонению и активизирующие продукционные правила базы знаний. Проектирование регулятора поддерживает *Matlab*.

Библиографический список

1. Хижняков Ю.Н. Нечеткое, нейронное и гибридное управление: учеб. пособие / Ю.Н. Хижняков. – Пермь: Изд-во Перм. нац. исслед. политехн. ун-та, 2013. 303 с.
2. Хижняков Ю.Н., Южаков А.А. Нейро-нечеткий регулятор частоты газотурбинного двигателя. Приборы. – №5. 2010. С. 17-21.
3. Хижняков Ю.Н. Современные проблемы теории управления. / Ю.Н. Хижняков. – Пермь: Изд-во Перм. нац. исслед. политехн. ун-та, 2015. 237 с.
4. Гостев В.И. Проектирование нечетких регуляторов для систем автоматического регулирования. – СПб: БХВ-Петербург, 2011. 416 с.
5. Бобырь М.В., Кулабухов С.А. Дефаззификация вывода из базы нечетких правил на основе метода разности площадей. Вестник компьютерных и информационных технологий. Издательский дом «Спектр», Москва, №9, 2015. С.32-41.

ANALYSIS AND SYNTHESIS OF FUZZY REGULATORS

Khizhnyakov Yuri N, Yuzhakov Alexander A.
Perm National Research Polytechnic University
614000, Russia, Perm, Komsomolsky Prospect, 29, luda @ at.pstu.ru

The article describes the experience of the development and use of fuzzy regulators to control an aircraft engine under uncertainty in order to increase the reliability of aircraft operation. The considered developments of regulators based on fuzzy logic meet the requirements of real-time systems.

Keywords: aircraft engine, fuzzifier, knowledge base, defuzzifier, synapses, algorithms, terms, sigmoid membership functions, singleton, proportions

Научное издание

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

Сборник статей по материалам
Четвертой всероссийской научно-практической конференции,
проводимой в рамках Пермского естественнонаучного форума
«Математика и глобальные вызовы XXI века»
(г. Пермь, 21–23 мая 2019 г.)

Часть I

Издается в авторской редакции
Компьютерная верстка *М. Н. Федорук*

Подписано в печать 08.05.2019. Формат 60×84/16
Усл. печ. л. 15.93. Тираж 100 экз. Заказ 23

Издательский центр
Пермского государственного
национального исследовательского университета.
614990, г. Пермь, ул. Букирева, 15

ООО Учебный центр «ИНФОРМАТИКА».
614990, г. Пермь, ул. Букирева, 15