

УДК: 007.52 ГРНТИ: 20.51.19

DOI: 10.15643/jscientia.2017.9.001

ПОЛОЖЕНИЕ МОДЕЛИ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ В МЕДИЦИНСКИХ ЭКСПЕРТНЫХ СИСТЕМАХ

Ю. А. Волчек¹, О. Н. Шишко¹, О. С. Спиридонова², Т. В. Мохорт¹

¹ Белорусский государственный медицинский университет

Беларусь, 220116 г. Минск, проспект Дзержинского, 83

² Минский городской клинический онкологический диспансер

Беларусь, 220013 г. Минск, проспект Независимости, 64

✉ Волчек Юлия Александровна – yuliana-dovsk@mail.ru

В статье отражены некоторые аспекты использования современных информационных технологий в медицинской деятельности. На основании комплексного и многоуровневого анализа большого числа клинических данных медицинские экспертные системы позволяют прогнозировать течение и исход определенных нозологических единиц, а также ориентированы на принятие решений по плану дальнейшей тактики ведения конкретного пациента. Искусственные нейронные сети (ИНС) представляет собой самообучающийся аппаратный прототип нейрона коры головного мозга с конкретно задаваемой структурой и уникальной классифицирующей способностью. Приведенные примеры реализации нейросетевых технологий в практической медицине демонстрируют выгодные преимущества данных экспертных систем и являются важными расширениями будущего проектирования искусственного интеллекта.

Ключевые слова: медицинские экспертные системы, искусственная нейронная сеть, искусственный интеллект.

POSITION OF THE MODEL OF THE ARTIFICIAL NEURAL NETWORK IN MEDICAL EXPERT SYSTEMS

Y. A. Volchek¹, V. M. Shyshko¹, O. S. Spiridonova², T. V. Mokhort¹

¹ Belarusian State Medical University

83 Dzerzhinsky Ave., 220116 Minsk, Belarus

² Minsk City Clinical Oncology Center

64 Nezavisimosti Ave., 220013 Minsk, Belarus

✉ Volchek Yulia – yuliana-dovsk@mail.ru

The article reflects some aspects of the use of modern information technologies in medical activities. Based on the complex and multilevel analysis of a large number of clinical data, medical expert systems allow you to predict the course and outcome of certain nosological units, and are also focused on making decisions on the plan for further tactics for conducting a particular patient. Artificial neural networks (INS) is a self-learning hardware prototype neuron of the cerebral cortex with a specifically defined structure and a unique classifying ability. The above examples of implementation of neural network technologies in practical medicine demonstrate the advantageous advantages of these expert systems and are important expansions of the future design of artificial intelligence.

Keywords: medical expert systems, artificial neural network, artificial intelligence.

Интенсивное развитие медицинской науки, расширение возможностей углубления в этиологию, патогенез заболевания, увеличение данных о маркерах различных патологических состояний диктует необходимость поиска новых подходов к обработке полученных результатов. На современном этапе важно провести быстрый анализ большого числа данных и принять верное решение, которое может повлиять на прогнозы, течение и исходы заболевания. В связи с этим все более пристальное внимание уделяется информационным технологиям (ИТ), а в рамках медицины можно говорить об "электронной медицине" [1]. ИТ реализуются в виде медицинских информационных систем (МИС) различного назначения и отдельных автоматизированных лечебно-диагностических приборов, среди которых – современные экспертные системы (ЭС). ЭС представляют собой компьютерные программы, производящие анализ на основе определенных исходных данных, предназначенные для оказания помощи специалистам в конкретных областях знаний и достижения значимых результатов [2].

Применение ЭС позволяет решить различные задачи, к которым относится прогнозирование рисков развития

заболеваний, осложнений и эффективности лечения, ранняя диагностика, планирование лечения, мониторинг состояния здоровья пациента, автоматизированный анализ и статистическая обработка клинического материала. Экспертные МИС значительно упрощают работу в таких ситуациях, когда невозможно представить задачу в числовой форме, отсутствует определенность или точность в изучаемых параметрах или нет однозначного алгоритма решения задач [3]. Данные характеристики подходят для решения и медицинских задач, представляющих собой большой объем многомерных, сложных и порой противоречивых клинических данных, полученных в процессе цензурированных наблюдений.

В настоящее время в медицинских исследованиях преобладает использование статистических методов обработки данных. Самыми распространенными описательными методами, используемыми в традиционных статистических исследованиях, являются анализ выживаемости и многомерный комплексный анализ, классифицирующийся на дискриминантный, кластерный, факторный и корреляционный.

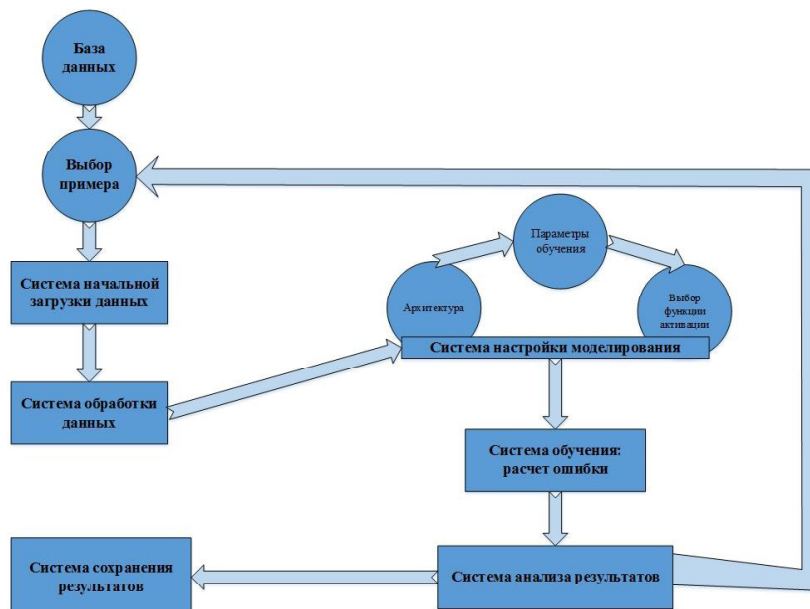


Рисунок 1 – Структурная схема проектирования ИИС

Основанные на изучении закономерности вероятностей появления определенного ожидаемого события в динамике на объектах исследуемой группы, методы анализа выживаемости позволяют оценить зависимости между многомерными непрерывными переменными со значениями времени жизни на основании регрессионных моделей. Для описания выживаемости в исследуемой выборке используется построение таблиц дожития или таблиц времен жизни, представляющих собой расширенную таблицу частот. Путем интервальных вычислений различных показателей объектов наблюдаемых групп рассчитывается ряд таких индикаторов, как доля умерших и выживших, плотность вероятности, функция выживания и интенсивности, на основании которых дается описание происхождению, интересующего события. Для непосредственной оценки функции выживания случайных цензурированных, но не группированных наблюдений в любой промежуток времени используется метод Каплана-Мейера, представляющего собой произведения вероятностей выживаемости в данный момент времени на следующий, когда наблюдение произошло [4]. В процессе анализа используются различные варианты подходов, например, метод логарифмического рангового теста (лог-ранк тест), к наиболее используемым и рекомендуемым в современных публикациях и достоверно эффективным относится модель Кокса (Cox Proportional Hazards Model), основанная на данных множественной регрессии и использующая в качестве выходного параметра значение отношения рисков и его доверительный интервал [5,6,7].

На мировом рынке медицинских компьютерных продуктов существует около 250 ЭС, введенных в эксплуатацию и активно используемых в различных учреждениях здравоохранения, приобретение которых возможно как в специальных каталогах, так и в сети интернет. Примером данных технологий может послужить PUFF-система – кодированное на языке BASIC интеллектуальное расширение аппарата исследования лёгких, предназначенная для диагностики заболеваний. Данные с измерительных приборов, оценивающих функцию легких, непосредственно после поступления на персональный компьютер врача обрабатываются и выводятся в форме конкретного диагноза и перечня рекомендаций для дальнейшего лечения [9].

Практическое использование в определенное время находили такие системы как MYCIN, предназначенная для установления штамма различных видов микроорганизмов, способных вызывать тяжелые формы инфекций, а также с целью рекомендации подбора оптимальной дозы антибиотиков индивидуально для каждого пациента в зависимости от его массы тела; AES, предназначенная для диагностирования различных заболеваний желудочно-кишечного тракта; INTERNIST (широко специализированная медицинская система); ЭС "ПЕРИТОН" для выбора метода экстракорпоральной гемокоррекции при перитоните; "РИСК-ОНКОЛОГИЯ" для формирования групп риска по ряду онкологических заболеваний; "СКАЗ" – для аппаратно-программного комплекса автоматизированного электрокардиографического обследования.

Одной из онлайн-версий МИС является бесплатное англоязычное программное обеспечение EasyDiagnosis компании MatheMEDics, позволяющее на основании только субъективного тестирования с определенной долей вероятности установить предполагаемый диагноз или подробный обзор каждой полученной диагностической категории. Для прогнозирования эффекта неосознаваемого воздействия на эмоциональную сферу массовых аудиторий фонетических свойств любого текста и полноценно проведенного контент-анализа, выявления личностных качеств психологического портрета авторов текста реализована Психолингвистическая ЭС Ваал(R), представляющая собой набор DLL-библиотек в текстовом процессоре Word for Windows.

В настоящее время в медицине наиболее эффективно использование таких ЭС, как методы добычи данных и искусственные нейронные сети, позволяющие решать задачи диагностики и прогнозирования различных заболеваний, а также выбирать тактику лечения и профилактики и др. [8, 9]

Методы добычи данных являются мощным статистическим аппаратом при исследовании данных в сравнительной аналитике, используемые для обнаружения скрытых закономерностей и построения прогностических моделей. Благодаря гибким алгоритмам представления результатов вычислений, удобному пользовательскому интерфейсу, объемному инструментальному анализу технологии метод добычи данных может использовать даже начинающий пользователь, не имеющий профессиональной ма-

тематической подготовки. Основу системы обычно составляют метод опорных векторов (МОВ, или Support Vector Machine), метод деревьев решений (decision trees), метод "ближайшего соседа" в пространстве признаков, байесовская классификация, линейная регрессия, кластерный и корреляционный анализы, методы поиска ассоциативных правил, генетические алгоритмы, представленных в виде определенных паттернов [10]. Зачастую при создании МИС применяются именно МОВ, позволяющего разделять объекты разной классовой принадлежности путем построения гиперплоскостей в многомерном пространстве.

Первое упоминание об ИНС относится в 1943 году, когда в одной из публикаций У. Маккалох и У. Питтс на электрической схеме представили модель нейронной сети. Далее в 1950-х годах исследовательская лаборатория IBM начинает активную работу в данном направлении, однако предпочтение отдается классическим методам статической обработки и применение ИНС отходит на дальний план. Кроме того, массивность оборудования в то время также могло препятствовать возникновению симпатии к данному подходу анализа данных. Лишь 1985 году основательно окреп интерес к нейронным сетям, Американский институт физики стал проводить ежегодные встречи "Нейронные сети для вычислений" [11].

На сегодняшний день можно сказать, что ИНС "представляет собой математическую модель, а также её программное или аппаратное воплощение, основанную на автоматическом моделировании функций головного мозга методами автоматической классификации реальных ситуаций из практики" [12]. Упрощенно один из вариантов этапа моделирования ИНС представлен на рисунке 1.

Основу нейросети составляют элементарные и однотипные ячейки, имитирующие нейроны мозга. Искусственный нейрон обладает группой синапсов – однонаправленных входных связей, соединенных с выходами других нейронов, с которых сигнал возбуждения или торможения поступает на синапсы следующих нейронов по аналогии с нервными клетками головного мозга [13]. Схематически искусственный нейрон представлен на рисунке 2.




Рисунок 2 – Искусственный нейрон

где x – вход нейрона,
 y – выход нейрона,
 w – весовой коэффициент нейрона,
 s – текущее состояние нейрона.

1. Текущее состояние нейрона, определяется по формуле:

$$s = \sum_{i=1}^n x_i \cdot w_i \quad (1)$$

2. Выход нейрона (что является функцией его состояния):

$$y = f(s) \quad (2)$$

3. Активационная нелинейная функция f с насыщением (функция S-образного вида):

$$f(x) = \frac{1}{1 + e^{-\alpha x}} \quad (3)$$

Также для всех ИНС характерен принцип параллельной обработки сигналов, который достигается путем объединения большого числа нейронов различных конфигураций в так называемые слои и их последующей обработке исходя из заданных в интерфейсе настроек или при загрузке ранее сохраненной нейросети из файла. Пример обработки результатов самой ИНС представлен на рисунке 3.

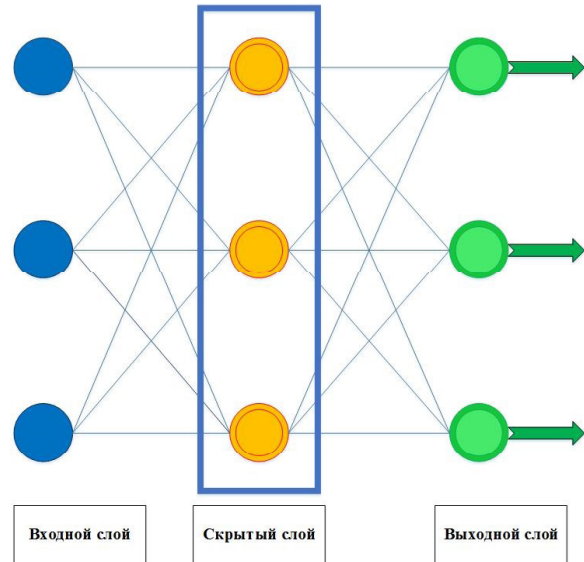


Рисунок 3 – Пример обработки результатов, многослойный перцептрон

В зависимости от поставленных задач и имеющихся данных для обучения при проведении многомерных клинических исследований используются различные виды топологии нейросетей, написанных с помощью простых (BASIC) или сложных языков объектно-ориентированного программирования, таких как C++:

- 1) обучение с учителем:
 - перцептрон;
- 2) обучение без учителя:
 - перцептрон;
 - самоорганизующаяся карта Кохонена;
 - нейронная сеть Кохонена;
 - сети адаптивного резонанса;
- 3) смешанное обучение:
 - сеть радиально-базисных функций;
 - вероятностная ИНС.

На сегодняшний день существует множество моделей используемых архитектур ИНС, которые различаются своей вычислительной сложностью, степенью сходства с живыми нейронами головного мозга, а также обладающие исключительной и единственной в своем создании уникальностью. В связи с этим ИНС не подлежат стандартам каких-либо классификаций в сравнении с традиционными статистическими методами.

Существующие нейронные сети способны работать как с числовыми данными, лежащими в определенном ограниченном диапазоне, так и нечисловыми параметрами, например, графическими изображениями различных конфигураций. Однако нестандартный масштаб количественных характеристик, наличие пропущенных значений, вариативность номинальных переменных, преобразование ка-

чественных параметров в числовую функцию или объявление их незначимыми, создают дополнительные проблемы в работе ИНС и искажают выходной результат.

Как с научной, так и с практической точки зрения одним из основных преимуществ использования нейросетей является ее способность к обучению с анализом данных, установлением сложных и скрытых связей и последующим представлением независимых результатов [3,14]. В процессе обучения при появлении большого числа ошибок, можно пересмотреть как конфигурацию самой сети, так и изменить включенные в ее обучение параметры [15].

Таким образом, преимуществами нейросетевых экспертных систем перед обычными МИС являются:

- способность обучения на множественных качественных и количественных примерах при неизвестных закономерностях между входными и выходными данными без фрагментации выборки данных. Более точно описание исследуемых параметров, возможность отображения динамики статистических свойств различных показателей;
- эффективное сжатие данных за счет построения нелинейных отображений и способность визуализации в пространстве меньшего числа нелинейных главных компонент построенной нейросети;
- возможность принятия решения на основе абсолютной устойчивости к шумам входных данных и адаптации к изменениям окружающей среды;
- моделирование реальных ситуаций решения задач осуществляется путем анализа знаний из собственного опыта, приобретаемого ИНС самостоятельно. Минимальное или полное отсутствие воздействия субъективного фактора на конечный результат. Возможность ручного редактирования значений отдельных параметров и их свойств искусственной нейронной сети, а также иные способы включения экспертных знаний в сеть;
- полученные результаты не всегда однозначны, поэтому стоит критично относиться к полученному результату;
- потенциальная отказоустойчивость при аппаратной реализации ИНС;
- возможность применения в ситуациях, требующих незамедлительного принятия решения.

Вместе с тем использование нейросетевых технологий для решения практических задач связано и с множеством трудностей. Одной из доминирующих проблем применения моделей ИНС является заранее неизвестная архитектура проектируемой нейронной сети и ее степень сложности, которых будет достаточно для достоверности получаемого результата. Данные факторы могут оказаться недопустимо высокими, что потребует еще более глобального усложнения архитектуры сетей. Простые нейронные сети, имеющие один скрытый слой, способны решать только простейшие, линейно разделяемые задачи [17]. Это ограничение преодолимо при использовании многослойных нейронных сетей, требующих значительных вычислительных ресурсов, техническим аспектам по ликвидации которых в виде увеличения мощности процессоров ПК и усовершенствовании систем кластеризации посвящено множество исследований [18].

Существует множество примеров применения нейронных сетей в области здравоохранения. Однако подавляющее большинство работ выполнено зарубежными исследователями и касается возможностей использования ИНС только в диагностике различных клинических ситуаций.

Первая функционально активная ИНС была создана в 1990 Вильямом Бакстом из Калифорнийского университета. Созданный многослойный перцептрон использовался для распознавания инфаркта миокарда у пациентов, поступающих в приемный покой с острой болью в области груди. Обучающаяся на 20 различных клинических параметрах ИНС продемонстрировала 92%-точность при обнаружении ИМ и дала только 4% случаев сигналов ложной тревоги.

На основе ИНС Jyoti Soni et al. (2011) создали веб-интерфейс интеллектуальной системы прогнозирования риска развития сердечной недостаточности (IHDP). В качестве базы данных были использованы 303 истории болезни пациентов больницы Кливленда с изучением всех имеющихся антропоморфометрических, анамнестических и лабораторных данных, общее количество которых составило 13 закодированных числовых параметра. Обученный при помощи 3 машинных алгоритмов с контролируемым управлением (байесовская сеть, K-NN, Decision List algorithm) в Java-платформе, взвешенный ассоциативный классификатор (WAC) с точностью 81,51% предсказал риск развития заболеваний сердца в исследуемой совокупности пациентов. Экспериментальные результаты также показали, что WAC является эффективным методом возможности для извлечения значимых паттернов из диагностического набора данных в диагностике сердечно-сосудистых заболеваний [19].

Nathan Hoot и Dominik Aronsky (2005) использовали нейросетевые технологии для прогнозирования 90-дневной выживаемости трансплантатов печени. Чувствительность разработанной байесовской модели, обученной по клиническим и лабораторным данным пациентов объединенной сети базы Sharing за 2000–2002 г., верификация – с проведением ROC- и множественного регрессионного анализа, составила 95%, прогнозирующая ценность – 91% [20].

Как метод классификации с целью автоматизированного обнаружения лиц с хронической болью в спине Daniel Callan и др. (2014) обучили SLR зеркальный декодер с помощью процедуры кросс-проверки на 25 образцах контрастных изображений по данным МРТ у пациентов 2 групп: 1) с хроническими болями, 2) – контрольная группа. Путем распознавания многомерных моделей функциональной деятельности в соматосенсорной и нижней теменной областях коры общая точность классификации в группы составила 92,3% ($p < 0,05$). Также установлено, что паттерны активности ГМ могут быть использованы в качестве диагностических маркеров хронических болей [21].

Для идентификации злокачественного статуса воспалительных лимфатических узлов и оценки надежности этой методики по сравнению с традиционными в дифференциальной диагностике немелкоклеточного рака легкого Toney LK и др. (2014) создали ИНС по алгоритму обратного распространения ошибки с одним скрытым слоем по данным ПЭТ и КТ 133 пациентов с доказанным хирургическим статусом, точность определения стадии N которой составила 99,2% [22].

Andersson P.A. и др. (2011) построили и проверили эффективность модели ИНС для раннего прогнозирования тяжести острого панкреатита (AP). В ходе проведенного исследования были получены значимые предикторы в развитии AP, обладающие большей клинической эффективностью по сравнению со стандартными критериями APACHE II. Чувствительность в правильности определения классифицированных пациентов была значительно выше для ИНС, чем для логистической регрессии ($p = 0,002$), 75 и

50% соответственно [23].

Для создания и обеспечения эффективной диагностики рака молочной железы Gogunescu F. и др. (2011) конкурентно были оценены 3 созданные архитектуры ИНС, а именно многослойный перцептрон (MLP), радиальная базисная функция (RBF), вероятностные нейронные сети (PNN). Модели MLP и RBF в соответствии с предоставленными данными визуализации обладали более высокой производительностью по сравнению с PNN. Определена статистически значимая разница ($p < 0,05$) между средними пропорциями правильно классифицированных случаев рака МЖ во всех моделях созданных ИНС [24].

В кардиологии нейросети применяются для анализа шумов сердца, аритмий, определения внутрижелудочковой эктопической активности. Обучение ИНС проведено для распознавания изменений сегмента ST-T, определения числа вовлеченных в атеросклеротический процесс сосудов [25].

Существует множество данных использования ИНС в диабетологии. Среди общего количества пациентов ежегодных медицинских осмотров с 2000 по 2006г. была создана выборочная совокупность общей численность 410 человек. На основании ряда клинических параметров, включая индекс резистентности к инсулину и определение адипонектина в сыворотке крови, Higoose H. и др. (2011) создали ИНС, чувствительность которой в сравнение с моделью множественной регрессии в прогнозировании 6-летней частоты развития метаболического синдрома составила 93 и 27% соответственно [26].

S. Wilfred Franklin и S. Edward Rajan (2013) разработали и протестировали нейросеть, основанную на классификации каждого пикселя сосудистого сегмента изображений сетчатки, доступные в базе данных DRIVE. Измеренная точность созданной многослойной ИНС с прямой подачей и состоящей из одного входного слоя, трех скрытых слоев (15 нейронов) и одного выходного слоя, в среднем составила 0,953. Автоматизированная сегментация кровеносных сосудов от фундус-изображений посредством нейросети является эффективным инструментом для предварительного скрининга диабетической ретинопатии, позволяющая не только анализировать большое число изображений, а также производить более глубокую характеристику свойств сосудов сетчатки [27].

С целью оценочного прогнозирования уровня глюкозы в крови (BG – Blood Glucose) у пациентов с СД 1 типа выполнено сравнение ИНС (Layer-Recurrent Network, сеть Элмана, Nonlinear Autoregressive Network) и модели экстраполяции по выборке максимального правдоподобия (EMMLS). Показано, что при краткосрочном прогнозировании уровня глюкозы более точный результат дает нейронная сеть, а при долгосрочном прогнозировании – модель EMMLS (более чем на 2%). На качественном уровне прогнозирование фактов роста/снижения уровня BG, а также скорости и пределов изменения верно предсказывают обе системы. Экстраполяция методом максимального подобия в комбинации с нейронной сетью способны дать достаточно точный прогноз уровня глюкозы в крови пациента, что может быть использовано для принятия решения об оптимальной дозе инсулина, которая должна быть введена в данный момент времени [28].

Для количественной классификации HbA1C и уровня глюкозы в крови как неинвазивного метода диагностики использованы многослойная, Elman и радиальная базовая

структуры нейронных сетей. Генеральная совокупность составила данные 297 пациентов, 73 из которых использовались для проверки структуры NN. Согласно полученным результатам: количественная оценка RBF была близка к характеристикам структуры Elman NN; для классификации уровня HbA1C и уровня глюкозы в крови достаточно использование всего 4 атрибутов (отклонения от испарения влаги и QCM, САД (мм рт ст) и частота пульса); при этом наиболее эффективным для обучения ИНС является значение параметра HbA1C, отражающего средний уровень глюкозы в течение предыдущих 2-3 месячных периодов [29].

Заключение. Таким образом, использование нейросетевых технологий имеет определенные перспективы. В прогнозировании заболеваний используется все большее число диагностически значимых маркеров, обработка которых в совокупности с другими данными становится более трудоемкой. Адаптация информационных технологий в области медицины требует понимания механизмов обработки данных компьютерной программой, а также знанием механизмов развития заболеваний. Проводимые исследования с применением нейросети говорят о перспективности направления и еще многих ее неизученных возможностях.

ЛИТЕРАТУРА

1. Назаренко Г.И., Гулиев Я.И., Ермаков Д.Е. *Медицинские информационные системы: теория и практика*. М.: Физматлит, **2005**. 320 с.
2. Коротких Н.Г., Петров И.Ю., Петров А.И. *О проблемах выявления экспертных знаний при разработке медицинских компьютерных программ // ВНМТ. 2012. № 2. С. 192-195.*
3. Андрейчиков А.В. Андрейчикова О.Н. *Интеллектуальные информационные системы*. М.: Финансы и статистика, **2004**. 423 с.
4. Румянцев П.О., Саенко В.А. и др. *Статистические методы анализа в клинической практике*. Обнинск: ГУ РМНЦ РАМН, **2009**. 46 с.
5. Liang W., Shen G., Zhang Y. et al. *Development and validation of a nomogram for predicting the survival of patients with non-metastatic nasopharyngeal carcinoma after curative treatment // Chinese Journal of Cancer. 2016. No. 1. Pp. 98-106.*
6. Бокерия О.Л., Базарсадаева Т.С., Шварц В.А., Ахобеков А.А. *Эффективность статинотерапии в профилактике фибрилляции предсердий у пациентов после аортокоронарного шунтирования // Анналы аритмологии. 2014. Т. 11. № 3. С. 161-169.*
7. Aigelsreiter A., Neumann J., Pichler M. et al. *Hepatocellular carcinomas with intracellular hyaline bodies have a poor prognosis // Liver International. 2017. Vol. 37. No. 4. Pp. 600-610.*
8. Чубукова И.А. *Data Mining*. М.: ИНТУИТ, БИНОМ. Лаборатория знаний, **2008**. 384 с.
9. Дюк В.А., Эмануэль В.Л. *Информационные технологии в медико-биологических исследованиях*. СПб.: Питер, **2003**. 528 с.
10. Дюк В.А., Самойленко В.А. *Data Mining: учебный курс*. СПб.: Питер, **2001**. 368 с.
11. Луценко Е.В. *Интеллектуальные информационные системы. Учебное пособие*. 2-е изд., перераб. и доп. Краснодар: КубГАУ, **2006**. 615 с.
12. Haykin S., Principe J., Sejnowski T. et al. *New Directions in Statistical Signal Processing: From Systems to Brains*. London: The MIT Press, **2007**. 544 p.
13. Медведев В.С. *Нейронные сети. Matlab 6*. М.: Диалог-МИФИ, **2002**. 496 с.
14. Осовский С. *Нейронные сети для обработки информации*. М.: Финансы и статистика, **2004**. 344 с.

15. Жариков О.Г., Ковалев В.А., Литвин А.А. *Современные возможности использования некоторых экспертных систем в медицине // Врачи и информационные технологии.* **2008.** № 5. С. 24–30.
16. Богомолов С.Д., Киселев С.В., Медведев А.П., Назаров В.М. *Применение искусственных нейронных сетей для прогнозирования в хирургии // Медикум.* **2003.** № 1.
17. Галушкин А. *Нейронные сети. Основы теории.* М.: Горячая Линия-Телеком, **2012.** 523 с.
18. Крючин О.В. *Искусственные нейронные сети и кластерные системы. Реализация нейросетевого симулятора // Вестник Тамбовского университета. Серия: Естественные и технические науки.* **2010.** Т. 15. № 1. С. 306-311.
19. Patil S.B., Kumaraswamy Y.S. *Intelligent and Effective Heart Attack Prediction System Using Data Mining and Artificial Neural Network // Eur. J. Sci. Res.* **2009.** No. 31 (4): Pp. 642-656.
20. Hoot N., Aronsky D. *Using Bayesian Networks to Predict Survival of Liver Transplant Patients // AMIA 2005 Symposium.* Washington: AMIA knowledge center, **2005.** Pp. 345-349.
21. Callan D., Mills L., Nott C., et al. *A Tool for Classifying Individuals with Chronic Back Pain: Using Multivariate Pattern Analysis with Functional Magnetic Resonance Imaging Data // PLoS ONE.* **2014.** Vol. 9. No. 6. Pp. 1-12.
22. Toney L., Vesselle H. *Neural Networks for Nodal Staging of Non-Small Cell Lung Cancer with FDG PET and CT: Importance of Combining Uptake Values and Sizes of Nodes and Primary Tumor // Radiology.* — **2014.** Vol. 270. No. 1. Pp. 91-98.
23. Andersson B., Andersson R., Ohlsson M. et al. *Prediction of severe acute pancreatitis at admission to hospital using artificial neural networks // Pancreatology.* **2011.** No. 11. Pp. 28-35.
24. Gorunescu F., Gorunescu M., Saftoiu A. et al. *Competitive/collaborative neural computing system for medical diagnosis in pancreatic cancer detection // Expert Syst.* **2011.** No. 28(1). Pp. 33-44.
25. Kurt I., Ture M., Turhan Kurum A. *Comparing performances of logistic regression, classification and regression tree, and neural networks for predicting coronary artery disease // Expert Systems with Applications.* **2008.** Vol. 34. No. 1. Pp. 366-374.
26. Hirose H., Takayama T., Hozawa S. et al. *Prediction of metabolic syndrome using artificial neural network system based on clinical data including insulin resistance index and serum adiponectin // Comput. Biol. Med.* **2011.** No. 41 Pp. 1051-1056.
27. Franklina S., Rajan S. *An automated retinal imaging method for the early diagnosis of diabetic retinopathy // Technology and Health Care* **21.** **2013.** Pp. 557-569.
28. Чернецов С.А., Чучуева И.А. *Прогнозирование уровня глюкозы в крови больных инсулинозависимым диабетом нейронными сетями и методом экстраполяции по выборке максимального подобия // Наука и образование: научное издание МГТУ им. Н.Э. Баумана.* **2010.** № 11. С. 1-9.
29. Saraoğlu H., Temurtas F., Altikat S. *Quantitative classification of HbA1C and blood glucose level for diabetes diagnosis using neural networks // Australas Phys Eng Sci Med.* **2013.** No. 36(4). Pp. 397-403.

Поступила в редакцию 11.09.2017