

Искусственные нейронные сети в кардиологии: анализ численных и текстовых данных

Онищенко П.С.^{*1,2}, Клышников К.Ю.^{†2}, Овчаренко Е.А.^{‡2}

¹*Институт вычислительных технологий Сибирского отделения РАН, Новосибирск,
Россия*

²*Научно-исследовательский институт комплексных проблем сердечно-сосудистых
заболеваний, Кемерово, Россия*

Аннотация. В данном обзоре рассмотрены работы, посвященные применению искусственных нейронных сетей для обработки численных и текстовых данных. Рассмотрены системы поддержки принятия решения; прогнозирования, включая прогнозы исходов лечения заболеваний сердечно-сосудистой системы; оценки рисков. Показана возможность использования искусственных нейронных сетей в качестве альтернативного подхода относительно стандартных методов обработки клинических данных пациента. Использование нейросетевых технологий при создании автоматизированных ассистентов лечащего врача позволит более качественно и оперативно предоставлять пациентам медицинские услуги.

Ключевые слова: кардиология, сердечно-сосудистая система, сердечно-сосудистые заболевания, искусственные нейронные сети.

ВВЕДЕНИЕ

Интенсивное развитие медицинских методов, оборудования и инструментария позволяет обнаруживать новые индикаторы (маркеры) заболеваний [1–3], повышая качество диагностики, что актуально для сердечно-сосудистых заболеваний (ССЗ), особенно в промышленных центрах [4–6]. Однако увеличение количества диагностических признаков влечет за собой удлинение времени их обработки и усложнение процесса систематизации врачом, т.к. зачастую клинические данные разрознены и представлены как количественными показателями, так изображениями и текстовыми данными. Частично данная проблема решается внедрением шкал риска, наглядным примером которых в кардиологии и сердечно-сосудистой хирургии являются SCORE, TIMI, CRUSADE, GRACE и т.д. [7, 8]. Несмотря на доказанную высокую эффективность такого подхода, шкалы обладают существенным исходным недостатком – искусственным ограничением параметров построения, что необходимо для полуавтоматического подсчета [9]. Кроме того, шкалы достаточно эффективно работают в популяциях, сходных с теми, которые использовались для создания или валидации такого инструмента, что может вызывать существенные смещения оценок в других популяциях [9]. При этом важно отметить, что медицинское обследование пациента, его анамнез, осмотр приводят к образованию большого объема данных, потенциально вносящих вклад в прогнозирование исхода, постановку диагноза и определение рисков, которые зачастую не учитываются при шкальном походе. В связи с этим,

*onis.pavel@gmail.com

†klyshnikovk@gmail.com

‡ov.eugene@gmail.com

информационные технологии как инструмент обработки больших массивов данных получают широкое распространение в медицине [10]. Начиная с середины 20 века было разработано множество клинических систем, поддерживающих принятие решения кардиологом [11, 12], которые легли в основу медицинских информационных систем различного назначения и отдельных автоматизированных лечебно-диагностических комплексов. Их применение позволяет решить задачи прогнозирования рисков развития заболеваний, осложнений и эффективности лечения, ранней диагностики, мониторинга состояния пациента и др. [13].

Анализ представленных работ показывает, что возможности использования искусственных нейронных сетей (ИНС) сводятся к трем основным прикладным группам: системам поддержки принятия решений (СППР); прогнозирования, в частности исходов лечения ССЗ; оценки рисков, включая риски развития ССЗ, на основе широкого спектра входных данных.

ПРИНЦИП

Развитие математических методов и аппаратной (hardware) части позволяет применять значительно более прогрессивные, по сравнению со стандартными алгоритмами, системы – ИНС. Принцип работы основан на нечеткой логике. Настройка ИНС (задание весовых коэффициентов) заключается в ее «обучении», по аналогии с обучением человека. Работа с большим количеством входных данных, а также установление неявных взаимосвязей между параметрами и их сочетаниями, обусловили широкое распространение ИНС во многих сферах медицины. Анализ современной литературы по данным базы PubMed демонстрирует явный интерес исследователей ИНС к ключевым проблемам медицины – онкологии, заболеваниям сердечно-сосудистой и пищеварительной систем (рис. 1).




Рис. 1. Количество экспериментальных работ по применению ИНС в области десяти ведущих сфер заболеваний населения в период с 2013 по 2018 год. Сравнение получено путем поиска типов заболеваний в литературе по данным PubMed.

Для более полного понимания плюсов и минусов использования ИНС необходимо коротко остановиться на принципе данного подхода. Основу ИНС составляют элементарные однотипные ячейки памяти, схожие с нейронами мозга. Данный «нейрон» в простейшем варианте представления имеет серию «дендритов» (входных параметров X) и один «аксон» (выходной параметр Y) [14] (рис. 2).




Рис. 2. Схема одного нейрона ИНС (слева) в сравнении с нейроном человека (справа): $x_1, x_2 \dots x_n$ – дендриты, т.е. входы нейрона, Y – аксон, т.е. выход нейрона, $w_1, w_2 \dots w_n$ – весовые коэффициенты, определяющие вклад каждого входного параметра в итоговый результат, S – текущее состояние нейрона, т.е. тело нейрона.

На вход каждого нейрона (ячейки) подается группа параметров $\mathbf{X} = \{x_1, x_2 \dots x_n\}$ количественных, графических, текстовых или их сочетаний, которые влияют на итоговый результат Y с помощью своих весовых коэффициентов $\mathbf{w} = \{w_1, w_2 \dots w_n\}$:

$$Y = \sum_{i=1}^n w_i x_i .$$

В процессе своего исторического развития первые ИНС (перцептроны) были простыми и состояли из входных ячеек, на которые подавали данные \mathbf{X} , и выходных, где получали обработанные данные Y . С усовершенствованием аппаратной базы усложнялись и ИНС – появились многослойные топологии, содержащие несколько уровней ячеек между входами и выходами (рис. 3). Были представлены ИНС с различным соотношением входов и выходов, что позволило убирать часть ненужной информации из получаемых данных или наоборот, получать новые характеристики этих данных, их сочетания.

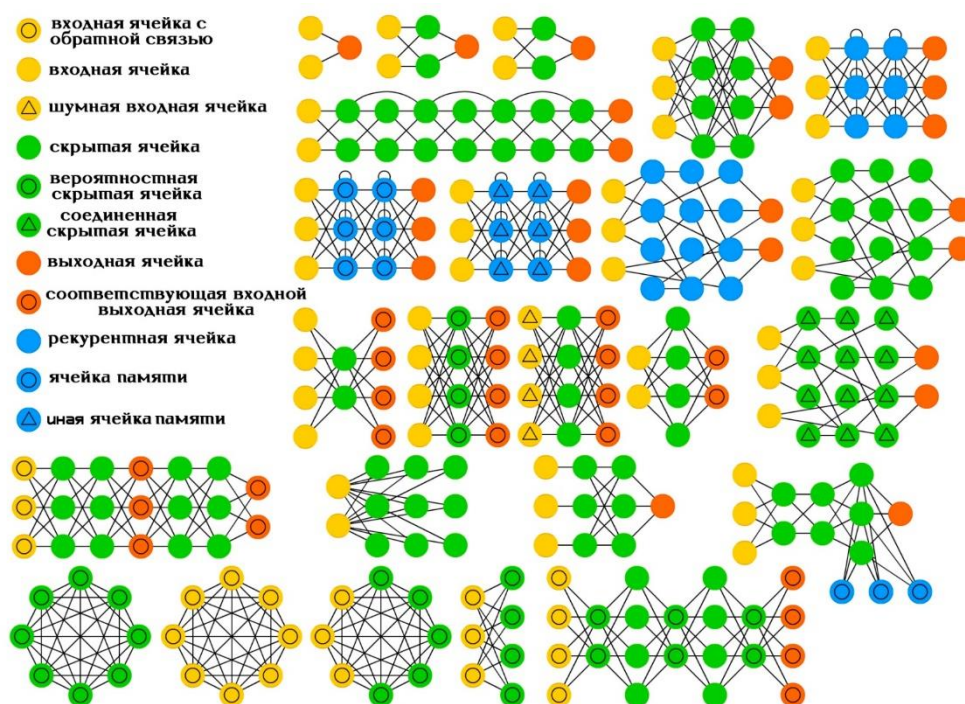


Рис. 3. Примеры существующих топологий ИНС [14].

Обучение

Ключевой особенностью ИНС является необходимость проведения ее обучения, т.е. подбора весовых коэффициентов \mathbf{w} , чтобы модель на выходе давала результат, который

требует от нее разработчик. Для этой цели используют выборку данных, которая содержит набор параметров X (например, анамнез, данные функциональных методов исследования, результаты анализов, изображения) и известный исход Y (например, твердые или мягкие конечные точки, выделенные на изображении области интереса). При этом весовые коэффициенты заранее не определены, задача ИНС – самостоятельно их вычислить.

Неоспоримым преимуществом ИНС перед типичными линейными алгоритмами или статистическими методами (например, реализованными в MS Excel [15], Statistica [16]), применяемыми при работе с медицинскими данными, является ее способность к обучению с анализом данных, нахождением связей и последующим представлением независимых результатов [17, 18]. Однако такой подход несет и существенный минус – требование к большой выборке клинических случаев с известным исходом. В процессе разработки можно не только изменить топологию ИНС, но и количество параметров, включенных в ее обучение [19]. Развитие ИНС привело к изучению данных с точки зрения глубокого обучения (deep learning), т.е. выявление паттернов в имеющейся информации [20]. По сравнению с пакетами для обработки статистических данных, например, Statistica, ИНС могут обнаруживать не всегда очевидные взаимосвязи между изучаемыми признаками и взаимосвязи между входными признаками и предсказаниями.

Проблема количества данных для обучения

Как известно, для каждой задачи требуется разное количество данных для обучения ИНС. Заранее затруднительно определить, какой объем данных для обучения необходим – недостаточное количество приведет к неточности модели, а излишнее обучение, или переобучение, заставит ИНС не обучаться, а зазубривать данные, что приведет к шуму, который влияет на точность результата [21]. Тем не менее, существуют методы статистической эвристики, которые позволяют определить подходящий размер выборки – данные методы выглядят как специальные коэффициенты масштабирования [22], например, увеличение выборки на определенную константу либо определенный процент для достижения желаемого уровня достоверности.

ПРИМЕНЕНИЕ В КАРДИОЛОГИИ

В рассмотренной нами литературе описано применение ИНС в качестве интеллектуальной системы, упрощающей постановку диагноза и оказывающей помощь в определении тактики и перспектив лечения ССЗ. Дополнительные источники описаны в таблице 1.

Системы поддержки принятия решений

В исследовании [23] авторами была использована рекуррентная ИНС для раннего выявления начала сердечной недостаточности. В данном исследовании были использованы 3884 случая сердечной недостаточности для обучения ИНС и данные 28903 людей из контрольной группы, которые являются пациентами неотложной медицинской помощи. Каждому из них соответствовали 72 клинических кода, описывающих их состояние. Подчеркивается, что ИНС проявила превосходную эффективность в прогнозировании начала сердечной недостаточности по сравнению с популярными методами. Так, используя 12-месячное окно наблюдения, ИНС показала точность в среднем 75.2 %, а при 18-месячном – 85.9 %.

Таблица 1. Дополнительные литературные источники

Источник	Краткое описание	Примененная ИНС	Объем выборки	Чувствительность / специфичность
Оценка / диагностика				
[56]	Авторы использовали ИНС глубокого обучения для оценки тридцатисекундных записей ЭКГ пациентов. Каждая из записей была отнесена к одному из 12 классов сердечного ритма. В статье приведено сравнение точности определения классов сердечного ритма ИНС и квалифицированными кардиологами. Различие составило 5.7 % в пользу ИНС.	ИНС глубокого обучения	91232 записей ЭКГ 53549 пациентов	83.7 % / 97.2 %
[57]	Автором преследовалась цель разработки метода автоматического распознавания малоподвижного поведения, связанного с сердечно-сосудистым риском, основанного на количественном измерении физической активности с использованием носимых датчиков	13-слойная ИНС	5 взрослых людей (40 ± 10 лет) по 28800 записей продолжительностью 23 минуты	93.33 % / 97.78 %
[58]	Описывается разработанный носимый монитор ЭКГ, с использованием ИНС для автоматической классификации полученных данных	Трехслойная	549 двухминутных оцифрованных записей ЭКГ 290 пациентов	100 % / 96.6 % Точность: 97 %
[59]	Предлагается новый подход к диагностике сердечной деятельности, основанный на полиномах Грама – Шмидта и вероятностных нейронных сетях	Вероятностная	3126 записей звуков сердца, длиной 5–120 секунд	93 % / 91 % Точность: 94 %
[60]	Использовали ИНС (см. Niemi et al. [61]) для получения некоторых характеристик для оценки послеоперационных уровней липидов и липопротеинов в плазме крови в пятилетние периоды у пациентов, перенесших коронарное шунтирование и получавших статины	Многослойный перцептрон	953 пациента, перенесших коронарное шунтирование	—
Прогнозирование				
[62]	ИНС, позволяющая при уменьшении воздействия радиационного воздействия электро- и сейсмокардиографии более точно собирать данные, во время проспективного обследования КТ-ангиографии	Двуслойная	Протестирована на 7 пациентах из контрольной группы и 11 с болезнями сердца	Контрольная группа: 89.9 % / 93.5 % С болезнями сердца 80.6 % / 83.8 %
[63]	Сравнение работы шести методов машинного обучения на задаче прогнозирования лиц, подверженных риску развития гипертонии, и которые могут получить наибольшую пользу от вмешательств	Четырехслойная	23095 пациента с 43 показателями жизнедеятельности	30.06 % / 88.56 %
[64]	Метод для объединения свойств из истории болезни пациента и данных ЭКГ для прогнозирования ССЗ в течение одного года после острого коронарного синдрома без подъема сегмента ST	RNN	Всего 7550 пациентов с симптомами острого коронарного синдрома без подъема сегмента ST	AUC = 0.767 на валидационной выборке*

*Примечание: AUC (Area Under the Curve) – количественный показатель при анализе качества классификации. Чем больше этот показатель относительно 0.5, тем качественнее классификатор.

J.K. Kim и S. Kang [24] использовали ИНС глубокого обучения для оценки статистических данных. Выборка содержала данные 4146 пациентов со средним возрастом 52 года. При оценке их состояния учитывали возраст, пол, индекс массы тела, общий холестерин, холестерин липопротеинов высокой плотности, систолическое артериальное давление, диастолическое артериальное давление, триглицерид, гемоглобин, заболевания щитовидной железы, хронические почечная недостаточность, гепатит В, гепатит С, цирроз печени, курение и диабет. По данным, которые предоставили авторы, наилучшая производительность была получена при исключении семи параметров (пол, гемоглобин, заболевания щитовидной железы, хронические почечная недостаточность, гепатиты В и С, цирроз печени) с точностью прогнозирования в 81.2 %.

Использование ИНС в области обработки ЭКГ рассматривается с точки зрения применения вейвлет преобразований [25] с точностью определения Р-волн, QRS-комплексов и Т-волн в среднем 97.5 %, 98.4 % и 97.2 %, соответственно. Однако, применение ИНС позволяет увеличить скорость и качество анализа этих данных. В работе G. Sannino и G. De Pietro [26] была применена ИНС глубокого обучения для автоматической классификации сигналов ЭКГ. В работе был использован набор данных MIT-BIH [27, 28], содержащий 48 получасовых записей из двухканальных амбулаторных ЭКГ 47 пациентов. Процесс обработки сигнала состоял из следующих шагов: уменьшение шума; определение пиков на ЭКГ сигнале (выявление расположения Р-, Т-волн и R-пиков); сегментация сигнала на одиночные удары сердца, которые будут отнесены к «здоровой» и «патологической» группе; извлечение дополнительной информации о сигнале (разбиение на удары сердца приводит к потере информации о профиле отдельной пульсации и вариативности сигнала). Каждый получасовой отрезок ЭКГ был поделен на пятиминутные отрезки, что в общей сложности дало 84615 уникальных записей. Их классификация показала, что 66750 записей отвечает критериям «нормальной» группы, 2288 – «патологической» (содержащие преждевременные сокращения желудочков, наджелудочковые преждевременные сокращения или слияния желудочковых и нормальных сокращений), а 14828 являются неклассифицируемыми записями, которые затем были исключены из рассмотрения. В результате такой подготовки данных 2288 записей из «здоровой» группы были случайным образом отобраны для дальнейшей работы. Всего для обучающего набора были выбраны 60 % от 4576 записей (1466 записей из «здоровой» группы и 1246 из «патологической»). Разработанная ИНС глубокого обучения была создана с использованием Google TensorFlow (Google, США) и показала крайне высокую точность (более 99 %), по сравнению с другими алгоритмами.

Авторами работы [29] была использована 1D-CNN (CNN – сверточная нейронная сеть, созданная для распознавания изображений) для определения сердечной аритмии на данных ЭКГ большой длины. В исследовании были использованы записи 45 пациентов из базы данных MIT-BIH. Предложенный подход основан на анализе десятисекундных отрезков, включающих в себя несколько сокращений сердца (несколько QRS-комплексов, каждый из которых описывает часть одной пульсации). Описанная ИНС распознает 17 классов сердечного ритма, среди которых: нормальный синусовый ритм, преждевременное желудочковое сокращение, трепетание и мерцание предсердий, желудочковая бигеминия и тригеминия, блокада левого или правого пучка Гиса и другие. Всего рассматриваемый набор данных состоял из 1000 фрагментов, отобранных случайным образом. Тестирование ИНС проводилось на трех наборах классов: 17 классов (полный набор), 15 классов (исключены следующие случаи: наджелудочковая тахикардия и слияние желудочкового и нормального ритма) и 13 классов (дополнительно исключены из рассмотрения преждевременное желудочковое сокращение и желудочковая тахикардия). Набор данных для обучения составил 583, 149

и 700 фрагментов, для валидации – 125, 149 и 150 фрагментов и для тестирования – 125, 147 и 150 фрагментов для набора из 13, 15 и 17 классов, соответственно. В результате полученная ИНС показала точность в размере 95.2 %, 92.5 % и 91.3 %, чувствительность – 93.5 %, 88.5 % и 83.9 % и специфичность – 99.6 %, 99.4 % и 99.4 % для набора из 13, 15 и 17 классов, соответственно. Авторы также отмечают, что время классификации каждого сегмента составило 15 миллисекунд, что позволяет использовать данный метод для автоматической обработки сигнала в режиме реального времени.

V.A. Moskalenko с соавторами в [30] описывает разработку алгоритма для сегментации ЭКГ на основе CNN, а именно UNet архитектуры. Рассматриваемый набор данных состоял из 455 записей стандартной 12-канальной ЭКГ из базы данных LUDB (база данных ЭКГ Лобачевского университета) длительностью 10 секунд с частотой дискретизации 500 Гц. Из всего набора данных 200 записей были выбраны для тестов, а остальные – для обучения. Автор отмечает, что разработанная ИНС обрабатывает каждый из двенадцати каналов отдельно от других, следовательно, для обучения были использованы $255 \times 12 = 3060$ сигналов. Точность работы данной ИНС составила, как минимум, 97.8 %, 99.5 % и 99.9 % при определении начал и концов P- и T-волн, а также QRS-комплексов, соответственно. Другой работой указанного автора [31] стало создание программного комплекса «Киберсердце-диагностика» для автоматического анализа ЭКГ, в котором были применены методы машинного обучения, среди которых SVM, дерево решений, ИНС и другие, для автоматического анализа ЭКГ. В данной работе использованы 1652 записи (45 % мужчин и 55 % женщин с возрастом 17–80 лет) стандартной 12-канальной ЭКГ, которую назвали «Кардиобаза», 1242 из которых были использованы в качестве тренировочной выборки. Каждая запись ЭКГ описана врачами-экспертами и использована как эталон, с которым сравнивался результат работы комплекса. Еще одним способом оценки работы программного комплекса стало сравнение с базами признаков: Arrhythmia Data Set (410 записей 12-канальных ЭКГ, описываемая 279 признаками с 16 классами признаков ЭКГ); PhysioNet PTBDB (549 записей 290 пациентов, каждая из которых относится к одному из 9 классов); PhysioNet Competition 2017 (8528 одноканальных пятиминутных записей ЭКГ, отнесенных к одному из четырех классов). Разработанная авторами база данных «Кардиобаза» была разделена на 9 классов, которые выбраны исходя из классических клинико-электрофизиологических подходов к заключениям по ЭКГ: абсолютная норма, синусовая аритмия, блокада правой ножки пучка Гиса, двухпучковая блокада, фибрилляция предсердий, ишемические изменения, гипертрофия левых отделов сердца, имплантированный электрокардиостимулятор и другое. Точность диагностики на различных классах признаков составила от 83.8 % до 94.5 % (на классе «Ишемические изменения» и «Блокада правой ножки пучка Гиса»), а в сравнении с заключением врачей-экспертов – от 62.9 % до 95.1 % на 9 классах признаков для базы «Кардиобаза».

В исследовании S. Savalia и V. Ematian [32] при использовании ИНС были определены различные типы аритмии. Данные ЭКГ подавали обученной с помощью двух алгоритмов MLP (многослойный перцептрон Румельхарта) и CNN. Изложенные в работе результаты показывают, что предложенные алгоритмы могут эффективно диагностировать различные сердечно-сосудистые заболевания с точностью 88.7 % для MLP и 83.5 % для CNN. По мнению авторов, хотя эффективность ожидаемых методов является достойной, проблема диагностики аритмии далека от решения и существуют множество осложнений, которые стоит исследовать.

P. Lu с соавторами [33] предложили усовершенствованную (на основе параболических уравнений) модель глубокого обучения ИНС для оценки результатов ЭКГ, имеющую 91.3 % точность, которая в среднем на 8.4 % выше, чем при использовании методов решения задачи автоматической диагностики (линейный SVM [34], Naïve Bayes и дерево решений [35]). Дальнейшее исследование автор видит в

применении модели прогнозирования, основанной на улучшенном глубоком обучении к фактическим прогнозам сердечно-сосудистых заболеваний.

В работе команды G.H. Tison [36] описана разработка и валидация ИНС для определения фибрилляции предсердий по данным ЭКГ, полученным с помощью «умных» часов Apple Watch (Apple Inc, США). В общей сложности в исследовании были использованы данные ЭКГ 9750 участников исследования Health eHeart Study, у которых была мерцательная аритмия в период с февраля 2016 по март 2017 года: 6682 человек были отобраны для обучающей выборки, 3068 – для тестирования и 51 пациент – валидационная выборка. Обучение сети проводилось с использованием неконтролируемого подхода, который авторы называют эвристической предварительной подготовкой, с использованием Google TensorFlow (Google, США). Результатом обработки данных ИНС стала величина соответствия 0.97 для выявления фибрилляции предсердий по эталонному ЭКГ в 12 стандартных ответвлениях, что говорит о практически полном покрытии данных моделью. Чувствительность составила 98.0 %, а специфичность – 90.2 %. В предварительном анализе, основанном на самоотчете о постоянной фибрилляции предсердий у амбулаторных участников, статистика соответствия составила 0.72, чувствительность – 67.7 %, специфичность – 67.6 %. Таким образом, авторами показана возможность определения фибрилляции предсердий человека по данным ЭКГ с использованием наручных «умных» часов.

Прогнозирование

Коллектив под руководством P.-F. Tsai [37] разработал систему, основанную на ИНС, для предсказания сроков пребывания пациентов в стационаре с одним из трех основных диагнозов: коронарный атеросклероз (КАС), сердечная недостаточность (СН) и острый инфаркт миокарда (ОИМ). Всего были использованы данные 2377 поступивших пациентов с кардиологическими расстройствами. Тренировочная выборка содержала в себе данные 744 поступивших пациентов с КАС и 1155 – с СН и ОИМ. Тестовая группа состояла из данных 189 пациентов с КАС и 289 – с СН и ОИМ. Во время обучения 70 % случайно отобранных данных использовались для тренировки ИНС, а остальные – для валидации. Использование модели ИНС позволило правильно прогнозировать время стационарного пребывания пациентов с КАС 88.07 % – 89.95 % на стадии выписки и 88.31 – 91.53 % на стадии поступления. Для пациентов с ОИМ или СН точность в пределах от 64.12 % до 66.78 % на стадии выписки и от 63.69 % до 67.47 % на стадии поступления, когда допускают погрешность в размере двух дней. Таким образом, используя предложенный метод, можно планировать работу лечебно-профилактического учреждения, его загруженность, т.е. решать вопросы администрирования. Подобный подход был рассмотрен E. Kutafina и соавторами [38], в исследовании которых описана модель с использованием ИНС для прогнозирования занятости кроватей в больничном стационаре. В исследовании были использованы исторические данные о поступлении и выписке пациентов в сочетании с внешними факторами, например, государственными праздниками или школьными каникулами. Полученная ИНС была оптимизирована для предсказания загруженности на 60 дней во время летнего сезона (с мая по сентябрь).

J.M. Kwon и соавторы [39] разработали основанную на использовании ИНС систему в качестве системы мониторинга за состоянием пациента и оповещения об ухудшении его состояния. ИНС была использована для оценки параметров температуры тела, сердечного ритма, частоты дыхания и систолического кровяного давления. В исследовании приняли участие все пациенты из 2 больниц (первая больница специализируется на сердечно-сосудистых заболеваниях, а вторая – общего профиля) в течение 91 месяца. Всего были собраны данные 52131 пациента, из которых ко второй больнице относятся 1772. Обучающая выборка состояла только из данных 46725

пациентов первой больницы, а остальные были отнесены к тестовой выборке. Как отмечает автор, полученная система обладает высокой чувствительностью и специфичностью: число ложных срабатываний снижено на 82.2 %, 13.5 % и 42.1 % по сравнению с модифицированной системой раннего предупреждения, методом случайного леса и логистической регрессией, соответственно.

А. Meyer с соавторами [40] показали возможность применения методов глубокого машинного обучения для прогнозирования серьезных осложнений во время интенсивной терапии в режиме реального времени после кардиохирургического вмешательства на открытом сердце. Исследование основано на использовании рекуррентной ИНС. Результат ее работы на основе данных 9269 пациентов показал, что разработанная ИНС в состоянии улучшить прогноз абсолютного осложнения на 29 % для кровотечений, на 24 % для смертности и почечной недостаточности по сравнению с соответствующими клиническими эталонными инструментами. Отличие от существующих прогностических клинических моделей для оценки вероятности смерти пациента (например, APACHE II или SAPS II) заключается в том, что в модель были включены статические и динамические показатели пациентов (пол, возраст, кровяное давление и др.) после кардиоторакальной операции, что позволило избежать сбора дополнительной информации медицинским персоналом. В заключении авторы сообщают, что возможен точный подсчет в режиме реального времени, основанный на конкретных группах пациентов и индивидуальных клинических условиях, с регулярно собираемыми данными во время оказания неотложной помощи, который может расширить процесс принятия решений врачом.

В работе S. Nanayakkara с соавторами [41] были использованы внутрибольничные данные, доступные в течение первых 24 часов после поступления пациента, с целью разработки более точной модели прогнозирования риска, используя методы как логистической регрессии, так и машинного обучения, в сочетании с демографической, физиологической и биохимической информацией. Входными параметрами для ИНС являлись: возраст, пол, сопутствующие заболевания и статус ремиссии при поступлении в отделение интенсивной терапии, отдельные компоненты шкалы комы Глазго до введения седации, выделение мочи, самые высокие и самые низкие физиологические и биохимические показатели, а также потребность в искусственной вентиляции легких в течение первых 24 часов после поступления в отделение интенсивной терапии и количество часов в больнице до поступления в отделение интенсивной терапии. Всего в исследовании приняло участие 48485 пациентов, поступивших в отделения интенсивной терапии Австралии и Новой Зеландии, у которых был диагноз остановка сердца вне больницы. После исключения было оставлено 39566 пациентов, включенных в анализ, из которых 45.6 % (18019) не дожили до выписки из больницы. Полученные результаты показывают возможность применения клиницистами данной ИНС для прогнозирования возможного летального исхода, т.к. точность алгоритма составила 97 %.

Л.Н. Ясницкий и Ф.М. Черепанов [42] создали нейронную сеть прогнозирования изменения состояния пациента в зависимости от изменения образа жизни. Авторами были исследованы 8 параметров, среди которых были: риск заболевания инфарктом миокарда, стенокардия стабильная, стенокардия нестабильная, ишемическая болезнь сердца, гипертоническая болезнь, аритмия и блокада сердца, хроническая и острая сердечная недостаточность. К сожалению, в работе не описан процесс обучения и уровень точности полученной ИНС, но отмечено, что данным методом, при использовании исторических данных с учетом текущего состояния пациента, ИНС позволяет снизить погрешность моделирования в среднем на 5–7 %. В заключение авторы говорят, что предложенная ИНС является «нейроэкспертной медицинской системой», с помощью которой можно не только производить диагностику, но и получать долгосрочные прогнозы развития заболеваний, а также рассматривать с

прогностической точки зрения шансы развития новых заболеваний. Разработанная ИНС позволяет «управлять» появлением и развитием прогнозируемых заболеваний путем предоставления рекомендаций по ведению образа жизни.

Оценка рисков

R. Nagain с соавторами [43] показано, что применение ИНС по сравнению с существующими системами оценки риска ССЗ, на примере оценки рисков по Фрамингему, разработанной в 1960 годах, дает большее преимущество. Авторами использованы данные 689 пациентов с симптомами ССЗ. Набор, состоящий из данных 5209 пациентов с ССЗ, был использован для валидации полученной ИНС. Используемые параметры: пол, возраст, общий холестерин, липопротеины высокой плотности, систолическое артериальное давление, диастолическое артериальное давление, сахарный диабет, индекс массы тела и курение. В работе сказано, что оценка рисков, полученная от ИНС, составила 98.6 %, тогда как по Фрамингему – 19.2 %.

Авторами работы [44] была произведена оценка возможности ИНС предсказать функциональное старение радиоцефальной артериовенозной фистулы, которая часто применяется при гемодиализе пациентов. В исследовании были использованы проспективные базы данных 266 пациентов за четырехлетний период с 10 параметрами для каждого пациента. Среди этих параметров были демографические (возраст, пол), анатомические (диаметры вен и лучевой артерии), сопутствующие заболевания (сахарный диабет, ИБС, хроническая СН, артериальная гипертензия), тип анестезии (местный или общий) и наличие пульсации, шума и вибрации грудной стенки. В результате обучения общая точность ИНС при обучении достигла 86.4 %, при валидации – 82.5 %, при тестировании – 77.5 % и точность на всем объеме данных – 84.5 %. В указанной работе показана способность ИНС с высокой степенью точности прогнозировать функциональное созревание и распознавать закономерности, которые на него влияют.

Коллектив авторов под руководством H. Li [45] исследовал влияние 15 параметров, среди которых уровень образования, наличие факта родов до текущей беременности, наличия ВПС в семейном анамнезе, наличие хронических болезней у родителей и других факторов, на риск рождения ребенка с ВПС. В исследовании участвовали 358 пациентов, из которых 300 отобрали случайным образом для тренировки (из них 101 случай рождения с ВПС), остальные использовали для тестирования полученной ИНС. Точность составила 83 % на тренировочном наборе данных и 78 % – на тестовом. Автор отмечает, что такая низкая точность обусловлена двумя факторами. Во-первых, не считая семейного анамнеза наличия ВПС, остальные 14 параметров не являются специфическими индикаторами ВПС, но являются общими факторами риска окружающей среды для различных врожденных дефектов. Во-вторых, не все факторы риска были включены в качестве предикторов.

Коллектив под руководством S.F. Weng [46] использовал 22 входных параметра, среди которых пол, возраст, общий уровень холестерина, холестерин липопротеинов высокой плотности, систолическое кровяное давление, курение, наличие диабета, индекс массы тела, триглицериды, наличие гипертензии, этнос и др. для оценки рисков формирования ССЗ. Выборка данных состояла из данных 378256 пациентов, из которых 295267 было выбрано в качестве тренировочного набора, а на 82989 наборах производили валидацию полученной ИНС. В работе помимо оценки рисков была произведена классификация факторов риска ССЗ. Так, по данным, полученным с использованием ИНС, важнейшими факторами являются фибрилляция предсердий, этнос, применение оральных кортикостероидов, возраст, наличие тяжелых психических расстройств, индекс депривации, наличие хронических болезней почек, курение, пол. По

сравнению с существующим алгоритмом АНА/АСА [47] для прогнозирования рисков, ИНС показала увеличение чувствительности на 3.6 % при уровне точности 95 %.

A. Sbrollini с соавторами [48] разработали специализированную ИНС, которая позволяет обнаруживать вновь возникающие или прогрессирующие патологии сердца по последовательным данным стандартной 12-канальной ЭКГ. Их сравнение дает возможность определить новые патологии, либо проверить эффективность конкретной терапии или вмешательства. Выборка для обучения и тестирования ИНС состояла из двух наборов данных: содержащих информацию о сердечной недостаточности (128 ЭКГ) и об ишемии (482 ЭКГ). Каждое ЭКГ конвертировали в векторкардиограмму и далее вычисляли 13 параметров. Весь набор ЭКГ случайным образом разделили на два набора: обучающий (64 ЭКГ СН и 241 ЭКГ ишемии) и тестировочный (65 ЭКГ СН и 241 ЭКГ ишемии). Особенность применяемой ИНС заключается в динамической формировке архитектуры, используя повторяющуюся процедуру структурирования и обучения, которая была разработана авторами для решения данного типа задач классификации. В результате обучения и тестирования ИНС на двух клинических базах данных была получена трехуровневая архитектура ИНС. Оценка работы алгоритма с помощью ROC-анализа показала качество работы 84 % и 83 % соответственно каждой базе данных.

Коммерческие решения

В современном мире применение ИНС имеет широкое распространение, например, для детекции лиц [49] и нахождения людей по фото [50], для создания беспилотных автомобилей [51], для увеличения прочности производимой продукции (например, деталей для автомобилей) и уменьшения необходимых ресурсов для их создания [52]. ИНС в повседневной жизни находят применение в виртуальных помощниках, таких как, Siri (Apple) или Cortana (Windows). Они помогают найти полезную и интересующую пользователя информацию, используя естественный человеческий язык. Также ИНС получили развитие и в коммерческом секторе, например, IBM Watson [53] – суперкомпьютер компании IBM, оснащенный вопросно-ответной системой искусственного интеллекта (ИИ). Он нашел применение в медицине:

- как аннотатор для клинических данных. Около 80 % медицинской информации является неструктурированной, способность ИИ обрабатывать естественный язык позволяет ему читать клинический текст из любого источника;
- для анализа данных пациента. ИИ может выявить проблемы, содержащиеся в исторических медицинских записях пациентов – как в структурированном, так и в неструктурированном тексте. Он суммирует информацию из истории болезни пациента и может предоставить «осознанную» сводку истории его заболевания;
- для определения меры клинического сходства между пациентами. ИИ может определять меру клинического сходства между пациентами, что дает возможность исследователям создавать не статистические, а динамические группы пациентов. Это также позволяет понять, какой путь лечения лучше подходит для данной группы пациентов;
- для медицинского понимания. С помощью технологий ИИ исследователи могут найти информацию в неструктурированной медицинской литературе, чтобы поддерживать гипотезы, помогая в открытии новых идей. ИИ может читать полный набор медицинской литературы, такой как Medline, и идентифицировать документы, которые семантически связаны с любой комбинацией медицинских понятий.

В частном случае, IBM Watson был применен в онкологии [54, 55]. Так, в двойном слепом исследовании сравнивали решения, принятые с помощью совета по онкологии, с решением, принятым системой Watson Oncology. Результаты показали, что 90 % рекомендаций, сделанных системой, соответствовали рекомендациям совета, но системе потребовалось всего 40 секунд для завершения процесса.

ПЕРСПЕКТИВЫ И ВЫВОДЫ

Преимущества ИНС перед медицинскими информационными системами и статистическими методами заключаются в способности обучения на больших множествах параметров при неизвестных закономерностях между входными и выходными данными. ИНС дают возможность получать более точные описания исследуемых параметров, а также отображать динамику статистических свойств различных показателей. ИНС позволяют принять решение на основе 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. Результаты работы ИНС подвержены минимальным воздействиям на конечный результат субъективного фактора клинициста и его опыта (положительного или отрицательного) на конечный результат или полностью от них отделены. Применение ИНС дает возможность ручного редактирования значений отдельных параметров и их свойств, а также иные способы включения экспертных знаний в сеть. Использование ИНС также предоставляет гибкий инструмент для ситуаций, в которых требуется незамедлительное принятие решения.

Применение ИНС в медицине является перспективным направлением, так как с их развитием будут увеличиваться размеры обрабатываемых данных. Внедрение ИНС позволит:

- облегчить и ускорить работу с пациентами;
- улучшить качество оказываемых медицинских услуг за счет подбора персонализированного метода лечения;
- прогнозировать ход заболевания;
- выявлять заболевания на ранних стадиях;
- использовать телемедицину для отдаленных поселений, где недоступны инструменты современной медицинской помощи.

С экономической точки зрения, использование ИНС может уменьшить количество затрачиваемого времени на обработку данных и постановку диагноза, что теоретически может снизить загруженность клиницистов. Это позволит уделять больше времени сложным случаям, что скажется положительным образом на качестве медицинского обслуживания и уменьшении неблагоприятных исходов в случае тяжелых заболеваний.

Так как со временем происходит накопление большого объема данных по каждому пациенту, то врачам становится все сложнее обрабатывать такой объем информации. Использование электронных медицинских карт удобно с точки зрения доступа к данным. При хранении историй болезней и результатов обследований и анализов в базе данных позволит ИНС эффективнее обрабатывать большой объем данных, что приведет к увеличению объема знаний. Также электронное хранение информации открывает широкое окно возможностей для обучения медицинского персонала и врачей на конкретных примерах и большой выборке. Они позволяют анализировать огромный объем данных и не только предоставлять исследователям усредненные характеристики заболеваний, но и проводить статистические и эпидемиологические оценки по учреждениям, городам, регионам, странам, миру.

Работа выполнена в рамках фундаментальной темы НИИ КПССЗ № 0546-2015-0011 "Патогенетическое обоснование разработки имплантатов для сердечно-сосудистой хирургии на основе биосовместимых материалов, с реализацией пациент-ориентированного подхода с использованием математического моделирования, тканевой инженерии и геномных предикторов".

СПИСОК ЛИТЕРАТУРЫ

1. Dhingra R., Vasani R.S., Biomarkers in cardiovascular disease: Statistical assessment and section on key novel heart failure biomarkers. *Trends in Cardiovascular Medicine*. 2017. V. 27. № 2. P. 123–133. doi: [10.1016/j.tcm.2016.07.005](https://doi.org/10.1016/j.tcm.2016.07.005).
2. Копьева К.В., Гракова Е.В., Тепляков А.Т. Новые маркеры сердечной недостаточности: значение для диагностики и прогнозирования NT-proBNP и интерлейкиновых рецепторов – членов семейства ST2. *Комплексные проблемы сердечно-сосудистых заболеваний*. 2018. Т. 7. № 1. С. 94–101. doi: [10.17802/2306-1278-2018-7-1-94-101](https://doi.org/10.17802/2306-1278-2018-7-1-94-101).
3. Wang J., Tan G.J., Han L.N., Bai Y.Y., He M., Liu H.B. Novel biomarkers for cardiovascular risk prediction. *Journal of Geriatric Cardiology*. 2017. V. 14. № 2. P. 135–150. doi: [10.17650/1818-8338-2014-1-4-8](https://doi.org/10.17650/1818-8338-2014-1-4-8).
4. Pyakurel P., Karki P., Lamsal M., Ghimire A., Pokharel P.K. Cardiovascular risk factors among industrial workers: a cross-sectional study from eastern Nepal. *J. Occup. Med. Toxicol.* 2016. V. 11. P. 25. doi: [10.1186/s12995-016-0109-6](https://doi.org/10.1186/s12995-016-0109-6).
5. Kinoshita M., Yokote K., Arai H., Iida M., Ishigaki Y., Ishibashi S., Umemoto S., Egusa G., Ohmura H., Okamura T., Kihara S., Koba S., Saito I., Shoji T., Daida H., Tsukamoto K., Deguchi J., Dohi S., Dobashi K., Hamaguchi H., Hara M., Hiro T., Biro S., Fujioka Y., Maruyama C., Miyamoto Y., Murakami Y., Yokode M., Yoshida H., Rakugi H., Wakatsuki A., Yamashita S. Japan Atherosclerosis Society (JAS) Guidelines for Prevention of Atherosclerotic Cardiovascular Diseases 2017. *J. Atheroscler. Thromb.* 2018. V. 25. № 9. P. 846–84. doi: [10.5551/jat.GL2017](https://doi.org/10.5551/jat.GL2017).
6. Табакаев М.В., Артамонова Г.В. Урбанизация и сердечно-сосудистые заболевания в современном обществе. *Российский кардиологический журнал*. 2015. Т. 6. № 122. С. 94–99. doi: [10.15829/1560-4071-2015-06-94-99](https://doi.org/10.15829/1560-4071-2015-06-94-99) (Tabakaev M.V., Artamonova G.V. Urbanization and cardiovascular diseases in modern society. *Russ. J. Cardiol.* 2015. V. 6. № 122. P. 94–99. doi: [10.15829/1560-4071-2015-06-94-99](https://doi.org/10.15829/1560-4071-2015-06-94-99)).
7. Studziński K., Tomasik T., Krzysztoń J., Józwiak J., Windak A. Effect of using cardiovascular risk scoring in routine risk assessment in primary prevention of cardiovascular disease: protocol for an overview of systematic reviews. *BMJ Open*. 2017. V. 7. № 3. doi: [10.1136/bmjopen-2016-014206](https://doi.org/10.1136/bmjopen-2016-014206).
8. Garg N., Muduli S.K., Kapoor A., Tewari S., Kumar S., Khanna R., Goel P.K. Comparison of different cardiovascular risk score calculators for cardiovascular risk prediction and guideline recommended statin uses. *Indian Heart Journal*. 2017. V. 69. № 4. P. 458–463. doi: [10.1016/j.ihj.2017.01.015](https://doi.org/10.1016/j.ihj.2017.01.015).
9. Jiang F., Jiang Y., Zhi H., Dong Y., Li H., Ma S., Wang Y., Dong Q., Shen H., Wang Y. Artificial intelligence in healthcare: past, present and future. *Stroke Vasc. Neurol.* 2017. V. 2. № 4. P. 230–243. doi: [10.1136/svn-2017-000101](https://doi.org/10.1136/svn-2017-000101).
10. Sacchi L., Lanzola G., Viani N., Quaglini S. Personalization and Patient Involvement in Decision Support Systems: Current Trends. *Yearb. Med. Inform.* 2015. V. 10. № 1. P. 106–118. doi: [10.15265/IY-2015-015](https://doi.org/10.15265/IY-2015-015).
11. Miller R.A. Medical diagnostic decision support systems – past, present, and future: a threaded bibliography and brief commentary. *J. Am. Med. Inform. Assoc.* 1994. № 1. P. 8–27. doi: [10.1136/jamia.1994.95236141](https://doi.org/10.1136/jamia.1994.95236141).
12. Tiwari P., Shah N., Samuel E., Shah P., Patel Y., Tiwari P. Clinical decision support systems. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*. 2019. V. 5. № 2. P. 993–995. doi: [10.32628/CSEIT1952264](https://doi.org/10.32628/CSEIT1952264).
13. Ramesh A.N., Kambhampati C., Monson J.R.T., Drew P.J. Artificial intelligence in medicine. *Ann. R. Coll. Surg. Engl.* 2004. V. 86. № 5. P. 334–338. doi: [10.1308/147870804290](https://doi.org/10.1308/147870804290).

14. Медведев В.С., Потемкин В.Г. *Нейронные сети MATLAB 6*. М.: Диалог-МИФИ, 2002. 496 с.
15. Herkenhoff L., Fogli J. *Applied statistics for business and management using Microsoft Excel*. New York: Springer, 2013. doi: [10.1007/978-1-4614-8423-3](https://doi.org/10.1007/978-1-4614-8423-3).
16. Weiß C.H. StatSoft Inc., Tulsa O.K.: STATISTICA, Version 8. *Advances in Statistical Analysis*. 2007. V. 91 № 3. P. 339–341. doi: [10.1007/s10182-007-0038-x](https://doi.org/10.1007/s10182-007-0038-x).
17. Grapov D., Fahrman J., Wanichthanarak K., Khoomrung S. Rise of deep learning for genomic, proteomic, and metabolomic data integration in precision medicine. *OMICS: A Journal of Integrative Biology*. 2018. V. 22. № 10. P. 630–636. doi: [10.1089/omi.2018.0097](https://doi.org/10.1089/omi.2018.0097).
18. Han S.H., Kim K.W., Kim S., Youn Y.C. Artificial neural network: understanding the basic concepts without mathematics. *Dement Neurocognitive Disord*. 2018. V. 17. № 3. P. 83–89. doi: [10.12779/dnd.2018.17.3.83](https://doi.org/10.12779/dnd.2018.17.3.83).
19. Жариков О.Г., Ковалев В.А., Литвин А.А. Современные возможности использования некоторых экспертных систем в медицине. *Врач и информационные технологии*. 2008. № 5. С. 24–30.
20. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. Cambridge: MIT Press, 2016. 800 p.
21. Panchal G., Ganatra A., Shah P., Panchal D. Determination of over-learning and over-fitting problem in back propagation neural network. *International Journal on Soft Computing*. 2011. V. 2. № 2. P. 40–51. doi: [10.5121/ijsc.2011.2204](https://doi.org/10.5121/ijsc.2011.2204).
22. Розыходжаева Г.А., Розыходжаева Д.А. Особенности формирования обучающей выборки и обучения нейронной сети с неполными входными данными при решении частных медицинских задач. *Научное обозрение. Биологические науки*. 2017. № 5. С. 28–32.
23. Choi E., Schuetz A., Stewart W.F., Sun J. Using recurrent neural network models for early detection of heart failure onset. *J. Am. Med. Inform. Assoc.* 2017. V. 24. № 2. P. 361–370. doi: [10.1093/jamia/ocw112](https://doi.org/10.1093/jamia/ocw112).
24. Kim J.K., Kang S. Neural Network-Based Coronary Heart Disease Risk Prediction Using Feature Correlation Analysis. *J. Healthc. Eng.* 2017. doi: [10.1155/2017/2780501](https://doi.org/10.1155/2017/2780501).
25. Kalyakulina A.I., Yusipov I.I., Moskalenko V.A., Nikolskiy A.V., Kozlov A.A., Zolotykh N.Yu., Ivanchenko M.V. Finding morphology points of electrocardiographic-signal waves using wavelet analysis. *Radiophysics and Quantum Electronics*. 2019. V. 61. № 8–9. P. 689–703. doi: [10.1007/s11141-019-09929-2](https://doi.org/10.1007/s11141-019-09929-2).
26. Sannino G., De Pietro G. A deep learning approach for ECG-based heartbeat classification for arrhythmia detection. *Future Generation Computer Systems*. 2018. V. 86. P. 446–455. doi: [10.1016/j.future.2018.03.057](https://doi.org/10.1016/j.future.2018.03.057).
27. Goldberger A.L., Amaral L.A., Glass L., Hausdorff J.M., Ivanov P.C., Mark R.G., Mietus J.E., Moody G.B., Peng C.-K., Stanley H.E. Physiobank, physiotoolkit, and physionet. *Circulation*. 2000. V. 101. № 23. doi: [10.1161/01.cir.101.23.e215](https://doi.org/10.1161/01.cir.101.23.e215).
28. Moody G.B., Mark R.G. The impact of the MIT-BIH arrhythmia database. *IEEE Engineering in Medicine and Biology Magazine*. 2001. V. 20. № 3. P. 45–50. doi: [10.1109/51.932724](https://doi.org/10.1109/51.932724).
29. Yıldırım Ö., Pławiak P., Tan R.-S., Acharya U.R. Arrhythmia detection using deep convolutional neural network with long duration ECG signals. *Computers in biology and medicine*. 2018. V. 102. P. 411–420. doi: [10.1016/j.compbiomed.2018.09.009](https://doi.org/10.1016/j.compbiomed.2018.09.009).
30. Moskalenko V., Zolotykh N., Osipov G. Deep Learning for ECG Segmentation. In: *International Conference on Neuroinformatics*. Eds. Kryzhanovsky B., Dunin-Barkowski W., Redko V., Tumentsev Yu. Cham: Springer, 2019. P. 246–254.
31. Москаленко В. А., Никольский А.В., Золотых Н.Ю., Козлов А.А., Косоногов К.А., Калякулина А.И., Юсипов И.И., Леванов В.М. Программный комплекс

- «Киберсердце-диагностика» для автоматического анализа электрокардиограмм с применением методов машинного обучения. *Современные технологии в медицине*. 2019. Т. 11. № 2. С. 86–91. doi: [10.17691/stm2019.11.2.12](https://doi.org/10.17691/stm2019.11.2.12).
32. Savalia S., Emamian V. Cardiac arrhythmia classification by multi-layer perceptron and convolution neural networks. *Bioengineering (Basel)*. 2018. V. 5. № 2. doi: [10.3390/bioengineering5020035](https://doi.org/10.3390/bioengineering5020035).
 33. Lu P., Guo S., Zhang H., Li Q., Wang Y., Wang Y., Qi L. Research on improved depth belief network-based prediction of cardiovascular diseases. *J. Healthc Eng.* 2018. doi: [10.1155/2018/8954878](https://doi.org/10.1155/2018/8954878).
 34. Iftikhar S., Fatima K., Rehman A., Almazyad A.S., Saba T. An evolution based hybrid approach for heart disease classification and associated risk factor identification. *Biomedical Research*. 2017. V. 28, № 8. P. 3451–3455.
 35. Chaurasia V., Pal S. Data Mining Approach to Detect Heart Diseases. *International Journal of Advanced Computer Science and Information Technology*. 2013. V. 2. № 4. P. 56–66.
 36. Tison G.H., Sanchez J.M., Ballinger B., Singh A., Olgin J.E., Pletcher M.J., Vittinghoff E., Lee E.S., Fan S.M., Gladstone R.A., Mikell C., Sohoni N., Hsieh J., Marcus G.M. Passive detection of atrial fibrillation using a commercially available smartwatch. *JAMA Cardiology*. 2018. V. 3. № 5. P. 409–416. doi: [10.1001/jamacardio.2018.0136](https://doi.org/10.1001/jamacardio.2018.0136).
 37. Tsai P.-F., Chen P.-C., Chen Y.-Y., Song H.-Y., Lin H.-M., Lin F.-M., Huang Q.-P. Length of hospital stay prediction at the admission stage for cardiology patients using artificial neural network. *J. Healthc. Eng.* 2016. doi: [10.1155/2016/7035463](https://doi.org/10.1155/2016/7035463).
 38. Kutafina E., Bechtold I., Kabino K., Jonas S.M. Recursive neural networks in hospital bed occupancy forecasting. *BMC Medical Informatics and Decision Making*. 2019. V. 19. № 39. doi: [10.1186/s12911-019-0776-1](https://doi.org/10.1186/s12911-019-0776-1).
 39. Kwon J.M., Lee Y., Lee Y., Lee S., Park J. An Algorithm Based on Deep Learning for Predicting In-Hospital Cardiac Arrest. *J. Am. Heart Assoc.* 2018. V. 7. № 13. doi: [10.1161/JAHA.118.008678](https://doi.org/10.1161/JAHA.118.008678).
 40. Meyer A., Zverinski D., Pfahringer B., Kempfert J., Kuehne T., Sündermann S.H., Stamm C., Hofmann T., Falk V., Eickhoff C. Machine learning for real-time prediction of complications in critical care: a retrospective study. *Lancet Respir. Med.* 2018. V. 6. № 12. P. 905–914. doi: [10.1016/S2213-2600\(18\)30300-X](https://doi.org/10.1016/S2213-2600(18)30300-X).
 41. Nanayakkara S., Fogarty S., Tremeer M., Ross K., Richards B., Bergmeir C., Xu S., Stub D., Smith K., Tacey M., Liew D., Pilcher D., Kaye D.M. Characterising risk of in-hospital mortality following cardiac arrest using machine learning: A retrospective international registry study. *PLoS Med.* 2018. V. 15. № 11. doi: [10.1371/journal.pmed.1002709](https://doi.org/10.1371/journal.pmed.1002709).
 42. 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](https://doi.org/10.15593/2499-9873/2018.3.08).
 43. Narain R., Saxena S., Goyal A.K. Cardiovascular risk prediction: a comparative study of Framingham and quantum neural network based approach. *Patient Prefer Adherence*. 2016. № 10. P. 1259–1270. doi: [10.2147/PPA.S108203](https://doi.org/10.2147/PPA.S108203).
 44. Kordzadeh A., Esfahlani S.S. The Role of Artificial Intelligence in the Prediction of Functional Maturation of Arteriovenous Fistula. *Ann. Vasc. Dis.* 2019. V. 12. № 1. P. 44–49. doi: [10.3400/avd.oa.18-00129](https://doi.org/10.3400/avd.oa.18-00129).
 45. Li H., Luo M., Zheng J., Luo J., Zeng R., Feng N., Du Q., Fang J. An artificial neural network prediction model of congenital heart disease based on risk factors. *Medicine (Baltimore)*. 2017. V. 96. № 6. doi: [10.1097/MD.00000000000006090](https://doi.org/10.1097/MD.00000000000006090).

46. Weng S.F., Reps J., Kai J., Garibaldi J.M., Qureshi N. Can machine-learning improve cardiovascular risk prediction using routine clinical data? *PLoS ONE*. 2017. V. 12. № 4. doi: [10.1371/journal.pone.0174944](https://doi.org/10.1371/journal.pone.0174944).
47. Stout K.K., Daniels C.J., Aboulhosn J.A., Bozkurt B., Broberg C.S., Colman J.M., Crumb S.R., Dearani J.A., Fuller S., Gurvitz M., Khairy P., Landzberg M.J., Saidi A., Valente A.M., Van Hare G.F. 2018 AHA/ACC guideline for the management of adults with congenital heart disease. *Journal of the American College of Cardiology*. 2018. doi: [10.1016/j.jacc.2018.08.1029](https://doi.org/10.1016/j.jacc.2018.08.1029).
48. Sbröllini A., De Jongh M.C., Ter Haar C.C., Treskes R.W., Man S., Burattini L., Swenne C.A. Serial electrocardiography to detect newly emerging or aggravating cardiac pathology: a deep-learning approach. *Biomed. Eng. Online*. 2019. V. 18. № 15. doi: [10.1186/s12938-019-0630-9](https://doi.org/10.1186/s12938-019-0630-9).
49. Sadek S., Al-Hamadi A., Michaelis B., Sayed U. Face detection and localization in color images: an efficient neural approach. *Journal of Software Engineering and Applications*. 2011. V. 04. № 12. P. 682–687. doi: [10.4236/jsea.2011.412080](https://doi.org/10.4236/jsea.2011.412080).
50. Xiao T., Li S., Wang B., Lin L., Wang X. End-to-end deep learning for person search. *arXiv: 1604.01850 [cs.CV]*. 2016.
51. Bin Sulaiman R. Artificial Intelligence Based Autonomous Car. *SSRN Electronic Journal*. 2018. doi: [10.2139/ssrn.3167638](https://doi.org/10.2139/ssrn.3167638).
52. Shaw P., Williams I. Reuse in practice: the UK's car and clothing sectors. *Detritus: Multidisciplinary journal of waste resources & residues*. 2018. V. 04. P. 36–47. doi: [10.31025/2611-4135/2018.13735](https://doi.org/10.31025/2611-4135/2018.13735).
53. IBM Watson. URL: <https://www.ibm.com/watson/> (дата обращения: 28.01.2020).
54. Curioni-Fontecedro A. A new era of oncology through artificial intelligence. *ESMO Open*. 2017. V. 2. № 2. doi: [10.1136/esmoopen-2017-000198](https://doi.org/10.1136/esmoopen-2017-000198).
55. Chen Y., Elenee Argentinis J.D., Weber G. IBM Watson: how cognitive computing can be applied to big data challenges in life sciences research. *Clin. Ther.* 2016. V. 38. № 4. P. 688–701. doi: [10.1016/j.clinthera.2015.12.001](https://doi.org/10.1016/j.clinthera.2015.12.001).
56. Hannun A.Y., Rajpurkar P., Haghpanahi M., Tison G.H., Bourn C., Turakhia M.P., Ng A.Y. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine*. 2019. V. 25. № 1. P. 65–69. doi: [10.1038/s41591-018-0268-3](https://doi.org/10.1038/s41591-018-0268-3).
57. Kaňtoch E. Recognition of sedentary behavior by machine learning analysis of wearable sensors during activities of daily living for telemedical assessment of cardiovascular risk. *Sensors*. 2018. V. 18 № 10. doi: [10.3390/s18103219](https://doi.org/10.3390/s18103219).
58. Mena L.J., Félix, V.G., Ochoa A., Ostos R., González E., Aspuru J., Velarde P., Maestre G.E. Mobile personal health monitoring for automated classification of electrocardiogram signals in elderly. *Computational and Mathematical Methods in Medicine*. 2018. V. 2018. P. 1–9. doi: [10.1155/2018/9128054](https://doi.org/10.1155/2018/9128054).
59. Beritelli F., Capizzi G., Lo Sciuto G., Napoli C., Scaglione F. Automatic heart activity diagnosis based on Gram polynomials and probabilistic neural networks. *Biomed. Eng. Lett.* 2017. V. 8. № 1. P. 77–85. doi: [10.1007/s13534-017-0046-z](https://doi.org/10.1007/s13534-017-0046-z).
60. Palomäki A., Hällberg V., Ala-Korpela M., Kovanen P.T., Malminiemi K. Prompt impact of first prospective statin mega-trials on postoperative lipid management of CABG patients: a 20-year follow-up in a single hospital. *Lipids Health Dis.* 2016. V. 15. P. 124. doi: [10.1186/s12944-016-0292-6](https://doi.org/10.1186/s12944-016-0292-6).
61. Niemi J., Mäkinen V.-P., Heikkinen J., Tenkanen L., Hiltunen Y., Hannuksela M. L., Jauhiainen M., Forsblom C., Taskinen M.R., Kesäniemi Y.A., Savolainen M.J., Kaski K., Groop P.H., Kovanen P.T., Ala-Korpela M. Estimation of VLDL, IDL, LDL, HDL2, apoA-I, and apoB from the Friedewald inputs—apoB and IDL, but not LDL, are

- associated with mortality in type 1 diabetes. *Annals of Medicine*. 2009. V. 41. № 6. P. 451–461. doi: [10.1080/07853890902893392](https://doi.org/10.1080/07853890902893392).
62. Yao J., Tridandapani S., Auffermann W.F., Wick C.A., Bhatti P.T. An adaptive seismocardiography (scg)-ecg multimodal framework for cardiac gating using artificial neural networks. *IEEE J. Transl. Eng. Health Med.* 2018. V. 6. doi: [10.1109/JTEHM.2018.2869141](https://doi.org/10.1109/JTEHM.2018.2869141).
63. Sakr S., Elshawi R., Ahmed A., Qureshi W.T., Brawner C., Keteyian S., Blaha M.J., Al-Mallah M.H. Using machine learning on cardiorespiratory fitness data for predicting hypertension: The Henry Ford Exercise Testing (FIT) Project. *PLoS One*. 2018. V. 13. № 4. doi: [10.1371/journal.pone.0195344](https://doi.org/10.1371/journal.pone.0195344).
64. Myers P.D., Scirica B.M., Stultz C.M. Machine learning improves risk stratification after acute coronary syndrome. *Sci. Rep.* 2017. V. 7. doi: [10.1038/s41598-017-12951-x](https://doi.org/10.1038/s41598-017-12951-x).

Рукопись поступила в редакцию 18.07.2019, переработанный вариант поступил 15.01.2020.
Дата опубликования 18.02.2020.

Artificial Neural Networks in Cardiology: Analysis of Numerical and Text Data

Onishchenko P.S.^{1,2}, Klyshnikov K.Y.², Ovcharenko E.A.²

¹*The Institute of Computational Technologies of SB RAS, Novosibirsk, Russia*

²*Federal State Budgetary Scientific Institution Research Institute for Complex Issues of Cardiovascular Diseases, Kemerovo, Russia*

Abstract. This review discusses works on the use of artificial neural networks for processing numerical and textual data. Application of a number of widely used approaches is considered, such as decision support systems; prediction systems, providing forecasts of outcomes of various methods of treatment of cardiovascular diseases, and risk assessment systems. The possibility of using artificial neural networks as an alternative approach to standard methods for processing patient clinical data has been shown. The use of neural network technologies in the creation of automated assistants to the attending physician will make it possible to provide medical services better and more efficiently.

Key words: *cardiology, cardiovascular system, cardiovascular diseases, artificial neural networks.*