

Нейросетевая диагностика заболеваний сердечно-сосудистой системы на основе data-driven-метода

С.Г. Мосин^{1,2}✉¹ Институт вычислительной математики и информационных технологий, КФУ,
г. Казань, 420008, Россия² «ЛабСистемс», г. Владимир, 600000, Россия

Ссылка для цитирования

Мосин С.Г. Нейросетевая диагностика заболеваний сердечно-сосудистой системы на основе data-driven-метода // Программные продукты и системы. 2024. Т. 37. № 1. С. 122–130. doi: 10.15827/0236-235X.142.122-130

Информация о статье

Группа специальностей ВАК: 1.2.1

Поступила в редакцию: 21.07.2023

После доработки: 02.10.2023

Принята к публикации: 27.10.2023

Аннотация. В работе рассмотрены способы диагностики заболеваний сердечно-сосудистой системы по электрокардиограмме (ЭКГ) с применением методов искусственного интеллекта. Определены проблемы диагностики заболеваний сердечно-сосудистой системы модельно-ориентированными методами (model-driven methods). Предложен подход к диагностике методом машинного обучения без выделения характерных параметров ЭКГ-сигналов (data-driven method). Представлены архитектура нейроморфного анализатора ЭКГ-сигналов на основе одномерной сверточной нейронной сети и маршрут его проектирования. Проведены экспериментальные исследования на наборе ЭКГ-сигналов РТВ-XL, подтвердившие работоспособность и эффективность предложенного подхода. Выполнены структурный и параметрический синтезы нейроморфного анализатора для разного количества внутренних слоев и исходных параметров обучения. В ходе сравнительного анализа полученных результатов установлено, что нейронная сеть с двумя сверточными слоями обладает низкой точностью обучения и высокими ошибками диагностирования, трехслойная нейронная сеть способствует росту ошибок I рода, а четырехслойная – росту ошибок II рода. Использование трехслойной сверточной нейронной сети с окном объединения меньшего размера обеспечило диагностирование до 85,66 % случаев инфаркта миокарда. В заключении означены направления дальнейших исследований по повышению точности диагностирования за счет снижения размерности входных ЭКГ-сигналов, а также введения вероятностной оценки принадлежности рассматриваемого сигнала одному из возможных состояний двойственной группы.

Ключевые слова: нейросетевая диагностика, нейроморфный анализатор, ЭКГ-сигнал, диагностика заболеваний сердечно-сосудистой системы, архитектура нейроморфного анализатора, маршрут проектирования, data-driven-метод

Благодарности. Работа выполнена в рамках Программы стратегического академического лидерства Казанского (Приволжского) федерального университета («ПРИОРИТЕТ-2030»)

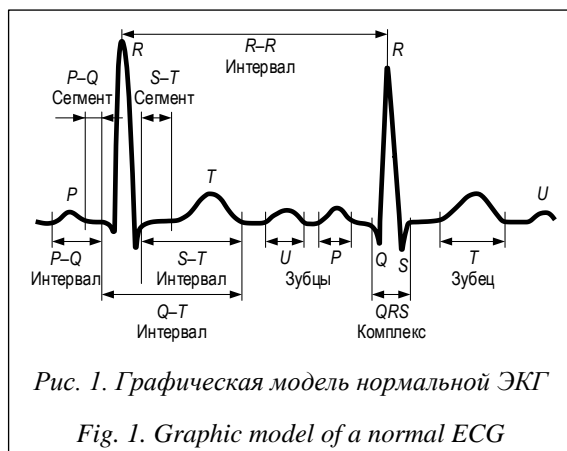
Введение. Методы машинного обучения находят широкое применение в различных областях деятельности человека, обеспечивая поддержку принятия решений на основе обработки больших объемов данных. Выделяют три основных направления использования методов: классификация (с учителем), кластеризация (без учителя) и регрессия. Методы классификации на основе машинного обучения получили широкое распространение в распознавании графических образов – объектов [1], рукописных символов [2], в тестировании и диагностике неисправностей технических объектов [3], диагностике заболеваний по результатам медицинских анализов и исследований [4, 5] и др.

По оценке Всемирной организации здравоохранения, заболевания сердечно-сосудистой системы являются одной из главных причин летальных исходов и инвалидности человека. Ранняя диагностика этих заболеваний позво-

ляет назначить эффективный способ профилактики и лечения, повышая продолжительность и качество жизни пациента.

Анализ *электрокардиограммы* (ЭКГ) – эффективный неинвазивный способ диагностики заболеваний, где главная роль закреплена за кардиологом или врачом функциональной диагностики, расшифровывающим сигналы ЭКГ и определяющим состояние сердечно-сосудистой системы пациента. Использование медицинских информационных систем поддержки принятия врачебных решений позволяет повысить качество диагностики заболеваний, снизить влияние человеческого фактора, независимо учитывать проявления случайных и детерминированных внешних факторов (шумы, искажения, нечеткость и т.п.). В настоящее время при анализе ЭКГ широкое распространение получили модельно-ориентированные методы машинного обучения, основанные на ис-

пользовании характерных параметров, выделенных по сигналам ЭКГ пациента согласно идеальной *PQRST*-модели сердечного импульса (рис. 1). К характерным параметрам относятся ширина комплекса *QRS*, длительность интервала *Q-T*, длительность интервала *R-R*, длительность интервала *P-Q*, амплитуда зубца *S*, направление зубца *T*, амплитуда и длительность зубца *P*, ширина и глубина зубца *Q* и др.



Так, в работе [6] предложено использовать многослойный перцептрон для диагностики нормального состояния и четырех заболеваний сердечно-сосудистой системы на основе девяти характерных параметров ЭКГ-сигнала, которые подаются на входной слой. Для обучения использован алгоритм обратного распространения ошибки. Применение метода Гамильтона для обнаружения *R*-пиков ЭКГ-сигналов и последующая бинарная классификация с использованием методов машинного обучения – случайный лес, логистическая регрессия, метод опорных векторов и нейронная сеть – описаны в [7]. В работе [8] рассмотрена предобработка ЭКГ-сигналов с использованием КИХ-фильтра и сегментации с последующим обучением сверточной нейронной сети (НС) полученными отсчетами с применением алгоритма обратного распространения ошибки и алгоритма оптимизации Adam. Подход к выделению характерных параметров *QRS*-комплекса на основе сегментации ЭКГ-сигналов методом декомпозиции вариационного режима и усреднения сигнала с выпрямлением по фазе с последующей обработкой методами искусственного интеллекта (методом опорных векторов (SVM), ближайших средних (KNN), наивного байесовского классификатора (NB)) предложен в [9]. Система автоматического анализа ЭКГ с использованием метода детектирования ключевых точек и сегментации с после-

дующей классификацией заболеваний сердечно-сосудистой системы методами машинного обучения представлена в [10].

Анализ показал, что наличие шумов и искажений в реальных сигналах ЭКГ требует специализированной предобработки, связанной с фильтрацией, сегментацией, спектральным разложением и прочим, что предполагает наличие дополнительных вычислительных средств и затрат времени. Выделенные в итоге из ЭКГ-сигнала характерные параметры используют для обучения нейроморфного классификатора. Критическими шагами на этапе обучения НС являются выбор количества используемых параметров и оценка степени их влияния на качество диагностики. Наличие в обучающем наборе характерных параметров с низким влиянием на различимость диагностируемых состояний, а также исключение из обучающих наборов характерных параметров с высокой степенью влияния на различимость могут приводить к снижению качества обучения НС и последующей диагностики.

Альтернативой модельно-ориентированным методам, позволяющей избавиться от их недостатков и слабых сторон, могут служить методы машинного обучения, ориентированные на данные (data-driven methods). Главное требование таких методов – наличие большого объема размеченных данных, охватывающих разные варианты диагностируемых состояний. Методы глубокого машинного обучения (deep learning) и сверточные НС (Convolution Neural Network – CNN) нашли применение в данном направлении. Например, сверточная НС VGG16 и алгоритм обнаружения объектов YOLOv2 предложены в [11] для построения вектора признаков и распознавания лиц человека по видео. В [12] рассмотрены нейросетевая сверточная модель и этапы предобработки исходных данных для повышения точности диагностирования заболеваний дыхательных путей по анализу аудиозаписей дыхания пациентов. В [13] авторы предлагают применять архитектуру сверточной НС OpenPose, модифицированную моделью внимания, для автоматического выделения частей тела человека по изображению.

Две модели глубокого машинного обучения для предсказания рубцов миокарда по сигналам ЭКГ и клиническим параметрам, где первая модель основана на сверточной НС, а вторая – на комбинации CNN и НС прямого распространения (Feedforward Neural Network – FNN), предложены в [14]. Результаты экспериментальных исследований показали среднюю точ-

ность диагностики на уровне 70,2 % и 78,0 % для первой и второй моделей соответственно.

В данной работе предложен подход к автоматизированному построению *нейроморфного анализатора* (НА), обеспечивающего диагностику заболеваний сердечно-сосудистой системы при обработке непосредственных сигналов ЭКГ data-driven-методом машинного обучения без явного выделения характерных параметров.

Цель – автоматизация построения НА заболеваний сердечно-сосудистой системы на основе прямой классификации сигналов ЭКГ (без явного выделения характерных параметров) и его исследование.

Научная новизна заключается в следующем:

- предложена архитектура НА ЭКГ-сигналов, рассматриваемых в виде многомерных временных рядов, на основе одномерной сверточной НС, обеспечивающая диагностику заболеваний сердечно-сосудистой системы;
- разработан маршрут проектирования НА ЭКГ-сигналов, включающий автоматизированный структурный и параметрический синтез по заданному множеству ограничений;
- проведены экспериментальные исследования предложенного решения на наборе реальных данных пациентов, в ходе которых обеспечена эффективность диагностики инфаркта миокарда и предынфарктного состояния выше 85,6 %.

Представление сигналов ЭКГ

ЭКГ регистрирует сердечную активность с сохранением измеряемых электрических сигналов, нормальная форма которых имеет вид, представленный на рисунке 1. Запись ЭКГ в стандартных условиях проводят в двенадцати отведениях с подключением базового электрода (земля) к правой ноге пациента:

– *стандартные двухполюсные* (I, II и III) фиксируют во фронтальной плоскости разность потенциалов между двумя точками электрического поля на разных конечностях пациента;

– *усиленные однополюсные* (aVr , aVl и aVf) регистрируют разность потенциалов между одной из конечностей (r – правая рука, l – левая рука, f – левая нога), к которой подключен положительный электрод, и средним потенциалом с двух других конечностей (отрицательный электрод);

– *грудные отведения* ($v1-v6$) регистрируют разность потенциалов между активным поло-

жительным электродом, установленным в определенную точку грудной клетки (6 вариантов), и отрицательным электродом на трех конечностях.

Каждый зубец ЭКГ-сигнала отражает разные фазы сердечной активности: P – процесс возбуждения и расслабления предсердий; Q , S – фазу деполяризации межжелудочковой перегородки; R – фазу деполяризации нижних камер сердца; T – расслабление миокарда; U может отсутствовать, появление связывают с персистирующей электрической активностью отдельных элементов желудочков.

Сигнал ЭКГ в каждом отведении можно рассматривать в виде временного ряда, представленного временными отсчетами $\{x(t_i)\}$ с заданной частотой дискретизации (f_s), где $t_i = t_0 + i/f_s$, t_0 – начальное время записи отсчетов, $i = 1, \dots, N$, N – количество временных отсчетов.

Сигналы в двенадцати отведениях можно представить многомерным временным рядом:

$$\mathbf{TS} = \{x_k(t_i)\}, k = 1, \dots, 12, i = 1, \dots, N, \quad (1)$$

где k – номер отведения.

Архитектура нейроморфного анализатора

Реализацию НА предлагается осуществлять с использованием одномерной многослойной сверточной НС. В основе выбора архитектуры лежит анализ способа представления исходных данных (ЭКГ-сигналов) и ожидаемого результата в виде идентификатора принадлежности к одной из классификационных групп, соответствующей диагностируемому заболеванию.

Использование сверточной НС обусловлено ее возможностями обработки непосредственных данных с выделением из них необходимых для классификации признаков в ходе операции свертки на этапе обучения.

Одномерность сверточной НС определена структурой представления сигнала ЭКГ, как многомерного временного ряда (1), в виде прямоугольной матрицы

$$\mathbf{X} = [x_{ki}], x_{ki} = x_k(t_i), k = 1, \dots, K, i = 1, \dots, N, \quad (2)$$

где строки k соответствуют измерениям в одном из двенадцати отведений ($K = 12$), а столбцы i содержат последовательные значения временных отсчетов. Таким образом, значения матрицы (2) размерностью $K \times N$ поступают на вход НС для каждого экземпляра ЭКГ-сигнала.

Многослойность сверточной НС определена необходимостью выделения из исходных данных достаточного количества признаков с разной степенью детализации для классификации заболеваний сердечно-сосудистой системы.

Предлагаемая архитектура нейроморфного анализатора имеет вид, представленный на рисунке 2.

Основные операции, выполняемые при обучении предложенной НС, – свертка, объединение и классификация, которые реализуются в базисе последовательных сверточных слоев, слоев объединения и полносвязного слоя с функцией вероятностной классификации на выходе.

Операция свертки на каждом i -м уровне использует два параметра: FN_i – количество используемых фильтров и FS_i – размер ядра свертки. В результате выполнения данной операции формируется i -й сверточный слой, включающий FN_i матриц сформированных признаков. В каждом сверточном слое все матрицы имеют одинаковый размер, соответствующий размеру поступающих на его вход данных. За каждым сверточным слоем расположен слой активации на основе функции ELU (*Exponential Linear Unit*), которая позволяет использовать при обучении НС отрицательные значения входных данных.

Операция объединения на каждом i -м уровне использует два параметра: PS_i – размер окна объединения, S_i – шаг перемещения. В результате выполнения данной операции формируется i -й слой объединения, включающий FN_i матриц сформированных признаков меньшей размерности относительно размерности входных данных этого слоя:

$$K_i = f_1(K_{i-1}, FN_i, FS_i),$$

$$N_i = f_2(N_{i-1}, FN_i, FS_i),$$

$$K_i \leq K_{i-1}, N_i \leq N_{i-1}.$$

Полносвязный слой обеспечивает обработку признаков, сформированных в результате операций свертки и объединения на нескольких уровнях, с формированием классификационных признаков на выходе ($y_j, j = 1, \dots, M$), соответствующих вероятности принадлежности входного ЭКГ-сигнала одной из M категорий.

Реализация НА заболеваний сердечно-сосудистой системы

Предложен маршрут, обеспечивающий автоматизированное проектирование НА заболеваний сердечно-сосудистой системы в соответствии с представленной ранее архитектурой на основе сверточной НС с ориентацией на data-driven-метод (рис. 3), который включает следующие этапы.

1. Подготовка обучающего и тестового входных наборов, представленных кортежами $[X_{trn}; Y_{trn}]$ и $[X_{tst}; Y_{tst}]$ соответственно, где $X_{trn} \subset X, X_{tst} \subset X, X_{trn} \cap X_{tst} = \emptyset, X$ – множество ЭКГ-сигналов, X_{trn} и X_{tst} – подмножества ЭКГ-сигналов, используемые для обучения и тестирования соответственно; $Y_{trn} \subset Y, Y_{tst} \subset Y, Y$ – множество идентификаторов заболеваний сердечно-сосудистой системы, выявленных по сигналам из X .

2. Инициализация параметров синтеза и ограничений: ε – устанавливаемый относительный порог точности обучения НС; N_{Str_max} и N_{Par_max} – максимальное количество итераций при структурном и параметрическом синтезе НС соответственно; N_{trn_max} – максимальное количество циклов обучения каждого экземпляра НС; $N_{Str} = 0$ и $N_{Par} = 0$ – фактическое количество попыток структурного и параметрического синтеза соответственно.

3. Структурный синтез НА, в ходе которого определены количество сверточных слоев (N_{CL}) и тип используемых слоев объединения.

4. Параметрический синтез НА, в ходе которого назначены количество используемых фильтров (FN_i) и их размерность (FS_i) для каждого i -го сверточного слоя, размер окна объединения (PS_i) и величина шага перемещения окна (S_i) для каждого i -го слоя объединения.

5. Обучение НС входным набором $[X_{trn}; Y_{trn}]$, пока $Acc > \varepsilon$ и $t < N_{trn_max}$, где Acc – оцененная относительная точность обучения на те-

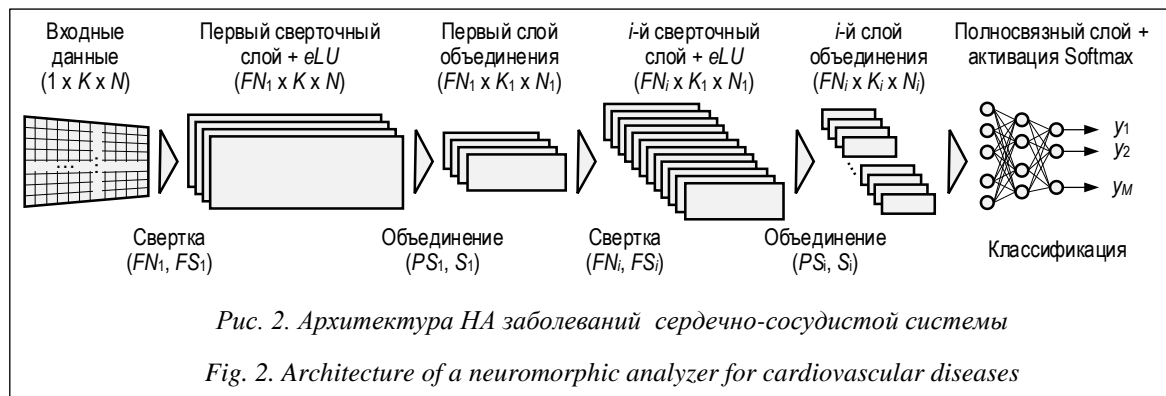


Рис. 2. Архитектура НА заболеваний сердечно-сосудистой системы

Fig. 2. Architecture of a neuromorphic analyzer for cardiovascular diseases

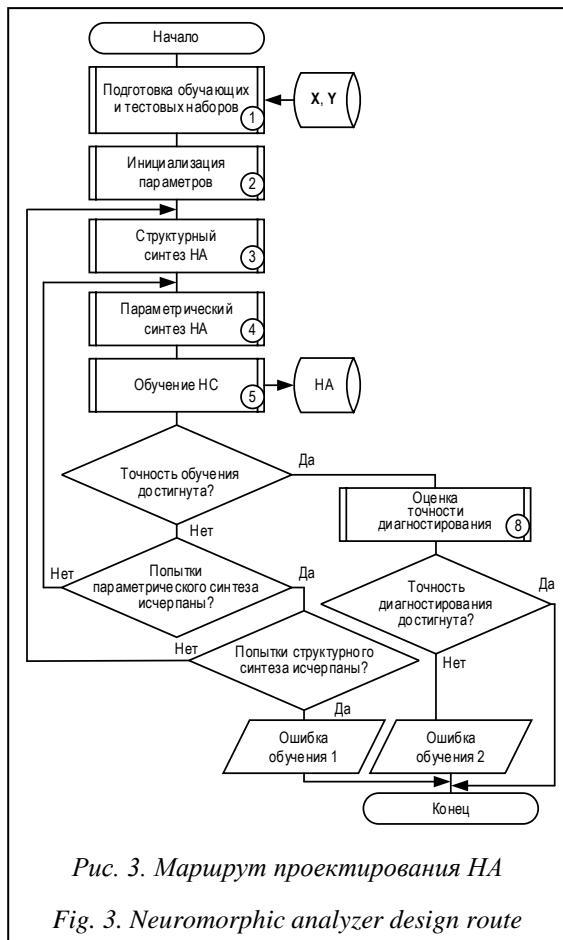


Рис. 3. Маршрут проектирования НА

Fig. 3. Neuromorphic analyzer design route

кушем шаге t . Математически процесс обучения сведен к решению оптимизационной задачи, в ходе которой выбирают параметры сети. В работе использован мини-пакетный адаптивный алгоритм оптимизации Adam, который применяет экспоненциальную скользящую среднюю первого и второго моментов градиента функции потерь и следующее правило обновления:

$$\begin{aligned}
 g_t &= \nabla_{\Theta} J(\Theta), m_t = \beta_1 m_{t-1} + (1 - \beta_1)g_t, v_t = \\
 &= \beta_2 v_{t-1} + (1 - \beta_2)g_t^2, \\
 m_{-t} &= m_t / (1 - \beta_{t1}), v_{-t} = v_t / (1 - \beta_{t2}), \\
 \Theta_{t+1} &= \Theta_t - \alpha m_{-t} / \text{sqrt}(v_{-t} + \sigma),
 \end{aligned}
 \tag{3}$$

где $J(\Theta)$ – функция потерь (целевая функция); Θ – параметры сети; α – скорость обучения; g_t – градиент; m_t и v_t – первый и второй моменты градиента соответственно; σ – сглаживающий параметр (исключает деление на 0).

Мини-пакетный вариант реализации адаптивной оптимизации предполагает использование для расчета небольших пакетов обучающих данных размером N_B , полученных при разбиении исходного набора $[X_{tm}; Y_{tm}]$. Алгоритм – мини-пакетная адаптивная оптимизация нейронной сети:

Инициализация:

1: $\Theta_0; N_B; \varepsilon \leftarrow 0.001; t \leftarrow 0; \sigma \leftarrow 10^{(-8)}$

2: $\alpha \leftarrow 0.001; \beta_1 \leftarrow 0.9; \beta_2 \leftarrow 0.999$

3: $m_0 \leftarrow 0; v_0 \leftarrow 0$

4: **repeat**

5: $t \leftarrow t + 1$

6: сформировать мини-пакет $\{(x^{(n)_{ki}}, y^{(n)})\}$, $n = 1..N_B$

7: $g_t \leftarrow \sum_n (\nabla_{\Theta} J(\{(x^{(n)_{ki}}, y^{(n)})\}, \Theta_{t-1}))$

8: $m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t$

9: $v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2$

10: $m_{-t} = m_t / (1 - \beta_{t1})$ // коррекция m_t при $t = (1, 10)$

11: $v_{-t} = v_t / (1 - \beta_{t2})$ // коррекция v_t при $t = (1, 1000)$

12: $\Theta_t = \Theta_{t-1} - \alpha m_{-t} / \text{sqrt}(v_{-t} + \sigma)$

13: $Acc = \Delta \Theta_t$

14: **until** and($Acc > \varepsilon, t < N_{tm_max}$)

return Θ_t

6. Если $Acc > \varepsilon, t = N_{tm_max}$ и $N_{Par} < N_{Par_max}$, то $N_{Par} = N_{Par} + 1$ и необходимо перейти к шагу 4, выбрав новые значения для параметров FN_i, FS_i, PS_i и $S_i, i = 1, \dots, N_{CL}$.

7. Если $Acc > \varepsilon$, и $t = N_{tm_max}$, и $N_{Par} = N_{Par_max}$, и $N_{Str} < N_{Str_max}$, то $N_{Par} = 0, N_{Str} = N_{Str} + 1$ и необходимо перейти к шагу 3, изменив количество сверточных слоев (N_{CL}) и/или тип используемых слоев объединения. В противном случае формируется уведомление об ошибке обучения 1 – «Невозможность обеспечить заданную точность обучения».

8. Если $Acc \leq \varepsilon$, то проводится оценка относительной точности диагностики заболеваний сердечно-сосудистой системы обученной НС на тестовых входных наборах $[X_{tst}; Y_{tst}]$. Если точность диагностирования соответствует ожидаемой, то синтезированный НА можно использовать для диагностики заболеваний сердечно-сосудистой системы. Иначе формируется уведомление об ошибке обучения 2 – «Невозможность обеспечить заданную точность диагностирования (на используемых обучающих наборах $[X_{tm}; Y_{tm}]$)».

Практическая часть

Экспериментальные исследования предложенной архитектуры и маршрута проектирования НА заболеваний сердечно-сосудистой системы выполнены в пакете математических и инженерных расчетов MATLAB на компьютере с процессором Intel(R) Core(TM) i5-7500 3.40 GHz (x64), ОЗУ 32 Гб. В ходе исследования использованы наборы ЭКГ-сигналов РТВ-

XL [15] с известными медицинскими заключениями, которые включают 9 514 образцов, соответствующих норме (*NORM*), и 5 420 образцов, соответствующих инфаркту миокарда (*MI*), которые представлены 12-канальными ЭКГ (I, II, III, *AVL*, *AVR*, *AVF*, V1, ..., V6) длительностью 10 секунд (<http://www.swsys.ru/uploaded/image/2024-1/1.jpg>). Входные коэффициенты для каждого канала – временной ряд длиной 1 000 отсчетов с 16-разрядной точностью. Соответственно, множество идентификаторов заболеваний сердечно-сосудистой системы образовано двумя видами ее состояний – $Y = \{NORM, MI\}$. Из исходного множества образцов X выделены подмножества ЭКГ-сигналов для формирования обучающих и тестовых наборов:

$$\begin{aligned} & \|X_{trn_NORM}\| = 8\,551, \|X_{tst_NORM}\| = 963, \\ & \|X_{trn_MI}\| = 4\,876, \|X_{tst_MI}\| = 544, \\ & X_{trn_NORM} \cup X_{trn_MI} = X_{trn}, \\ & X_{tst_NORM} \cup X_{tst_MI} = X_{tst}, X_{trn} \cap X_{tst} = \emptyset. \end{aligned}$$

Выполнен структурный и параметрический синтез НА в соответствии с предложенной архитектурой. Количественные характеристики обучения НС и ее последующего тестирования представлены в таблице 1.

Анализ результатов показывает, что НС с двумя сверточными слоями обладает низкой точностью обучения и высокими ошибками диагностирования. При увеличении числа сверточных слоев точность обучения возрастает до 99,99 %, а ошибки диагностирования снижаются. Важно отметить, что трехслойная НС способствует росту ошибок I рода, а четырехслойная – ошибок II рода.

Образцы ЭКГ-сигналов с отображением в одной координатной плоскости, диагностированных корректно и с ошибками I и II рода при использовании четырехслойной НС, приведены на рисунке 4.

Использование трехслойной сверточной НС с окном объединения меньшего размера позво-

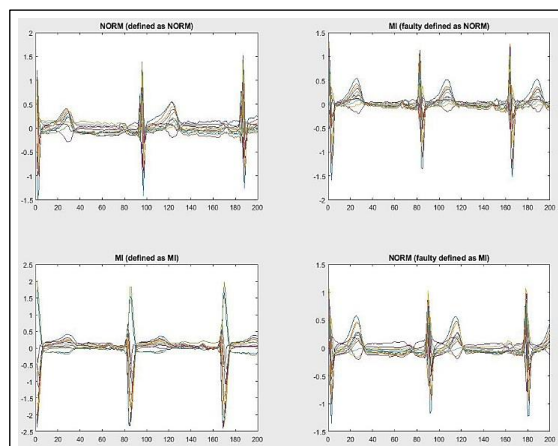


Рис. 4. ЭКГ-сигналы (200 отсчетов) с признаками, диагностированными НА с четырьмя сверточными слоями

Fig. 4. ECG signals (200 samples) with features diagnosed by a neuromorphic analyzer with four convolutional layers

ляет диагностировать до 85,66 % случаев инфаркта миокарда, что количественно выражается в увеличении на 17 случаев, для которых НА корректно диагностировал инфаркт миокарда, – лучше на 3,65 % по сравнению с четырехслойной архитектурой. Для медицинской практики важно обеспечить максимальное выявление заболеваний сердечно-сосудистой системы (снижение ошибок II рода), что приводит к дополнительному анализу ЭКГ несколькими профильными специалистами и выработке экспертного заключения по нозологии. Ранняя качественная диагностика заболеваний сердечно-сосудистой системы и оперативно назначенное лечение снижают риск летального исхода пациента. Таблица 2 дает возможность сравнить результаты диагностирования инфаркта миокарда, полученные в данном исследовании и другими авторами с применением иных методов на основе искусственных НС.

Таблица 1

Результаты экспериментальных исследований

Table 1

Experimental results

Показатель	Количество слоев					
	2		3		4	
Размер фильтра, размер окна	3, 3	3, 4	3, 3	3, 4	3, 3	3, 4
Точность обучения, %	97,82	97,54	98,45	99,43	99,95	99,99
Точность тестирования, %	88,92	90,05	89,85	89,85	90,38	90,84
Матрица ошибок, %	93,77 6,23 19,67 80,33	95,12 4,88 18,93 81,07	92,21 7,79 14,34 85,66	92,63 7,37 15,07 84,93	95,02 4,98 17,83 82,17	95,02 4,98 16,54 83,46

Таблица 2

Результаты сравнительного анализа

Table 2

Results of comparative analysis

Тип метода	Model-driven			Data-driven	
Источник	[6]	[7]	[8]	[14]	Предложенное решение
Точность диагностирования, %	79,0	77,5	84,02	до 78,0	85,66

Из таблицы 2 видно, что предложенное решение, основанное на data-driven-методе без явного выделения характерных параметров ЭКГ-сигналов, обеспечивает наибольшую точность диагностирования инфаркта миокарда среди рассмотренных вариантов (от 1,64 % до 8,16 %), в основе которых лежат model-driven-методы.

Заключение

Предложен подход к автоматизации построения нейроморфного анализатора, обеспечивающего выявление заболеваний сердечно-сосудистой системы с использованием одномерной многослойной сверточной НС и выполняющего непосредственный анализ ЭКГ-сигналов

без предварительного выделения характерных признаков. Разработана настраиваемая архитектура НА ЭКГ-сигналов, обеспечивающая диагностику заболеваний на основе data-driven-метода. Предложен и апробирован маршрут проектирования НА заболеваний сердечно-сосудистой системы. Результаты экспериментальных исследований показали точность диагностики инфаркта миокарда до 85,66 %, что выше полученной с использованием model-driven-методов. Дальнейшие исследования планируется направить на поиск методов повышения точности диагностирования за счет снижения размерности входных ЭКГ-сигналов, а также введения вероятностной оценки принадлежности рассматриваемого сигнала одному из возможных состояний двойственной группы.

Список литературы

1. Лобанов М.Г., Шоломов Д.Л. Об ускорении архитектуры сверточной нейронной сети на базе ResNet в задаче распознавания объектов дорожной сцены // Информационные технологии и вычислительные системы. 2019. № 3. С. 57–65. doi: 10.14357/20718632190305.
2. Kayumov Z., Tumakov D., Mosin S. Combined convolutional and perceptron neural networks for handwritten digits recognition. Proc. Int. Conf. DSPA, 2020, pp. 1–5. doi: 10.1109/DSPA48919.2020.9213301.
3. Mosin S. Machine learning and data mining methods in testing and diagnostics of analog and mixed-signal integrated circuits: Case study. In: CCIS. Proc. SIRS, 2019, vol. 968, pp. 240–255. doi: 10.1007/978-981-13-5758-9_21.
4. Гусев А.В., Гаврилов Д.В., Корсаков И.Н., Серова Л.М., Новицкий Р.Э., Кузнецова Т.Ю. Перспективы использования методов машинного обучения для предсказания сердечно-сосудистых заболеваний // Врач и информационные технологии. 2019. № 3. С. 41–47.
5. Мишкин И.А., Сахаров А.А. Изучение использования алгоритмов машинного обучения в оценке риска развития сердечно-сосудистых заболеваний // Инновации. Наука. Образование. 2020. № 17. С. 187–202.
6. Мустафаев А.Г. Использование нейросетевых методов для автоматического анализа электрокардиограмм при диагностике заболеваний сердечно-сосудистой системы // Кибернетика и программирование. 2019. № 1. С. 66–74. doi: 10.25136/2306-4196.2019.1.19343.
7. Пирова Д.Ф., Забержинский Б.Э., Машков А.В. Обнаружение признаков болезни сердца с использованием методов машинного обучения // ИТНТ: сб. тр. по мат. VI Междунар. конф. 2020. Т. 4. С. 736–740.
8. Катков П.И., Храмов А.Г. Исследование возможности использования искусственных нейронных сетей для диагностики инфаркта миокарда по электрокардиограмме // ИТНТ: сб. тр. по мат. VI Междунар. конф. 2019. Т. 4. С. 893–898.
9. Goovaerts G., Padhy S., Vandenberk B., Varon C. et al. A machine-learning approach for detection and quantification of QRS fragmentation. J-BHI, 2019, vol. 23, no. 5, pp. 1980–1989. doi: 10.1109/JBHI.2018.2878492.
10. Moskalenko V.A., Nikolskiy A.V., Zolotykh N.Yu., Kozlov A.A., Kosonogov K.A. et al. Cyberheart-diagnostics software package for automated electrocardiogram analysis based on machine learning techniques. Modern Technologies in Medicine, 2019, vol. 11, no. 2, pp. 86–91. doi: 10.17691/stm2019.11.2.12.
11. Бобков А.В., Аунг Х. Идентификация человека по видеоизображению в реальном времени на основе сетей YOLOv2 и VGG 16 // Автоматика и телемеханика. 2022. № 10. С. 94–104. doi: 10.31857/S0005231022100099.
12. Катермина Т.С., Сибатулин А.Ф. Применение методов искусственного интеллекта к задаче диагностики заболеваний дыхательных путей // Computational Nanotechnology. 2022. Т. 9. № 2. С. 92–103. doi: 10.33693/2313-223X-2022-9-2-92-103.

13. Сорокина В.В., Абламейко С.В. Выделение отдельных участков тела человека на изображении с использованием нейронных сетей и модели внимания // Журнал БГУ. Математика. Информатика. 2022. № 2. С. 94–106. doi: 10.33581/2520-6508-2022-2-94-106.

14. Gumpfer N., Grün D., Hannig J., Keller T., Guckert M. Detecting myocardial scar using electrocardiogram data and deep neural networks. *Biological Chemistry*, 2021, vol. 402, no. 8, pp. 911–923. doi: 10.1515/hsz-2020-0169.

15. Wagner P., Strodtzoff N., Bousseljot R., Samek W., Schaeffter T. PTB-XL, a large publicly available electrocardiography dataset (version 1.0.3). *PhysioNet*, 2022. URL: <https://physionet.org/content/ptb-xl/1.0.3/> (дата обращения: 02.09.2023).

Software & Systems

doi: 10.15827/0236-235X.142.122-130

2024, 37(1), pp. 122–130

Neural network diagnosis of the cardiovascular diseases based on data-driven method

Sergey G. Mosin ^{1,2} ✉

¹ Institute of Computational Mathematics and Information Technologies,
Kazan (Volga Region) Federal University,
Kazan, 420008, Russian Federation

² LabSystems LLC, Vladimir, 600000, Russian Federation

For citation

Mosin, S.G. (2024) 'Neural network diagnosis of the cardiovascular diseases based on data-driven method', *Software & Systems*, 37(1), pp. 122–130 (in Russ.). doi: 10.15827/0236-235X.142.122-130

Article info

Received: 21.07.2023

After revision: 02.10.2023

Accepted: 27.10.2023

Abstract. The paper considers methods for diagnosing cardiovascular diseases by electrocardiogram (ECG) tracing using artificial intelligence methods. It also determines the problems of diagnosing cardiovascular diseases by model-driven methods. The author proposes an approach to diagnosing cardiovascular diseases by a data-driven machine learning method without extracting the characteristic parameters of ECG signals. There is a presented architecture of a neuromorphic ECG signal analyzer based on a one-dimensional convolutional neural network, as well as its design route. Experimental studies were carried out on a set of ECG signals PTB-XL; they confirmed the operability and efficiency of the proposed approach. Both structural and parametric synthesis of a neuromorphic analyzer was performed for a different number of internal layers and initial training parameters. A comparative analysis of the obtained results found that a neural network with two convolutional layers has low training accuracy and high diagnosis errors; a three-layer neural network contributes to the growth of type I error; a four-layer neural network contributes to the growth of type II error. The use of a three-layer convolutional neural network with a smaller pooling window provided the diagnosis of up to 85.66 % of myocardial infarction cases. In conclusion, the author gives the directions for further research to improve the diagnosis accuracy by reducing an input ECG signal dimension, as well as introducing a probabilistic assessment of whether the considered signal belongs to one of the possible states of an ambiguity group.

Keywords: neuromorphic analyzer (NA), ECG signals, diagnostics of cardiovascular diseases, NA architecture, NA design route, data-driven method

Acknowledgements. This paper has been supported by the Kazan Federal University Strategic Academic Leadership Program ("PRIORITY-2030")

References

1. Lobanov, M.G., Sholomov, D.L. (2019) 'On the acceleration of the convolutional neural network architecture based on resnet in the task of road scene objects recognition', *JITCS*, (3), pp. 57–65 (in Russ.). doi: 10.14357/20718632190305.
2. Kayumov, Z., Tumakov, D., Mosin, S. (2020) 'Combined convolutional and perceptron neural networks for handwritten digits recognition', *Proc. Int. Conf. DSPA*, pp. 1–5. doi: 10.1109/DSPA48919.2020.9213301.
3. Mosin, S. (2019) 'Machine learning and data mining methods in testing and diagnostics of analog and mixed-signal integrated circuits: Case study', in *CCIS. Proc. SIRS*, 968, pp. 240–255. doi: 10.1007/978-981-13-5758-9_21.
4. Gusev, A.V., Gavrilov, D.V., Korsakov, I.N., Serova, L.M., Novitsky, R.E., Kuznetsova, T.Yu. (2019) 'Prospects for the use of machine learning methods for predicting cardiovascular disease', *Medical Doctor and Inform. Tech.*, (3), pp. 41–47 (in Russ.).
5. Mishkin, I.A., Sakharov, A.A. (2020) 'Studying the use of machine learning algorithms in assessing the risk of developing cardiovascular diseases', *Innovation. Sci. Education*, (17), pp. 187–202 (in Russ.).

6. Mustafaev, A.G. (2019) 'Neural network techniques for automatic electrocardiogram analysis in the diagnosis of diseases of the cardiovascular system', *Cybernetics and Programming*, (1), pp. 66–74 (in Russ.). doi: 10.25136/2306-4196.2019.1.19343.
7. Pirova, D.F., Zaberzhinskiy, B.E., Mashkov, A.V. (2020) 'Detecting heart disease symptoms using machine learning', *Proc. ITNT*, 4, pp. 736–740 (in Russ.).
8. Katkov, P.I., Khramov, A.G. (2019) 'The study of the possibility of using artificial neural networks for the diagnosis of myocardial infarction by electrocardiogram', *Proc. ITNT*, 4, pp. 893–898 (in Russ.).
9. Goovaerts, G., Padhy, S., Vandenberg, B., Varon, C. et al. (2019) 'A machine-learning approach for detection and quantification of QRS fragmentation', *J-BHI*, 23(5), pp. 1980–1989. doi: 10.1109/JBHI.2018.2878492.
10. Moskalenko, V.A., Nikolskiy, A.V., Zolotykh, N.Yu., Kozlov, A.A., Kosonogov, K.A. et al. (2019) 'Cyberheart-diagnostics software package for automated electrocardiogram analysis based on machine learning techniques', *Modern Technologies in Medicine*, 11(2), pp. 86–91. doi: 10.17691/stm2019.11.2.12.
11. Bobkov, A.V., Aung, H. (2022) 'Identification of a person from a video image in real time based on the YOLOv2 and VGG-16 networks', *Automation and Remote Control*, (10), pp. 1567–1575 (in Russ.). doi: 10.31857/S0005231022100099.
12. Katermina, T.S., Sibagatulin, A.F. (2022) 'Application of artificial intelligence methods to the task of diagnosing respiratory diseases', *Computational Nanotechnology*, 9(2), pp. 92–103 (in Russ.). doi: 10.33693/2313-223X-2022-9-2-92-103.
13. Sorokina, V.V., Ablameyko, S.V. (2022) 'Detection of human body parts on the image using the neural networks and the attention model', *J. of the BSU. Math. and Inform.*, (2), pp. 94–106 (in Russ.). doi: 10.33581/2520-6508-2022-2-94-106.
14. Gumpfer, N., Grün, D., Hannig, J., Keller, T., Guckert, M. (2021) 'Detecting myocardial scar using electrocardiogram data and deep neural networks', *Biological Chemistry*, 402(8), pp. 911–923. doi: 10.1515/hsz-2020-0169.
15. Wagner, P., Strodthoff, N., Bousseljot, R., Samek, W., Schaeffter, T. (2022) 'PTB-XL, a large publicly available electrocardiography dataset (version 1.0.3)', *PhysioNet*, available at: <https://physionet.org/content/ptb-xl/1.0.3/> (accessed September 02, 2023).

Авторы

Мосин Сергей Геннадьевич^{1,2},
д.т.н., доцент, smosin@ieee.org

¹ Институт вычислительной математики
и информационных технологий,
КФУ, г. Казань,
420008, Россия

² «ЛабСистемс»,
г. Владимир, 600000, Россия

Authors

Sergey G. Mosin^{1,2}, Dr.Sc. (Engineering),
Associate Professor, smosin@ieee.org

¹ Institute of Computational Mathematics
and Information Technologies,
Kazan (Volga Region) Federal University,
Kazan, 420008, Russian Federation

² LabSystems LLC,
Vladimir, 600000, Russian Federation