

УДК 615.032; 616-085; 616-092.11  
DOI 10.24412/2312-2935-2023-3-515-531

## ДИАГНОСТИКА ДЕКОМПЕНСАЦИИ ХРОНИЧЕСКОЙ СЕРДЕЧНОЙ НЕДОСТАТОЧНОСТИ ПРИ ПЕРВИЧНОМ ОБСЛЕДОВАНИИ У ЛИЦ СТАРШИХ ВОЗРАСТНЫХ ГРУПП НА ОСНОВЕ ГЕМАТОЛОГИЧЕСКИХ ПОКАЗАТЕЛЕЙ С ПРИМЕНЕНИЕМ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ

А.А. Яковлев<sup>1,2,3</sup>, Г.А. Рыжак<sup>1</sup>, Д.Я. Шулькин<sup>5</sup>, А.С. Пушкин<sup>1,2,4</sup>

<sup>1</sup> АННО ВО НИЦ «Санкт-Петербургский институт биорегуляции и геронтологии», г. Санкт-Петербург

<sup>2</sup> СПб ГБУЗ «Городская многопрофильная больница № 2», г. Санкт-Петербург

<sup>3</sup> ФГБОУ ВО «Санкт-Петербургский государственный университет», г. Санкт-Петербург

<sup>4</sup> ГБОУ ВПО «Первый Санкт-Петербургский медицинский университет им. И.П. Павлова» Министерства здравоохранения Российской Федерации, г. Санкт-Петербург

<sup>5</sup> RobotDreams® GmbH, 8010, Австрия, г. Грац

**Актуальность.** Декомпенсация хронической сердечной недостаточности (ХСН) является одной из самых распространённых причин госпитализации пациентов старших возрастных групп. Нередко данный диагноз на догоспитальном этапе устанавливается необоснованно и в последующем отвергается на разных этапах госпитализации пациента. Для первичной диагностики декомпенсации хронической сердечной недостаточности на догоспитальном этапе или в приёмном отделении необходимо иметь скрининговый тест, позволяющий быстро определиться в отношении наличия декомпенсации заболевания. Общеклинический анализ крови, является одним из наиболее доступных методов лабораторной диагностики в реальной клинической практике. Учитывая рост количества данных, получаемых врачами при обследовании пациента, что приводит к повышению нагрузки на медицинских работников на всех этапах оказания помощи, появляется необходимость использования различных методов машинного обучения для увеличения эффективности обработки и интерпретации предоставляемой диагностической информации.

**Цель исследования.** Улучшение качества диагностики декомпенсации хронической сердечной недостаточности при первичном обследовании у лиц старших возрастных групп на основе гематологических показателей с применением алгоритмов машинного обучения.

**Материалы и методы.** Проведено проспективное пилотное исследование. Всего обследовано 101 человек (34 мужчины, 67 женщин). Средний возраст пациентов составил 74 (72;76) года. Критериями включения были возраст старше 18 лет, предварительный диагноз «I50.0 – Застойная сердечная недостаточность». Всем пациентам в рамках рутинного обследования при госпитализации производилось исследование общеклинического анализа крови на автоматическом гематологическом 5-diff анализаторе.

**Результаты исследования.** В результате применения метода глубокого обучения удалось достичь площади под ROC-кривой=0,8077 на тестовой выборке при оценке качества диагностики декомпенсации ХСН у пациентов разных возрастных групп. Достигнутое качество первичной диагностики можно считать приемлемым и перспективным для дальнейшего накопления базы данных с целью дополнительного обучения разработанного алгоритма и повышения характеристик точности диагностики декомпенсации хронической сердечной недостаточности.

**Заключение.** Достигнутое качество первичной диагностики можно считать приемлемым и перспективным для дальнейшего накопления базы данных с целью дополнительного обучения разработанного алгоритма и повышения характеристик точности диагностики декомпенсации хронической сердечной недостаточности.

**Ключевые слова:** хроническая сердечная недостаточность, машинное обучение, гематология, пожилой и старческий возраст, гериатрия

## DIAGNOSIS OF DECOMPENSATION OF CHRONIC HEART FAILURE DURING PRIMARY EXAMINATION IN DIFFERENT AGE GROUPS BASED ON HEMATOLOGICAL PARAMETERS USING MACHINE LEARNING ALGORITHMS

*A.A. Yakovlev<sup>1,2,3</sup> G.A. Ryzhak<sup>1</sup> D. Shulkin<sup>4</sup> A.S. Pushkin<sup>1,2,4</sup>*

<sup>1</sup> Saint Petersburg Institute of Bioregulation and Gerontology, St. Petersburg

<sup>2</sup> St. Petersburg State Institution of Healthcare "City Multifield Hospital №2", St. Petersburg

<sup>3</sup> St.-Petersburg State University, St. Petersburg

<sup>4</sup> I. P. Pavlov First State Medical University of St. Petersburg, St. Petersburg

<sup>5</sup> RobotDreams® GmbH, Austria, Graz

**Background.** Decompensation of chronic heart failure (CHF) is one of the most common reasons for hospitalization of older patients. Often this diagnosis at the pre-hospital stage is established unreasonably and subsequently rejected at different stages of patient hospitalization. For primary diagnosis of decompensation of chronic heart failure at the pre-hospital stage or in the emergency room it is necessary to have a screening test that allows to quickly determine the presence of decompensation of the disease. General clinical blood analysis, is one of the most accessible methods of laboratory diagnostics in real clinical practice. Taking into account the growing amount of data received by doctors during patient examination, which leads to an increased workload on medical workers at all stages of care, there is a need to use various machine learning methods to increase the efficiency of processing and interpretation of the provided diagnostic information.

**Purpose of the study.** The aim of the study is to improve the quality of diagnostics of chronic heart failure decompensation during primary examination in elderly patients on the basis of hematologic indices using machine learning algorithms.

**Method.** A prospective pilot study was conducted. A total of 101 patients (34 men, 67 women) were examined. The mean age of the patients was 74 (72;76) years. Inclusion criteria were age over 18 years, preliminary diagnosis "I50.0 - Congestive Heart Failure". All patients underwent a routine examination during hospitalization for a general clinical blood test on an automatic hematological 5-diff analyzer.

**Results.** As a result of application of deep learning method it was possible to reach the area under ROC-curve=0,8077 on the test sample when assessing the quality of diagnosis of decompensation of CHF in patients of different age groups. The achieved quality of primary diagnosis can be considered acceptable and promising for further accumulation of the database with the purpose of additional training of the developed algorithm and increasing the accuracy characteristics of diagnosis of chronic heart failure decompensation.

**Conclusion.** The achieved quality of primary diagnosis can be considered acceptable and promising for further accumulation of the database with the purpose of additional training of the developed

algorithm and increasing the accuracy characteristics of diagnosis of chronic heart failure decompensation.

**Key words:** chronic heart failure, machine learning; hematology, elderly and senile, geriatrics

Пациенты, страдающие хронической сердечной недостаточностью (ХСН), которые преимущественно относятся к лицам пожилого и старческого возраста, периодически госпитализируются в стационар в связи с декомпенсацией, что может происходить по разным причинам, таким как, развитие резистентности к мочегонной терапии, возникновение острых инфекционных и неинфекционных заболеваний, эпизоды тромбоэмболии ветвей лёгочной артерии, необоснованная отмена препаратов, присоединение анемии [2]. Однако, необходимо отметить, что, нередко диагноз декомпенсации ХСН на догоспитальном этапе устанавливается необоснованно и в последующем отвергается на разных этапах госпитализации пациента [9]. Существуют особые группы пациентов, диагностика заболеваний у которых может быть затруднительна – это дети, пациенты, злоупотребляющие алкоголем, наркотическими и психотропными препаратами, имеющие интеллектуально-мнестические расстройства и пациенты старших возрастных групп. Диагностика декомпенсации ХСН у таких пациентов затруднительна. При первичном контакте в специализированном стационаре больные, поступающие с диагнозом по МКБ-10 «I50.0 – Застойная сердечная недостаточность», подвергаются комплексному обследованию, включающему опрос, осмотр, электрокардиографическое исследование, рентгенологическое исследование, лабораторный мониторинг. Наряду с пациентами, имеющими типичную картину декомпенсации ХСН, части пациентов требуется проведение дифференциального диагноза с другой патологией. Так, например, пациент с одышкой, может иметь декомпенсацию лёгочной патологии, анемию, интоксикационный синдром и т.д. [14]. Задачей врача приёмного покоя стационара является правильная сортировка пациентов, для направления в профильные отделения, где больному будет оказана качественная помощь наиболее квалифицированными специалистами. В современных клинических рекомендациях, предлагается оценивать натрийуретические пептиды для проведения первичной дифференциальной диагностики одышки [6]. Однако, этот анализ достаточно дорог, не всегда доступен и имеет широкий «серый» диагностический интервал, когда ни отвергнуть, ни подтвердить диагноз однозначно невозможно, особенно это справедливо для больных старших возрастных групп. Поэтому для первичной диагностики ХСН на догоспитальном этапе или в приёмном отделении необходимо иметь скрининговый тест, позволяющий быстро сориентироваться в отношении того, действительно ли имеет место

декомпенсация ХСН или пациент на самом деле имеет другую патологию, симулирующую декомпенсацию хронической сердечной недостаточности.

В течение последних десятилетий мы наблюдаем рост значимости визуализирующих методов диагностики, таких как, например, компьютерная томография, магнитно-резонансная томография, позитронная эмиссионная томография, маммография, ультразвуковое исследование, рентген для раннего обнаружения, динамического наблюдения и лечения заболеваний [3]. Традиционно интерпретацию данных, полученных при проведении вышеупомянутых исследований проводят специалисты с профильным медицинским образованием. Широкий спектр патологии, требующей тщательной оценки, высокая нагрузка на специалистов интерпретирующих данные исследований, обуславливает необходимость поиска инструментов, которые могли бы ускорить и облегчить работу с большими массивами сложных медицинских данных.

С появлением глубокого обучения (deep learning) [16] эта проблема стала менее актуальной, так как данная технология интегрировала этап инжиниринга признаков в обучающий процесс. Глубокое обучение позволяет извлекать информативные представления данных автономно, без активного участия человека, используя только набор данных с минимальной предварительной обработкой [10].

Успех глубокого обучения обусловлен несколькими факторами: [3], во-первых, развитием высокотехнологичных центральных процессоров (ЦП) и графических процессоров (ГП); во-вторых, обеспечением доступности большого объема данных (Big Data); в-третьих, активной разработкой и внедрением обучающих алгоритмов [5, 7, 17].

Одним из ценных источников информации о пациенте для лечащего врача по-прежнему остаётся клинический анализ крови. Инструментом для визуализации свойств клеток крови, измеренных гематологическим анализатором, является диаграмма рассеяния. Диаграмма рассеяния (скатерограмма от scatter англ.) – это графическое представление точек данных, расположенных на двумерной плоскости. Каждая точка на графике представляет одну клетку, а две оси характеризуют различные параметры, измеренные анализатором. Большинство гематологических анализаторов выдают как минимум два основных графика рассеяния: один для эритроцитов (RBC) и тромбоцитов (PLT) и один для лейкоцитов (WBC). Диаграмма рассеяния RBC и PLT показывает размер и распределение эритроцитов и тромбоцитов, а диаграмма рассеяния WBC показывает размер и распределение различных субпопуляций лейкоцитов. Эти изображения позволяют сотрудникам клинических

лабораторий идентифицировать или заподозрить различные заболевания, которые имеют характерные особенности распределения клеток на графиках [13]. Так в исследовании Campuzano-Zuluaga G. и соавт. использовали диаграммы рассеяния, созданные гематологическим анализатором Sysmex XE-2100, чтобы отличить образцы крови пациентов с малярией от образцов крови без малярии [4]. В ходе исследования авторы проанализировали диаграммы рассеяния и выявили специфические закономерности, которые встречались только у пациентов, инфицированных малярией. На основе этих закономерностей были разработаны диагностические критерии для выявления малярийной инфекции. В исследовании Пушкина А.С. и Шулькина Д.Я. [1] использовался метод диагностики острого коронарного синдрома (ОКС) на основе измеренных характеристик лейкоцитов. Авторами были созданы диаграммы рассеяния размера и сложности клеток, которые измерялись гематологическим анализатором Abbott Cell-Dyn Sapphire. В данной работе была достигнута чувствительность 0,97 и специфичность 0,94.

В исследовании [1] анализируется возможность применение метода, описанного в вышеупомянутом патенте [1], для классификации инфаркта миокарда и нестабильной стенокардии у пациентов с острым коронарным синдромом (ОКС). Результаты показали чувствительность 0,77 и специфичность 0,80 ( $AUC-ROC = 0,77$ ) для верификации диагноза инфаркта миокарда и нестабильной стенокардии у пациентов с ОКС.

Вышеупомянутые исследования основаны преимущественно на ручных, статистических и математических методах. Однако, применение моделей глубокого обучения (Deep Learning), в частности сверточных нейронных сетей (CNN), имеет высокий потенциал для дальнейшего повышения чувствительности при анализе диаграмм рассеяния, используемых в диагностике и подтверждении различных заболеваний и состояний. В частности, применение CNN при анализе диаграмм рассеяния может помочь распознавать более сложные паттерны и взаимосвязи в данных, тем самым повышая чувствительность и специфичность используемых в реальной клинической практике методов диагностики.

В данной статье впервые будет представлено исследование применения сверточных нейронных сетей для анализа диаграмм рассеяния с целью диагностики хронической сердечной недостаточности при первичном обследовании у лиц старших возрастных групп.

**Материалы и методы.** Исследование проводилось на базе кардиологического отделения №3 СПб ГБУЗ «Городская многопрофильная больница №2». Всего в исследование был включен 101 человек (34 мужчины, 67 женщин) в возрасте от 25 до 93 лет, средний возраст

составил 74 (72;76) года, 95% из них относились к лицам старших возрастных групп. Критериями включения были возраст старше 18 лет, предварительный диагноз «I50.0 – Застойная сердечная недостаточность». Критериями исключения были сопутствующие онкологические заболевания и наследственные заболевания крови, возраст менее 18 лет, инфекционные заболевания на момент включения в исследование; психические заболевания или недееспособность; беременность, ранний послеродовой период, период лактации; отказ пациента от участия в данном исследовании.

Диагноз хроническая сердечная недостаточность устанавливался в соответствии с клиническими рекомендациями по диагностике и лечению пациентов с ХСН [12].

В соответствии с современными представлениями, для постановки диагноза ХСН необходимо наличие 4-х основных критериев:


- Характерные жалобы: одышка, ортопноэ, пароксизмальная ночная одышка, снижение толерантности к нагрузкам, слабость, утомляемость, увеличение времени восстановления после нагрузки, бендопнеа, ночной кашель, потеря веса, депрессия, сердцебиение.
- Подтверждающие жалобы клинические признаки (в сомнительных случаях реакции на мочегонную терапию), наиболее специфичными из которых являются: повышение центрального венозного давления в яремных венах, гепатоюгулярный рефлюкс, третий тон (ритм галопа), смещение верхушечного толчка влево.
- Доказательства наличия систолической (снижение фракции выброса левого желудочка) и/или диастолической дисфункции по данным эхокардиографии.
- Определение натрийуретических пептидов (для исключения диагноза ХСН).

В приёмном отделении при поступлении пациента с подозрением на декомпенсацию хронической сердечной недостаточности оценивались жалобы и клинические признаки, на основании которых предварительно подтверждался или отвергался диагноз декомпенсации хронической сердечной недостаточности, тогда как ЭХОКГ и определение натрийуретических пептидов проводилось позднее, чтобы сократить время пребывания пациента в приёмном отделении, сохраняя высокую пропускную способность. Необходимо также отметить, что всем пациентам в приёмном отделении была снята ЭКГ, выполнено рентгенологическое исследование органов грудной клетки, проводились общий клинический анализ крови, коагулограмма, биохимический анализ крови с оценкой содержания калия и натрия, общего белка, глюкозы, креатинина, мочевины, общего билирубина. АЛТ, АСТ.

Для принятия решения о декомпенсации ХСН и необходимости госпитализации пациентов определяли функциональный класс ХСН по NYHA (Нью-Йоркская ассоциация сердца).

Клинический анализ крови исследовали в приёмном отделении стационара в течение первых 20 минут после поступления пациента. Для анализа использовали венозную кровь, полученную из кубитальной вены с применением вакуумной системы взятия крови с антикоагулянтом КЗЭДТА. Анализ осуществлялся на автоматическом гематологическом 5-diff анализаторе Cell-Dyn Ruby (Abbott, США). С помощью данного оборудования оценивали размер клетки и ядерную лобулярность (дольчатость). Все извлеченные данные были сохранены в таблицах MS Excel.

Для обучения использовались скаттерограммы на основе каналов ALL 0° и IAS 10°. Это изображение позволяет оценить пять субпопуляций лейкоцитов. Разработанная нами модель глубокого обучения является сверточной нейронной сетью (Convolutional Neural Network, CNN), которая широко используется для обработки изображений. Модель была построена на основе последовательной модели Keras и включала в себя слои Conv2D, BatchNormalization, MaxPooling2D, Flatten, Dropout и Dense (рисунок 1).



**Рисунок 1.** Архитектура сверточной нейронной сети для анализа диаграмм рассеяния на основе каналов ALL 0° и IAS 10° в первичной диагностике сердечной недостаточности


С целью увеличения объёма обучающей выборки и предотвращения переобучения была использована техника аугментации данных. Эта техника подразумевает создание новых

образцов внесением случайных изменений в существующие изображения. В данной работе были использованы следующие методы аугментации: случайное отражение по вертикали и горизонтали, поворот на 90, 180 и 270 градусов, случайный поворот в диапазоне от -5 до 5 градусов, а также случайные смещения по вертикали и горизонтали. Переобучение (*overfitting*) – это одна из ключевых проблем в машинном обучении, которая происходит, когда алгоритм слишком точно подгоняется под тренировочные данные, в результате чего происходит потеря способности обобщать новые данные. Суть переобучения заключается в том, что модель, вместо того чтобы учиться на основе общих закономерностей, начинает "запоминать" конкретные случаи из тренировочного набора. В результате, хотя модель может показывать отличные результаты на тестовых выборках, она становится плохо применима к новым, ранее не встречавшимся ей данным, поскольку не способна корректно интерпретировать общие тенденции, что может привести к существенному ухудшению качества работы модели в реальных условиях.

В рамках исследований проводились кросс-валидации на трех наборах данных. Кросс-валидация — это метод оценки аналитического алгоритма и его поведения на независимом наборе данных. Она используется для проверки того, насколько хорошо алгоритм будет работать на новых данных, и оценки возможности обобщения модели.

**Результаты и обсуждение.** В первой части исследования обучающая выборка состояла из 118 образцов крови, включая 56 отрицательных случаев (пациенты без острой сердечно-сосудистой патологии) и 62 положительных (пациенты с ХСН). Тестовая выборка включала в себя 59 образцов крови, из которых 26 были отрицательными, а 33 – положительными. После применения алгоритма были получены следующие результаты: AUC-ROC составила 0,9604; чувствительность – 0,9091; специфичность – 0,9615 и точность – 0,9322. ROC-кривая является графиком, отображающим производительность бинарного классификатора при различных пороговых значениях (рисунок 2). Чувствительность – это способность модели подтвердить положительный результат, в то время как специфичность показывает способность модели правильно классифицировать отрицательный результат. Точность является долей правильно классифицированных случаев среди всех случаев.





**Рисунок 2.** ROC-кривая для первичной диагностики хронической сердечной недостаточности

Для повышения качества оценки метода исследования был двухкратно применён перекрёстный подход анализа выборки, при котором происходит перераспределение пациентов случайным образом внутри групп между обучающей и тестовой выборками. Средние показатели для трёх аналогичных исследований выглядят следующим образом:

Средняя AUC-ROC:  $(0,9889 + 0,9603 + 0,9553) / 3 = 0,9681$ .


Средняя чувствительность:  $(0,9459 + 0,9090 + 0,8400) / 3 = 0,8983$ .

Средняя специфичность:  $(0,9545 + 0,9615 + 0,8529) / 3 = 0,9230$ .

Средняя точность:  $(0,9491 + 0,9322 + 0,8474) / 3 = 0,9096$ .

Следующей частью нашего исследования были отдельно проанализированы данные пациентов с уже диагностированной хронической сердечной недостаточностью. Мы разделили этих пациентов на две группы: первую группу составили пациенты с функциональными классами по NYHA I и II во вторую группу вошли пациенты с классами III и IV.

Набор данных для обучения на первой выборке включал 63 пациента, из которых 27 были отнесены к первой группе, а 36 ко второй группе. Тестовый набор состоял из 32 пациентов, 9 из которых были отнесены к первой группе, а 23 ко второй группе. В результате проведения обучения и тестирования на этой выборке были получены следующие значения метрик: AUC-ROC составила 0,7584; чувствительность — 0,7826; специфичность – 0,7778; точность – 0,7812 (рисунок 3).



**Рисунок 3.** ROC-кривая первичной стратификации функционального класса ХСН по NYHA

Для повышения качества оценки метода исследования был аналогично первой части исследования был двукратно применён перекрёстный подход анализа выборки, при котором происходит перераспределение пациентов случайным образом внутри групп между обучающей и тестовой выборками. Средние показатели для трёх аналогичных исследований выглядят следующим образом:

$$\text{Средняя AUC-ROC: } (0,7584 + 0,8828 + 0,7818) / 3 = 0,8077.$$

$$\text{Средняя чувствительность: } (0,7826 + 0,6875 + 0,7000) / 3 = 0,7234.$$

$$\text{Средняя специфичность: } (0,7778 + 0,8125 + 0,7273) / 3 = 0,7725.$$

$$\text{Средняя точность: } (0,7812 + 0,75 + 0,7097) / 3 = 0,7470.$$

**Обсуждение.** В ходе данного исследования мы применяли методы глубокого обучения для обработки данных скаттерограмм с целью первичной диагностики и подтверждения стадии хронической сердечной недостаточности. Результаты эксперимента продемонстрировали высокую эффективность такого подхода.

В первом эксперименте, целью которого было предсказание наличия декомпенсации хронической сердечной недостаточности при первичном медицинском контакте в стационаре, алгоритм показал высокие AUC-ROC, чувствительность, специфичность и точность, с средними значениями 0,968, 0,8983, 0,9230 и 0,9096 соответственно. Эти результаты свидетельствуют о том, что модель глубокого обучения способна эффективно выявлять признаки сердечной недостаточности, что потенциально может облегчить процесс диагностики в реальной клинической практике.

Во второй части исследования, где задачей была верификация функциональных классов ХСН по NYHA, алгоритм также продемонстрировал умеренно высокие значения метрик. Средние значения AUC-ROC, чувствительности, специфичности и точности составили 0,8077; 0,7234; 0,7725 и 0,7470 соответственно. Несмотря на то, что эти показатели ниже, чем в первой части, они указывают на потенциальную способность модели хорошо дифференцировать разные стадии сердечной недостаточности, что является дополнительным критерием для госпитализации пациента в профильное лечебное учреждение.

Стоит отметить, что использование методов машинного обучения в реальной клинической практике является перспективным и может значительно повысить эффективность диагностики и лечения заболеваний. Тем не менее, внедрение методик, основанных на использовании таких моделей, требует тщательной проверки и валидации на независимых выборках, чтобы убедиться в их обобщающей способности и надежности, перед их применением в реальной клинической практике.

Декомпенсация хронической сердечной недостаточности является одной из основных причин госпитализации у лиц старше 65 лет. Следовательно, ранняя диагностика, при первичном медицинском контакте с последующим своевременным обращением за медицинской помощью и коррекцией терапии имеют решающее значение, поскольку они влияют на прогноз у этих пациентов [8]. Добавление в алгоритм обследования таких пациентов лабораторных методов, не требующих дополнительных ресурсов, быстро выполнимых и обладающих высокой предсказательной ценностью значительно улучшает

качество оказания помощи пациентам старших возрастных групп с хронической сердечной недостаточностью.

В заключение необходимо отметить, что результаты нашего исследования убедительно свидетельствуют о возможности применения методов глубокого обучения для анализа данных скаттерграмм с целью первичной диагностики декомпенсации хронической сердечной недостаточности. И хотя данная методика выглядит очень перспективной, перед внедрением в реальную клиническую практику требуется проведение дополнительных исследований на независимых выборках для подтверждения полученных результатов.

#### **Выводы.**

1. Применение метода глубокого обучения для анализа данных скаттерграмм клинического анализа крови при первичной диагностике декомпенсации ХСН у лиц старших возрастных групп позволяет с 90% вероятностью подтвердить диагноз.

2. Стратификация функционального класса ХСН по NYHA с применением метода глубокого обучения для анализа данных скаттерграмм клинического анализа крови позволяет в 80% правильно принимать решение относительно необходимости госпитализации пациента.

3. Основными преимуществами метода является его скорость, рутинность, простота, дешевизна и распространенность. Метод не требует дополнительных материальных и человеческих ресурсов, а, следовательно, может и, на наш взгляд, должен применяться при первичном обследовании лиц старших возрастных групп обращающихся/поступающих с первичным диагнозом «I50.0 – Застойная сердечная недостаточность».

4. Добавление в алгоритм обследования таких пациентов оценки натрийуретических пептидов позволит практически со 100-процентной вероятностью подтвердить диагноз декомпенсации хронической сердечной недостаточности.

#### **Список литературы**

1. Пушкин А.С., Шулькин Д.Я., Борисова Л.В. и др. Алгоритм стратификации риска развития инфаркта миокарда у пациентов с острым коронарным синдромом при первичном обследовании. Клиническая лабораторная диагностика. 2020;65 (6): 394-400. doi: 10.18821/0869-2084-2020-65-6-111-222

2. Anand I.S., Gupta P. Anemia and Iron Deficiency in Heart Failure: Current Concepts and Emerging Therapies. *Circulation*. 2018;138 (1): 80-98. doi: 10.1161/CIRCULATIONAHA.118.030099
3. Brody H. Medical imaging. *Nature*. 2013;502 (7473). S81. doi: 10.1038/502s81a.
4. Campuzano-Zuluaga G., Alvarez-Sánchez G., Escobar-Gallo G.E. et al. Design of malaria diagnostic criteria for the Sysmex XE-2100 hematology analyzer. *Am. J. Trop. Med. Hyg.* 2010;82 (3): 402-411. doi: 10.4269/ajtmh.2010.09-0464
5. Hinton G.E., Salakhutdinov R.R. Reducing the dimensionality of data with neural networks *Science*. 2006;313. (5786): 504-507. doi: 10.1126/science.1127647
6. Ibrahim N., Januzzi J.L. The potential role of natriuretic peptides and other biomarkers in heart failure diagnosis, prognosis and management. *Expert Rev. Cardiovasc. Ther.* 2015;13 (9): 1017-1030. doi: 10.1586/14779072.2015.1071664
7. Ioffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *Proceedings of Machine Learning Research*. 2015;27: 448-456.
8. Kadoglou N.P.E., Parissis J., Karavidas A. et al. Assessment of acute heart failure prognosis: the promising role of prognostic models and biomarkers. *Heart Fail Rev.* 2022;27 (2): 655-663. doi: 10.1007/s10741-021-10122-9
9. Kurmani S., Squire I. Acute Heart Failure: Definition, Classification and Epidemiology. *Curr Heart Fail Rep.* 2017;14 (5):385-392. doi: 10.1007/s11897-017-0351-y
10. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*. 2015;521 (7553): 436-444. doi: 10.1038/nature14539.
11. Li S.F., Koons K., Barajas F. Elderly Woman With Chest Pain and Cough. *Ann. Emerg. Med.* 2017;70 (5): e43-e44. doi: 10.1016/j.annemergmed.2017.05.026
12. McDonagh T., Metra M., Adamo M. et al. 2021 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure: Developed by the Task Force for the diagnosis and treatment of acute and chronic heart failure of the European Society of Cardiology (ESC). With the special contribution of the Heart Failure Association (HFA) of the ESC. *Eur. J. Heart Fail.* 2022;24 (1): 4-131. doi: 10.1002/ejhf.2333
13. Osman J., Lambert J., Templé M. et al. Rapid screening of COVID-19 patients using white blood cell scattergrams, a study on 381 patients. *Br. J. Haematol.* 2020;190 (5): 718-722. doi: 10.1111/bjh.16943

14. Reddy Y.N.V., Kaye D.M., Handoko M.L. et al. Diagnosis of Heart Failure With Preserved Ejection Fraction Among Patients With Unexplained Dyspnea. *JAMA Cardiol.* 2022;7 (9): 891-899. doi: 10.1001/jamacardio.2022
15. Sabouret P., Attias D., Beauvais C. et al. Diagnosis and management of heart failure from hospital admission to discharge: A practical expert guidance. *Ann Cardiol Angeiol (Paris).* 2022;71 (1): 41-52. doi: 10.1016/j.ancard.2021.05.004
16. Schmidhuber J. Deep learning in neural networks: an overview. *Neural Netw.* 2015;61: 85-117. doi: 10.1016/j.neunet.2014.09.003
17. Vincent P., Larochelle H., Lajoie I. et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of Machine Learning Research.* 2010;11: 3371–3408.

### References

1. Pushkin A.S., Shulkin D., Borisova L.V. et al. Algoritm stratifikacii riska razvitiya infarkta miokarda u pacientov s ostrym koronarnym sindromom pri pervichnom obsledovanii [Algorithm to stratify the risk of myocardial infarction in patients with acute coronary syndrome at primary examination]. *Klinicheskaya laboratornaya diagnostika [Clinical laboratory diagnostics].* 2020;65 (6): 394-400. (In Russian) doi: 10.18821/0869-2084-2020-65-6-111-222
2. Anand I.S., Gupta P. Anemia and Iron Deficiency in Heart Failure: Current Concepts and Emerging Therapies. *Circulation.* 2018;138 (1): 80-98. doi: 10.1161/CIRCULATIONAHA.118.030099
3. Brody H. Medical imaging. *Nature.* 2013;502 (7473). S81. doi: 10.1038/502s81a.
4. Campuzano-Zuluaga G., Alvarez-Sánchez G., Escobar-Gallo G.E. et al. Design of malaria diagnostic criteria for the Sysmex XE-2100 hematology analyzer. *Am. J. Trop. Med. Hyg.* 2010;82 (3): 402-411. doi: 10.4269/ajtmh.2010.09-0464
5. Hinton G.E., Salakhutdinov R.R. Reducing the dimensionality of data with neural networks *Science.* 2006;313. (5786): 504-507. doi: 10.1126/science.1127647
6. Ibrahim N., Januzzi J.L. The potential role of natriuretic peptides and other biomarkers in heart failure diagnosis, prognosis and management. *Expert Rev. Cardiovasc. Ther.* 2015;13 (9): 1017-1030. doi: 10.1586/14779072.2015.1071664
7. Ioffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *Proceedings of Machine Learning Research.* 2015;27: 448-456.

8. Kadoglou N.P.E., Parissis J., Karavidas A. et al. Assessment of acute heart failure prognosis: the promising role of prognostic models and biomarkers. *Heart Fail Rev.* 2022;27 (2): 655-663. doi: 10.1007/s10741-021-10122-9
9. Kurmani S., Squire I. Acute Heart Failure: Definition, Classification and Epidemiology. *Curr Heart Fail Rep.* 2017;14 (5):385-392. doi: 10.1007/s11897-017-0351-y
10. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature.* 2015;521 (7553): 436-444. doi: 10.1038/nature14539.
11. Li S.F., Koons K., Barajas F. Elderly Woman With Chest Pain and Cough. *Ann. Emerg. Med.* 2017;70 (5): e43-e44. doi: 10.1016/j.annemergmed.2017.05.026
12. McDonagh T., Metra M., Adamo M. et al. 2021 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure: Developed by the Task Force for the diagnosis and treatment of acute and chronic heart failure of the European Society of Cardiology (ESC). With the special contribution of the Heart Failure Association (HFA) of the ESC. *Eur. J. Heart Fail.* 2022;24 (1): 4-131. doi: 10.1002/ejhf.2333
13. Osman J., Lambert J., Templé M. et al. Rapid screening of COVID-19 patients using white blood cell scattergrams, a study on 381 patients. *Br. J. Haematol.* 2020;190 (5): 718-722. doi: 10.1111/bjh.16943
14. Reddy Y.N.V., Kaye D.M., Handoko M.L. et al. Diagnosis of Heart Failure With Preserved Ejection Fraction Among Patients With Unexplained Dyspnea. *JAMA Cardiol.* 2022;7 (9): 891-899. doi: 10.1001/jamacardio.2022
15. Sabouret P., Attias D., Beauvais C. et al. Diagnosis and management of heart failure from hospital admission to discharge: A practical expert guidance. *Ann Cardiol Angeiol (Paris).* 2022;71 (1): 41-52. doi: 10.1016/j.ancard.2021.05.004
16. Schmidhuber J. Deep learning in neural networks: an overview. *Neural Netw.* 2015;61: 85-117. doi: 10.1016/j.neunet.2014.09.003
17. Vincent P., Larochelle H., Lajoie I. et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of Machine Learning Research.* 2010;11: 3371–3408.

**Финансирование.** Исследование не имело спонсорской поддержки.

**Конфликт интересов.** Автор заявляет об отсутствии конфликта интересов.

**Acknowledgments.** The study did not have sponsorship.

**Conflict of interests.** The author declare no conflict of interest.

### Сведения об авторах

**Яковлев Артём Алексеевич** – кандидат медицинских наук. Старший научный сотрудник лаборатории возрастной клинической патологии отдела клинической геронтологии и гериатрии, АННО ВО НИЦ «Санкт-Петербургский институт биорегуляции и геронтологии», 197110, Россия, г. Санкт-Петербург, пр. Динамо, 3; заведующий отделением, врач-кардиолог СПб ГБУЗ «Городская многопрофильная больница №2», 194354, Россия, Санкт-Петербург, пер. Учебный, 5; ассистент кафедры госпитальной терапии медицинского факультета ФГБОУ ВО «Санкт-Петербургский государственный университет», 199034, г. Санкт-Петербург, Университетская наб., д. 7–9, e-mail: yakotema@yandex.ru, ORCID 0000-0003-2537-3658; SPIN-код: 6723-9231

**Рыжак Галина Анатольевна** – доктор медицинских наук, профессор, заслуженный деятель науки РФ. Заместитель директора по научной работе и новым технологиям, АННО ВО НИЦ «Санкт-Петербургский институт биорегуляции и геронтологии», 197110, Россия, г. Санкт-Петербург, пр. Динамо, 3. ORCID 0000-0003-2536-1438; SPIN-код: 5543-5974

**Шулькин Дмитрий Яковлевич** – магистр наук (вычислительная инженерия) MSc., директор и сооснователь компании RobotDreams® GmbH, 8010 Грац, Австрия. ORCID 0000-0003-4832-1041

**Пушкин Александр Сергеевич** – доктор биологических наук, доцент. Ведущий научный сотрудник лаборатории возрастной клинической патологии отдела клинической геронтологии и гериатрии АННО ВО НИЦ «Санкт-Петербургский институт биорегуляции и геронтологии», 197110, Россия, г. Санкт-Петербург, пр. Динамо, 3; заведующий отделом экстренных исследований клиничко-диагностической лаборатории, врач клинической лабораторной диагностики СПб ГБУЗ «Городская многопрофильная больница №2», 194354, Россия, Санкт-Петербург, пер. Учебный, 5; профессор кафедры клинической лабораторной диагностики с курсом молекулярной медицины, ГБОУ ВПО «Первый Санкт-Петербургский медицинский университет им. И.П. Павлова» Министерства здравоохранения Российской Федерации, 197022, Россия, Санкт-Петербург, ул. Льва Толстого 6-8. ORCID: 0000-0003-2875-9521; SPIN-код: 8934-2969

### About the authors

**Yakovlev Artem Alekseevich** – PhD. Senior Researcher, Laboratory of Age-related Clinical Pathology, Department of Clinical Gerontology and Geriatrics Saint Petersburg Institute of Bioregulation and Gerontology, 3, Dynamo pr., Saint Petersburg, Russia, 197110; Assistant of the Hospital Therapy Department St.-Petersburg State University, 7/9 Universitetskaya Emb., St Petersburg 199034, Russia. e-mail: yakotema@yandex.ru, ORCID 0000-0003-2537-3658; SPIN-code: 6723-9231

**Ryzhak G.A.** – Doctor of Mediical Sciences, Professor. Deputy Director for Research and New Technologies Clinical Gerontology and Geriatrics Saint Petersburg Institute of Bioregulation and Gerontology, 3, Dynamo pr., Saint-Petersburg, Russia, 197110. ORCID 0000-0003-2536-1438; SPIN- code: 5543-5974



**Shulkin Dimitrij** – Master of Science in Computational Engineering (University of Applied Sciences Hamburg HAW), CEO and Co-Founder of RobotDreams GmbH, Graz, Austria. ORCID 0000-0003-4832-1041

**Pushkin Aleksandr Sergeevich** – Doctor of Biological Sciences, Associate Professor. Leading Researcher of Age-related Clinical Pathology Laboratory, Department of Clinical Gerontology and Geriatrics Saint Petersburg Institute of Bioregulation and Gerontology, 3, Dynamo pr., Saint-Petersburg, Russia, 197110; Head of Emergency Department of Clinical Diagnostic Laboratory, St. Petersburg City Multidisciplinary Hospital No. 2, per. Uchebnyy, Saint-Petersburg, Russia, 194354; Professor of Clinical Laboratory Diagnostics Department with Course of Molecular Medicine, Pavlov First Saint-Petersburg State Medical University, L'va Tolstogo str. 6-8 Saint-Petersburg, Russia, 197022; ORCID: 0000-0003-2875-9521; SPIN 8934-2969

Статья получена: 15.07.2023 г.  
Принята к публикации: 28.09.2023 г.