



<https://doi.org/10.29001/2073-8552-2024-39-2-36-45>
УДК 616.126.52:616.132-06]-07:616.1-089:004.8(048.8)

Методы искусственного интеллекта в сердечно-сосудистой хирургии и диагностика патологии аорты и аортального клапана (обзор литературы)

Г.И. Ким^{1,2}, И.С. Блеканов¹, Ф.В. Ежов¹, Л.А. Коваленко¹,
Е.С. Ларин¹, Е.С. Разумилов¹, К.В. Пугин¹, М.С. Дадашов¹,
В.А. Пягай^{1,2}, Д.В. Шматов^{1,2}

¹ Санкт-Петербургский государственный университет (СПбГУ),
199034, Российская Федерация, Санкт-Петербург, Университетская наб., 79

² Клиника высоких медицинских технологий имени Н.И. Пирогова, Санкт-Петербургский государственный университет (СПбГУ),
190103 Российская Федерация, Санкт-Петербург, наб. Фонтанки, 154

Аннотация

Ведение пациентов с патологией аорты и аортального клапана является крайне актуальной темой. Основная проблема данной патологии – отсутствие явных симптомов до наступления жизнеугрожающего состояния, расслоения или разрыва аорты. Наиболее актуальной в этой ситуации становится ранняя своевременная диагностика, и ведущую роль в этом плане играют визуализирующие методы исследований. Однако основным лимитирующим фактором является скорость и качество оценки изображений. В связи с этим актуальной задачей представляется разработка ассистента врача на основе искусственного интеллекта (ИИ) для интеллектуального анализа изображений (Computer vision, CV). В данной статье сделан обзор современных нейросетевых методов эффективного анализа диагностических изображений (мультиспиральная компьютерная томография (МСКТ) и магнитно-резонансная томография (МРТ)), актуальных для исследования заболеваний сердечно-сосудистой системы в целом и аорты в частности. Одним из главных акцентов данного разбора является исследование применимости современных нейросетевых методов на основе архитектуры Transformer или механизма внимания, демонстрирующих высокие показатели точности в решении широкого спектра задач в других предметных областях и имеющих высокий потенциал применимости для качественного анализа диагностических изображений. Приведен обзор двух фундаментальных задач интеллектуального анализа изображений: классификации (архитектура ResNet, архитектора ViT, архитектора Swin Transformer) и семантической сегментации (2D подходы – U-Net, TransUNet, Swin-Unet, Segmenter и 3D подходы – 3D-Unet, Swin UNETR, VT-UNET). Описанные методы при должной точной настройке и правильном подходе к их обучению позволяют эффективно автоматизировать процесс диагностики патологии аорты и аортального клапана. Для успешной реализации проектов в области разработки ИИ следует учитывать ряд ограничений: качественный набор данных, серверные графические станции с мощными видеокартами, наличие междисциплинарной экспертной группы, подготовленные сценарии для тестирования в условиях, приближенных к реальным.

Ключевые слова:	сердечно-сосудистая хирургия; диагностика патологии аорты; искусственный интеллект; глубокое обучение; нейронные сети; диагностические изображения; сегментация изображений; классификация изображений.
Конфликт интересов:	авторы декларируют отсутствие конфликта интересов.
Финансирование:	выполнено без финансовой поддержки грантов, общественных, некоммерческих, коммерческих организаций и структур.
Для цитирования:	Ким Г.И., Блеканов И.С., Ежов Ф.В., Коваленко Л.А., Ларин Е.С., Разумилов Е.С., Пугин К.В., Дадашов М.С., Пягай В.А., Шматов Д.В. Методы искусственного интеллекта в сердечно-сосудистой хирургии и диагностика патологии аорты и аортального клапана (обзор литературы). <i>Сибирский журнал клинической и экспериментальной медицины</i> . 2024;39(2):36–45. https://doi.org/10.29001/2073-8552-2024-39-2-36-45 .

Artificial intelligence methods in cardiovascular surgery and diagnosis of pathology of the aorta and aortic valve (literature review)

Gleb I. Kim^{1, 2}, Ivan S. Blekanov¹, Fedor V. Ezhov¹, Lev A. Kovalenko¹, Evgeniy S. Larin¹, Evgeniy S. Razumilov¹, Kirill V. Pugin¹, Murad S. Dadashov¹, Viktor A. Pyagay^{1, 2}, Dmitriy V. Shmatov^{1, 2}

¹ St. Petersburg State University,
7-9, Universitetskaya emb., St. Petersburg, 199034, Russian Federation

² St. Petersburg State University Hospital, St. Petersburg State University,
154, the Fontanka River emb., St. Petersburg, 190103, Russian Federation

Abstract

The management of patients with aortic and aortic valve pathology is an extremely relevant task. The main problem of this pathology is the absence of obvious symptoms before the onset of a life-threatening condition, dissection or rupture of the aorta. Early timely diagnosis becomes the most relevant in this situation, and imaging research methods play a leading role in this regard. However, the main limiting factor is the speed and quality of image evaluation. Therefore, an actual task is to develop an AI-based physician assistant for image mining (Computer vision, CV). This article provides an overview of modern neural network methods for effective analysis of diagnostic images (MSCT and MRI) relevant for the study of diseases of the cardiovascular system in general and the aorta in particular. One of the main focuses of this analysis is the study of the applicability of modern neural network methods based on the Transformer architecture or the Attention Mechanism, which show high accuracy rates in solving a wide range of tasks in other subject areas, and have a high potential of applicability for qualitative analysis of diagnostic images. An overview of two fundamental problems of image mining is given: classification (ResNet architecture, ViT architect, Swin Transformer architect) and semantic segmentation (2D approaches – U-Net, TransUNet, Swin-Unet, Segmenter and 3D approaches – 3D-Unet, Swin UNETR, VT-UNET). The described methods, with proper fine tuning and the right approach to their training, will effectively automate the process of diagnosing aortic and aortic valve pathology. For the successful implementation of AI development projects, a number of limitations should be taken into account: a high-quality data set, server graphics stations with powerful graphics cards, an interdisciplinary expert group, prepared scenarios for testing in conditions close to real ones.

Keywords:	cardiovascular surgery; diagnosis of aortic pathology; artificial intelligence; deep learning; neural networks; diagnostic images; image segmentation; image classification.
Conflict of interest:	the authors do not declare a conflict of interest.
Funding:	the work was carried out without financial support from grants, public, non-profit, commercial organizations and structures.
For citation:	Kim G.I., Blekanov I.S., Ezhov F.V., Kovalenko L.A., Larin E.S., Razumilov E.S., Pugin K.V., Dadashov M.S., Pyagay V.A., Shmatov D.V. Artificial intelligence methods in cardiovascular surgery and diagnosis of pathology of the aorta and aortic valve (literature review). <i>Siberian Journal of Clinical and Experimental Medicine</i> . 2024;39(2):36–45. https://doi.org/10.29001/2073-8552-2024-39-2-36-45 .

Введение

В эпоху доказательной медицины вычислительные технологии, такие как искусственный интеллект (ИИ), компьютерное моделирование и расширенная реальность могут изменить систему здравоохранения во всем мире. Наиболее значимой проблемой в медицине до сегодняшнего дня остается постоянно растущее количество сердечно-сосудистых заболеваний. Именно поэтому новые технологии особенно актуально использовать в области кардиологии и сердечно-сосудистой хирургии.

Основной причиной смертности пациентов с сердечно-сосудистой патологией является ишемическая

болезнь сердца, которая в большинстве случаев имеет выраженную клиническую картину и хорошо поддается медикаментозному и хирургическому лечению. В свою очередь, пациенты с аневризмой грудной аорты не имеют столь ярко выраженных симптомов, поэтому диагноз заболевания вне его обострения может быть установлен только в ходе визуализации аорты, например, в ходе профилактического осмотра или в ходе обследования по поводу других заболеваний.

Аневризма аорты – это патологическое увеличение диаметра магистральной артерии вследствие врожденного или приобретенного изменения структуры ее стенки. Согласно различным оценкам, распространенность

аневризмы брюшной аорты в мире у мужчин старше 60 лет составляет около 4–8%, а у женщин – около 0,5–1,5% [1]. Встречаемость аневризмы грудной аорты реже, чем брюшной и составляет в западных странах порядка 5–10 случаев (0,005–0,01%) в год на 100 000 населения [2]. Распространенность этого заболевания в мире может колебаться в пределах 1% в промышленно развитых странах [3]. Общая частота разрывов таких аневризм составляет 1,6 на 100 000 человек в год [4].

В большинстве случаев увеличенная аорта со временем прогрессивно расширяется. Этот процесс может привести к расслоению или разрыву сосуда, которые являются наиболее катастрофическими осложнениями аневризмы аорты и причинами внезапной сердечной смерти. Поэтому в литературе такое патологическое состояние называют «тихим убийцей».

К факторам риска возникновения аневризмы аорты относят артериальную гипертензию, дисплазию соединительной ткани (синдромные и несиндромные варианты), наличие двусторчатого аортального клапана, пожилой возраст, употребление табака, атеросклероз. Чаще аневризмы встречаются у мужчин, однако по статистике женщины имеют более высокий риск расслоения или разрыва аорты и последующей смерти.

Клинически аневризма может протекать бессимптомно и бывает случайной находкой. Физикальное обследование обычно ничем не примечательно, хотя наличие диастолического шума, указывающего на аортальную регургитацию, должно вызывать подозрение в отношении аневризмы восходящего отдела аорты.

Исходя из скудности клинической картины и опасности фатальных событий, важное значение в данной ситуации имеет своевременная диагностика и диспансеризация, особенно в случае выявления патологии среди родственников первой линии. Визуализирующие методы диагностики (эхокардиография (ЭхоКГ), магнитно-резонансная томография (МРТ), мультиспиральная компьютерная томография (МСКТ) с кардиосинхронизацией) позволяют получить изображения, по которым можно определить наличие, местоположение, размер и характер изменений стенки аорты. МСКТ и МРТ имеют почти равные возможности для выявления аневризмы. Использование МСКТ и МРТ при симптоматических аневризмах также лучше, чем ЭхоКГ в случае определения патологического изменения на уровне дистальной части восходящего отдела или дуги аорты [5].

В настоящее время наиболее эффективным методом лечения является открытое хирургическое или эндоваскулярное протезирование аорты. Расслоенная или разорвавшаяся аневризма аорты требует экстренного лечения, тогда как симптоматическая неразорвавшаяся аневризма должна быть восстановлена как можно скорее [6].

Внедрение технологий ИИ в клиническую практику сердечно-сосудистой хирургии переживает экспоненциальное развитие. Интеграция ИИ с клиническими данными и данными визуализирующих методов диагностики потенциально может привести к созданию новых моделей прецизионной диагностики и прогнозирования для улучшения периоперационного ведения пациентов с патологией сердца и сосудов.

Так, специализированные технологии ИИ на основе существующих больших медицинских данных дают результаты, которые врачи могут использовать для улучшения диагностики. Например, эхокардиограмма, обработанная алгоритмами ИИ, в настоящее время используется для

диагностики сердечной недостаточности, фибрилляции предсердий, анемии, гипертрофической кардиомиопатии и легочной гипертензии. После того как проверенные и протестированные алгоритмы будут массово внедрены в рутинную работу в клинике, они смогут снизить когнитивную нагрузку врачей, предлагая предварительную диагностику, подсвечивая важные аспекты состояния пациентов и предотвращая возникновение постановки неверного диагноза. Одним из перспективных направлений по внедрению ИИ в области кардиохирургии является лечение заболеваний аорты, в частности аневризмы грудной аорты.

За последние несколько лет все чаще появляются работы, в которых исследователи в составе междисциплинарных научных групп делают попытки автоматизации процесса диагностики и лечебного процесса в области кардиологии с помощью классических статистических методов машинного обучения (Machine Learning, ML) и методов глубокого обучения (Deep Learning, DL), основанных на использовании нейронных сетей. Например, в кардиологии первым применением нейронных сетей стала разработка самообучающихся нейронных сетей для электрокардиографии (ЭКГ) [7]. В другой работе [8] те же авторы обучили самообучающуюся нейронную сеть с использованием 60 ЭКГ для локализации атриовентрикулярного дополнительного пути у пациентов с синдромом Вольфа – Паркинсона – Уайта, используя поляриность дельта-волн в качестве входных данных. В 1999 г. Т. Binder и соавт. применили нейронные сети для анализа данных ЭхоКГ [9]. Позже, уже в XXI в., мощности компьютеров позволили использовать технологии для чтения и анализа КТ- и МРТ-изображений.

В данной статье сделан обзор современных нейросетевых методов эффективного анализа диагностических изображений, актуальных для исследования заболеваний сердечно-сосудистой системы и имеющих высокий потенциал реального применения на практике. Одним из главных акцентов данного обзора является изучение применимости современных нейросетевых методов на основе архитектуры Transformer или механизма внимания, показывающих высокие показатели точности в решении широкого спектра задач в других предметных областях и имеющих высокий потенциал применимости для качественного анализа диагностических изображений.

Роль ИИ в анализе медицинских изображений

На основе ИИ может быть проведен анализ и интерпретация таких методов исследования сердечно-сосудистой системы, как трансторакальная и чреспищеводная ЭхоКГ, МСКТ, МРТ, аортография, коронарография и другие методы. Целью применения ИИ в данном случае является выявление патологии и определение предположительного метода дальнейшей тактики ведения пациента на основе комплексного анализа изображений. В частности, речь идет о предоперационной подготовке и послеоперационном наблюдении пациентов с сердечно-сосудистыми заболеваниями. Так, например, при проведении коронарографии ИИ способен оценить гемодинамическую значимость стенозов [10].

Электрокардиография

Анализ ЭКГ на основе ИИ на сегодняшний день расширился до множества точек приложений и достиг производительности человеческого уровня, эффективно выявляя сердечные заболевания с помощью больших наборов

данных ЭКГ, включая обнаружение аритмии, оценку уровня гликированного гемоглобина, определение токсичности применяемого дигоксина, распознавание расслоения аорты, пневмоторакса и инфаркта миокарда [11].

Эхокардиография

ЭхоКГ позволяет точно определить состояние сократимости миокарда, клапанного аппарата сердца и восходящего отдела аорты не только в плановой, но и в экстренной ситуации. Одним из главных преимуществ ЭхоКГ в экстренной ситуации является возможность оценить наличие патологии непосредственно в приемном покое большинства стационаров, что существенно ускоряет все процессы на пути маршрутизации пациента в ходе госпитализации. В то же время полный протокол исследования занимает длительное время, что не всегда делает его практичным в экстренных ситуациях.

Типичное ЭхоКГ-исследование предоставляет большие объемы данных, что может вызвать когнитивную перегрузку и привести к ошибкам. Кроме того, из-за субъективности оценки, особенностей разных точек зрения при обследовании неизбежно возникают проблемы вариативности внутри и между исследователями. Применение ИИ и автоматизации в практике специалистов ЭхоКГ позволит проводить последовательные, быстрые и точные измерения, что даст возможность поставить более точный диагноз и улучшить ведение пациентов [12].

МСКТ сердца и МСКТ-аортография

МСКТ сердца имеет явные преимущества при оценке клапанного аппарата, геометрии фиброзных колец, стенок левого желудочка при кардиомиопатиях. Это золотой стандарт определения размера фиброзного кольца и незаменимый инструмент при предоперационном планировании транскатетерного протезирования аортального клапана (TAVI). Надежное измерение размеров кольца аортального клапана, корня аорты и высоты коронарных устьев имеет решающее значение для выбора соответствующего протеза аортального клапана и позиционирования во время операции, что может повысить вероятность благоприятного исхода и снизить послеоперационные осложнения [12]. В данном случае использование ИИ может с высокой точностью дать рекомендации по предоперационной подготовке у таких пациентов за счет глубокого анализа архитектоники сердца и его структур.

Решение о хирургическом лечении аневризм аорты для предотвращения расслоения или разрыва основывается на оценке диаметра сосуда и его изменений с течением времени. Соответственно, точные измерения диаметра аорты имеют ключевое значение. За счет полуавтоматической сегментации аорты доступные в настоящее время трехмерные рабочие станции не могут измерить внешний диаметр аорты из-за тромба, заполняющего просвет. Однако последние разработки с применением ИИ позволили обеспечивать автоматические измерения поперечного сечения внешней и наружной стенки аорты, что дает точный ответ по тактике лечения пациента с такой аневризмой.

Нейросетевые методы анализа медицинских изображений

Как отмечалось ранее, методы ИИ широко используются для интеллектуального анализа изображений (Computer Vision, CV) в различных областях и имеют высокий потенциал для анализа диагностических изображений [13, 14].

Исходя из особенностей диагностических изображений, описанных в разделе 2, их анализ с помощью методов ИИ в большинстве случаев сводится к решению двух фундаментальных задач CV: классификации и семантической сегментации, которые давно исследуются и эффективно решаются в основном с помощью нейронных сетей [15]. Задачи CV традиционно решаются с помощью сверточных нейронных сетей (CNN), но с появлением архитектуры Transformer качество интеллектуального анализа изображений существенно улучшилось. Стали появляться практики внедрения элементов архитектуры Transformer в классические архитектуры CNN, в частности, А. Dosovitskiy и соавт. [16] предложили Vision Transformer (ViT). Благодаря высоким показателям точности базовые системы Vision Transformer быстро заняли лидирующие позиции в различных задачах, включая обнаружение объектов [17], семантическую сегментацию [18] и т.д., в том числе и в медицине [19].

Классификация

В задаче классификации нейронная сеть, получая на вход изображение, на выходе предсказывает порядковый номер (метку) класса. Если классов два, то такая задача классификации называется бинарной [20]. Например, данная задача может решаться в контексте вопроса: «есть ли на снимке патология?». Если классов больше двух, то классификация является многоклассовой (multiclass) [21]. В такой задаче нужно сопоставить изображение с одним из номеров (меток) классов, например, указать, какой из органов присутствует на КТ-снимке. Если одно изображение необходимо сопоставить с несколькими номерами (метками) классов, то такая классификация является мультиклассовой (multi-label) [22].

Далее рассматриваются современные нейросетевые архитектуры, применяемые в задаче классификации:

Архитектура ResNet. Достаточно популярная на сегодняшний день архитектура несмотря на то, что статья [23] вышла в 2016 г. Сравнение ResNet с другими архитектурами для классификации медицинских снимков, помимо хорошей точности работы, также показало высокую скорость обучения и обработки изображений этой архитектурой [24].

Архитектура ViT. Нейросетевая архитектура Visual Transformer [16] представляет собой модификацию трансформера для обработки изображений вместо текста (рис. 1). Оригинальная архитектура Transformer принимает на вход n слов и имеет вычислительную сложность $O(n^2)$. При переносе архитектуры Transformer на задачи, связанные с изображениями, возникла проблема, что в изображении считать «словом»? Идея представить каждый пиксель в качестве слова столкнулась с высокой вычислительной сложностью $O((H \times W)^2)$ (где W – ширина изображения, H – высота изображения).

А. Dosovitskiy и соавт. решили проблему представлением изображения в виде патчей (кусочков) размером $P \times P$ и передачей их через архитектуру трансформера вместо слов для извлечения признаков и классификации. Таким образом, получилось снизить вычислительную сложность с $O((H \times W)^2)$ до $O((H \times W/P^2)^2)$. Visual Transformer продемонстрировала выдающиеся результаты в задачах классификации изображений, превзойдя другие методы, такие как сверточные нейронные сети. Однако стоит отметить важный аспект: для достижения

высоких показателей точности результатов требуется обучение на большом объеме данных. Исследователям Google был доступен датасет JFT-300M. Без предварительного обучения на обширном наборе данных, даже при сильной регуляризации, модель склонна к переобучению и показывает заметно менее эффективные результаты по сравнению с моделями ResNet.

Архитектура Swin Transformer. Swin Transformer представляет собой улучшенную версию архитектуры ViT.

Z. Liu и соавт. [17] предложили помимо разбиения изображения на патчи использовать механизм сдвигающихся окон, после чего вычислять значения внимания внутри окна (Window Multihead Self-Attention), а также внутри окна после сдвига (Shifted Window Multihead Self-Attention) (рис. 2). Это позволяет захватывать визуальную информацию между непересекающимися окнами, при этом уменьшая вычислительную сложность по сравнению с механизмом Global Self-Attention.




Рис. 1. Схема архитектуры Visual Transformer
Fig. 1. Vial Transformer architecture diagram




Рис. 2. Структура блока Swin Transformer
Fig. 2. Swin Transformer block structure

Сегментация

Задача семантической сегментации в CV заключается в разделении изображения на отдельные сегменты, каждый из которых соответствует определенному объекту или классу объектов. Также как и в случае с классификацией нейронная сеть обучается на парах «объект – ответ», где объектом выступает изображение, а ответом – «маска». Маска является набором заранее размеченных сегментов, интересных исследователю. Каждому изображению сопоставляется своя маска с заранее размеченными интересующими сегментами. В данной задаче нейросеть, получая на вход изображение, на выходе должна восстановить маску (метку) класса.

Ниже рассматриваются методы семантической сегментации в двумерной и трехмерной постановках, основанных на архитектуре encoder-decoder (также называемая U-shape архитектура, рис. 3).

2D подходы

Классическое применение моделей семантической сегментации заключается в использовании двумерных изображений. Однако этот подход также применим и к задачам компьютерного зрения в медицине, где, несмотря на частое взаимодействие с трехмерными изображениями (например, КТ- или МРТ-снимками), объемные данные разбиваются на набор двумерных изображений. После этого к каждому такому изображению применяется

модель семантической сегментации; и в конце результат, полученный для каждого отдельного изображения, объединяется в трехмерную маску. К примеру, из трехмерного КТ-исследования можно извлечь двумерные изображения в аксиальной плоскости (срезы в поперечной плоскости тела).

U-Net. Обзор нейросетевых подходов сегментации изображений стоит начать с обзора «базовой», но по-прежнему широко используемой архитектуры U-Net [15] (схематически структура изображена на рисунке 4), которая нашла свое применение во многих задачах анализа медицинских изображений, таких как обнаружение туберкулеза легких на рентгеновских снимках, обнаружение злокачественных опухолей на КТ-снимках [25]; мультиорганная сегментация [26], сегментация опухолей печени [27]. Структура сети состоит из блоков encoder и decoder, которые связаны между собой с помощью «skip-connections» (см. рис. 4). Энкодер представляет собой типичную архитектуру сверточной нейронной сети, каждый блок которой последовательно понижает размер изображения в 2 раза, а количество извлеченных признаков повышает в 2 раза. Напротив, каждый слой декодера повышает размер изображения в 2 раза, а количество признаков сокращается вдвое. На этапе декодирования происходит объединение выходов соответствующих блоков энкодера и декодера посредством skip-connections. Это необходимо, чтобы дополнить промежуточную потерянную информацию о границах нужных классов на изображении.



Рис. 3. Архитектура «Кодировщик-декодировщик»
Fig. 3. "Encoder-decoder" architecture




Рис. 4. Архитектура U-Net
Fig. 4. U-Net architecture

TransUNet. Архитектура TransUNet [28] появилась в результате совмещения ViT (см. раздел 3.1) и U-Net. Вместо использования одной сверточной нейронной сети внутри энкодера U-Net авторы предложили применить гибридный CNN и ViT. Модели TransUNet уже успели показать высокие результаты в задачах, связанных с сегментацией медицинских изображений – выделение опухолей легких [29], обнаружение клеточных ядер [30].

Swin-Unet. Архитектура Swin-Unet [31] – это U-Net подобная архитектура, энкодер и декодер которой состоят

только из Swin Transformer блоков (рис. 5), рассмотренных в разделе 3.1. Hu Cao и соавт. исследовали применимость Swin-Unet к задачам мультиорганной сегментации, а также к задаче выделения частей сердца на МРТ-изображении (левый желудочек, правый желудочек и миокард), где получили результаты, в среднем превосходящие другие модели семантической сегментации.

Segmenter. Архитектура Segmenter [32] – это еще одна архитектура, основой которой служит Visual Transformer. Авторы предложили использовать K-обучаемых




Рис. 5. Архитектура Swin-Unet
Fig. 5. Swin-Unet architecture

эмбеддингов (K – количество классов, используемых для сегментации), которые применяются при декодировании признаков, полученных после кодирования. Кодирование и декодирование осуществляется с помощью ViT. В задаче обнаружения опухолевых патологий печени Segmenter показывает лучшие результаты в сравнении с другими 11 архитектурами нейронных сетей [33].

3D подходы

3D подход в семантической сегментации отличается от классического 2D подхода тем, что он работает с объемными данными, такими как медицинские изображения (КТ-снимки) различных органов. Для этого используются методы обработки и анализа объемных данных, которые позволяют точнее выделять объекты на изображении.

В данном разделе рассмотрены современные нейросетевые методы в задаче трехмерной семантической сегментации:

3D-UNet [34] представляет собой расширение классической двумерной архитектуры UNet, рассмотренной

в разделе 2.2.1, на трехмерное пространство. Данная нейросеть используется для сегментации медицинских изображений, таких как снимки мозга [35–37], сердца [38, 39], легких [40, 41] и других органов [42, 43], в трехмерном пространстве. Основным преимуществом 3D-UNet является его способность к точной сегментации медицинских изображений в трехмерном пространстве, что делает его особенно полезным для анализа объемных данных, таких как КТ- или МРТ-снимки. 3D-UNet стал широко используемым инструментом в медицинской области, и его применение продолжает расширяться в области медицинского образования, исследований и практического здравоохранения.

Swin UNETR и VT-UNET. Как и в случае с двумерными подходами, зарекомендовавшие себя техники трансформеров и механизмов внимания нашли применение в трехмерных подходах. Swin UNETR [44] – это передовая модель для сегментации медицинских изображений, основанная на архитектуре Swin Transformer, рассмотренной ранее в разделе 3.1. VT-UNET [45] является

модификацией архитектуры 3D-UNet с использованием Volumetric Transformer в качестве encoder.

Тем не менее, несмотря на высокую точность результатов сегментации нейросетевыми подходами данного типа, наблюдаются и существенные недостатки в их использовании, связанные, в первую очередь, с ресурсозатратностью вычислительных мощностей как на этапе обучения и тестирования моделей, так и на этапе использования и анализа в реальных условиях их эксплуатации в корпоративных системах принятия решения.

Заключение

Проведенный обзор современных нейросетевых методов, основанных на архитектуре Transformer с механизмом внимания и сверточных нейронных сетей, показывает высокую способность таких подходов ИИ к качественному анализу диагностических изображений (МСКТ и МРТ). Данные методы при должной точной настройке и правильном подходе к их обучению позволяют эффективно автоматизировать процесс диагностики патологии аорты и аортального клапана, а также лечебного процесса в области кардиологии и сердечно-сосудистой хирургии.

Несмотря на высокую эффективность использования нейросетевых подходов, существует и ряд существенных ограничений, которые необходимо устранить для успешной их реализации:

1. Наличие качественных наборов данных, которые должны быть подготовлены высококвалифицированными специалистами-экспертами в соответствующих областях медицины. Создание таких наборов является нетривиальной задачей, требующей точности в разметке данных и наличия эргономичных и специализированных инструментов краудсорсинга для работы с проприетарными форматами медицинских данных, такими как DICOM (Digital Imaging and Communications in Medicine) [46].

2. Наличие серверных графических станций с мощными видеокартами, необходимых для эффективного обучения и тестирования нейронных сетей. Во-первых, это объясняется сложностью архитектуры, которая для достижения высокой точности может содержать миллионы (а некоторые современные модели миллиарды) параметров, требующих больших вычислительных ресурсов

для вычисления и обновления. А во-вторых, это связано с требованием больших объемов данных для эффективного обучения, поскольку полнота данных для обучения влияет на точность принятия решения.

3. Наличие междисциплинарной, синхронизированной в рамках поставленной задачи, экспертной группы, состоящей как из специалистов в области кардиологии, сердечно-сосудистой хирургии и лучевой диагностики, так и специалистов по направлению анализа больших данных, математического моделирования и информационных технологий.

4. Наличие подготовленных реальных сценариев для тестирования в условиях, приближенных к реальным. В большинстве научных исследований данный компонент менее всего проработан, поскольку нейросетевые методы тестируются в идеальных условиях, а реальные условия требуют не только наличия у рабочей группы технических компетенций, но и нормативного и административного ресурса.

Таким образом, большинство приложений ИИ ограничиваются исследовательскими целями [47, 48] и покрывают, так или иначе, разрешение ограничений 1–3. Однако в условиях постоянного технологического развития и увеличения спроса на сердечно-сосудистые диагностические исследования нужно стремиться к включению ИИ в стандарты лечения. Ведение пациентов с использованием данной технологии не будет подразумевать абсолютно полную обособленность. Однако ИИ может стать надежным помощником всему здравоохранению, улучшая результаты лечения пациентов и снижая рутинную нагрузку на людей, а также неся в дальнейшем преимущества с экономической точки зрения. Кроме того, интересной перспективой развития является развитие интеллектуальной операционной, которая потенциально может позволить сделать роботизированную хирургию автономной. Так, благодаря обучению рекуррентной нейронной сети на трехмерных петлевых траекториях, созданных хирургом-человеком, уже сегодня роботизированная система способна выполнять некоторые этапы операции [49].

Хотелось бы подчеркнуть важность использования современных информационных технологий на основе ИИ в медицине, особенно в сердечно-сосудистой хирургии, которая с самого начала своего появления была локомотивом научной мысли и применения инноваций в клинической практике.

Литература / References

1. Yuan Z., Lu Y., Wei J., Wu J., Yang J., Cai Z. Abdominal aortic aneurysm: Roles of inflammatory cells. *Front. Immunol.* 2021;11:609161. DOI: 10.3389/fimmu.2020.609161.
2. Oladokun D., Patterson B.O., Sobocinski J., Karthikesalingam A., Loftus I., Thompson M.M. et al. Systematic review of the growth rates and influencing factors in thoracic aortic aneurysms. *Eur. J. Vasc. Endovasc. Surg.* 2016;51:674–81. DOI: 10.1016/j.ejvs.2016.01.017.
3. Benjamin E.J., Muntner P., Alonso A., Bittencourt M.S., Callaway C.W., Carson A.P. et al. Heart disease and stroke statistics – 2019 update: A report from the American Heart Association. *Circulation.* 2019;139(10):e56–e528. DOI: 10.1161/CIR.0000000000000659.
4. Gouveia E., Melo R., Mourão M., Caldeira D., Alves M., Lopes A. et al. A systematic review and meta-analysis of the incidence of acute aortic dissections in population-based studies. *J. Vasc. Surg.* 2022;75(2):709–720. DOI: 10.1016/j.jvs.2021.08.080.
5. Goldstein S.A., Evangelista A., Abbata S., Arai A., Asch F.M., Badano L.P. et al. Multimodality imaging of diseases of the thoracic aorta in adults: From the American Society of Echocardiography and the European Association of Cardiovascular Imaging: Endorsed by the Society Of Cardiovascular Computed Tomography and Society for Cardiovascular Magnetic Resonance. *Journal of the American Society of Echocardiography.* 2015;28(2):119–182. DOI: 10.1016/j.echo.2014.11.015.
6. Chaikof E.L., Dalman R.L., Eskandari M.K., Jackson B.M., Lee W.A., Mansour M.A. et al. The Society for Vascular Surgery practice guidelines on the care of patients with an abdominal aortic aneurysm. *J. Vasc. Surg.* 2018;67(1):2–77. DOI: 10.1016/j.jvs.2017.10.044.
7. Dassen W.R., Mulleneers R.G., Smeets J., den Dulk K., Cruz F., Brugada P. et al. Self-learning neural networks in electrocardiography. *J. Electrocardiol.* 1990;23:200–202. DOI: 10.1016/0022-0736(90)90102-8.
8. Dassen W.R., Mulleneers R.G., Den Dulk K., Smeets J.R., Cruz F., Penn O.C. et al. An artificial neural network to localize atrioventricular accessory pathways in patients suffering from the Wolff-Parkinson-White syndrome. *Pacing Clin. Electrophysiol.* 1990;13(12 Pt. 2):1792–1796. DOI: 10.1111/j.1540-8159.1990.tb06892.x.
9. Binder T., Strosner M., Moertl D., Strohm T., Baumgartner H., Maurer G. et al. Artificial neural networks and spatial temporal contour linking for automated endocardial contour detection on echocardiograms: A novel approach to determine left ventricular contractile function. *Ultrasound Med. Biol.* 1999;25:1069–1076. DOI: 10.1016/S0301-5629(99)00059-9.
10. Pellicano M., Lavi I., De Bruyne B., Vaknin-Assa H., Assali A., Valtzer O.

- et al. Validation study of image-based fractional flow reserve during coronary angiography. *Circ. Cardiovasc. Interv.* 2017;10(9):e005259. DOI: 10.1161/CIRCINTERVENTIONS.116.005259.
11. Chen H.Y., Lin C.S., Fang W.H., Lee C.C., Ho C.L., Wang C.H. et al. Artificial intelligence-enabled electrocardiogram predicted left ventricle diameter as an independent risk factor of long-term cardiovascular outcome in patients with normal ejection fraction. *Front. Med.* 2022;9:870523. DOI: 10.3389/fmed.2022.870523.
12. Long Q., Ye X., Zhao Q. Artificial intelligence and automation in valvular heart diseases. *Card. J.* 2020;27(4):404–420. DOI: 10.5603/CJ.a2020.0087.
13. Коваленко Л.А., Ларин Е.С., Блеканов И.С., Ким Г.И. Методы построения 3D модели аорты сердца и её сечения для автоматизации процесса КТ-диагностики. Процессы управления и устойчивость. Труды 54-й международной научной конференции аспирантов и студентов. 2023;10(1):298–303. Kovalenko L.A., Larin E.S., Blekanov I.S., Kim G.I. Methods of constructing a 3D model of the heart aorta and its section for automating the CT diagnostic process. *Control Processes and Stability*. (In Russ). 2023;10(1):298–303. <http://hdl.handle.net/11701/41728> (15.04.2024).
14. Ежов Ф.В., Ларин Е.С., Блеканов И.С., Ким Г.И. Нейросетевые методы сегментации аорты сердца при автоматической диагностике снимков КТ. Процессы управления и устойчивость. Труды 54-й международной научной конференции аспирантов и студентов. 2023;10(1):263–267. Ezhov F.V., Larin E.S., Blekanov I.S., Kim G.I. Neural network methods of segmentation of the aorta of the heart in the automatic diagnosis of CT scans. Management processes and sustainability. (In Russ). 2023;10(1):263–267. <http://hdl.handle.net/11701/41728> (15.04.2024).
15. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation. In: Navab N., Hornegger J., Wells W., Frangi A. (eds.) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. MICCAI 2015. Lecture Notes in Computer Science, vol. 9351. Springer, Cham. DOI: 10.1007/978-3-319-24574-4_28.
16. Dosovitskiy A., Beyer L., Kolesnikov A., Weissenborn D., Zhai X., Unterthiner T. et al. An image is worth 16 × 16 words: Transformers for image recognition at scale. *arXiv:2010.11929*. DOI: 10.48550/arXiv.2010.11929.
17. Liu Z., Lin Y., Cao Y., Hu H., Wei Y., Zhang Z. et al. Swin transformer: Hierarchical vision transformer using shifted windows. *Proceedings of the IEEE/CVF International Conference on Computer Vision, Montreal, 10–17 October 2021*, 10012–10022. DOI: 10.1109/ICCV48922.2021.00986.
18. Xie E., Wang W., Yu Z., Anandkumar A., Alvarez J.M., Luo P. SegFormer: Simple and efficient design for semantic segmentation with transformers. *Advances in Neural Information Processing Systems*. 2021;34:12077–12090. DOI: 10.48550/arXiv.2105.15203.
19. Li J., Chen J., Tang Y., Wang C., Landman B.A., Zhou S.K. Transforming medical imaging with transformers? A comparative review of key properties, current progresses, and future perspectives. *Medical image analysis*. 2023;102762. DOI: 10.48550/arXiv.2206.01136.
20. Zerouaoui H., Idri A. Deep hybrid architectures for binary classification of medical breast cancer images. *Biomedical Signal Processing and Control*. 2022;71(part_B):103226. DOI: 10.1016/j.bspc.2021.103226.
21. Farooq A., Anwar S., Awais M., Rehman S. A deep CNN based multi-class classification of Alzheimer's disease using MRI. 2017 IEEE International Conference on Imaging Systems and Techniques (Ist). 2017;1–6. DOI: 10.1109/IST.2017.8261460.
22. Guan Q., Huang Y. Multi-label chest X-ray image classification via category-wise residual attention learning. *Pattern Recognition Letters*. 2020;130:259–266. DOI: 10.1016/j.patrec.2018.10.027.
23. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition. *arXiv: Computer Vision and Pattern Recognition (cs.CV)*. DOI: 10.48550/arXiv.1512.03385.
24. Bressen K.K., Adams L.C., Erleben C., Hamm B., Niehues S.M., Vahldiek J.L. Comparing different deep learning architectures for classification of chest radiographs. *Scientific Reports*. 2020;10(1):13590. DOI: 10.1038/s41598-020-70479-z.
25. Yao W., Bai J., Liao W., Chen Y., Liu M., Xie Y. From CNN to Transformer: A review of medical image segmentation models. *arXiv: Image and Video Processing (eess.IV); Computer Vision and Pattern Recognition (cs.CV); Machine Learning (cs.LG)*. DOI: 10.48550/arXiv.2308.05305.
26. Azad R., Aghdam E.K., Rauland A. et al. Medical image segmentation review: The success of U-net. *arXiv: Image and Video Processing (eess.IV)*. DOI: 10.48550/arXiv.2211.14830.
27. Bilic P., Christ P., Li H.B., Vorontsov E., Ben-Cohen A., Kaissis G. et al. The liver tumor segmentation benchmark (LiTS). *Med. Image Anal.* 2023;84:102680. DOI: 10.1016/j.media.2022.102680.
28. Chen J., Lu Y., Yu Q., Luo X., Adeli E., Wang Y. et al. TransUNet: Transformers make strong encoders for medical image segmentation. *arXiv: Computer Vision and Pattern Recognition (cs.CV)*. DOI: 10.48550/arXiv.2102.04306.
29. Chang C., Lin T., Lin C., Cheng H. Application of TransUNet for segmenting lung mass from chest X-ray image. 2022 IEEE International Conference on Consumer Electronics – Taiwan. 2022;175–176. DOI: 10.1109/ICCE-Taiwan55306.2022.9869180.
30. Khan M.S., Ali S., Lee Y.R., Kang M.K., Pank S.Y., Tak W.Y. et al. TransUNet-lite: A robust approach to cell nuclei segmentation. *Proceedings of the 2023 7th International Conference on Medical and Health Informatics. ICMHI'23. Association for Computing Machinery*; 2023:251–258. DOI: 10.1145/3608298.3608344.
31. Cao H., Wang Y., Chen J., Jiang D., Zhang X., Tian Q. et al. Swin-unet: Unet-like pure transformer for medical image segmentation. *arXiv: Image and Video Processing (eess.IV)*. DOI: 10.48550/arXiv.2105.05537.
32. Strudel R., Garcia R., Laptev I., Schmid C. Segmenter: Transformer for semantic segmentation. *arXiv: Computer Vision and Pattern Recognition (cs.CV)*. DOI: 10.48550/arXiv.2105.05633.
33. Nguyen C., Asad Z., Huo Y. Evaluating transformer-based semantic segmentation networks for pathological image segmentation. *arXiv: Image and Video Processing (eess.IV)*. DOI: 10.48550/arXiv.2108.11993.
34. Çiçek, Ö., Abdulkadir, A., Lienkamp, S.S., Brox, T., Ronneberger, O. (2016). 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. In: Ourselin S., Joskowicz L., Sabuncu M., Unal G., Wells W. (eds.) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016*. MICCAI 2016. Lecture Notes in Computer Science, vol. 9901. Springer, Cham. DOI: 10.1007/978-3-319-46723-8_49.
35. Qamar S., Jin H., Zheng R., Ahmad P., Usama M. A variant form of 3D-Unet for infant brain segmentation. *Future Generation Computer Systems*. 2020;108:613–623. DOI: 10.1016/j.future.2019.11.021.
36. Islam M., Vibashan V., Jose V.J.M., Wijethilake N., Utkarsh U., Ren H. Brain tumor segmentation and survival prediction using 3D attention Unet. *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 5th International Workshop, Brainles 2019, Held in Conjunction with Miccai 2019, Shenzhen, China, October 17, 2019, Revised Selected Papers, Part I*, 5. 2020:262–272. DOI: 10.48550/arXiv.2104.00985.
37. Hwang H., Rehman H.Z.U., Lee S. 3D U-net for skull stripping in brain MRI. *Appl. Sci.* 2019;9(3):569. DOI: 10.3390/app9030569.
38. Kong F., Wilson N., Shadden S. A deep-learning approach for direct whole-heart mesh reconstruction. *Medical image analysis*. 2021;74:102222. DOI: 10.1016/j.media.2021.102222.
39. Habijan M., Leventić H., Galić I., Babin D. Whole heart segmentation from CT images using 3D U-net architecture. 2019 International Conference on Systems, Signals and Image Processing (IwSSIP). IEEE; 2019:121–126. DOI: 10.1109/IWSSIP.2019.8787253.
40. Xiao Z., Liu B., Geng L., Zhang F., Liu Y. Segmentation of lung nodules using improved 3D-Unet neural network. *Symmetry*. 2020;12(11):1787. DOI: 10.3390/sym12111787.
41. Wu W., Gao L., Duan H., Huang G., Ye X., Nie S. Segmentation of pulmonary nodules in CT images based on 3D-Unet combined with three-dimensional conditional random field optimization. *Medical Physics*. 2020;47(9):4054–4063. DOI: 10.1002/mp.14248.
42. Yu W., Fang B., Liu Y., Gao M., Zheng S., Wang Y. Liver vessels segmentation based on 3d residual U-net. 2019 IEEE International Conference on Image Processing (Icip). 2019:250–254. DOI: 10.1109/ICIP.2019.8802951.
43. Zhao W., Jiang D., Queralt J.P., Westerlund T. MSS U-net: 3D segmentation of kidneys and tumors from CT images with a multi-scale supervised U-net. *Informatics in Medicine Unlocked*. 2020;19:100357. DOI: 10.1016/j.imu.2020.100357.
44. Hatamizadeh A., Nath V., Tang Y., Yang D., Roth H.R., Xu D. Swin UNETR: Swin transformers for semantic segmentation of brain tumors in MRI images. In: *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, 2021:272–284. DOI: 10.48550/arXiv.2201.01266.
45. Peiris H., Hayat M., Chen Z., Egan G., Harandi M. A robust volumetric transformer for accurate 3D tumor segmentation. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. 2022:162–172. DOI: 10.48550/arXiv.2111.13300.
46. Ежов Ф.В., Коваленко Л.А., Разумилов Е.С., Блеканов И.С. Инструменты краудсорсинга для анализа и обработки медицинских изображений в виде снимков КТ. Процессы управления и устойчивость. Труды 54-й международной научной конференции аспирантов и студентов. 2023;10(1):291–297. Ezhov F.V., Kovalenko L.A., Razumilov E.S., Blekanov I.S. Crowdsourcing tools for analyzing and processing medical images in the form of CT scans. Management processes and sustainability. (In Russ). 2023;10(1):291–297. <http://hdl.handle.net/11701/41728> (15.04.2024).

47. Fischer U.M., Shireman P.K., Lin J.C. Current applications of artificial intelligence in vascular surgery. *Semin. Vasc. Surg.* 2021;34(4):268–271. DOI: 10.1053/j.semvascsurg.2021.10.008.
48. Lanzafame L.R.M., Bucolo G.M., Muscogiuri G., Sironi S., Gaeta M., Ascenti G. et al. Artificial intelligence in cardiovascular CT and MR imaging. *Life*. (Basel). 2023;13(2):507. DOI: 10.3390/life13020507.
49. Grespan L., Fiorini P., Colucci G., Grespan L., Fiorini P., Colucci G. Patient safety in robotic surgery. In: Grespan L., Fiorini P., Colucci G. *The Route to Patient Safety in Robotic Surgery*. Springer Cham; 2019:7–23. DOI: 10.1007/978-3-030-03020-9_2.

Информация о вкладе авторов

Ким Г.И., Блеканов И.С. – написание и редактирование статьи, обсуждение полученных результатов, окончательное утверждение содержания статьи.

Ежов Ф.В., Коваленко Л.А., Ларин Е.С., Разумилов Е.С., Пугин К.В., Дадашов М.С. – написание статьи, обзор литературы, подбор материалов.

Пягай В.А. – обзор литературы, обсуждение полученных результатов. Шматов Д.В. – редактирование статьи, обсуждение полученных результатов.

Сведения об авторах

Ким Глеб Ирламович, канд. мед. наук, сердечно-сосудистый хирург, кардиохирургическое отделение, Клиника высоких медицинских технологий им. Н.И. Пирогова, СПбГУ, Санкт-Петербург, <http://orcid.org/0000-0002-9344-5724>.

E-mail: gikim.cor@gmail.com.

Блеканов Иван Станиславович, канд. тех. наук, доцент, заведующий кафедрой технологии программирования, факультет прикладной математики – процессов управления, СПбГУ, Санкт-Петербург, <http://orcid.org/0000-0002-7305-1429>.

E-mail: i.blekanov@spbu.ru.

Ежов Федор Валерьевич, аспирант, факультет прикладной математики – процессов управления, СПбГУ, Санкт-Петербург, <http://orcid.org/0009-0007-1468-0042>.

E-mail: moremenes@yandex.ru.

Коваленко Лев Алексеевич, аспирант, факультет прикладной математики – процессов управления, СПбГУ, Санкт-Петербург, <http://orcid.org/0009-0007-8233-4387>.

E-mail: i.blekanov@spbu.ru.

Ларин Евгений Сергеевич, аспирант, факультет прикладной математики – процессов управления, СПбГУ, Санкт-Петербург, <http://orcid.org/0009-0007-6199-3607>.

E-mail: st054551@student.spbu.ru.

Разумилов Егор Сергеевич, аспирант, факультет прикладной математики – процессов управления, СПбГУ, Санкт-Петербург, <http://orcid.org/0000-0003-0189-5013>.

E-mail: i.blekanov@spbu.ru.

Пугин Кирилл Витальевич, аспирант, факультет прикладной математики – процессов управления, СПбГУ, Санкт-Петербург, <http://orcid.org/0009-0003-9398-3850>.

E-mail: st069636@student.spbu.ru.

Дадашов Мурад Сахиб оглы, студент, медицинский факультет, СПбГУ, Санкт-Петербург, <http://orcid.org/0009-0006-5714-3805>.

E-mail: muraddadashov1309@gmail.com.

Пягай Виктор Александрович, сердечно-сосудистый хирург, кардиохирургическое отделение, Клиника высоких медицинских технологий им. Н.И. Пирогова, СПбГУ, Санкт-Петербург, <http://orcid.org/0009-0001-8010-6184>.

E-mail: viktorpyagay@mail.ru.

Шматов Дмитрий Викторович, д-р мед. наук, заместитель директора по медицинской части (кардиохирургия), Клиника высоких медицинских технологий им. Н.И. Пирогова, СПбГУ, Санкт-Петербург, <http://orcid.org/0000-0002-1296-8161>.

E-mail: dv.shmatov@gmail.com.

 **Ким Глеб Ирламович**, e-mail: gikim.cor@gmail.com.

Поступила 16.02.2024;
рецензия получена 12.04.2024;
принята к публикации 28.05.2024.

Information on author contributions

Kim G.I., Blekanov I.S. – article writing and editing, discussing of the results obtained, final approval of the article content.

Ezhov F.V., Kovalenko L.A., Larin E.S., Razumilov E.S., Pugin K.V., Dadashov M.S. – article writing, literature review, material selection.

Pyagay V.A. – literature review, discussion of the results obtained.

Shmatov D.V. – article editing, discussing of the results obtained.

Information about the authors

Gleb I. Kim, Cand. Sci. (Med.), Cardiovascular Surgeon, Cardiac Surgery Department, St. Petersburg State University Hospital, <http://orcid.org/0000-0002-9344-5724>.

E-mail: gikim.cor@gmail.com.

Ivan S. Blekanov, Cand. Sci. (Techn.), Associate Professor, Head of the Department of Programming Technology, Faculty of Applied Mathematics and Control Processes, Saint Petersburg State University, <http://orcid.org/0000-0002-7305-1429>.

E-mail: i.blekanov@spbu.ru.

Fedor V. Ezhov, Graduate Student, Faculty of Applied Mathematics and Control Processes, Saint Petersburg State University, <http://orcid.org/0009-0007-1468-0042>.

E-mail: moremenes@yandex.ru.

Lev A. Kovalenko, Graduate Student, Faculty of Applied Mathematics and Control Processes, Saint Petersburg State University, <http://orcid.org/0009-0007-8233-4387>.

E-mail: i.blekanov@spbu.ru.

Evgeniy S. Larin, Graduate Student, Faculty of Applied Mathematics and Control Processes, Saint Petersburg State University, <http://orcid.org/0009-0007-6199-3607>.

E-mail: st054551@student.spbu.ru.

Egor S. Razumilov, Graduate Student, Faculty of Applied Mathematics and Control Processes, Saint Petersburg State University, <http://orcid.org/0000-0003-0189-5013>.

E-mail: i.blekanov@spbu.ru.

Kirill V. Pugin, Graduate Student, Faculty of Applied Mathematics and Control Processes, Saint Petersburg State University, <http://orcid.org/0009-0003-9398-3850>.

E-mail: st069636@student.spbu.ru.

Murad S. Dadashov, Student, Faculty of Medicine, Saint Petersburg State University, <http://orcid.org/0009-0006-5714-3805>.

E-mail: muraddadashov1309@gmail.com.

Viktor A. Pyagay, Cardiovascular Surgeon, Cardiac Surgery Department, St. Petersburg State University Hospital, <http://orcid.org/0009-0001-8010-6184>.

E-mail: viktorpyagay@mail.ru.

Dmitry V. Shmatov, Dr. Sci. (Med.), Deputy Director for Medical Affairs (Cardiac Surgery), St. Petersburg State University Hospital, <http://orcid.org/0000-0002-1296-8161>.

E-mail: dv.shmatov@gmail.com.

 **Gleb I. Kim**, e-mail: gikim.cor@gmail.com.

Received 16.02.2024;
review received 12.04.2024;
accepted for publication 28.05.2024.