

КЛЫШНИКОВ К.Ю.,

к.м.н., НИИ КПССЗ, г. Кемерово, Россия, e-mail: klyshku@kemcardio.ru

ОВЧАРЕНКО Е.А.,

к.т.н., НИИ КПССЗ, г. Кемерово, Россия, e-mail: ovchea@kemcardio.ru

ДАНИЛОВ В.В.,

к.т.н., НИ ТПУ, г. Томск, Россия, e-mail: danilovvv@tpu.ru

ОНИЩЕНКО П.С.,

НИИ КПССЗ, г. Кемерово, Россия, e-mail: onisps@kemcardio.ru

РЕЗОВА М.А.,

НИИ КПССЗ, г. Кемерово, Россия, e-mail: rezvma@kemcardio.ru

ГЛУШКОВА Т.В.,

к.б.н., НИИ КПССЗ, г. Кемерово, Россия, e-mail: glushtv@kemcardio.ru

КОСТЮНИН А.Е.,

к.б.н., НИИ КПССЗ, г. Кемерово, Россия, e-mail: kostae@kemcardio.ru

БАРБАРАШ Л.С.,

Академик РАН, д.м.н., НИИ КПССЗ, г. Кемерово, Россия, e-mail: director@kemcardio.ru

МАШИННОЕ ОБУЧЕНИЕ В ЗАДАЧЕ ДЕТЕКЦИИ СТЕНОЗОВ СОСУДОВ КОРОНАРНОГО БАССЕЙНА

DOI: 10.25881/18110193_2022_2_52

Аннотация.

Актуальность. Учитывая рост интереса исследователей и клинических специалистов к алгоритмам обработки медицинских данных, существенно возросли перспективы прикладного применения подобных подходов – прежде всего использования глубоких нейронных сетей в задачах детекции патологических участков. Однако использование таких методик сопряжено с низким уровнем точности локализации, недостаточным для трансляции наработку в область ассистирующих систем для принятия врачебных решений.

Цель. Настоящее исследование направлено на оценку скорости и точности работы современной архитектуры сверточной нейронной сети RFCN ResNet-101 V2 для перспектив автоматизированной обработки клинических данных коронарографий.

Материалы и методы. Основой для обучения выбранной архитектуры нейросети стали клинические графические данные коронарографии 50 пациентов, у которых было выявлено наличие одноочаговых поражений (стенозов) более 75%. В исследовании оценены метрики классификационной и локализационной точности при определении положения одноочагового поражения коронарной артерии.

Результаты. Показано, что использованная архитектура нейронной сети способна осуществлять детекцию с точностью 94%, но в значительной мере не удовлетворяет требованиям производительности (скорости обработки).

Заключение. Полученные результаты определяют дальнейшее направление развития данного подхода – снижение времени анализа каждого кадра коронарографии за счет методов препроцессинга изображений.

Ключевые слова: нейронная сеть; коронарография; tAP; локализация; стеноз коронарной артерии.

Для цитирования: Клышников К.Ю., Овчаренко Е.А., Данилов В. В., Онищенко П.С., Резова М. А., Глушкова Т.В., Костюнин А.Е., Барбараш Л. С. Машинное обучение в задаче детекции стенозов сосудов коронарного бассейна. *Врач и информационные технологии.* 2022; 2: 52-61. doi: 10.25881/18110193_2022_2_52.

KLYSHNIKOV K.YU.,

PhD, Research Institute for CloCD, Kemerovo, Russia, e-mail: klyshku@kemcardio.ru

OVCHARENKO E.A.,

PhD, Research Institute for CloCD, Kemerovo, Russia, e-mail: ovchea@kemcardio.ru

DANILOV V.V.,

PhD, TPU, Tomsk, Russia, e-mail: danilovvv@tpu.ru

ONISHCHENKO P.S.,

Research Institute for CloCD, Kemerovo, Russia. e-mail: onisps@kemcardio.ru

REZVOVA M.A.,

Research Institute for CloCD, Kemerovo, Russia, e-mail: rezvma@kemcardio.ru

GLUSHKOVA T.V.,

PhD, Research Institute for CloCD, Kemerovo, Russia, e-mail: glushtv@kemcardio.ru

KOSTYUNIN A.E.,

PhD, Research Institute for CloCD, Kemerovo, Russia, e-mail: kostae@kemcardio.ru

BARBARASH L.S.,

Academician of the RAS, Dr. Sci (Medicine), Research Institute for CloCD, Kemerovo, Russia, e-mail: director@kemcardio.ru

MACHINE LEARNING IN THE DETECTION OF CORONARY STENOSIS PROBLEM SOLVING

DOI: 10.25881/18110193_2022_2_52

Abstract.

Background. Considering the growing interest of researchers and clinical specialists in algorithms for processing medical data, the prospects for the applied application of such approaches have significantly increased, primarily, involving the use of deep neural networks in the tasks of detecting pathological areas. However, the use of such approaches is associated with a low level of localization accuracy, insufficient to translate the developments into the field of assistive systems for making medical decisions.

Aim. This work is aimed at assessing the speed and accuracy of the modern architecture of the convolutional neural network RFCN ResNet-101 V2 for the prospects for automated processing of clinical data from coronary angiography.

Materials and methods. The basis for the chosen neural network architecture training was the clinical graphic data of 50 patients subjected to routine coronary angiography, which is characterized by the presence of single-focal lesions (stenoses) in more than 75% of all cases. The study evaluated the metrics of classification and localization accuracy in determining the position of a single-focal coronary artery lesion.

Results. The utilized architecture of the neural network was capable of detecting single-focal lesions with an accuracy of 94%. However, to a large extent, it didn't the performance requirements (processing speed).

Conclusion. The results obtained determine the further direction of development of the presented approach, which should be reducing the time of analysis of each frame of coronary angiography due to image preprocessing methods.

Keywords: neural network; coronary angiography; F1-score; localization; stenosis of the coronary artery.

For citation: Klyshnikov K.Yu., Ovcharenko E.A., Danilov V.V., Onishchenko P.S., Rezvova M.A., Glushkova T.V., Kostyunin A.E., Barbarash L.S. Machine learning in the detection of coronary stenosis problem solving. Medical doctor and information technology. 2022; 2: 52-61. doi: 10.25881/18110193_2022_2_52.

ВВЕДЕНИЕ

Ишемическая болезнь сердца является наиболее распространенным типом сердечно-сосудистых заболеваний и сохраняет лидирующие позиции в качестве основной причины смертности в России [1] и в мире [2]. Стенозирование просвета коронарных артерий в результате обструкции атеросклеротической бляшкой значительно ухудшает кровоснабжение миокарда, дисбалансируя потребность и обеспечение последнего кислородом. Возникновение в таком случае патологических состояний, в том числе инфаркта миокарда, требует оперативной диагностики и лечения, ключевыми методами которых является рентгеновская коронарография с последующим чрескожным коронарным вмешательством, являющимся на сегодняшний день «золотым стандартом» [3]. Основой обеих процедур является визуализация анатомии русла коронарных артерий с помощью рентгенконтрастного вещества для локализации и выявления в режиме реального времени участка окклюзии. При этом данный анализ производится кардиологом при визуальной оценке и в некоторых случаях может иметь субъективный характер, а также является трудоемким процессом, требующим большого клинического опыта [3]. Предполагается, что частичная автоматизация обнаружения стенозированных участков на основе математических алгоритмов обработки графических данных может повысить эффективность и достоверность диагностики, в том числе как дополнение к шкальным методам и статистическим прогностическим моделям [4].

Развитие методов машинного обучения для анализа больших массивов изображений получило широкое распространение в медицине и демонстрирует высокое качество классификации, локализации и сегментации данных, в том числе в составе систем поддержки врачебных решений [5]. Стоит ожидать, что более активное внедрение данных алгоритмов, в частности, сверточных нейронных сетей, способно существенно изменить результативность диагностического процесса, исключить субъективность и в конечном итоге улучшить исходы последующих лечебных процедур. В настоящее время в литературе представлен ряд работ по применению автоматических алгоритмов

для решения задачи диагностики (локализации) обструкции коронарных артерий. В частности, Shahzad и др. [6] использовали метод извлечения центральной линии сосуда и выявление стеноза путем сравнения реального диаметра сегментированного просвета с ожидаемым диаметром смоделированного здорового просвета. Wang и др. [7] применили модель для сегментации внутренней и внешней стенок артерий с определением областей наибольшей разницы между двумя измерениями, что свидетельствовало о наличии стеноза. Аналогично, Broersen и др. [8] определяли контуры артериальной стенки, а затем для выявления стеноза использовали регрессионную модель для расчета отклонений данных измерений от нормальных сосудов. Такие алгоритмические методы удобны для задач локализации, однако демонстрируют низкую точность (чувствительность 54,1% [7]; 27,7% [8]), требуют повышения скорости обработки, о чем сообщают некоторые авторы представленных работ [7], и ориентированы на более специфичный метод диагностики — компьютерную томографию коронарных артерий.

Принципиально другой подход демонстрирует работа [9] по использованию сверточной нейронной сети U-Net, в которой авторы подтверждают эффективность применения машинного обучения именно для коронарной ангиографии. Авторы показали, что нейросеть способна локализовать одиночный стеноз коронарной артерии с чувствительностью 87,2% и интегральной метрикой классификации F1-score 83,2%. Указанные показатели, безусловно, являются высокими, однако недостаточными для принятия столь важного врачебного решения, как определение тактики лечения. Высокотехнологичная медицинская помощь требует максимального уровня точности диагностики, поэтому практическое внедрение подобных алгоритмов требует совершенствования качества (точности) локализации патологических участков.

В настоящей работе представлен результат использования более современной модели сверточной нейронной сети применительно к локализации участка стеноза коронарной артерии с фокусом на высокую точность детекции при обеспечении приемлемой скорости обработки данных коронарной ангиографии.

Таблица 1 — Характеристика пациентов, ангиографические данные которых были использованы для обучения, валидации и тестирования нейросети

Показатель	Значение
Общее количество пациентов	50
Средний возраст ± ст.откл., лет	60,3±13,8
Мужчины, n (%)	34 (68%)
Женщины, n (%)	16 (32%)
Индекс массы тела, кг/м ²	21,6±5,1
Классификация ишемической болезни сердца	
Класс I NYHA, n (%)	3 (6%)
Класс II NYHA, n (%)	41 (82%)
Класс III NYHA, n (%)	6 (12%)
Коморбидность	
Артериальная гипертензия, n (%)	26 (52%)
Сахарный диабет, n (%)	7 (14%)
Хроническая сердечная недостаточность, класс 1–2, n (%)	18 (36%)

МАТЕРИАЛ И МЕТОДЫ

Исходными данными для обучения нейросети стали ретроспективные результаты ангиографии случайным образом отобранных 50 пациентов, поступивших в НИИ «Комплексных проблем сердечно-сосудистых заболеваний» (г. Кемерово, Россия) в период 2018–2020 гг., для которых был выявлен одноочаговый стеноз коронарной артерии (независимо от локализации) более 75%. Критерием исключения стало наличие двух и более стенозированных участков, которые установил оператор — интервенционный кардиолог. Характеристика пациентов, включенных в исследование, представлена ниже (табл. 1). Все ангиографические изображения получены на установке Innova (GE Healthcare, США).

Стоит предполагать, что полученная выборка является репрезентативной, исходя из двух основных особенностей: отбор пациентов для включения в исследование проведен случайным образом, без ограничений по возрасту, полу и другим характеристикам; полученные характеристики (табл.1) соответствуют «портрету» пациента [10], которому проводится чрескожное коронарное вмешательство для реваскуляризации миокарда.

При каждом прохождении рентгеноконтрастного вещества формировали файлы видеозаписи (n = 50) с разрешением 512×512 пикселей в оттенках серого, частотой 12,5 кадров/с, содержащие 36–175 кадров. Файлы видеозаписей разделяли на отдельные изображения, используя библиотеку Python OpenCV. После чего интервенционный

кардиолог, проводивший ангиографические исследования, отбирал изображения, содержащие контрастирование стенозированного участка, и размечал данные области, используя инструментарий платформы Supervise.ly (США). На всех этапах работы (разметка, обучение нейросети) полученные изображения не подвергали обрезке, изменению размеров или фокусировке области поиска участка стеноза, то есть обрабатывали весь кадр целиком. Суммарно выборка составила 2000 изображений, которая была случайным образом разделена на: обучающий (70%, 1400 шт.); валидационный (15%, 300 шт.) и тестовый (15%, 300 шт.) наборы. Краткая схема дизайна исследования представлена на рис. 1.

В качестве модели нейросети и использовали детектор RFCN ResNet-101 V2 [11], реализующий подход многозадачного обучения: одновременной классификации изображения на наличие/отсутствие стеноза и локализацию его на изображении. Модель нейросети реализована на базе фреймворка The TensorFlow Object Detection API, содержит 44,7 млн. весов, входной массив — матрица 600×600×3. В качестве подхода для регуляризации использовали технику Early stopping [12] для снижения риска переобучения.

Эффективность работы указанной модели характеризуется метрикой локализации (mAP), которая определяет точность. Вычисление данной оценки производят следующим образом [13]:

а) Обученная нейросеть располагает свое предсказание о месте стенозированного участка




Рисунок 1 — Дизайн исследования.

на каждом кадре набора данных — обучающей, валидационной, тестовой выборках.

- б) Производится оценка точности того, насколько такое предсказание нейросети близко к результатам разметки, которую нанес интервенционный кардиолог. Сперва успешным считают перекрытие площадей «предсказание-разметка» не менее 50%, что является истинно положительным случаем, в противной ситуации — ложноположительным.
- в) Вычисляют точность (precision):

$$\text{Точность} = \frac{\text{Истинно положительные}}{\text{Все предсказания}}$$
- г) Увеличивают порог вычисления точности на +5% до достижения в итоге 95% границы, вычисляя каждый раз точность по формуле предыдущего пункта.
- д) Усредняют точность, формируя таким образом итоговую единственную оценку mAP из всего диапазона перекрытия площадей «предсказание-разметка» — 50...95%.

РЕЗУЛЬТАТЫ

В ходе обучения нейросети наглядно продемонстрирован рост целевой метрики, характеризующей точность локализации стеноза.

Видно, что, начиная с двадцать пятой эпохи, происходит значительное повышение качества определения области стеноза на изображениях, достигающее к сотой эпохе — 0,94 по метрике mAP. В целом, процесс обучения стабилизировался именно к сотой итерации и не приводил к дальнейшему росту данного показателя (Рис. 2). Общее время обучения составило 23,2 часа.

Подробный анализ подтверждает, что алгоритм увеличивает качество детекции с ростом итерации обучения, при этом рост происходит плавно, без значимых флуктуаций, то есть поиск локального минимума функции потерь происходит с оптимальными настройками. Исследование работы нейросети на валидационном и тестовом наборе данных продемонстрировало схожие значения метрики mAP: 0,93 и 0,94, соответственно. Стоит предполагать, что такой результат свидетельствует об отсутствии переобучения, обеспеченного техникой Early stopping. Помимо количественного анализа более примечателен качественный анализ результатов локализации. Показано, что использованная нейросеть в большинстве случаев определяет стенозированные участки сосудов в областях, соответствующих размеченным данным (Рис. 3),

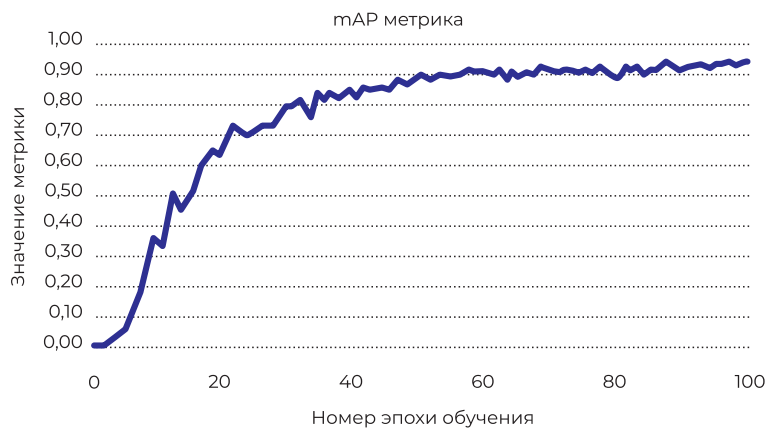


Рисунок 2 — Изменение эффективности работы модели в ходе обучения.




Рисунок 3 — Примеры работы нейросети.




Рисунок 4 — Ложноположительные результаты работы нейросети.

располагая соответствующие метки на изображениях в местах стенозов.

Однако в ряде случаев нейросеть срабатывает ложноположительно, то есть определяет участок стеноза в том месте, где его не должно быть. Такие эффекты наблюдали для 75 кадров (3,75% от всей совокупности изображений). Распределение таких случаев между выборками в целом не носило системного характера: 49 кадров (3,5%) для обучающего; 12 кадров (4%) для валидационного; 14 кадров (4,67%) для тестового набора. Некоторые примеры подобных ошибок приведены на рис. 4.

Кроме того, на 43 снимках (2,15%) алгоритм не определял участки стеноза при их наличии. В данных случаях нейросеть в целом не располагала предсказания на изображения и такое вычисление не зависело от порога метрики mAP. Примечательно, что и в этих случаях не наблюдали системности в формировании таких ошибок, так как их наблюдали для 27 кадров (1,93%) обучающей, 7 кадров (2,33%) валидационной, 9 кадров (3%) тестовой выборки.

Немаловажным критерием производительности работы представленной нейросети стало время анализа одного снимка, которое составило 0,099 с, что, таким образом, обеспечивает обработку 10 кадров/с.

ОБСУЖДЕНИЕ

Особенностью обработки клинических данных с перспективой прикладного

диагностического применения являются ошибки детекции — ложные срабатывания [14; 15], в ложноположительных случаях определяющие для пациента необходимость проведения вмешательства, которое в действительности не требуется, а в ложноотрицательных случаях приводят к «недополучению» жизнеспасующей процедуры. Именно наличие такого критерия и несоответствие ему современных нейросетей задерживает внедрение систем поддержки врачебных решений на основе математических алгоритмов в клиническую практику, в особенности в интервенционной кардиологии. Основной мотивацией настоящего исследования стала минимизация риска ложных детекций стенозов коронарных артерий путем использования более актуальной архитектуры, чем представленной в ранних аналогичных работах [9]. Мы смогли продемонстрировать такую точность локализации, равную 0,94 по метрике mAP, что превосходит результаты Wu с соавт., которым удалось достичь значения 0,872 [9]. Полученные в настоящем исследовании результаты в большей степени соответствуют критериям качества обработки медицинских данных. В своей работе зарубежные коллеги акцентируют особое внимание на ложноположительных случаях, в особенности при множественном неправильном срабатывании нейросети: ряд снимков, наряду с верной локализацией стеноза, имеет по две ошибки, значительно «утяжеляющих» таким образом диагноз

пациента. Подобная недостаточная точность работы U-net алгоритма и наличие настолько «грубых» ошибок возможно обусловлены «возрастом» нейросети, которую разработали еще в 2015 году [16]. Для сравнения: использованная в нашем исследовании архитектура RFCN ResNet-101 V2 описана в работе 2019 года [11]. Тем не менее полностью исключить ошибки в нашем исследовании также не удалось: мы наблюдали как ложные детекции стенозов (ложное повышение тяжести состояния пациента), так и отсутствие выявления патологического участка (недооценка тяжести состояния пациента). Одним из методов борьбы с подобными ошибками может стать интеграция в анализ коронарографии сведений с соседних кадров записи. Так как в ходе диагностической процедуры получают не отдельные изображения, а видеозапись, то возможно отслеживать, определяет ли нейросеть на предыдущем (i-1) и последующем (i+1) кадрах участки стеноза, чтобы сделать предположение о верной детекции на промежуточном (i-том) кадре. Подобный анализ может включать 1-3-5 окружающих кадров и корректировать результат работы алгоритма. Безусловно возникают некоторые трудности с началом контрастирования и его окончанием, для которых окружающие кадры еще (или уже) не содержат сведений о стенозах, однако в целом подобный подход может значительно повысить точность работы исследованной нейросети.

Вторым важным аспектом, рассмотренным в настоящей работе, явилась скорость работы алгоритма. Показано, что использование сложной «тяжеловесной» архитектуры привело к малой скорости обработки данных — 10 кадров/с. При этом клинические данные коронарографии записывают со скоростью 12,5–14 кадров/с, в связи с чем, предположительно, выбранная архитектура (RFCN ResNet-101 V2) не способна обеспечить анализ в реальном времени, что безусловно требует дальнейшей разработки. Включение в последовательность обработки дополнительных техник повышения производительности, в том числе препроцессинга изображений, сужение области поиска коронарной артерии, выделение только контрастных элементов на снимке — способны повысить скорость анализа с сохранением качества детекции.

ОГРАНИЧЕНИЯ ИССЛЕДОВАНИЯ

Настоящая работа демонстрирует пример применения нейросетевого алгоритма для обработки данных коронарной ангиографии только с одним патологическим участком, что безусловно не отражает всей вариативности и сложности диагностического процесса, который проводит интервенционный кардиолог при обследовании пациента с ишемической болезнью сердца. Наиболее ценной для прикладного применения может стать система, одновременно определяющая два и более стенозов, вычисляющая их детальные характеристики, поддерживающая принятие врачебных решений. Однако без исследования особенностей основных этапов работы нейросети, оценки ее качества и точности, определения требующих оптимизации «узких мест» алгоритма приблизиться к созданию «идеальной» системы невозможно. Именно поэтому мы демонстрируем собственный первичный задел и основные дальнейшие направления работы в этой области для перспектив создания более продвинутой системы автоматической обработки коронарной ангиографии.

ЗАКЛЮЧЕНИЕ

В рамках настоящего исследования с целью выявления одноочаговых стенозов артерий проведено обучение перспективного нейросетевого детектора RFCN ResNet-101 V2 на клинических ангиографических данных. Показано, что данная архитектура способна обеспечить высокую точность локализации стенозированного участка на изображении (до 94%), однако вследствие своей сложности не способна провести анализ в режиме реального времени, то есть не обеспечивает достаточную производительность. Дальнейшие работы по оптимизации входных данных для анализа или использованию вспомогательных техник способны повысить точность и скорость работы алгоритма, что оставляет возможность создать надежный и быстрый инструмент-помощник для интервенционной кардиологии.

Источник финансирования. Исследование выполнено в рамках Комплексной научно-технической программы полного инновационного цикла «Разработка и внедрение комплекса технологий в области разведки и добычи твердых

полезных ископаемых, обеспечения промышленной безопасности, биоремедиации, создания новых продуктов глубокой переработки из угольного сырья при последовательном

снижении экологической нагрузки на окружающую среду и рисков для жизни населения» (утв. Распоряжением Правительства РФ от 11 мая 2022 г. №1144-р).

ЛИТЕРАТУРА/REFERENCES

1. Сердечно-Сосудистая Хирургия — 2018. Болезни и врожденные аномалии системы кровообращения / Под ред. Бокерия Л.А., Милиевской Е.Б., Кудзоевой З.Ф., Прянишникова В.В., Скопина А.И., Юрлова И.А. — М.: ФГБУ «НМИЦССХ им. А.Н. Бакулева» МЗ РФ, 2019. [Bokeriya LA, Milievskaya EB, Kudzoeva ZF, Pryanishnikov VV, Skopin AI, Yurlov IA, editors. Cardiovascular Surgery - 2018. Diseases and congenital abnormalities of circulatory system. Moscow: NMITsSSKh im. A.N. Bakuleva. 2019. (In Russ).]
2. Khan MA, Hashim MJ, Mustafa H, et al. Global Epidemiology of Ischemic Heart Disease: Results from the Global Burden of Disease Study. *Cureus*. 2020; 12(7): e9349. doi:10.7759/cureus.9349.
3. Gu D, Qu J, Zhang H, et al. Revascularization for Coronary Artery Disease: Principle and Challenges. 2020: 75-100. doi:10.1007/978-981-15-2517-9_3.
4. Тарасов Р.С., Ганюков В.И. Прогностическая роль исходной и резидуальной выраженности коронарного атеросклероза у пациентов с инфарктом миокарда после первичного чрескожного коронарного вмешательства // Комплексные проблемы сердечно-сосудистых заболеваний. — 2016. — Т5. — №4. — С.6-14. [Tarasov RS, Ganyukov VI. Prognostic role of initial and residual severity of coronary atherosclerosis in myocardial infarction patients undergoing primary percutaneous coronary intervention. *Complex Issues of Cardiovascular Diseases*. 2016; 5(4): 6-14. (In Russ).] doi: 10.17802/2306-1278-2016-4-6-14.
5. Sutton RT, Pincock D, Baumgart DC, et al. An overview of clinical decision support systems: benefits, risks, and strategies for success. *npj Digit Med*. 2020; 3(1): 17. doi:10.1038/s41746-020-0221-y.
6. Shahzad R, Kirişli H, Metz C, et al. Automatic segmentation, detection and quantification of coronary artery stenoses on CTA. *Int J Cardiovasc Imaging*. 2013; 29(8): 1847-1859. doi:10.1007/s10554-013-0271-1.
7. Wang C, Moreno R, Smedby Ö. Vessel Segmentation Using Implicit Model-Guided Level Sets. In: MICCAI 2012.
8. Broersen A, Kitslaar PH, Frenay M, et al. FrenchCoast: Fast, Robust Extraction for the Nice CHallenge on COronary Artery Segmentation of the Tree. 2012.
9. Wu W, Zhang J, Xie H, et al. Automatic detection of coronary artery stenosis by convolutional neural network with temporal constraint. *Comput Biol Med*. 2020; 118: 103657. doi:10.1016/j.combiomed.2020.103657.
10. Леонова В.О., Кочергина А.М., Барбараш О.Л. Клинический портрет пациента перед плановым чрескожным коронарным вмешательством в условиях реальной практики // Кардиология. — 2020. — Т.60. — №4. — С.31-35. [Leonova VO, Kochergina AM, Barbarash OL. Clinical Portrait of The Patient before the Planned Percutaneous Coronary Intervention in Conditions of Real Practice. *Kardiologiya*. 2020; 60(4): 31-35. (In Russ).] doi: 10.18087/cardio.2020.4.n937.
11. Лобанова 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. [Lobanov MG, Sholomov DL. On the acceleration of the convolutional neural network architecture based on resnet in the task of road scene objects recognition. 2019; 3: 57-65. (In Russ).] doi:10.14357/20718632190305.
12. Rice L, Wong E, Kolter JZ. Overfitting in adversarially robust deep learning [Internet]. 2020 [cited 2022 June 27] Available at: <https://arxiv.org/abs/2002.11569>.

13. Zaidi SSA, Ansari M.S, Aslam A, Kanwal N, Asghar M, Lee B. A Survey of Modern Deep Learning based Object Detection Models. [Internet]. 2021 [cited 2022 June 27] Available at: <https://arxiv.org/abs/2104.11892>.
14. Brnabic A, Hess LM. Systematic literature review of machine learning methods used in the analysis of real-world data for patient-provider decision making. *BMC Med Inform Decis Mak.* 2021; 21(1): 54. doi:10.1186/s12911-021-01403-2.
15. Jankovic I, Chen JH. Clinical Decision Support and Implications for the Clinician Burnout Crisis. *Yearb Med Inform.* 2020; 29(1): 145-154. doi:10.1055/s-0040-1701986.
16. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation [Internet]. 2015 [cited 2022 Apr 29] Available at: <https://arxiv.org/abs/1505.04597>.