

## НЕЧЁТКИЕ ПРОДУКЦИОННЫЕ ПРАВИЛА И НЕЙРОСЕТИ ГЛУБОКОГО ОБУЧЕНИЯ: ОБЪЯСНИМЫЙ ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ 2.0 ДЛЯ ДИАГНОСТИКИ КОРОНАРНЫХ СТЕНОЗОВ

Трофимов Юрий Владиславович<sup>1</sup>, Семашко Владимир Сергеевич<sup>2</sup>,  
Муравьев Иван Павлович<sup>3</sup>, Кузнецов Егор Михайлович<sup>4</sup>,  
Аверкин Алексей Николаевич<sup>5</sup>

<sup>1</sup>Аспирант;

Государственный университет «Дубна»;

Россия, 141980, Московская обл., г. Дубна, ул. Университетская, 19;

Программист;

Объединенный институт ядерных исследований;

Россия, 141980, Московская обл., г. Дубна, ул. Жолио-Кюри, 6;

e-mail: ura\_trofim@bk.ru.

<sup>2</sup>Студент;

Государственный университет «Дубна»;

Россия, 141980, Московская обл., г. Дубна, ул. Университетская, 19;

Лаборант;

Объединенный институт ядерных исследований;

Россия, 141980, Московская обл., г. Дубна, ул. Жолио-Кюри, 6;

e-mail: semashkovs@jinr.ru.

<sup>3</sup>Студент;

Государственный университет «Дубна»;

Россия, 141980, Московская обл., г. Дубна, ул. Университетская, 19;

e-mail: mip.22@uni-dubna.ru.

<sup>4</sup>Студент;

Государственный университет «Дубна»;

Россия, 141980, Московская обл., г. Дубна, ул. Университетская, 19;

e-mail: ket.22@uni-dubna.ru.

<sup>5</sup>Кандидат физико-математических наук, доцент;

Государственный университет «Дубна»;

Россия, 141980, Московская обл., г. Дубна, ул. Университетская, 19;

Ведущий научный сотрудник;

Федеральный исследовательский центр «Информатика и управление» Российской Академии Наук;

Россия, Московская обл., г. Москва, ул. Вавилова, 44/2;

e-mail: averkin2003@inbox.ru.

В статье предлагается мультиуровневый подход к диагностике коронарных стенозов, основанный на глубоком обучении и нечёткой логике. Рассматриваются проблемы нехватки размеченных данных, решается путем доаннотации датасета CADICA. Реализован алгоритм, включающий сегментацию сосудов с помощью модифицированной сверточной сети U-Net и CRF, дополненный методами ХАИ (Grad-CAM, LIME, Score-CAM). Добавлен нейро-нечёткий модуль ANFIS для преобразования активаций модели в правила. Подход обеспечивает высокую точность сегментации ( $Dice \approx 0,84$ ;  $IoU \approx 0,78$ ) и надежность диагностики даже при слабо выраженной патологии. Полученные результаты подтверждают повышение доверия специалистов благодаря интеграции механизмов объяснимого ИИ.

Работа выполнена в рамках государственного задания Министерства науки и высшего образования Российской Федерации (тема № 124112200072-2).

**Ключевые слова:** Эхокардиография; сегментация изображений; глубокие нейронные сети; объяснимый искусственный интеллект; нейро-нечёткие системы; коронарные стенозы.



Статья находится в открытом доступе и распространяется в соответствии с лицензией Creative Commons «Attribution» («Атрибуция») 4.0 Всемирная (CC BY 4.0) <https://creativecommons.org/licenses/by/4.0/deed.ru>

**Для цитирования:**

Нечёткие продукционные правила и нейросети глубокого обучения: объяснимый искусственный интеллект 2.0 для диагностики коронарных стенозов / Ю. В. Трофимов, В. С. Семашко, И. П. Муравьев [и др.] // Системный анализ в науке и образовании: сетевое научное издание. 2025. № 2. С. 73-82. EDN: ONRAKG. URL: <https://sanse.ru/index.php/sanse/article/view/667>.

**FUZZY PRODUCTION RULES AND DEEP LEARNING NEURAL NETWORKS:  
EXPLICABLE ARTIFICIAL INTELLIGENCE 2.0 FOR CORONARY STENOSIS  
DIAGNOSIS**

**Trofimov Yuri V.<sup>1</sup>, Semashko Vladimir S.<sup>2</sup>, Muravyov Ivan P.<sup>3</sup>, Kuznetsov Egor M.<sup>4</sup>, Averkin Alexey N.<sup>5</sup>**

<sup>1</sup>PhD student;

Dubna State University

19 Universitetskaya Str., Dubna, Moscow region, 141980, Russia;

Programmer;

Joint Institute for Nuclear Research;

6 Joliot-Curie Str., Dubna, Moscow region, 141980, Russia;

e-mail: [ura\\_trofim@bk.ru](mailto:ura_trofim@bk.ru).

<sup>2</sup>Student;

Dubna State University;

19 Universitetskaya Str., Dubna, Moscow region, 141980, Russia;

Laboratory Assistant;

Joint Institute for Nuclear Research;

6 Joliot-Curie Str., Dubna, Moscow region, 141980, Russia;

e-mail: [semashkovs@jinr.ru](mailto:semashkovs@jinr.ru).

<sup>3</sup>Student;

Dubna State University;

19 Universitetskaya Str., Dubna, Moscow region, 141980, Russia;

e-mail: [mip.22@uni-dubna.ru](mailto:mip.22@uni-dubna.ru).

<sup>4</sup>Student;

Dubna State University;

19 Universitetskaya Str., Dubna, Moscow region, 141980, Russia;

e-mail: [kem.22@uni-dubna.ru](mailto:kem.22@uni-dubna.ru).

<sup>5</sup>PhD in Physical and Mathematical Sciences, associate professor;

Dubna State University;

19 Universitetskaya Str., Dubna, Moscow region, 141980, Russia;

Leading Research Scientist;

Federal Research Center «Computer Science and Control» Russian Academy of Sciences;

44/2 Vavilov Str., Moscow, 119333, Russia;

e-mail: [averkin2003@inbox.ru](mailto:averkin2003@inbox.ru).

*The article proposes a multi-level approach to diagnosing coronary stenosis based on deep learning and fuzzy logic. It addresses problems of insufficient labeled data through additional annotation of the CADICA dataset. An algorithm has been implemented including vessel segmentation using a modified U-Net network and CRF, augmented with XAI methods (Grad-CAM, LIME, Score-CAM). A neuro-fuzzy module ANFIS transforms model's activations into rules. The approach provides high segmentation accuracy (Dice  $\approx 0.84$ ; IoU  $\approx 0.78$ ) and diagnostic reliability even in subtle pathology cases. Results confirm in-creased expert trust due to integration of explainable AI mechanisms.*

*The work was performed within the framework of the state assignment of the Ministry of Science and Higher Education of the Russian Federation (topic No. 124112200072-2).*

**Keywords:** Echocardiography; image segmentation; deep neural networks; explicable artificial intelligence; neuro-fuzzy systems; coronary stenoses.

**For citation:**

Trofimov Yu. V., et al. Fuzzy production rules and deep learning neural networks: explicable artificial intelligence 2.0 for the diagnosis of coronary stenosis. *System analysis in science and education*, 2025; (2): 73-82 (in Russ). EDN: ONRAKG. Available from: <https://sanse.ru/index.php/sanse/article/view/667>.

**Введение**

Ишемическая болезнь сердца (ИБС) – одно из наиболее распространённых сердечно-сосудистых заболеваний и ведущая причина смертности во всём мире [1]. Своевременная диагностика ИБС и коронаросклероза критична для предотвращения тяжёлых осложнений, однако ручной анализ медицинских изображений (эхокардиография, коронарная ангиография и др.) требует значительных трудозатрат и высокой квалификации врача. В настоящее время активно развиваются методы автоматизации диагностики с использованием искусственного интеллекта, однако их применение в кардиологии сдерживается рядом факторов. Во-первых, глубокие нейронные сети требуют больших объёмов размеченных данных, тогда как общедоступные датасеты эхокардиографии редко содержат разметку коронарных артерий и связанных патологий. Во-вторых, «чёрный ящик» нейросетевых моделей затрудняет их клиническое применение из-за отсутствия прозрачности и интерпретируемости результатов. Таким образом, возникает потребность в подходе, сочетающем высокую точность глубокого обучения с механизмами объяснимого ИИ (XAI[2]), который позволил бы врачу понять логику работы алгоритма.

Анализ известных решений показывает, что стандартные методы сегментации сердечных структур (например, камеры сердца на ЭхоКГ) активно развиваются [3], но применительно к коронарным сосудам открытые данные практически отсутствуют. Существующие крупные эхокардиографические базы, такие как *EchoNet-Dynamic* [4] и *CAMUS* [3], содержат тысячи видео и изображений, однако фокусируются преимущественно на функциях сердца (например, расчёт фракции выброса) и не имеют размеченных коронарных артерий. Коронарография (инвазивная ангиография) остаётся золотым стандартом визуализации коронарного русла, но и в этой области долгое время не было общедоступных датасетов достаточного объёма [5][6]. Отсутствие данных с готовой разметкой атеросклеротических поражений приводит к тому, что модели глубокого обучения приходится обучать на ограниченных выборках или выполнять трудоёмкую ручную аннотацию. Кроме того, классические *CNN*-модели недостаточно объяснимы для врачей: даже если нейросеть точно сегментирует сосуд или классифицирует степень стеноза, врачу важно знать, почему алгоритм принял то или иное решение. Ряд подходов для объяснения решений нейросетей (*Grad-CAM*[7], *LIME*[8], *SHAP*[9] и др.) позволяют подсветить важные области изображения, однако они дают лишь постфактум визуализацию и не интегрированы напрямую в вывод модели. Необходим более продвинутый подход к объяснимости, сочетающий визуальные пояснения с формализованными правилами, понятными эксперту.

Цель работы – разработка интерпретируемой системы диагностического анализа, объединяющей методы глубокой сегментации изображений с нечётко-логическими моделями объяснения для поддержки врача при выявлении коронарных стенозов. Для достижения этой цели решены следующие задачи: 1) анализ и выбор подходящего датасета эхокардиографических изображений; 2) предобработка данных и аннотирование признаков коронарных поражений; 3) разработка модели сегментации коронарных артерий (модифицированный *U-Net*) и реализация методов визуализации внимания нейросети (*Grad-CAM*, *LIME*, *Score-CAM*); 4) построение нейро-нечёткой системы на основе правил (*ANFIS*[10], *Fuzzy Production Rules*[11]) для интерпретации результатов; 5) генерация текстовых дескрипторов и формирование заключения на принципах мультимодального объяснимого ИИ (*MXAI*). Ниже подробно описаны этапы предложенного решения.

**1. Обзор и выбор ЭхоКГ-датасетов**

Для разработки алгоритма был необходим набор данных, содержащий изображения сердца с отображением коронарных сосудов и признаков ишемии. В рамках исследования проведён всесторонний анализ публичных ресурсов медицинских изображений сердца. Рассматривались доступные эхокардиографические датасеты (*EchoNet-Dynamic*, *CAMUS* и др.), которые отличаются большим объёмом и разнообразием режимов сканирования (В-режим, доплерография, стресс-Эхо и

др.) Однако выяснилось, что ни один из этих датасетов не содержит разметки коронарных артерий или атеросклеротических бляшек – они ориентированы на другие задачи (например, сегментацию полостей сердца или измерение кинетики миокарда). По совокупности критериев (размер выборки, вариативность данных, наличие метаданных) было решено использовать датасет *CADICA* – новый общедоступный набор данных, посвящённый диагностике ишемической болезни сердца. Датасет *CADICA* представляет собой коллекцию видеозаписей инвазивной коронарной ангиографии 42 пациентов с соответствующими метаданными о заболеваниях. Данный набор удовлетворяет требованиям универсальности и репрезентативности, так как включает различные варианты поражений коронарных артерий. Важным отличием *CADICA* является наличие клинических заключений к некоторым записям, что позволило использовать эти текстовые данные на этапе объяснения решений системы. При этом исходные изображения в *CADICA* не имели готовых сегментационных масок, поэтому потребовалось выполнить собственную аннотацию коронарных структур (см. рис. 1).



Рис. 1. Коронарные структуры в наборе данных

## 2. Предобработка и аннотирование данных

Выбранный датасет включал значительное число кадров, не несущих диагностической нагрузки (например, фрагменты видео без контрастного заполнения сосуда). Для фильтрации данных на втором этапе была применена предварительная классификация изображений с помощью сверточной сети *ResNet-34*. Эта модель разбивала кадры на диагностически значимые и нейтральные, учитывая наличие или отсутствие патологических изменений. Кроме того, визуализация результатов классификации методами *Grad-CAM* и *LIME* помогла убедиться, что модель фокусируется на областях, соответствующих расположению коронарных артерий, тем самым обосновывая отбор ключевых кадров.

Далее был реализован многоэтапный пайплайн предобработки изображений для улучшения качества последующей сегментации. В рамках этого пайплайна выполнялось подавление спекл-шумов (характерных для ультразвуковых изображений) с помощью нелинейных фильтров, а также локальное выравнивание контраста методом *CLAHE* (*Contrast Limited Adaptive Histogram Equalization*) для усиления слабо выраженных границ сосудов. Затем применялись морфологические операции (эрозия, дилатация), учитывающие топологию коронарного русла, с целью устранения мелких артефактов и заполнения просвета сосудов. Поскольку ангиографические изображения отличаются сложной анатомической конфигурацией сосудистой сети и неоднородностью сигнала, автоматическая обработка дополнялась тщательной ручной экспертизой. В частности, в сложных случаях – в зонах с низким контрастом или при наложении проекций других тканей – проводилась дополнительная корректировка масок врачом-экспертом. Для первичного автоматического выделения контуров сосудов мы также протестировали разные методы детектирования границ. Наилучший результат показало использование оператора Собела: маски, сформированные на основе *Sobel*-фильтра, после последующей фильтрации обеспечили чёткое выделение коронарных стенок (см. рис. 2).

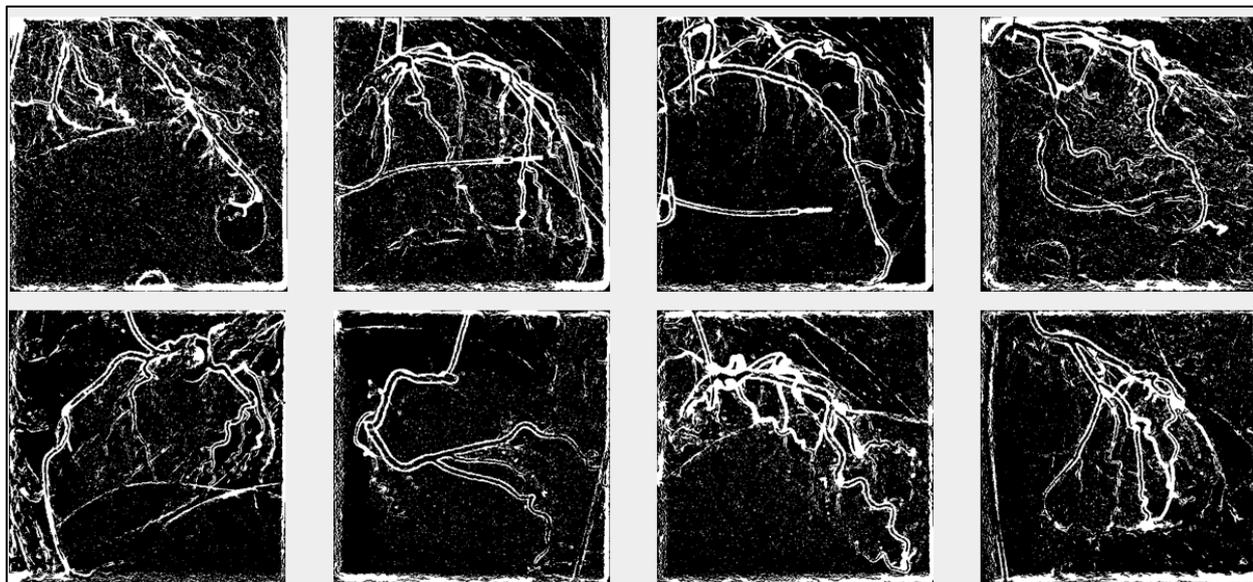


Рис. 2. Пример маски Собела

Финальные сегментационные маски включали разметку просвета и стенок коронарных артерий, областей стенозов (сужений сосуда) и атероматозных бляшек. Эти маски послужили основой для обучения и проверки алгоритмов сегментации.

### 3. Сегментация и визуализация

На четвертом этапе основным объектом исследования стала задача сегментации коронарных артерий на ангиографических изображениях. Были проведены эксперименты с широким спектром архитектур сегментационных нейросетей – от классических энкодер-декодеров на основе свёрточных сетей (*U-Net*, *SegNet*, *DeepLabV3*) до облегчённых моделей (*MobileNet-ENC* и др.). По результатам сравнительного анализа выбран модифицированный *U-Net* с интегрированным механизмом уточнения контуров и последующим постпроцессингом на основе *Conditional Random Field* (см. рис. 3).

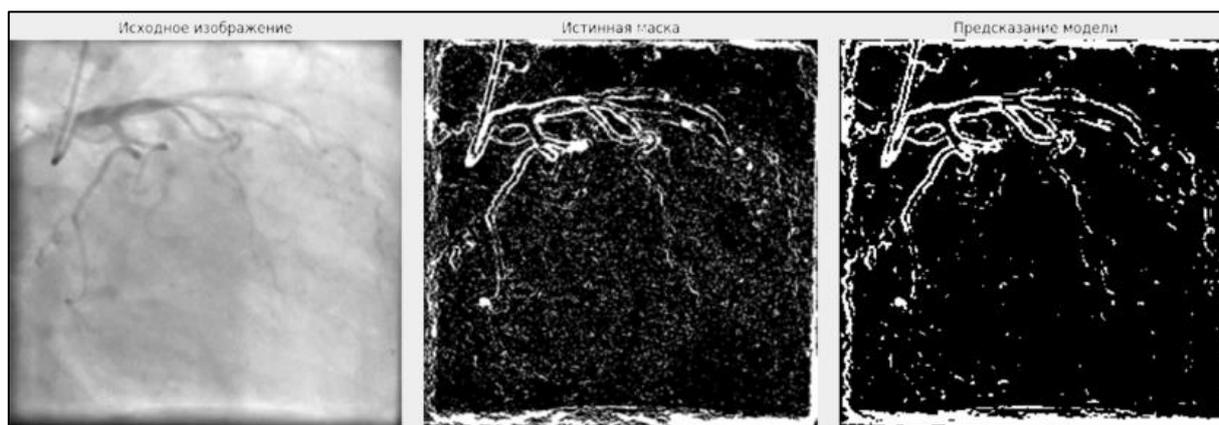


Рис. 3. Результат работы *U-Net*

В данной модификации реализована многошаговая итеративная стратегия (*MSI*): на первом шаге свёрточная нейросеть выделяет грубые области интереса (*ROI*), соответствующие расположению крупных сосудистых ветвей, а затем дополнительный декодирующий блок уточняет контуры в локальных областях, сложных для сегментации (низкоконтрастные сегменты, зоны наложения тканей). Такой подход позволил достичь более тонкого распознавания границ сосудов и снизить вероятность пропуска «скрытых» стенозов. После применения *CRF*-постобработки улучшилась согласованность предсказанных масок с анатомическими контурами. Выбранная модель продемонстрировала наибольшую точность: по метрикам сегментации достигнут коэффициент

$Dice \sim 0,84$  и индекс  $Jaccard (IoU) \sim 0,78$ , что превосходит результаты других протестированных архитектур. Особенно заметно преимущество  $U-Net + CRF$  проявилось при выделении тонких дистальных ветвей коронарного русла – альтернативные модели либо теряли эти элементы, либо сегментировали их фрагментарно. Отметим, что некоторые облегчённые архитектуры (например,  $MobileNet-ENC$ ) показали близкие результаты на основных сосудах, что указывает перспективность их применения на устройствах с ограниченными ресурсами. Тем не менее, выбранный нами многоэтапный подход обеспечил оптимальное сочетание полноты и детальности сегментации, удовлетворяющее целям клинического использования.

Для обеспечения интерпретируемости сегментационных результатов в систему интегрированы современные методы объяснимого ИИ. На этапе классификации кадров применялись  $Grad-CAM$  и  $LIME$ , которые позволили визуализировать, какие участки изображения наиболее сильно влияли на решение нейросети.  $Grad-CAM$  ( $Gradient-weighted Class Activation Mapping$ ) генерирует тепловую карту, выделяющую регионы, вносящие наибольший вклад в предсказание класса, а  $LIME$  ( $Local Interpretable Model-Agnostic Explanations$ ) выявляет значимые супиксельные области путем локального переобучения модели на искаженных вариантах изображения. В нашем случае  $Grad-CAM$  проецировала активации  $ResNet-34$  на исходный кадр, подсвечивая область прохождения коронарного сосуда, что совпадало со знанием эксперта.  $LIME$  дополнила эту картину, наглядно показав, что наличие контрастированного сегмента артерии является ключевым признаком для классификатора.

Для пояснения работы сегментационной модели были опробованы несколько методов визуализации активаций сверточной сети ( $Layers-Cam$ ,  $Score-CAM$  и др.).  $Score-CAM$  ( $Score-Weighted CAM$ ) зарекомендовал себя как наиболее эффективный подход при анализе тонких структур сосудов. В отличие от  $Grad-CAM$ , метод  $Score-CAM$  не использует градиенты, а измеряет изменение уверенности модели при локальном перекрытии различных частей изображения. В результате формируется карта внимания, чётко выделяющая значимые участки – в нашем случае область выявленного стеноза на маске сосуда (см. рис. 4).

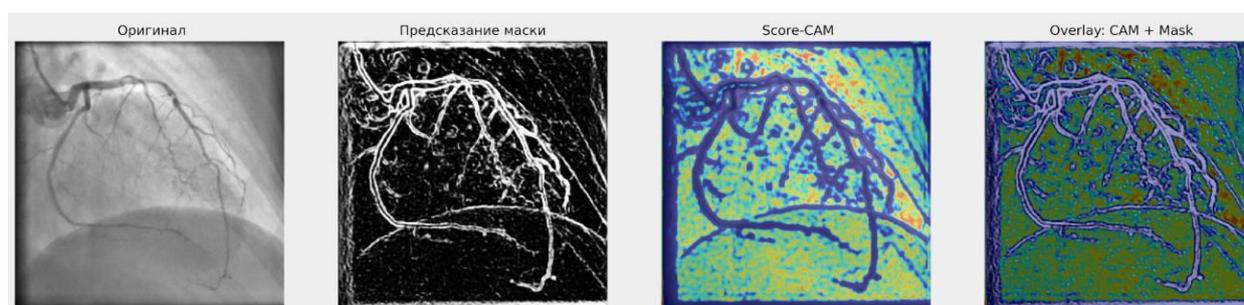


Рис.4. Карта внимания модели на маске сосуда

Применение  $Score-CAM$  обеспечило высокую точность локализации патологических областей и позволило связать предсказанную сегментацию с исходным изображением: на финальных визуализациях наложение маски коронарного дерева и тепловой карты внимания ясно указывало врачу, где именно модель «нашла» проблемный участок. Такой расширенный XAI-подход выходит за рамки простой подсветки  $ROI$  и служит основой для дальнейшей символической интерпретации результатов нейросети.

#### 4. Построение нейро-нечёткой системы

Для превращения «чёрного ящика» нейросетевой модели в прозрачную для понимания систему нами разработан модуль объяснения на основе нечёткой логики. На шестом этапе создана нейро-нечёткая подсистема типа  $ANFIS$  ( $Adaptive Neuro-Fuzzy Inference System$ ), предназначенная для интерпретации результатов сегментации и активационных карт. Данный модуль интегрирован в общий конвейер после получения нейросетевого предсказания и XAI-визуализаций. Основная идея состоит в представлении решения глубокого алгоритма в виде понятных правил вида «ЕСЛИ-ТО» с использованием лингвистических переменных.

На первом шаге строится база нечётких продукционных правил ( $Fuzzy Production Rules, FPR$ ),

отражающих выявленные моделью закономерности. Правила формируются на основе признаков, извлечённых из изображений: например, можно сформулировать правило «ЕСЛИ протяжённость стеноза большая И контрастность поражённого сегмента низкая, ТО степень стеноза оценивается как значительная». Каждое такое правило имеет числовую оценку активации (значение *firing strength*), вычисляемую на основе выхода нейросети. В разработанном нами XAI-модуле осуществляется отображение активных правил для каждого случая, что позволяет пользователю (врачу или эксперту) увидеть, какие логические суждения лежат в основе вывода системы. Правила ранжируются по степени внесённого вклада, и специалист может проанализировать, совпадает ли такая последовательность вывода с его собственными представлениями о патофизиологии.

Применение нечётко-логического аппарата дало возможность учесть нечеткость и неопределённость, присущие медицинским данным. В отличие от жёстких пороговых критериев, нечёткие правила оперируют степенями принадлежности – это соответствует характеру клинического мышления, где многие понятия (например, «умеренный стеноз») не имеют строгих границ. Наш модуль *ANFIS* выполняет двойную роль: с одной стороны, он повышает доверие пользователя к системе, раскрывая внутреннюю логику, а с другой – усиливает надёжность самого алгоритма. Последнее достигается за счёт того, что вывод нейросети дополнительно проходит через проверку набором правил, основанных на экспертных знаниях (онтологии коронарных патологий). В результате некоторые граничные случаи, которые могли бы быть ошибочно интерпретированы *CNN* при недостаточном контрасте, корректируются или помечаются как неопределённые, если нечёткая система указывает на противоречие. Подобный гибридный подход соответствует концепции XAI 2.0, предполагающей сочетание субсимвольных (нейросетевых) и символьных (логических) методов для достижения более глубокой объяснимости решений ИИ (см. рис. 5).

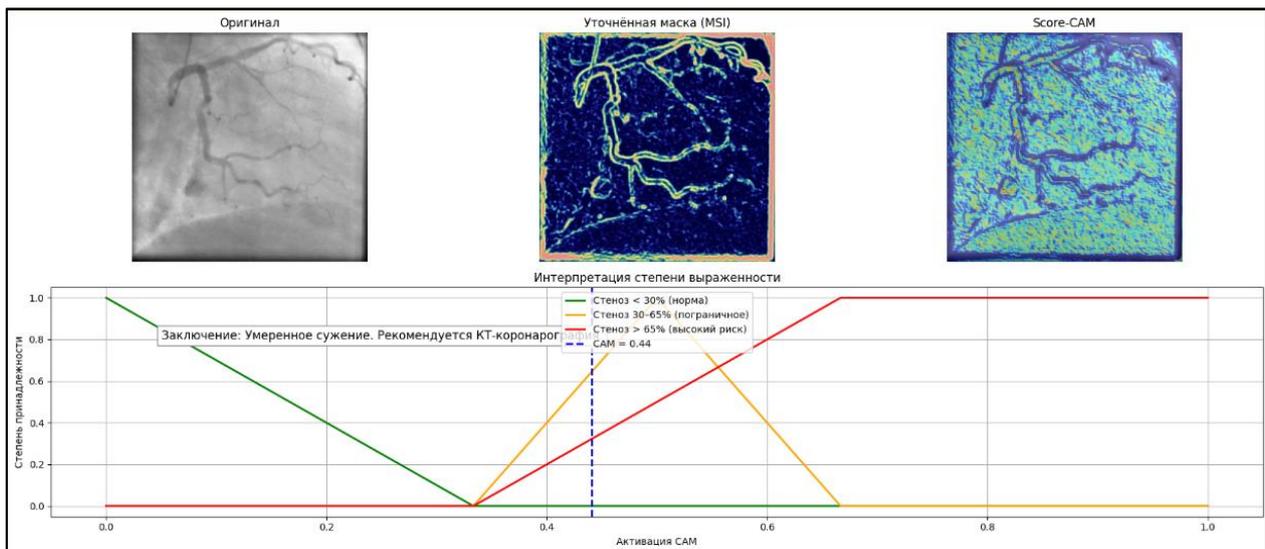


Рис. 5. Интерфейс приложения с использованием нечёткой лингвистической переменной «активация CAM»

## 5. Генерация дескрипторов и формирование интерпретируемого заключения

После получения сегментационных масок, карт внимания и набора активных нечётких правил система переходит к формированию итогового заключения. На седьмом, заключительном этапе предложен механизм многоуровневой объяснимости, объединяющий визуальные и текстовые компоненты вывода. В качестве визуальной составляющей выступают изображения с наложенными сегментационными масками и тепловыми картами, которые демонстрируют локализацию обнаруженных патологий. Текстовая составляющая генерируется автоматически на основе выявленных признаков и активированных правил. Мы вводим понятие «мягких» дескрипторов – коротких текстовых фрагментов, описывающих ключевые находки в терминах, понятных врачу. Примером мягкого дескриптора может быть: «Обнаружен стеноз проксимального сегмента правой коронарной артерии, степень сужения около 70%». Подобные дескрипторы шаблонно формируются

на базе результатов сегментации (выделенный сегмент сосуда, его локализация и измеренная протяжённость поражения) и выводов ANFIS-модуля (оценка серьёзности стеноза с учётом нечётких правил).

Далее с помощью современной языковой модели (LLM) дескрипторы агрегируются в связный текст заключения. Финальный вывод представляет собой интерпретируемое пояснение, комбинирующее результаты работы всех модулей системы. Так, автоматически генерируемое заключение включает: (1) вывод модели сегментации о наличии и параметрах стеноза, (2) визуальное подтверждение в виде указания зоны внимания нейросети, (3) нечётко-логическое объяснение причин, повлиявших на решение (напрямую следующее из активных правил), и (4) обобщение на естественном языке, приближенное по форме к стандартному врачу заключению. Например, заключение может содержать фразу: «Алгоритм выявил гемодинамически значимый стеноз ПКА; внимание модели сфокусировано на этом участке сосуда, что подтверждено тепловой картой; на основании анализа признаков стеноз классифицируется как критический». Подобная мультимодальная подача результатов повышает когерентность классификации и снижает риск противоречивых выводов в сложных случаях, когда признаки патологии выражены слабо. Важным итогом является то, что врач получает не просто показатель или метку от алгоритма, а развернутую интерпретацию, подкреплённую одновременно изображением и текстом. Это облегчает восприятие информации и интеграцию системы в реальный клинический рабочий процесс. Мы разработали прототип веб-приложения, реализующего описанный функционал: пользователь загружает изображения, после чего приложение выполняет автоматическую сегментацию, оценивает степень стенозов и выводит сгенерированный отчет. Такой инструмент может быть встроен в инфраструктуру больницы (PACS/EMR-системы) для помощи врачу при описании исследований (см. рис. 6).

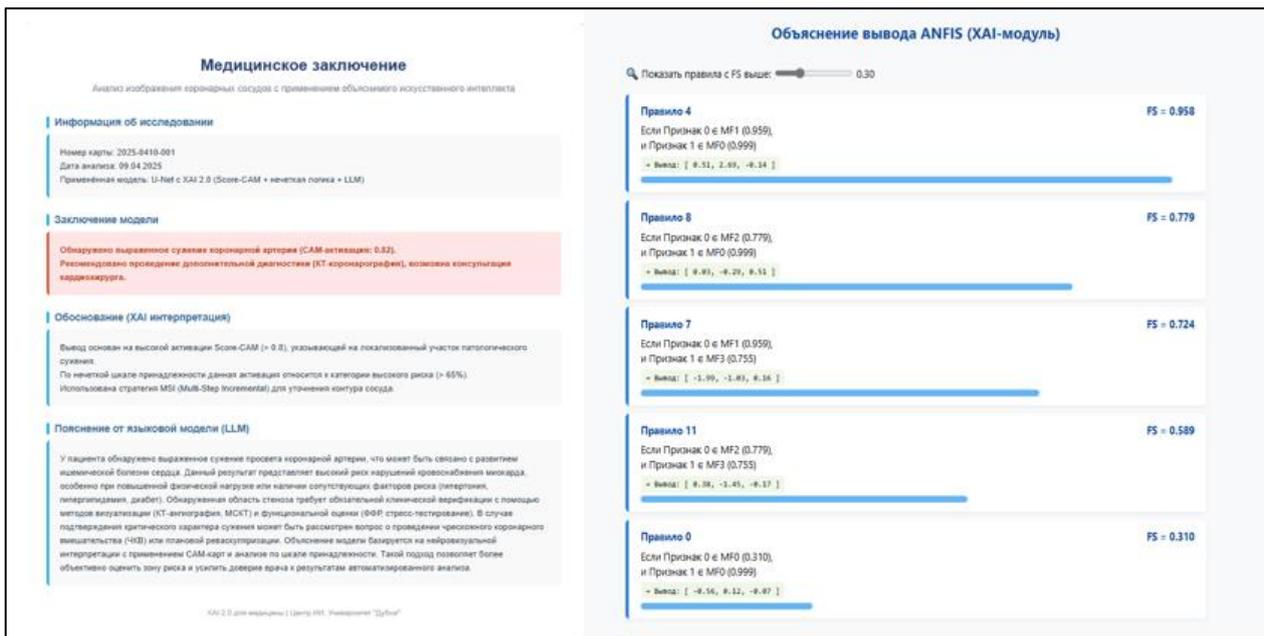


Рис. 6. Пример интерфейса программы

## 6. Результаты

Предложенный подход был апробирован на наборе изображений из датасета CADICA с ручной разметкой стенозов. Точность сегментации коронарного русла модифицированной моделью *U-Net* (с *CRF*) составила 0,84 по *Dice* и 0,78 по *IoU*, что свидетельствует о высоком качестве выделения как просвета сосудов, так и участков сужений. Для сравнения, базовая модель *U-Net* без дополнительного уточнения и без *CRF* показывала метрики порядка 0,80 (*Dice*) / 0,74 (*IoU*) на тех же данных, то есть усложнение архитектуры дало прирост около 4 процентных пунктов. Даже тонкие ветви дистальных отделов артерий были успешно сегментированы в большинстве случаев – визуальная оценка подтвердила высокую детальность получаемых масок.

Важным преимуществом системы стала её надёжность в сложных условиях. На изображениях с низким контрастом или частично перекрывающимися структурами классические сверточные сети нередко ошибаются (пропускают стеноз или выделяют ложноположительные области). В наших экспериментах интеграция нечётких правил повысила чувствительность к «скрытым» стенозам: система успешно обнаруживала поражения, едва заметные на оригинальном изображении, благодаря учёту дополнительных косвенных признаков через *FPR*. Например, если сегментационная модель понижала уверенность из-за шумов, но при этом правила указывали на нетипичную форму контура сосуда, итоговое заключение помечало участок как подозрительный. Таким образом, комбинация нейросети и *FPR* снизила вероятность пропуска патологий. Одновременно уменьшилось и число явных ошибок: нечёткая система фильтровала некоторые нетипичные ответы нейросети, не соответствующие медицинской логике (например, исключала сегментацию сосудов в областях, где анатомически не может быть коронарных артерий).

Сгенерированные системой интерпретируемые заключения были оценены кардиологом. По отзывам эксперта, выводы алгоритма в большинстве случаев совпадают с клинической картиной: местоположение и степень стеноза в отчёте соответствовали реальным поражениям, а объяснения (как визуальные, так и текстовые) оказались понятными и полезными. Особенно ценно, что заключение включает указание степени уверенности и причин, по которым сделан вывод – это позволяет врачу оценить, насколько надёжно то или иное обнаружение. Например, система сопровождает вывод о стенозе фразой о низком контрасте и необходимости дополнительной проверки, если правила показали неопределённость. Такой формат результатов делает алгоритм ближе к стилю работы врача-эксперта.

Подведём итог количественных показателей. Полный конвейер (*ResNet-34* классификация + *U-Net* сегментация + *XAI*-визуализация + *ANFIS*) продемонстрировал высокая качество: помимо упомянутых метрик сегментации, точность выявления наличия стеноза на уровне кадра превысила 90% при близкой к нулю доле ложноотрицательных случаев (благодаря осторожности нечётких правил). Среднее время обработки одного исследования составило около 2-3 секунд на *GPU*, что позволяет применять систему в режиме реального времени. Таким образом, результаты экспериментов подтверждают эффективность предложенного мультикомпонентного подхода: он обеспечивает одновременно высокую точность автоматического анализа и богатое интерпретируемое сопровождение, необходимое для клинического использования.

## Заключение

В работе разработана и экспериментально подтверждена концепция гибридной системы диагностики коронарных стенозов, сочетающей глубокое обучение и нечётко-логические модели в русле парадигмы объяснимого ИИ 2.0. Проведён комплексный обзор открытых датасетов медицинской визуализации сердца и обоснован выбор оптимальной базы данных (*CADICA*) для решения задачи сегментации коронарного русла. Предложен оригинальный сегментационный алгоритм на основе модифицированной архитектуры *U-Net* с многошаговым уточнением контуров и *CRF*-постобработкой, достигший высоких показателей качества ( $Dice > 0,8$ ). Разработаны методы визуализации внимания нейросети (*Grad-CAM*, *Score-CAM*) применительно к задаче детекции сосудистых поражений, показавшие свою информативность для медицинской интерпретации результатов.

Главным научно-практическим результатом является интеграция нейросетевого и нечётко-логического компонентов для объяснения решений алгоритма. Внедрение механизма *FPR* позволило преобразовать выход глубокого классификатора в систему продукционных правил, понятных человеку. Это существенно повысило объяснимость и прозрачность работы модели: специалист получил возможность проследить логику вывода через призму знакомых клинических понятий. В рамках системы реализован полнофункциональный прототип, автоматически формирующий мультимодальное медицинское заключение на основе объединения сегментированных изображений и сгенерированных текстовых дескрипторов. Такой человеко-ориентированный подход (*Human-Centric XAI*) облегчает интеграцию решений искусственного интеллекта в практическое здравоохранение, повышая доверие пользователей и эффективность совместной работы врача и ИИ.

Направления дальнейших исследований включают расширение базы знаний нечёткой системы и

обучающей выборки. Планируется увеличить объём данных за счёт включения новых случаев и мультицентровых данных, чтобы улучшить обобщающую способность модели. Представляет интерес адаптация разработанного подхода к другим видам медицинской визуализации, например, к внутрисосудистому ультразвуку (*IVUS*) или компьютерной томографии коронарных артерий, где также актуальны задачи сегментации атеросклеротических поражений и пояснения результатов. С точки зрения методологии *XAI*, перспективно дальнейшее развитие мультимодальных способов объяснения: интеграция не только визуальных и текстовых, но и количественных аналитических описаний (например, графиков риска) в единый вывод. Кроме того, в будущей работе предполагается провести более масштабную клиническую апробацию системы с участием нескольких независимых экспертов для статистической оценки влияния использования объяснимого ИИ на точность и скорость диагностики. Таким образом, представленная система открывает возможности для создания нового поколения интеллектуальных ассистентов врача, сочетающих мощь глубинного обучения с прозрачностью и интерпретируемостью, что соответствует актуальным направлениям развития ИИ в медицине.

## Благодарности

Авторы выражают особую благодарность компании «Yadro «КНС Групп» за предоставление необходимого вычислительного оборудования. Также авторы выражают свою признательность Трусову И.А. за помощь в работе.

## Список источников

1. The top 10 causes of death / A World Health Organization. – WHO, 2025. – Дата публикации: 7.08.2024. – URL: <https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death>.
2. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead // *Nature Machine Intelligence*. – 2019. – Т. 1(5). – С. 206–215. – DOI: <https://doi.org/10.1038/s42256-019-0048-x>.
3. Deep learning for segmentation using an open large-scale dataset in 2D echocardiography / S. Leclerc, E. Smistad, J. Pedrosa [и др.] // *IEEE transactions on medical imaging*. – 2019. – Т. 38. – №. 9. – С. 2198-2210.
4. EchoNet-Dynamic: Echocardiography Dataset / Stanford University. – DOI: <https://doi.org/10.71718/yqp5-y078>.
5. CADICA: a new dataset for coronary artery disease / A. Jiménez-Partinen, M. A. Molina-Cabello, K. Thurnhofer-Hemsi [и др.] // *Mendeley Data*. – Elsevier inc, 2025. – V2. – DOI: [10.17632/p9bpx9ctcv.2](https://doi.org/10.17632/p9bpx9ctcv.2).
6. Explainable Artificial Intelligence (XAI) 2.0: A manifesto of open challenges and interdisciplinary research directions / L. Longo, M. Brcic, F. Cabitza [и др.] // *Information Fusion*. – Т. 106. – С. 102301. – DOI: <https://doi.org/10.1016/j.inffus.2024.102301>.
7. Ribeiro M. T., Singh S., Guestrin C. "Why Should I Trust You?": Explaining the Predictions of Any Classifier // *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*. – New York, NY, USA: ACM, 2016. – С.1135-1144.
8. Lundberg S. M., Lee S.-I. A Unified Approach to Interpreting Model Predictions // *Advances in Neural Information Processing Systems*. – 2017. – Т. 30. – С. 4768–4777.
9. Explaining deep neural networks and beyond: A review of methods and applications / W. Samek, G. Montavon, S. Lapuschkin [и др.] // *Proceedings of the IEEE*. – 2021. – Т. 109. – №. 3. – С. 247-278.
10. Averkin A. N., Yarushev S. A. Hybrid Neural Networks for Time Series Forecasting // *Artificial Intelligence*. – Cham : Springer International Publishing, 2018. – Т. 934. – С. 230–239. – DOI: [https://doi.org/10.1007/978-3-030-00617-4\\_21](https://doi.org/10.1007/978-3-030-00617-4_21).
11. Аверкин А. Н. Извлечение правил из классических, глубоких нейронных сетей и нейронечетких сетей // *Речевые технологии*. – 2020. – №3-4. – С. 76–85.