

## Комплексная система анализа фундус-изображений с применением методов глубокого обучения

К. Д. Аксенов<sup>1,2</sup>, Л. Е. Аксенова<sup>1,2</sup>

<sup>1</sup>ООО «Пространство интеллектуальных решений», Новороссийск, Краснодарский край, Россия

<sup>2</sup>Новороссийский политехнический институт (филиал) Кубанского государственного технологического университета, Новороссийск, Краснодарский край, Россия

**Аннотация.** Целью работы является создание вычислительного конвейера для автоматизированного анализа фундус-изображений, включающего классификацию патологий, сегментацию биомаркеров и сосудистой сети, а также интеграцию алгоритмов в специализированную медицинскую платформу. Для обучения моделей использованы открытые наборы данных. Для классификации применена мультимодальная трансформерная модель с архитектурой Vision Transformer и BERT, которая показала значение AUC 0.9155 на тестовой выборке. Для сегментации сосудов использовали архитектуры семейства U-Net (U-Net++, Attention U-Net), а для биомаркеров — U-Net с энкодером ResNeSt-50 и Mask R-CNN, что обеспечило высокие значения метрик Dice и IoU на стандартных датасетах. Все алгоритмы интегрированы в микросервисную платформу, включающую сервер Django, DICOM-хранилище Orthanc, систему управления данными (PostgreSQL, Redis) и модуль AI-ассистента формирования отчётов. Нагрузочные испытания подтвердили устойчивость системы. Полученные результаты демонстрируют возможность создания комплексных решений, которые способны автоматизировать несколько этапов анализа изображений глазного дна. В то же время требуется и дополнительная валидация предложенного подхода на клинических данных для оценки его диагностической ценности.

**Ключевые слова:** искусственный интеллект, офтальмология, фундус-изображения, сегментация, классификация

## A comprehensive system for fundus image analysis using deep learning methods

К. Д. Аксенов<sup>1,2</sup>, Л. Е. Аксенова<sup>1,2</sup>

<sup>1</sup>LLC Predict Space, Novorossiysk, Krasnodar Region, Russia

<sup>2</sup>Novorossiysk Polytechnic Institute (branch), Kuban State Technological University, Novorossiysk, Krasnodar Region, Russia

**Abstract.** The aim of this study is the development of a computational pipeline for automated fundus image analysis, including pathology classification, biomarker and vessel segmentation, as well as the integration of algorithms into a specialized medical platform. Open datasets were used for model training. For classification, a multimodal transformer model combining Vision Transformer and BERT architectures was employed, achieving an AUC of 0.9155 on the test set. Vessel segmentation was performed using U-Net family architectures (U-Net++, Attention U-Net), while biomarker segmentation was carried out with a U-Net model using a ResNeSt-50 encoder and Mask R-CNN, yielding high Dice and IoU metrics on standard datasets. All algorithms were integrated into a microservice-based platform comprising a Django server, an Orthanc DICOM storage, a data management system (PostgreSQL, Redis), and an AI assistant module for report generation. Load testing confirmed the robustness of the system. The results demonstrate the feasibility of developing comprehensive solutions capable of automating multiple stages of fundus image analysis. At the same time, additional validation on clinical data is required to assess the diagnostic value of the proposed approach.

**Keywords:** artificial intelligence, ophthalmology, fundus images, segmentation, classification

### Введение

Скрининг заболеваний сетчатки по изображениям глазного дна (фундус-изображениям) остаётся важной и одновременно сложной задачей современной офтальмологии. Согласно данным литературы, отмечается устойчивое развитие программ скрининга заболеваний сетчатки с использованием фундус-камер и технологий искусственного интеллекта (ИИ) в мире. К примеру, сеть MinuteClinic (CVS Health) предлагает телемедицинские обследования сетчатки в более чем 1200 филиалах с применением портативного RetinaVue 700 Imager и удалённой оценки офтальмологами, что позволяет повысить охват пациентов и доступность скрининга [1]. Кроме того, совсем недавно FDA одобрило портативную систему Optomed Aurora с модулем AI-анализа, которая может проводить автономный скрининг заболеваний сетчатки менее чем за минуту, что важно в условиях нехватки специалистов и высоких временных затрат стандартной диагностики [2]. Несмотря на то, что фундус-съёмка является неинвазивной и относительно недорогой процедурой, её широкое применение ограничено такими факторами, как нехватка квалифицированных специалистов-офтальмологов, высокая нагрузка на

медицинские учреждения, а также вариации качества изображений, обусловленные разными типами камер, освещением, степенью прозрачности сред глаза и др. [3, 4]. В реальных клинических условиях диагностика часто требует тщательного осмотра, времени и ресурсов, что может приводить к задержкам выявления заболеваний, особенно в регионах с ограниченным доступом к офтальмологам.

Развитие машинного обучения (и в особенности глубокого обучения) за последние годы дало мощный толчок в решении этих проблем. Модели на основе сверточных нейронных сетей, трансформеров и их гибридов доказали свою способность автоматически распознавать проявления диабетической ретинопатии, возрастной макулярной дегенерации, окклюзий сосудов, — не только классифицировать состояния, но и сегментировать отдельные биомаркеры (кровоизлияния, микроаневризмы, экссудаты и др.). Например, в работе Duan с соавт. был разработан гибридный алгоритм на основе методов глубокого обучения, который использует DenseNet121 и XGBoost, для классификации 16 заболеваний по широкогольным фундус-снимкам [5]. Другие исследования подчёркивают рост числа разработок, направленных на раннее выявление и автоматизацию анализа фундус-изображений при диабетической ретинопатии, глаукоме и возрастной макулярной дегенерации [6]. Среди конкретных работ по сегментации сосудов и биомаркеров особенно выделяются модели, которые объединяют визуальную сегментацию сосудистой сети и очагов поражения. Например, в работе Kim и др. представлена модель, сочетающая механизмы внимания, многомасштабное слияние признаков (JPU) и блоки трансформеров [7].

Таким образом, уже существует достаточное число публикаций, подтверждающих, что проблемы, связанные с нехваткой специалистов, вариабельностью данных, необходимостью быстрых и автоматизированных решений, могут быть решены средствами машинного и глубокого обучения [8]. Однако многие модели ориентированы на одну задачу — либо классификацию заболеваний, либо сегментацию структур, либо обнаружение конкретного биомаркера. В то же время лишь незначительное количество работ посвящено комплексным системам, которые одновременно автоматизируют несколько этапов оценки изображений врачом — от дифференциальной диагностики и выделения биомаркеров до создания отчета [9].

## Постановка задачи

Целью исследования являлось создание вычислительного конвейера обработки изображений глазного дна и его интеграции в медицинскую информационную систему. Задачами исследования являлись разработка моделей классификации и сегментации изображений глазного дна, разработка архитектуры платформы, а также интеграция моделей в платформу.

## Теория

### 1. Классификация патологий

Для обучения и валидации модели классификации использовали открытый набор данных RFMiD [6]. Примеры изображений приведены на рисунке 1.

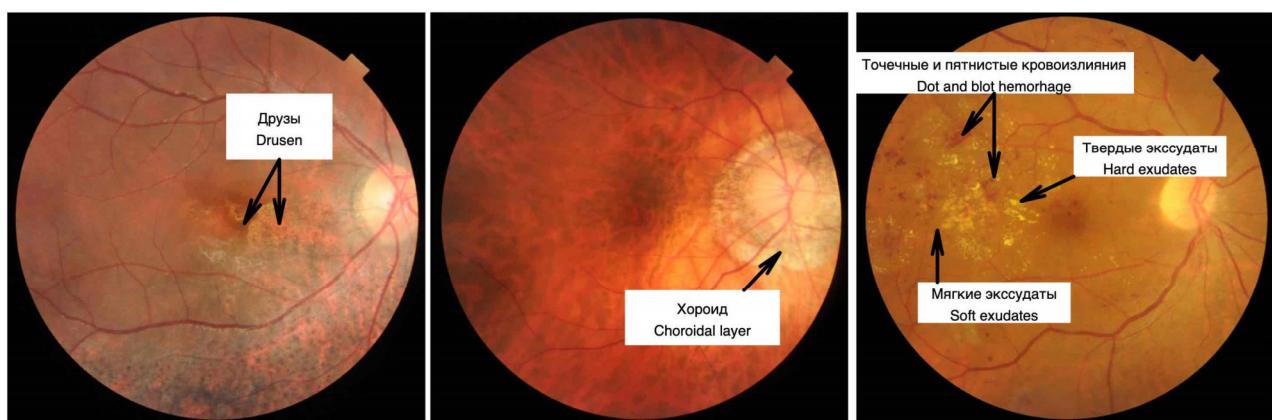


Рисунок 1. Примеры изображений глазного дна из набора данных RFMiD для классов: a) друзы (Drusens, DN); b) миопия (Myopia, MYA); c) окклюзия ветви центральной вены сетчатки (Branch Retinal Vein Occlusion, BRVO) и определяющие данные классы характерные визуальные признаки

Он состоит из 3200 снимков дна, полученных с помощью трех различных фундус-камер и размечен относительно 46 классов двумя экспертами. В настоящем исследовании использована вторая версия набора данных RFMID, в которой все классы с числом изображений менее 10 были объединены в одну обобщённую категорию «Другие». Таким образом, итоговое количество классов для обучения и оценки составило 29. Общий набор был разделен на обучающую (1920), валидационную (640) и тестовую (640) выборки. Количество данных приведено в таблице 1.

Таблица 1. Распределение изображений по классам заболеваний в наборе данных

Класс	Все	Тре-нинг	Вали-дация	Тест	Класс	Все	Тре-нинг	Вали-дация	Тест
Норма (NL)	669	401	134	134	Хориоретинит (CRS)	54	32	11	11
Диабетическая ретинопатия (DR)	632	379	126	127	Окклюзия центральной вены сетчатки (CRVO)	45	27	9	9
Помутнение оптических сред (MH)	523	314	105	104	Клетки пигментного эпителия сетчатки (RPEC)	32	19	6	7
Ковшевидное углубление диска зрительного нерва (ODC)	445	267	89	89	Макулярный рубец (MS)	27	16	5	6
Тесселяция (TSLN)	304	182	61	61	Эпиретинальная мембрана (ERM)	26	16	5	5
Друзы (DN)	230	138	46	46	Передняя ишемическая нейропатия зрительного нерва (AION)	26	16	5	5
Возрастная макулярная дегенерация (ARMD)	169	101	34	34	Астероидный гиалоз (AH)	25	15	5	5
Миопия (MYA)	167	100	33	34	Тракция сетчатки (RT)	25	15	5	5
Окклюзия ветви центральной вены сетчатки (BRVO)	119	71	24	24	Эксудация (EDN)	24	14	5	5
Побледнение диска зрительного нерва (ODP)	115	69	23	23	Парафовеолярная телангигиэктомия (PT)	17	10	3	4
Отек диска зрительного нерва (ODE)	96	58	19	19	Макулярное отверстие (MHL)	17	10	3	4
Лазерные рубцы (LS)	79	47	16	16	Оптоцилиарный шунт (ST)	11	7	2	2
Ретинит (RS)	71	43	14	14	Пигментный ретинит (RP)	10	6	2	2
Центральная серозная ретинопатия (CSR)	61	37	12	12	Извитые сосуды (TV)	10	6	2	2
Другие						67	40	13	14

Для решения задачи многоклассовой классификации заболеваний по изображениям глазного дна в настоящем исследовании использовалась трансформерная мультимодальная модель, сочетающая визуальный и текстовый энкодеры. Визуальный модуль представляет собой Vision Transformer (ViT), извлекающий глобальные пространственные признаки из цветных фундус-фотографий (CFP), а текстовый модуль основан на архитектуре BERT и обрабатывает клинические отчёты, получая семантические текстовые представления. На этапе предварительного обучения модель обучалась на триплетах «левый глаз – правый глаз – текст» в парадигме контрастного обучения, где формировались сопоставления между изображениями и текстами на трёх уровнях: левый глаз, правый глаз и уровень пациента в режиме самоконтролируемого обучения на 1,6 млн неразмеченных фундус-изображений [10]. Таким образом, модель может одновременно учитывать как локальные особенности отдельных глаз, так и информацию о пациенте в целом. Веса визуальных энкодеров для обоих глаз были общими (shared weights). В рамках настоящего исследования предварительно обученная модель была дообучена на наборе данных RFMID, содержащем изображения глазного дна с разметкой по 29 классам. Дообучение выполнялось в течение 75 эпох с использованием оптимизатора AdamW, фиксированной скоростью обучения  $3 \times 10^{-5}$  и размером батча 256.

## 2. Сегментация сосудистой сети

Для задачи сегментации сосудистой сети на фундус-изображениях использовались архитектуры семейства U-Net (рис. 2). В качестве базовой модели применялись U-Net и её модификации, включая Attention U-Net и U-Net++, специально адаптированные для выделения сосудистых структур различного калибра. Энкодер выполнял последовательное извлечение признаков с понижением пространственного разрешения, что обеспечивало захват глобальных характеристик изображения, тогда как декодер восстанавливал пространственную структуру посредством апсемплинга и скип-соединений. Такая архитектура позволяла сохранять мелкие сосудистые ветви, важные для диагностики микроангиопатий. Для повышения точности использовались механизмы внимания (Attention Gates), позволяющие модели фокусироваться на области сосудистой сети и подавлять фоновые шумы. В качестве функции потерь применялась комбинированная метрика Dice Loss и Binary Cross-Entropy, что позволило учитывать как глобальную форму сосудистой сети (перекрытие предсказанной и истинной маски), так и точность локального распознавания мелких сосудов [11].

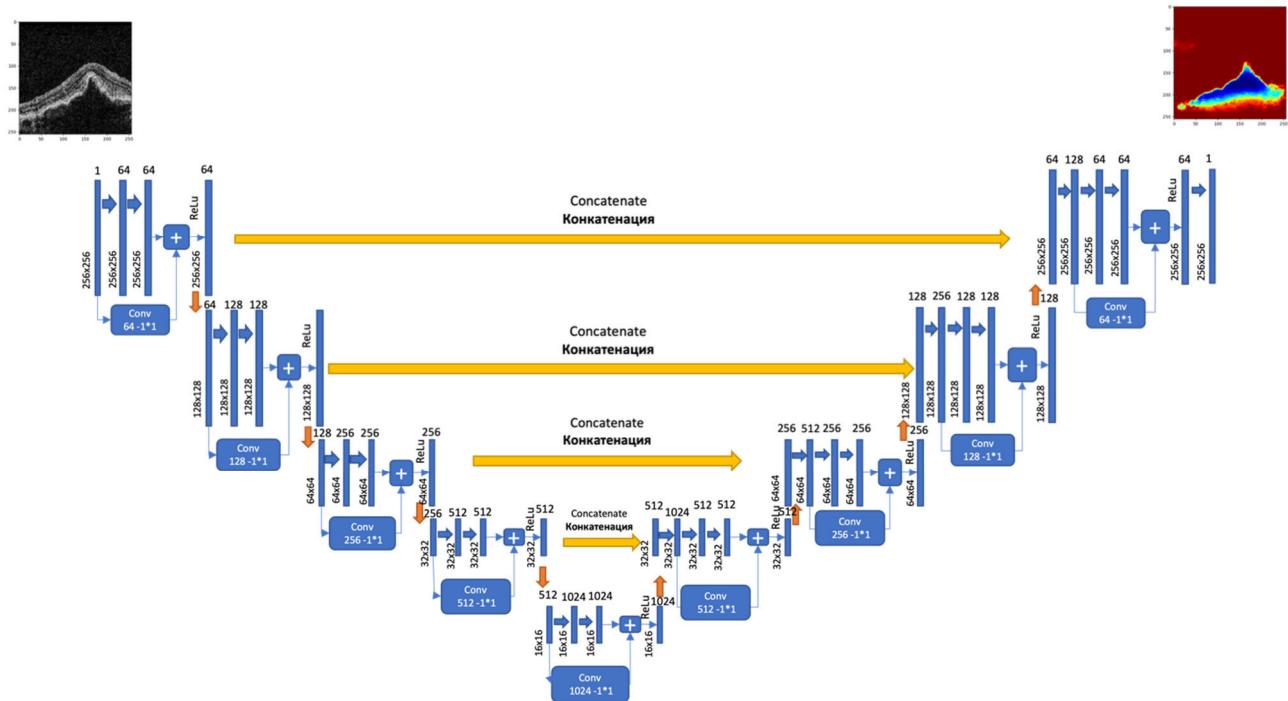


Рисунок 2. Архитектура U-Net

## 3. Сегментация биомаркеров

Для решения задачи автоматизированного выделения патологических структур на изображениях глазного дна были использованы два подхода: пиксельная сегментация и объектная детекция. Их реализация основана на архитектурах глубокого обучения, интегрированных в библиотеку fundus-lesions-toolkit [12]. Для семантической сегментации патологических очагов применялась архитектура U-Net с энкодером ResNeSt-50, обеспечивающим извлечение многоуровневых признаков из входного изображения. В качестве функции потерь использовались комбинированные Dice Loss и Focal Loss. Выход модели представляет собой многоканальную карту вероятностей, соответствующую четырём типам патологических очагов: мягкие экссудаты (cotton wool spots), твёрдые экссудаты, кровоизлияния и микроаневризмы.

Для задачи локализации и подсчёта очагов поражения использовалась архитектура Mask R-CNN, включающая базовую архитектуру ResNet с пирамидальной сетью признаков (FPN). На первом этапе Region Proposal Network (RPN) формирует кандидаты областей интереса, для которых затем выполняется уточнение с использованием операции RoIAlign. Для каждого выделенного региона параллельно решаются три подзадачи: классификация по типу поражения, регрессия координат ограничивающего прямоугольника и сегментация области. Такой подход позволяет не только

определять принадлежность очагов к конкретной категории, но и выделять их границы на изображении.

Для обеспечения воспроизводимости и сокращения времени обучения использовались предобученные модели, доступные через платформу HuggingFace Hub. Механизм загрузки весов позволял выбирать варианты моделей, обученные на различных открытых наборах данных (IDRiD, MESSIDOR, DDR, FGADR, RETINAL-LESIONS), а также использовать ансамблевые решения на основе объединённых датасетов. Это обеспечило высокую обобщающую способность алгоритмов.

#### 4. Цифровая платформа

В процессе проектирования и реализации цифровой платформы применялись современные методы архитектурного и программного проектирования. Архитектура системы была спроектирована с использованием принципов микросервисной модели, что обеспечило модульность, масштабируемость и гибкость интеграции компонентов. В качестве основного фреймворка для серверной части использован Django, реализующий бизнес-логику и REST API, а для клиентской части – React, обеспечивающий динамичный пользовательский интерфейс. Хранение структурированных данных организовано на базе реляционной СУБД PostgreSQL, в то время как кэширование реализовано с помощью Redis. Диагностические изображения обрабатываются и хранятся на DICOM-сервере Orthanc, обеспечивающем интеграцию с офтальмологическим оборудованием. Для задач автоматизированного анализа изображений применялись модели глубокого обучения, разработанные с использованием PyTorch и TensorFlow, с выносом тяжёлых вычислений в асинхронные задачи через Celery. Инфраструктура развернута в изолированной среде с использованием Docker, что гарантирует переносимость и удобство развертывания. Проектирование системы было основано на предварительном анализе клинического рабочего процесса врача-офтальмолога, что позволило структурировать этапы сбора, хранения и анализа данных. Были использованы следующие типы данных: демографическая информация пациентов, структурированные записи осмотров, данные медицинской визуализации, а также результаты аннотированных выборок для обучения ИИ-моделей. Для обеспечения совместимости и безопасности применены стандарты HL7, DICOM, механизмы авторизации, шифрования и логирования доступа к медицинским данным. Особое внимание удалено стандартизации интерфейсов взаимодействия модулей и унификации идентификации пациента.

## Результаты

В рамках работы были разработаны и протестированы алгоритмы анализа изображений глазного дна, включающие многоклассовую классификацию патологий, сегментацию сосудистой сети и выявление биомаркеров.

#### 1. Классификация патологий

Для задачи диагностики офтальмологических и системных заболеваний по фундус-изображениям использовалась мультимодальная трансформерная модель, объединяющая визуальные и текстовые признаки. Модель обучена на датасете RFMiD (3200 изображений, 29 классов) и показала высокие результаты: AUC = 0.9155 на тестовой выборке без признаков переобучения (рис. 3).

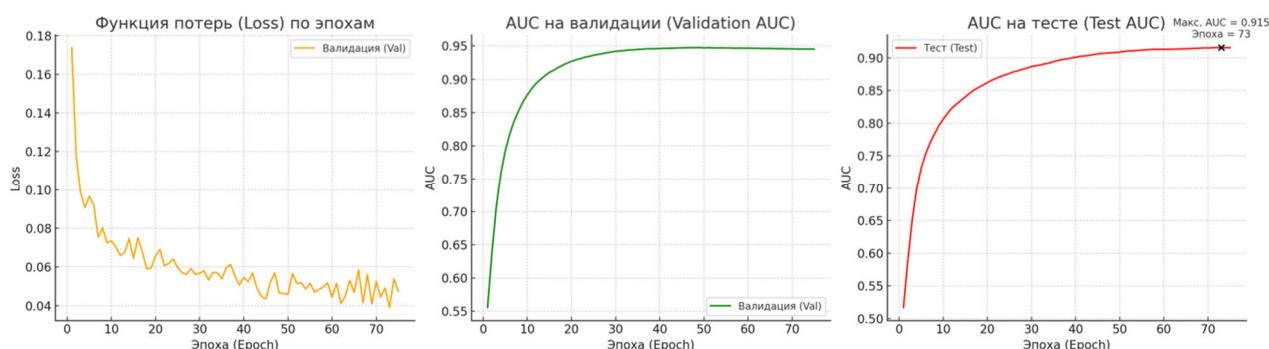


Рисунок 3. Динамика обучения модели: функция потерь (Loss), AUC на валидационном и AUC на тестовом наборах по эпохам

## 2. Сегментация биомаркеров и сосудов

Для выделения ключевых структур использованы специализированные модели:

- fundus-lesions-toolkit — сегментация очагов поражения (экссудаты, кровоизлияния, микроаневризмы);
- fundus-vessels-toolkit — сегментация сосудистой сети.

Обе модели адаптированы и интегрированы в единую вычислительную среду (рис. 4).

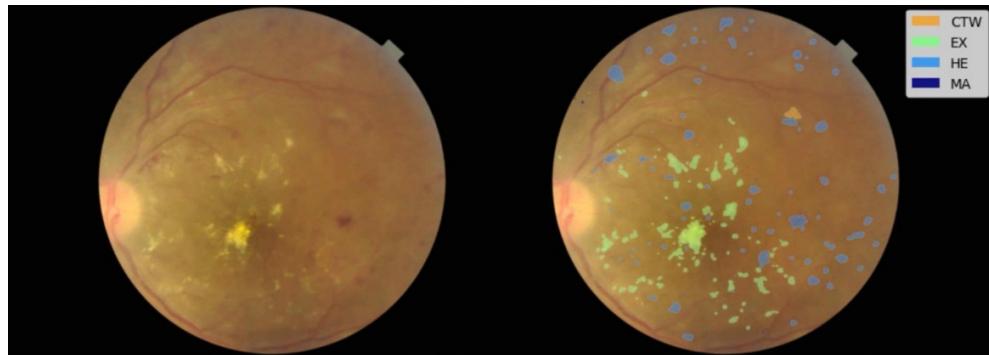


Рисунок 4. Примеры сегментации биомаркеров на реальных изображениях глазного дна: очаги мягких экссудатов (cotton wool spots - CTW), твёрдые экссудаты (exudates - EX), кровоизлияния (hemorrhages - HE) и микроаневризмы (microaneurysms - MA)

Результаты, полученные с помощью моделей классификации и сегментации, передаются на анализ большой языковой моделью, которая формирует предварительное заключение: предполагаемый диагноз, список биомаркеров, а также рекомендации по дополнительному обследованию. Такой подход обеспечивает интерпретацию данных в удобном для врача формате (рис. 5).

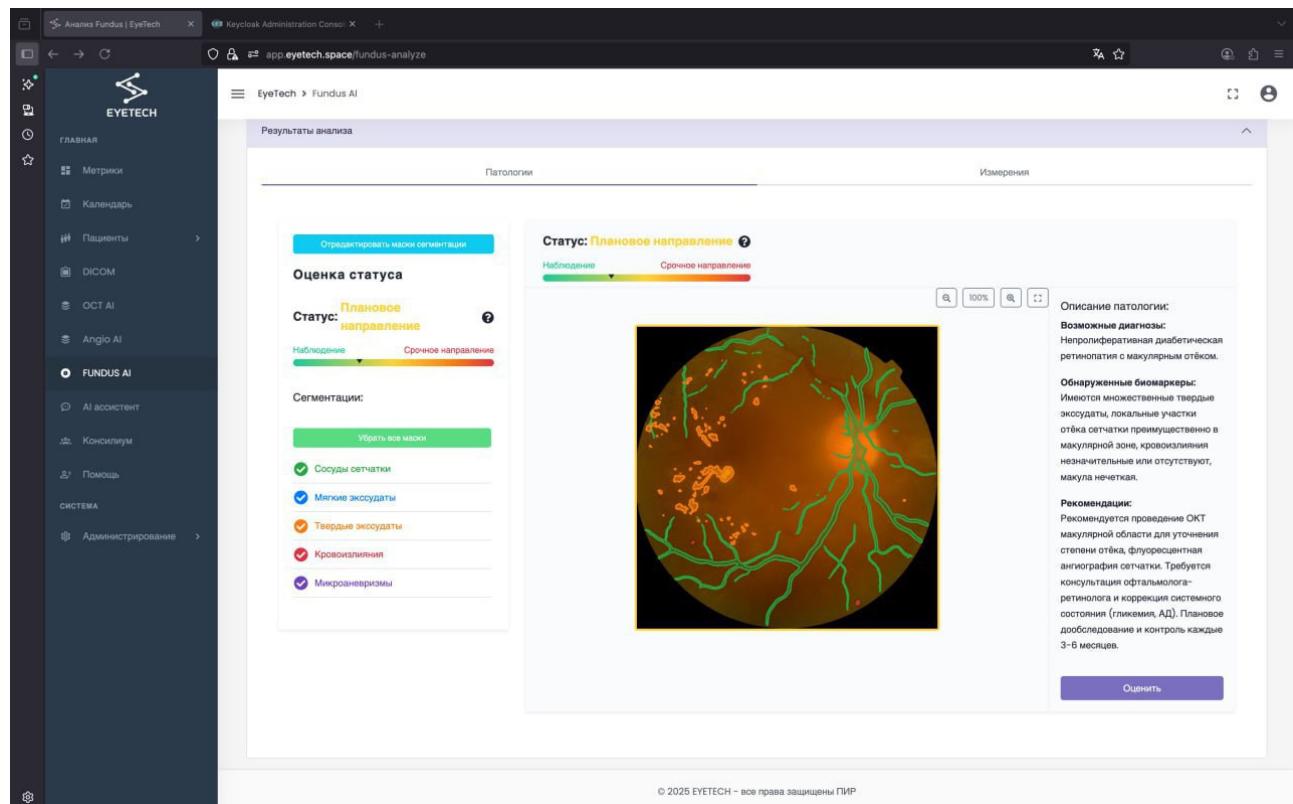


Рисунок 5. Графический интерфейс платформы с интегрированными моделями глубокого обучения и большой языковой моделью

### 3. Архитектура и инфраструктура платформы.

Для интеграции алгоритмов создана специализированная офтальмологическая платформа на основе микросервисной архитектуры (рис. 6).

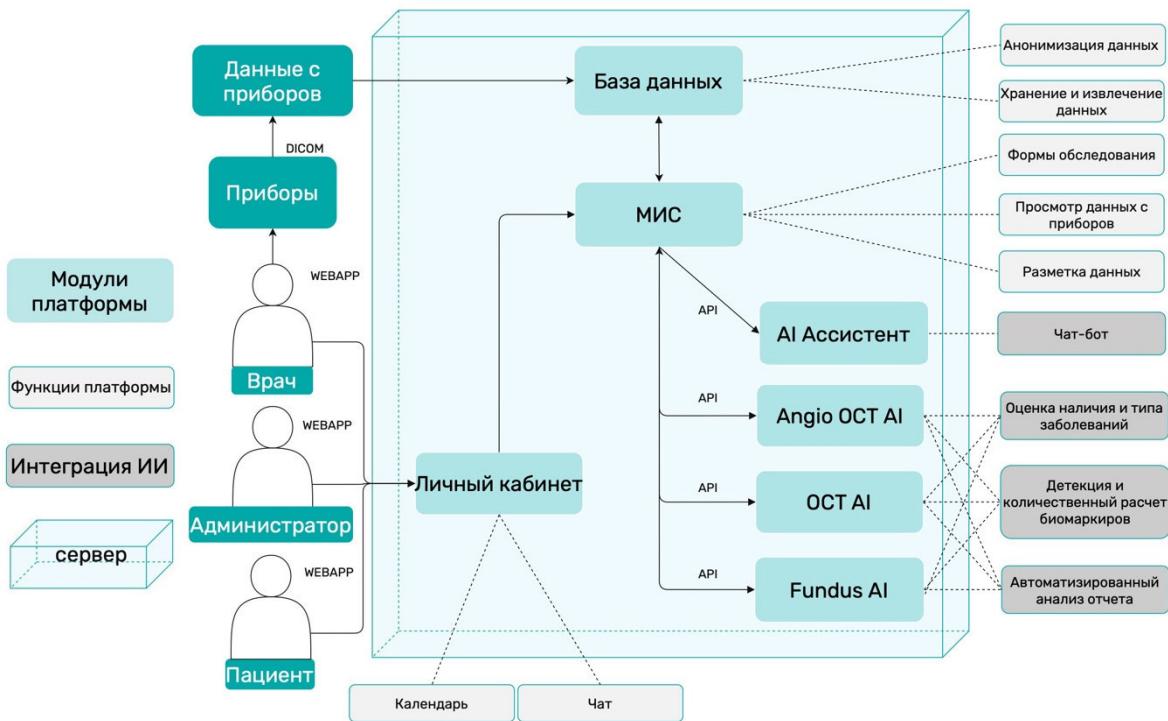


Рисунок 6. Высокоуровневая архитектура платформы

На рисунке 7 представлена микросервисная архитектура платформы, которая включает брокер задач и распределённую систему обработки данных. Такая архитектура обеспечивает масштабируемость и устойчивость системы за счёт декомпозиции на отдельные функциональные компоненты, каждый из которых отвечает за специфический набор задач: веб-интерфейс, обработку запросов, работу с базой данных, асинхронное выполнение задач и анализ изображений средствами машинного обучения. Центральное взаимодействие осуществляется через Django-бэкенд, который координирует обмен данными между пользователем, хранилищем медицинских изображений (ORTHANC), PostgreSQL-базой данных, брокером Redis и сервисами ИИ, реализованными на FastAPI.

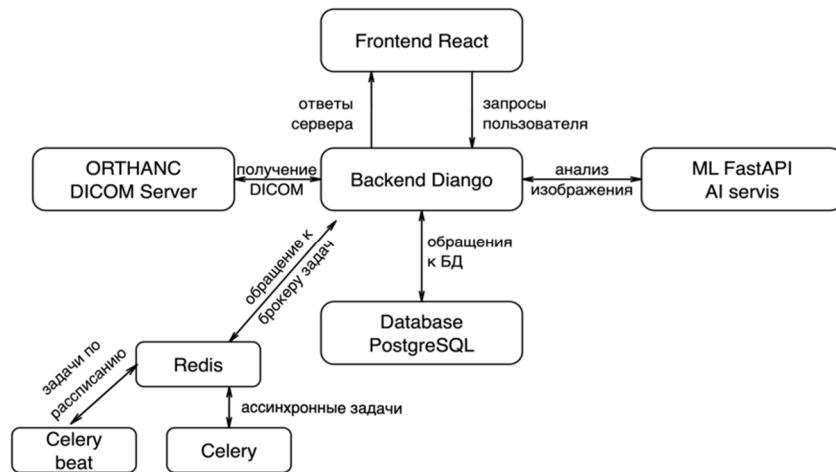


Рисунок 7. Микросервисная архитектура платформы

Нагрузочные тесты подтвердили масштабируемость системы: стабильная работа сохраняется при до 800 одновременных пользователей и 960 запросах/с.

## Обсуждение результатов

В ходе работы была разработана и протестирована многоуровневая система для вычислительного конвейера обработки изображений глазного дна и его интеграции в медицинскую информационную систему. Данная система представляет собой цифровую платформу, которая включает модули многоклассовой классификации патологий, сегментации сосудистой сети и выявления биомаркеров, DICOM-сервер Orthanc, систему управления данными (PostgreSQL, Redis, Django backend) и AI-ассистента. Полученные результаты показывают, что предложенные методы демонстрируют высокую точность и стабильное обучение на тестовых выборках из открытых наборов данных. В частности, мультимодальная трансформерная модель классификации заболеваний достигла значения AUC 0.9155 без признаков переобучения. Таким образом, результаты классификации можно рассматривать как основу для более широкого внедрения автоматизированных систем поддержки принятия решений в офтальмологической практике. Для задач сегментации сосудов и биомаркеров интеграция специализированных моделей (U-Net, Attention U-Net, Mask R-CNN) позволила достичь высоких значений метрик Dice и IoU, обеспечив корректное выделение как сосудистой сети, так и локальных патологических очагов. Однако стоит отметить, что точность для отдельных категорий поражений (например, микроаневризм) может быть ограничена качеством исходной разметки и дисбалансом классов. На следующем этапе анализа необходимо провести детальную оценку точности по каждому классу относительно различных метрик (чувствительность, специфичность, F1-score) с учётом клинической значимости каждого биомаркера.

В ходе исследования было показано, что офтальмологическая платформа является масштабируемой и устойчивой. Микросервисная архитектура обеспечивает возможность интеграции новых алгоритмов и модулей без модификации всей системы, что делает решение перспективным для тиражирования в другие области медицинской диагностики. Включение модуля анализа на основе большой языковой модели позволило автоматически формировать клинические заключения за счет объединения результатов классификации и сегментации в интерпретируемый для врача формат. Такой подход существенно повышает удобство использования системы и может способствовать сокращению времени постановки диагноза.

Несмотря на полученные положительные результаты, исследование имеет ряд ограничений. Во-первых, обучение и тестирование моделей проводилось на открытых наборах данных (RFMiD, IDRiD, MESSIDOR и др.), которые могут не полностью отражать клиническое разнообразие реальных случаев. Во-вторых, качество разметки, выполненной экспертами, не исключает вариабельности, что особенно важно для мелких структур, таких как микроаневризмы. В-третьих, в исследовании не проводилась внешняя валидация на клинических данных локальных медицинских учреждений, что ограничивает обобщаемость результатов. Следовательно, дальнейшие исследования должны быть направлены на адаптацию алгоритмов к реальным клиническим данным, оценку их диагностической ценности в условиях практического применения, а также на сравнение с результатами, получаемыми врачами-офтальмологами.

## Заключение

Разработанная система демонстрирует высокую степень автоматизации и поддержки принятия врачебных решений, а также отвечает требованиям надёжности, масштабируемости и совместимости с медицинской инфраструктурой. Полученные результаты подтверждают перспективность интеграции современных информационных решений в офтальмологическую практику и указывают на возможность их дальнейшего применения для других направлений медицинской диагностики.

## Источник финансирования

Исследование выполнено при финансовой поддержке Кубанского научного фонда, ООО ПИР в рамках проекта № НТИП-24.1/1 «Портативный оптический прибор для визуализации глазного дна со встроенными технологиями искусственного интеллекта».

**Список литературы**

1. Gustaitis J. CVS now offering retinopathy exams. Diabetes Self-Management. March 4, 2022. <https://www.diabetesselfmanagement.com/news-research/2022/03/04/cvs-now-offering-retinopathy-exams/> Accessed August 30, 2023.
2. Lupidi M., Danieli L., Fruttini D., Nicolai M., Lassandro N., Chhablani J., Mariotti C. Artificial intelligence in diabetic retinopathy screening: clinical assessment using handheld fundus camera in a real-life setting. *Acta Diabetol.* 2023 Aug;60(8):1083-1088. doi: 10.1007/s00592-023-02104-0. Epub 2023 May 8. PMID: 37154944; PMCID: PMC10166040
3. Cleveland, S. D., Baker, M. J., Erdman, A. G., Nazari, H. Current and future directions for the use of handheld fundus cameras in telehealth. *Expert Review of Medical Devices.* 2025, 22(7): 657–665. <https://doi.org/10.1080/17434440.2025.2508877>
4. Chan T.Y., Wang J.H., Chen N., Chiu C.J. The Assessment of Retinal Image Quality Using a Non-Mydriatic Fundus Camera in a Teleophthalmologic Platform. *Diagnostics (Basel).* 2024 (Jul): 17;14(14):1543. doi: 10.3390/diagnostics14141543. PMID: 39061681; PMCID: PMC11275639
5. Duan M-M., Tu X. Deep learning-based classification of multiple fundus diseases using ultra-widefield images. *Front. Cell Dev. Biol.* 2025; 13:1630667. doi: 10.3389/fcell.2025.1630667
6. Hassan, B., Raja, H., Hassan, T. et al. A comprehensive review of artificial intelligence models for screening major retinal diseases. *Artif Intell Rev.* 2024, 57, 111. <https://doi.org/10.1007/s10462-024-10736-z>
7. Kim, Hyung-Joo, Hassan Eesaar, Kil To Chong. Transformer-Enhanced Retinal Vessel Segmentation for Diabetic Retinopathy Detection Using Attention Mechanisms and Multi-Scale Fusion. *Applied Sciences.* 2024. 14, no. 22: 10658. <https://doi.org/10.3390/app142210658>
8. Liang X., Bao Y., Du Y., Kong N. AI-Assisted Screening for Diabetic Retinopathy and Fundus Abnormalities in a Large-Scale Physical Examination Population. *Clin Ophthalmol.* 2025 Aug 22;19:2889-2900. doi: 10.2147/OPTH.S538020. PMID: 40873655; PMCID: PMC12380004
9. Zedadra, Amina, Mahmoud Yassine Salah-Salah, Ouarda Zedadra, and Antonio Guerrieri. Multi-Modal AI for Multi-Label Retinal Disease Prediction Using OCT and Fundus Images: A Hybrid Approach. *Sensors.* 2025, 25(14): 4492. <https://doi.org/10.3390/s25144492>
10. Zhou, Y., Chia, M.A., Wagner, S.K. et al. A foundation model for generalizable disease detection from retinal images. *Nature.* 2023, 622: 156–163. <https://doi.org/10.1038/s41586-023-06555-x>
11. Roy, S. K., Ahmed, M., Rangayyan, R. M. Deep learning-based retinal vessel segmentation: A comprehensive review and benchmark. *IEEE Trans. Med. Imaging.* Dec. 2023; 42(12):3567–3583, doi: 10.1109/TMI.2023.10230840].
12. Lesions Segmentation Toolkit for Fundus Images. Режим доступа: <https://github.com/ClementPla/fundus-lesions-toolkit> (дата обращения: 02.08.2025).