

УДК 617.7:004.8
EDN: AUMXRN
<https://doi.org/10.15275/ssmj2202145>

Оригинальная статья

МЕТОД ИНТЕРПРЕТИРУЕМОЙ КОМПЬЮТЕРНОЙ КЛАССИФИКАЦИИ ИЗОБРАЖЕНИЙ ГЛАЗНОГО ДНА ДЛЯ ПЕРВИЧНОГО ОФТАЛЬМОЛОГИЧЕСКОГО СКРИНИНГА

О.Н. Долинина¹, Д.А. Арутюнян¹, Е.И. Кочкарева¹, Т.Г. Каменских², И.О. Колбенева², Е.В. Веселова²

¹ФГБОУ ВО «Ульяновский государственный технический университет», Ульяновск, Россия

²ФГБОУ ВО «Саратовский государственный медицинский университет им. В.И. Разумовского» Минздрава России, Саратов, Россия

INTERPRETABLE CLASSIFICATION METHOD FOR FUNDUS IMAGE ANALYSIS IN PRIMARY OPHTHALMOLOGICAL SCREENING

O.N. Dolinina¹, D.A. Arutyunyan¹, E.I. Kochkareva¹, T.G. Kamenskikh², I.O. Kolbeneva², E.V. Veselova²

¹Ulyanovsk State Technical University, Ulyanovsk, Russia

²V.I. Razumovsky Saratov State Medical University, Saratov, Russia

Для цитирования: Долинина О.Н., Арутюнян Д.А., Кочкарева Е.И., Каменских Т.Г., Колбенева И.О., Веселова Е.В. Метод интерпретируемой компьютерной классификации изображений глазного дна для первичного офтальмологического скрининга. Саратовский научно-медицинский журнал. 2026; 22 (2): 145-149. EDN: AUMXRN. <https://doi.org/10.15275/ssmj2202145>

Аннотация. Цель: разработка и экспериментальная оценка метода интерпретируемой классификации изображений глазного дна для первичного офтальмологического скрининга, основанного на совместном использовании модели глубокого обучения и средств визуального объяснения ее решений. *Материал и методы.* Исследование выполнено на выборке из 2500 изображений глазного дна, сбалансированной по 5 классам (по 500 изображений на класс): дегенеративные изменения сетчатки, патология макулярной области, нейроофтальмологическая патология, сосудистая патология сетчатки и отсутствие клинически значимой патологии. В качестве классификатора использована сверточная нейронная сеть с ConvNeXt-подобной архитектурой. Качество классификации оценивали по метрике Accuracy, качество интерпретации – по метрике Intersection over Union (IoU). *Результаты* – для базовой модели значения Accuracy составили 0,74–0,77, тогда как для модели с учетом интерпретационной компоненты – 0,79–0,82. Качество интерпретации для базовой модели достигало IoU примерно 0,79, а для предложенного метода – 0,98–0,99. *Заключение.* Предложенный метод обеспечивает не только классификацию изображений глазного дна, но и визуальное объяснение результатов. Использование экспертных аннотаций при обучении повышает соответствие карт значимости клинически значимым областям изображения и может способствовать повышению доверия к системам поддержки принятия клинических решений при первичном офтальмологическом скрининге.

Ключевые слова: изображение глазного дна, офтальмологический скрининг, глубокое обучение, интерпретируемая классификация, карта значимости

For citation: Dolinina ON, Arutyunyan DA, Kochkareva EI, Kamenskikh TG, Kolbeneva IO, Veselova EV. Interpretable classification method for fundus image analysis in primary ophthalmological screening. Saratov Journal of Medical Scientific Research. 2026; 22 (2): 145-149. (In Russ.) EDN: AUMXRN. <https://doi.org/10.15275/ssmj2202145>

Abstract. *Objective:* to develop and experimentally evaluate an interpretable fundus image classification method for primary ophthalmic screening based on the joint use of a deep learning model and visual explanation techniques. *Material and methods.* The study was conducted on a dataset of 2,500 fundus images balanced across 5 classes (500 images per class): degenerative retinal changes, macular pathology, neuro-ophthalmic pathology, retinal vascular pathology, and the absence of clinically significant pathology. A convolutional neural network with a ConvNeXt-like architecture was used as the classifier. Classification performance was assessed using Accuracy, while interpretability quality was evaluated using the Intersection over Union (IoU) metric. *Results.* The baseline model achieved Accuracy values ranging from 0.74 to 0.77, whereas the model incorporating the interpretability component achieved values between 0.79 and 0.82. The interpretability quality of the baseline model reached an IoU of approximately 0.79, while the proposed method achieved IoU values of 0.98–0.99. *Conclusion.* The proposed method provides not only fundus image classification but also a visual explanation of the obtained results. Incorporating expert annotations into the training process improves the correspondence between attention maps and clinically relevant image regions and may increase trust in clinical decision support systems for primary ophthalmic screening.

Keywords: fundus image, ophthalmological screening, deep learning, interpretable classification, saliency map

Введение. Заболевания сетчатки и зрительного нерва относятся к значимым причинам слепоты и слабовидения. К базовым методам диагностики таких заболеваний относятся офтальмоскопия глазного дна (ГД) и его фотографирование по различным методикам, включая многопольное стереофотографирование с последующим анализом изображения.

В связи с развитием методов глубокого обучения особую актуальность приобретает компьютерный анализ изображений ГД. Он позволяет оценивать состояние сетчатки, диска зрительного нерва, сосудистой системы и других структур ГД с использованием цифровых

методов обработки и анализа изображений. Традиционная диагностика по снимкам ГД основана на экспертной интерпретации данных, полученных с помощью фундускамер и других средств визуализации. Такие изображения содержат клинически значимую информацию и применяются для выявления широкого спектра патологий. Однако данный подход требует высокой квалификации врача-офтальмолога и значительного клинического опыта, что ограничивает его масштабируемость, особенно в сельских, удаленных и ресурсно-ограниченных регионах [1, 2].

Одним из перспективных направлений повышения доступности первичного офтальмологического скрининга является применение систем поддержки принятия клинических решений, основанных на методах глубокого

Ответственный автор – Татьяна Григорьевна Каменских
Corresponding author – Tatiana G. Kamenskikh
E-mail: kamtanvan@mail.ru

обучения. Сверточные нейронные сети демонстрируют высокую эффективность в задачах классификации изображений ГД и позволяют автоматизировать выявление патологических изменений [3–6]. Вместе с тем практическое использование таких решений ограничивается недостаточной прозрачностью алгоритмов: многие модели функционируют как «черные ящики», предоставляя итоговый класс без объяснения причин принятого решения [7, 8].

Для задач первичного скрининга особое значение имеет не постановка окончательного нозологического диагноза, а отнесение изображения к укрупненной группе патологий или группе риска, требующей последующего обследования. В этой постановке возрастает значимость интерпретируемых подходов, которые совмещают классификацию изображения с визуальным объяснением результата и позволяют выделять области изображения, оказавшие наибольшее влияние на решение модели [7, 9, 10].

Цель – разработка и экспериментальная оценка метода интерпретируемой классификации изображений ГД для первичного офтальмологического скрининга, основанного на совместном использовании модели глубокого обучения и средств визуального объяснения ее решений.

Материал и методы. Дизайн исследования и исходные данные. Работа представляет собой экспериментальное исследование метода автоматической классификации изображений ГД. Исследование направлено на оценку влияния включения экспертных аннотаций патологически значимых областей в процесс обучения модели на качество классификации и интерпретируемость результата.

Для обучения и валидации классификационной модели использовали выборку из 2500 изображений ГД. Выборка была сбалансирована по 5 классам и включала по 500 изображений на каждый класс: признаки дегенеративных изменений сетчатки, признаки патологии макулярной области, признаки нейроофтальмологической патологии, признаки сосудистой патологии сетчатки, клинически значимая патология не выявлена. Принадлежность изображений к классам была уточнена медицинским экспертом.

В рамках исследования анализировались две характеристики: качество отнесения изображения к укрупненной группе офтальмологической патологии и степень совпадения автоматически выделяемых моделью областей с экспертной разметкой. С учетом ограниченного объема доступной информации об исходной выборке исследование рассматривалось как экспериментальная проверка предложенного алгоритмического подхода.

Для проверки качества интерпретации патологии ГД с помощью метода автоматической классификации изображений ГД обследованы 100 пациентов – 167 глаз с различной патологией. Были выделены 4 класса заболеваний.

1-й класс – сосудистая патология – 38 глаз с диабетической ретинопатией;

2-й класс – дегенеративные заболевания сетчатки: сухая форма возрастной макулярной дегенерации с развитием географической атрофии (43 глаза), пигментная дистрофия сетчатки (2 глаза);

3-й класс – патология макулярной области: возрастная макулярная дегенерация, влажная форма (57 глаз);

4-й класс – нейроофтальмологическая патология: частичная атрофия зрительного нерва (17 глаз). Методы обследования включали офтальмоскопию, визометрию, компьютерную статическую периметрию, оптическую когерентную томографию. Фотографирование

ГД проводили на фундус-камере Topcon TRC-NW7SF (Topcon, Япония) с шириной поля 50 градусов.

Постановка задачи классификации и интерпретации. Пусть X – множество изображений ГД, Y – множество диагностических классов, соответствующих укрупненным группам офтальмологических заболеваний, а A – множество экспертных аннотаций патологически значимых областей. Для каждого изображения $x \in X$ задана истинная метка $y \in Y$, а для части изображений – аннотация $a(x) \in A$, отражающая локализацию клинически значимой зоны.

Задача классификации формализуется как отображение

$$f_{\theta}: X \rightarrow R^{|Y|}, \quad (1)$$

где θ – параметры модели, а $f_{\theta}(x)$ представляет собой вектор оценок принадлежности изображения диагностическим классам. В отличие от стандартной постановки задачи классификации в рассматриваемом подходе требуется также построение интерпретируемого объяснения решения. Для этого вводится отображение

$$g_{\theta}: X \rightarrow M, \quad (2)$$

где M – пространство карт значимости, а $g_{\theta}(x)$ определяет области изображения, оказавшие наибольшее влияние на предсказание модели.

Следовательно, модель должна решать 2 взаимосвязанные задачи: корректно относить изображение к диагностическому классу и формировать карту значимости [7, 11], согласованную с экспертным представлением о локализации патологических изменений. Для количественной оценки такой согласованности используется метрика Intersection over Union (IoU) [12–14]:

$$\text{IoU}(R_{\theta}(x), a(x)) = \frac{|R_{\theta}(x) \cap a(x)|}{|R_{\theta}(x) \cup a(x)|}, \quad (3)$$

где $R_{\theta}(x)$ – область, выделенная моделью как значимая для классификации, а $a(x)$ – экспертная аннотация. Чем выше значение IoU , тем ближе интерпретация модели к клинически ожидаемой локализации патологии.

Модель и процедура обучения. В качестве базового классификатора использовали сверточную нейронную сеть с ConvNeXt-подобной архитектурой, способную выделять пространственно локализованные признаки, значимые для различения патологических изменений сетчатки, сосудистой системы, макулярной области и диска зрительного нерва [5, 6]. Размер входных изображений составлял 384×384 пикселя. Для визуализации причин предсказания применялись методы класса CAM, включая Grad-CAM и Score-CAM, формирующие тепловые карты на основе активаций последнего сверточного слоя [8].

Ключевая особенность предложенного подхода заключалась в том, что интерпретация учитывалась не только на этапе анализа результата, но и непосредственно в процессе обучения модели. Функция потерь строилась как комбинация ошибки классификации и ошибки интерпретации, определяемой через степень совпадения карты значимости с экспертной аннотацией:

$$L = L_{cls} + \lambda L_{int}, \quad (4)$$

где L_{cls} – классификационная составляющая функции потерь, L_{int} – интерпретационная составляющая, связанная с согласованием карты значимости и экспертной аннотации, а λ – весовой коэффициент интерпретационной компоненты.

Интерпретационная составляющая задавалась как

$$L_{int} = 1 - \text{IoU}_i. \quad (5)$$

Обучение выполняли в течение 40 эпох. Размер батча составлял 16, скорость обучения – 2×10^{-5} , коэффициент

weight decay – 1×10^{-4} . Для контроля качества обучения использовали валидационное разбиение с долей валидационной части 0,2. Применяли сглаживание меток с коэффициентом 0,05, увеличение обучающей выборки с коэффициентом 2, фиксированное значение seed = 42 и смешанную точность вычислений. Количество рабочих процессов загрузки данных составляло 4.

В прикладном смысле такая схема обучения направлена на то, чтобы модель принимала решение не только формально корректно, но и по клинически содержательным областям изображения. Это особенно важно для медицинских задач, в которых высокая числовая точность без объяснимости не обеспечивает достаточного доверия к результату и ограничивает возможность практического внедрения системы [7, 10, 11].

Оценка качества модели. Качество классификации оценивали по показателю ассигасу:

$$\text{Accuracy} = \frac{1}{N} \sum_{i=1}^N x_i I(\tilde{y}_i = y_i) \quad (6)$$

где $\tilde{y}_i$ – предсказанный моделью класс изображения x_i , y_i – истинная метка класса, I – индикатор совпадения предсказанной и истинной меток.

Качество интерпретации оценивали по метрике IoU, отражающей степень совпадения карты значимости модели с экспертной аннотацией патологически значимой области. Сопоставлялись 2 группы моделей: базовый классификатор, обученный по стандартной функции потерь, и классификатор аналогичной архитектуры, в обучение которого дополнительно включали интерпретационную компоненту на основе IoU.

Оценка результатов носила сравнительный экспериментальный характер. Основными анализируемыми показателями были ассигасу и IoU. Доверительные интервалы и статистическую значимость различий между моделями в настоящей работе не рассчитывали, что учитывалось при интерпретации полученных результатов.

Результаты. Экспериментальная проверка направлена на оценку влияния включения интерпретационной компоненты в функцию потерь на качество

первичного офтальмологического скрининга по изображениям ГД. Сравнивали 2 модели: базовый классификатор, обученный по стандартной функции потерь, и классификатор, в обучение которого была включена компонента согласования карты значимости с экспертной аннотацией патологической области.

Для базового классификатора значения ассигасу находились в диапазоне 0,74–0,77. Для модели, обученной с использованием функции потерь, учитывающей IoU, значения ассигасу составляли 0,79–0,82. Таким образом, добавление интерпретационной компоненты не сопровождалось снижением качества классификации и было связано с увеличением ассигасу.

Наиболее выраженные различия между сравниваемыми подходами получены при оценке качества интерпретации. Для базовой модели степень совпадения карт значимости с экспертными аннотациями составляла приблизительно 0,79 по метрике IoU. Для модели, обученной с учетом интерпретационной компоненты, значения IoU достигали 0,98–0,99.

Для данной модели с целью анализа были представлены 4 класса патологии ГД:

1-й класс – сосудистая патология: 37 изображений ГД были классифицированы правильно (97,4%), 1 изображение отнесено к норме;


2-й класс – дегенеративные заболевания сетчатки, все 45 изображений были классифицированы правильно (100%);

3-й класс – патология макулярной области, 56 изображений были классифицированы правильно (98,2%), 1 изображение отнесено ко 2-му классу.

4-й класс – нейроофтальмология, 16 (93,8%) изображений были классифицированы правильно, 1 изображение отнесено к норме.

Таким образом, итоговый результат работы модели включал предсказанную укрупненную группу патологии, оценку уверенности классификации и карту значимости, визуально указывающую область изображения, оказавшую наибольшее влияние на предсказание. Общий итог правильных классификаций составил в среднем 97,3%.

Пример такого результата представлен на рисунке.



Пример результата работы интерпретируемой модели: исходное изображение глазного дна (а), предсказанный класс и карта значимости (б), визуализирующая область, оказавшую наибольшее влияние на классификацию

Обсуждение. Полученные результаты показывают, что включение экспертных аннотаций патологически значимых областей в процесс обучения позволяет повысить не только интерпретируемость модели, но и качество классификации изображений ГД. В отличие от стандартной классификационной схемы, предложенный подход делает интерпретацию частью процедуры оптимизации, а не только этапом последующего анализа результата.

Повышение ассигасы с 0,74–0,77 до 0,79–0,82 указывает на то, что согласование внимания модели с экспертно выделенными областями не ухудшает распознавание, а может способствовать более устойчивому выделению клинически значимых признаков. Еще более выраженное увеличение IoU с приблизительно 0,79 до 0,98–0,99 свидетельствует о более точной локализации областей изображения, на основании которых модель формирует предсказание.

С практической точки зрения это важно для систем поддержки принятия клинических решений в офтальмологии. Для первичного скрининга требуется не замена врача и не постановка окончательного диагноза, а обоснованное выделение случаев, нуждающихся в дальнейшем обследовании. Точность выделения типа патологии ГД во многом зависит не только от модели, используемой для классификации изображений, но и от стадии заболевания и от его этиологии.

В любом случае в такой задаче визуальное объяснение результата повышает прозрачность работы алгоритма и может облегчить его использование врачом при сортировке пациентов по группам риска [7, 11].

Предложенный подход также имеет значение для ресурсно-ограниченных условий. Возможность работы с компактной моделью и изображениями сравнительно невысокого разрешения снижает вычислительные требования к системе. Это потенциально расширяет применимость метода в удаленных регионах, небольших медицинских пунктах и мобильных диагностических комплексах, где доступ к специализированной офтальмологической помощи ограничен [1, 2, 15–17].

Ограничениями исследования являются отсутствие открытого описания источника исходного набора изображений, ограниченный объем доступных сведений о процедуре формирования экспертной разметки, отсутствие отдельной внешней тестовой выборки и отсутствие расчета доверительных интервалов для полученных метрик. Кроме того, для подтверждения устойчивости результатов требуется независимая валидация на внешних наборах данных, сравнение с альтернативными методами интерпретации и клиническая оценка полезности карт значимости врачами-офтальмологами [18–20].

Заключение. Разработан метод интерпретируемой классификации изображений ГД для задач первичного офтальмологического скрининга. Метод основан на совместном решении задачи классификации и задачи согласования карт значимости с экспертными аннотациями патологически значимых областей.

Экспериментальная проверка показала, что включение интерпретационной компоненты в функцию потерь повышает ассигасы с 0,74–0,77 до 0,79–0,82 и увеличивает согласованность карт значимости с экспертной разметкой по метрике IoU приблизительно с 0,79 до 0,98–0,99.

Полученные результаты позволяют рассматривать предложенный подход как перспективную основу для разработки систем поддержки первичного офтальмологического скрининга, в которых результат автоматической классификации сопровождается визуальным объяснением и может быть проверен специалистом.

Конфликт интересов отсутствует.

Вклад авторов. Все авторы сделали эквивалентный вклад в подготовку публикации.

Информированное согласие на публикацию. Пациенты подписали форму добровольного информированного согласия на публикацию медицинской информации.

Источник финансирования. Авторы декларируют отсутствие внешнего финансирования для проведения исследования и публикации статьи.

Соответствие принципам этики. Протокол исследования одобрен локальным этическим комитетом. Одобрение и процедуру проведения протокола получали по принципам Хельсинкской декларации.

References (Список источников)

- Burton MJ, Ramke J, Marques AP, et al. The Lancet Global Health Commission on Global Eye Health: Vision beyond 2020. *Lancet Global Health*. 2021;9(4):489–551.
- Zheng S, Choo J, Chen J, et al. The barriers to global eye care equity and the role of digital innovations. *Adv Ophthalmol Pract Res*. 2021;1(2):100021. DOI:10.1016/j.aopr.2021.100021
- Akhtar S, Aftab S, Ali O, et al. A deep learning-based model for diabetic retinopathy grading. *Sci Rep*. 2025;15(1):3763. DOI:10.1038/s41598-025-87171-9
- Duan MM, 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
- Mienye ID, Swart TG, Obaide G, et al. Deep convolutional neural networks in medical image analysis: A review. *Information (Switzerland)*. 2025;16(3):195. DOI:10.3390/info16030195
- Sebastian A, Elharrouss O, Al-Maadeed S, Al-Maadeed NA. Survey on deep-learning-based diabetic retinopathy classification. *Diagnostics (Basel)*. 2023;13(3):345. DOI:10.3390/diagnostics13030345
- Tjoa E, Guan C. A survey on explainable artificial intelligence (XAI): Toward medical XAI. *IEEE Trans Neural Netw Learn Syst*. 2021;32(11):4793–813. DOI:10.1109/TNNLS.2020.3027314
- Abdallah HH, Nagibin SYA. Search and analysis of explainable artificial intelligence methods in machine learning problems: Classification and interpretation of models. *Information Technology and Applied Mathematics*. 2024;1:113. (In Russ.) Абдаллах Х.Х., Нагибин С.Я. Поиск и анализ методов объяснимого искусственного интеллекта в задачах машинного обучения: классификация и интерпретация моделей. *Информационные технологии и прикладная математика*. 2024;1:113.
- Boulaabi M, Ben Aicha Gader T, Kacem Ech A, Mbarek S. Advanced Segmentation of Diabetic Retinopathy Lesions Using DeepLabv3+. 2024 IEEE/ACS 21st International Conference on Computer Systems and Applications (AICCSA 2024). 2024 arXiv:2504.17306 [cs.CV]. DOI:10.48550/arXiv.2504.17306
- Holzinger A, Carrington A, Müller H. Measuring the quality of explanations: The System Causability Scale (SCS): Comparing human and machine explanations. *KI – Künstliche Intelligenz*. 2021;2(34):193–8. arXiv:1912.09024 [cs.AI]. DOI:10.48550/arXiv.1912.09024
- Xie X, Niu J, Liu X, et al. A survey on incorporating domain knowledge into deep learning for medical image analysis. *Med Image Anal*. 2021;11(69):101985. DOI:10.1016/j.media.2021.101985
- Cheng B, Girshick R, Dollár P, et al. Boundary IoU: Improving object-centric image segmentation evaluation. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2021. arXiv:2103.16562 [cs.CV]. DOI:10.48550/arXiv.2103.16562
- Miller C, Portlock T, Nyaga DM., O'Sullivan JM. A review of model evaluation metrics for machine learning in genetics

and genomics. *Front Bioinform.* 2024;4:1457619. DOI:10.3389/fbiof.2024.1457619

14. Rainio O, Teuho J, Klén R. Evaluation metrics and statistical tests for machine learning. *Sci Rep.* 2024;14(1):6086. DOI:10.1038/s41598-024-56706-x

15. Esteva A, Robicquet A, Ramsundar B, et al. A guide to deep learning in healthcare. *Nat Med.* 2019;25(1):24-9. DOI:10.1038/s41591-018-0316-z

16. GBD 2019 Blindness and Vision Impairment Collaborators, Vision Loss Expert Group of the Global Burden of Disease Study. Causes of blindness and vision impairment in 2020 and trends over 30 years, and prevalence of avoidable blindness in relation to VISION 2020: The Right to Sight: An analysis for the Global Burden of Disease Study. *Lancet Global Health.* 2021;9(2):144-60.

17. Jiang H, Gao M, Liu Z, et al. GlanceSeg: Real time microaneurysm lesion segmentation with gaze map guided

foundation model for early detection of diabetic retinopathy. *IEEE Journal of Biomedical and Health Informatics.* 2024;2(1):1-14.

18. Rieger L, Singh C, Murdoch WJ, Yu B. Interpretations are useful: penalizing explanations to align neural networks with prior knowledge. *Proceedings of the 37th International Conference on Machine Learning (ICML).* 2020;119:8116-26.

19. Ross AS, Hughes MC, Doshi-Velez F. Right for the right reasons: training differentiable models by constraining their explanations. *Proceedings of the 26th International Joint Conference on Artificial Intelligence (IJCAI).* 2022. arXiv:1703.03717 [cs.LG]. DOI:10.48550/arXiv.1703.03717

20. Sebastian A, Elharrouss O, Al-Maadeed S, Al-Maadeed NA. A survey on diabetic retinopathy lesion detection and segmentation. *Appl Sci.* 2023;13(8):51. DOI:10.3390/app13085111

Статья поступила в редакцию 24.04.2026; одобрена после рецензирования 25.05.2026; принята к публикации 27.05.2026.
The article was submitted 24.04.2026; approved after reviewing 25.05.2026; accepted for publication 27.05.2026.

Информация об авторах:

Ольга Николаевна Долинина – профессор кафедры «Информационные системы», доктор технических наук, odolinina09@gmail.com, ORCID 0000-0001-5256-3161; **Дмитрий Аркадьевич Арутюнян** – студент-магистр, d.arutyunyan@ulstu.ru, ORCID 0009-0002-5256-8776; **Елизавета Игоревна Кочкарева** – студент-магистр, e.kochkareva@ulstu.ru, ORCID 0009-0007-2998-0822; **Татьяна Григорьевна Каменских** – заведующая кафедрой глазных болезней, профессор, доктор медицинских наук, kamtanvan@mail.ru, ORCID 0000-0001-8709-5599; **Игорь Олегович Колбенеv** – доцент кафедры глазных болезней, кандидат медицинских наук, ikolbenedev@gmail.com, ORCID 0000-0002-9936-1062; **Екатерина Викторовна Веселова** – доцент кафедры глазных болезней, кандидат медицинских наук, sirphoto@yandex.ru, ORCID 0000-0001-8511-1313.

Information about the authors:

Olga N. Dolinina – Professor of the Departments of "Information Systems", DSc (Engineering), odolinina09@gmail.com, ORCID 0000-0001-5256-3161; **Dmitry A. Arutyunyan** – Master's Degree Student, d.arutyunyan@ulstu.ru, ORCID 0009-0002-5256-8776; **Elizaveta I. Kochkareva** – Master's Degree Student, e.kochkareva@ulstu.ru, ORCID 0009-0007-2998-0822; **Tatyana G. Kamenskikh** – Head of the Eye Diseases Department, Professor, DSc, kamtanvan@mail.ru, ORCID 0000-0001-8709-5599; **Igor O. Kolbenedev** – Assistant Professor of the Eye Diseases Department, PhD, ikolbenedev@gmail.com, ORCID 0000-0002-9936-1062; **Ekaterina V. Veselova** – Assistant Professor of the Eye Diseases Department, PhD, sirphoto@yandex.ru, ORCID 0000-0001-8511-1313.

УДК 617.7: 616-022.7

EDN: BECYFQ

<https://doi.org/10.15275/ssmj2202149>

Клинический случай

ЭНДОФТАЛЬМИТ, ВЫЗВАННЫЙ ГИАЛОГИФОМИЦЕТАМИ У ПАЦИЕНТКИ С САХАРНЫМ ДИАБЕТОМ (КЛИНИЧЕСКИЙ СЛУЧАЙ)

Т.В. Гаврилова^{1, 2}, А.О. Чарушин^{1, 2}, М.В. Миронченков^{1, 2}, С.Н. Хостелиди³, Е.С. Миронченкова^{1, 2}, И.П. Чарушина¹

¹ФГБОУ ВО «Пермский государственный медицинский университет им. акад. Е.А. Вагнера» Минздрава России, Пермь, Россия

²ГБУЗ ПК «Пермская краевая клиническая больница», Пермь, Россия

³ФГБОУ ВО «Северо-Западный государственный медицинский университет им. И.И. Мечникова» Минздрава России, Санкт-Петербург, Россия

ENDOPHTHALMITIS CAUSED BY HYALOPHYCOMYCETES IN A PATIENT WITH TYPE 2 DIABETES MELLITUS (CLINICAL CASE)

T.V. Gavrilova^{1, 2}, A.O. Charushin^{1, 2}, M.V. Mironchenkov^{1, 2}, S.N. Khostelidi³, E.S. Mironchenkova^{1, 2}, I.P. Charushina¹

¹Academician Ye.A. Vagner Perm State Medical University, Perm, Russia

²Perm Regional Clinical Hospital, Perm, Russia

³North-West State Medical University n. a. I.I. Mechnikov, Saint Petersburg, Russia

Для цитирования: Гаврилова Т.В., Чарушин А.О., Миронченков М.В., Хостелиди С.Н., Миронченкова Е.С., Чарушина И.П. Эндофталмлит, вызванный гиалогифомицетами у пациентки с сахарным диабетом (клинический случай). *Саратовский научно-медицинский журнал.* 2026; 22 (2): 149-153. EDN: BECYFQ. <https://doi.org/10.15275/ssmj2202149>

Аннотация. Представлен клинический случай послеоперационного эндофталмита, вызванного представителями группы гиалогифомицетов, у 75-летней пациентки с сахарным диабетом 2-го типа и хронической болезнью почек. Заболевание развилось через 10 дней после плановой фактоэмульсификации катаракты с имплантацией интраокулярной линзы и сопровождалось тяжелым воспалением, резистентным к антибактериальной терапии и повторным витреоретинальным вмешательствам. Прогрессирование процесса до панопталмита потребовало энуклеации глазного яблока. Этиология выявленного заболевания (септированные гифы и конидиальные структуры, характерные для гиалогифомицетов) подтверждена при пересмотре гистологических препаратов в микологическом референс-центре.

Ключевые слова: эндофталмлит, имплантация интраокулярной линзы, гиалогифомицеты, витрэктомия, энуклеация глазного яблока