

Автоматизированная диагностика эпилетинальной мембраны на ОКТ-изображениях с использованием алгоритмов глубокого обучения

А.Д. Першин¹, Д.Д. Хардин¹, А.А. Никифорова^{2,3}, А.А. Дворникова²,
А.Д. Степичев², М.К. Кулябин⁴, В.И. Борисов¹✉

¹ ФГАОУ ВО «УрФУ им. первого Президента России Б.Н. Ельцина», ИРИТ-РТФ, ул. Мира, д. 32, Екатеринбург, 620062, Россия

² ООО «Клиника офтальмохирургии Профессорская Плюс», ул. Вайнера, д. 15, Екатеринбург, 620014, Россия

³ ФГБОУ ВО УГМУ Минздрава России, ул. Репина, д. 3, Екатеринбург, 620028, Россия

⁴ ООО «ВизиоМедИИ», Головинское шоссе, д. 8, Москва, 125212, Россия

Цель работы — разработка и оценка эффективности нейросетевой модели для автоматической сегментации эпилетинальной мембраны (ЭМ) по данным оптической когерентной томографии (ОКТ). **Материал и методы.** Исследование включает анализ 322 размеченных ОКТ-изображений макулярной зоны с признаками ЭМ: 167 сканов — из клиники «Профессорская Плюс», 155 — из открытого датасета OCTDL. Проведено обучение и сравнение пяти архитектур: U-Net, Attention U-Net, TransUNet, LOCTSeg и Tiny-UNet. Для генерации первичных аннотаций использовалась базовая модель U-Net, прошедшая клиническую валидацию. Сегментация оценивалась по метрикам Dice и IoU. Аннотации проверялись тремя офтальмологами с опытом работы больше 10 лет. **Результаты.** Все модели показали сопоставимые значения Dice и IoU, без статистически значимого различия между ними. Модель Tiny-UNet продемонстрировала наилучшее соотношение качества и ресурсной эффективности: 570 тыс. параметров, время обучения одной эпохи — 1/5 от U-Net, итоговое время обучения — 20 мин. При этом точность сегментации составила Dice = 86,1 %, IoU = 78,6 %. **Заключение.** Tiny-UNet представляет оптимальной архитектурой для задач автоматической сегментации ЭМ: она обеспечивает высокую точность при минимальных вычислительных затратах и подходит для внедрения в клиническую практику, включая мобильные и облачные телемедицинские решения.

Ключевые слова: эпилетинальная мембрана; оптическая когерентная томография; сегментация; нейронные сети; глубокое обучение

Конфликт интересов: отсутствует.

Прозрачность финансовой деятельности: никто из авторов не имеет финансовой заинтересованности в представленных материалах или методах.

Для цитирования: Першин А.Д., Хардин Д.Д., Никифорова А.А., Дворникова А.А., Степичев А.Д., Кулябин М.К., Борисов В.И. Автоматизированная диагностика эпилетинальной мембраны на ОКТ-изображениях с использованием алгоритмов глубокого обучения. Российский офтальмологический журнал. 2025; 18 (3 Приложение): 32–6. <https://doi.org/10.21516/2072-0076-2025-18-3-supplement-32-36>

Automated diagnostics of epiretinal membrane on OCT images using deep learning algorithms

Andrey D. Pershin¹, Danil D. Khardin¹, Anastasia A. Nikiforova^{2, 3}, Anna A. Dvornikova²,
Andrey D. Stepichev², Mikhail K. Kulyabin⁴, Vasilii I. Borisov¹✉

¹Ural Federal University named after the first President of Russia B.N. Yeltsin, IRIT-RTF, 32, Mira St.,
Yekaterinburg, 620062, Russia

²OOO Ophthalmosurgery Clinic Professorskaya Plus, 15, Vainera St., Yekaterinburg, 620014, Russia

³Ural State Medical University of the Ministry of Health of the Russian Federation, 3, Repina St., Yekaterinburg, 620028, Russia

⁴OOO VisioMed.AI, 8, Golovinskoe Sh., Moscow, 125212, Russia

v.i.borisov@urfu.ru

Purpose: to develop and evaluate the effectiveness of a neural network model for automatic segmentation of epiretinal membrane (ERM) in optical coherence tomography (OCT) images. **Materials and methods.** The study includes 322 labeled macular OCT scans with signs of ERM: 167 from the private dataset of the “Professorskaya Plus” clinic and 155 from the public OCTDL dataset. Five architectures were selected for comparison: U-Net, Attention U-Net, TransUNet, LOCTSeg, and Tiny-UNet. Initial annotations were generated using a baseline U-Net model and underwent expert clinical validation. Segmentation performance was assessed using Dice coefficient and Intersection over Union (IoU). Annotation quality was ensured by three experienced ophthalmologists with over 10 years of clinical practice. **Results.** All models demonstrated comparable Dice and IoU scores, with no statistically significant differences. Tiny-UNet showed the best balance of accuracy and computational efficiency: 570K parameters, 5× faster training per epoch than U-Net, and total training time of only 20 min. Segmentation accuracy reached Dice = 86.1 %, IoU = 78.6 %. **Conclusion.** Tiny-UNet appears to be the optimal architecture for ERM segmentation tasks, offering high accuracy with minimal computational requirements. Its efficiency makes it suitable for clinical deployment, including in mobile and cloud-based telemedicine platforms.

Keywords: epiretinal membrane; OCT; segmentation; neural networks; deep learning

Conflict of interest: there is no conflict of interest.

Financial disclosure: no author has a financial or property interest in any material or method mentioned.

For citation: Pershin A.D., Khardin D.D., Nikiforova A.A., Dvornikova A.A., Stepichev A.D., Kulyabin M.K., Borisov V.I. Automated diagnostics of epiretinal membrane on OCT images using deep learning algorithms. Russian ophthalmological journal. 2025; 18 (3 Supplement): 32-6 (In Russ.). <https://doi.org/10.21516/2072-0076-2025-18-3-supplement-32-36>

Эпиретинальная мембрана (ЭРМ) — одна из частых офтальмопатологий, сопровождающаяся снижением остроты зрения. Она обусловлена формированием фиброзной ткани на внутренней поверхности сетчатки в области макулы, что приводит к ее деформации и искажению изображения. В 80 % случаев ЭРМ идиопатическая, в 20 % — вторичная, возникающая на фоне других заболеваний, операций или травм [1–3]. Согласно данным литературы, ЭРМ выявляется у 2 % лиц моложе 60 лет и у 10–30 % старше 70 лет; женщины страдают чаще, а в 20 % случаев поражаются оба глаза. Рост частоты ЭРМ с возрастом связан с увеличением числа задней отслойки стекловидного тела (ЗООТ), операций по поводу катаракты и макулярных патологий [4]. На офтальмоскопии ЭРМ проявляется блеском в макуле (cellophane reflex) и радиальными складками, однако золотым стандартом диагностики остается оптическая когерентная томография (ОКТ), позволяющая выявить мембрану на ранней стадии и оценить степень вовлечения слоев сетчатки [5, 6].

ОКТ позволяет классифицировать стадии ЭРМ, оценивать целостность эллипсоидной зоны фоторецепторов, толщину фовеолы и наличие эктопического внутреннего фовеального слоя (EIFL) — параметров, имеющих прогностическое значение при планировании лечения [7, 8]. Единственным эффективным методом терапии остается витрэктомия с удалением мембраны и восстановлением анатомии сетчатки. Однако при незначительном снижении

зрения и отсутствии выраженных изменений вмешательство, как правило, не требуется. Начальные формы ЭРМ часто протекают стабильно, поэтому показано регулярное наблюдение с динамическим ОКТ-контролем для своевременного выявления прогрессирования.

Использование методов глубокого обучения для анализа ОКТ-изображений представляет собой эффективный способ повышения точности, воспроизводимости и оперативности диагностики за счет минимизации субъективных ошибок.

ЦЕЛЬ работы — разработка и тестирование модели нейронной сети, способной проводить автоматическую сегментацию ЭРМ на ОКТ-снимках.

МАТЕРИАЛ И МЕТОДЫ

Сегментация ЭРМ на ОКТ является ключевым этапом в диагностике и мониторинге патологии, позволяя проводить точный морфологический анализ и планировать лечение. На сегодняшний день разработано несколько подходов, основанных как на классических методах компьютерного зрения, так и на современных алгоритмах глубокого обучения.

Ранние подходы к автоматизированной сегментации ЭРМ, такие как метод классификации патчей на основе 3D-ОКТ с использованием визуальных и морфологических признаков [9], постепенно уступили место более эффективным нейросетевым решениям. М. Gende и соавт. [10] при-

менили DenseNet-121 для локализации ЭРМ вдоль границы внутренней пограничной мембраны (ILM), позже дополнив архитектуру FPN (Feature Pyramid Network) и декодером для одновременной сегментации и диагностики. Y. Tang и соавт. [11] использовали классическую U-Net, достигнув высоких показателей точности и улучшения качества диагностики. E. Parra-Mora и L. Cruz [12] разработали компактную модель LOCTSeg (0,57 млн параметров), продемонстрировавшую превосходство над более тяжеловесными архитектурами. Среди российских решений стоит выделить работу Е.А. Каталевой и соавт. [13], в которой EfficientNetB0 с FPN реализован в прикладной системе Retina.AI. J. Chen и соавт. [14] предложили каскадную архитектуру Cascade Multi-Receptive Fields с высокой точностью при минимальных ресурсах (0,48 млн параметров), что подтверждает устойчивую тенденцию к повышению эффективности при снижении вычислительных затрат.

Для сравнения были выбраны пять нейросетевых архитектур: U-Net, Attention U-Net, TransUNet, LOCTSeg и Tiny-UNet — как проверенные решения в задачах сегментации медицинских изображений с различными архитектурными подходами. Обучение и тестирование проводились на комбинированном датасете, включающем 322 размеченных ОКТ-скана с ЭРМ: 155 из открытого набора OCTDL [15], из которых 60 снимков с изолированной ЭРМ и 95 снимков в комбинации с диабетическим макулярным отеком, возрастной макулярной дегенерацией и др. (устройство Optovue Avanti RTVue XR), и 167 — из клиники «Профессорская Плюс», из них 105 снимков с изолированной ЭРМ и 62 с сочетанной патологией. Данные были разделены в соотношении 80 % (256 снимков) на обучение и 20 % (66 снимков) на тестирование, изображения из тестовой выборки не использовались в обучении.

Базовая модель U-Net, обученная на частных данных (коэффициент Дайса (DC): 0,859, пересечение по объ-

единению (IoU): 0,779), была использована для генерации предварительных масок на открытом датасете OCTDL. Аннотации прошли независимую клиническую валидацию и после корректировок были признаны достоверными и пригодными для обучения.

Аннотирование и валидация снимков ОКТ выполнена группой опытных врачей-офтальмологов, каждый из которых имеет стаж клинической работы более 10 лет и специализируется на патологии заднего отдела глаза. Экспертная группа включала трех специалистов, обладающих опытом в постановке диагнозов с высокой диагностической точностью и имеющих длительную практику интерпретации ОКТ-изображений, что обеспечило высокое качество аннотаций. Каждый снимок проходил двойную независимую оценку двумя офтальмологами; в случае расхождения мнений или для обеспечения единообразия классификации финальное мнение выносилось третьим экспертом. Таким образом, полученный набор данных отличается высокой клинической достоверностью и стандартизацией, что обеспечивает его ценность как надежной базы для разработки и валидации алгоритмов автоматизированного анализа ОКТ-изображений.

Подробное описание этапов предобработки данных, конфигурации моделей, используемых метрик и вычислительной среды представлено в нашей предыдущей работе [16].

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Несмотря на различия в средних значениях DC и IoU, высокие стандартные отклонения указывают на пересечение результатов, что не позволяет выявить статистически значимое превосходство какой-либо модели.

Tiny-UNet выделяется высокой ресурсной эффективностью: при размере 2,32 МБ и 570 тыс. параметров она в 15 раз компактнее LOCTSeg, требует в 24 раза меньше операций, чем U-Net, и в 125 раз меньше, чем TransUNet. Обучается в 5 раз быстрее U-Net и завершается за 20 мин

Таблица. Результаты тестирования моделей нейронных сетей
Table. Results of testing neural network models

Характеристики Characteristics	Архитектура Architecture				
Метрика Metrics	Tiny-UNet	UNet	Attention UNet	LOCTSeg	TransUNet
Вес модели, Мб Weight models, MB	2,320	124,24	126	35,79	410,49
Параметры, млн Parameters, mln	0,570	31,038	31,389	0,890	102,859
Вычислительная сложность Computational complexity, GFLOPs	2,308	54,741	55,851	94,653	289,853
Среднее время обучения эпохи GPU, с Average training time of GPU era, s	12,12 ± 0,19	64,20 ± 1,37	72,71 ± 0,80	102,95 ± 0,27	125,63 ± 0,90
Медианное время инференса GPU (CPU), мс Median GPU (CPU) inference time, ms	11,29 (874,95)	74,25 (3571,76)	78,01 (4360,78)	112,65 (6499,67)	154,89 (6953,43)
Лучшая эпоха The best epoch	21	36	61	41	56
Общее время обучения (100 эпох, GPU), мин Total training time (100 epochs, GPU), min	20,2	107	121,2	176,6	209,4
DC, %	86,12 ± 6,50	85,90 ± 6,00	86,20 ± 5,59	85,69 ± 7,91	84,77 ± 7,86
IoU, %	78,65 ± 7,35	77,93 ± 6,95	78,93 ± 6,44	78,22 ± 8,61	77,59 ± 8,40




Рисунок. Пример работы модели Tiny-UNet в задаче сегментации ЭРМ
Figure. An example of the Tiny-UNet model in the ERM segmentation task

против более 200 у TransUNet (лучшие результаты выделены курсивом в таблице). С учетом сопоставимого качества сегментации и значительного преимущества по эффективности Tiny-UNet представляется оптимальным решением — она сочетает высокую скорость, низкую ресурсоемкость и практическую применимость.

Для наглядности результатов сегментации использована цветовая кодировка: зеленый — верные предсказания, красный — пропущенные пораженные области, желтый — ложные срабатывания модели (рисунок).

ЗАКЛЮЧЕНИЕ

Полученные результаты подтверждают высокую эффективность модели Tiny-UNet для автоматической сегментации ЭРМ по данным ОКТ (коэффициент Дайса — 86,1 %, IoU — 78,6 %). Применение данной архитектуры может существенно повысить точность, воспроизводимость и доступность диагностики в офтальмологической практике, особенно в условиях ограниченных ресурсов.

В дальнейшем планируется расширение обучающей выборки, адаптация модели к другим видам макулярной патологии, а также интеграция в телемедицинские и клинико-диагностические платформы, что открывает перспективы для более широкой клинической валидации и внедрения в практическое здравоохранение. В долгосрочной перспективе модель может быть адаптирована под мобильные и облачные решения, что позволит использовать ее в рамках скрининговых программ и телемедицинских платформ. Размещение модели в облачных инфраструктурах обеспечит доступ к инструменту из любой точки страны, включая отдаленные регионы, что особенно актуально в условиях нарастающего дефицита медицинских специалистов вне мегаполисов.

Литература/References

- Dupas B, Tadayoni R, Gaudric A. Epiretinal membranes. *J Fr Ophthalmol.* 2015; 38, 9: 861–75. doi: 10.1016/j.jfo.2015.08.004

- Fung AT, Galvin J, Tran T. Epiretinal membrane: A review. *Clin Exp Ophthalmol.* 2021; 49, 3: 289–308. doi: 10.1111/ceo.13914
- Vallejo-Garcia JL, Romano M, Pagano L, et al. OCT changes of idiopathic epiretinal membrane after cataract surgery. *Int J Retina Vitreous.* 2020; 6, 37. doi: 10.1186/s40942-020-00239-8
- Mitchell P, Smith W, Chey T, et al. Prevalence and associations of epiretinal membranes. The Blue Mountains Eye Study. *Ophthalmology.* 1997 Jun; 104, 6: 1033–40. doi: 10.1016/s0161-6420(97)30190-0
- Gale MJ, Scruggs BA, Flaxel CJ. Diabetic eye disease: A review of screening and management recommendations. *Clin Exp Ophthalmol.* 2021 Mar; 49 (2): 128–45. doi: 10.1111/ceo.13894
- Govetto A, Lalane RA, Sarraf D, et al. Insights into epiretinal membranes: Presence of ectopic inner foveal layers and a new optical coherence tomography staging scheme. *Am J Ophthalmol.* 2017; 175: 99–113. doi: 10.1016/j.ajo.2016.12.006
- Шпак А.А., Журавлев А.С., Колесник С.В. и др. Прогностические критерии функциональных исходов хирургического лечения идиопатического эпиретинального фиброза, основанные на оптической когерентной томографии. *Офтальмохирургия.* 2024; 2 (139): 109–15. [Shpak A.A., Zhuravlev A.S., Kolesnik S.V., et al. Prognostic criteria for functional outcomes of surgical treatment of idiopathic epiretinal fibrosis based on optical coherence tomography. *Fyodorov journal of ophthalmic surgery.* 2024; 2 (139): 109–15 (In Russ.)]. <https://doi.org/10.25276/0235-4160-2024-2-109-115>
- Stevenson W, Ponce CPM, Agarwal DR, et al. Epiretinal membrane: optical coherence tomography-based diagnosis and classification. *Clin Ophthalmol.* 2016; 10: 527–34. doi: 10.2147/OPHT. S97722
- Baamonde S, de Moura J, Novo J, et al. Automatic identification and intuitive map representation of the epiretinal membrane presence in 3D OCT volumes. *Sensors.* 2019; 19 (23). doi: 10.3390/s19235269
- Gende M, de Moura J, Novo J, et al. Fully automatic epiretinal membrane segmentation in OCT scans using convolutional networks. *AI Applications for Disease Diagnosis and Treatment, IGI Global Scientific Publishing.* 2022; 88–121. doi: 10.4018/978-1-6684-2304-2.ch004
- Tang Y, Gao X, Wang W, et al. Automated detection of epiretinal membranes in OCT images using deep learning. *Ophthalmic Res.* 2023; 66 (1): 238–46. doi: 10.1159/000525929
- Parra-Mora E, da Silva Cruz LA. LOCTseg: A lightweight fully convolutional network for end-to-end optical coherence tomography segmentation. *Comput Biol Med.* 2022 Nov; 150: 106174. doi: 10.1016/j.compbiomed.2022.106174
- Каталевская Е.А., Сизов А.Ю., Гилемзянова Л.И. Алгоритм искусственного интеллекта для сегментации патологических структур на сканах оптической когерентной томографии сетчатки глаза. *Российский журнал телемедицины и электронного здравоохранения.* 2022; 8 (3): 21–7. [Katalevskaya E.A., Sizov A.Yu., Gilemyanova L.I. Artificial intelligence

- algorithm for segmentation of pathological structures on retinal optical coherence tomography scans. *Rossiiskij zhurnal telemeditsiny i elektronnoho zdravooohraneniya*. 2022; 8 (3): 21–7 (In Russ.)). <https://doi.org/10.29188/2712-9217-2022-8-3-21-27>
14. Chen J, Lu Y, Yu Q, et al. TransUNet: Transformers make strong encoders for medical image segmentation. 2021 Feb; arXiv: arXiv:2102.04306. doi: 10.48550/arXiv.2102.04306
 15. Kulyabin M, Zhdanov A, Nikiforova A, et al. OCTDL: Optical coherence tomography dataset for image-based deep learning methods. *Sci Data*. 2024 Apr; 11 (1): 365. doi: 10.1038/s41597-024-03182-7
 16. Kulyabin M, Zhdanov A, Pershin A, et al. Segment anything in optical coherence tomography: SAM 2 for volumetric segmentation of retinal biomarkers. *Bioengineering*. 2024 Sep; 11 (9): 940. doi: 10.3390/bioengineering11090940

Вклад авторов в работу: А.Д. Першин — концептуализация и дизайн исследования, практическая реализация, обработка данных, подготовка черновика; Д.Д. Хардин — практическая реализация, обработка данных; А.А. Никифорова — концептуализация, подготовка черновика; А.А. Дворникова, А.Д. Степичев — концептуализация, сбор и обработка данных, подготовка черновика; М.К. Кулябин — сбор и обработка данных, подготовка черновика; В.И. Борисов — организация исследования, подготовка черновика, рецензирование и редактирование.

Authors' contribution: A.D. Pershin — concept and design of the study, practical implementation, data processing, writing of the article; D.D. Hardin — practical implementation, data processing; A.A. Nikiforova — concept, preparation of the draft; A.A. Dvornikova, A.D. Stepichev — concept, data collection and processing, preparation of the draft; M.K. Kulyabin — data collection and processing, preparation of the draft; V.I. Borisov — research organization, preparation of the draft, reviewing and editing of the article.

Поступила: 28.06.2025. Переработана: 15.07.2025. Принята к печати: 16.07.2025
Originally received: 28.06.2025. Final revision: 15.07.2025. Accepted: 16.07.2025

ИНФОРМАЦИЯ ОБ АВТОРАХ/INFORMATION ABOUT THE AUTHORS

ФГАОУ ВО «УрФУ им. первого Президента России Б.Н. Ельцина», ИРИТ-РТФ, ул. Мира, д. 32, Екатеринбург, 620062, Россия

Андрей Дмитриевич Першин — аспирант, инженер данных, ORCID 0009-0007-7480-5054

Данил Дмитриевич Хардин — студент, инженер данных

Василий Ильич Борисов — канд. тех. наук, доцент, ORCID 0000-0003-0486-7552

¹ ООО «Клиника офтальмохирургии Профессорская Плюс», ул. Вайнера, д. 15, Екатеринбург, 620014, Россия

² ФГБОУ ВО УГМУ Минздрава России, ул. Репина, д. 3, Екатеринбург, 620028, Россия

Анастасия Андреевна Никифорова — канд. мед. наук, врач-офтальмолог^{1, 2}, ORCID 0000-0001-6672-6726

Анна Андреевна Дворникова — врач-офтальмолог¹, ORCID 0009-0005-6983-0066

Андрей Дмитриевич Степичев — врач-офтальмолог¹, ORCID 0009-0005-4087-5957

ООО «ВизиоМедИИ», Головинское ш., д. 8, Москва, 125212, Россия

Михаил Константинович Кулябин — канд. тех. наук, инженер данных, ORCID 0009-0007-0440-030X

Для контактов: Василий Ильич Борисов,
v.i.borisov@urfu.ru

Ural Federal University named after the first President of Russia B.N. Yeltsin, IRIT-RTF, 32, Mira St., Yekaterinburg, 620062, Russia

Andrey D. Pershin — PhD student, data engineer, ORCID 0009-0007-7480-5054

Danil D. Khardin — student, data engineer

Vasilii I. Borisov — Cand. of Tech. Sci., associate professor, ORCID 0000-0003-0486-7552

¹ ООО Ophthalmosurgery Clinic Professorskaya Plus, 15, Vainera St., Yekaterinburg, 620014, Russia

² Ural State Medical University of the Ministry of Health of the Russian Federation, 3, Repina St., Yekaterinburg, 620028, Russia

Anastasia A. Nikiforova — Cand. of Med. Sci., ophthalmologist^{1, 2}, ORCID 0000-0001-6672-6726

Anna A. Dvornikova — ophthalmologist¹, ORCID 0009-0005-6983-0066

Andrey D. Stepichev — ophthalmologist¹, ORCID 0009-0005-4087-5957

ООО VisioMed.AI, 8, Golovinskoe Sh., Moscow, 125212, Russia

Mikhail K. Kulyabin — Cand. of Tech. Sci., data engineer, ORCID 0009-0007-0440-030X

For contacts: Vasily I. Borisov,

v.i.borisov@urfu.ru