Алгоритм сегментации и анализа отслойки пигментного эпителия

Р.Т. Самигуллин [1], Н.Ю. Ильясова [1,2], Д.В. Кирш [1,2], Е.Ю. Зубкова [3], Е.А. Замыцкий [4], Н.С. Демин [1,2]
[1] Самарский национальный исследовательский университет имени академика С.П. Королева, 443086, Россия, г. Самара, Московское шоссе, д. 34;
[2] Институт систем обработки изображений, НИЦ «Курчатовский институт», 443001, Россия, г. Самара, ул. Молодогвардейская, д. 151;
[3] ГБУЗ «Самарская областная клиническая офтальмологическая больница им. Т.И. Ерошевского», 443068, Россия, г. Самара, ул. Ново-Садовая, д. 158;
[4] Самарский государственный медицинский университет, 443099, Россия, г. Самара, ул. Чапаевская, д. 89

Аннотация

В работе представлен алгоритм автоматической сегментации отслойки пигментного эпителия (PED) на изображениях оптической когерентной томографии (ОКТ) с последующей количественной оценкой её морфометрических характеристик. Для выделения области PED использована свёрточная нейронная сеть архитектуры U-Net, обученная на экспертно аннотированных ОКТ-B-сканах. Точность сегментации оценивалась с применением метрик Dice Score (Dice) и Intersection over Union (IoU) и показала высокое соответствие референсной разметке (Dice = 0,8614; IoU = 0,7590). На основе сегментированных данных выполнена трёхмерная реконструкция PED и реализован расчёт линейных размеров, площади и объёма с учётом метрологических параметров томографа. Оценка результатов показала, что суммарная относительная погрешность объёмных измерений не превышает 2 – 3 %. Предложенный подход обеспечивает объективную и воспроизводимую количественную оценку PED и может быть использован в клинических и исследовательских задачах.

Ключевые слова: отслойка пигментного эпителия (PED), оптическая когерентная томография (ОКТ), сегментация изображений, глубокое обучение, количественная оценка, биомаркеры сетчатки, анализ морфологии.

Цитирование: **Самигуллин, Р.Т.** Алгоритм сегментации и анализа отслойки пигментного эпителия / Р.Т. Самигуллин, Н.Ю. Ильясова, Д.В. Кирш, Е.Ю. Зубкова, Е.А. Замыцкий, Н.С. Демин // Компьютерная оптика. – 2026. – Т. 50, № 5. – 2000. – doi: 10.18287/COJ2000.

Citation: Samigullin RT, Ilyasova NYu, Kirsh DV, Zubkova EYu, Zamytskiy EA, Demin NS. Algorithm for segmentation and analysis of pigment epithelial detachment. Computer Optics 2026; 50(5): 2000. doi: 10.18287/COJ2000.

Введение

Точная клиническая оценка параметров отслойки пигментного эпителия (PED) на данных оптической когерентной томографии (ОКТ) становится всё более значимой в офтальмологии. Повышенная частота выявления PED в контексте таких заболеваний, как возрастная макулярная дегенерация (ВМД), поликистическая хориоидальная васкуляризация (PCV) и другие формы хориоретинальной патологии, делает объёмную и морфометрическую характеристику PED важным элементом клинического мониторинга и прогноза.

Например, в многоцентровых фазах III-исследованиях TENAYA и LUCERNE показано, что морфологические признаки, по данным ОКТ, включая наличие и характеристики PED, широко используются для оценки активности неоваскулярной ВМД и мониторинга ответа на anti-VEGF терапию [1].

Существующие данные свидетельствуют, что морфологические характеристики PED, такие как высота, площадь и объём, имеют клиническое значение. В частности, показано, что большая высота PED ассоциирована с повышенным риском развития разрыва пигментного эпителия (RPE tear), являющегося серьёзным осложнением anti-VEGF терапии [2].

Комплексный анализ ОКТ-биомаркеров, включая количественную оценку PED, рассматривается как ключевой элемент персонализированного подхода к ведению пациентов с неоваскулярной ВМД [3, 4]. Внедрение автоматизированных методов анализа соответствует общей тенденции цифровизации и интеграции искусственного интеллекта в офтальмологическую практику [5, 6].

Кроме того, структурные характеристики PED и сопутствующие морфологические признаки (включая тип PED и параметры его внутренней структуры) коррелируют с функциональными исходами и ответом на лечение, что подчёркивает прогностическую значимость комплексной количественной оценки PED [3].

Повышенная частота выявления PED в контексте таких заболеваний, как возрастная макулярная дегенерация (ВМД), поликистическая хориоидальная васкуляризация (PCV) и другие формы хориоретинальной патологии [7], делает объёмную и морфометрическую характеристику PED важным элементом клинического мониторинга и прогноза.

В последние годы для автоматизации выделения анатомических и патологических структур на медицинских изображениях всё более широко применяются методы глубокого обучения, в том числе сверточные нейронные сети, показавшие высокую эффективность при анализе данных ОКТ и других видов медицинской визуализации [8 – 13].

Однако несмотря на признание клинической значимости, оценка PED часто остаётся ручной, субъективной и трудоёмкой процедурой. Разметка зон отслойки, измерение высоты, площади или объёма вручную с помощью программных средств требует значительного участия эксперта и подвержена меж- и внутрисубъектной вариабельности [14 – 15]. В условиях растущего объёма ОКТ-сканов и потребности в количественных биомаркерах для оценки эффективности терапии и прогноза возникает явная необходимость в автоматизации сегментации и количественного анализа PED. Автоматизированный подход может обеспечить более высокую воспроизводимость, ускорить процесс и повысить точность извлечения морфометрических параметров, что, в свою очередь, способствует интеграции данных в системы поддержки принятия решений и исследования на больших выборках.

Цель данного исследования – разработать алгоритм автоматической сегментации отслойки пигментного эпителия (PED) на ОКТ-изображениях и выполнить её количественную оценку (в частности, таких параметров, как высота, площадь, объём) для последующего использования в исследовательских и клинических задачах.

1. Материалы и методы

В исследовании использовали ретроспективную выборку ОКТ-изображений в формате DICOM, полученных с клинических томографов. В анализ включали серии B-сканов пациентов с диагностированной отслойкой пигментного эпителия (PED) различной этиологии, включая возрастную макулярную дегенерацию. Аннотирование данных выполняли эксперты-офтальмологи: на каждом исходном B-скане вручную сегментировали область PED для создания референсных масок, которые в дальнейшем использовали для обучения и валидации модели.

Для автоматического выделения области PED применяли алгоритм сегментации на основе сверточной нейронной сети архитектуры U-Net. Выбор архитектуры обусловлен её эффективностью в задачах анализа биомедицинских изображений, где требуется точное восстановление пространственных взаимоотношений структур. Симметричная структура U-Net по схеме «энкодер-декодер» с skip-соединениями позволяет объединять признаки разного уровня: глобальные контекстные особенности, извлекаемые энкодером, и локальные детали, восстанавливаемые декодером. Это свойство критически важно для точного определения границ PED, которые часто имеют сложную и нерегулярную форму. Эффективность U-Net и её модификаций продемонстрирована в задачах сегментации ОСТ-изображений, включая сравнение архитектур для разделения слоёв сетчатки [16]; сегментацию сосудов сетчатки с использованием комбинированных U-Net и VGG-моделей [17]; а также гибридную U-Net с механизмом внимания для сегментации подслоёв сетчатки [18]. Ряд исследований также подтверждает эффективность U-Net и его модификаций для решения смежных задач, таких как детекция глаукомы [19], семантическая сегментация ретинальной жидкости [20] и автоматический количественный анализ макулярного отека [21], что дополнительно обосновывает выбор данной архитектурной парадигмы. Эффективность алгоритма оценивали путём сравнения результатов автоматической сегментации с референсными экспертными масками. В результате работы алгоритма для каждого B-скана в серии генерировалась бинарная маска PED.

На основе серии сегментированных масок, реконструированных в трехмерный объем, проводили количественный анализ морфометрических характеристик PED. Рассчитываемые параметры включали максимальную высоту отслоения, площадь проекции на плоскость среза, объем отслоения (вычисленный как интегральная характеристика по всем B-сканам), а также оценивали пространственную конфигурацию области отслойки. Данный подход позволяет провести комплексную оценку морфологии PED и ее распределения в макулярной зоне.

Разработанная модель сегментации PED основана на архитектуре сверточной нейронной сети типа U-Net, реализованной с учётом особенностей биомедицинских изображений; общая схема архитектуры представлена на рис. 1.

Архитектура включает пять нисходящих и пять восходящих уровней, формирующих симметричную структуру «энкодер-декодер». Каждый уровень энкодера выполняет двойную свёртку с ядром 3×3, нормализацию по батчу и активацию ReLU, после чего применяется операция субдискретизации (MaxPooling 2×2), позволяющая уменьшить размерность признаковых карт и извлечь контекстные признаки. Восходящая часть декодера симметрично восстанавливает пространственное разрешение с использованием билинейной интерполяции, а на каждом уровне происходит объединение соответствующих признаков энкодера и декодера через skip-соединения, обеспечивающие сохранение детальной информации о границах объектов. Выходной слой реализован в виде свёртки 1×1, преобразующей многоканальные признаки в одноканальную карту вероятностей, отражающую распределение PED.

В процессе инференса применяется сигмоидная функция активации и последующая бинаризация при пороговом значении 0,5, что позволяет формировать итоговую бинарную маску области PED. Для повышения

точности пространственного соответствия результирующая маска масштабируется до исходного разрешения ОКТ-изображения с сохранением чётких контуров посредством интерполяции ближайшего соседа.

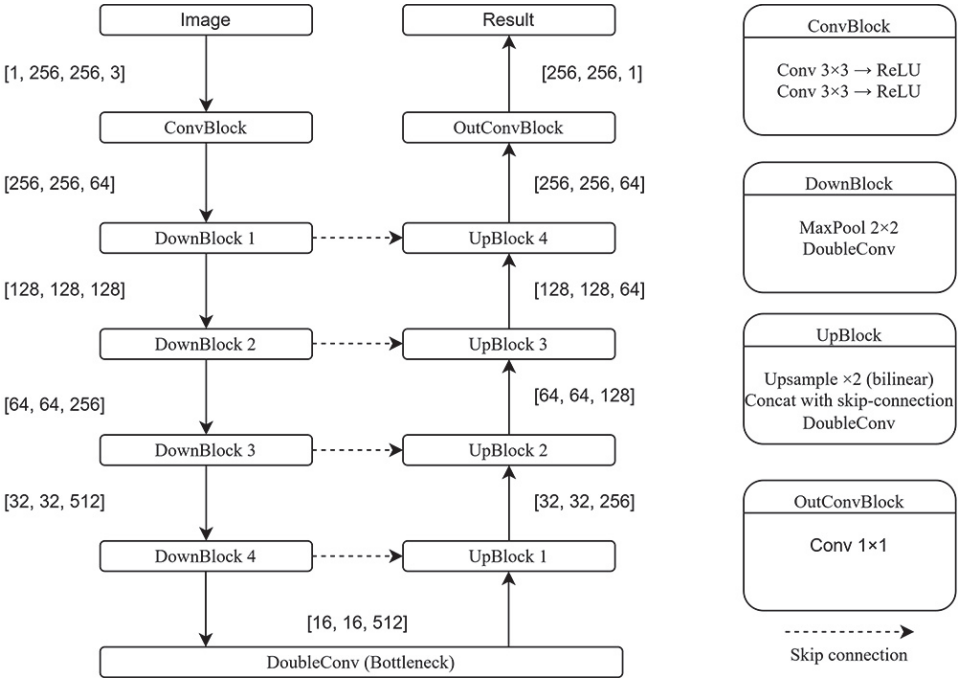


Рис. 1. Схема использованной модели нейронной сети U-net

2. Процесс обучения

Обучение модели осуществлялось на наборе данных из 1009 ОКТ-изображений, разделённых на обучающую (60 %), валидационную (20 %) и тестовую (20 %) выборки. Пример изображения представлен на рис. 2. Все изображения предварительно нормализовывались и приводились к размеру 256×256 пикселей. Для оптимизации использовался алгоритм Adam с начальными параметрами: скорость обучения 0,001, $\beta_1 = 0{,}9$, $\beta_2 = 0{,}999$. В качестве функции потерь применялась BCEWithLogitsLoss, объединяющая бинарную кросс-энтропию и сигмоидную активацию, что обеспечивает устойчивость обучения и корректную обработку классов с дисбалансом.

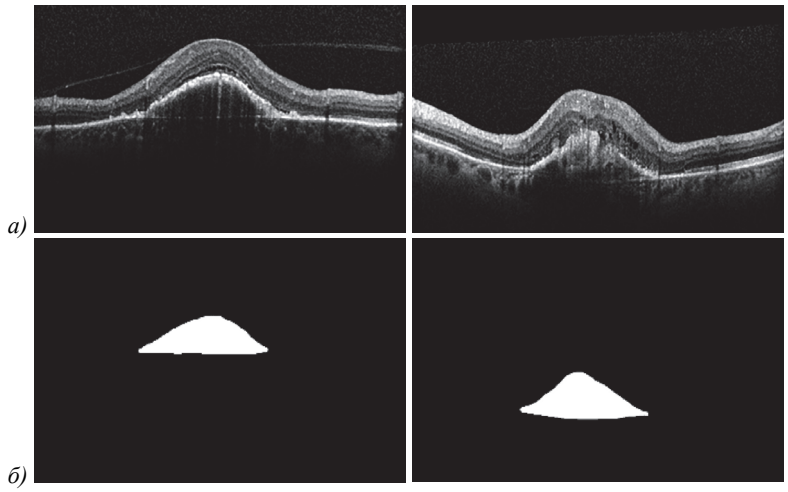
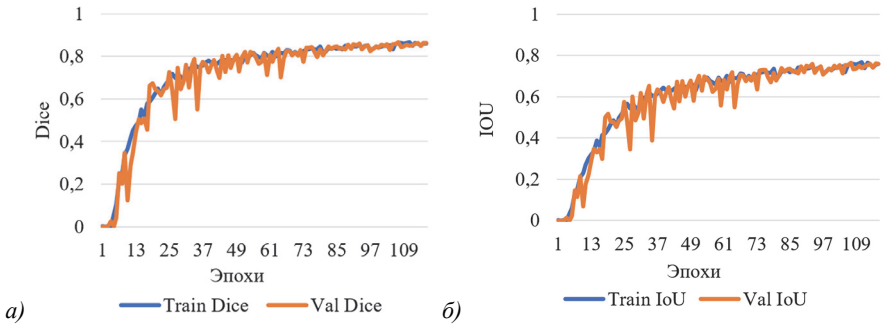


Рис. 2. Пример использованных для обучения данных: а) изображение, б) маска

Обучение выполнялось в течение 120 эпох с размером пакета 8, при этом реализована стратегия ранней остановки, основанная на контроле функции потерь на валидационной выборке. По завершении каждой эпохи рассчитывались метрики Dice Score и IoU, позволяющие оценить степень совпадения предсказанных масок с экспертной разметкой.

Динамика изменения значений метрик Dice Score и IoU на обучающей и валидационной выборках представлена на рис. 3 (*а* и *б* соответственно), что позволяет наглядно оценить процесс сходимости модели в ходе обучения.



а) *б)*

Рис. 3. Результаты обучения: а) по метрике Dice Score, б) по метрике IOU

Для предотвращения деградации модели в процессе обучения сохранялись веса с минимальным значением валидационных потерь. Итоговая модель тестировалась в режиме инференса на тестовых данных, что позволило подтвердить её способность к обобщению и точной локализации PED на B-сканах различного качества.

Финальная модель продемонстрировала высокую точность сегментации. Значение метрики Dice Score составило 0,8614, а IoU (Intersection over Union) – 0,7590. Анализ кривых обучения, представленных на рис. 3, подтвердил сходимость тренировочных и валидационных кривых, что свидетельствует об отсутствии выраженного переобучения.

3. Расчет количественных характеристик и погрешностей

Для перевода пиксельных измерений в физические параметры использовались характеристики прибора: размер одного B-скана 200×200 мкм, а расстояние между соседними сканами (межсрезовое расстояние) – 3,33 мкм. Указанные метрологические параметры томографа являются ключевыми для обеспечения корректности количественного анализа, так как позволяют установить однозначное соответствие между дискретным представлением данных в пикселях и реальными физическими размерами в пространстве. Это позволяет выполнять пересчёт координат и площадей из пиксельного представления в физические единицы, необходимые для количественного морфометрического анализа области отслойки пигментного эпителия (PED).

Масштабный коэффициент s (мкм/пиксель), необходимый для пересчёта пиксельных измерений в физические, вычислялся по формуле

$$s = \frac{L}{w},$$

где L – номинальная ширина скана (200 мкм), w – ширина изображения в пикселях.

Данный коэффициент применяется для перевода линейных размеров в плоскости сканирования, что обеспечивает корректность определения геометрических характеристик PED. Объём отслоения пигментного эпителия (PED) определялся как сумма площадей поперечных сечений на всех B-сканах с учётом межсрезового расстояния:

Объём отслоения пигментного эпителия (PED) определялся как сумма площадей поперечных сечений на всех B-сканах с учётом межсрезового расстояния:

$$V = s^2 h \sum_{i=1}^{n} N_i ,$$

где s^2 – масштабный коэффициент (мкм/пиксель), h – межсрезовое расстояние (мкм), N_i – количество пикселей объекта на i-м срезе.

Геометрические характеристики PED (длина, ширина и высота) вычислялись как разности между максимальными и минимальными координатами объекта по осям X, Y и Z соответственно. Особое клиническое значение имеет максимальная высота отслойки, которая рассчитывалась для каждого трёхмерного объекта. Такой подход обеспечивает количественную оценку формы и пространственного распределения PED в пределах макулярной зоны.

Оценка погрешности расчёта характеристик включает три основных компонента:

1. Погрешность масштабирования (Δs), связанная с неточностью определения номинальной ширины скана L.
2. Погрешность межсрезового расстояния (Δh), обусловленная дискретизацией пространства между соседними B-сканами.
3. Погрешность дискретизации (Δd), возникающая при представлении границ объектов в пиксельной сетке.

Расчёт погрешностей выполнялся с учетом трёх основных источников погрешности.

Погрешность масштабирования изображения является систематической и связана с неточностью определения номинальной ширины скана L. Для исследований принято знание $L = 200$ мкм. с погрешностью (1 % от L).

Масштабный коэффициент s вычисляется через L, следовательно:

$\frac{\Delta s}{s} = \frac{\Delta L}{L}$.

Дискретизация пространства вносит случайную погрешность, которая проявляется при определении межсрезового расстояния h. Последнее вычисляется через количество срезов n:

$$h = \frac{L}{n-1}.$$

Для межсрезового расстояния принимается аналогичная относительная погрешность:

$$\frac{\Delta h}{h} = \frac{\Delta L}{L}.$$

Погрешности линейных и объёмных параметров оценивались с учётом совместного влияния указанных факторов. Линейные размеры PED (длина, ширина, высота) имеют комбинированную погрешность, зависящую от масштабного и дискретного факторов:

$$\Delta L_{\text{общ}} = \sqrt{\left(\frac{s}{2}\right)^2 + (\Delta s)^2},$$

где $s/2$ соответствует половине пикселя (дискретизация изображения).

Относительная погрешность объёма учитывает влияние масштабного коэффициента по двум осям (X и Y) и межсрезового расстояния (ось Z):

$$\frac{\Delta V}{V} = \sqrt{\left(2\frac{\Delta s}{s}\right)^2 + \left(\frac{\Delta h}{h}\right)^2}.$$

Коэффициент 2 перед $\Delta s/s$ отражает квадратичную зависимость объёма от масштаба s^2 (площадь пикселя). Таким образом, общая погрешность определяется в основном аппаратными характеристиками томографа, в то время как вклад ошибки собственно сегментации, оцениваемой через метрики Dice и IoU, оказывается пренебрежимо малым при достижении высоких значений этих метрик.

4. Анализ результатов

Для томографа с параметрами:

– $L = 200$ мкм – номинальная ширина B-скана;

– $\Delta L/L = 0{,}01$ – относительная погрешность ширины скана (1 %);

– $h = 3{,}33$ мкм – межсрезовое расстояние между соседними B-сканами;

– $\Delta h/h = 0{,}01$ – относительная погрешность межсрезового расстояния.

Принимаем, что вклад дискретизации незначителен. Тогда относительная погрешность объёма составляет:

$$\frac{\Delta V}{V} = \sqrt{(2 \times 0{,}01)^2 + (0{,}01)^2} = \sqrt{0{,}0005} \approx 0{,}022,$$

что соответствует 2,2 %.

Даже при учёте дополнительной погрешности дискретизации ($\Delta N/N \approx 0{,}02$) итоговая погрешность не превышает 3 %. Это подтверждает достаточную точность метода для клинического морфометрического анализа PED, в том числе для динамического наблюдения, где важна регистрация минимальных, но статистически значимых изменений объёма патологии в ответ на терапию. Важно отметить, что ключевым условием достижения такой низкой общей погрешности является высокое качество исходной сегментации, которое в нашем случае обеспечено моделью U-Net и подтверждено метриками Dice Score (0,8614) и IoU (0,7590). Эти метрики свидетельствуют, что ошибка определения границ PED существенно ниже порога, который мог бы внести заметный вклад в погрешность итоговых физических измерений.



а) б) в)

Рис. 4. Пример построения маски: а) изначальное изображение, б) ручная разметка, в) предсказанная маска

Представленные на рис. 4 результаты наглядно демонстрируют высокую степень соответствия между экспертной разметкой и результатами работы алгоритма. Сопоставление сегментированных областей показывает, что модель корректно выделяет область PED даже в условиях неоднородной внутренней структуры

и нечётких границ, что часто встречается в клинической практике. Количественные же результаты, выраженные в метриках и оценке погрешности, указывают на то, что разработанный подход не только автоматизирует процесс, но и обеспечивает воспроизводимую и объективную количественную оценку, свободную от субъективной вариабельности, присущей ручным измерениям. Таким образом, комплексная оценка, объединяющая качественный анализ изображений и количественные метрики точности сегментации с оценкой погрешности морфометрии, всесторонне подтверждает эффективность и надёжность предложенного алгоритма для решения задач анализа PED.

Заключение

В ходе проведённого исследования была разработана и апробирована методика автоматической сегментации отслойки пигментного эпителия (PED) на оптических когерентных томограммах с последующей количественной оценкой её морфометрических характеристик. Применение архитектуры U-Net позволило обеспечить высокую точность выделения области PED, что является ключевым этапом для объективного анализа структурных изменений в сетчатке. Полученные результаты сегментации, пример которых представлен на рис. 3, продемонстрировали высокое соответствие экспертным разметкам (Dice Score 0,8614, IoU 0,7590), что подтверждает эффективность разработанного подхода и корректность выбора нейросетевой архитектуры.

На основе сегментированных масок был разработан метод вычисления количественных параметров PED, включающих объём, линейные размеры и пространственную конфигурацию. Разработанные формулы учитывают метрологические параметры томографа и особенности дискретизации данных, что позволило провести оценку погрешностей измерений. Показано, что суммарная относительная погрешность объёмной оценки составляет порядка 2 – 3 %, что делает метод пригодным для клинического применения и динамического мониторинга состояния пациентов.

Предложенный алгоритм обеспечивает автоматизацию процесса анализа PED, снижает субъективность оценок и позволяет получать воспроизводимые количественные показатели, что важно как для диагностики, так и для оценки эффективности терапии. Полученные результаты демонстрируют потенциал интеграции подобных алгоритмов в клинические рабочие процессы и системы поддержки принятия врачебных решений. Направления дальнейших исследований включают расширение набора анализируемых структур сетчатки с использованием современных архитектур глубокого обучения [22, 23], разработку многоуровневых моделей для сегментации сложных патологий и оптимизацию алгоритмов морфометрии для больших клинических выборок с учетом требований к клиническим испытаниям ИИ-решений [13].

Благодарности

Работа проведена в рамках выполнения государственного задания НИЦ «Курчатовский институт» (в части теории) и в рамках выполнения государственного задания Самарскому университету, шифр проекта FSSS-2024-0014 (в части экспериментов и программной реализации).

References

[1] Khanani AM, Guymer RH, Kaiser PK, Nishijo K, Wolf A, Gekkieva M, Heier JS. TENAYA and LUCERNE: Two-year results from the phase 3 neovascular age-related macular degeneration trials of faricimab with treat-and-extend dosing in year 2. Ophthalmology 2024; 131(8): 914-926. DOI: 10.1016/j.ophtha.2024.02.014.

[2] Leitritz MA, Gelisken F, Inhoffen W, Voelker M, Helb HM, Pauleikhoff D, Bartz-Schmidt KU, Schmitz-Valckenberg S. Can the risk of retinal pigment epithelium tears after bevacizumab treatment be predicted? An optical coherence tomography study. Eye 2008; 22: 1504-1507. DOI: 10.1038/eye.2008.145.

[3] Nawash B, Lakshmi K, Al-Sweedan SA, Alqudah A. Prognostic optical coherence tomography biomarkers in neovascular age-related macular degeneration. Journal of Clinical Medicine 2023; 12(9): 3049. DOI: 10.3390/jcm12093049.

[4] Rispoli M, Romano MR, Sacconi R, Marchese A, Parrulli F, Bandello F. Practical guidance for imaging biomarkers in exudative age-related macular degeneration. Survey of Ophthalmology 2023; 68(4): 615-627. DOI: 10.1016/j.survophthal.2023.02.004.

[5] Ul Kadir SM, Shamsuddin S, Azlan CAN, Yap CY, Tajul Arifin K. Artificial intelligence in ophthalmology: An overview. Ophthalmology Research 2022; 5(1). DOI: 10.33425/2639-9482.1024.

[6] Sivaguru R, Venkatesh D, Kumar A. Applications of artificial intelligence in the medical field: A survey. International Research Journal of Advanced Engineering Hub 2024; 2(3): 407-415. DOI: 10.47392/IRJAEH.2024.0060.

[7] Pedanova EK, Doga AV. Treatment of polypoid choroidal vasculopathy: Photodynamic therapy, anti-VEGF therapy, or their combination? A review [In Russian]. Ophthalmology in Russia 2019; 16(2): 151-158. DOI: 10.18008/1816-5095-2019-2-151-158.

[8] Saeidian J, Shafabakhsh R, Fathi A, Moeini A, Javanmard SH. Segmentation of choroidal area in optical coherence tomography images using a transfer learning-based conventional neural network: A focus on diabetic retinopathy and a literature review. BMC Medical Imaging 2024; 24(1): 281. DOI: 10.1186/s12880-024-01459-2.

[9] Marciniak T, Stankiewicz A, Zaradzki P. Neural networks application for accurate retina vessel segmentation from OCT fundus reconstruction. Sensors 2023; 23(4): 1870. DOI: 10.3390/s23041870.

[10] Leandro J, Nunes S, Alves D, Santos T, Leite J, Marques IP, Figueira J, Pires I. OCT-based deep-learning models for the identification of retinal key signs. Scientific Reports 2023; 13(1): 14628. DOI: 10.1038/s41598-023-41362-4.

[11] Zhang H, Jia Y, Liu Y, Chen H. Retinal OCT image segmentation with deep learning: A review of advances, datasets, and evaluation metrics. Computerized Medical Imaging and Graphics 2025; 123: 102539. DOI: 10.1016/j.compmedimag.2025.102539.
[12] Eckardt F, Menghini M, Birtel J, Weber RG, Herrmann P, Pfau M, Holz FG, den Hollander AI, Charbel Issa P. Deep learning-based retinal layer segmentation in optical coherence tomography scans of patients with inherited retinal diseases. Klinische Monatsblätter für Augenheilkunde 2025; 242(9): 903-911. DOI: 10.1055/a-2227-3742.
[13] Lin M, Chen Q, Liu J, Ma Y, Yu W. Recent advanced deep learning architectures for retinal fluid segmentation on optical coherence tomography images. Sensors 2022; 22(8): 3055. DOI: 10.3390/s22083055.
[14] Pattathil N, Zhao JZL, Sam-Oyerinde O, Felfeli T. Adherence of randomised controlled trials using artificial intelligence in ophthalmology to CONSORT-AI guidelines: A systematic review and critical appraisal. BMJ Health & Care Informatics 2023; 30(1): e100757. DOI: 10.1136/bmjhci-2023-100757.
[15] Balas M, Micieli JA, Wong JCY. Integrating AI with tele-ophthalmology in Canada: A review. Canadian Journal of Ophthalmology 2025; 60(3): e337-e343. DOI: 10.1016/j.jcjo.2024.08.013.
[16] Kugelman J, Zhang J, Abou Shousha M, Feuer W, Kishor K, Baniasadi N, Wang J, Lee CS, Lee AY. A comparison of deep learning U-Net architectures for posterior segment OCT retinal layer segmentation. Scientific Reports 2022; 12(1): 14888. DOI: 10.1038/s41598-022-18646-2.
[17] Wani MY, Bhat JI, Mir AH. Automated retinal blood vessel segmentation via U-Net and VGG-based models. Spectrum of Engineering Sciences 2025; 3(4): 490-498.
[18] Karn PK, Abdulla WH. Advancing ocular imaging: A hybrid attention mechanism-based U-Net model for precise segmentation of sub-retinal layers in OCT images. Bioengineering 2024; 11(3): 240. DOI: 10.3390/bioengineering11030240.
[19] Shinde R. Glaucoma detection in retinal fundus images using U-Net and supervised machine learning algorithms. Intelligent-Based Medicine 2021; 5: 100038. DOI: 10.1016/j.ibmed.2021.100038.
[20] Pavani PG, Biswal B, Gandhi TK, Kota AR. Robust semantic segmentation of retinal fluids from SD-OCT images using FAM-U-Net. Biomedical Signal Processing and Control 2024; 87: 105481. DOI: 10.1016/j.bspc.2023.105481.
[21] Michl M, Schlegl T, Waldstein SM, Bogunovic H, Podkowinski D, Gerendas BS, Sadeghipour A, Schmidt-Erfurth U. Automated quantification of macular fluid in retinal diseases and their response to anti-VEGF therapy. British Journal of Ophthalmology 2022; 106(1): 113-120. DOI: 10.1136/bjophthalmol-2020-317764.
[22] Aksenova LE, Fedorenko SV, Kurenkov AS, Zaytsev AV, Zheltov SYu, Khoroshilov AV. Development and testing of an automated system for retinal OCT image analysis [In Russian]. Doklady of the Russian Academy of Sciences. Mathematics, Informatics, Control Processes 2023; 514(2): 169-176.
[23] Ibragimova RR, Shchuko AG, Zhidkova SA, Pashkina AV, Khoroshilov AV. Algorithm for segmentation of macular OCT images for analysis of patients with age-related macular degeneration [In Russian]. Bulletin of Russian State Medical University 2022; (6): 89-96.

Сведения об авторах

Самигуллин Равиль Тагирович, 2001 года рождения, аспирант Самарского национального исследовательского университета имени академика С.П. Королева. Сфера научных интересов: интеллектуальный анализ медицинских изображений; цифровая обработка изображений; математическое моделирование; распознавание образов и искусственный интеллект. E-mail: *samigullin.ravil2015@yandex.ru*

Ильясова Наталья Юрьевна, 1966 года рождения. В 1991 году окончила с отличием Самарский государственный аэрокосмический университет имени С.П. Королёва (СГАУ). В 1997 году защитила диссертацию на соискание степени кандидата технических наук, в 2015 году защитила диссертацию на соискание степени доктора технических наук. В настоящее время работает в должности ведущего научного сотрудника Отделения «Институт систем обработки изображений – Самара» Курчатовского комплекса кристаллографии и фотоники федерального государственного бюджетного учреждения «Национальный исследовательский центр «Курчатовский институт» и по совместительству профессором кафедры технической кибернетики Самарского национального исследовательского университета имени академика С.П. Королева. Круг научных интересов включает цифровую обработку сигналов и изображений, анализ и интерпретацию биомедицинских изображений. Имеет более 250 публикаций, четыре монографии (в соавторстве). E-mail*: ilyasova@ipsiras.ru*

Кирш Дмитрий Викторович, 1990 года рождения, в 2019 году защитил диссертацию на соискание степени кандидата технических наук по специальности 05.13.17 «Теоретические основы информатики». В настоящий момент работает в должности доцента на кафедре технической кибернетики Самарского национального исследовательского университета имени академика С.П. Королева (Самарский университет), а также в должности научного сотрудника Отделения «Институт систем обработки изображений – Самара» Курчатовского комплекса кристаллографии и фотоники федерального государственного бюджетного учреждения «Национальный исследовательский центр «Курчатовский институт». Сфера научных интересов: цифровая обработка изображений и распознавание образов, машинное обучение, методы идентификации в кристаллографии. E-mail: *kirsh@ssau.ru*

Зубкова Елена Юрьевна, врач-офтальмолог, заведующая диагностическим отделением Самарской областной офтальмологической больницы имени Т.И. Ерошевского.

Замыцкий Евгений Андреевич, заведующий отделением лазерной микрохирургии ГБУЗ «СОКОБ им. Т.И. Ерошевского» ассистент кафедры офтальмологии ИПО Самарского государственного медицинского университета. Сфера научных интересов: диабетическая ретинопатия, диабетический макулярный отёк, лазерное лечение диабетического макулярного отёка. E-mail**:** *undue_@mail.ru.*

Демин Никита Сергеевич, 1994 года рождения, в 2025 году защитил диссертацию на соискание степени кандидата технических наук. В настоящий момент работает в должности старшего преподавателя кафедры технической кибернетики Самарского национального исследовательского университета имени академика С.П. Королева. Сфера научных интересов: интеллектуальный анализ медицинских изображений; цифровая обработка изображений; математическое моделирование; распознавание образов и искусственный интеллект. E-mail: *volfgunus@gmail.com*

Поступила в редакцию 24 марта 2026 г. *Окончательный вариант – 29 мая 2026 г.*

Algorithm for segmentation and analysis of pigment epithelial detachment

R.T. Samigullin [1], N.Yu. Ilyasova [1, 2], D.V. Kirsh [1, 2], E.Yu. Zubkova [3], E.A. Zamytskiy [4], N.S. Demin [1, 2]
[1] Samara National Research University, Moskovskoye Shosse 34, Samara, 443086, Russia;
[2] Image Processing Systems Institute, NRC "Kurchatov Institute", Molodogvardeyskaya St. 151, Samara, 443001, Russia;
[3] Samara Regional Clinical Ophthalmological Hospital named after T.I. Eroshevky, Samara, 443068, Russia, Samara, st. Novo-Sadovaya, 158;
[4] Samara State Medical University, Chapaevskaya St. 89, Samara, 443099, Russia

Abstract

The paper presents an algorithm for automatic segmentation of pigment epithelial detachment (PED) in optical coherence tomography (OCT) images, followed by a quantitative assessment of its morphometric characteristics. A convolutional neural network with a U-Net architecture, trained on expert-annotated OCT-B scans, was used to highlight the PED area. Segmentation accuracy was assessed using the Dice Score and Intersection over Union (IoU) metrics and showed high correspondence with the reference annotation (Dice = 0.8614; IoU = 0.7590). Based on the segmented data, a three-dimensional reconstruction of the PED was performed and the linear dimensions, area, and volume were calculated, taking into account the metrological parameters of the tomograph. The error assessment showed that the total relative uncertainty of the volume measurements did not exceed 2–3%. The proposed approach provides an objective and reproducible quantitative assessment of PED and can be used in clinical and research tasks.

Keywords: pigment epithelial detachment (PED), optical coherence tomography (OCT), image segmentation, deep learning, quantitative assessment, retinal biomarkers, morphology analysis.

Citation: Samigullin RT, Ilyasova NYu, Kirsh DV, Zubkova EYu, Zamytskiy EA, Demin NS. Algorithm for segmentation and analysis of pigment epithelial detachment. Computer Optics 2026; 50(5): 2000. doi: 10.18287/COJ2000.

Acknowledgements: The work was carried out within the state assignment of NRC “Kurchatov Institute” (theoretical part) and within the state assignment of Samara University, theme FSSS-2024-0014 (experiments and software implementation).

About authors

Ravil Tagirovich Samigullin (b. 2001), postgraduate student at Samara National Research University. Research interests: intellectual analysis of medical images; digital image processing; mathematical modeling; image recognition and artificial intelligence. E-mail: *samigullin.ravil2015@yandex.ru*

Nataly Yurievna Ilyasova (b. 1966), graduated with honors from S.P. Korolyov Samara State Aerospace University (SSAU) (1991). She received her PhD (1997) and DSc (2015) in Technical Sciences. At present, she is a leading researcher at the Image Processing Systems Institute, NRC "Kurchatov Institute" and also a part-time professor at the Technical Cybernetics Department of Samara National Research University. The area of interests includes digital signals and image processing, pattern recognition and artificial intelligence, biomedical imaging and analysis. Her list of publications contains more than 250 scientific papers and 4 monographs published with coauthors. E-mail: *ilyasova@ipsiras.ru*

Dmitriy Victorovich Kirsh (b. 1990) completed (2018) the postgraduate program in Computer Science and Computer Engineering. He received his PhD (2019) in Technical Sciences. At present, he is an associate professor at the Technical Cybernetics Department of Samara National Research University and also a researcher at the Image Processing Systems Institute, NRC "Kurchatov Institute". The area of interests includes digital image processing and pattern recognition, machine learning, identification of crystal lattices. E-mail: *kirsh@ssau.ru*

Elena Yurievna Zubkova, ophthalmologist. Head of the Diagnostic Department of the Samara Regional Ophthalmological Hospital named after T.I. Eroshevsky.

Evgeniy Andreevich Zamytskiy, Head of the Laser Microsurgery Department of the Samara Regional Ophthalmological Hospital named after T.I. Eroshevsky and Assistant at the Department of Ophthalmology, Institute of Professional Education, Samara State Medical University. Research interests: diabetic retinopathy, diabetic macular edema, diabetic macular edema laser treatment. E-mail: *undue_@mail.ru*

Nikita Sergeevich Demin (b. 1994), completed (2023) the postgraduate program in Computer Science and Computer Engineering. He received his PhD (2025) in Technical Sciences. At present he is an associate professor at the Technical

Cybernetics department of Samara University. The area of interests includes digital image processing, mathematical modeling, pattern recognition and artificial intelligence. E-mail: *volfgunus@gmail.com*

Received March 24, 2026. The final version – May 29, 2026.