

## ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И МАШИННОЕ ОБУЧЕНИЕ В ДИАГНОСТИКЕ ЦЕНТРАЛЬНОЙ СЕРОЗНОЙ ХОРИОРЕТИНОПАТИИ НА ОСНОВАНИИ ОПТИЧЕСКОЙ КОГЕРЕНТНОЙ ТОМОГРАФИИ

© А.Н. Куликов<sup>1</sup>, Е.Ю. Малахова<sup>2</sup>, Д.С. Мальцев<sup>1</sup>

<sup>1</sup> ФГБВОУ ВО «Военно-медицинская академия им. С.М. Кирова» Минобороны России, Санкт-Петербург;

<sup>2</sup> Институт физиологии им. И.П. Павлова Российской академии наук, Санкт-Петербург

Для цитирования: Куликов А.Н., Малахова Е.Ю., Мальцев Д.С. Искусственный интеллект и машинное обучение в диагностике центральной серозной хориоретинопатии на основании оптической когерентной томографии // Офтальмологические ведомости. — 2019. — Т. 12. — № 1. — С. 13–20. <https://doi.org/10.17816/OV12113-20>

Поступила: 26.12.2018

Одобрена: 11.02.2019

Принята: 15.03.2019

✧ **Цель** данного исследования состояла в изучении возможности машинного обучения для выявления изолированной отслойки нейроэпителия сетчатки и изменений пигментного эпителия сетчатки как диагностических критериев центральной серозной хориоретинопатии (ЦСХ). **Материал и методы.** В это исследование были включены пациенты с острой ЦСХ, прошедшие стандартное офтальмологическое обследование и выполнившие оптическую когерентную томографию с помощью RTVue-XR Avanti (протокол Angio Retina HD, 6 × 6 мм). Для обучающей разметки был использован ep face пласт толщиной 10 мкм в плоскости над пигментным эпителием сетчатки. В соответствии с задачами обучения нейронной сети на кросс-секционных сканах были выделены три категории патологических изменений: класс 1 — субретиальная жидкость, класс 2 — аномалии пигментного эпителия сетчатки и класс 3 — точки просачивания. Количество данных для каждой из категорий составило 4800/1400 тренировочных/тестовых изображений для класса 1, 2000/802 для класса 2 и 1504/408 для класса 3. Для решения задачи сегментации патологий на ОКТ-сканах была использована архитектура, аналогичная U-net. **Результаты.** Анализ тестовых сетов показал, что чувствительность, специфичность, точность и F1-мера в детекции субретиальной жидкости составили 0,61; 0,99; 0,99 и 0,76 соответственно; для детекции аномалий пигментного эпителия сетчатки чувствительность, специфичность, точность и F1-мера равнялись 0,14; 0,95; 0,94 и 0,24 соответственно; для детекции точки просачивания чувствительность, специфичность, точность и F1-мера составили 0,06; 1,0; 1,0 и 0,12 соответственно. **Заключение.** Таким образом, машинное обучение демонстрирует высокий потенциал в идентификации патологических изменений, характерных для острой формы ЦСХ (отслойки нейроэпителия сетчатки и альтерации пигментного эпителия сетчатки), по данным ОКТ. Томическая индикация точки просачивания представляется возможной на больших обучающих сетах.

✧ **Ключевые слова:** центральная серозная хориоретинопатия; оптическая когерентная томография; искусственный интеллект; машинное обучение; нейронная сеть.

## ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING FOR OPTICAL COHERENCE TOMOGRAPHY-BASED DIAGNOSIS IN CENTRAL SEROUS CHORIORETINOPATHY

© A.N. Kulikov<sup>1</sup>, E.Yu. Malahova<sup>2</sup>, D.S. Maltsev<sup>1</sup>

<sup>1</sup> S.M. Kirov Military Medical Academy, Saint Petersburg, Russia;

<sup>2</sup> Pavlov Institute of Physiology Russian Academy of Sciences, Saint Petersburg, Russia

For citation: Kulikov AN, Malahova EYu, Maltsev DS. Artificial intelligence and machine learning for optical coherence tomography-based diagnosis in central serous chorioretinopathy. *Ophthalmology Journal*. 2019;12(1):13-20. <https://doi.org/10.17816/OV12113-20>

Received: 26.12.2018

Revised: 11.02.2019

Accepted: 15.03.2019

✧ **The aim** of the present study was to examine the potential of machine learning for identification of isolated neurosensory retina detachment and retinal pigment epithelium (RPE) alterations as diagnostic criteria of central serous chorioretinopathy (CSC). **Material and methods.** Patients with acute CSC

in whom a standard ophthalmic examination and optical coherence tomography (OCT) using RTVue-XR Avanti (Angio Retina HD scan protocol,  $6 \times 6$  mm) was performed were included in the study. 10- $\mu$ m en face slab above the RPE layer was used to create ground truth masks. Learning aims were defined as identification of 3 classes of structural abnormalities on OCT cross-sectional scans: class 1 — subretinal fluid, class 2 — RPE abnormalities, and class 3 — leakage points. Data for each of the 3 classes included: 4800/1400 training/test images for class 1, 2000/802 training/test images for class 2, and 1504/408 training/test images for class 3. Unet-similar architecture was used for segmentation of abnormalities on OCT cross-sectional scans. **Results.** Analysis of test sets revealed sensitivity, specificity, precision, and F1-score for detection of subretinal fluid of 0.61, 0.99, 0.99, and 0.76, respectively. For detection of RPE abnormalities sensitivity, specificity, precision, and F1-score were 0.14, 0.95, 0.94 and 0.24, respectively. For detection of leakage point sensitivity, specificity, precision, and F1-score were 0.06, 1.0, 1.0, and 0.12, respectively. **Conclusions.** Thus, machine learning demonstrated high potential in the OCT-based identification of structural abnormalities associated with acute CSC (neurosensory retina detachment and RPE alterations). Topical identification of the leakage point appears to be possible using large learning sets.

✧ **Keywords:** central serous chorioretinopathy; optical coherence tomography; artificial intelligence; machine learning; neural network.

В офтальмологии в целом, и особенно в ретинологии, диагностические подходы базируются преимущественно на технологиях, связанных с получением и анализом изображений. Однако большие объёмы данных, требующих анализа, и сложный характер анализируемых изображений могут снижать эффективность таких диагностических подходов. Это наиболее заметно в рамках скрининговых программ и первичной диагностики, когда потребность в автоматизации и увеличении точности анализа наиболее высока.

В последнее время с экспоненциальным ростом производительности компьютеров стал возможен относительно быстрый анализ большого количества данных, составивший основу технологий искусственного интеллекта (ИИ). ИИ позволяет использовать компьютер для решения задач без применения строгого алгоритма. Примером такой задачи является распознавание изображения с целью идентификации изображаемых объектов независимо от их переменных неспецифичных характеристик и окружения на изображении. При этом решение конкретной задачи достигается путём обучения в процессе предварительного решения множества сходных задач — машинного обучения, именно поэтому ИИ и машинное обучение, как способ решения задачи по анализу диагностических изображений, могут совершить революцию в диагностике заболеваний органа зрения. Примером клинического применения ИИ и машинного обучения служит скрининг на наличие диабетической ретинопатии с помощью машинного анализа фундус-снимков, который уже сейчас демонстрирует высокие показатели работоспособности [1].

Оптическая когерентная томография (ОКТ) — технология неинвазивной прижизненной визуализации структур глаза с разрешением до 5 мкм. ОКТ хорошо подходит на роль скринингового подхода в ретинологии, так как позволяет относительно быстро и неинвазивно диагностировать все основные заболевания центральной сетчатки (макулопатии).

ОКТ применяют для диагностики центральной серозной хориоретинопатии (ЦСХ). Хотя с появлением ОКТ ЦСХ стала относительно легко диагностируемым заболеванием, без использования флюоресцентной ангиографии (ФАГ) диагноз ставят в том числе путём исключения других возможных причин аккумуляции субретинальной жидкости. Ключевое значение при этом имеет анализ состояния пигментного эпителия сетчатки (ПЭС), который остаётся относительно сохранным при острой форме этого заболевания [2]. Известным ограничением применения ОКТ для диагностики ЦСХ является невозможность идентифицировать точку просачивания, что необходимо не только для верификации диагноза, но и для лечения, в случае если оно показано. Тем не менее в нескольких работах было установлено, что идентификация точки просачивания с помощью ОКТ возможна по крайней мере у части пациентов с ЦСХ, однако такой подход достаточно сложен даже для опытного специалиста [3–5].

Таким образом, улучшение анализа изображений ОКТ при ЦСХ представляет собой важную клиническую проблему, которая может быть решена с применением машинного обучения. Потенциальная цель машинного распознавания данных ОКТ может быть сведена к задачам, ко-

которые решает специалист при диагностике ЦСХ на основании ОКТ: 1) предположение, что данный случай подозрителен на наличие ЦСХ (по наличию отслойки относительно неизменённого нейрорепителля; 2) исключение сходных патологических состояний, прежде всего влажной формы возрастной макулярной дегенерации по степени изменения ПЭС; 3) идентификация зоны, предположительно ответственной за просачивание. Возможности детекции субретиальной жидкости с помощью машинной сегментации уже были показаны ранее [6–8]. Однако успешное решение всех трёх задач не только позволяет с высокой степенью достоверности классифицировать данные ОКТ как относящиеся к ЦСХ, но и создаёт основу для составления плана лечения, в случае если оно потребуется.

**Целью** данного исследования было изучить возможности машинного обучения для выявления изолированной отслойки нейрорепителля сетчатки (НЭС) и изменений ПЭС как диагностических критериев ЦСХ.

## МАТЕРИАЛ И МЕТОДЫ

### Получение данных

В исследование были включены пациенты с острой ЦСХ длительностью не более 6 месяцев с верифицированной с помощью ФАГ точкой просачивания. Критериями исключения были: анамнестически установленные повторные эпизоды заболевания; признаки хронической ЦСХ (выраженные изменения пигментного эпителия, атрофия НЭС, диффузное просачивание по данным ФАГ); любые сопутствующие заболевания заднего сегмента глаза; изменения прозрачности оптических сред, препятствующие адекватной визуализации заднего сегмента; качество ОКТ-сканирования менее 7/10.

Все пациенты прошли стандартное офтальмологическое обследование и выполнили ОКТ. ОКТ было проведено с помощью RTVue-XR Avanti (Optovue, Fremont, CA) и включало 6-мм трёхмерный скан (400 повторных В-сканов по 400 А-сканов каждый) по протоколу Angio Retina HD, центрированный по центру макулы или точке просачивания. В случае наличия нескольких отслоек НЭС, не входящих в пределы одного скана, каждую отслойку включали в отдельный скан.

### Разметка данных

Структурные изображения анфас в пласте Custome (между линией сегментации мембраны Бруха в позиции 0 мкм и линией сегментации

мембраны Бруха в позиции 10 мкм) были экспортированы для визуализации зоны отслойки и создания масок пространственного распределения зон отслойки НЭС, зон изменений ПЭС и отдельно зон изменений ПЭС, ответственных за просачивание. Зона, ответственная за просачивание, была определена путём наложения анфас-изображения на изображение ФАГ. Флюоресцентную ангиографию выполняли по стандартному протоколу, для анализа использовали снимки, полученные на 20–35-й секунде.

### Создание обучающего множества

В соответствии с задачами обучения нейронной сети были выделены три категории патологических изменений: наличие субретиальной жидкости (1), аномалии ПЭС (2) и точек просачивания (3). Если категория присутствовала на трёхмерном скане, то отмечали координаты, ограничивающие её область. Область категории 1 была дополнительно уточнена при помощи 2D-маски пространственного распределения зон отслойки НЭС. Таким образом, сопоставляли трёхмерный ОКТ-снимок и бинарные ground-truth-маски (по количеству категорий), указывающие ограничивающие координаты области интереса. Оригинальные файлы ОКТ-сканов были считаны в numpy-массивы, переведены в логарифмическую шкалу и нормализованы. Полученные массивы переведены в 2D-изображения, аналогичные А- и В-сканам, и сопоставлены с соответствующим срезом трёхмерной маски. Из 46 ОКТ-снимков десять случайным образом были выбраны как тестовые изображения и не предъявлялись нейронной сети во время обучения. В обучающее множество для отдельной задачи входили изображения, на которых присутствовала область интереса. Количество данных, таким образом, отличалось для каждой из категорий, составляя 4800/1400 тренировочных/тестовых изображений для класса 1, 2000/802 для класса 2 и 1504/408 для класса 3. Для увеличения мощности тренировочного сета производили аугментацию данных: размеры изображения могли быть увеличены/уменьшены на 0,4 от оригинального размера, отражены по горизонтали либо повернуты на угол до 30°. Размер подаваемых в модель изображений составлял 256 × 256 пикселей.

### Статистические методы

Так как модели обучали решению задачи бинарной сегментации, для оценки качества рабо-

ты алгоритма мы использовали матрицу ошибок (TP — истинно положительные, TN — истинно отрицательные, FP — ложноположительные, FN — ложноотрицательные) и основанные на ней показатели — чувствительность, специфичность, точность, F1-мера.

Чувствительность =  $TP / P$ .

Специфичность =  $TN / N$ .

Точность =  $TP / (TP + FP)$ .

F1-мера =  $2TP / (2TP + FP + FN)$ .

Метрики рабочей характеристики приёмника (ROC) и площади под кривой (AUC) не были применимы из-за значительного дисбаланса классов. ROC-кривая отражает качество классификации в координатах чувствительности и специфичности.

При анализе изображений использовали два основных подхода: классификацию и сегментацию, соответствующие анализу множества сканов и каждого индивидуального изображения.

### Архитектура нейронной сети

Для решения задачи сегментации патологий на ОКТ-сканах мы выбрали архитектуру, аналогичную Unet [9], которая широко применяется для анализа медицинских данных. Нейронная сеть состоит из четырёх свёрточных слоёв (32–32–64–64 фильтров размером  $3 \times 3$  пикселей), чередующихся операциями подвыборки, и четырёх последующих свёрточных слоёв, чередующихся операциями повышающей дискретизации (64–64–64–64 фильтров размером  $3 \times 3$  пикселей). После первой операции, повышающей дискретизации к признакам, извлечённым в предыдущем слое, добавляется информация из начальных свёрточных слоёв. Завершается процесс сегментации двумя дополнительными свёрточными слоями (32–1 фильтров размером  $3 \times 3$  пикселей). В качестве функции активации во внутренних слоях применяется ReLU, выходной слой сигмоида. Общее количество обучаемых параметров сети составляет 305К.

Таблица 1 / Table 1

**Статистические показатели эффективности работы нейронной сети по сегментации В-сканов**  
**Statistical indices of neural network working efficacy upon B-scan segmentation**

Показатели	Чувствительность	Специфичность	Точность	F1-мера
Субретинальная жидкость	0,67	0,98	0,70	0,68
Аномалии ПЭС	0,51	0,99	0,13	0,21
Точки просачивания	0,60	0,99	0,05	0,09

Примечание. ПЭС — пигментный эпителий сетчатки.

### РЕЗУЛЬТАТЫ


В исследование было включено 40 пациентов (46 глаз), средний возраст пациентов составил  $44,8 \pm 10,8$  года, среди них было 34 мужчины и 6 женщин. Всего использовали 46 индивидуальных трёхмерных сканов, каждый из которых рассматривали как отдельный случай.

Для каждой из поставленных задач была обучена нейронная сеть, выделяющая на изображениях А- и В-сканов патологические области. Результатом работы сети является двухмерная маска с размером, аналогичным входным данным ( $256 \times 256$  пикселей). Маска представляет собой карту вероятностей отнесения каждого отдельного пикселя к целевому классу. Для расчёта качества работы алгоритма выходная маска была бинаризирована по значению 0,5, где все пиксели с вероятностями больше указанной принимались за классифицированные положительно.

Качество работы модели оценивали по скану в целом, то есть из ОКТ-данных извлекали В-сканы, которые по отдельности подавали в модель для анализа, затем полученные предсказания компоновались в 3D-объём и сравнивались с 3D-маской. В табл. 1 приведены результаты, усреднённые по всему тестовому множеству. Следует учитывать, что разметка не являлась попиксельной — маска приблизительно ограничивала патологическую область (разметка bounding box). При этом зона интереса аппроксимировалась до прямоугольной, что в процессе обучения и тестирования моделей приводило к погрешностям в сегментации (рис. 1).


Дополнительно мы оценили качество классификации изображения по всей совокупности В-сканов: каждому В-скану присваивали положительный класс, если в нём было найдено хотя бы 5 пикселей, отнесённых к патологическим. Полученные для срезов категории сравнивали с исходными данными (В-скан считался положительным, если в маске присутствовали положительно размеченные пиксели). Результаты представлены в табл. 2 (рис. 2).





**Рис. 1.** Пример детекции обученной нейронной сетью субретинальной жидкости на индивидуальном В-скане: *a* — исходный В-скан; *b* — результат распознавания зоны скопления субретинальной жидкости; *c* — распределение вероятностной характеристики наличия субретинальной жидкости

**Fig. 1.** Example of detection of subretinal fluid within an individual B-scan by the taught-in neural network: *a* — a raw cross-sectional OCT scan; *b* — resultant image of detection of subretinal fluid accumulation area; *c* — distribution of a probabilistic characteristic of subretinal fluid presence



**Рис. 2.** Репрезентативный пример детекции субретинальной жидкости на совокупности В-сканов обученной нейронной сетью: *a* — анфас-изображение, демонстрирующее распределение субретинальной жидкости; *b* — результат распознавания и картирования зоны распределения субретинальной жидкости в совокупности В-сканов; *c* — распределение вероятностной характеристики наличия субретинальной жидкости на индивидуальном В-скане. Положение скана отмечено пунктирной линией

**Fig. 2.** Representative example of subretinal fluid detection within a stack of B-scans by the taught-in neural network: *a* — en face image demonstrating the subretinal fluid distribution; *b* — resultant image after detection and mapping of subretinal fluid from a stack of B-scans; *c* — distribution of a probabilistic characteristic of subretinal fluid presence on an individual B-scan. The dashed line represents a position of cross-sectional scan

Таблица 2 / Table 2

**Статистические показатели эффективности работы нейронной сети по классификации совокупности В-сканов**  
**Statistical indices of neural network working efficacy upon B-scan set classification**

Показатели	Чувствительность	Специфичность	Точность	F1-мера
Субретинальная жидкость	0,61	0,99	0,99	0,76
Аномалии ПЭС	0,14	0,95	0,94	0,24
Точки просачивания	0,06	1,0	1,0	0,12

Примечание. ПЭС — пигментный эпителий сетчатки.

## ОБСУЖДЕНИЕ

В данном исследовании проведён анализ возможностей машинного обучения для классификации изменений сетчатки при острой неосложненной ЦСХ. Используемая нейронная сеть и алгоритм обучения позволяют достичь высоких показателей чувствительности и специфичности в диагностике отслойки НЭС как в пределах каждого индивидуального В-скана, так и в совокупности В-сканов. Таким образом задачу картирования распределения субретинальной жидкости можно считать успешно решённой. В индикации аномалий ПЭС, что является более сложной задачей, нейронная сеть продемонстрировала несколько худшие показатели, в первую очередь за счёт сниженных показателей чувствительности при анализе совокупности сканов, хотя выявление заметной альтерации ПЭС (например, высоких отслоек) осуществляется эффективно и с высокой специфичностью. Несмотря на то что совокупность этих диагностических алгоритмов может лечь в основу первичной диагностики ЦСХ с помощью ОКТ, текущее состояние модели не позволяет использовать все элементы алгоритма с равной эффективностью.

Существует две основные причины снижения работоспособности системы при анализе изменений ПЭС: трудности точной разметки и ограниченное представительство этого класса изменений в обучающих сетях, из которых последняя, на наш взгляд, имеет наибольшее значение. При достаточно высокой распространённости в популяции только ограниченное число случаев подходит для обучения нейронной сети, что отражено в критериях включения — исключения. Высокие требования к однородности и разрешению сканов также ограничивают входной поток случаев. Кроме того, часть наблюдений необходимо было исключить из обучающего сета для последующего использования в тесте. Таким образом, только около 40 индивидуальных случаев было взято для обучения.

Проблема больших массивов данных для обучения хорошо известна в области ИИ. В ранее опубликованных работах, исследующих применение технологий машинного обучения для анализа данных ОКТ, обучающие сети включают до 100 000 индивидуальных сканов. Общее количество сканов в нашем обучающем сете составило более 16 000. Однако представительство анализируемых признаков было неравномерным. Если, по приблизительным оценкам, отслойку НЭС включали 40–50 % В-сканов, то изменения

ПЭС присутствовали не более чем в 15 % сканов, а точка просачивания была представлена не более чем в 5 % сканов. Это полностью отражает результаты работы нейронной сети по идентификации данных типов изменений. Таким образом, для адекватного обучения идентификации точки просачивания может потребоваться в 10 раз больше индивидуальных случаев.

Другая, упомянутая выше проблема, — точность картирования изменений. Поскольку разметка каждого индивидуального В-скана ограниченной группой специалистов в большом массиве данных не представляется возможной, использование системы координат (разметка bounding box) наиболее целесообразно. Однако это ведёт к тому, что существенное представительство в патологических зонах принадлежит нормальным или не относящимся к этому виду патологии областям. Это становится очевидным, если учесть, что зона разметки представляет собой прямоугольник, а любая патологическая зона имеет неправильную форму. Хотя эта проблема не может быть решена напрямую — улучшением разметки, наращивание обучающего сета способно преодолеть это ограничение. Более того, на большом сете это может дать преимущества в обучении, так как система будет лучше «знакома» с «неидеальными» данными.

Притом что фактически в исследовании использовали малый обучающий сет, его результаты показывают перспективы применения ИИ в сфере ОКТ-диагностики в офтальмологии. Более того, логические подходы к диагностике, использованные в нашей работе, демонстрируют свою применимость по крайней мере в рамках ЦСХ и, возможно, сходных заболеваний.

Описанный алгоритм базируется на оценке всего массива данных трёхмерного скана, а не только отдельных В-сканов, что важно для дифференциальной диагностики и выявления бессимптомных случаев. Именно отсутствие существенных изменений за пределами отслойки НЭС имеет значение для дифференциальной диагностики, поскольку при других макулопатиях НЭС и ПЭС за пределами отслойки НЭС могут демонстрировать различные патологические изменения. Анализ «сырого» файла даёт возможность исключить участие человеческого фактора на этапе до обработки данных нейронной сетью. Этот факт также позволяет рассчитывать на выявление зон, ответственных за просачивание, поскольку потенциально такая зона может локализоваться в любом участке отслойки НЭС.

Трёхмерное сканирование является хорошо известной опцией ОКТ, с помощью которой удаётся составить представление о состоянии всей макулы по данным одного скана. Однако длительное время при оценке большой площади глазного дна происходила потеря в качестве изображения кросс-секционных тканей, и ультраструктурный анализ состояния НЭС и ПЭС на таких сканах не мог быть выполнен адекватным образом. В последние несколько лет два события в процессе эволюции ОКТ изменили ситуацию: многократное увеличение скорости сканирования и применение технологий коррекции артефактов движения. Всё это привело к увеличению разрешения каждого индивидуального кросс-секционного скана в пределах трёхмерного скана до величин, обеспечивающих идентификацию минимальных изменений ПЭС, например характерных для точки просачивания при ЦСХ. Кроме того, это позволило уменьшить шаг между последовательными кросс-секционными сканами и минимизировать вероятность того, что патологические изменения будут локализоваться между сканами. Таким образом, анализ сетчатки и ПЭС с высоким разрешением в пределах трёхмерного скана представляет собой дополнительную, не в полной мере оценённую опцию ОКТ-ангиографии, удачно вписывающуюся в концепцию машинного обучения.

Сильная сторона этого исследования состоит в том, что, кроме прямой задачи улучшения диагностики ЦСХ, оно показывает возможность решения сходных классификационных задач для идентификации источника экссудации при других макулопатиях. Например, этот подход может быть реализован для целей планирования лазерных вмешательств при диабетическом макулярном отёке, связанном с просачиванием из микроаневризм. Работа классификатора для этих случаев будет иметь сходный алгоритм: 1) обнаружение патологической зоны; 2) выявление подозрительных микроаневризм; 3) идентификация микроаневризм, ответственных за просачивание и служащих мишенями лазерного воздействия. Кроме того, в данном исследовании обучающий и тестовый наборы были получены на разных пациентах, поэтому дублирование изображений в процессе обучения и в эксперименте исключено.

Данное исследование имеет несколько ограничений. Во-первых, мы не проводили сравнения диагностических возможностей системы для смешанной выборки, включающей помимо ЦСХ и другие заболевания. Этот вопрос важен для прямого клинического применения, однако требу-

ет отдельного изучения. Во-вторых, для диагностики ЦСХ большое значение имеет состояние сосудистой оболочки, которое оценивают по морфологическим изменениям, внутренней структуре и толщине. Эти данные могут быть использованы в первичной (и дифференциальной) диагностике, так как увеличение индекса васкуляризации и толщины сосудистой оболочки позволяет исключить ряд других макулопатий. При этом повышается точность идентификации точки просачивания, которая обычно связана с локальным утолщением сосудов сосудистой оболочки. Хотя мы не знаем, какую роль сыграл анализ сосудистой оболочки в применённом нами алгоритме, трёхмерного сканирования, основанного на усреднении четырёх сканов, может быть недостаточно для полного анализа некоторых случаев с использованием данных спектральной ОКТ, так как этот вариант ОКТ ограничен глубиной проникновения сканирующего луча. В-третьих, в исследование включено относительно небольшое число пациентов. Как и во многих подобных исследованиях, этот недостаток частично компенсируется фрагментацией изображений. Однако это накладывает ограничения на экстраполяцию результатов на весь спектр ЦСХ, которая в целом (в отличие от острой формы) является достаточно полиморфной патологией.

## ЗАКЛЮЧЕНИЕ

Данное исследование продемонстрировало высокий потенциал технологии искусственного интеллекта и машинного обучения в диагностике отдельных морфологических характеристик ЦСХ на основании данных трёхмерного ОКТ-сканирования. Среди основных морфологических изменений наиболее точно детектируются отслойки НЭС и альтерация ПЭС как в пределах индивидуальных В-сканов, так и на анфас-изображении. Детекция точки просачивания по данным ОКТ на основании машинного обучения возможна, но для адекватной работы такого алгоритма требуется большой массив обучающих данных.

### *Раскрытие конфликта интересов*

У авторов нет конфликта интересов и материальной заинтересованности в данном исследовании.

### *Участие авторов*

Д.С. Мальцев, Е.Ю. Малахова — концепция и дизайн исследования.

Д.С. Мальцев, Е.Ю. Малахова — сбор и обработка материала.

Д.С. Мальцев, Е.Ю. Малахова, А.Н. Куликов — написание текста.

А.Н. Куликов — редактирование.

## ЛИТЕРАТУРА

1. Gargeya R, Leng T. Automated identification of diabetic retinopathy using deep learning. *Ophthalmology*. 2017;124(7):962-969. <https://doi.org/10.1016/j.ophtha.2017.02.008>.
2. Daruich A, Matet A, Dirani A, et al. Central serous chorioretinopathy: Recent findings and new physiopathology hypothesis. *Prog Retin Eye Res*. 2015;48:82-118. <https://doi.org/10.1016/j.preteyeres.2015.05.003>.
3. Maltsev DS, Kulikov AN, Chhablani J. Topography-guided identification of leakage point in central serous chorioretinopathy: a base for fluorescein angiography-free focal laser photocoagulation. *Br J Ophthalmol*. 2018;102(9):1218-1225. <https://doi.org/10.1136/bjophthalmol-2017-311338>.
4. Бойко Э.В., Мальцев Д.С. Фокальная навигационная лазерная коагуляция сетчатки с помощью ОКТ-картирования // Вестник офтальмологии. — 2016. — Т. 132. — № 3. — С. 56–60. [Boyko EV, Mal'tsev DS. En face' optical coherence tomography guided focal navigated laser photocoagulation. *Annals of ophthalmology*. 2016;132(3):56-60. (In Russ.)]. <https://doi.org/10.17116/oftalma2016132356-60>.
5. Maltsev DS, Kulikov AN, Chhablani J. Clinical application of fluorescein angiography-free navigated focal laser photocoagulation in central serous chorioretinopathy. *Ophthalmic Surg Lasers Imaging Retina*. [In Press]
6. Xiang D, Tian H, Yang X, et al. Automatic segmentation of retinal layer in OCT images with choroidal neovascularization. *IEEE Trans Image Process*. 2018;27(12):5880-5891. <https://doi.org/10.1109/TIP.2018.2860255>.
7. Khalid S, Akram MU, Hassan T, et al. Fully automated robust system to detect retinal edema, central serous chorioretinopathy, and age related macular degeneration from optical coherence tomography images. *Biomed Res Int*. 2017;2017:7148245. <https://doi.org/10.1155/2017/7148245>.
8. Wu M, Fan W, Chen Q, et al. Three-dimensional continuous max flow optimization-based serous retinal detachment segmentation in SD-OCT for central serous chorioretinopathy. *Biomed Opt Express*. 2017;8(9):4257-4274. <https://doi.org/10.1364/BOE.8.004257>.
9. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. In: Medical image computing and computer-assisted intervention – MICCAI 2015. MICCAI 2015. Lecture notes in computer science. Vol. 9351. Ed. by N. Navab, J. Hornegger, W. Wells, A. Frangi. Cham: Springer; 2015. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28).

## Сведения об авторах

**Алексей Николаевич Куликов** — д-р мед. наук, доцент, начальник кафедры офтальмологии. ФГБВОУ ВО «Военно-медицинская академия им. С.М. Кирова» Министерства обороны Российской Федерации, Санкт-Петербург. E-mail: alexey.kulikov@mail.ru. SPIN: 6440-7706.

**Екатерина Юрьевна Малахова** — младший научный сотрудник. Институт физиологии им. И.П. Павлова Российской академии наук, Санкт-Петербург. E-mail: katerina.malahova@gmail.com.ru.

**Дмитрий Сергеевич Мальцев** — канд. мед. наук, врач-офтальмолог клиники офтальмологии. ФГБВОУ ВО «Военно-медицинская академия им. С.М. Кирова» Министерства обороны Российской Федерации, Санкт-Петербург. E-mail: glaz.med@yandex.ru.

## Information about the authors

**Alexey N. Kulikov** — MD, PhD, DMedSc, Professor, Head of the Department. Ophthalmology Department. S.M. Kirov Military Medical Academy, St. Petersburg, Russia. E-mail: alexey.kulikov@mail.ru. SPIN: 6440-7706.

**Ekaterina Yu. Malahova** — Associate Researcher. Pavlov Institute of Physiology Russian Academy of Sciences, St. Petersburg, Russia. E-mail: katerina.malahova@gmail.com.

**Dmitrii S. Maltsev** — MD, PhD, ophthalmologist of the Ophthalmology Department. S.M. Kirov Military Medical Academy, St. Petersburg, Russia. E-mail: glaz.med@yandex.ru.