

Разработка алгоритма анализа ОКТ-изображений для дифференциальной диагностики отёка сетчатки на основе глубокого обучения

Н.С. Демин^{1,2}, Н.Ю. Ильясова^{1,2}, Е.А. Замыцкий³, А.В. Золотарев³, Д.В. Кириш^{1,2}, А.Ю. Ионов¹

¹ Самарский национальный исследовательский университет имени академика С.П. Королёва, 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 Самарский государственный медицинский университет, 443099, Россия, г. Самара, ул. Чапаевская, д. 89

Аннотация

Целью работы является разработка алгоритма дифференциальной диагностики отёка сетчатки, изучение методов глубокого обучения и их применение для анализа изображений. В работе исследовано применение свёрточных нейронных сетей для задачи семантической сегментации слоёв сетчатки глаза и доказана его эффективность при выделении двух выбранных слоёв (пигментного эпителия и сетчатки). Был реализован алгоритм классификации заболеваний, основанный на интеллектуальном анализе выделенных нейронной сетью слоёв. Приведено доказательство его применимости для дифференциальной диагностики отёка сетчатки. Точность предсказания заболевания составила 90 %.

Ключевые слова: сегментация изображений, свёрточные нейронные сети, классификация изображений, оптическая когерентная томография, возрастная макулярная дегенерация, диабетический макулярный отёк.

Цитирование: Демин, Н.С. Разработка алгоритма анализа ОКТ-изображений для дифференциальной диагностики отёка сетчатки на основе глубокого обучения / Н.С. Демин, Н.Ю. Ильясова, Е.А. Замыцкий, А.В. Золотарев, Д.В. Кириш, А.Ю. Ионов // Компьютерная оптика. – 2025. – Т. 49, № 2. – С. 292-300. – DOI: 10.18287/2412-6179-CO-1613.

Citation: Demin NS, Ilyasova NY, Zamytskyi EA, Zolotarev AV, Kirsh DV, Ionov AYU. Development of an OCT image analysis algorithm for differential diagnosis of retinal edema based on deep learning. Computer Optics 2025; 49(2): 292-300. DOI: 10.18287/2412-6179-CO-1613.

Введение

Совершенствование методов анализа внутренней микроструктуры биологических тканей в целях диагностики заболеваний является одним из главных вопросов в медицине. Современным решением проблемы является использование оптической когерентной томографии (ОКТ). Широко применяется оптическая когерентная томография в офтальмологии. С помощью указанной технологии можно диагностировать дистрофические и воспалительные заболевания глазного дна [1]. ОКТ позволяет выявить изменения в слоях сетчатки и диагностировать различные патологии, в частности, возрастную макулярную дегенерацию (ВМД) и диабетическую ретинопатию. Возрастная макулярная дегенерация – это хроническое прогрессирующее многофакторное заболевание сетчатки, при котором существенно страдает центральное зрение. Диабетическая ретинопатия зачастую сопровождается диабетическим макулярным отёком (ДМО). Диабетический макулярный отёк – это поражение сетчатой оболочки глаза на фоне неадекватной компенсации сахарного диабета. Обе болезни могут привести к необратимым последствиям – полной слепоте, поэтому чрезвычайно важно обнаружить их на ранних стадиях развития и назначить качественное лечение [2, 3].

Возрастная макулярная дегенерация (ВМД) и диабетический макулярный отёк (ДМО) являются заболеваниями, которые влияют на сетчатку глаза, вызывают разнообразные изменения профиля. Проявлениями ВМД являются: образование друз, изменения в пигментном эпителии (ПЭ) сетчатки, географическая атрофия ПЭ и хориокапилляров в макулярной области, развитие хориоидальной неоваскуляризации [4]. Для диабетического макулярного отёка характерны: появление микроаневризм и микрогеморрагий, интратретинальные микрососудистые аномалии в одном или более квадрантах, четкообразность вен в одном или более квадрантах, фиброз на диске зрительного нерва, неоваскуляризация сетчатки [5].

Использование изображений оптической когерентной томографии помогает врачам своевременно поставить диагноз и назначить необходимое лечение. Однако интерпретация изображений требует высокой квалификации и большого опыта врача-офтальмолога. Не стоит также забывать про человеческий фактор, ведь людям свойственно ошибаться вследствие усталости или каких-либо других причин. Решением данных проблем является использование компьютерного зрения. Применение искусственного интеллекта в медицине позволяет повысить эффективность и точность диагностики, а также сократить время, затрачиваемое на анализ изображений [6].

Большое распространение получили методы на основе свёрточных нейронных сетей, позволяющие выделять не только слои сетчатки, но и области скопления жидкостей. В работе [7] представлен способ локализации области макулярного отёка с использованием данных ОКТ. Способ состоит из нескольких методов: для поиска границы между стекловидным телом и сетчаткой на снимках ОКТ применяется метод Кэнни, а алгоритм Краскала позволяет сегментировать сетчатку. По сегментированной области строится карта распределения высоты сетчатки, которую в дальнейшем сравнивают с эталоном.

Автоматическое выделение слоёв на изображениях оптической когерентной томографии может быть выполнено с помощью алгоритма, основанного на вычислении градиента функции яркости [8]. Также для повышения качества используется билатеральный фильтр для удаления шумов. Средняя абсолютная ошибка сегментации этим алгоритмом варьируется в интервале 1,78–4,89 микрометра в зависимости от конкретного пациента и качества изображения ОКТ.

В статье [9] описано применение обученного классификатора для детектирования границ слоёв. При обучении применяется алгоритм машинного обучения random forest. Классификатор генерирует множество деревьев классификации, которые затем объединяются для вычисления правдоподобия принадлежности к каждому классу. Авторы статьи указывают значение средней абсолютной ошибки, равное 3,40 микрометрам.

В настоящий момент сегментация всё чаще осуществляется на основе применения свёрточных нейронных сетей. Sandra Morales и другие используют сеть U-Net для сегментации слоёв на изображениях ОКТ [10]. Сегментированные слои могут быть использованы для формирования карты толщины слоёв. Благодаря анализу снимков ОКТ формируется структура глазного дна, дополняющая информацию, наблюдаемую на снимке глазного дна. Данная информация используется для анализа состояния сетчатки по патологическим и анатомическим особенностям.

В работе [11] авторами был представлен метод автоматического формирования плана лазерной коагуляции. С помощью сегментации ОКТ-сканов с плана коагуляции удалялись зоны, запрещённые для воздействия лазера: сосуды, диск зрительного нерва и другие, тем самым ограничивая воздействие лазера только на необходимые участки. Описанный метод используется для повышения эффективности лечения диабетической ретинопатии.

В данной работе применялся метод сегментации изображений ОКТ с помощью свёрточных нейронных сетей с последующим анализом выделенных областей и выявлением патологий с помощью специальных алгоритмов и исследований.

Целью работы была разработка алгоритма дифференциальной диагностики отёка сетчатки, позволяю-

щего по входным данным выявлять две патологии глазного дна: ВМД и ДМО, а также классифицировать больных с ДМО по типу лечения – определять возможность применения лазерной коагуляции. Далее описаны характеристики, необходимые для определения отличий классов друг от друга.

1. Алгоритм дифференциальной диагностики макулярного отёка

Для решения поставленной задачи дифференциальной диагностики отёка сетчатки был предложен алгоритм анализа изображений оптической когерентной томографии, этапы которого представлены на рис. 1.

Разработка алгоритма была разделена на следующие этапы:

- 1) предварительная обработка и подготовка исходных данных;
- 2) семантическая сегментация слоя сетчатки и пигментного эпителия на исходном изображении оптической когерентной томографии с помощью свёрточной нейронной сети;
- 3) применение медианного фильтра;
- 4) обработка сегментированного слоя пигментного эпителия: построение аппроксимирующей кривой и вычисление признаков кривизны контура ПЭ;
- 5) классификация пациентов по найденным согласно 4 пункту признакам по двум типам патологии: ВМД и ДМО;
- 6) при выявлении ДМО формирование карты высот слоя сетчатки и определение наличия повреждений фовеолы;
- 7) классификация пациентов с ДМО по типу лечения согласно результатам 6 пункта: определение возможности применения лазерной коагуляции на основании отсутствия повреждений макулы.

На рис. 1 представлена разработанная технология, выполняющая семантическую сегментацию изображений оптической когерентной томографии глазного дна по областям интереса: слою сетчатки и пигментного эпителия. При сегментации медицинских изображений очень часто используют свёрточные нейронные сети. Они позволяют быстро и качественно обрабатывать огромный объем информации. Главным отличием от обычных нейронных сетей является наличие операции свёртки в архитектуре [12, 13]. В работе была спроектирована свёрточная нейронная сеть на основе сети ReLayNet, которая была разработана специально для задачи сегментации слоёв сетчатки [14]. Архитектура используемой сети (см. рис. 2) напоминает полносвязную свёрточную нейронную сеть U-Net, предназначенную для сегментации медицинских изображений. Огромным преимуществом данной архитектуры является её эффективность при малом количестве доступных данных [15].

В рамках интеллектуального анализа слоёв применялись следующие фильтры: усредняющий, экстремальный и медианный. Принцип действия экстре-

мального фильтра заключается в том, что для каждого положения окна строится и анализируется вариационный ряд по отсчётам, попадающим в окно. Формула экстремального фильтра выглядит следующим образом:

$$g = \begin{cases} f_1, & f_0 - f_1 < f_N - f_0 \\ f_N, & f_0 - f_1 \geq f_N - f_0 \end{cases}$$

где g – выходное значение, f_0 – центральный отсчёт вариационного ряда, f_1 – первый отсчёт вариационного ряда, f_N – последний отсчёт вариационного ряда.

Для диагностики начальной стадии развития ВМД необходимо определить наличие искривлений слоя пигментного эпителия. Для решения проблемы был предложен следующий метод: с помощью построения аппроксимации верхнего контура слоя пигментного эпителия произвести оценку, насколько сильно различаются кривые у пациента с ВМД и ДМО. Так как у пациента с ДМО слой пигментного эпителия не содержит искривлений, аппроксимирующая кривая должна практически совпасть с контуром слоя пигмента, а значение отклонения должно быть мало.

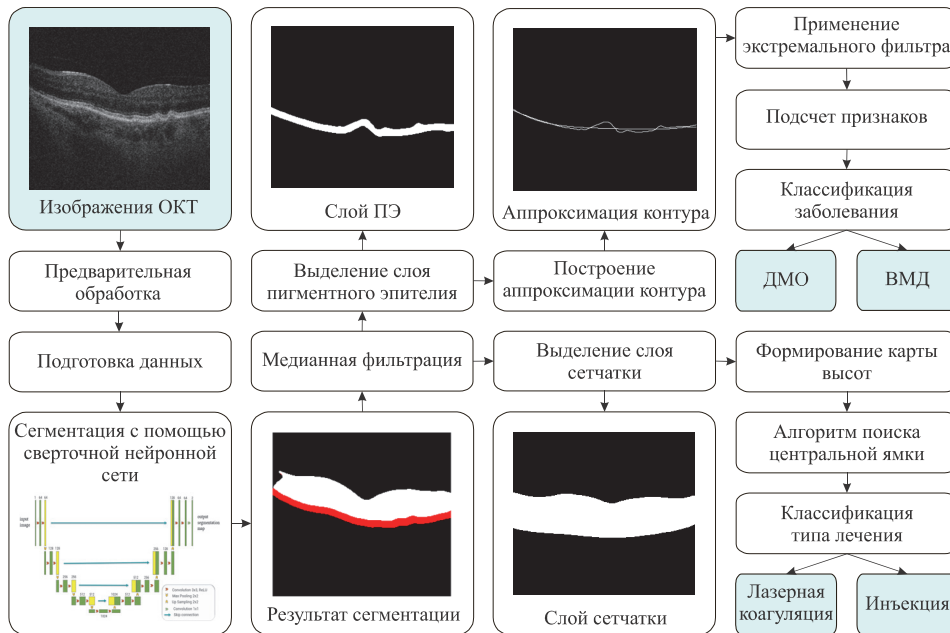


Рис. 1. Схема алгоритма дифференциальной диагностики ДМО: а) удаление фонового региона с ОКТ, б) бинаризация ОКТ с предварительным удалением слоя нервных волокон, в) аппроксимированный пигментный слой с друзьями, г) результат подбора полинома 3-го порядка для оценки «здорового» пигментного слоя, д) результат смещения «нормального» пигментного слоя вниз, е) результат работы алгоритма выделения друз

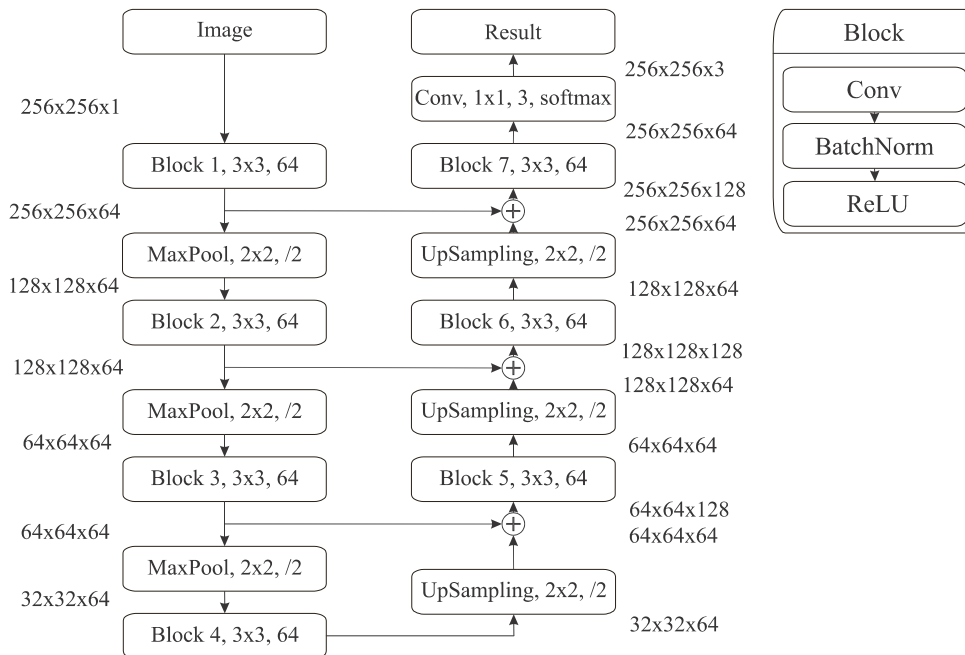


Рис. 2. Архитектура спроектированной свёрточной нейронной сети

Отклонение контура слоя пигментного эпителия от аппроксимирующей кривой относительно длины контура будем определять следующим образом:

$$\delta(k, p) = \frac{\sum_{i=0}^n (k_i - p_i)^2}{L},$$

где L – длина контура слоя ПЭ, k_i – пиксель из массива значений контура, p_i – соответствующий пиксель аппроксимирующей кривой.

Для количественного сравнения величин отклонения в норме и патологии далее были посчитаны такие статистические величины, как математическое ожидание и дисперсия. Определение наличия патологии осуществим с помощью классификатора, обученного на полученных признаках. В рамках этапа анализа слоя сетчатки необходимо оценить повреждение макулы (см. рис. 3) для определения возможности проведения лазерной коагуляции. В настоящей работе задача сводится к поиску центральной ямки или фовеолы – небольшого углубления, которое находится в центре сетчатки на скане оптической когерентной томографии. Сканы, характеризующиеся отсутствием ямки, соответствуют больным с повреждённой фовеолой. Для них проведение лазерной коагуляции недопустимо.

Для определения наличия фовеолы был предложен алгоритм на основе аппроксимации и сформированной карты высот слоя сетчатки. Для обнаружения центральной ямки сначала проводился подсчёт карты высоты сетчатки. Далее полученная карта аппроксимировалась поверхностью 2-го порядка, в соответствии с формой сетчатки эта поверхность была выбрана в виде параболоида. После аппроксимации строилась бинарная карта отклонения подсчитанной высоты от аппроксимирующей плоскости. На основе этой карты искалась центральная ямка, имеющая характерные признаки. Ямка имеет эллипсоидный вид с отрицательным отклонением от аппроксимирующей плоскости с центром, близким к центру изображения.

Для решения поставленной задачи была использована база неразмеченных изображений, предоставленная врачом самарской клиники. База данных содержит ОКТ-изображения сетчатки 28 пациентов с различными патологиями глазного дна. Для каждого пациента имеется 85 В-сканов в формате (.png) с разрешением 940×640. На рис. 3 изображено исходное изображение – ОКТ-скан сетчатки глаза.

2. Экспериментальные исследования

2.1. Оценка точности выделения областей интереса на изображениях ОКТ

После аугментации размеченный датасет был разбит на обучающую и валидационную выборку: обучающая состоит из 783 изображений и соответствующих им масок, а валидационная – из 224 изображений и соответствующих им масок. Обучение про-

дилось с использованием метода обратного распространения ошибки, а в качестве алгоритма оптимизации был выбран хорошо зарекомендовавший себя оптимизатор Adam.




Рис. 3. Пример исходного изображения среза сетчатки пациента

Для решения задачи семантической сегментации была произведена разметка 510 ОКТ-сканов, которые затем прошли проверку и корректировку врачом-офтальмологом. Каждому ОКТ-скану в наборе данных была сопоставлена маска, соответствующая каждому классу (бинарное изображение). Также разрешение изображения и соответствующих ему масок было изменено на 256×256. Для изображения, представленного на рис. 2, были выделены две маски для каждого из вышеупомянутых областей интереса, показанные на рис. 4.



Рис. 4. Пример маски для слоя пигментного эпителия и для слоя сетчатки

В качестве метрики качества для обучения и оценки модели был выбран коэффициент Дайса, который определяется следующим образом:

$$Dice(y_{true}, y_{pred}) = 2 \times \frac{\sum_i y_{true_i} \times y_{pred_i}}{\sum_i y_{true_i} + \sum_i y_{pred_i}},$$

где y_{pred} – набор предсказаний нашей модели, y_{true} – набор исходных истинных ответов. Из графика, представленного на рис. 5, можно оценить зависимость значений метрики Дайса от количества эпох.

Из графика видно, что максимальное значение для валидационной выборки достигается приблизительно на 50 эпохе со значением 0,9835, а для обучающей выборки – со значением 0,9861. Такие высокие результаты для задачи семантической сегментации получаются, в частности, из-за использования техники аугментации данных, позволяющей избежать переобучения модели. В качестве функции потерь выбрана функция:

$$loss = 1 - Dice(y_true, y_pred),$$

где y_pred – набор предсказаний нашей модели, y_true – набор исходных истинных ответов.




Рис. 5. График изменения коэффициента Дайса в процессе обучения




Рис. 6. График изменения функции потерь в процессе обучения

График изменения функции ошибки представлен на рис. 6. Из него можно оценить зависимость значе-

ний функции потерь от количества эпох. Максимальное значение функции потерь для валидационного набора на 50 эпохе не превышает 0,0194.

Окончательные результаты основных метрик были сформулированы в табл. 1. Полученные результаты показывают, что обученная модель эффективно справляется с поставленной задачей сегментации.

Табл. 1. Результирующие значения метрик и функции потерь

	Обучающая	Валидационная	Тестовая
Loss	0,0167	0,0194	0,0198
Dice coefficient	0,9861	0,9835	0,9789

Проверим работу данной модели на конкретном изображении. На рис. 7 представлено исходное изображение, а также представлены маски: размеченная вручную врачом, результат сегментации с помощью нейронной сети. Как можно заметить, нейронная сеть даёт неидеальную, но максимально приближенную к разметке врачом сегментацию сетчатки исходного изображения ОКТ.

2.2. Исследование алгоритма детекции деформаций в слое пигментного эпителия

Для проведения экспериментального исследования были обработаны сканы ОКТ 28 больных (15 – с ДМО, 13 – с ВМД). С помощью томографа формируется 85 сканов на одного больного, вместе составляющих трёхмерную визуализацию глазного дна. Все сканы были предварительно сегментированы с помощью разработанной свёрточной нейронной сети, описанной ранее. На рис. 8 представлен результат выделения слоя пигментного эпителия и показан верхний контур и аппроксимирующая его кривая 3-го порядка.



Рис. 7. Исходное изображение ОКТ и сегментированные изображения: размеченное врачом-экспертом, размеченное свёрточной нейронной сетью




Рис. 8. а) Сегментированный слой ПЭ больного с ВМД; б) контур сегментированного слоя пигментного эпителия и аппроксимирующая его кривая

График зависимости величины отклонения кривых от номера скана для больного с возрастной макулярной дегенерацией и без неё представлен на рис. 9. Можно заметить, что отклонение от аппроксимирующей кривой у пациента с ДМО намного меньше, чем у пациента с ВМД на центральных сканах.

Также стоит обратить внимание на наличие острых пиков – резких повышений значений отклонения. Данные пики могут быть следствием шумов при сегментации, поэтому было принято решение провести

сглаживание полученного сигнала – отклонения контура от аппроксимирующей кривой. Были рассмотрены усредняющий, медианный и экстремальный фильтр. После тестирования данных фильтров был выбран экстремальный фильтр из-за более точного сохранения полезной информации. Применение экстремального фильтра позволило убрать одиночные пики, что доказывает эффективность его применения в данной задаче. Результат применения фильтра к графикам можно увидеть на рис. 10. Проанализировав рис. 10, можно сделать вывод, что наибольшее отклонение контура у пациента с ВМД достигается в районе 40–46 сканов, а на первых и последних сканах оно не так существенно. Были построены графики для нескольких больных, чтобы подтвердить гипотезу. Это поможет сократить интервал сканов, который необходимо обработать для определения наличия патологии.

На рис. 11 представлены графики шести других больных с ВМД. Красной линией на графиках изображено математическое ожидание сигнала. Далее для каждого пациента был осуществлён поиск номеров первого и последнего скана, значение отклонения на которых превышает математическое ожидание.

Выполнив усреднение по 13 больным, был определён средний интервал сканов, в которых наблюдается наибольшее значение отклонения: с 20 по 64 сканы. В дальнейшем анализ проводился только в данном интервале. Был произведён расчёт значений математического ожидания и дисперсии в интервале от 20 до 64 сканов.

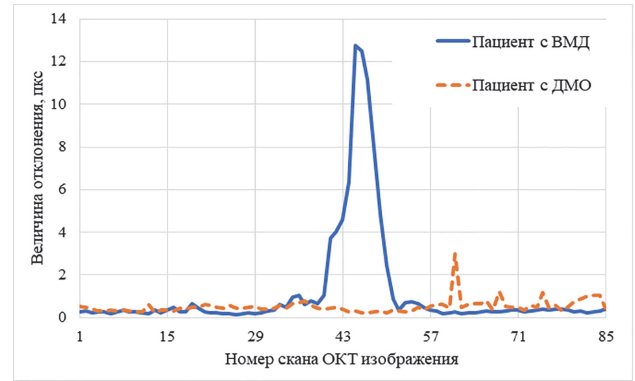


Рис. 9. Графики зависимости отклонения контура от номера скана

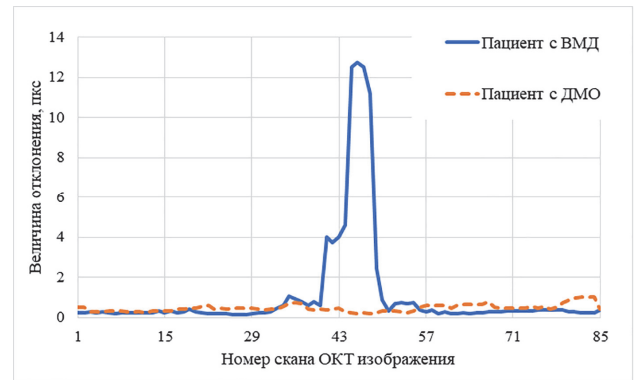


Рис. 10. Графики зависимости отклонения контура от номера скана после применения экстремального фильтра

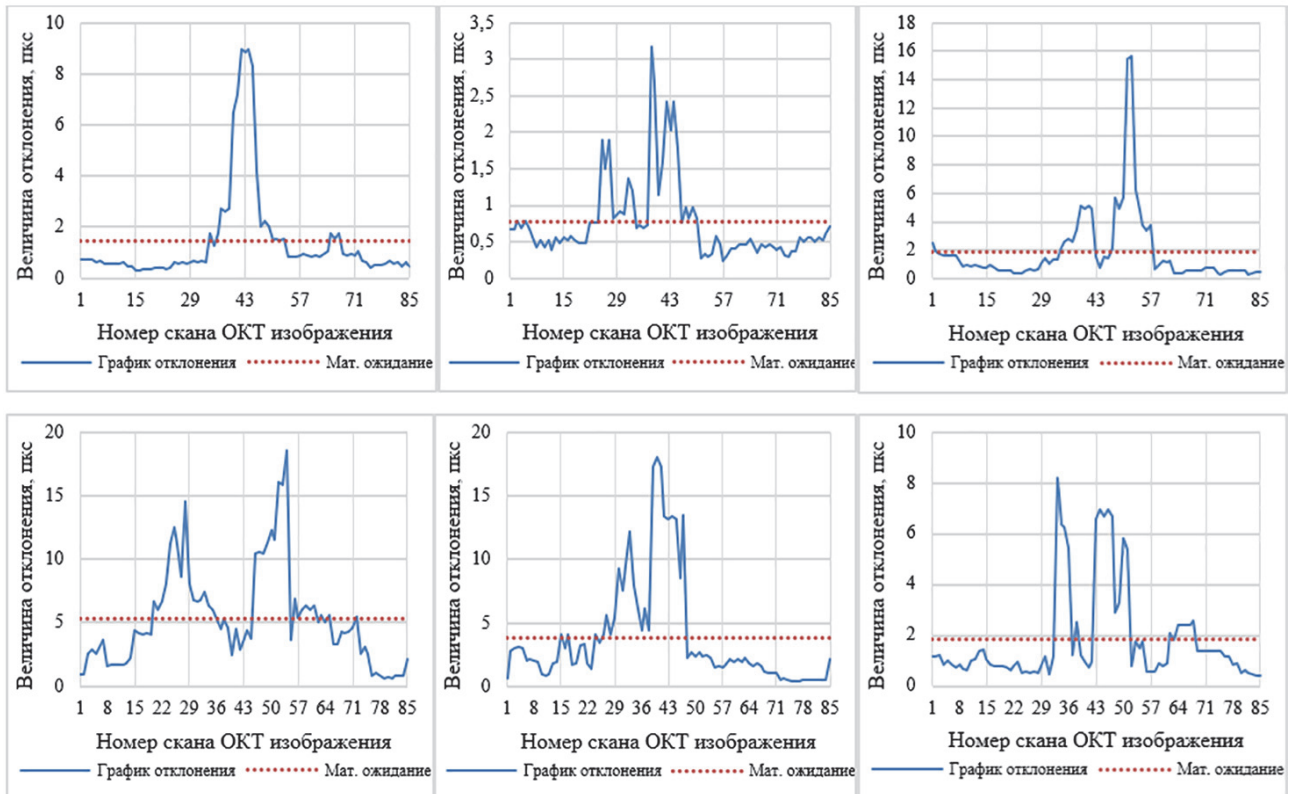


Рис. 11. Графики зависимостей отклонения нескольких больных

Полученные данные изображены на графике, представленном на рис. 12. Как можно заметить по рис. 12, значение математического ожидания и дисперсии отклонения контура от аппроксимирующей кривой для пациентов с ДМО намного меньше, чем для пациентов с ВМД.

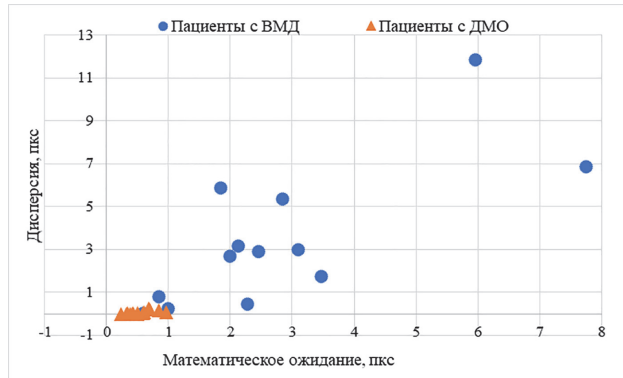


Рис. 12. Распределение пациентов по значениям математического ожидания и дисперсии

2.3. Исследование поиска центральной ямки в слое сетчатки

Для проведения экспериментального исследования были обработаны сканы ОКТ 15 больных: у 12 пациентов отёк не затрагивает фовеолу, у 3 наблюдается поражение центральной ямки. При исследовании слоя сетчатки офтальмологом формируется 85 сканов на одного пациента, так же как и в случае с обработкой слоя пигментного эпителия. После предварительной сегментации с помощью нейронной сети для каждого пациента была построена карта высот сетчатки. Была проведена аппроксимация полученной карты поверхностью второго порядка. И построено бинарное изображение отклонения карты высот от аппроксимирующей поверхности. На рис. 13 представлены карты высот и результирующее бинарное изображение.

В ходе эксперимента было обнаружено, что аппроксимирующие коэффициенты довольно малы, а значит, для упрощения вычислений можно в качестве аппроксимирующей поверхности взять поверхность первого порядка. В некоторых случаях коэффициенты аппроксимации при переменных были близки к нулю, что соответствует обычной пороговой обработке.

2.4. Оценка качества дифференциальной диагностики

После реализации всех необходимых алгоритмов была проведена оценка точности алгоритма дифференциальной диагностики отёка сетчатки по трём классам: пациенты с ВМД, пациенты с ДМО с возможностью применения лазерной коагуляции и пациенты с ДМО с типом лечения инъекция.

Для оценки использовались данные 28 пациентов по 85 сканов для каждого: 15 – с ВМД, 10 – с ДМО (тип лечения – лазерная коагуляция), 3 – с ДМО (тип лечения – инъекция). Построенный по подсчитанным

признакам классификатор логистической регрессии дал достаточно высокий результат точности предсказания типа заболевания. Так как количество пациентов мало, для оценки точности модели был использован метод перекрёстной проверки с количеством разбиений, равным 7. Значение точности классификатора составило 90 %.




Рис. 13. Результаты бинаризации карты высот сетчатки с использованием аппроксимирующей плоскости в качестве порога: (а) карта высот без центральной ямки, (б) результат бинаризации карты высот без центральной ямки, (в) карта высот с центральной ямкой, (г) результат бинаризации карты высот с центральной ямкой

Также была выполнена оценка точности классификации по формулам Precision, Recall и F1-score.

Результаты подсчитанных метрик представлены в табл. 2. Стоит отметить, что алгоритм точно определяет тип лечения, а ошибки возникают при классификации заболевания.

Табл. 2. Результирующие значения метрик классификации

	ВМД	ДМО (лазерная коагуляция)	ДМО (инъекция)
Precision	1,00	0,87	0,75
Recall	0,80	1,00	1,00
F1	0,89	0,93	0,86

Заключение

В данной работе было изучено применение методов глубокого обучения для обработки медицинских изображений, проведено исследование свёрточных нейронных сетей для задачи сегментации изображений ОКТ по областям интереса (слой пигментного эпителия, слой сетчатки).

Был разработан алгоритм анализа изображений ОКТ для дифференциальной диагностики отёка сетчатки. Алгоритм состоит из нескольких этапов: сегментирования слоёв сетчатки с помощью свёрточной нейронной сети и интеллектуального анализа областей интереса.

Была написана программная реализация технологии свёрточной нейронной сети для выполнения сег-

ментации сетчатки на изображениях ОКТ. Результаты показывают, что полученная модель позволяет достаточно качественно определить слой сетчатки и пигментного эпителия на изображениях ОКТ. На валидационном наборе данных спроектированная свёрточная нейронная сеть достигает 98,35 % точности по выбранной метрике.

Был реализован алгоритм классификации заболеваний и типов лечения на основе анализа сегментированных областей. Точность предсказания заболевания составила 90 %. Также был сделан вывод, что ошибка возникает при классификации типа патологии (возрастная макулярная дегенерация или диабетический макулярный отёк), в определении типа лечения пациентов с ДМО алгоритм показал идеальную точность.

Результаты, полученные в данной научно-исследовательской работе, свидетельствуют о возможности применения алгоритма для поставленной задачи.

Благодарности

Работа выполнена в рамках выполнения государственного задания НИЦ «Курчатовский институт».

References

- [1] Zakharova MA, Kuroedov AV. Optical coherence tomography: a technology that has become a reality [In Russian]. *RMZ. Clinical Ophthalmology* 2015; 16(4): 204-211.
- [2] Fursova AJ, Gamza YA, Derbeneva AS, Vasilieva MS. Anti-angiogenesis therapy of diabetic macular edema in patients with primary open-angle glaucoma [In Russian]. *Russian Annals of Ophthalmology* 2020; 136(6, vyp 2): 185-194. DOI: 10.17116/oftalma2020136062185.
- [3] Gvetadze AA, Koroleva IA. Age-related macular degeneration. A modern view of the problem (literature review) [In Russian]. *RMJ. Clinical Ophthalmology* 2015; 16(1): 39-43.
- [4] Kizi BN. Age-related macular degeneration of the retina. *Academy* 2018; 8(35): 57-62.
- [5] Astakhov YS, Neroev VV, Shestakova MV, Zaitseva OV, Okhotsimskaya TD, Ryabina MV, Kononenko IV. Diabetes mellitus: diabetic retinopathy, diabetic macular edema. Clinical guidelines [In Russian]. Ministry of Health of the Russian Federation Publisher; 2013.
- [6] Harry DD, Sahakyan SV, Khoroshilova-Maslova IP, Tsygankov, AY, Nikitin, OI, Tarasov GY. Machine learning methods in ophthalmology. A review of the literature [In Russian]. *Ophthalmology* 2020; 17(1): 20-31. DOI: 10.18008/1816-5095-2020-1-20-31.
- [7] Demin NS, Ilyasova NYu, Shirokanov AS, Zamytsky EA. Segmentation of OCT images for localization of macular diabetic edema area [In Russian]. *Proc Information Technologies and Nanotechnologies (ITNT-2020)* 2020; 4: 212-219.
- [8] Lu S, Cheung CYL, Liu J, Lim JH, Leung CKS, Wong TY. Automated layer segmentation of optical coherence tomography images. *IEEE Trans Biomed Eng* 2010; 57(10): 2605-2608. DOI: 10.1109/tbme.2010.2055057.
- [9] Lang A, Carass A, Hauser M, Sotirchos ES, Calabresi PA, Ying HS, Prince JL. Retinal layer segmentation of macular OCT images using boundary classification. *Biomed Opt Express* 2013; 4(7): 1133-1352. DOI: 10.1364/boe.4.001133.
- [10] Morales S, Colomer A, Mossi JM, del Amor R, Woldbye D, Klemp K, Larsen M, Naranjo V. Retinal layer segmentation in rodent OCT images: Local intensity profiles & fully convolutional neural networks. *Comput Methods Programs Biomed* 2021; 198: 105788. DOI: 10.1016/j.cmpb.2020.105788.
- [11] Ilyasova N, Demin N, Andriyanov N. Development of a computer system for automatically generating a laser photocoagulation plan to improve the retinal coagulation quality in the treatment of diabetic retinopathy. *Symmetry* 2023; 15(2): 287. DOI: 10.3390/sym15020287.
- [12] Hao S, Zhou Y, Guo Y. A brief survey on semantic segmentation with deep learning. *Neurocomputing* 2020; 406: 302-321. DOI: 10.1016/j.neucom.2019.11.118
- [13] Sikorsky OS. A review of convolutional neural networks for the task of image classification [In Russian]. *New Information Technologies in Automated Systems* 2017; 20: 37-42.
- [14] Roy AG, Conjeti S, Karri SK, Sheet D, Katouzian A, Wachinger C, Navab N. ReLayNet: retinal layer and fluid segmentation of macular optical coherence tomography using fully convolutional networks. *Biomedical Optics Express* 2017; 8(8): 3627-3642. DOI: 10.1364/boe.8.003627.
- [15] Siddique N, Paheding S, Elkin CP, Devabhaktuni V. U-net and its variants for medical image segmentation: A review of theory and applications. *IEEE Access* 2021; 9: 82031-82057. DOI: 10.1109/access.2021.3086020.
- [16] Müller A, Guido S. Introduction to machine learning with Python: A guide for data scientists. Sebastopol, CA: O'Reilly Media Inc; 2017. ISBN: 978-1-449-36941-5.
- [17] Bradski G, Kaehler A. Learning OpenCV: Computer vision with the OpenCV library. Sebastopol, CA: O'Reilly Media Inc; 2008. ISBN: 978-0-596-51613-0.
- [18] Ternovoy EA. Python libraries for image processing, examples of using [In Russian]. All-Russian Student Conf "Student Scientific Spring" Dedicated to the 85th Anniversary of YuA Gagarin 2019: 314-314.
- [19] Moruzzi G. Plotting with matplotlib. In Book: Moruzzi G. Essential Python for the physicist. Cham, Switzerland: Springer Nature Switzerland AG; 2020: 53-69. DOI: 10.1007/978-3-030-45027-4_3.
- [20] Géron A. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. 2nd ed. Sebastopol, CA: O'Reilly Media Inc; 2019. ISBN: 978-1-492-03264-9.
- [21] Shorten C, Khoshgoftaar TM. A survey on image data augmentation for deep learning. *J Big Data* 2019; 6(1): 60. DOI: 10.1186/s40537-019-0197-0.
- [22] Castro E, Cardoso JS, Pereira JC. Elastic deformations for data augmentation in breast cancer mass detection. 2018 IEEE EMBS Int Conf on Biomedical & Health Informatics (BHI) 2018: 230-234. DOI: 10.1109/BHI.2018.8333411.
- [23] Oliphant TE. Guide to NumPy. 2nd ed. Continuum Press; 2015. ISBN: 978-1-5173-0007-4.

Сведения об авторах

Демин Никита Сергеевич, 1994 года рождения, аспирант Самарского национального исследовательского университета имени академика С.П. Королёва. Сфера научных интересов: интеллектуальный анализ медицин-

ских изображений; цифровая обработка изображений; математическое моделирование; распознавание образов и искусственный интеллект. E-mail: volfgunus@gmail.com

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 заведующей лабораторией математических методов обработки изображений Отделения «Институт систем обработки изображений – Самара» Курчатовского комплекса кристаллографии и фотоники федерального государственного бюджетного учреждения «Национальный исследовательский центр «Курчатовский институт» и по совместительству доцентом кафедры технической кибернетики СГАУ. Круг научных интересов включает цифровую обработку сигналов и изображений, анализ и интерпретацию биомедицинских изображений. Имеет более 170 публикаций, три монографии (в соавторстве).

E-mail: ilyasova@ipsiras.ru

Замыцкий Евгений Андреевич, кандидат медицинских наук, врач-офтальмолог кабинета лазерной микрохирургии офтальмоэндокринологического консультативно-диагностического отделения Самарской областной офтальмологической больницы им. Т.И. Ерошевского, ассистент кафедры глазных болезней Самарского государственного медицинского университета. Сфера научных интересов: офтальмология, патология сетчатки, лазерные и медикаментозные методы лечения ретиальной патологии. E-mail: undue@mail.ru

Золотарев Андрей Владимирович, доктор медицинских наук, главный внештатный специалист Министерства здравоохранения Самарской области по офтальмологии, заведующий, доцент кафедры офтальмологии ФГБОУ ВО Самарского государственного медицинского университета Минздрава России. Сфера научных интересов: офтальмология, глаукомное поражение глаз, поражения центрального отдела сетчатки глаза.

Кириш 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

Ионов Артем Юрьевич, 2001 года рождения, магистр Самарского национального исследовательского университета имени академика С.П. Королёва. Сфера научных интересов: системы искусственного интеллекта.

E-mail: artem.ionov.96@mail.ru

ГРНТИ: 28.23.14

Поступила в редакцию 19 сентября 2024 г. Окончательный вариант – 10 октября 2024 г.

Development of an OCT image analysis algorithm for differential diagnosis of retinal edema based on deep learning

N.S. Demin ^{1,2}, N.Y. Ilyasova ^{1,2}, E.A. Zamytskiy ³, A.V. Zolotarev ³, D.V. Kirsh ^{1,2}, A.Y. Ionov ¹

¹ Samara National Research University, 443086, Samara, Russia, Moskovskoye Shosse 34;

² Image Processing Systems Institute, NRC "Kurchatov Institute",
Molodogvardeyskaya Str. 151, Samara, 443001, Russia;

³ Federal State Budgetary Educational Institution of Higher Education «Samara State Medical University» of the Ministry of Healthcare of the Russian Federation, 89, Chapaevskaya st., Samara, Russia, 443099

Abstract

The aim of this work is to develop an algorithm for differential diagnosis of retinal edema and study deep learning methods and their application to image analysis. The application of convolutional neural networks for the task of semantic segmentation of retinal layers is investigated and its efficiency is proved for two selected layers (pigment epithelium and retina). An algorithm of disease classification based on the intellectual analysis of the layers selected by the neural network is implemented. A proof of its applicability for differential diagnostics of retinal edema is presented. The accuracy of disease detection amounts to 90%.

Keywords: image segmentation, convolutional neural networks, image classification, optical coherence tomography, age-related macular degeneration, diabetic macular edema.

Citation: Demin NS, Ilyasova NY, Zamytskiy EA, Zolotarev AV, Kirsh DV, Ionov AY. Development of an OCT image analysis algorithm for differential diagnosis of retinal edema based on deep learning. *Computer Optics* 2025; 49(2): 292-300. DOI: 10.18287/2412-6179-CO-1613.

Acknowledgements: This work was carried out within the state assignment of NRC "Kurchatov Institute".

Authors' information

Nikita Sergeevich Demin (born 1994), graduated (2019) with a master's degree in Applied Mathematics and Informatics. At present he is a postgraduate student of Samara University. The area of interests includes digital image processing, mathematical modeling, pattern recognition and artificial intelligence. E-mail: volfgunus@gmail.com

Nataly Yurievna Ilyasova (born 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 Head of Laboratory at the Image Processing Systems Institute, NRC "Kurchatov Institute", and holding a part-time position of Associate Professor at the Technical Cybernetics Department of Samara 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 170 scientific papers and 3 monographs published with coauthors. E-mail: ilyasova@ipsiras.ru

Evgeniy Andreevich Zamytskiy, Candidate of Medical Sciences, Laser Microsurgery Office Ophthalmologist of the Ophthalmoenocrinological Consulting and Diagnostic Department of the Samara Regional Ophthalmological Hospital named after T.I. Eroshevsky, Assistant of the Department Eye Diseases Samara State Medical University, Field of interests: ophthalmology, retinal pathology, laser and drug treatments for retinal pathology. E-mail: undue_@mail.ru

Andrey Vladimirovich Zolotarev, MD, Chief Freelance Specialist in Ophthalmology of Samara Region Health Ministry, Head, Associate Professor Department of Eye Diseases of the Samara State Medical University by Health Ministry of the Russian Federation. Field of interests: ophthalmology, glaucoma pathology of the eye, lesions central part of the retina.

Dmitriy Victorovich Kirsh (b. 1990) completed (2018) the postgraduate program in Computer Science and Computer Engineering. At present, he is a lecturer at the Technical Cybernetics Department of Samara 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, methods of mathematical formulation and comparison of crystal lattices, classification of crystal lattices. E-mail: kirsh@ssau.ru

Artem Yurievich Ionov (born 2001), graduated (2023) with a Bachelor's degree in Laser Engineering and Laser Technologies. Currently, he is a master's student at Samara University. His area of interest is artificial intelligence systems. E-mail: artem.ionov.96@mail.ru

Received September 19, 2024. The final version – October 10, 2024.
