



DOI: <https://doi.org/10.15688/mpcm.jvolsu.2023.1.3>

УДК 519.688
ББК 16.633.1

Дата поступления статьи: 11.01.2023
Дата принятия статьи: 21.02.2023

РАЗРАБОТКА КЛАССИФИКАТОРА ФОТОИЗОБРАЖЕНИЙ ПАТОЛОГИЙ ДЛЯ УЛЬТРАМАЛОГО НАБОРА ДАННЫХ

Антон Андреевич Адамов

Кандидат технических наук, младший научный сотрудник
института математики и информационных технологий,
старший преподаватель кафедры радиофизики,
Волгоградский государственный университет
anton.a.adamov@gmail.com, faa-162_758896@volsu.ru, rf@volsu.ru
<https://orcid.org/0000-0002-7394-0744>
просп. Университетский, 100, 400062 г. Волгоград, Российская Федерация

Ирина Асатуровна Гндоян

Доктор медицинских наук, заведующая кафедрой офтальмологии,
Волгоградский государственный медицинский университет
irina.gndoyan@mail.ru
<https://orcid.org/0000-0001-7581-9473>
пл. Павших Борцов, 1, 400131 г. Волгоград, Российская Федерация

Алена Игоревна Дятчина

Аспирант кафедры офтальмологии,
Волгоградский государственный медицинский университет
alena.dyatchina@yandex.ru
<https://orcid.org/0000-0001-9632-5800>
пл. Павших Борцов, 1, 400131 г. Волгоград, Российская Федерация

Владимир Николаевич Храмов

Кандидат физико-математических наук, доцент кафедры радиофизики,
Волгоградский государственный университет
vladimir.khramov@volsu.ru, rf@volsu.ru
<https://orcid.org/0000-0001-8988-0929>
просп. Университетский, 100, 400062 г. Волгоград, Российская Федерация

Аннотация. Цель работы: создать алгоритм и реализовать его в программном средстве для классификации фотоизображений патологий центральной области глазного дна человека, выявляемых при помощи исследования аутофлуоресценции, по 8 типам-паттернам: нормальный, минимальные изменения, фокальный, пятнистый, линейный, кружевоподобный, ретикулярный, крапчатый. Методы: алгоритмы машинного обучения (сверточные нейронные сети) и компьютерного зрения (гистораммные методы, перцептивные хэш-алгоритмы). Главная особенность задачи: ультрамалый набор уникальных фотоизображений с точно диагностируемым типом патологии (18 штук). Точность прогнозов при решении задачи с помощью нейросети 12,5%. Точность прогнозов разработанного алгоритма с использованием комбинации гистограмм, перцептивного хэша и 1 опорного фото нормального состояния глазного дна равна 60% при подборе параметров классификатора из набора 1 фото на 1 патологию. При использовании 3 опорных фото нормы — 85%. Предложенное решение может использоваться в медицине, офтальмологии, фотонике и оптике биотканей, машинном обучении как в научно-исследовательских, так и учебных целях.

Ключевые слова: обработка фотоизображений, компьютерное зрение, машинное обучение, классификация изображений, гистограмма, перцептивный хэш, офтальмологическая диагностика, компьютеризация медицины.

Введение

Последние несколько лет в научных статьях и средствах массовой информации часто появляются новости об очередных успехах методов машинного обучения (МО) и искусственного интеллекта (ИИ) в решении задач от автопилотирования автомобилей до создания виртуальных помощников (от текстовых чатов до систем видеонаблюдения) [8; 14; 20; 27; 31; 32; 34; 35]. Выпущено множество книг и фреймворков поддержки глубокого обучения [6; 18; 25; 26; 36], которые хорошо демократизируют данное направление, что привлекает еще больше исследователей в данную область.

При этом активно внедряемая компьютеризация медицины предоставляет широкое поле применению развивающихся технологий МО и ИИ [28; 39; 43] для анализа в большинстве случаев фотоизображений (медицинских снимков в разных диапазонах длин волн: рентгенограммы, фото в УФ-, ИК- и видимом свете) с целью диагностики патологических изменений в тканях человеческого организма. Внедрение техник ИИ и МО в оценку результатов медицинских исследований повышает точность выявления заболеваний [8; 12; 34; 35; 40]. Кроме того, одной из важных и актуальных задач современной медицинской диагностики является разработка консультативно-диагностических систем [3].

Следует отметить, что корректность работы данных интеллектуальных систем требует наличия достаточно объемного набора обучающих данных. Если говорить о визуальной информации (в частности, фотоизображениях), то это число начинается от нескольких десятков тысяч уникальных штук [6; 18; 25]. Данные в требуемых количествах для часто встречающихся заболеваний успешно собраны, размечены и размещены в системе Kaggle, например, для офтальмологии [42]. Помощь таких систем больше нужна молодым специалистам на этапах обучения и в начале их практики, поскольку высококвалифицированный врач принимает диагностическое решение на основе накопленного багажа знаний и клинического опыта и не часто прибегает к помощи интеллектуальных систем.

Однако действительно важным направлением применения интеллектуальной помощи в медицинской диагностике, как для опытных, так и для молодых специалистов, было бы использование данных техник в выявлении случаев редкой патологии. Из-за малой распространенности таких заболеваний даже опытный врач может испытывать трудности в диагностике и допускать ошибки. При этом из-за меньшей распространенности этих заболеваний сложнее сформировать обучающую выборку в количестве, необходимом для корректного формирования весовых коэффициентов нейронной сети. Требуется привлечение иных подходов анализа изображений. Кроме этого, развитие алгоритмов альтернативных МО и ИИ актуально на сегодняшний день, так как поможет предотвратить «голландскую болезнь» в области обработки фото- и видеоданных, которые сейчас находятся под гегемонией методов сверточных нейросетей.

В данной работе мы рассмотрим задачу программной классификации фотоданных исследования аутофлуоресценции центральной области глазного дна в диагностике возрастной макулярной дегенерации [4]. Цель работы: создать алгоритм и реализовать его в программном средстве для классификации фотоизображений патологий центральной области глазного дна человека, выявляемых при помощи исследования аутофлуоресценции, по 8 типам-паттернам: нормальный, минимальные изменения, фокальный, пятнистый, линейный, кружевоподобный, ретикулярный, крапчатый [4; 29]. Главная особенность задачи: ультрамалый набор уникальных фотоизображений с точно диагностируемым типом патологии (включая нормальное состояние): 18 фото в оттенках серого, то есть отдельный пиксель несет информацию о яркости (интенсивности) в градациях от 0 (черный) до 255 (белый цвет).

Заметим, что решение данной задачи с помощью нейросетей уже существует в той или иной степени при наличии нескольких тысяч снимков глазного дна [7; 13; 41]. В данном случае задача интересна как демонстрационная для применения альтернативных методов при наличии ограничения на количество доступных данных.

1. Решение с помощью нейронной сверточной сети

Данное решение призвано продемонстрировать несостоятельность уже классического подхода МО с применением сверточной нейросети при наличии столь малого количества фотоизображений патологии. Напомним, что «небольшой» объем для обучения сверточной нейронной сети с нуля — это количество от нескольких сотен до нескольких десятков тысяч изображений [25].

Мы частично использовали результаты работы [41] (1 356 533 обучаемых параметров). С архитектурой сети можно ознакомиться в репозитории проекта [9]. Принято считать, что нейросеть обучена корректно, то есть найден набор параметров класси-

катора, если потери для новых данных будут минимальными [6; 18; 25]. Из графиков на рисунке 1 видно, что данных недостаточно для верного формирования весовых коэффициентов: сеть сразу же переобучается (рис. 1а), а использование стандартных методов регуляризации [26]: прореживания (dropout с коэффициентом 0,2) и «бутылочного горлышка» (bottleneck) (добавление дополнительного скрытого слоя с 5 нейронами перед выходным слоем с 8) помогли уменьшить потери при проверке (рис. 1б), но не дали существенного увеличения точности, которая составила 12,5% (максимальное значение из результатов для разных комбинаций рассмотренных нами архитектур).

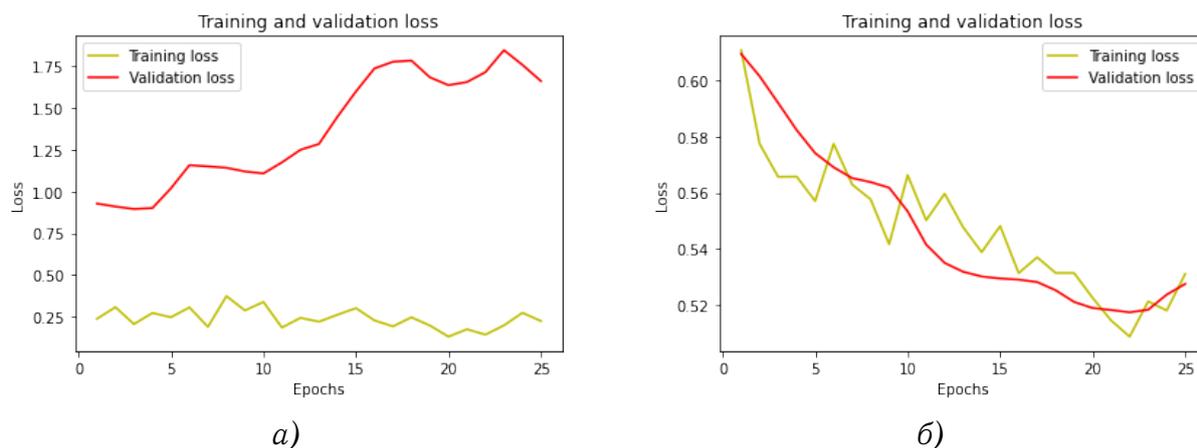


Рис. 1. Кривые потерь на этапах проверки и обучения:

- а) «стандартная» архитектура сети из 4 сверточных слоев, 2 скрытых (128 и 64 нейрона) и 1 выходного (8 нейронов по числу типов патологий, включая норму);
- б) сеть с прореживанием и еще одним скрытым «bottleneck»-слоем из 5 нейронов

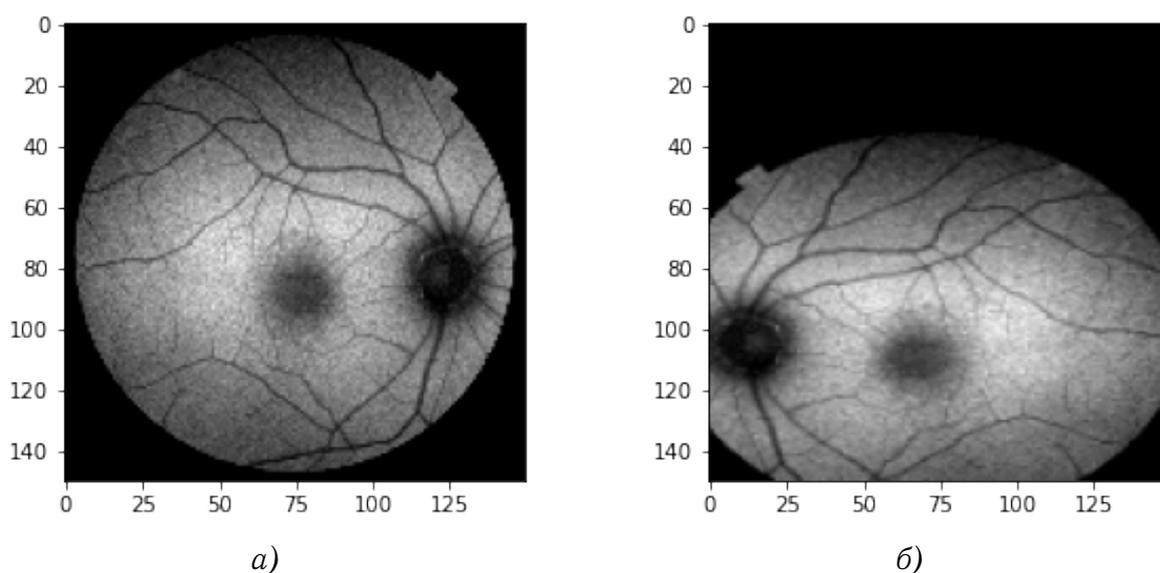


Рис. 2. Пример фото из набора: а) без искажений; б) с применением случайных расширений

Использование предварительно обученной сети [41] и ее дообучение с «замораживанием» верхних слоев и расширением данных случайными преобразованиями (рис. 2)

для изображений (ImageDataGenerator в Keras [25]) не принесли существенного увеличения точности. Мы также рассмотрели вариант дообучения нейросети без «замораживания» слоев, что эквивалентно не случайной, а «оптимизированной» инициализации весов нейросети, но и это не позволило увеличить точность предсказаний на проверочных данных.

2. Решение без использования нейросети

Методы классификации изображений до бурного развития и практического применения глубокого обучения обычно сводились к ручному построению дерева решений на основе поиска: шаблонов, локальных особенностей и инвариантных признаков для выделенных сегментов. Это накладывало ряд ограничений, так как можно было использовать малое количество признаков и их комбинаций, при этом достаточно сложно подобрать пороговые значения [2; 10; 11; 15; 16; 19; 24].

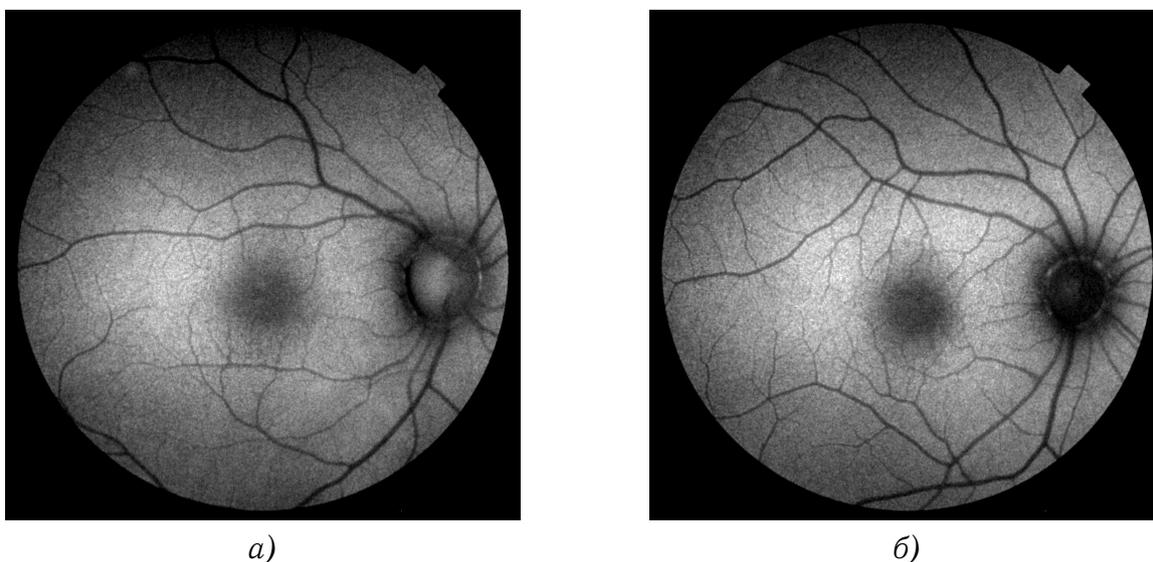


Рис. 3. Фото нормального глазного дна для разных глаз из набора:
а) условная норма 1; б) условная норма 2

Мы приняли решение использовать для классификации метод опорной нормы, при которой классификация изображений будет производиться путем сравнения исследуемого фото с фиксированным фотоизображением условного нормального глазного дна. Необходимо выбрать инструменты для получения критериев классификации: параметров, определяющих принадлежность к типу патологии. Мы пришли к выводу, что самые простые и популярные варианты не подходят для решения поставленных задач. Прямая (попиксельная) разница изображений [10; 15; 24] слишком большая и зависит от множества факторов: высокая чувствительность к небольшим смещениям, поворотам и контрастности фотоизображений. Разница между Фурье-образами фото [19] наоборот слишком мала для данного набора изображений. Поэтому мы использовали гистограммный метод, хорошо себя показавший в решении задачи распределения изображений на 3 класса при оценке качества полуфабрикатов и готовой продукции в металлургической промышленности [21], и перцептивный хэш для сравнения изображений.

Гистограмма цифрового 8-битового изображения [22] — это дискретная функция

$$h(r_k) = n_k,$$

где r_k — k -й уровень яркости; n_k — количество пикселей с яркостью r_k , $k \in [0; 255]$. Гистограммные методы широко используются в разных областях техники: от распознавания образов и рентгенологии до анализа допечатной продукции в полиграфии [5; 17; 22] и МО [33].

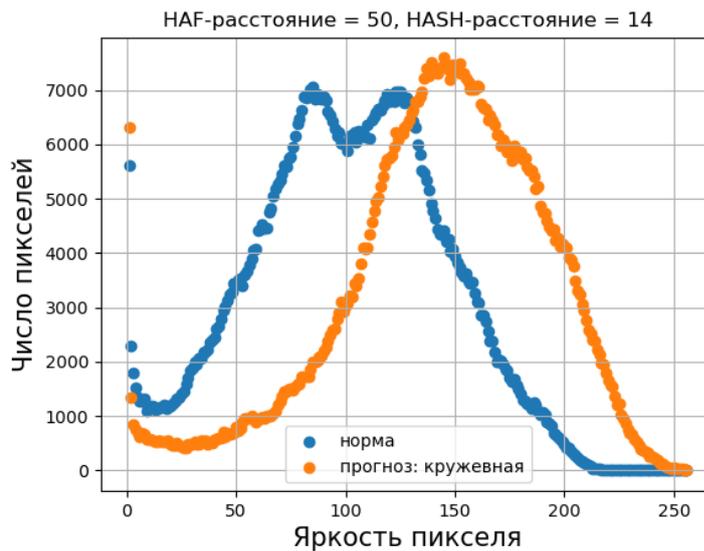


Рис. 4. Результат работы классификатора с опорным фото условной нормы 1 (рис. 3а)

Перцептивные хэши — это другая концепция по сравнению с криптографическими хэш-функциями [37; 38]. Самый простой из них — это среднее хеширование (average hashing). Хэш-отпечаток получается следующим образом: изображение уменьшается до 8×8 , так что общее число пикселей составляет 64. Результирующая матрица 8 на 8 преобразуется в двоичное представление с помощью пороговой обработки. Присвоение 0 или 1 для каждого пикселя основано на зависимости от того, больше он или меньше среднего. Значения 64 отдельных бита переводятся в одно 64-битное значение. Порядок не имеет значения, если он сохраняется постоянным. Таким образом, результирующее изображение можно рассчитать с очень небольшими вычислительными затратами, поскольку для каждого пикселя необходимо выполнить только простую операцию сравнения [37].

Если нужно сравнить две картинки, то просто строится хэш для каждой из них и подсчитывается количество разных битов, обозначаемое как расстояние Хэмминга. Нулевое расстояние означает, что это, скорее всего, одинаковые картинки (или вариации одного изображения). Дистанция 5 означает, что картинки в чем-то отличаются, но в целом довольно близки друг к другу. Если дистанция 10 или больше, то это, вероятно, совершенно разные изображения [30; 37].

Разницу средних хэшей (расстояние Хэмминга) мы обозначили для определенности как HASH-расстояние. Из описания алгоритма формирования хэш-отпечатка ясно, что это расстояние будет зависеть от ориентации изображений (поворота или зерка-

льного отображения) и даже нормальное состояние для левого и правого глаза будет нетождественным. Поэтому данный параметр был вспомогательным в нашем решении.

Основной параметр для классификатора мы назвали НАФ-расстояние (сокр. от Autofluoreszenz-Foto-Histogramm — «гистограмма фотоизображения аутофлюоресценции»). Для двух изображений (опорного и исследуемого) он формировался следующим образом: каждое изображение сначала размывалось с помощью ядра $\text{shape } 6 \text{ на } 6$ [23] (значение было подобрано эмпирически для конкретного фотонабора в этой задаче путем перебора значений в цикле). Это было нужно для нивелирования влияния мелких несущественных артефактов самого фото (малые смещения, повороты или пульсации яркости) и достижения эффекта «усреднения» фото нормального глазного дна. Ведь в идеале мы должны были бы сравнивать фотоизображения глазного дна без патологии и с ней одного и того же пациента, что является практически невыполнимой задачей.



Рис. 5. Фото паттерна аутофлюоресценции: а) с минимальными изменениями; б) кружевоподобного

**Правила распределения фото патологий по типам
(должны выполнять оба условия для параметров a и b)**

Тип паттерна	НАФ-расстояние (a)	HASH-расстояние (b)
Нормальный	$0 \leq a \leq 3$ или $8 \leq a \leq 12$	$0 \leq b \leq 3$
Минимальные изменения	$22 \leq a \leq 36$	$4 \leq b \leq 6$
Фокальный	$16 \leq a \leq 30$	$9 \leq b \leq 12$
Пятнистый	$5 \leq a \leq 11$	$10 \leq b \leq 13$
Линейный	$4 \leq a \leq 18$	$4 \leq b \leq 7$
Кружевоподобный	$a > 37$	$b > 10$
Ретикулярный	$21 \leq a \leq 35$	$8 \leq b \leq 13$
Крапчатый	$10 \leq a \leq 22$	$8 \leq b \leq 11$

Далее мы строили гистограммы для двух сравниваемых изображений. Диапазон гистограмм был выбран не от 0, а от 1 до 255, чтобы не учитывать изображение окуляра на снимке (рис. 3).

После этого мы вычисляли разницу между массивами отсортированных гистограмм, как между двумя векторами при $n = 100$ (параметр был подобран также эмпирически) — ширине интервала около максимума гистограммы, так как основную часть информации несет высокочастотная часть гистограммы. Результатом работы программы стали графики гистограмм сравниваемых изображений и величины определенных расстояний с прогнозом типа патологии. На рисунке 4 показан результат работы программы для условной нормы 1 (рис. 3а). Фото кружевоподобного паттерна — на рисунке 5б.

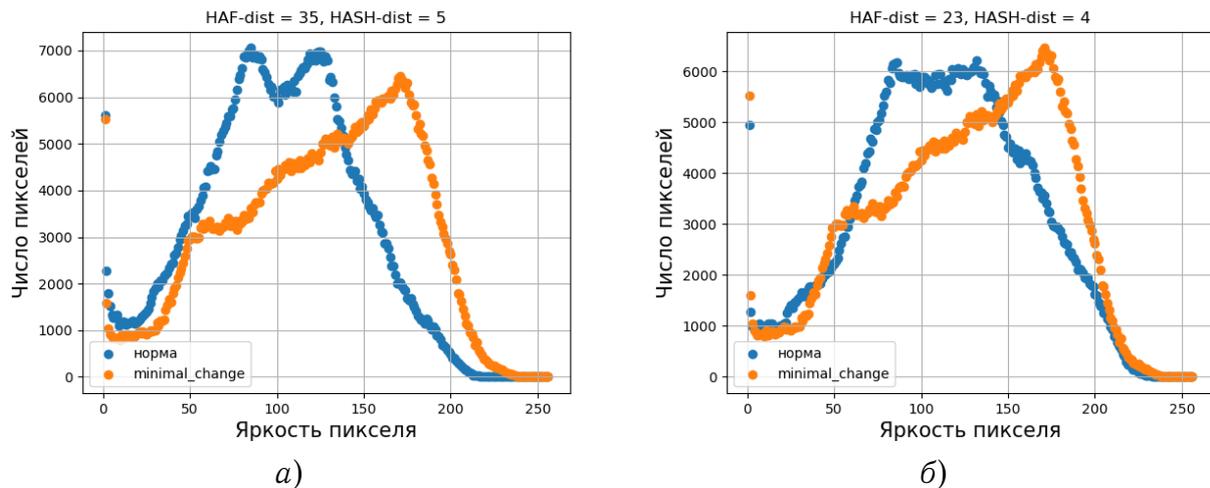


Рис. 6. Результат работы классификатора для минимальных изменений (рис. 5а):
 а) с опорным фото условной нормы 1 (рис. 3а);
 б) с опорным фото условной нормы 2 (рис. 3б)

Условия классификации (прогноз) были подобраны из набора 1 фото на патологию. Они представлены в виде таблицы. Отметим, что для фотоизображений с минимальными изменениями (рис. 5а) «разница» гистограмм (HAF-расстояние) имеет большие значения (рис. 6). Данный факт интересен тем, что в случае с МО мы можем предположить, зная принцип формирования паттернов и используя визуализацию промежуточных активаций, что паттерны нормального состояния и минимальных изменений должны быть практически мало отличимы [25]. HASH-расстояние демонстрирует именно этот факт.

Результат работы программы (HASH-расстояние) зависит от расположения сравниваемых снимков. Если сравнить норму 1 и норму 2 (рис. 3) или фото нормы и патологии, например, пятнистого паттерна между собой в двух случаях: как они есть (оба правых или левых глаза) и одно из них зеркально отобразить, что эквивалентно фото левого и правого глаза, то прогноз программы может не совпасть (рис. 7).

В случае несовпадения фотографий с нормой относительно ориентации глаз (левый/правый) в программе предусмотрен режим зеркального отображения исследуемого фото. С программной реализацией описанного алгоритма можно ознакомиться подробнее в репозитории проекта [9].

Точность разработанного решения на проверочных фото составила 60% при использовании только фото нормы 1. При использовании 3 опорных фото для нормально-

го паттерна точность возросла до 85 %, что уже сравнимо с результатами аналогичной работы [13], использующей методы МО.

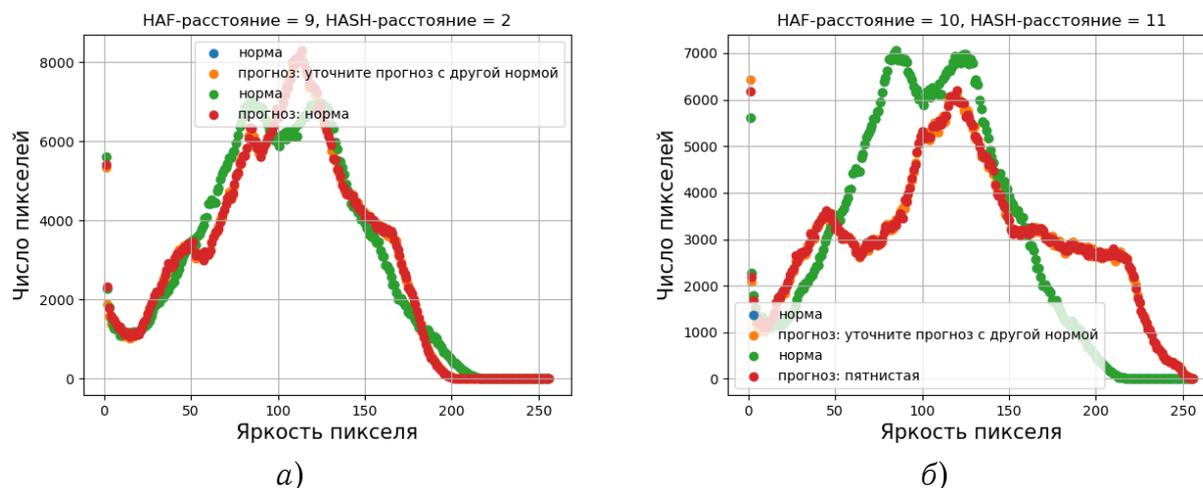


Рис. 7. Результат работы классификатора с опорным фото условной нормы 1 и:
а) с нормой 2 и ее зеркальным отображением относительно вертикальной оси;
б) с фото пятнистого паттерна и его зеркального отображения относительно вертикальной оси

Заключение

В результате проведенного исследования цель работы была достигнута: созданный алгоритм и реализованное на его основе программное средство позволяют проводить классификацию фотоизображений исследования аутофлюоресценции центральной области глазного дна человека по 8 типам при ультрамалом наборе исходных данных (несколько десятков уникальных единиц). Точность работы представленного решения сопоставима с некоторыми аналогичными МО-решениями, которые используют гораздо большие объемы обучающих данных, и может достигать 80–85 %.

Научная новизна, в сравнении с известными методами классификации изображений, заключается в комбинированном подходе: использовании числовых значений HAF- и HASH-расстояний, получаемых «прямой» разницей гистограмм исследуемого и опорного фотоизображения и их перцептивных хэшей. При этом решение реализуется в области малых наборов данных, где методы МО работают крайне неудовлетворительно и максимальная точность прогнозов на новых данных не превышает 12,5 %.

При соответственном подборе параметров классификатора разработанные алгоритмы могут быть также использованы для диагностической классификации в процессе оценки патологических изменений по фотоизображениям в тканях и структурах человеческого организма при других малораспространенных заболеваниях.

СПИСОК ЛИТЕРАТУРЫ

1. База данных: Патологии центральной области глазного дна человека, выявляемые при помощи исследования аутофлюоресценцией. — Электрон. текстовые дан. — Режим доступа: <https://notabug.org/Tonypythonu/meddb>. — Загл. с экрана.

2. Бобков, А. В. Системы распознавания образов : учеб. пособие / А. В. Бобков. — М. : Изд-во МГТУ им. Н. Э. Баумана, 2018. — 187 с.
3. Гермашев, И. В. Применение моделей нечеткой математики для решения задач медицинской диагностики / И. В. Гермашев, В. И. Дубовская // Математическая физика и компьютерное моделирование. — 2021. — Т. 24, № 4. — С. 53–65. — DOI: <https://doi.org/10.15688/mpcm.jvolsu.2021.4.4>
4. Гндоян, И. А. Аутофлуоресценция глазного дна в диагностике возрастной макулярной дегенерации / И. А. Гндоян, А. В. Петраевский, А. И. Дятчина // Вестник офтальмологии. — 2020. — Т. 136, № 5. — С. 136–141. — DOI: <https://doi.org/10.17116/oftalma2020136051136>
5. Гонсалес, Р. Цифровая обработка изображений / Р. Гонсалес, Р. Вудс. — М. : Техносфера, 2005. — 1072 с.
6. Джереми, Х. Глубокое обучение с fastai и PyTorch: минимум формул, минимум кода, максимум эффективности / Х. Джереми, Г. Сильвейн. — СПб. : Питер, 2022. — 624 с.
7. Ильясова, Н. Ю. Применение сверточных нейронных сетей для анализа изображений глазного дна / Н. Ю. Ильясова, А. С. Широкаев, И. А. Климов // Сборник трудов ИТНТ-2019. — 2019. — Т. 4. — С. 111–118.
8. Использование программы IBM WATSON в лечении онкологических заболеваний в Южной Корее. — Электрон. текстовые дан. — Режим доступа: <https://medical-express.ru/branches/oncologiya/ibm-watson-v-medicine>. — Загл. с экрана.
9. Классификатор фотоизображений АФ глазного дна. — Электрон. текстовые дан. — Режим доступа: <https://github.com/Antoniii/humashineye>. — Загл. с экрана.
10. Крейман, Г. Биологическое и компьютерное зрение / Г. Крейман. — М. : ДМК Пресс, 2022. — 314 с.
11. Логинов, В. Н. Разработка web-приложения системы идентификации дефектов металла на полутоновых изображениях с использованием каскадного классификатора Хаара на платформе Asp .Net Core MVC / В. Н. Логинов, К. А. Щипанов, В. В. Лавров // Вестник Череповецкого государственного университета. — 2019. — № 4. — С. 8–22.
12. Лосев, А. Г. Интеллектуальный анализ данных микроволновой радиотермометрии в диагностике рака молочной железы / А. Г. Лосев, В. В. Левшинский // Математическая физика и компьютерное моделирование. — 2017. — № 5 (342). — С. 16–22. — DOI: <https://doi.org/10.15688/mpcm.jvolsu.2017.5.6>
13. Лошманов, В. И. Разработка и валидация метода классификации офтальмологической патологии с применением глубокого машинного обучения / В. И. Лошманов, А. Г. Кравец // Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика. — 2021. — № 2. — С. 57–65. — DOI: [10.24143/2072-9502-2021-2-57-65](https://doi.org/10.24143/2072-9502-2021-2-57-65)
14. Методы и алгоритмы контурного анализа для задач классификации сложноструктурируемых изображений / М. В. Дюдин, А. Д. Поваляев, Е. С. Подвальный, Р. А. Томакова // Вестник ВГТУ. — 2014. — Т. 10, № 3–1. — С. 54–59.
15. Молодяков, С. А. Применение функций OpenCV в компьютерном зрении (60 примеров на Python) / С. А. Молодяков. — СПб. : Изд-во Политехн. ун-та, 2022. — 296 с.
16. Обнаружение объектов без машинного обучения. — Электрон. текстовые дан. — Режим доступа: <https://newtechaudit.ru/obnaruzhenie-obektov-bez-ispolzovaniya-mashinnogo-obucheniya/>. — Загл. с экрана.
17. Обработка изображений в цифровой фотографии. Анализ гистограмм. — Электрон. текстовые дан. — Режим доступа: http://photomagic2007.narod.ru/Stati/analiz_gist/analiz_gist.html. — Загл. с экрана.
18. Орельен, Ж. Прикладное машинное обучение с помощью Scikit-Learn, Keras и TensorFlow: концепции, инструменты и техники для создания интеллектуальных систем / Ж. Орельен. — СПб. : ООО «Диалектика», 2020. — 1040 с.

19. Павельева, Е. А. Обработка и анализ изображений на основе использования информации о фазе / Е. А. Павельева // Компьютерная оптика. — 2018. — Т. 42, № 6. — С. 1022–1034.
20. Половинкин, А. Н. Алгоритмы классификации изображений с большим числом категорий объектов / А. Н. Половинкин // Вестник ННГУ. — 2013. — № 4-1. — С. 225–232.
21. Посохов, И. Методика построения функции принадлежности для классификации изображений на основе гистограмм яркости / И. Посохов, И. С. Логунова. — Электрон. текстовые дан. — Режим доступа: <https://ceur-ws.org/Vol-1197/paper20.pdf>. — Загл. с экрана.
22. Пухова, Е. А. Оценка гистограммных преобразований в печатном процессе / Е. А. Пухова, Ю. С. Андреев, О. В. Панкин // Известия ТулГУ. Технические науки. — 2018. — № 6. — С. 1–10.
23. Функция `cv2.blur()` в OpenCV Python. — Электрон. текстовые дан. — Режим доступа: <https://tonais.ru/library/funktsiya-cv2-blur-opencv-python>. — Загл. с экрана.
24. Шакирьянов, Э. Д. Компьютерное зрение на Python. Первые шаги / Э. Д. Шакирьянов. — Электрон. текстовые дан. — Режим доступа: https://www.litres.ru/get_pdf_trial/63606057.pdf. — Загл. с экрана.
25. Шолле, Ф. Глубокое обучение на Python / Ф. Шолле. — СПб. : Питер, 2018. — 400 с.
26. Элбон, К. Машинное обучение с использованием Python. Сборник рецептов / К. Элбон. — СПб. : БХВ-Петербург, 2019. — 384 с.
27. Ярышев, С. Н. Технологии глубокого обучения и нейронных сетей в задачах видеоанализа / С. Н. Ярышев, В. А. Рыжова. — СПб. : Ун-т ИТМО, 2022. — 82 с.
28. Aykat, S. Deep Learning in Retinal Diseases Diagnosis: A Review / S. Aykat, S. Senan // Machine Learning and AI Techniques in Interactive Medical Image Analysis. — 2023. — P. 34. — DOI: 10.4018/978-1-6684-4671-3.ch001
29. Classification of Fundus Autofluorescence Patterns in Early Age-Related Macular Disease / A. Bindewald, A. C. Bird, S. S. Dandekar, J. Dolar-Szczasny, J. Dreyhaupt, F. W. Fitzke, W. Einbock, F. G. Holz, J. J. Jorzik, C. Keilhauer, N. Lois, J. Mlynski, D. Pauleikhoff, G. Staurenghi, S. Wolf // Investigative Ophthalmology & Visual Science. — 2005. — Vol. 46, № 9. — P. 3309–3314.
30. Detection of Duplicate Images Using Image Hash Functions. — Electronic text data. — Mode of access: <https://towardsdatascience.com/detection-of-duplicate-images-using-image-hash-functions-4d9c53f04a75>. — Title from screen.
31. FCOS: Fully Convolutional One-Stage Object Detection. — Electronic text data. — Mode of access: <https://arxiv.org/abs/1904.01355>. — Title from screen.
32. Feature Pyramid Networks for Object Detection. — Electronic text data. — Mode of access: <https://arxiv.org/abs/1612.03144>. — Title from screen.
33. Histogram Matching. — Electronic text data. — Mode of access: https://scikit-image.org/docs/stable/auto_examples/color_exposure/plot_histogram_matching.html#sphx-glr-auto-examples-color-exposure-plot-histogram-matching-py. — Title from screen.
34. IBM Bets Future on Cognitive Platform Watson. — Electronic text data. — Mode of access: <https://koreajoongangdaily.joins.com/news/article/article.aspx?aid=3032651>. — Title from screen.
35. IBM's Watson to Be Used at Korean Hospital. — Electronic text data. — Mode of access: https://www.koreatimes.co.kr/www/tech/2020/03/129_213747.html. — Title from screen.
36. Image Classification from Scratch. — Electronic text data. — Mode of access: https://keras.io/examples/vision/image_classification_from_scratch/. — Title from screen.
37. Image Similarity Assessment. Master's Thesis. — Electronic text data. — Mode of access: https://dspace5.zcu.cz/bitstream/11025/12532/1/dip_fric_vojtech.pdf. — Title from screen.
38. Jie, Z. Novel Block-DCT and PCA Based Image Perceptual Hashing Algorithm / Z. Jie

// IJCSI International Journal of Computer Science Issues. — 2013. — Vol. 10, iss. 1, № 3. — P. 399–403.

39. Kim, H. Exploiting the vulnerability of deep learning-based artificial intelligence models in medical imaging: Adversarial attacks / H. Kim, D. C. Jung, B. W. Choi // Journal of the Korean Society of Radiology. — 2019. — № 80 (2). — P. 259–273. — DOI: 10.3348/jksr.2019.80.2.259

40. MedPy 0.4.0. — Electronic text data. — Mode of access: <https://pypi.org/project/MedPy/>. — Title from screen.

41. Mutli Label Classification. — Electronic text data. — Mode of access: <https://www.kaggle.com/code/mustafa9901/mutli-label-classification>. — Title from screen.

42. Retinal Disease Classification. — Electronic text data. — Mode of access: <https://www.kaggle.com/datasets/andrewmvd/retinal-disease-classification>. — Title from screen.

43. Verma, M. AI and Machine Learning: Supervised Learning Techniques Based on IoMT / M. Verma // The Internet of Medical Things (IoMT) and Telemedicine Frameworks and Applications. — 2023. — P. 177–188. — DOI: 10.4018/978-1-6684-3533-5.ch010

REFERENCES

1. *Baza dannykh: Patologii tsentralnoy oblasti glaznogo dna cheloveka, vyyavlyaemye pri pomoshchi issledovaniya autoflyuorestsentsiy* [Database: Pathologies of the Central Area of the Human Fundus Detected by Autofluorescence Examination]. URL: <https://notabug.org/Tonypythony/meddb>.

2. Bobkov A.V. *Sistemy raspoznavaniya obrazov: ucheb. posobie* [Image Recognition Systems: Tutorial]. Moscow, Izd-vo MGTU im. N.E. Baumana, 2018. 187 p.

3. Germashev I.V., Dubovskaya V.I. Primenenie modeley nechetkoy matematiki dlya resheniya zadach meditsinskoj diagnostiki [Application of Fuzzy Mathematics Models for Solving Medical Diagnostics Problems]. *Matematicheskaya fizika i kompyuternoe modelirovanie* [Mathematical Physics and Computer Modeling], 2021, vol. 24, no. 4, pp. 53-65. DOI: <https://doi.org/10.15688/mpcm.jvolsu.2021.4.4>

4. Gndoyan I.A., Petraevskiy A.V., Dyatchina A.I. Autoflyuorestsentsiya glaznogo dna v diagnostike vozrastnoy makulyarnoy degeneratsii [Fundus Autofluorescence in the Diagnosis of Age-Related Macular Degeneration]. *Vestnik oftalmologii*, 2020, vol. 136, no. 5, pp. 136-141. DOI: <https://doi.org/10.17116/oftalma2020136051136>

5. Gonsales R., Vuds R. *Tsifrovaya obrabotka izobrazheniy* [Digital Image Processing]. Moscow, Tekhnosfera Publ., 2005. 1072 p.

6. Dzheremi Kh., Silvey G. *Glubokoe obuchenie s fastai i PyTorch: minimum formul, minimum koda, maksimum effektivnosti* [Deep Learning for Coders with Fastai and PyTorch: AI Applications Without a PhD]. Saint Petersburg, Piter Publ., 2022. 624 p.

7. Ilyasova N.Yu., Shirokanyov A.S., Klimov I.A. Primenenie svyortochnykh neyronnykh setey dlya analiza izobrazheniy glaznogo dna [Application of Convolutional Neural Networks for the Analysis of Fundus Images]. *Sbornik trudov ITNT-2019*, 2019, vol. 4, pp. 111-118.

8. *Ispolzovanie programmy IBM WATSON v lechenii onkologicheskikh zabolevaniy v Yuzhnoy Koree* [Using the IBM WATSON Program in the Treatment of Cancer in South Korea]. URL: <https://medical-express.ru/branches/oncologiya/ibm-watson-v-medicine>.

9. *Klassifikator fotoizobrazheniy AF glaznogo dna* [Classifier of AF Images of the Fundus]. URL: <https://github.com/Antoniii/humashineye>.

10. Kreyman G. *Biologicheskoe i kompyuternoe zrenie* [Biological and Computer Vision]. Moscow, DMK Press Publ., 2022. 314 p.

11. Loginov V.N., Shchipanov K.A., Lavrov V.V. Razrabotka web-prilozheniya sistemy identifikatsii defektov metalla na polutonovykh izobrazheniyakh s ispolzovaniem kaskadnogo klassifikatora Khaara na platforme Asp .Net Core MVC [Development of a Web Application for the Identification of Metal Defects on Halftone Images Using the Cascade Haar Classifier on

the Asp Platform .Net Core MVC]. *Vestnik Cherepovetskogo gosudarstvennogo universiteta* [Bulletin of Cherepovets State University], 2019, no. 4, pp. 8-22.

12. Losev A.G., Levshinskiy V.V. Intellektualnyy analiz dannykh mikrovolnovoy radiotermometrii v diagnostike raka molochnoy zhelezy [Intelligent Analysis of Microwave Radiothermometry Data in the Diagnosis of Breast Cancer]. *Matematicheskaya fizika i kompyuternoe modelirovanie* [Mathematical Physics and Computer Modeling], 2017, no. 5 (342), pp. 16-22. DOI: <https://doi.org/10.15688/mpcm.jvolsu.2017.5.6>

13. Loshmanov V.I., Kravets A.G. Razrabotka i validatsiya metoda klassifikatsii oftalmologicheskoy patologii s primeneniem glubokogo mashinnogo obucheniya [Development and Validation of the Method of Classification of Ophthalmic Pathology Using Deep Machine Learning]. *Vestnik Astrakhanskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika i informatika* [Bulletin of the Astrakhan State Technical University. Series: Management, Computer Engineering and Computer Science], 2021, no. 2, pp. 57-65. DOI: 10.24143/2072-9502-2021-2-57-65

14. Dyudin M.V., Povalyaev A.D., Podvalnyy E.S., Tomakova R.A. Metody i algoritmy konturnogo analiza dlya zadach klassifikatsii slozhnostrukturiruyemykh izobrazheniy [Methods and Algorithms of the Contour Analysis for Problems of the Categorizations Complex-Structured Images]. *Vestnik VGTU* [Bulletin of VSTU], 2014, vol. 10, no. 3–1, pp. 54-59.

15. Molodyakov S.A. *Primenenie funktsiy OpenCV v kompyuternom zrenii (60 primerov na Python)* [Application of OpenCV Functions in Computer Vision (60 Python Examples)]. Saint Petersburg, Izd-vo Politekhn. un-ta Publ., 2022. 296 p.

16. *Obnaruzhenie obyektov bez mashinnogo obucheniya* [Object Detection Without Using Machine Learning]. URL: <https://newtechaudit.ru/obnaruzhenie-obyektov-bez-ispolzovaniya-mashinnogo-obucheniya/>.

17. *Obrabotka izobrazheniy v tsifrovoy fotografii. Analiz gistogramm* [Image Processing in Digital Photography. Histogram Analysis]. URL: http://photomagic2007.narod.ru/Stati/analiz_gist/analiz_gist.html.

18. Orelyen Zh. *Prikladnoe mashinnoe obuchenie s pomoshchyu Scikit-Learn, Keras i TensorFlow: kontseptsii, instrumenty i tekhniki dlya sozdaniya intellektualnykh sistem* [Applied Machine Learning Using Scikit-Learn, Kurs and TensorFlow: Concepts, Tools and Techniques for Creating Intelligent Systems]. Saint Petersburg, OOO «Dialektika» Publ., 2020. 1040 p.

19. Pavelyeva E.A. Obrabotka i analiz izobrazheniy na osnove ispolzovaniya informatsii o faze [Processing and Analysis of Images Based on the Use of Phase Information]. *Kompyuternaya optika* [Computer optics], 2018, vol. 42, no. 6, pp. 1022-1034.

20. Polovinkin A.N. Algoritmy klassifikatsii izobrazheniy s bolshim chislom kategoriy obyektov [Algorithms for Classifying Images with a Large Number of Object Categories]. *Vestnik NNGU* [Bulletin of the UNN], 2013, no. 4-1, pp. 225-232.

21. Posokhov I., Logunova I.S. *Metodika postroeniya funktsii prinadlezhnosti dlya klassifikatsii izobrazheniy na osnove gistogramm yarkosti* [Methodology for Constructing the Membership Function for Classifying Images Based on Brightness Histograms]. URL: <https://ceur-ws.org/Vol-1197/paper20.pdf>.

22. Pukhova E.A., Andreev Yu.S., Pankin O.V. Otsenka gistogrammnykh preobrazovaniy v pechatnom protsesse [Evaluation of Histogram Transformations in the Printing Process]. *Izvestiya TulGU. Tekhnicheskie nauki* [News of TulSU. Technical Sciences], 2018, no. 6, pp. 1-10.

23. *Funktsiya cv2.blur() v OpenCV Python* [Cv2.blur() Function in OpenCV Python]. URL: <https://tonais.ru/library/funktsiya-cv2-blur-opencv-python>.

24. Shakiryaynov E.D. *Kompyuternoe zrenie na Python. Perveye shagi* [Computer Vision in Python. First Steps]. URL: https://www.litres.ru/get_pdf_trial/63606057.pdf.

25. Sholle F. *Glubokoe obuchenie na Python* [Deep Learning with Python]. Saint Petersburg, Piter Publ., 2018. 400 p.

26. Elbon K. *Mashinnoe obuchenie s ispolzovaniem Python. Sbornik retseptov* [Machine Learning Using Python. Basic Collection]. Saint Petersburg, BKhV-Peterburg Publ., 2019. 384 p.

27. Yaryshev S.N., Ryzhova V.A. *Tekhnologii glubokogo obucheniya i neyronnykh setey v zadachakh videoanaliza* [Technologies of Deep Learning and Neural Networks in Video Analysis Tasks]. Saint Petersburg, Un-t ITMO Publ., 2022. 82 p.
28. Aykat S., Senan S. Deep Learning in Retinal Diseases Diagnosis: A Review. *Machine Learning and AI Techniques in Interactive Medical Image Analysis*, 2023, pp. 34. DOI: 10.4018/978-1-6684-4671-3.ch001
29. Bindewald A., Bird A.C., Dandekar S.S., Dolar-Szczasny J., Dreyhaupt J., Fitzke F.W., Einbock W., Holz F.G., Jorzik J.J., Keilhauer C., Lois N., Mlynski J., Pauleikhoff D., Staurenghi G., Wolf S. Classification of Fundus Autofluorescence Patterns in Early Age-Related Macular Disease. *Investigative Ophthalmology & Visual Science*, 2005, vol. 46, no. 9, pp. 3309-3314.
30. *Detection of Duplicate Images Using Image Hash Functions*. URL: <https://towardsdatascience.com/detection-of-duplicate-images-using-image-hash-functions-4d9c53f04a75>.
31. *FCOS: Fully Convolutional One-Stage Object Detection*. URL: <https://arxiv.org/abs/1904.01355>.
32. *Feature Pyramid Networks for Object Detection*. URL: <https://arxiv.org/abs/1612.03144>.
33. *Histogram Matching*. URL: https://scikit-image.org/docs/stable/auto_examples/color_exposure/plot_histogram_matching.html#sphx-glr-auto-examples-color-exposure-plot-histogram-matching-py.
34. *IBM Bets Future on Cognitive Platform Watson*. URL: <https://koreajoongangdaily.joins.com/news/article/article.aspx?aid=3032651>.
35. *IBM's Watson to Be Used at Korean Hospital*. URL: https://www.koreatimes.co.kr/www/tech/2020/03/129_213747.html.
36. *Image Classification from Scratch*. URL: https://keras.io/examples/vision/image_classification_from_scratch/.
37. *Image Similarity Assessment. Master's Thesis*. URL: https://dspace5.zcu.cz/bitstream/11025/12532/1/dip_fric_vojtech.pdf.
38. Jie Z. Novel Block-DCT and PCA Based Image Perceptual Hashing Algorithm. *IJCSI International Journal of Computer Science Issues*, 2013, vol. 10, iss. 1, no. 3, pp. 399-403.
39. Kim H., Jung D.C., Choi B.W. Exploiting the Vulnerability of Deep Learning-Based Artificial Intelligence Models in Medical Imaging: Adversarial Attacks. *Journal of the Korean Society of Radiology*, 2019, no. 80 (2), pp. 259-273. DOI: 10.3348/jksr.2019.80.2.259
40. *MedPy 0.4.0*. URL: <https://pypi.org/project/MedPy/>.
41. *Mutli Label Classification*. URL: <https://www.kaggle.com/code/mustafa9901/mutli-label-classification>.
42. *Retinal Disease Classification*. URL: <https://www.kaggle.com/datasets/andrewmvd/retinal-disease-classification>.
43. Verma M. AI and Machine Learning: Supervised Learning Techniques Based on IoMT. *The Internet of Medical Things (IoMT) and Telemedicine Frameworks and Applications*, 2023, pp. 177-188. DOI: 10.4018/978-1-6684-3533-5.ch010

**DEVELOPMENT OF A CLASSIFIER
OF PHOTO IMAGES OF PATHOLOGIES
FOR AN ULTRA-SMALL DATA SET**

Anton A. Adamov

Candidate of Technical Sciences, Junior Researcher, Institute of Mathematics and Information Technology,
Senior Lecturer, Department of Radiophysics,
Volgograd State University
anton.a.adamov@gmail.com, faa-162_758896@volsu.ru, rf@volsu.ru
<https://orcid.org/0000-0002-7394-0744>
Prosp. Universitetsky, 100, 400062 Volgograd, Russian Federation

Irina A. Gndoyan

Doctor of Medical Sciences, Head of the Department of Ophthalmology,
Volgograd State Medical University
irina.gndoyan@mail.ru
<https://orcid.org/0000-0001-7581-9473>
Sq. Pavshikh Bortsov, 1, 400131 Volgograd, Russian Federation

Alena I. Dyatchina

Postgraduate Student, Department of Ophthalmology,
Volgograd State Medical University
alena.dyatchina@yandex.ru
<https://orcid.org/0000-0001-9632-5800>
Sq. Pavshikh Bortsov, 1, 400131 Volgograd, Russian Federation

Vladimir N. Khramov

Candidate of Physical and Mathematical Sciences, Associate Professor,
Department of Radiophysics,
Volgograd State University
vladimir.khramov@volsu.ru, rf@volsu.ru
<https://orcid.org/0000-0001-8988-0929>
Prosp. Universitetsky, 100, 400062 Volgograd, Russian Federation

Abstract. The purpose of the work is to create an algorithm and implement it in a software tool for classifying photographic images of pathology of the central region of the human fundus, detected by autofluorescence research, according to 8 types-patterns: normal, minimal changes, focal, spotted, linear, lace-like, reticular, speckled. Methods used machine learning algorithms (convolutional neural networks) and computer vision (histogram methods, perceptual hash algorithms). The main feature of the task is an ultra-small set of unique photoimages with an accurately diagnosed type of pathology (18 pieces). The accuracy of forecasts when solving a problem using a neural network is 12.5%. The accuracy of the predictions of the developed algorithm using a combination of histograms, perceptual hash and one reference photo of the normal state of the fundus is 60% when selecting the classifier parameters from a set of one

photo for one pathology. When using three reference photos, the norm is 85%. The proposed solution can be used in medicine, ophthalmology, photonics and optics of biological tissues, machine learning for both research and educational purposes.

Key words: photo image processing, computer vision, machine learning, image classification, histogram, perceptual hash, ophthalmological diagnostics, computerization of medicine.