

Вестник Череповецкого государственного университета. 2025. № 1 (124). С. 70–79.
Cherepovets State University Bulletin, 2025, no. 1 (124), pp. 70–79.

Научная статья

УДК 004.93:617.7

<https://elibrary.ru/ebeolo>

<https://doi.org/10.23859/1994-0637-2025-1-124-6>

Нейросетевая модель распознавания патологий глазного дна на основе оптической когерентной томографии

Игорь Олегович Темкин¹, Владимир Владимирович Горин^{2✉}

^{1,2}Национальный исследовательский технологический университет «МИСИС»,
Москва, Россия

¹asu@misis.ru, <https://orcid.org/0000-0001-8150-6529>

^{2✉}okwstn@gmail.com, <https://orcid.org/0009-0001-3064-2149>

Аннотация. В статье представлено исследование по разработке модели искусственной нейронной сети для автоматического распознавания патологий глазного дна на основе изображений оптической когерентной томографии (ОКТ). Проведен анализ современных методов диагностики заболеваний глазного дна и применимости компьютерного зрения и нейронных сетей. Для исследования использован набор данных, находящийся в открытом доступе, содержащий 84713 изображений, предварительно аннотированных экспертами на четыре категории: хориоидальная неоваскуляризация, диабетическая ретинопатия (DME), дегенерация макулы и заднего полюса (DRUSEN) и нормальное состояние (NORMAL). Разработанная авторская архитектура нейронной сети, состоящая из нескольких сверточных слоев, слоев подвыборки и полносвязанных слоев, показала высокую точность классификации (0.98) и превосходит предобученные модели ResNet50 и VGG16. Метрики точности и полноты подтверждают высокую эффективность модели в автоматическом распознавании патологий глазного дна, что в перспективе открывает возможности для снижения нагрузки на медицинский персонал и повышения точности диагностики. Применение данной модели в клинической практике будет способствовать улучшению качества медицинского обслуживания, повышению скорости диагностики заболеваний и увеличению эффективности лечения пациентов.

Ключевые слова: оптическая когерентная томография, сверточная нейронная сеть, классификация патологий глазного дна, автоматизация диагностики, глубокое обучение в медицине

Для цитирования: Темкин И. О., Горин В. В. Нейросетевая модель распознавания патологий глазного дна на основе оптической когерентной томографии // Вестник Череповецкого государственного университета. 2025. № 1 (124). С. 70–79. <https://doi.org/10.23859/1994-0637-2025-1-124-6>; EDN: EBEOLO

Neural network model for detection of retinal pathologies based on optical coherence tomography images

Igor O. Temkin¹, Vladimir V. Gorin²✉

^{1,2}The National University of Science and Technology "MISIS",
Moscow, Russia

¹asu@isis.ru, <https://orcid.org/0000-0001-8150-6529>

²✉okwstn@gmail.com, <https://orcid.org/0009-0001-3064-2149>

Abstract. The article presents a study on the development of an artificial neural network model for the automatic recognition of fundus pathologies based on optical coherence tomography (OCT) images. An analysis of modern methods for diagnosing fundus diseases and the applicability of computer vision and neural networks was conducted. The study used an open-access dataset containing 84,713 images, pre-annotated by experts into four categories: choroidal neovascularization (CNV), diabetic macular edema (DME), drusen (DRUSEN), and normal (NORMAL). The developed author's neural network architecture, consisting of several convolutional layers, pooling layers, and fully connected layers, demonstrated high classification accuracy (0.98) and outperformed pre-trained models such as ResNet50 and VGG16. Accuracy and completeness metrics confirm the high efficiency of the model in the automatic recognition of fundus pathologies, which opens up opportunities for reducing the workload on medical personnel and increasing diagnostic accuracy. The application of this model in clinical practice will contribute to improving the quality of medical care, increasing the speed of disease diagnosis, and enhancing the effectiveness of patient treatment.

Keywords: optical coherence tomography, convolutional neural network, retinal pathology classification, diagnostic automation, deep learning in medicine

For citation: Temkin I. O., Gorin V. V. Neural network model for detection of retinal pathologies based on optical coherence tomography images. *Cherepovets State University Bulletin*, 2025, no. 1 (124), pp. 70–79. (In Russ.) <https://doi.org/10.23859/1994-0637-2025-1-124-6>; EDN: EBEOLO

Введение

Современные методы диагностики заболеваний глазного дна играют ключевую роль в раннем выявлении ряда патологий, что обеспечивает повышение эффективности офтальмологического лечения. Эти патологии могут привести к значительной потере зрения и даже к слепоте, если их своевременно не выявить и не начать лечение. ОКТ представляет собой один из наиболее эффективных методов визуализации структур глазного дна, позволяющий получать изображения с высоким разрешением. Однако анализ большого объема данных ОКТ вручную требует значительных временных затрат со стороны специалистов.

В последние годы методы машинного обучения, особенно глубокие нейронные сети, показали высокую эффективность в автоматизации анализа медицинских изображений. Применение сверточных нейронных сетей (CNN) для классификации изображений ОКТ позволяет значительно ускорить процесс диагностики и повысить точность выявления патологий.

Целью данного исследования является улучшение качества лечения больных за счет разработки и использования модели нейронной сети для автоматического распознавания патологий глазного дна на основе изображений ОКТ. Для достижения

этой цели был использован набор данных, содержащий 84,713 изображений, которые эксперты разделили на четыре категории: хориоидальная неоваскуляризация (CNV), диабетическая ретинопатия (DME), дегенерация макулы и заднего полюса (DRUSEN) и нормальное состояние (NORMAL).

Разработка модели включала несколько этапов: сбор и предобработка данных, выбор и обучение архитектуры нейронной сети, а также оценка ее производительности. В качестве архитектур были выбраны предобученные модели ResNet50 и VGG16, а также авторская модель, специально адаптированная для задачи классификации изображений ОКТ.

Основная часть

В последние годы методы искусственного интеллекта и машинного обучения находят все более широкое применение в медицинской области. Нейронные сети, в частности сверточные нейронные сети (CNN), демонстрируют высокую эффективность в задачах анализа медицинских изображений. Они применяются для диагностики различных заболеваний, таких как рак легких, меланома, а также для анализа рентгеновских и МРТ изображений.

Например, исследование¹, проведенное в 2017 году, показало, что CNN могут достичь точности, сопоставимой с врачами-экспертами, при диагностике меланомы на основе дерматоскопических изображений. В другом исследовании² CNN использовались для автоматического распознавания аномалий на рентгеновских снимках грудной клетки, достигнув высокой точности и снизив нагрузку на радиологов.

Однако существует проблема дефицита специалистов, особенно актуальная для ряда регионов РФ. Это приводит к тому, что многие пациенты не получают своевременную диагностику и лечение, что отрицательно сказывается на качестве медицинских услуг. В таких условиях внедрение систем распознавания патологий глазного дна на основе нейронных сетей может стать важным инструментом для улучшения качества оказываемой медицинской помощи.

Также немаловажно отметить, что часто при решении практических задач используются подходы, основанные на использовании проверенных и частично обученных архитектур и их дообучении на конкретных релевантных задачах данных. При этом специальные методы селекции данных позволяют существенно улучшить качество решаемых задач распознавания. В нашем случае, несмотря на успешное применение предобученных моделей ResNet50 и VGG16, был выбран другой подход: разработка авторской архитектуры нейронной сети, специально адаптированной для классификации изображений ОКТ.

¹ Esteva A., Kuprel B., Novoa R. A., Ko J., Swetter J. M., Bloe H. M., Thrun S. Dermatologist-level classification of skin cancer with deep neural networks // Nature. 2017. No. 542. P. 115–118. <https://doi.org/10.1038/nature21056>

² Wang X., Peng Y., Lu L., Lu Z., Bagheri M., Summers R. M. ChestX-ray8: Hospital-scale Chest x-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases // IEEE Transactions on Medical Imaging. 2017. Vol. 36, no. 7. P. 1945–1956. <https://doi.org/10.1109/TMI.2017.2699723>

Для разработки и обучения модели нейронной сети использовался открытый набор данных, содержащий 84,713 изображений ОКТ. Изображения были аннотированы экспертами и разделены на четыре категории: CNV, DME, DRUSEN и NORMAL. Важно отметить, что данные сбалансированы, что позволяет избежать проблем, связанных с дисбалансом классов, таких как переобучение модели на более представленных классах.

При организации процесса обучения был использован традиционный подход разделения данных на обучающую, валидационную и тестовую выборки. Данные разделяются на обучающую (90 %) и валидационную (10 %) выборки. Затем обучающая выборка делится на две части: 80 % для обучения и 20 % для тестирования. Модель сначала обучается на 80 % обучающей выборки, затем оценивается на 20 % тестовой выборки. После этого проводится оценка на валидационной выборке (10 %) для настройки гиперпараметров и выбора оптимальной модели. Этот подход позволяет избежать переобучения и обеспечивает объективную оценку производительности модели, проверяя ее обобщающую способность на валидационной выборке.

Одной из характерных особенностей данных ОКТ является наличие шумов на изображениях. Шумы могут возникать по разным причинам: движение пациента во время сканирования, аппаратные ограничения или артефакты, возникающие в процессе обработки изображений. Наличие шумов может значительно усложнить задачу распознавания патологий и привести к снижению точности модели.

Для снижения влияния шумов на изображения был использован медианный фильтр. Медианный фильтр заменяет значение каждого пикселя на медиану значений пикселей в окрестности заданного размера. В отличие от других методов фильтрации, таких как гауссово размытие или среднее фильтрование, медианный фильтр эффективно устраняет шумы, сохраняя при этом резкие границы объектов на изображении. Это особенно важно для медицинских изображений, где четкость границ может быть критичной для правильной диагностики. Основные недостатки других видов фильтров заключаются в следующем:

1. Гауссово размытие: размывает изображение, что может привести к потере деталей и снижению точности распознавания.
2. Среднее фильтрование: может размывать резкие границы и создавать артефакты, что также негативно сказывается на точности модели.

Применение медианного фильтра показало наилучший результат по сравнению с другими методами фильтрации, так как позволило улучшить обобщающую способность модели, сохранив важные детали изображения.

Формула медианного фильтра (1):

$$\hat{I}(x, y) = \text{median} \left\{ I(x + i, y + i) \mid i = -\frac{N}{2}, \dots, \frac{N}{2}, j = -\frac{N}{2}, \dots, \frac{N}{2} \right\}, \quad (1)$$

где $\hat{I}(x, y)$ – значение пикселя после применения медианного фильтра, $I(x + i, y + i)$ – значение пикселя в окрестности размера $N \times N$, N – размер окна фильтра.

В последние годы конволюционные нейронные сети стали основным инструментом для анализа и распознавания изображений. Среди многообразия моделей наибольшее признание получили архитектуры ResNet и VGG, которые продемонстрировали высокую эффективность в различных задачах компьютерного зрения.

ResNet50 (Residual Network) была предложена в 2015 году командой исследователей Microsoft Research и стала одной из самых влиятельных архитектур в области глубокого обучения. Ключевая идея ResNet заключается в использовании блоков с пропуском (skip connections), что позволяет обучать очень глубокие нейронные сети без проблем, связанных с затуханием градиентов.

VGG16 была разработана в Visual Geometry Group при Оксфордском университете и представлена в 2014 году. Основной принцип архитектуры VGG заключается в использовании блоков со сверточными слоями размером 3×3 и пулинг слоями размером 2×2 .

Сеть ResNet50:

- Residual блоки. Каждый блок содержит несколько слоев свертки, к которым добавляется пропускающий соединительный слой. Это позволяет градиентам эффективно распространяться через сеть.

- Глубина. ResNet50 содержит 50 слоев, включая слои свертки, пулинга и полносвязные слои.

- 1×1 свертки. Использование сверток размером 1×1 уменьшает количество параметров и вычислительные затраты.

Сеть VGG16:

- Глубина. VGG16 состоит из 16 слоев, включая сверточные и полносвязные слои.

- Свертки 3×3 . Использование сверток размером 3×3 позволяет модели извлекать более сложные признаки из изображений.

- Функции активации ReLU. Использование функции активации ReLU после каждого сверточного слоя для введения нелинейности.

Обе модели, ResNet50 и VGG16, были предварительно обучены на наборе данных ImageNet. ImageNet содержит более миллиона изображений, разделенных на более чем тысячу категорий. Обучение на таком крупном наборе данных позволяет моделям изучать широкий спектр объектов и сцен, что способствует повышению их обобщающей способности и точности при классификации изображений.

ResNet50 и VGG16 были выбраны для сравнения производительности с авторской моделью, так как они являются наиболее популярными архитектурами, используемыми в задачах классификации изображений, что позволяет корректно оценить производительность разработанной модели.

Процесс создания архитектуры модели начался с анализа требований к задаче и особенностей данных ОКТ. Основной целью было создание модели, способной эффективно обрабатывать медицинские изображения с высокой степенью детализации и точности. Для этого были проведены эксперименты с различными комбинациями сверточных и пулинг слоев, а также методами регуляризации, такими как Dropout и Batch Normalization. Важной частью процесса была оценка влияния каждого компонента архитектуры на общую производительность модели. В результате многократ-

ных итераций и тестирований была сформирована окончательная архитектура, состоящая из двух основных частей: извлекателя признаков (feature extractor) и классификатора (classifier):

Feature Extractor:

- Несколько сверточных слоев для извлечения высокоуровневых признаков из входных изображений.
- Первые сверточные слои выявляют простейшие геометрические формы и текстурные особенности, более глубокие слои – более сложные и абстрактные признаки.
- Количество сверточных слоев подобрано экспериментальным путем для обеспечения достаточного уровня абстракции при минимизации риска переобучения.

Classifier:

- Полносвязные слои принимают на вход выделенные признаки и производят классификацию изображений по заданным классам патологий глазного дна.
- Количество полносвязных слоев было подобрано с учетом достаточности для обучения модели на имеющихся данных без переобучения.

Основные части архитектуры, в свою очередь, состоят из следующих слоев:

1. Сверточные слои. 8 сверточных слоев, каждый содержит 64 фильтра размером 3x3.
2. Пулинг слои. 8 пулинг слоев типа MaxPooling с окном 2x2.
3. Batch Normalization. Применяется после каждого сверточного слоя для стабилизации обучения.
4. Функции активации. ReLU используются после каждого сверточного и полносвязного слоя.
5. Dropout. Применяется с вероятностью отсечения нейронов в полносвязных слоях для предотвращения переобучения.
6. Полносвязные слои. 3 полносвязных слоя с 256, 128 и 64 нейронами соответственно.
7. Выходной слой. Argmax слой для классификации на 4 класса патологий глазного дна.

Для оценки производительности моделей в задачах классификации используются различные метрики, каждая из которых предоставляет уникальную информацию о качестве предсказаний. В данном исследовании мы опирались на несколько ключевых метрик: точность (accuracy), полноту (recall), точность предсказания (precision) и F1-меру.

1. Accuracy (2) – это отношение правильно классифицированных примеров к общему числу примеров в выборке. Она показывает, насколько часто модель делает правильные предсказания.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}, \quad (2)$$

где TP (True Positives) – истинно положительные; TN (True Negatives) – истинно отрицательные; FP (False Positives) – ложно положительные; FN (False Negatives) – ложно отрицательные.

2. **Recall (3)** – это доля правильно классифицированных положительных примеров от общего числа положительных примеров. Она важна в медицинских задачах, так как акцентируется на способности модели обнаруживать все положительные случаи.

$$recall = \frac{TP}{TP+FN}. \quad (3)$$

В медицинских задачах, таких как диагностика заболеваний глазного дна, recall является одной из наиболее важных метрик. Это объясняется следующими причинами:

- в медицинской практике пропуск положительного случая (ложноотрицательный результат) может иметь серьезные последствия для здоровья пациента. Несвоевременное выявление заболеваний глазного дна (диабетического макулярного отека или хориоидальной неоваскуляризации) может привести к прогрессированию заболевания и значительной потере зрения. Полнота позволяет минимизировать количество таких пропущенных случаев;
- высокое значение recall гарантирует, что модель обнаруживает все или почти все положительные случаи заболевания, что критически важно для раннего выявления и начала лечения;
- в условиях, где последствия пропущенного диагноза могут быть необратимыми, важнее обеспечить высокую полноту, даже если это может привести к увеличению числа ложноположительных случаев. Ложноположительные результаты могут быть проверены дополнительными методами, в то время как ложноотрицательные результаты могут привести к упущенному лечению.

Одним из критических аспектов в разработке нейронной сети является процесс обучения модели и подбор гиперпараметров. В данном исследовании все модели, включая разработанную авторскую архитектуру, а также предобученные ResNet50 и VGG16, обучались на одном и том же наборе данных с одинаковым количеством эпох. Это позволяет объективно сравнивать их производительность.

Обучение модели включает несколько этапов:

1. Инициализация модели. На данном этапе модели были инициализированы с начальными значениями весов. Для предобученных моделей ResNet50 и VGG16 использовались веса, полученные в результате обучения на наборе данных ImageNet.
2. Разделение данных. Набор данных был разделен на три части: обучающую (90 %) и валидационную (10 %) выборки. Затем обучающая выборка делится на две части: 80 % для обучения и 20 % для тестирования. Обучающая выборка использовалась для корректировки весов модели, тестовая – для мониторинга производительности модели на данных, не участвующих в обучении, а валидационная – для окончательной оценки модели.
3. Предобработка данных. Изображения обрабатывались с использованием медианного фильтра для удаления шумов и улучшения качества изображений. Медианный фильтр был выбран на основании его способности сохранять резкие границы и минимально искажать изображение по сравнению с другими методами, такими как гауссово размытие и среднее фильтрование.

4. Аугментация данных. Применялись методы аугментации данных, такие как случайные повороты и горизонтальные отражения, чтобы улучшить обобщающую способность модели и уменьшить переобучение.

5. Обучение. Обучение моделей проводилось с использованием стохастического градиентного спуска и других методов оптимизации. Все модели обучались в течение 150 эпох.

Гиперпараметры играют важную роль в процессе обучения нейронной сети, так как они могут существенно влиять на производительность модели. В данном исследовании использовались следующие ключевые гиперпараметры:

- Скорость обучения (Learning Rate). Начальная скорость обучения была установлена на 0.001 и постепенно снижалась до 0.0001 для более плавного приближения к оптимальным значениям функции потерь.

- Dropout. Применялся с вероятностью 0.08 для уменьшения переобучения путем случайного отключения нейронов.

- L2 регуляризация. Использовалась с коэффициентом 0.01 для контроля роста весов и предотвращения переобучения.

В итоге были достигнуты следующие результаты:

Наибольшее среднее значение метрики recall по классам получилось при использовании разработанной архитектуры нейронной сети и составило 96,75 % против 93,5 % у модели ResNet50 и 88,5 % у модели VGG16.

Выводы

В данной научной статье была решена задача разработки модели нейронной сети для распознавания патологий глазного дна на основе изображений ОКТ. Целью исследования было найти эффективное решение, чтобы повысить качество оказания медицинских услуг и снизить нагрузку на медицинский персонал.

Выбранный подход к решению задачи позволил достичь высокой точности классификации и преодолеть ограничения предобученных моделей, такие как недостаточная адаптивность к специфическим признакам данных ОКТ. Применение оригинальной модели продемонстрировало превосходство по всем основным метрикам, а именно – точность классификации составила 0.98, полнота для классов CNV, DME, DRUSEN и NORMAL достигла значений 0.98, 0.96, 0.96 и 0.97 соответственно, что подтверждает целесообразность разработки специализированных архитектур для решения узкоспециализированных задач.

Результаты исследования подтверждают, что разработанная модель имеет значительный потенциал для внедрения в медицинскую практику. Автоматизация процесса распознавания патологий глазного дна на основе ОКТ может значительно повысить качество медицинского обслуживания путем снижения времени диагностики, что в свою очередь способствует более раннему началу лечения и улучшению результатов терапии у пациентов. Внедрение таких технологий в клиническую практику будет способствовать улучшению качества жизни пациентов и оптимизации работы медицинских учреждений.

В ходе исследования была успешно разработана и протестирована модель нейронной сети для автоматического распознавания патологий глазного дна. Резуль-

таты показали высокую точность и надежность предложенной модели, что подтверждает ее потенциал для применения в медицинской практике. Дальнейшее развитие и внедрение данной технологии может существенно улучшить процесс диагностики и лечения заболеваний глазного дна, что является важным шагом в направлении повышения качества медицинской помощи.

Список литературы / References

Епифанов В. А., Темкин И. О., Кальгов И. В. Процедура автоматического безрадарного определения скорости мобильных объектов с использованием стационарной камеры. *Программные продукты и системы*, 2023, № 1 (36), с. 165–174. <https://doi.org/10.15827/0236-235X.141.165-174>

Epifanov V. A., Temkin I. O., Kalgov I. V. The procedure of automatic radar-less speed measurement of mobile objects using a stationary camera. *Software and systems*, 2023, no. 1 (36), pp. 165–174. (In Russ.) <https://doi.org/10.15827/0236-235X.141.165-174>

Епифанов В. А., Темкин И. О., Кроснояружский С. Е. Эффективный алгоритм идентификации транспортных средств в системах видеонаблюдения. *Горный информационный аналитический бюллетень*, 2023, № 6, с. 5–18. https://doi.org/10.25018/0236_1493_2023_6_0_5; EDN: QEZDOP

Epifanov V. A., Temkin I. O., Krosnoyaruzhsky S. E. Efficient algorithm of transport identification in video surveillance systems. *Mining informational and analytical bulletin*, 2023, no. 6, pp. 5–18. (In Russ.) https://doi.org/10.25018/0236_1493_2023_6_0_5; EDN: QEZDOP

De Boer J. F., Leitgeb R., Wojtkowski M. Twenty-five years of optical coherence tomography: the paradigm shift in sensitivity and speed provided by Fourier-domain OCT. *Biomedical Optics Express*, 2017, vol. 8, no. 7, pp. 3248–3280. <https://doi.org/10.1364/BOE.8.003248>

Diao S., Su J., Yang C., Zhu W., Xiang D., Chen X., Peng Q., Shi F. Classification and segmentation of OCT images for age-related macular degeneration based on dual guidance networks. *Biomedical Signal Processing and Control*, 2023, vol. 84, no. 9, pp. 1–11. <https://doi.org/10.1016/j.bspc.2023.104810>

Esteva A., Kuprel B., Novoa R. A., Ko J., Swetter J. M., Bloue H. M., Trun S. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 2017, vol. 542, pp. 115–118. <https://doi.org/10.1038/nature21056>

Huang D., Swanson E. A., Lin C. P., Schuman J. S., William G. Stinson W. G., Chang W., Hee M. R., Flotte T., Gregory K., Puliafito C. A., Fujimoto J. G. Optical coherence tomography. *Science*, 1991, vol. 254, pp. 1178–1181. <https://doi.org/10.1126/science.1957169>

Wang X., Peng Y., Lu L., Lu Z., Bagheri M., Summers R. M. ChestX-ray8: Hospital-scale chest X-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. *IEEE Transactions on Medical Imaging*, 2017, vol. 36, no. 7, pp. 1945–1956. <https://doi.org/10.1109/TMI.2017.2699723>

Сведения об авторах

Игорь Олегович Темкин – доктор технических наук, профессор; <https://orcid.org/0000-0001-8150-6529>, asu@misis.ru, Национальный исследовательский технологический университет «МИСИС» (д. 4, пр-т Ленинский, 119049 Москва, Россия); **Igor O. Temkin** – Doctor of Technical Sciences, Professor, <https://orcid.org/0000-0001-8150-6529>, asu@misis.ru, The National University of Science and Technology “MISIS” (4, pr. Leninskii, 119049 Moscow, Russia).

Владимир Владимирович Горин – <https://orcid.org/0009-0001-3064-2149>, okwstn@gmail.com, Национальный исследовательский технологический университет «МИСИС» (д. 4, пр-т Ленинский, 119049 Москва, Россия); **Vladimir V. Gorin** – <https://orcid.org/0009-0001-3064-2149>, okwstn@gmail.com, The National University of Science and Technology “MISIS” (4, pr. Leninskii, 119049 Moscow, Russia).

Заявленный вклад авторов: авторы сделали разный вклад в подготовку публикации, что отражено в последовательности персоналий авторского коллектива. Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: the authors made different contributions to the preparation of the publication, which is reflected in the sequence of personalities of the author's team. The authors declare no conflicts of interests.

Статья поступила в редакцию 08.07.2024; одобрена после рецензирования 14.10.2024; принята к публикации 28.10.2024.

The article was submitted 08.07.2024; Approved after reviewing 14.10.2024; Accepted for publication 28.10.2024.