

**МЕТОДИКА ИССЛЕДОВАНИЙ
METHODS OF INVESTIGATIONS**

Научная статья

УДК 597.087.1:004.8**DOI: 10.26428/1606-9919-2025-205-518-534****EDN: JCTWNA****АВТОМАТИЗАЦИЯ БЕСПИЛОТНОГО УЧЕТА ПРОИЗВОДИТЕЛЕЙ
КЕТЫ И КИЖУЧА МЕТОДАМИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА****В.В. Свиридов, А.Ю. Поваров, Д.В. Коцюк***Хабаровский филиал ВНИРО (ХабаровскНИРО),
680038, г. Хабаровск, Амурский бульвар, 13а

Аннотация. Опубликованные методики беспилотного учета тихоокеанских лососей позволяют получать силами специалистов дальневосточных филиалов ВНИРО качественные фотоматериалы, однако их обработка в целях подсчета на них производителей весьма трудоемка, а практика применения методов искусственного интеллекта, в частности моделей глубокого обучения (иначе — искусственных нейронных сетей), отсутствует. Публикации по автоматизации беспилотного учета тихоокеанских лососей посредством нейросетей посвящены лишь снелке кеты и носят предварительный характер. Нами создана модель глубокого обучения, способная эффективно проводить автоматическое видоспецифичное выявление производителей кеты и кижуча, а также снелки кеты в многовидовых скоплениях на материалах беспилотного учета. Нейросеть базируется на обширных обучающих материалах, работает на изображениях одновременно с несколькими классами объектов по их выявлению. Приведено подробное воспроизводимое техническое описание подготовки, проверки качества и эксплуатации модели глубокого обучения по тихоокеанским лососям на базе настольной ГИС. Описаны различные факторы, влияющие на качество работы нейросети, даны рекомендации по его повышению. Обосновано, почему показатели качества модели следует рассматривать лишь в контексте визуальных характеристик целевых объектов на обрабатываемых фотоматериалах, которые могут значительно варьировать. Предложены способы повышения качества результатов работы нейросети посредством задействования функционала геоинформационного программного обеспечения. Приведены рекомендации по оптимизации создания модели с помощью инструментария фотограмметрического и геоинформационного программного обеспечения. Предложена схема пересчета выдачи нейросети по обработанным фотоматериалам для получения скорректированной оценки тотального количества объектов на отснятой акватории.

Ключевые слова: тихоокеанские лососи, БПЛА, автоматизация, искусственный интеллект, глубокое обучение, нейросеть, ГИС

* Свиридов Владимир Владимирович, кандидат биологических наук, ведущий научный сотрудник, sviridov@khabarovsk.vniro.ru, ORCID 0000-0002-6060-1532; Поваров Андрей Юрьевич, заведующий сектором, povarov@khabarovsk.vniro.ru, ORCID 0009-0000-7664-7458; Коцюк Денис Владимирович, кандидат биологических наук, руководитель филиала, kotsyuk@khabarovsk.vniro.ru, ORCID 0000-0002-7123-1792.

Для цитирования: Свиридов В.В., Поваров А.Ю., Коцюк Д.В. Автоматизация беспилотного учета производителей кеты и кижуча методами искусственного интеллекта // Изв. ТИНРО. — 2025. — Т. 205, вып. 3. — С. 518–534. DOI: 10.26428/1606-9919-2025-205-518-534. EDN: JCTWNA.

Original article

Automation of unmanned counting for spawners of chum and coho salmon with methods of artificial intelligence

Vladimir V. Sviridov*, Andrey Yu. Povarov**, Denis V. Kotsyuk***

*—*** Khabarovsk branch of VNIRO (KhabarovskNIRO),

13a, Amursky Blvd, Khabarovsk, 680038, Russia

* Ph.D., leading researcher, sviridov@khabarovsk.vniro.ru, ORCID 0000-0002-6060-1532

** head of sector, povarov@khabarovsk.vniro.ru, ORCID 0009-0000-7664-7458

*** Ph.D., director, kotsyuk@khabarovsk.vniro.ru, ORCID 0000-0002-7123-1792

Abstract. Published methods of unmanned counting of pacific salmon allow to obtain high-quality photographic materials, but their processing is a rather hard labor. Practice of using the artificial intelligence methods, in particular deep learning models (otherwise — artificial neural networks), for this purpose is still insufficient, preliminary and concerns the counts of post-spawn chum salmon only. In this study, a deep learning model was created capable for effective automatic species-specific detection of chum and coho salmon spawners and post-spawn chum salmon in multi-species aggregations using enumerated data of unmanned surveys. This neural network is based on wide training materials and is able to process simultaneously images with several classes of objects and identify all of them. Detailed and reproducible technical description of the preparation, quality control, and operation with the deep learning model for pacific salmon is presented for a desktop GIS environment. Various factors affecting quality of the neural network are described, and recommendations for improving its work are given. Quality indicators of the model should be considered in the context of visual characteristics of target objects in processed photographic materials, which can vary significantly. Quality of the neural network output can be improved by using functionality of geoinformation software. Recommendations are given for optimizing the model development using the tools of photogrammetric and geoinformation software. Scheme for recalculating the neural network output based on processed photographic materials is proposed to obtain a corrected estimate of the total number of objects in the surveyed water area.

Keywords: pacific salmon, UAV, automation, artificial intelligence, deep learning, neural network, GIS

For citation: Sviridov V.V., Povarov A.Yu., Kotsyuk D.V. Automation of unmanned counting for spawners of chum and coho salmon with methods of artificial intelligence, *Izv. Tikhookean. Nauchno-Issled. Inst. Rybn. Khoz. Okeanogr.*, 2025, vol. 205, no. 3, pp. 518–534. (In Russ.). DOI: 10.26428/1606-9919-2025-205-518-534. EDN: JCTWNA.

Введение

Методы искусственного интеллекта (ИИ), в частности модели глубокого обучения, или, иначе, искусственные нейронные сети (ИНС), плотно вошли в практику автоматизации учета объектов животного мира по материалам беспилотной фотосъемки [Attard et al., 2024]. На перспективность применения искусственных нейросетей для автоматизации беспилотного учета указывалось как в отношении водных биологических ресурсов (ВБР) в целом, так и по тихоокеанским лососям в частности [Dujon et al., 2021; Свиридов и др., 2022a; Rodofili et al., 2022; Свиридов, Поваров, 2024]. Опубликованные методики беспилотного учета тихоокеанских лососей позволяют получать силами специалистов дальневосточных филиалов ВНИРО качественные фотоматериалы, однако их обработка в целях подсчета производителей весьма трудоемка, а практика применения моделей глубокого обучения в целях автоматизации отсутствует [Свиридов и др., 2022a, б].

Среди работ по автоматизации подсчета ВБР посредством нейросетей на материалах беспилотной, пилотируемой и спутниковой фотосъемки доминируют публикации по морским млекопитающим [Borowicz et al., 2019; Gray et al., 2019; Guirado et

al., 2019; Методические рекомендации..., 2021; Dujon et al., 2021; Infantes et al., 2022; Rodofili et al., 2022; Boulent et al., 2023]. Есть успешные попытки применения ИНС на крупных хрящевых рыбах [Gorkin et al., 2020; Butcher et al., 2021; Desgarnier et al., 2022]. Принципиальная возможность использования нейросетей для автоматизации обработки материалов беспилотного учета для костистых рыб впервые была показана на примере отнерестившихся особей кеты [Свиридов, Поваров, 2024]. Однако данная работа носила предварительный характер, была проведена на сравнительно малом объеме обучающих данных и лишь для снулых экземпляров (сненки). Для учета заходов тихоокеанских лососей в нерестовые реки по очевидным причинам значим подсчет не столько сненки, сколько живых производителей. Аналогично другим видам ВБР для работ по тихоокеанским лососям актуальна возможность видоспецифичного учета в многовидовых скоплениях [Rodofili et al., 2022].

Производители тихоокеанских лососей в ходе нерестовой миграции в водотоках претерпевают значительные брачные изменения: ввиду подвижности они более визуально изменчивы в сравнении со сненкой. Это неизбежно приводит к повышенной сложности распознавания их на материалах беспилотной фотосъемки: чем визуально разнообразнее объекты учета, тем труднее создать нейросеть, способную эффективно выявлять их на фотоматериалах. Дополнительные сложности для выявления тихоокеанских лососей на снимках создают их сравнительно малые размеры и особенности водного окружения, что делает их намного более сложным объектом для автоматического подсчета в сравнении с морскими млекопитающими, крупными наземными видами животных и тем более объектами антропогенной инфраструктуры [Свиридов и др., 2022а; Свиридов, Поваров, 2024; Attard et al., 2024].

Целью настоящей работы было создание модели глубокого обучения, способной эффективно проводить автоматическое выявление производителей и сненки тихоокеанских лососей (кеты и кижуча) в многовидовых скоплениях на материалах беспилотного учета в зависимости от видовой принадлежности. Учитывая новизну разрабатываемого вопроса и потенциальный интерес других исследователей к воспроизведению разработанных подходов на собственных материалах, дополнительной целью ставили подробное описание полученной нейросети и ее применения.

Материалы и методы

Беспилотный учет тихоокеанских лососей в реках Хабаровского края в 2020–2024 гг. проводили на основе методических подходов собственной разработки [Свиридов и др., 2022а, б]. Объем, сроки и места сбора материалов беспилотной аэрофотосъемки, использованных при создании и тестировании модели глубокого обучения, приведены в табл. 1. Если для этапа создания нейросети применялись фотоматериалы лишь по рекам Охотского района Хабаровского края, то для тестирования — дополнительно по притокам р. Амур. Трекканальные 8-битные снимки, полученные потребительскими БПЛА модельных рядов Mavic и Phantom производства компании DJI, подвергали фотограмметрической обработке в ПО Agisoft Metashape Professional 2.2. Векторизацию полученных фотограмметрических продуктов в целях подготовки обучающих данных для создания нейросети, а также все дальнейшие работы по созданию и тестированию модели глубокого обучения проводили в настольной геоинформационной системе (ГИС) ArcGIS Pro 3.1 с установленными библиотеками сред глубокого обучения и расширением Image Analyst. В целях ускорения работ использовали специализированный сервер для разработки нейросетей, оснащенный промышленными видеокартами NVIDIA A100 с выделенной памятью 80 Гб.

Для качественного учета объектов методами ИИ они должны быть четко различимы на материалах аэрофотосъемки, иметь относительно стабильные визуальные характеристики [Свиридов и др., 2022а]. Если оператор не может выявить объекты учета на снимке, то нейросеть тоже не сможет сделать этого, так как ее работа основана

Таблица 1

Объем, сроки и места сбора материалов беспилотной аэрофотосъемки, использованных при создании и тестировании модели глубокого обучения

Table 1

Volume, timing, and locations of drone aerial photography datasets used for creation and testing the deep learning model

Вид работ	Река–контрольный участок	Дата	Количество векторизованных рыб, экз.		
			Производители кеты	Сненка кеты	Производители кижуча
Создание модели	Кухтуй–Бакирка	11.09.2021	3303	158	7
	Кухтуй–Бакирка	04.10.2022	4	34	
	Кухтуй–Бакирка	28.09.2023	1786	129	
	Охота–Аганджа	24.09.2022	72	352	29
	Охота–Алонка	13.09.2021	12	1	
	Охота–Безымянный	02.10.2022	151	1036	
	Охота–Ключи	05.09.2023	57		
	Охота–Ключи	25.09.2023	162	90	174
	Охота–Комендантский	30.09.2022	93	386	404
	Охота–Комендантский	25.09.2023	81	439	13
	Охота–Кочумазная	30.09.2022	99	189	233
	Охота–Мельчиканка	26.09.2022		4	
	Охота–Третий Гайдык	12.09.2021	90	7	
	Урак–Луктур	28.08.2023	23	1	
	Урак–Тырай	22.08.2021	12	7	
	Всего		5945	2833	860
Тестирование модели	<i>Охотский район</i>				
	Охота–Сухой ключ	24.09.2022	101	124	251
	Охота–Третий Гайдык	30.09.2024	73	49	
	Охота–Третий Гайдык	24.09.2022	141	69	
	Охота–Чумка	01.10.2023	198	204	470
	Всего		513	446	721
	<i>Бассейн р. Амур</i>				
	Амгунь–Дуки	19.10.2021	33	119	
	Ануй–Аджу	28.10.2020	81	119	
	Хор–Теплая	31.10.2022	45	30	
	Хор–Теплая	29.10.2023		37	
	Всего		159	305	

на тренировке по обучающим данным, размеченным (векторизованным в настольной ГИС) оператором. Соответственно, для создания ИНС была проделана работа по отбору подходящих фотоматериалов. Стремались, чтобы на них были представлены все стадии брачных изменений лососей и разнообразные окружающие условия, а качество фотосъемки позволяло оператору уверенно опознавать объекты учета, не имело артефактов или брака. Не использовали фотоматериалы, характеризующиеся низким качеством (мутность, турбулентность, ветровая рябь, избыточный смаз, некорректная экспозиция, визуальные артефакты и т.д.).

Методы создания нейросети и оценки ее качества в настоящей работе выполнены по схеме, реализованной и подробно описанной ранее при разработке модели глубокого обучения по сненке кеты [Свиридов, Поваров, 2024]. Во избежание повторов описание данных методов в настоящей работе опущено, за исключением некоторых улучшающих нововведений, изложенных далее. Количество классов (категорий выявляемых объектов) разрабатываемой нейросети было расширено с одного до трех: помимо сненки кеты нейросеть обучали по производителям кеты и кижуча. По сненке кижуча работу не проводили

ввиду недостаточности объемов отснятых по ней материалов (данный вид в районе работ нерестится преимущественно позже, и количества его сненки на фотоматериалах было недостаточно для создания качественных обучающих библиотек для тренировки нейросети).

В целях повышения качества модели для класса сненки кеты количество обучающих меток (размеченных образцов изображений для тренировки модели) было существенно увеличено по сравнению с таковым в ранее проведенной работе (табл. 1; [Свиридов, Поваров, 2024]). Стремление расширить количество обучающих меток по сненке кеты оправдано, учитывая, что создание качественной нейросети по визуальным изменчивым ВБР обычно требует их не менее нескольких тысяч [Gorkin et al., 2020]. Количество обучающих меток по производителям кеты было максимальным среди трех классов, это связано как с обилием материалов по данному классу, так и с его более высоким визуальным разнообразием, что выдвигает повышенные требования к объему обучающих данных. Объем обучающих данных по кижучу был вынужденно минимален среди трех классов по причине ограниченности сборов по данному виду.

Процедуры фотограмметрической обработки отобранных фотоматериалов повторяли таковые в ранее опубликованной методике по сненке кеты [Свиридов, Поваров, 2024]. Однако конечным фотограмметрическим продуктом, используемым для векторизации обучающих меток в настольной ГИС, были не ортофотопланы, а ортофотоснимки (исходные снимки, подвергнутые ортотрансформации). Для подвижных объектов ортофотоснимки дают возможность многократного увеличения объемов обучающих данных, так как для тренировки модели можно использовать все исходные снимки, подвергнутые ортотрансформации, а не их фотомозаику (ортофотоплан), на которой ввиду сшивки отображается лишь небольшая часть изначальной фотографии. Такой подход был расценен как допустимый из-за естественной подвижности производителей, приводящей к визуальным различиям их внешнего вида на перекрывающихся снимках, снятых с пространственным пересечением (рис. 1). Отчасти он приемлем и по сненке, поскольку при фотографировании в существенно различающихся ракурсах ее внешний вид значительно различается на разных ортофотоснимках. Предложенный способ увеличения объема обучающих выборок — важный элемент оптимизации разработки нейросети, так как увеличение количества обучающих меток, являющееся важным



Рис. 1. Изменчивость внешнего вида производителей кеты в одном месте на перекрывающихся ортофотоснимках (а, б — интервал между снимками 2 с) участка Бакирка, р. Кухтуй, 11.09.2021. Желтым цветом показан векторизованный в настольной ГИС контур объекта (обучающая метка полигональной геометрии в векторном формате)

Fig. 1. Variability in appearance of chum salmon spawners in one location on overlapping orthophotographs (а, б — the images with 2 second interval) in the Bakirka site on Kukhtuy River on September 11, 2021. Yellow line indicates the object contour vectorized in the desktop GIS (training label of polygonal geometry in vector format)

элементом повышения качества модели, может быть затруднено при малых сборах. Очевидно, что созданные таким образом обучающие данные уступают в качестве тем, что создавались бы по принципу «один экземпляр — одна обучающая метка». Однако на начальном этапе, в условиях ограниченности объема качественных фотоматериалов, такой прием представляется приемлемым.

Из других различий с ранее реализованным подходом [Свиридов, Поваров, 2024] следует упомянуть увеличенное количество тренировочных эпох при обучении нейросети (100 вместо 20) в целях повышения качества ИНС. Также для тестирования полученной модели по каждому классу использовали не один ортофотоплан, а несколько, чтобы лучше оценить изменчивость качества работы нейросети (табл. 1).

Для оценки качества полученной нейросети использовали два главных показателя — точность и полноту [Свиридов, Поваров, 2024]. Точность рассчитывали как отношение числа истинноположительных (корректно выявленных) прогнозов модели к числу всех положительных прогнозов модели (т.е. сумме истинноположительных и ложноположительных — ошибочно выявленных). За полноту принимали отношение количества истинноположительных прогнозов модели к реальному числу объектов данного класса на ортофотоплане. Реальное число объектов равно сумме истинноположительных и ложноотрицательных (ошибочно пропущенных) прогнозов модели. При интерпретации результатов модели по отдельному классу ложноотрицательными считали не только пропуски объектов соответствующего класса, но и их отнесение к неверному классу. Достаточная точность модели важна для минимизации затрат времени на ручную выбраковку оператором ложноположительных срабатываний при корректировке выдачи нейросети. Высокий охват особенно важен при учете видов, характеризующихся низкой встречаемостью на учетных материалах [Boulent et al., 2023].

Результаты и их обсуждение

Показатели созданной нейросети

Нейросеть, созданная посредством инструмента геообработки «Тренировать модель глубокого обучения», характеризовалась достаточно высокими показателями точности для всех трех классов: производители кеты — 0,95, сненка кеты — 0,98, производители кижуча — 0,96. Данные показатели точности рассчитаны по валидационной выборке — части векторизованных обучающих меток, не использованных для тренировки модели, но зарезервированных для оценки ее качества по ходу обучения. Визуальное сравнение векторизованных оператором полигональных контуров из валидационной выборки с полигонами, сгенерированными нейросетью, показало сходство их геометрии, что положительно характеризует полученную модель (рис. 2).

Тестирование качества созданной нейросети на ортофотопланах посредством инструмента геообработки «Выявить объекты при помощи глубокого обучения» показало, что она способна обнаруживать сразу нескольких классов объектов, т.е. обрабатывать фотоматериалы, содержащие многовидовые скопления производителей тихоокеанских лососей и сненку. Разработанная нейросеть оказалась эффективна и в случаях присутствия на фотоматериалах сложного фона (тени от производителей, опад и т.д.) при условии хорошего качества снимков (рис. 3).

На рис. 4 приведены разные виды прогнозов нейросети по производителям кеты на участке на р. Охота для иллюстрации того, как конкретный вариант соотношения между ними привел к результирующим значениям точности и полноты, определяющим качество модели. Так, значение точности работы модели по этим фотоматериалам согласно проведенному тестированию составило 0,93. То есть 93 % экземпляров производителей кеты, выявленных моделью, были истинноположительными (139 экз. — истинноположительных прогнозов и 11 экз. — ложноположительных). Полнота модели составила 0,70: нейросеть выявила 70 % от реального количества производителей кеты



Рис. 2. Примеры пар валидационной выборки с полупрозрачными полигонами целевых классов, оцифрованными оператором (**верхний ряд**) и спрогнозированными созданной моделью (**нижний ряд**)

Fig. 2. Examples of validation sample pairs with semi-transparent polygons of target classes digitized by operator (**top row**) and predicted by the created model (**bottom row**)



Рис. 3. Пример одновременного выявления нейросетью нескольких классов объектов, присутствующих на фрагменте ортофотоплана участка Сухой ключ, р. Охота, 24.09.2022. Пунктирные красные линии — истинноположительные прогнозы модели по производителям кеты, черные — по снетке кеты, синие — производителям кижуча

Fig. 3. An example of simultaneous detection by the neural network of several classes of objects presented on a fragment of the orthophoto of the Sukhoi Klyuch site on Okhota River on September 24, 2022. True positive predictions of the model for chum salmon spawners are shown by *dotted red contours*, for post-spawn chum salmon — by *black contours*, and for coho salmon spawners — by *blue contours*

на анализируемом участке (139 экз. в выдаче были истинноположительными, 59 — ложноотрицательными).




Рис. 4. Результаты ручной векторизации производителей кеты оператором и автоматического выявления моделью для участка Чумка, р. Охота, 01.10.2023. Отдельные экземпляры обозначены синими кружками; **а** — фактическая ситуация (ручная векторизация оператором, 198 экз.); **б** — истинноположительные прогнозы (139 экз.); **в** — ложноположительные (11 экз.); **г** — ложноотрицательные (59 экз.) и границы увеличенного фрагмента (красный прямоугольник); **д** — увеличенный фрагмент (желтые контуры — истинноположительные прогнозы, розовые — ложноположительные, красные кружки — ложноотрицательные, в правом нижнем углу — три экземпляра кижуча вне выдачи модели)

Fig. 4. Results of manual vectorization for chum salmon spawners by operator and their automatic detection by the model for the Chumka site on Okhota River on October 1, 2023. Individuals are marked with blue circles: **a** — real situation (manual vectorization by operator, 198 ind.); **b** — true positive predictions (139 ind.); **v** — false positive predictions (11 ind.); **г** — false negative predictions (59 inds.) and the boundaries of enlarged fragment (red rectangle); **д** — enlarged fragment (yellow contours — true positive predictions, pink contours — false positive predictions, red circles — false negative predictions, three individuals of coho salmon in the lower right corner are not presented in the model output)

Значения точности и полноты разработанной нейросети, рассчитанные по результатам тестирования на нескольких ортофотопланах для каждого из трех целевых классов, приведены в табл. 2. В ней для трех обследованных классов указано не только среднее значение точности и полноты, но и их размах, чтобы оценить изменчивость качества работы нейросети.

Таблица 2

Показатели качества разработанной нейросети

Table 2

Quality parameters of the developed neural network

Регион	Река–контрольный участок	Дата	Показатели качества					
			Точность			Полнота		
			М	Min	Max	М	Min	Max
Производители кеты								
Охотский район	Охота–Сухой ключ	24.09.2022	0,87			0,53		
	Охота–Третий Гайдык	30.09.2024	0,95			0,58		
	Охота–Третий Гайдык	24.09.2022	0,93			0,38		
	Охота–Чумка	01.10.2023	0,93			0,70		
	Для региона		0,92	0,87	0,95	0,55	0,38	0,70
Бассейн р. Амур	Ануй–Аджу	28.10.2020	0,80			0,30		
	Амгунь–Дуки	19.10.2021	0,63			0,45		
	Хор–Теплая	31.10.2022	0,65			0,38		
	Для региона		0,69	0,63	0,80	0,38	0,30	0,45
Для класса			0,82	0,63	0,95	0,47	0,30	0,70
Сценка кеты								
Охотский район	Охота–Сухой ключ	24.09.2022	0,25			0,58		
	Охота–Третий Гайдык	30.09.2024	0,68			0,80		
	Охота–Третий Гайдык	24.09.2022	0,67			0,72		
	Охота–Чумка	01.10.2023	0,67			0,46		
	Для региона		0,57	0,25	0,68	0,64	0,46	0,80
Бассейн р. Амур	Ануй–Аджу	28.10.2020	0,72			0,69		
	Амгунь–Дуки	19.10.2021	0,70			0,90		
	Хор–Теплая	31.10.2022	0,31			0,83		
	Хор–Теплая	29.10.2023	0,31			0,86		
	Для региона		0,51	0,31	0,72	0,82	0,69	0,90
Для класса			0,54	0,25	0,72	0,73	0,46	0,90
Производители кижуча								
Охотский район	Охота–Сухой ключ	24.09.2022	0,94			0,30		
	Охота–Чумка	01.10.2023	0,97			0,26		
	Для региона и класса		0,96	0,94	0,97	0,28	0,26	0,30

Качество работы нейросети, оцениваемое по показателям точности и полноты, варьировало в широком диапазоне и зависело от качества визуализации объектов учета на ортофотопланах, использованных для тестирования. Следует различать точность модели, оцененную по результатам тестирования на ортофотопланах, приведенную в табл. 2, и точность, рассчитанную по набору валидационных данных, указанную ранее. Показатели точности по набору валидационных данных являются предварительными и завышенными, так как основаны на случайной выборке из разметки, векторизованной для обучения модели. Отчасти это обусловлено тем, что для повышения качества разрабатываемой нейросети для ее обучения использовались наиболее качественные фотоматериалы из имеющихся, что является стандартной практикой. При тестировании модели качество обрабатываемых ортофотопланов в целом было ниже, что и привело к меньшим показателям точности нейросети для этапа тестирования.

Сопоставление показателей качества нейросети между тремя классами показывает, что наибольшая точность модели характерна при работе по производителям кижуча (0,96), а наименьшая — по сненке кеты (0,54, табл. 2). Это объяснимо наибольшей разнородностью визуального ряда сненки кеты в сравнении с двумя другими классами ввиду существенного изменения ее внешнего вида в процессе распада. Производители кижуча характеризуются более компактным и выраженным визуальным рядом, что минимизирует ложноположительные срабатывания по данному классу и приводит к увеличению точности. Однако для производителей кижуча отмечено наименьшее значение полноты модели (0,28) среди всех трех классов, что, по-видимому, объяснимо многократно меньшим объемом обучающих данных по нему.

Большее значение полноты модели по сненке кеты (0,73) в сравнении с производителями данного вида (0,47, табл. 2) может быть обусловлено следующими причинами. Зачастую сненка, в отличие от живых производителей, ориентирована боком вверх, что приводит к существенному увеличению площади ее контура на фотоснимке, сделанном в надир. Проистекающая из этого представленность сненки повышенным количеством пикселей может приводить к улучшенным показателям полноты модели. Очевидно, что качество работы нейросети по определенному объекту напрямую связано с количеством пикселей, которыми он показан на обучающих и рабочих фотоматериалах. Ориентированность сненки вверх светлым боком или брюхом, а не темной спиной, как у живых производителей, также приводит к улучшенной визуализации на снимках в условиях сильного поглощения света водой. Немаловажно и то, что сненка в большинстве случаев неподвижна, что дает ее меньший фотографический смаз на снимках в сравнении с подвижными производителями.

Усредненные по классу значения точности и полноты для разработанной модели колебались в интервале соответственно 0,54–0,96 и 0,28–0,73 (табл. 2). В целом они сопоставимы с усредненными показателями качества нейросетей, опубликованными для различных ВБР. Так, для ластоногих приводятся как сравнительно низкие показатели точности и полноты (0,27 и 0,79 по капскому морскому котика [Dujon et al., 2021]), так и высокие (0,94 и 0,97 по обыкновенному тюленю [Infantes et al., 2022]). Сравнительно высокие значения точности и полноты представлены по скатам без разделения по видам — 0,90 и 0,92 [Desgarnier et al., 2022]. Для головастой морской черепахи опубликованы существенно меньшие значения — 0,20 и 0,75 [Dujon et al., 2021]. Для голотурий без разделения по видам данные показатели качества модели довольно высоки — 0,82 и 0,83 [Li et al., 2021]. Столь существенный разброс показателей качества нейросетей, разработанных для разных видов ВБР, очевидно, связан с различиями в качестве отснятых материалов, условиях съемки, размерных и визуальных характеристиках учетных объектов.

Изменчивость качества работы модели можно оценить визуально, сопоставляя результаты обработки ею ортофотопланов и реальную ситуацию на них, анализируя причины и частоту типичных ложных срабатываний. На рис. 5 приведены примеры типичной работы нейросети по каждому из целевых классов.

О межрегиональной преемственности созданной модели, обученной на фотоматериалах из рек Охотского района, свидетельствует сопоставимость показателей ее качества (точности и полноты) между водотоками Охотского района и бассейна р. Амур (табл. 2). Данный факт имеет практическое значение: он демонстрирует возможность применения созданной нейросети для районов, фотоматериалы из которых не применялись для ее обучения.

Другим важным показателем качества разработанной нейросети является сходство между генерируемым моделью полигональным контуром и реальной геометрией целевого объекта. Как видно на рис. 2, 3, 4 и 5, разработанная нейросеть для всех целевых классов генерирует контуры, преимущественно близкие к реальной геометрии. Очевидно, что качество оконтуривания целевых объектов, как и эффективность




Рис. 5. Примеры типичной работы нейросети по каждому из целевых классов на фрагменте ортофотоплана: производители кеты, участок Дуки, р. Амгунь, 19.10.2021 (а); сценка кеты, участок Теплая, р. Хор, 29.10.2023 (б); производители кижуча, участок Чумка, р. Охота, 01.10.2023 (в). Желтые контуры — истинноположительные прогнозы, розовые — ложноположительные, красные кружки — ложноотрицательные. Для визуального упрощения рисунка по конкретному классу выдача модели приведена лишь для него

Fig. 5. Examples of typical neural network performance for each of the target classes on an orthophoto fragment: chum salmon producers, Duki site on Amgun River on October 19, 2021 (а); post-spawn chum salmon, Teplaya site on Khor River on October 29, 2023 (б); coho salmon producers, Chumka site on Okhota River on October 1, 2023 (в). Yellow contours are true positive predictions, pink contours are false positive predictions, red circles are false negative predictions. To simplify visually this figure for a specific class, the model output is given only for it

их выявления на снимках, зависят от визуальных характеристик отснятых фотоматериалов, от того, насколько четко на них видны объекты учета. Точность контуров, генерируемых нейросетью, важна для автоматизации контроля качества результатов работы нейросети, например для выбраковки ложноположительных срабатываний. Такая выбраковка возможна благодаря функционалу настольной ГИС, позволяющему автоматически отфильтровывать ложноположительные срабатывания модели, характеризующиеся размерными и морфологическими характеристиками, не свойственными производителям (нереально малые или чрезмерные значения площади сгенерированного полигона и т.д.).

Причины изменчивости качества работы нейросети

Рассмотрим типичные ошибочные срабатывания созданной нейросети как проявление разнокачественности ее работы по различным эпизодам учета и проанализируем их возможные причины. Часть ложноположительных срабатываний нейросети обусловлена отнесением объекта к некорректному классу (например, принятие производителя кеты за сненку этого вида и наоборот). По очевидным причинам визуальная дифференциация сненки и живых производителей весьма затруднена в случае последних стадий брачных изменений. Соответственно, чем больше целевых классов присутствует на обрабатываемом нейросетью ортофотоплане, тем выше вероятность снижения качества работы модели по каждому классу. Поэтому для выявления объектов посредством глубокого обучения представляется целесообразным использовать нейросети, обученные лишь по классам объектов, присутствующим на целевых фотоматериалах.

Другой причиной ложноположительных срабатываний модели являются элементы фона, визуально сходные с тихоокеанскими лососями, в первую очередь древесная и водная растительность, опад. Отмеченные низкие показатели точности модели для сненки кеты (табл. 2) обусловлены в том числе ее внешним сходством с элементами опада, приводящим к увеличению частоты ложноположительных срабатываний (рис. 6, а). Очевидно, что качество работы нейросети будет выше в случае визуально несходного с лососями фона, без растительности, опада.

Ложноположительные срабатывания модели характерны по растительности и опадку не только в воде, но и на суше. В ранее проведенной работе по снелке кеты для минимизации подобных ошибочных срабатываний и повышения тем самым качества работы нейросети для инструмента геообработки «Выявить объекты при помощи глубокого обучения» использовали ограничивающий полигон, охватывающий целевую часть водотока с буфером в 2 м для частичного охвата берега [Свиридов, Поваров, 2024]. Аналогичный подход был использован и в настоящей работе, что позволило избежать большого числа ложноположительных срабатываний на наземной растительности и существенного снижения качества работы нейросети.

Основной причиной ложноотрицательных срабатываний является сниженное качество фотоматериалов, которое может быть обусловлено как устранимыми ошибками оператора БПЛА по настройке полетного задания и камеры, приводящими к ухудшению качества фотоматериалов (рис. 6, б), так и неустраняемыми неблагоприятными условиями аэрофотосъемки (мутность, ветровая рябь, избыточная глубина и т.д.). Дополнительной причиной ложноотрицательных срабатываний является визуальное блокирование объектов учета как элементами их окружения (растительность и т.д.), так и другими экземплярами (взаимное наложение в скоплениях). Плотные многоуровневые скопления производителей — наиболее сложный вариант для автоматического подсчета нейросетью, неизбежно требующий экспертной корректировки результатов работы модели (рис. 6, в).




Рис. 6. Изменчивость частоты ошибочных срабатываний модели в зависимости от особенностей обрабатываемых фотоматериалов. Желтые контуры — истинноположительные прогнозы, розовые — ложноположительные, красные кружки — ложноотрицательные. Верхний ряд — фоновое окружение и ложноположительные срабатывания по снимке кеты (a1 — однородное дно, a2 — дно с обильным опадом и растительностью); средний ряд — качество съемки и ложноотрицательные срабатывания по производителям кеты (b1 — качественная съемка, b2 — избыточный смаз); нижний ряд — блокирование объектов и ложноотрицательные срабатывания по производителям кижуча (в1 — без блокирования, в2 — блокирование другими производителями)

Fig. 6. Variability of the model's false positives predictions depending on characteristics of the processed photo materials. Yellow contours are true positive predictions, pink contours are false positive predictions, red circles are false negative predictions. Top row: background environment and false positive predictions for post-spawn chum salmon (a1 — uniform bottom, a2 — bottom with abundant litter and vegetation). Middle row: photographic quality and false negative predictions for chum salmon spawners (b1 — high-quality shooting, b2 — excessive blur). Bottom row: blocking of objects and false negative predictions for coho salmon spawners (в1 — no blocking, в2 — blocking by other spawners)

Эксплуатация и дальнейшая оптимизация нейросети

Чтобы добиться автоматизации беспилотного учета лососей посредством методов ИИ, нужно не только выполнить их автоматическое выявление с помощью нейросети на фотоматериалах, но и трансформировать эти сведения в оценку тотального количества объектов на отснятой акватории. Предлагаемая схема расчета общего количества объектов на всей площади, покрытой съемкой, включает ряд этапов, реализуемых посредством функционала настольной ГИС (рис. 7).




Рис. 7. Этапы расчета общего количества объектов учета на акватории, охваченной беспилотной аэрофотосъемкой

Fig. 7. Stages of calculating the total number of enumerated objects in the water area covered by unmanned aerial photography

Как видно на данной схеме (рис. 7), нецелесообразно подвергать ручной корректировке результаты работы нейросети по всей отснятой акватории, достаточно ограничиться пространственно-рандомной выборкой, получить по ней корректировочный коэффициент и посредством его уточнить результаты модели. Очевидно, что в пределах отснятой акватории соотношение между локальным истинным количеством учетных объектов и оценкой нейросети будет разниться ввиду неизбежной пространственной изменчивости качества визуализации объектов на фотоматериалах. Поэтому необходима ручная обработка набора участков для вычисления среднего корректировочного коэффициента в целях пересчета оценки нейросети на уточненное количество объектов. Следует понимать, что в ряде случаев попросту невозможно точно определить количество ложноотрицательных срабатываний модели (маскирование производителей мутностью, избыточной глубиной и блокирующей растительностью, многоуровневые плотные скопления и т.д.), что неизбежно скажется на точности получаемых оценок общего количества на отснятой акватории.

Дополним способы дальнейшей оптимизации нейросети, приведенные нами ранее [Свиридов, Поваров, 2024], новыми рекомендациями. В свете опыта, полученного в ходе векторизации 9638 полигональных меток для обучения нейросети по трем целевым классам (см. табл. 1), стало очевидным, что для создания обучающих библиотек крайне желательно использовать фотоматериалы с присутствием лишь одного вида. Это позволяет существенно снизить нагрузку на оператора настольной ГИС, проводящего векторизацию, повысить ее скорость, минимизировать риски присвоения некорректного класса оцифрованному объекту. Также как для облегчения и ускорения работ по векторизации обучающих данных, так и для повышения качества создаваемой нейросети важно по возможности использовать фотоматериалы с наиболее качественной визуализацией целевых объектов.

Заключение

Выполненная работа демонстрирует для костистых рыб возможность автоматического распознавания живых особей на материалах беспилотной съемки посредством методов ИИ. На обширных обучающих материалах создана нейросеть, способная распознавать на изображениях одновременно нескольких классов объектов, т.е. работать по многовидовым скоплениям, включающим как производителей тихоокеанских лососей, так и сненку. Представлено подробное воспроизводимое техническое описание создания, тестирования и эксплуатации модели глубокого обучения по тихоокеанским лососям на базе настольной ГИС. Изложены факторы, определяющие качество работы нейросети, а также рекомендации по его повышению. Показано, что точность и полноту модели можно рассматривать лишь в контексте качества обрабатываемых ею фотоматериалов, которое может значительно варьировать. Приведены способы оптимизации создания модели и повышения качества ее работы посредством функ-

ционала фотограмметрического и геоинформационного программного обеспечения. Предложена схема перехода от выдачи нейросети по обработанным фотоматериалам к скорректированной оценке тотального количества объектов на отснятой акватории.

Дальнейшая автоматизация беспилотного учета тихоокеанских лососей методами ИИ должна охватить другие виды тихоокеанских лососей, их нерестовые бугры, проводиться с учетом региональной специфики. Предложенный подход по созданию нейросетей на базе настольной ГИС, обладающей полнофункциональным инструментарием для разработки и эксплуатации моделей глубокого обучения, применим для решения аналогичных задач по другим видам рыб и ВБР.

Благодарности (ACKNOWLEDGEMENTS)

Авторы благодарят сотрудников Хабаровского филиала ВНИРО за участие в сборе материалов.

Authors are grateful to colleagues from Khabarovsk branch of VNIRO for their assistance in materials collection.

Финансирование работы (FUNDING)

Работа выполнена в рамках бюджетного финансирования.

The study was conducted on the basis of budget funding.

Соблюдение этических стандартов (COMPLIANCE WITH ETHICAL STANDARDS)

Все применимые национальные, институциональные и международные этические принципы соблюдены. Авторы заявляют, что у них нет конфликта интересов.

All applicable national, institutional and international ethical guidelines are implemented. Authors claim that they have no conflict of interests.

Информация о вкладе авторов (AUTHOR CONTRIBUTIONS)

В.В. Свиридов и А.Ю. Поваров — сбор и обработка данных, анализ результатов, написание статьи; Д.В. Коцюк — планирование работ, анализ результатов, написание статьи.

V.V. Sviridov and A.Yu. Povarov — data collection and processing, results analysis, text writing and illustrating; D.V. Kotsyuk — survey planning, results analysis, text writing.

Список литературы

Методические рекомендации по проведению учета приплода байкальской нерпы (*Pusa sibirica*) с беспилотных летательных аппаратов в Байкальском рыбохозяйственном бассейне / сост. В.А. Бизиков, В.А. Петерфельд, В.И. Черноок и др. — М. : ВНИРО, 2021. — 56 с.

Свиридов В.В., Коцюк Д.В., Подорожнюк Е.В. Беспилотный фотограмметрический учет тихоокеанских лососей посредством БПЛА потребительского класса // Изв. ТИНРО. — 2022а. — Т. 202, вып. 2. — С. 429–449. DOI: 10.26428/1606-9919-2022-202-429-449. EDN: CNQNAF.

Свиридов В.В., Подорожнюк Е.В., Никитин В.Д., Скорик А.В. Модификации беспилотного учета производителей тихоокеанских лососей в реках Сахалинской области и Хабаровского края // Изв. ТИНРО. — 2022б. — Т. 202, вып. 4. — С. 1015–1031. DOI: 10.26428/1606-9919-2022-202-1015-1031. EDN: JULFRV.

Свиридов В.В., Поваров А.Ю. Применение методов искусственного интеллекта для автоматизации беспилотного учета отнерестившихся особей кеты в Хабаровском крае // Вопр. рыб-ва. — 2024. — Т. 25, № 4. — С. 113–124. DOI: 10.36038/0234-2774-2024-25-4-113-124.

Attard M.R., Phillips R.A., Bowler E. et al. Review of Satellite Remote Sensing and Unoccupied Aircraft Systems for Counting Wildlife on Land // Remote Sensing. — 2024. — Vol. 16, № 4. — P. 1–23. DOI: 10.3390/rs16040627.

Borowicz A., Le H., Humphries G. et al. Aerial-trained deep learning networks for surveying cetaceans from satellite imagery // PLoS ONE. — 2019. — Vol. 14, № 10: e0212532. DOI: 10.1371/journal.pone.0212532.

- Boulent J., Charry B., Kennedy M. et al.** Scaling whale monitoring using deep learning: A human-in-the-loop solution for analyzing aerial datasets // *Frontiers in Marine Science*. — 2023. — Vol. 10. — P. 1–13. DOI: 10.3389/fmars.2023.1099479.
- Butcher P., Colefax A., Gorkin I. et al.** The drone revolution of shark science: A review // *Drones*. — 2021. — Vol. 5, № 1. — P. 1–8. DOI: 10.3390/drones5010008.
- Desgarnier L., Mouillot D., Vigliola L. et al.** Putting eagle rays on the map by coupling aerial video-surveys and deep learning // *Biological Conservation*. — 2022. — Vol. 267. — P. 109494. DOI: 10.1016/j.biocon.2022.109494.
- Dujon A., Ierodiaconou D., Geeson J. et al.** Machine learning to detect marine animals in UAV imagery: effect of morphology, spacing, behaviour and habitat // *Remote Sensing in Ecology and Conservation*. — 2021. — Vol. 7, № 3. — P. 341–354. DOI: 10.1002/rse2.205.
- Gorkin R., Adams K., Berryman M.J. et al.** Sharkeye: Real-Time Autonomous Personal Shark Alerting via Aerial Surveillance // *Drones*. — 2020. — Vol. 4, № 2. — P. 1–18. DOI: 10.3390/drones4020018.
- Gray P., Bierlich K., Mantell S. et al.** Drones and convolutional neural networks facilitate automated and accurate cetacean species identification and photogrammetry // *Methods in Ecology and Evolution*. — 2019. — Vol. 10, № 9. — P. 1490–1500. DOI: 10.1111/2041-210X.13246.
- Guirado E., Tabik S., Rivas M. et al.** Whale counting in satellite and aerial images with deep learning // *Scientific reports*. — 2019. — Vol. 9, № 1. — P. 14259. DOI: 10.1038/s41598-019-50795-9.
- Infantes E., Carroll D., Silva W. et al.** An automated work-flow for pinniped surveys: a new tool for monitoring population dynamics // *Frontiers in Ecology and Evolution*. — 2022. — Vol. 10. — P. 1–17. DOI: 10.3389/fevo.2022.905309.
- Li J.Y., Duce S., Joyce K.E. et al.** SeeCucumbers: Using Deep Learning and Drone Imagery to Detect Sea Cucumbers on Coral Reef Flats // *Drones*. — 2021. — Vol. 5, № 2. — P. 1–28. DOI: 10.3390/drones5020028.
- Rodofili E., Lecours V., LaRue M.** Remote sensing techniques for automated marine mammals detection: review of methods and current challenges // *Peer J*. — 2022. — Vol. 10. — P. 1–22. DOI: 10.7717/peerj.13540.

References

- Bizikov, V.A., Peterfeld, V.A., Chernook, V.I., Kuznetsov, N.V., Petrov, E.A., Bobkov, A.I., Tkachev, V.V., Sidorov, L.K., and Boltnev, E.A.,** *Metodicheskiye rekomendatsii po provedeniyu ucheta priploda baykal'skoy nerpy (Pusa sibirica) s bespilotnykh letatel'nykh apparatov v Baykal'skom rybokhozyaystvennom bassejne* (Methodological recommendations for the accounting of the offspring of the Baikal seal (*Pusa sibirica*) from unmanned aerial vehicles in the Baikal fishery basin), Moscow: VNIRO, 2021.
- Sviridov, V.V., Kotsyuk, D.V., and Podorozhnyuk, E.V.,** Photogrammetric counts of pacific salmon by means of unmanned aerial vehicles of consumer grade, *Izv. Tikhookean. Nauchno-Issled. Inst. Rybn. Khoz. Okeanogr.*, 2022, vol. 202, no. 2, pp. 429–449. doi 10.26428/1606-9919-2022-202-429-449. EDN: CNQHAF.
- Sviridov, V.V., Podorozhnyuk, E.V., Nikitin, V.D., and Skorik, A.V.,** Modifications of unmanned aerial survey on spawners of pacific salmon in the rivers of Sakhalin and Khabarovsk Regions, *Izv. Tikhookean. Nauchno-Issled. Inst. Rybn. Khoz. Okeanogr.*, 2022, vol. 202, no. 4, pp. 1015–1031. doi 10.26428/1606-9919-2022-202-1015-1031. EDN: JULFRV.
- Sviridov, V.V. and Povarov, A.Yu.,** Application of artificial intelligence methods to automate post-spawn chum salmon individuals enumeration by means of unmanned aerial vehicles in Khabarovsk Territory, *Vopr. rybolov.*, 2024, vol. 25, no. 4, pp. 113–124. doi 10.36038/0234-2774-2024-25-4-113-124
- Attard, M.R.G., Phillips, R.A., Bowler E., Clarke, P.J., Cubaynes, H., Johnston, D.W., and Fretwell, P.T.,** Review of Satellite Remote Sensing and Unoccupied Aircraft Systems for Counting Wildlife on Land, *Remote Sensing*, 2024, vol. 16, no. 4, pp. 1–23. doi 10.3390/rs16040627
- Borowicz, A., Le, H., Humphries, G., Nehls, G., Höschle, C., Kosarev, V., and Lynch, H.J.,** Aerial-trained deep learning networks for surveying cetaceans from satellite imagery, *PLoS ONE*, 2019, vol. 14, no. 10, art. ID e0212532. doi 10.1371/journal.pone.0212532
- Boulent, J., Charry, B., Kennedy, M., Tissier, E., Fan, R., Marcoux, M., Watt, C., Gagné-Turcotte, A.,** Scaling whale monitoring using deep learning: A human-in-the-loop solution for analyzing aerial datasets, *Frontiers in Marine Science*, 2023, vol. 10, pp. 1–13. doi 10.3389/fmars.2023.1099479
- Butcher, P., Colefax, A., Gorkin, I. Kajiura, S., López, N., Mourier, J., Purcell, C., Skomal, G., Tucker, Ja., Walsh, A., Williamson, Ja., and Raoult, V.,** The drone revolution of shark science: A review, *Drones*, 2021, vol. 5, no 1, pp. 1–8. doi 10.3390/drones5010008

Desgarnier, L., Mouillot, D., Vigliola, L., Chaumont, M., and Mannocci, L., Putting eagle rays on the map by coupling aerial video-surveys and deep learning, *Biological Conservation*, 2022, vol. 267, pp. 109494. doi 10.1016/j.biocon.2022.109494

Dujon, A., Ierodiaconou, D., Geeson, J., Arnould, J., Allan, B., Katselidis, K., and Schofield, G., Machine learning to detect marine animals in UAV imagery: effect of morphology, spacing, behaviour and habitat, *Remote Sensing in Ecology and Conservation*, 2021, vol. 7, no. 3, pp. 341–354. doi 10.1002/rse2.205

Gorkin, R., Adams, K., Berryman, M.J., Aubin, S., Li, W., and Davis, A.R., Sharkeye: Real-Time Autonomous Personal Shark Alerting via Aerial Surveillance, *Drones*, 2020, vol. 4, no. 2, pp. 1–18. doi 10.3390/drones4020018

Gray, P., Bierlich, K., Mantell, S., Mantell, S., Friedlaender, A., Goldbogen, J., and Johnston, D., Drones and convolutional neural networks facilitate automated and accurate cetacean species identification and photogrammetry, *Methods in Ecology and Evolution*, 2019, vol. 10, no. 9, pp. 1490–1500. doi 10.1111/2041-210X.13246

Guirado, E., Tabik, S., Rivas, M., Alcaraz-Segura, D., and Herrera, F., Whale counting in satellite and aerial images with deep learning, *Scientific reports*, 2019, vol. 9, no. 1, pp. 14259. doi 10.1038/s41598-019-50795-9

Infantes, E., Carroll, D., Silva, W., Härkönen, T., Edwards, S.V., and Harding, K.C., An Automated Work-Flow For Pinniped Surveys: A New Tool For Monitoring Population Dynamics, *Frontiers In Ecology And Evolution*, 2022, vol. 10, pp. 1–17. doi 10.3389/Fevo.2022.905309

Li, J.Y., Duce, S., Joyce, K.E., and Xiang, W., SeeCucumbers: Using Deep Learning and Drone Imagery to Detect Sea Cucumbers on Coral Reef Flats, *Drones*, 2021, vol. 5, no. 2, pp. 1–28. doi 10.3390/drones5020028

Rodofili, E., Lecours, V., and LaRue, M., Remote sensing techniques for automated marine mammals detection: review of methods and current challenges, *Peer J.*, 2022, vol. 10, pp. 1–22. doi 10.7717/peerj.13540

Поступила в редакцию 4.06.2025 г.

После доработки 2.07.2025 г.

Принята к публикации 8.09.2025 г.

*The article was submitted 4.06.2025; approved after reviewing 2.07.2025;
accepted for publication 8.09.2025*