Вестник Череповецкого государственного университета, 2026, № 5 (134), с. 55–64.
Cherepovets State University Bulletin, 2026, no. 5 (134), pp. 55–64.

Научная статья
УДК 004.85:536.7
https://doi.org/10.23859/1994-0637-2026-5-134-5
https://elibrary.ru/txeigb

Применение интеллектуальных моделей для аппроксимации и прогнозирования параметров термодинамического процесса нагрева

Александр Олегович Руфанов
Череповецкий государственный университет,
Череповец, Россия
alexander@rufanov.net, https://orcid.org/0009-0006-6678-0910

Аннотация. В статье рассмотрена возможность применения интеллектуальных моделей для аппроксимации и прогнозирования температуры в модельном термодинамическом процессе нагрева, построена расчетная выборка на основе теплового баланса сосредоточенной системы, обучены регрессионные модели и сопоставлены их ошибки. В работе показано, что модели машинного обучения могут использоваться как быстрые приближенные заменители расчетной модели при сохранении физической интерпретируемости постановки.
Ключевые слова: термодинамический процесс, машинное обучение, тепловой баланс, интеллектуальная модель, прогнозирование температуры
Для цитирования: Руфанов А. О. Применение интеллектуальных моделей для аппроксимации и прогнозирования параметров термодинамического процесса нагрева**.** *Вестник Череповецкого государственного университета*, 2026, № 5 (134), с. 55–64. https://doi.org/10.23859/1994-0637-2026-5-134-5; EDN: TXEIGB

Application of intelligent models to approximate and predict parameters of a thermodynamic heating process

Alexander O. Rufanov
Cherepovets State University,
Cherepovets, Russia
alexander@rufanov.net, https://orcid.org/0009-0006-6678-0910

Abstract. The article examines the use of intelligent models for approximating and predicting temperature in a model thermodynamic heating process. A computational data set is generated from the heat balance equation of a lumped thermal system. Several regression models are trained and compared by error metrics. The results show that machine learning models can serve as fast approximate surrogates of a calculation model while preserving the physical interpretability of the problem statement.
Keywords: thermodynamic process, machine learning, heat balance, intelligent model, temperature prediction

© Руфанов А. О., 2026

For citation: Rufanov A. O. Application of intelligent models to approximate and predict parameters of a thermodynamic heating process. *Cherepovets State University Bulletin*, 2026, no. 5 (134), pp. 55–64. (In Russ.) https://doi.org/10.23859/1994-0637-2026-5-134-5; EDN: TXEIGB

Введение

Моделирование термодинамических процессов остается одной из базовых задач инженерного анализа, поскольку именно расчет изменения температуры, теплового потока и энергетического состояния объекта позволяет выбирать режимы работы оборудования, оценивать безопасность эксплуатации и прогнозировать поведение системы при изменении внешних условий. В классической постановке такая задача решается на основе уравнений теплового баланса, теплопроводности, конвекции и излучения, а также эмпирических коэффициентов, зависящих от конструкции и режима работы объекта[1].

В теплоэнергетических системах расчетная модель часто должна работать не в одном фиксированном режиме, а в диапазоне нагрузок. На практике это означает необходимость многократного пересчета температурных зависимостей при изменении начального состояния, мощности подвода теплоты, массы теплоносителя, теплоемкости, коэффициента теплопередачи и времени процесса. При простом объекте такая задача может быть решена аналитически, а при его усложнении, переходе к распределенным параметрам, нестационарным режимам и большим массивам эксплуатационных данных возрастает интерес к интеллектуальным моделям, способным быстро восстанавливать зависимость между входными параметрами и выходным состоянием системы.

Искусственный интеллект в настоящей работе понимается не как замена физической модели, а как инструмент построения аппроксимирующих зависимостей. Такой подход близок к идее суррогатного моделирования: сначала задается физически осмысленная постановка, затем формируется расчетная или экспериментальная выборка, после чего алгоритм машинного обучения овладевает возможностью воспроизводить результат с допустимой ошибкой. В инженерной практике это может быть полезно для предварительного анализа режимов, быстрой оценки последствий изменения параметров и последующего включения модели в цифровой контур управления[2].

Особый интерес представляет совмещение физического и машинного подходов. С одной стороны, полностью эмпирическая модель может быть точной только внутри области обучения и плохо переноситься на новые режимы. С другой стороны, чисто физическая модель требует задания коэффициентов, допущений и численного решения, а в сложных системах может быть ресурсоемкой. В последние годы актив-

[1] Bergman T. L., Lavine A. S., Incropera F. P. *DeWitt Fundamentals of Heat and Mass Transfer*. Hoboken: Wiley, 2017. 1048 p.; Bejan A. *Advanced Engineering Thermodynamics*. Hoboken: Wiley, 2016. 792 p. https://doi.org/10.1002/9781119245964

[2] Brunton S. L., Kutz J. N. *Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control*. Cambridge: Cambridge University Press, 2019. 472 p. https://doi.org/10.1017/9781108380690

но развивается направление физически информированных нейронных сетей, в которых условия и уравнения предметной области включаются в процесс обучения. Для задач теплопереноса такие подходы рассматриваются как перспективный способ решения прямых и обратных задач при неполных данных[1].

Цель исследования – показать на воспроизводимом модельном примере, каким образом интеллектуальные модели могут применяться для аппроксимации и прогнозирования параметров термодинамического процесса. В качестве объекта выбран процесс нагрева сосредоточенной тепловой системы с потерями в окружающую среду. Такая постановка достаточно проста для физической интерпретации и одновременно удобна для демонстрации методики построения расчетной выборки, обучения моделей и оценки качества прогноза.

Научная новизна работы заключается в формировании компактной методической схемы, связывающей тепловой баланс, расчетную выборку и сравнительную оценку моделей машинного обучения применительно к термодинамическому процессу. Практическая значимость состоит в том, что предложенный подход может быть перенесен на более сложные теплоэнергетические процессы, где интеллектуальная модель будет использоваться в качестве быстрого прогнозного блока, а физическая – сохранять роль основы для постановки задачи и проверки результата.

Основная часть

Материал и методы

В качестве расчетного объекта рассмотрена сосредоточенная система нагрева, в которой температура тела или теплоносителя считается равномерной по объему. Такое допущение соответствует классу lumped-моделей и применяется тогда, когда внутреннее температурное сопротивление объекта мало по сравнению с сопротивлением теплообмена с внешней средой[2]. Модель не претендует на описание всех реальных теплоэнергетических процессов, однако позволяет корректно показать связь между физической формулой и машинно-обучаемым прогнозом.

Тепловой баланс системы задан выражением:

$$m \cdot c \cdot \frac{dT}{dt} = P - K \cdot \left(T - T_\mathrm{env}\right), \quad (1)$$

где m – масса нагреваемого объекта, кг; c – удельная теплоемкость, Дж / (кг К); T – температура объекта, °С; $T_$env – температура окружающей среды, °С; P – мощность

[1] Cai S., Wang Z., Wang S., et al. Physics-Informed Neural Networks for Heat Transfer Problems. *Journal of Heat Transfer*, 2021, vol. 143, no. 6, p. 060801. https://doi.org/10.1115/1.4050542; EDN: FKYDDW; Raissi M., Perdikaris P., Karniadakis G. E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 2019, vol. 378, pp. 686–707. https://doi.org/10.1016/j.jcp.2018.10.045

[2] Han J.-C., Wright L. *Analytical Heat Transfer.* Boca Raton: CRC Press, 2022. https://doi.org/10.1201/9781003164487

подвода теплоты, Вт; K – интегральный коэффициент тепловых потерь, Вт / К; t – время, с.

Для постоянных P, K, m и c решение уравнения (1) имеет вид:

$$T(t) = T_\text{env} + \frac{P}{K} + \left(T_0 - T_\text{env} - \frac{P}{K}\right)\exp\left(\frac{-Kt}{mc}\right), \quad (2)$$

где T_0 – начальная температура тела, °C.

Формула (2) использована как эталонная расчетная модель. В рамках вычислительного эксперимента варьировались начальная температура, температура среды, мощность подвода теплоты, коэффициент потерь, масса, теплоемкость и время процесса. Для имитации измерительной неопределенности к расчетной температуре добавлялась нормально распределенная случайная компонента с малой дисперсией, что позволило не подменять задачу чистым копированием формулы и приблизить постановку к ситуации, в которой данные имеют технологическую погрешность. Диапазоны параметров расчетной выборки представлены в табл. 1.

Таблица 1

Диапазоны параметров расчетной выборки

Параметр	Обозначение	Диапазон	Единица	Роль в модели
Начальная температура	T_0	20–80	°C	Начальное состояние
Температура среды	$T_$env	15–30	°C	Внешнее условие
Мощность нагрева	P	200–1600	Вт	Источник энергии
Коэффициент потерь	K	4–18	Вт/К	Теплообмен со средой
Масса	m	1,5–7,0	кг	Тепловая инерция
Теплоемкость	c	3200–4300	Дж/(кг·К)	Материальный параметр
Время	t	60–3600	с	Горизонт прогноза

Объем расчетной выборки составил 3000 наблюдений. Выборка была разделена на обучающую и тестовую части в соотношении 70:30. В качестве входных признаков использовались семь параметров, приведенных в табл. 1, а целевой переменной являлась температура объекта в момент времени. Такой выбор целевой переменной соответствует типовой инженерной задаче: по известным режимным параметрам необходимо быстро получить прогноз температуры без повторного решения дифференциального уравнения.

В исследовании сопоставлены четыре типа интеллектуальных моделей: линейная регрессия, случайный лес, градиентный бустинг и многослойный персептрон. Линейная регрессия включена как простой базовый ориентир. Случайный лес выбран как ансамблевый метод, устойчивый к нелинейным зависимостям и взаимодей-

ствию признаков. Градиентный бустинг применен как последовательная ансамблевая модель, способная уточнять ошибку предыдущих деревьев. Многослойный персептрон использован как нейросетевая модель, способная приближать сложные нелинейные зависимости при нормировке входных признаков[1].

Качество моделей оценивалось на тестовой выборке. Для сопоставления использовались средняя абсолютная ошибка (MAE), среднеквадратическая ошибка (RMSE) и коэффициент детерминации (R^2). Эти метрики позволяют одновременно оценить средний масштаб ошибки, чувствительность к большим отклонениям и долю объясненной дисперсии целевой переменной. Метрики рассчитывались по формулам:

$$\mathrm{MAE} = \frac{1}{n} \cdot \sum \left| T_i - \hat{T}_i \right|, \tag{3}$$

$$\mathrm{RMSE} = \sqrt{\frac{1}{n} \cdot \sum \left(T_i - \hat{T}_i \right)^2}, \tag{4}$$

$$R^2 = 1 - \frac{\sum \left(T_i - \hat{T}_i \right)^2}{\sum \left(T_i - \bar{T} \right)^2}. \tag{5}$$

Реализация вычислительного эксперимента выполнена средствами Python с использованием библиотек машинного обучения[2]. Для воспроизводимости использовалась фиксированная инициализация генератора случайных чисел. Программная среда в данном исследовании выступает не как предмет статьи, а как инструмент проверки основной методической идеи: можно ли по параметрам термодинамического процесса обучить модель, которая с приемлемой точностью восстанавливает расчетную температуру. Логика вычислительного эксперимента отражена на рис. 1.

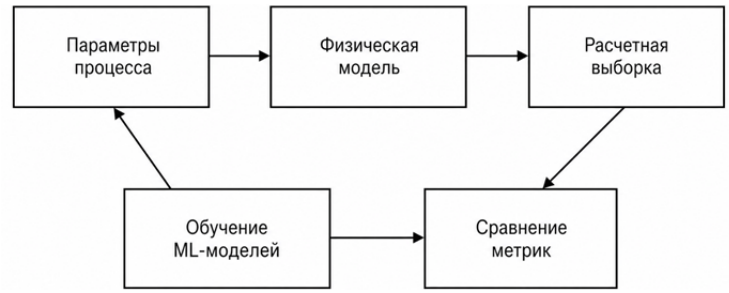


Рис. 1. Логика вычислительного эксперимента

[1] Goodfellow I., Bengio Y., Courville A. *Deep Learning*. Cambridge: MIT Press, 2016. 800 p.; Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. New York: Springer, 2009. 745 p. https://doi.org/10.1007/978-0-387-84858-7; Friedman J. H. Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 2001, vol. 29, no. 5, pp. 1189–1232. https://doi.org/10.1214/aos/1013203451; Breiman L. Random forests. *Machine Learning*, 2001, vol. 45, pp. 5–32. https://doi.org/10.1023/A:1010933404324

[2] Pedregosa F., Varoquaux G., Gramfort A., et al. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 2011, vol. 12, pp. 2825–2830.

Результаты

Полученные значения метрик приведены в табл. 2. Физическая модель ожидаемо показывает минимальную ошибку, поскольку именно она использована для формирования расчетной основы выборки. Однако сравнение интеллектуальных моделей также дает содержательный результат – ошибка линейной регрессии существенно выше, чем у ансамблевых и нейросетевой моделей, что указывает на нелинейный характер зависимости температуры от режима нагрева.

Наиболее точный результат среди интеллектуальных моделей в проведенном эксперименте показал MLP-регрессор. Его RMSE составила 3,72 °C, а коэффициент детерминации достиг 0,990. Градиентный бустинг и случайный лес также воспроизвели зависимость достаточно хорошо, но уступили нейросетевой модели по абсолютной и среднеквадратической ошибке. Это согласуется с характером задачи, поскольку формула (2) содержит экспоненциальную нелинейность, а температура зависит не только от отдельных параметров, но и от их сочетаний.

Таблица 2

Сравнение качества моделей на тестовой выборке

Модель	MAE, °C	RMSE, °C	R^2
Физическая модель	0,14	0,18	1,000
Линейная регрессия	12,09	17,13	0,788
Random Forest	5,01	7,19	0,963
Gradient Boosting	4,42	6,66	0,968
MLP-регрессор	2,49	3,72	0,990

На рис. 2 представлена динамика температуры для одного демонстрационного режима нагрева. Видно, что интеллектуальные модели воспроизводят общий характер кривой нагрева: быстрый рост температуры на начальном участке и постепенный выход на установившийся уровень. При этом градиентный бустинг несколько сглаживает переходную область, а MLP-регрессор ближе повторяет расчетную кривую в большей части временного диапазона.

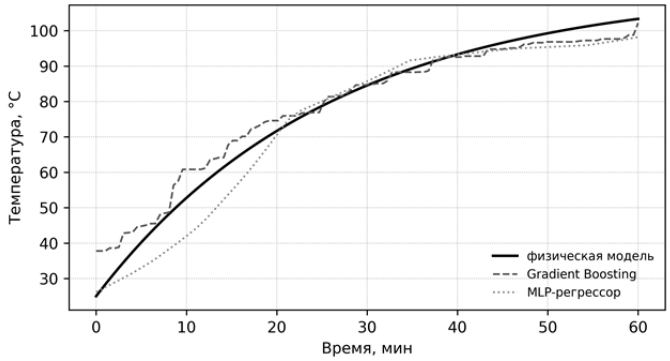


Рис. 2. Динамика температуры в демонстрационном режиме нагрева

Дополнительная проверка представлена на рис. 3. Точки показывают соотношение между расчетной температурой и прогнозом MLP-регрессора на тестовой выборке – чем ближе они расположены к диагонали, тем точнее модель воспроизводит эталонное значение. Основная масса наблюдений сконцентрирована рядом с диагональной линией, что подтверждает высокую точность аппроксимации внутри заданной области параметров.

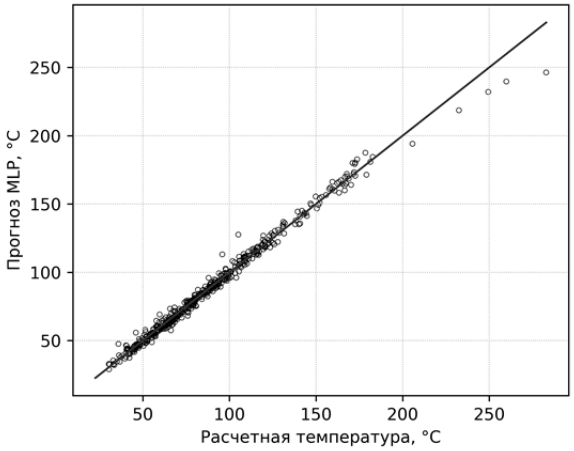


Рис. 3. Сравнение расчетных температур и прогнозов MLP-регрессора

Обсуждение

Результаты вычислительного эксперимента позволяют сделать несколько содержательных выводов. Во-первых, даже простая термодинамическая модель нагрева формирует нелинейную зависимость между входными параметрами и температурой, поэтому использование только линейной регрессии ограничено – такая модель может быть полезна как базовый ориентир, но она не отражает экспоненциальный характер переходного процесса. Для инженерного применения это означает, что выбор модели должен учитывать не только удобство реализации, но и физическую форму зависимости.

Во-вторых, ансамблевые методы и нейросетевой регрессор способны с хорошей точностью восстановить расчетную зависимость, что подтверждает возможность использования интеллектуальных моделей в качестве быстрых аппроксиматоров. Однако такой результат не должен трактоваться как доказательство универсальности любой ML-модели. Модель обучается на ограниченном диапазоне параметров, и ее надежность вне этого диапазона не гарантируется. Следовательно, при переносе подхода на реальные теплоэнергетические процессы требуется отдельная процедура валидации, контроль физической правдоподобности и проверка на новых режимах.

В-третьих, физическая модель сохраняет методологически важную роль – именно она задает смысл входных параметров, формирует структуру вычислительного эксперимента и позволяет оценить корректность прогноза. В задачах теплоэнергетики наиболее перспективным является не противопоставление физического и интел-

лектуального моделирования, а их объединение. Возможны разные варианты их взаимодействия: генерация расчетной выборки на основе физической модели, добавление физически осмысленных признаков, ограничение области допустимых прогнозов, включение уравнений баланса в функцию потерь нейронной сети.

Сравнение моделей также показывает, что интеллектуальная модель может быть полезна не только для прогноза температуры, но и для последующей оптимизации режима. Например, если модель быстро оценивает температуру при различных *P, K, m* и *t*, то ее можно использовать внутри алгоритма подбора мощности нагрева, времени выхода на режим или допустимой области параметров. В таком случае ML-модель становится расчетным модулем, который ускоряет перебор вариантов, а физическая модель используется для контрольной проверки выбранных решений.

Ограничение проведенного исследования состоит в том, что расчетная выборка сформирована по одной компактной физической постановке. Это осознанное методическое ограничение первой статьи по данной теме – задача состоит не в описании конкретного промышленного агрегата, а в демонстрации принципа моделирования термодинамического процесса с помощью интеллектуальных моделей. Для дальнейшего развития исследований в данном направлении необходимо перейти к более сложной постановке, включающей переменную тепловую нагрузку, инерционность теплообменника, несколько температурных узлов, данные с датчиков и реальные режимы теплоэнергетического оборудования.

С прикладной точки зрения наиболее важным является не сам факт достижения высокой метрики на расчетной выборке, а выстроенная логика работы с моделью. Исследователь должен определить физическую постановку, задать область параметров, сформировать выборку, обучить несколько моделей, сравнить их по единым метрикам, проверить форму кривых и только после этого обсуждать возможность переноса подхода на практический объект. Такой порядок снижает риск формального применения искусственного интеллекта без инженерного смысла. Возможности и ограничения используемых моделей приведены в табл. 3.

Таблица 3

Возможности и ограничения примененных моделей

Модель	Возможности	Ограничения
Линейная регрессия	простая интерпретация, быстрый расчет, удобный базовый ориентир	слабо описывает экспоненциальную нелинейность и взаимодействие параметров
Random Forest	устойчивость к нелинейностям, работа без сложной подготовки признаков	ступенчатость прогноза, ограниченная экстраполяция за пределами обучения
Gradient Boosting	хорошая точность на табличных данных, последовательное уточнение ошибки	чувствительность к настройкам и риску переобучения
MLP-регрессор	гладкая аппроксимация сложной зависимости, высокая точность в эксперименте	требует нормировки признаков и контроля области применимости

Выводы

В статье показано, что интеллектуальные модели могут использоваться для аппроксимации и прогнозирования параметров термодинамического процесса нагрева. На основе уравнения теплового баланса сосредоточенной системы сформирована расчетная выборка, включающая основные режимные параметры: начальную температуру, температуру среды, мощность нагрева, коэффициент тепловых потерь, массу, теплоемкость и время процесса.

Сравнение моделей показало, что линейная регрессия недостаточно точно воспроизводит нелинейную температурную зависимость. Ансамблевые модели и нейросетевой регрессор обеспечили существенно меньшую ошибку. Наилучший результат среди интеллектуальных моделей в проведенном эксперименте показал MLP-регрессор: RMSE составила 3,72 °C, а R^2 достиг 0,990. Это подтверждает возможность построения быстрого прогнозного блока для расчетной оценки температуры в заданной области параметров.

В то же время физическая модель остается необходимой частью исследования. Она задает инженерный смысл признаков, позволяет формировать расчетные данные и служит основой для проверки правдоподобности прогноза, поэтому применение искусственного интеллекта в моделировании теплоэнергетических процессов целесообразно рассматривать как гибридный подход, в котором машинное обучение ускоряет прогноз, а физическая модель обеспечивает интерпретируемость и контроль.

Дальнейшее развитие исследования связано с переходом от модельного процесса к реальным теплоэнергетическим объектам: теплообменникам, участкам тепловых сетей, котельному оборудованию и системам накопления тепловой энергии. Для таких объектов необходимо расширить набор признаков, использовать данные мониторинга, проверить устойчивость моделей на эксплуатационных режимах и рассмотреть физически информированные нейронные сети как инструмент объединения расчетных уравнений и данных.

Список литературы / References

Bejan A. *Advanced engineering thermodynamics*. Hoboken: Wiley, 2016. 792 p. https://doi.org/10.1002/9781119245964

Bergman T. L., Lavine A. S., Incropera F. P. *DeWitt fundamentals of heat and mass transfer*. Hoboken: Wiley, 2017. 1048 p.

Breiman L. *Random forests*. *Machine learning*, 2001, vol. 45, pp. 5–32. https://doi.org/10.1023/A:1010933404324

Brunton S. L., Kutz J. N. *Data-driven science and engineering: Machine learning, dynamical systems, and control*. Cambridge: Cambridge University Press, 2019. 472 p. https://doi.org/10.1017/9781108380690

Cai S., Wang Z., Wang S., et al. Physics-informed neural networks for heat transfer problems. *Journal of Heat Transfer*, 2021, vol. 143, no. 6, p. 060801. https://doi.org/10.1115/1.4050542; EDN: FKYDDW

Friedman J. H. Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 2001, vol. 29, no. 5, pp. 1189–1232. https://doi.org/10.1214/aos/1013203451

Goodfellow I., Bengio Y., Courville A. *Deep learning*. Cambridge: MIT Press, 2016. 800 p.

Han J.-C., Wright L. *Analytical heat transfer.* Boca Raton: CRC Press, 2022. https://doi.org/10.1201/9781003164487

Hastie T., Tibshirani R., Friedman J. *The elements of statistical learning: Data mining, inference, and prediction*. New York: Springer, 2009. 745 p. https://doi.org/10.1007/978-0-387-84858-7

Pedregosa F., Varoquaux G., Gramfort A., et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 2011, vol. 12, pp. 2825–2830.

Raissi M., Perdikaris P., Karniadakis G. E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 2019, vol. 378, pp. 686–707. https://doi.org/10.1016/j.jcp.2018.10.045

Сведения об авторе

Александр Олегович Руфанов – аспирант, https://orcid.org/0009-0006-6678-0910, alexnder@rufanov.net, Череповецкий государственный университет (д. 5, пр-т. Луначарского, 162600 Череповец, Россия); **Alexander O. Rufanov –** Postgraduate Student, https://orcid.org/0009-0006-6678-0910, alexnder@rufanov.net, Cherepovets State University (5, pr. Lunacharskogo, 162600 Cherepovets, Russia).

Статья поступила в редакцию 29.04.2026; одобрена после рецензирования 02.09.2026; принята к публикации 17.09.2026.

The article was submitted 29.04.2026; Approved after reviewing 02.09.2026; Accepted for publication 17.09.2026.