

МОРФОЛОГИЯ, ФИЗИОЛОГИЯ И ПАТОФИЗИОЛОГИЯ MORPHOLOGY, PHYSIOLOGY AND PATHOPHYSIOLOGY

СРАВНИТЕЛЬНЫЙ АНАЛИЗ РЕЗУЛЬТАТОВ ПРОГНОЗИРОВАНИЯ ДИАМЕТРОВ ДОЧЕРНИХ СЕГМЕНТОВ БИФУРКАЦИЙ ВЕНЕЧНЫХ АРТЕРИЙ В НОРМЕ, ПОЛУЧЕННЫХ С ИСПОЛЬЗОВАНИЕМ ГРАФОВЫХ НЕЙРОННЫХ СЕТЕЙ И ИЗВЕСТНЫХ МЕТОДОВ ЧИСЛЕННОГО МОДЕЛИРОВАНИЯ

Зенин О.К.¹,
Горбаченко В.И.¹,
Грибков Д.Н.¹,
Милтиадис И.²,
Кафаров Э.С.³,
Гайрабекова Ф.Р.⁴

¹ Пензенский государственный университет Минобрнауки России (440026, г. Пенза, ул. Красная, 40, Россия)

² Университет Палермо (Università degli Studi di Palermo) (90133, Пьяцца Марина, 61, Палермо, Италия)

³ Чеченский государственный университет им. А.А. Кадырова Минобрнауки России (364024, г. Грозный, ул. А. Шерипова, 32, Чеченская Республика, Россия)

⁴ Астраханский государственный медицинский университет Минздрава России (414000, г. Астрахань, ул. Бакинская, 121, Россия)

Автор, ответственный за переписку:
Зенин Олег Константинович
e-mail: zen.olegz@gmail.com

РЕЗЮМЕ

Обоснование. Точное определение диаметров венечных артерий сердца человека (ВАСЧ) играет ключевую роль в диагностике, оценке рисков и планировании лечения ишемической болезни сердца. Поскольку сосудистые сети имеют фрактальную структуру и состоят из артериальных бифуркаций (АБ), важной задачей является прогнозирование диаметров дочерних (дистальных) артериальных сегментов (АС) на основе известной величины диаметра материнского (проксимального) АС. Известные методы численного моделирования – прогнозирования диаметров артерий используют приближенные аналитические зависимости, полученные эмпирически.

Цель. Провести сравнительный анализ результатов прогнозирования диаметров дочерних сегментов (составных частей бифуркации), полученных с использованием графовых нейронных сетей и известных методов численного моделирования (ИМЧМ), основанных на данных морфометрии реальных венечных артерий сердца человека в норме.

Методы. Для достижения поставленной цели были реализованы и протестированы различные архитектуры GNN: GCN, GraphSAGE, GAT и TransformerConv. А также ИМЧМ и многослойный перцептрон. Проведен сравнительный статистический анализ результатов. Использовали ранее полученные данные морфометрии величин внутренних диаметров АС, составляющих 30 графов коррозионных препаратов ВАСЧ в норме.

Результаты. Впервые предложено использовать GNN для решения данной задачи. Сравнительный анализ результатов показал, что все GNN-модели превосходили по точности ИМЧМ и многослойный перцептрон, в прогнозировании величин диаметров дочерних АС меньшего калибра. Наилучшие результаты продемонстрировала TransformerConv, достигнув коэффициента детерминации $R^2 = 0,96$ и $RMSE = 0,199$ для прогноза большего дочернего диаметра и $R^2 = 0,76$ и $RMSE = 0,221$ — для меньшего.

Заключение. Разработанные модели могут стать основой для создания клинических систем поддержки принятия решений, позволяющих более точно оценивать состояние структуры ВАСЧ.

Ключевые слова: сердце человека, венечные артерии, графовые нейронные сети, прогнозирование диаметров, артериальная бифуркация, медицинская диагностика

Статья поступила: 29.12.2025
Статья принята: 17.06.2026
Статья опубликована: 23.07.2026

Для цитирования: Зенин О.К., Горбаченко В.И., Грибков Д.Н., Милтиадис И., Кафаров Э.С., Гайрабекова Ф.Р. Сравнительный анализ результатов прогнозирования диаметров дочерних сегментов бифуркаций венечных артерий в норме, полученных с использованием графовых нейронных сетей и известных методов численного моделирования. *Acta biomedica scientifica*. 2026; 11(3): 57-63. doi: 10.29413/ABS.2026-11.3.7

COMPARATIVE ANALYSIS OF THE RESULTS OF PREDICTING DIAMETERS OF DAUGHTER SEGMENTS OF CORONARY ARTERY BIFURCATIONS UNDER NORMAL CONDITIONS, OBTAINED USING GRAPH NEURAL NETWORKS AND KNOWN NUMERICAL MODELING METHODS

Zenin O.K.¹,
Gorbachenko V.I.¹,
Gribkov D.N.¹,
Miltiadis I.²,
Kafarov E.S.³,
Gairabekova E.R.⁴

¹ Penza State University (Krasnaya St., 40, 440026 Penza, Russian Federation)

² University of Palermo (Piazza Marina, 61, Palermo 90133, Italy)

³ A.A. Kadyrov Chechen State University (A. Sheripov St., 32, Grozny 364024, Chechen Republic, Russian Federation)

⁴ Astrakhan State Medical University (Bakinskaya St., 121, Astrakhan 414000, Russian Federation)

Corresponding author:

Oleg K. Zenin

e-mail: zen.olegz@gmail.com

ABSTRACT

Background. The accurate determination of human coronary artery (HCA) diameters plays a pivotal role in the diagnosis, risk assessment, and treatment planning of ischemic heart disease. Given that vascular networks possess a fractal structure and consist of arterial bifurcations (AB), a critical task is the prediction of the diameters of daughter (distal) arterial segments (AS) based on the known diameter of the mother (proximal) AS. Existing numerical modeling methods (ENMM) for predicting arterial diameters rely on approximate analytical dependencies derived empirically.

Aim. To conduct a comparative analysis of the results of predicting diameters of daughter segments (bifurcation components) obtained using Graph Neural Networks and known numerical modeling methods based on morphometric data of real healthy human coronary arteries.

Methods. To achieve this objective, various GNN architectures were implemented and tested: GCN, GraphSAGE, GAT, and TransformerConv. Additionally, ENMM and a Multilayer Perceptron (MLP) were evaluated. A comparative statistical analysis of the results was conducted. The study utilized previously obtained morphometric data on the internal diameters of AS comprising 30 corrosion cast graphs of healthy HCAs.

Results. This study proposes the use of GNNs for this specific task for the first time. Comparative analysis demonstrated that all GNN models surpassed both ENMM and the Multilayer Perceptron in accuracy when predicting the diameters of smaller-caliber daughter AS. The TransformerConv architecture demonstrated the best performance, achieving a coefficient of determination $R^2 = 0.96$ and RMSE = 0.199 for predicting the larger daughter segment diameter, and $R^2 = 0.76$ and RMSE = 0.221 for the smaller segment.

Conclusion. The developed models may serve as the foundation for creating clinical decision support systems, enabling more precise assessments of the structural status of human coronary arteries.

Keywords: human heart, coronary arteries, graph neural networks, diameter prediction, arterial bifurcation, medical diagnostics

Received: 29.12.2025

Accepted: 17.06.2026

Published: 23.07.2026

For citation: Zenin O.K., Gorbachenko V.I., Gribkov D.N., Miltiadis I., Kafarov E.S., Gairabekova E.R. Comparative analysis of the results of predicting diameters of daughter segments of coronary artery bifurcations under normal conditions, obtained using graph neural networks and known numerical modeling methods. *Acta biomeica scientifica*. 2026; 11(3): 57-63. doi: 10.29413/ABS.2026-11.3.7

ОБОСНОВАНИЕ

Актуальность проблемы прогнозирования диаметров венечных артерий сердца человека (ВАСЧ) сложно переоценить в современной кардиологии. Точное определение этих параметров играет критически важную роль в диагностике, профилактике и лечении ишемической болезни сердца, включая обнаружение стенозов, оценку гемодинамических рисков и планирование реваскуляризации.

С морфологической точки зрения внутриорганные артериальные русла принято рассматривать как фрактальные системы [1, 2]. Их основным структурным компонентом является артериальная бифуркация (АБ), состоящая из материнского (проксимального) артериального сегмента (АС) (D) и двух дочерних (дистальных) АС (d_{max} и d_{min}), отличающихся величиной внутреннего диаметра. В связи с этим, задача прогнозирования диаметров дочерних АС на основе известного значения диаметра материнского АС представляет значительный практический интерес. Для ее решения существуют известные методы численного моделирования (ИМЧМ) [3, 4], тогда как современные методы машинного обучения, в частности нейронные сети, до сих пор не нашли своего применения в этой области.

Структура сосудистого русла может быть представлена в виде графа — бинарного дерева. Для работы с данными такой структуры был разработан специальный класс алгоритмов — графовые нейронные сети (GNN) [5]. В то время как типичными задачами для GNN являются задачи классификации исследуемых объектов или предсказание связей, в данной работе предлагается новаторский подход: использование GNN для решения задачи регрессии, а именно прогнозирования диаметров дочерних АС на основе величины диаметра материнского АС.

ЦЕЛЬ ИССЛЕДОВАНИЯ

Провести сравнительный анализ результатов прогнозирования диаметров дочерних сегментов (составных частей бифуркации), полученных с использованием графовых нейронных сетей и известных методов численного моделирования, основанных на данных морфометрии реальных венечных артерий сердца человека в норме.

МЕТОДЫ

Дизайн исследования. В основу исследования легли результаты морфометрического анализа 30 ВАСЧ, полученные методом коррозионного препарирования [6]. Исходные данные были предоставлены в формате Excel-таблицы. Из всего набора признаков для обучения и валидации модели были отобраны следующие: величина диаметра материнского АС (D , мм); пол: 1-мужской пол, 2-женский пол; возрастная группа

пациента: 1 — лица 2-го периода зрелого возраста (мужчины от 36 до 60 лет, женщины от 36 до 55 лет) и 2 — пожилого возраста (мужчины от 61 до 75 лет, женщины от 56 до 75 лет) (Классификация АПН СССР (1965); уровень деления — вновь образовавшийся ряд АБ: от 1 до 20. Целевыми переменными, которые предстояло предсказать, выступили диаметры двух дочерних АС: d_{max} (мм) — диаметр большего АС и d_{min} (мм) — диаметр меньшего АС. Исследуемая выборка включала 30 образцов, в каждом из которых количество измеренных АС было больше 100. Данные были структурированы в виде 30 графов. Уровень деления и все значения диаметров рассматривались как числовые переменные, а пол и возрастная группа — как категориальные. Предварительный статистический анализ с применением библиотек Pandas и NumPy позволил установить, что закон распределения величин диаметров АС отличается от нормального и содержит выбросы.

Преобразование данных и построение графов. Для реализации GNN использовался фреймворк PyTorch Geometric (PyG) [7]. Подготовку табличных данных из Excel осуществляли с помощью библиотеки Pandas, данные преобразовывались в тензоры PyTorch. Анатомические связи (для построения графовой структуры данных) между АС определяли с применением библиотеки NetworkX [8]. Во избежание утечки данных (data leakage) разделение на обучающую и тестовую выборки проводилось на уровне целых русел ВАСЧ (графов). Обучающая выборка содержала 22 русла ВАСЧ (графа) (73 %), тестовая — 8 (27 %). Такой подход гарантирует, что модель не будет использовать информацию о структуре русел (графов) из тестового набора во время обучения. Обучающие данные были нормализованы с помощью RobustScaler из библиотеки scikit-learn [9], которая устойчива к выбросам. Параметры нормализации были сохранены для последующего применения к тестовым данным и при инференсе.

Архитектуры GNN. Были реализованы четыре ключевые архитектуры GNN: GCN (Graph Convolutional Network — графовая свёрточная сеть), GraphSAGE (Sample and Aggregate — графовая сеть выборки и агрегирования), GAT (Graph Attention Network — графовая сеть внимания) и TransformerConv (Graph Transformer — графовый трансформер). Для сравнения эффективности GNN-подхода также был использован многослойный перцептрон (MLP), обученный на тех же исходных признаках, но без учета графовой структуры и результаты ИМЧМ.

Используемое оборудование и процесс обучения. Все эксперименты проводились на ПК с ОС Windows 11, использующем подсистему WSL2 с дистрибутивом Ubuntu 24.04. Конфигурация оборудования: процессор Intel Core i7-14700KF, 64 ГБ ОЗУ, графический процессор Nvidia с 32 ГБ видеопамати. Используемые версии библиотек: PyTorch 2.7.0+cu128 и PyTorch Geometric 2.6.1. Для обучения моделей применяли оптимизатор AdamW [10] с L2-регуляризацией (weight decay) для борьбы с переобучением; функцию потерь HuberLoss [11], которая сочетает преимущества MSE (для малых ошибок)

и MAE (для больших ошибок), что делает ее устойчивой к выбросам. Для регуляризации использовали технику Dropout, а также раннюю остановку (early stopping) при отсутствии улучшения функции потерь в течение 50 эпох. Автоматизированный поиск гиперпараметров осуществляли с помощью библиотеки Optuna [12] в течение 200 проходов (trials). Логирование всех экспериментов осуществлялось в среде MLflow.

ИМЧМ – базовые модели для сравнения. Для верификации результатов нейросетевого прогнозирования были использованы ИМЧМ [3, 4]. Модель на основе работы [3] использует связь между значениями материнского AC (D), большего и меньшего дочерних AC (d_{max} и d_{min}), а также коэффициент асимметрии ($ratio$):

$$D^{\frac{7}{3}} = d_{max}^{\frac{7}{3}} + d_{min}^{\frac{7}{3}} \quad (1)$$

где D — материнского AC, d_{max} — диаметр большего дочернего AC и d_{min} — диаметр меньшего дочернего AC. Также авторы показывают асимметрию ветвления как отношение величин дочерних диаметров:

$$ratio = \frac{d_{min}}{d_{max}}. \quad (2)$$

В результате из (1) и (2) можно рассчитать диаметры дочерних AC:

$$d_{max} = D \cdot \left(\frac{1}{1 + ratio^{\frac{7}{3}}} \right)^{\frac{7}{3}}, \quad (3)$$

$$d_{min} = ratio \cdot d_{max}. \quad (4)$$

где: $ratio=0,625$

Модель на основе работы [4] связывает величины диаметров дочерних AC (d_{max} и d_{min}) со значением диаметра материнского AC (D) и параметрами асимметрии (α, β):

$$d_{max} = \alpha D, \quad d_{min} = \beta D. \quad (5)$$

где $\alpha \approx 0,9, \beta \approx 0,6$.

Сравнительный анализ результатов моделирования. Для оценки точности прогнозов использовали две метрики. А именно R^2 (коэффициент детерминации) и значение RMSE (среднеквадратичная ошибка). Качество прогнозирования было оценено на тестовой выборке с использованием коэффициента детерминации (R^2). Данная метрика определяет, какая доля дисперсии зависимой переменной объясняется регрессионной моделью. Для расчета коэффициента детерминации (R^2) использовали формулу, представленную ниже:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6),$$

где y_i — известное значение величины, $\hat{y}_i$ — оценка модели, $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$ — среднее значение величины,

n — количество примеров в тестовом наборе. Чем ближе к 1, тем лучше. Отрицательное значение означает, что модель работает хуже, чем простое предсказание средним значением. Также была использована метрика RMSE (Root Mean Squared Error) — стандартная величина ошибки в задачах регрессии, делает размерность метрики такой же, как у исходных данных (мм), что удобно для интерпретации:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7).$$

Чем ближе к 0, тем лучше. Сравнивали пять современных архитектур GNN, а также две классические аналитические модели из научной литературы.

РЕЗУЛЬТАТЫ

Предварительный анализ результатов (табл. 1) показывает, что прогнозировать величину d_{min} заметно сложнее, чем d_{max} . Рассчитанные значения R^2 и RMSE для различных архитектур MLP и GNN, а также ИМЧМ, описанных в литературе [3, 4] говорят о том, что для всех моделей (кроме TransformerConv) значение R^2 для меньшего дочернего AC существенно ниже, а величина RMSE — выше. Это логично, так как величина меньшего дочернего AC может сильнее зависеть от гемодинамических и топологических факторов. Представленные результаты прогнозирования двух ключевых параметров AC ВАСЧ: d_{max} — значение диаметра большего дочернего AC АБ и d_{min} — значение диаметра меньшего дочернего AC АБ. MLP (многослойный перцептрон) показывают удовлетворительные результаты, особенно для прогнозирования значения d_{max} . Этот результат заметно лучше, чем у GCN и GraphSAGE, т.е. даже без учета явной графовой структуры сеть может уловить основные закономерности.

Однако ее отставание от лучших GNN подтверждает важность учета связей. Значения, полученные с использованием GCN и GraphSAGE, показали средние, довольно скромные результаты для d_{max} . Их простые механизмы агрегации информации от ближайших соседей, видимо, недостаточны для точного моделирования ВАСЧ. Следует также отметить, что GraphSAGE немного лучше справляется с предсказанием величины d_{min} , чем архитектуры MLP и GCN. GAT (сеть внимания) проявляет избирательность. Для d_{max} она вторая по точности после TransformerConv ($R^2 = 0,71$), тогда как для d_{min} показывает худший RMSE среди исследуемых сетей. Возможно, механизм внимания GAT помогает выделить ключевые «родительские» признаки для большего дочернего AC (d_{max}), но оказывается менее эффективным для меньшего AC (d_{min}). TransformerConv демонстрирует исключительную точность для значений обоих параметров:

ТАБЛИЦА 1

ЗНАЧЕНИЯ R^2 И RMSE ДЛЯ РАЗЛИЧНЫХ АРХИТЕКТУР MLP И GNN, А ТАКЖЕ ИМЧМ, ОПИСАННЫХ В ЛИТЕРАТУРЕ

TABLE 1

R^2 AND RMSE VALUES FOR VARIOUS MLP AND GNN ARCHITECTURES, AS WELL AS ENMM, DESCRIBED IN THE LITERATURE

Модель	Результаты прогнозирования			
	d_{max}		d_{min}	
	R^2	RMSE (мм)	R^2	RMSE (мм)
MLP	0,59	0,566	0,37	0,359
GCN	0,51	0,625	0,37	0,359
GraphSAGE	0,53	0,612	0,43	0,341
GAT	0,71	0,479	0,28	0,385
TransformerConv	0,95	0,199	0,76	0,221
Модель Olufsen M.S. et al. [12]	0,42	0,675	-0,79	0,609
Модель Huo Y. & Kassab G. [3]	0,46	0,653	-0,51	0,559

Примечания: d_{max} – величина диаметра большего дочернего АС; d_{min} – величина диаметра меньшего дочернего АС; R^2 – коэффициент детерминации; RMSE – среднеквадратичная ошибка; MLP – многослойный перцептрон; GCN (Graph Convolutional Network) – графовая свёрточная сеть; GraphSAGE (Sample and Aggregate) – графовая сеть выборки и агрегирования; GAT (Graph Attention Network) – графовая сеть внимания; TransformerConv (Graph Transformer) – графовый трансформер.

R^2 близок к идеальному (0,95 и 0,76), а RMSE – минимальны (0,199 мм и 0,221 мм). Это указывает на то, что механизм внимания, лежащий в основе работы этой GNN, идеально подходит для учета сложных, нелокальных зависимостей в структуре ВАСЧ. Все GNN-архитектуры показали положительный и значимый R^2 . ИМЧМ [3, 4], основанные на физических принципах, показали неудовлетворительные или даже крайне плохие результаты, особенно для d_{min} ($R^2 = -0,79$ и $-0,51$). Это говорит о том, что реальные АБ ВАСЧ сложнее описываются традиционно используемыми для этих целей аналитическими законами.

ОБСУЖДЕНИЕ

В отличие от традиционных нейронных сетей, предназначенных для изолированных объектов (таблицы, изображения), GNN работают со структурированными системами взаимосвязанных узлов графа, извлекая информацию как из самих компонентов (узлов), так и из топологии связей между ними (ребер). Принцип работы GNN основан на механизме передачи сообщений (message passing). Узел собирает признаки своих ближайших соседей, далее собранные сообщения объединяются с помощью инвариантной к перестановке функции (сумма, среднее значение, максимум). Затем агрегированная информация комбинируется с текущими признаками узла, обновляя его состояние. Эта многослойная архитектура позволяет узлам учитывать информацию от все более далеких соседей.

В данной работе были реализованы ключевые архитектуры GNN. GCN (Graph Convolutional Network) [5] агрегирует признаки соседей с учетом их степени (количества связей). Это высокоэффективная архитектура, однако она не различает важность отдельных соседей. GraphSAGE (Sample and Aggregate) [13] вместо

использования всех соседей применяет выборку фиксированного размера, что позволяет масштабироваться на большие графы. GAT (Graph Attention Network) [14] назначает каждому соседу весовой коэффициент, определяющий его важность для текущего узла, используя механизм внимания. TransformerConv (Graph Transformer) [15] использует усовершенствованный механизм внимания, вдохновленный архитектурой трансформера [16], что позволяет учитывать более сложные глобальные зависимости в графе. Его превосходство объясняется глобальным вниманием. В отличие от GAT, который смотрит только на ближайших соседей, трансформер может оценивать важность любых узлов в графе. Это позволяет модели учесть комплексное влияние удаленных участков сосудистой сети на локальную геометрию АБ, что и приводит к высокой точности.

Сравнение эффективности моделей позволило установить четкую связь результатов моделирования и величины диаметра АС. ИМЧМ [3, 4] демонстрируют ограниченную точность прогнозирования значения исследуемого показателя для АС с большим диаметром. Это указывает на то, что модели находят явно выраженную связь величины диаметра дочернего АС и значения диаметра материнского. В то же время, все нейросетевые архитектуры демонстрируют явное превосходство над ИМЧМ [3, 4].

Для дочерних АС меньшего диаметра ситуация повторяется: все исследуемые нейронные сети превосходят результаты работы ИМЧМ. Это преимущество объясняется способностью нейросетей выявлять сложные, неочевидные связи между величинами исследуемых показателей, в то время как ИМЧМ [3, 4], основанные на упрощенных математических представлениях, не учитывают индивидуальные фенотипические особенности ВАСЧ.

Интересно, что, несмотря на естественную структуру кровотока, лишь одна графовая сеть – трансформер

(TransformerConv), смогла извлечь из этой структуры достаточную информацию для преодоления порога в 70 % по метрике R^2 при прогнозировании диаметра меньшего дочернего АС. Это достижение связано с механизмом внимания, который учитывает как локальные, так и глобальные связи в сети ВАСЧ. Анализ результатов предсказания ИМЧМ [3, 4] показывает, что они катастрофически плохи для прогноза величины d_{min} . Отрицательный R^2 означает, что их предсказания не только неточны, но и систематически ошибочны. Это ставит под сомнение универсальность лежащих в их основе физических принципов (например, законов минимума энергии или напряжения сдвига). Их относительно лучшие (но все равно низкие) показатели для прогнозирования значения d_{max} могут указывать на то, что величина диаметра большего дочернего АС все же грубо следует некоторым общим эмпирически установленным правилам.

Значительное превосходство нейросетевых моделей, особенно графовых нейронных сетей над ИМЧМ значений диаметров меньших дочерних АС, подтверждает перспективность их использования для решения теоретических и практических (клинических) медико-биологических задач. Высокие значения R^2 для всех исследованных моделей в случае большего дочернего АС свидетельствуют о сильной связи величин диаметров этой дочерней ветви и материнского АС, что также подтверждается высокой точностью гидродинамических моделей.

ЗАКЛЮЧЕНИЕ

Нейросетевые модели показали приемлемую эффективность в прогнозировании величин диаметров дочерних АС, входящих в состав АБ ВАСЧ, что свидетельствует о перспективности представленного подхода. GNN (особенно TransformerConv) являются мощным инструментом для прогнозирования геометрии АБ, значительно превосходя ИМЧМ. Эти модели нельзя применять для прогнозирования диаметра меньшего дочернего АС d_{min} в изученном наборе данных. Их использование может привести к серьезным ошибкам. Прогнозирование d_{min} является более сложной задачей, что требует использования наиболее совершенных архитектур (например, TransformerConv) или разработки новых специализированных подходов.

Основным недостатком работы является малый объем данных для обучения, что отрицательно сказывается на точности прогноза. Для повышения качества моделей необходимо увеличить и улучшить (свести к минимуму количество «выбросов») обучающие выборки.

Для практического применения (например, в медицинском моделировании или планировании операций) следует использовать графовые трансформеры (TransformerConv), как показавшие максимальную точность и надежность.

Исследователям в области гемодинамики стоит пересмотреть или существенно дополнить ставшие классическими законы ветвления на основе данных, полученных с помощью методов машинного обучения. Дальнейшее развитие исследований в данной области следует направить на расширение функциональности моделей путем одновременного прогнозирования не только величин диаметров, но и длин дочерних АС, а также значений углов между АС входящих в состав АБ. Это существенно повысит точность построения моделей ВАСЧ. И, следовательно, значительно улучшит перспективы широкого использования виртуальных моделей ВАСЧ в теоретической и практической медицине.

Финансирование

Авторы заявляют об отсутствии внешнего финансирования исследования.

Конфликт интересов

Авторы данной статьи сообщают об отсутствии конфликта интересов.

ЛИТЕРАТУРА/REFERENCES

1. Y.-li Chen, G.-Q. Bai, L.-xing Ren, Y. Bai, M.-y Sun, T. Shang, et al. Blood physiological and flow characteristics within coronary artery circulatory network for human heart based on vascular fractal theory. *Advances in Mechanical Engineering*. 2020; 12(7): 1–13. doi: 10.1177/1687814020933385
2. Зенин О.К., Кафаров Э.С., Милтиадис И. Сравнительный анализ результатов морфометрии внутренних диаметров сегментов, составляющих бифуркацию коррозионных препаратов реальных венечных артерий сердца человека и современных методик их расчетов. *Acta biomedica scientifica*. 2025; 10(5): 100-106. [Zenin OK, Kafarov ES, Miltiadis I. Comparative Analysis of Morphometric Data on Internal Diameters of Segments Forming Bifurcations in Corrosion Casts of Human Coronary Arteries and Their Calculation Using Contemporary Methods. *Acta biomedical scientifica*. 2025; 10(5): 100-106. (In Russ.)]. doi: 10.29413/ABS.2025-10.5.11
3. Huo Y, Kassab GS. Intraspecific scaling laws of vascular trees. *Journal of the Royal Society Interface*. 2012; 9(66): 190–200. doi: 10.1098/rsif.2011.0270
4. Olufsen MS, Peskin CS, Kim WY, Pedersen EM, Nadin A, Larsen J. Numerical Simulation and Experimental Validation of Blood Flow in Arteries with Structured-Tree Outflow Conditions. *Ann Biomed Eng*. 2000; 28(11): 1281-1299. doi: 10.1114/1.1326031
5. Labonne M. *Hands-On Graph Neural Networks Using Python: Practical techniques and architectures for building powerful graph and deep learning apps with PyTorch*. Birmingham-Mumbai: Packt Publishing; 2023.
6. Свидетельство о государственной регистрации базы данных № 2021623049 Российская Федерация. Количественная анатомия внутриорганного артериального русла сердца человека: № 2021622956:

заявл. 14.12.2021: опубл. 20.12.2021 / О. Зенин, А.В. Дмитриев, И.С. Милтых; заявитель Федеральное Государственное Бюджетное Образовательное Учреждение Высшего Образования «Пензенский Государственный Университет». [Certificate of state registration of database No. 2021623049 Russian Federation. Quantitative anatomy of the intraorgan arterial channel of the human heart: No. 2021622956: submitted. 14.12.2021: publ. 20.12.2021 / O. Zenin, AV Dmitriev, IS Miltikh; applicant Federal State Budgetary Educational Institution of Higher Education "Penza State University". (In Russ.)].

7. PyG documentation — pytorch_geometric documentation. URL: <https://pytorch-geometric.readthedocs.io/en/latest/> [date of access: December 25, 2025].

8. NetworkX — NetworkX documentation. URL: <https://networkx.org/en/> [date of access: December 25, 2025].

9. Scikit-learn: machine learning in Python — scikit-learn 1.8.0 documentation. URL: <https://scikit-learn.org/stable/> [date of access: December 25, 2025].

10. AdamW — PyTorch 2.9 documentation. URL: <https://docs.pytorch.org/docs/stable/generated/torch.optim.AdamW.html> [date of access: December 25, 2025].

11. HuberLoss — PyTorch 2.9 documentation. URL: <https://docs.pytorch.org/docs/stable/generated/torch.nn.HuberLoss.html> [date of access: December 25, 2025].

12. Akiba T, Sano S, Yanase T, Ohta T, Koyama M. Optuna: a next-generation hyperparameter optimization framework. In: *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2019. doi: 10.1145/3292500.3330701

13. Hamilton WL, Ying R, Leskovec J. Inductive representation learning on large graphs. In: *Proceedings of the 31st International Conference on Neural Information Processing Systems*. NIPS'17. Curran Associates Inc.; 2017: 1025-1035.

14. Veličković P, Cucurull G, Casanova A, Romero A, Liò P, Bengio Y. Graph Attention Networks. arXiv. *Preprint posted online*. 2017. doi: 10.48550/ARXIV.1710.10903

15. Shi Y, Huang Z, Feng S, Zhong H, Wang W, Sun Y. Masked label prediction: unified message passing model for semi-supervised classification. *Preprint posted online September 8, 2020*. doi: 10.48550/arXiv.2009.03509

16. Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need. arXiv. *Preprint posted online*. 2023. doi: 10.48550/arXiv.1706.03762

Сведения об авторах

Зенин Олег Константинович – доктор медицинских наук, профессор, профессор кафедры «Анатомия человека», ФГБОУ ВО «Пензенский государственный университет»; e-mail: zen.olegz@gmail.com, <https://orcid.org/0000-0002-5447-1989>

Горбаченко Владимир Иванович – доктор технических наук, профессор, заведующий кафедрой «Компьютерные технологии, факультет вычислительной техники» ФГБОУ ВО «Пензенский государственный университет»; e-mail: gorvi_edu@mail.ru, <https://orcid.org/0000-0002-1012-8855>

Грибков Дмитрий Николаевич – аспирант кафедры «Компьютерные технологии, факультет вычислительной техники» ФГБОУ ВО «Пензенский государственный университет»; e-mail: rororol23@mail.ru, <https://orcid.org/0000-0003-4728-5923>

Кафаров Эдгар Сабирович – доктор медицинских наук, доцент, заведующий кафедрой «Нормальная и топографическая анатомия с оперативной хирургией», ФГБОУ ВО «Чеченский государственный университет им. А.А. Кадырова»; e-mail: Edgar-kafaroff@yandex.ru, <https://orcid.org/0000-0001-9735-9981>

Илиас Милтиадис – магистрант Университета Палермо; e-mail: ilia.miltykh@you.unipa.it, <https://orcid.org/0000-0002-9130-3255>

Гайрабекова Фатима Руслановна – кандидат медицинских наук, доцент, доцент кафедры «Кардиология», ФГБОУ ВО «Астраханский государственный медицинский университет»; e-mail: miss-orstho@mail.ru, <https://orcid.org/0009-0000-7062-7595>

Information about the authors

Oleg K. Zenin – Dr. Sc. (Med.), professor, professor at the Department of Human Anatomy, Penza State University; e-mail: zen.olegz@gmail.com, <https://orcid.org/0000-0002-5447-1989>

Vladimir I. Gorbachenko – Dr. Sc. (Engineering Sciences), professor; head of the Department of Computer Technology, Faculty of Computer Engineering, Penza State University; e-mail: gorvi_edu@mail.ru, <https://orcid.org/0000-0002-1012-8855>

Dmitry N. Gribov – postgraduate student, Department of Computer Technology, Faculty of Computer Engineering, Penza State University; e-mail: rororol23@mail.ru, <https://orcid.org/0000-0003-4728-5923>

Edgar S. Kafarov – Dr. Sc. (Med.), associate professor; head of the Department of Normal and Topographical Anatomy with Operative Surgery, A.A. Kadyrov Chechen State University; e-mail: Edgar-kafaroff@yandex.ru, <https://orcid.org/0000-0001-9735-9981>

Ilias Miltiadis – MSc student at University of Palermo; e-mail: ilia.miltykh@you.unipa.it, <https://orcid.org/0000-0002-9130-3255>

Fatima R. Gayrabekova – Cand. Sc. (Med.), associate professor, associate professor at the Department of Cardiology, Astrakhan State Medical University; e-mail: miss-orstho@mail.ru, <https://orcid.org/0009-0000-7062-7595>