

# АВТОМАТИЧЕСКОЕ ОПРЕДЕЛЕНИЕ КЛЮЧЕВЫХ ПАРАМЕТРОВ ДЛЯ ПРОГНОЗИРОВАНИЯ ТАКТИКИ ХИРУРГИЧЕСКОГО ЛЕЧЕНИЯ ВЕНТРАЛЬНЫХ ГРЫЖ С ИСПОЛЬЗОВАНИЕМ ГЛУБОКОГО ОБУЧЕНИЯ

Балюра О.В.<sup>1</sup>, Гребенюк Е.А.<sup>2</sup>, Еселевич Р.В.<sup>1</sup>, Акбашев Р.А.\*<sup>1</sup>, Сувор Д.А.<sup>1</sup>

DOI: 10.25881/20728255\_2026\_21\_2\_96

<sup>1</sup> ФГБВОУ ВО «Военно-медицинская академия им. С.М. Кирова», Санкт-Петербург

<sup>2</sup> ФГБОУ ВО «Санкт-Петербургский государственный морской технический университет», Санкт-Петербург

**Резюме.** Обоснование. Выбор тактики хирургического лечения послеоперационных вентральных грыж (ПОВГ) до сих пор основывается на субъективной визуальной оценке результатов КТ хирургом, что приводит к вариативности решений и отсутствию стандартизации. Не существует утвержденных программных комплексов для автоматического анализа анатомии передней брюшной стенки.

Цель: разработать метод автоматического расчета ключевых хирургических параметров (RDR, объем грыжевого мешка) на основе семантической сегментации структур передней брюшной стенки с помощью сверточной нейронной сети U-Net для объективизации предоперационного планирования.

Материалы и методы. Проведено ретроспективное одноцентровое исследование на основе данных 25 пациентов с ПОВГ категорий W2–W3 (2024–2025 гг.). Выполнена ручная сегментация правой и левой прямых мышц живота и грыжевого мешка на КТ-срезах. Модель U-Net обучалась с функцией потерь Focal Loss и аугментацией данных. На основе результатов сегментации алгоритм автоматически вычислял параметр RDR (Rectus Diastasis Ratio) и объем грыжевого мешка, формируя прогностическое заключение о необходимости техники разделения компонентов (CST).

Результаты. Модель продемонстрировала стабильное обучение (потери на валидации: 0,0015). Качество сегментации грыжевого мешка составило 74,9%. Автоматический расчет RDR позволил корректно классифицировать тактику лечения для всех пациентов: при RDR > 1,5 рекомендована простая пластика (40% пациентов), при RDR < 1,5 – CST (60% пациентов). Время анализа сокращено до 2–3 минут на пациента против 30–60 минут при ручной оценке.

Заключение. Предложенный метод на основе сверточной нейронной сети U-Net позволяет автоматически выделять ключевые структуры передней брюшной стенки на КТ-изображениях. Это создает основу для разработки систем поддержки принятия решений, способных количественно оценивать параметры грыжевого дефекта и объективизировать предоперационное планирование.

**Ключевые слова:** вентральная грыжа, глубокое обучение, предоперационное планирование, семантическая сегментация, искусственный интеллект в хирургии.

## Обоснование

Послеоперационные вентральные грыжи (ПОВГ) – распространенное осложнение после абдоминальных операций, встречающееся у до 30% пациентов [1]. Успех лечения зависит от точного предоперационного планирования, основанного на объективной оценке анатомии передней брюшной стенки [2–4]. Неадекватная оценка рисков может привести к развитию абдоминального компартмент-синдрома.

В настоящее время отсутствует стандартизированный подход для количественной оценки характеристик

## AUTOMATIC DETERMINATION OF KEY PARAMETERS FOR PREDICTING THE TACTICS OF SURGICAL TREATMENT OF VENTRAL HERNIAS USING DEEP LEARNING

Balyura O.V.<sup>1</sup>, Grebeniuk E.A.<sup>2</sup>, Eselevich R.V.<sup>1</sup>, Akbashev R.A.\*<sup>1</sup>, Surov D.A.<sup>1</sup>

<sup>1</sup> S.M.Kirov Military Medical Academy, St. Petersburg

<sup>2</sup> Saint-Petersburg State Marine Technical University, St. Petersburg

**Abstract.** Rationale: The choice of surgical treatment tactics for postoperative ventral hernias (PVH) is still based on a subjective visual assessment of computed tomography (CT) examinations by a surgeon, which leads to variability of solutions and lack of standardization. There are no approved software packages for automatic analysis of the anatomy of the anterior abdominal wall.

Objective: To develop a method for the automatic calculation of key surgical parameters (RDR, hernial sac volume) based on the semantic segmentation of the structures of the anterior abdominal wall using the convolutional neural network U-Net to objectify preoperative planning.

Methods: A retrospective single-center study was conducted based on data from 25 patients with PVH of categories W2–W3 (2024–2025). Manual segmentation of the right and left rectus abdominis muscles and hernial sac on CT sections was performed. The U-Net model was trained with a Focal Loss function and data augmentation. Based on the segmentation results, the algorithm automatically calculated the RDR (Rectus Diastasis Ratio) parameter and the volume of the hernial sac, forming a prognostic conclusion about the need for a component separation technique (CST).

Results: The model demonstrated stable learning (validation losses: 0,0015). The segmentation quality of the hernial sac was 74,9%. The automatic calculation of RDR allowed us to correctly classify treatment tactics for all patients: with RDR > 1,5, simple plastic surgery is recommended (40% of patients), with RDR < 1,5 – CST (60% of patients). The analysis time is reduced to 2–3 minutes per patient versus 30–60 minutes for manual assessment.

Conclusion: The proposed method based on the U-Net convolutional neural network makes it possible to automatically identify key structures of the anterior abdominal wall on CT images. This creates the basis for the development of decision support systems capable of quantifying hernial defect parameters and objectifying preoperative planning.

**Keywords:** ventral hernia, deep learning, preoperative planning, semantic segmentation, artificial intelligence in surgery.

мышечно-апоневротического слоя передней брюшной стенки [5]. Выбор тактики, включая применение техники разделения компонентов (CST), основывается на субъективной интерпретации КТ-изображений, что приводит к вариативности решений [5; 6]. Стандартные радиологические заключения часто не содержат ключевых количественных метрик.

Одними из ключевых параметров, определяющими хирургическую тактику, являются:

1. Степень диастаза прямых мышц живота;
2. Морфологическое состояние мышечной ткани;

\* e-mail: renat1995@yandex.ru

### 3. Соотношение объема грыжевого мешка к объему брюшной полости.

Стремительное развитие технологий искусственного интеллекта (ИИ), в частности методов глубокого обучения (Deep Learning), кардинально меняет принцип анализа медицинских изображений. В контексте данной проблемы наиболее перспективным направлением является семантическая сегментация – задача точного пиксельного разделения изображения на смысловые области (например: прямые мышцы, грыжевой мешок, брюшная полость).

Методы глубокого обучения, в частности семантическая сегментация, позволяют автоматически анализировать медицинские изображения. Сверточные нейронные сети (CNN) эффективно выявляют пространственные признаки в изображениях. Архитектура U-Net, созданная для биомедицинской сегментации, демонстрирует высокую эффективность даже на ограниченных наборах данных [7; 8]. Ее симметричная структура позволяет точно локализовать границы объектов, что критически важно для выделения мышечных структур и контуров грыжи.

### Цель

Разработка метода автоматического определения и расчета ключевых прогностических параметров для прогнозирования тактики лечения на основе семантической сегментации структур передней брюшной стенки с использованием сверточной нейронной сети U-Net.

### Материалы и методы

Проведено ретроспективное одноцентровое исследование на основе данных пациентов с ПОВГ категории W2-W3 по классификации European Hernia Society [9]. В исследование включены 25 пациентов, проходивших лечение в 2024–2025 гг. Критерием включения являлось наличие подтвержденной ПОВГ W2-W3 (Рис. 1). Всем пациентам выполнялась КТ органов грудной клетки, брюшной полости и малого таза. Формирование когорты и сбор данных проводились на базе кафедры Военно-морской хирургии ФГБВОУ ВО «Военно-медицинская академия имени С.М. Кирова».

КТ-исследования выполнялись на томографах с реконструкцией аксиальных срезов толщиной 1 мм. Для обеспечения единообразия данных и повышения стабильности обучения нейронной сети все КТ-изображения были приведены к единому воксельному размеру и подвергнуты нормализации интенсивности сигнала в диапазон, оптимальный для визуализации мягких тканей.

Формирование эталонного набора данных для обучения и валидации модели являлось ключевым этапом. Для каждого пациента в программе 3D Slicer с использованием инструмента «Round Brush» была выполнена послойная ручная сегментация на КТ-срезах. Разметка включала три анатомических класса (Рис. 2):

1. Правая прямая мышца живота (right\_muscle);
2. Левая прямая мышца живота (left\_muscle);
3. Грыжевой мешок (hernia\_sac).



Рис. 1. Внешний вид пациента с большой ПОВГ (категория W3).

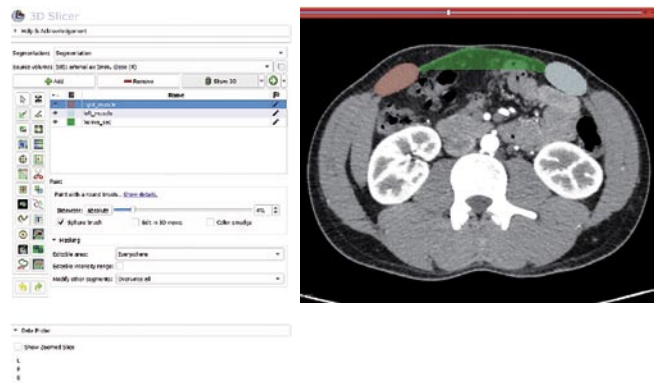


Рис. 2. Пример ручной сегментации структур передней брюшной стенки у пациента с ПОВГ в программе 3D Slicer.

Результаты ручной сегментации были независимо верифицированы опытным хирургом.

Для решения задачи семантической сегментации была выбрана сверточная нейронная сеть U-Net, хорошо зарекомендовавшая себя в задачах биомедицинской визуализации [9; 10]. Для компенсации дисбаланса классов, характерного для задач сегментации (когда целевые структуры, такие как мышцы, занимают малую часть изображения), была применена функция потерь Focal Loss. Данная функция позволяет модели уделять больше внимания сложным для классификации примерам, что повышает точность сегментации малых объектов.

Процесс обучения проводился с использованием оптимизатора Adam с начальной скоростью обучения  $1e-4$ . Для повышения обобщающей способности модели применялись методы аугментации данных, включая случайные повороты, отражения и незначительные изменения контрастности изображений. Выборка была разделена на обучающую и валидационную для мониторинга процесса обучения и предотвращения переобучения. Все этапы исследования были выполнены

с использованием языка программирования Python 3.9 и библиотек для научных вычислений: NumPy, PyDICOM, Scikit-learn, Matplotlib. Статистический анализ включал описательную статистику для характеристики выборки и визуальную оценку кривых обучения для анализа динамики функции потерь.

## Результаты

Процесс обучения сверточной нейронной сети U-Net с применением функции Focal Loss показал высокую эффективность и стабильную сходимость. Наблюдалось монотонное снижение значений функции потерь на тренировочной и на валидационной выборках (Рис. 3). К окончанию обучения значение функции потерь на валидации достигло 0,0015, что свидетельствует об успешной минимизации ошибки предсказания. Важным результатом является отсутствие признаков переобучения, что подтверждается параллельной динамикой кривых обучения и валидации, и указывает на хорошую обобщающую способность модели, достигнутую несмотря на ограниченный объем исходной выборки.

Качественный анализ результатов сегментации продемонстрировал способность модели точно идентифицировать и выделять целевые анатомические структуры. Визуальная оценка масок сегментации показала точное соответствие контуров правой и левой прямых мышц живота, грыжевого мешка их эталонным аналогам, созданным вручную.

Для объективной количественной оценки эффективности сегментации было проведено распределение предсказаний модели на валидационных данных (Рис. 4). Анализ показал, что грыжевой мешок был корректно идентифицирован в 74,9% случаев. Доля корректно сегментированных прямых мышц живота в совокупности составила 22,8%. На долю фона пришлось 2,3%. Полученные результаты свидетельствуют о высоком качестве сегментации грыжевого мешка, что является критически важным для последующего точного расчета его объема и отношения к объему брюшной полости. Несколько более низкий показатель сегментации мышечных структур (22,8%) объясняется их меньшей относительной площадью на срезе и сложностью точного определения границ при выраженном диастазе.

Разработанный алгоритм постобработки продемонстрировал высокую эффективность в автоматизации расчета клинически значимых показателей. Алгоритм успешно для каждого пациента выполнил следующие действия:

1. Проводил перебор всех КТ-срезов пациентов и корректно идентифицировал аксиальный срез с максимальным диастазом прямых мышц живота;
2. Вычислил морфометрические показатели такие как максимальный диастаз, суммарную толщину прямых мышц на уровне максимального диастаза, а также объем грыжевого мешка и его отношение к объему брюшной полости;

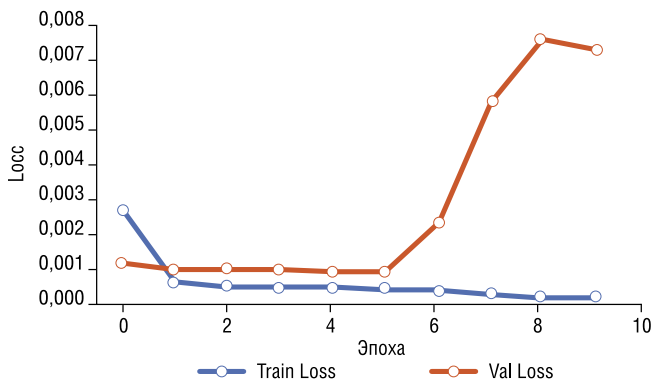


Рис. 3. Динамика функции потерь в процессе обучения модели.




Рис. 4. Распределение предсказаний на валидационных данных.

3. Рассчитал интегральный прогностический показатель RDR (Rectus Diastasis Ratio) для всех пациентов в когорте.

В качестве наглядного примера на Рис. 5 представлен детальный хирургический отчет, автоматически сгенерированный системой для пациента с ПОВГ. Отчет включает:

- Визуализацию результатов сегментации на аксиальном срезе 240 (срез с максимальным диастазом) с цветовым кодированием анатомических структур: левая прямая мышца (красный), правая прямая мышца (синий), грыжевой мешок (зеленый);
- Количественные измерения: ширину грыжевых ворот (223,3 мм), ширину отдельных мышечных структур (левая мышца – 50,3 мм и правая мышца – 39,3 мм);
- Анализ отношения объемов брюшной полости (64,1%) и грыжевого мешка (35,9%);
- На основании ширины грыжевых ворот выдается хирургическая оценка необходимости установки сетки пациенту;
- Расчет прогностического индекса RDR по формуле

$$\frac{(L_m + R_m)}{W_r},$$

где:  $L_m$  – левая прямая мышца,  $R_m$  – правая прямая мышца,  $W_r$  – ширина грыжевых ворот, и автоматическое формирование тактики лечения на основе заданных пороговых




Рис. 5. Детальный хирургический отчет о пациенте.

значений. В данном случае, система выдала заключение: «RDR > 1,5: нет. CST», что корректно указывает на показания к технике разделения компонентов для данного пациента.

Данный пример комплексно иллюстрирует способность системы не только выполнять точную сегментацию, но и предоставлять развернутую количественную оценку, достаточную для принятия обоснованного клинического решения.

Ключевым результатом исследования является успешная валидация автоматизированного прогностического контура на основе рассчитанного параметра RDR. Применение заранее заданных пороговых значений, основанных на клинических рекомендациях, позволило алгоритму автоматически сгенерировать заключения о предполагаемой хирургической тактике для каждого пациента.

Анализ данных по всей когорте выявил четкую корреляцию между значениями RDR и клинико-анатомическими характеристиками. Так, у пациентов с сохраненной мышечной массой и умеренным диастазом алгоритм рассчитывал значения RDR > 1,5 (40%). В этих случаях система автоматически рекомендовала проведение простой пластики, что объективно соответствовало благоприятным анатомическим условиям для закрытия дефекта без дополнительной техники.

У пациентов с выраженным диастазом и редуцированной толщиной прямых мышц алгоритм определял значения RDR < 1,5 (60%). Для данной группы было сгенерировано заключение о необходимости приме-

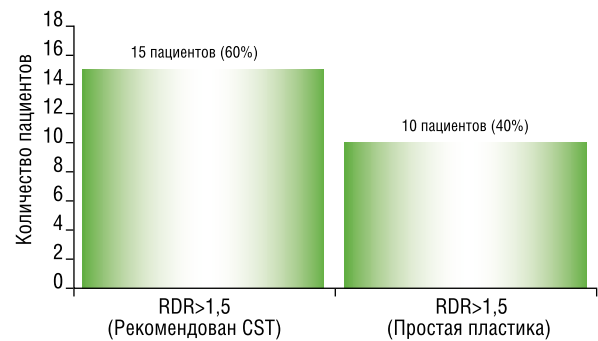


Рис. 6. Распределение пациентов по хирургической тактике на основе RDR.

ния техники разделения компонентов (CST). Данная рекомендация полностью соответствовала экспертному клиническому прогнозу, основанному на анализе тех же КТ-изображений (Рис. 6).

Таким образом, система обеспечивает не только точную сегментацию, но и комплексную аналитическую обработку данных с формированием клинически значимых заключений, объективизируя предоперационное планирование.

Сравнительный анализ временных затрат продемонстрировал значительное преимущество предложенного метода. Система выполняет полный анализ за 2–3 минуты вместо 30–60 минут при ручной оценке. Это подтверждает ее потенциал для интеграции в клиническую практику с целью оптимизации времени работы специалиста и стандартизации планирования операций.

## Обсуждение

Проведенное исследование демонстрирует потенциал глубокого обучения для автоматизации предоперационного планирования у пациентов с ПОВГ. Разработанная система на основе U-Net показала способность не только к точной семантической сегментации ключевых анатомических структур передней брюшной стенки, но и к формированию обоснованного прогностического заключения на основе параметра RDR.

В отличие от работ, сфокусированных на анализе исходов, наше исследование предлагает решение для этапа предоперационного планирования. Ключевое преимущество метода – стандартизация процесса принятия решений за счет количественной метрики RDR, интегрирующей информацию о степени диастаза и состоянии мышечной ткани.

Полученное распределение пациентов (60% с рекомендацией CST и 40% с рекомендацией простой пластики) подтверждает клиническую релевантность критерия RDR = 1,5. Важно отметить, что автоматизированное заключение в детальном отчете (Рис. 5) полностью соответствовало бы решению опытного хирурга, что свидетельствует о том, что система дополняет и усиливает эксперта, а не заменяет его.

Основным ограничением данного исследования является объем выборки (n = 25). В дальнейшем плани-

руется расширение датасета и валидация метода на независимой когорте с оценкой хирургических исходов.

## Выводы

Разработанная система на основе сверточной нейронной сети U-Net продемонстрировала способность точно сегментировать ключевые структуры передней брюшной стенки и автоматически вычислять клинически значимые параметры.

Главным достижением работы стала разработка и клиническая валидация интегрального показателя RDR, позволяющего количественно оценить анатомические условия для выбора хирургической тактики. Пороговое значение  $RDR < 1,5$  создает унифицированный стандарт для принятия решений о применении CST.

Практическая ценность системы подтверждается высокой точностью сегментации грыжевого мешка (74,9%) и значительным сокращением времени анализа. Полученные результаты создают основу для разработки систем поддержки принятия врачебных решений в герниологии.

**Авторы заявляют об отсутствии конфликта интересов (The authors declare no conflict of interest).**

## ЛИТЕРАТУРА/REFERENCES

1. Bosanquet DC, Ansell J, Abdelrahman T, et al. Systematic Review and Meta-Regression of Factors Affecting Midline Incisional Hernia Rates: Analysis of 14,618 Patients. *PLoS One*. 2015; 10(9): e0138745. doi: 10.1371/journal.pone.0138745.
2. Павелец К.В., Вавилова О.Г., Лобанов М.Ю. и др. Особенности предоперационной подготовки у пациентов с обширными и гигантскими послеоперационными вентральными грыжами // Вестник Санкт-Петербургской медицинской академии последипломного образования. – 2011. – Т.3 – №2. – С.32-36. [Pavelets KV, Vavilova OG, Lobanov MYu, et al. Features of preoperative preparation in patients with extensive and giant postoperative ventral hernias. *Vestnik Sankt-Peterburgskoj medicinskoj akademii poslediplomnogo obrazovaniya*. 2011; 3(2): 32-36. (In Russ.)]
3. Тимербулатов Ш.В., Абдуллин У.М., Викторов В.В. и др. Интраабдоминальная гипертензия и абдоминальный компартмент-синдром. Обзор литературы // Креативная хирургия и онкология. – 2024. – Т.14 – №2. – С.174-179. [Timerbulatov ShV, Abdullin UM, Viktorov VV, et al. Intra-abdominal hypertension and abdominal compartment syndrome. Literature review. *Kreativnaya khirurgiya i onkologiya*. 2024; 14(2): 174-179. (In Russ.)] doi: 10.24060/2076-3093-2024-14-2-174-179.
4. Лукоянычев Е.Е., Измайлов С.Г., Евсюков Д.А. и др. Возможности воздействия на системный уровень воспаления в острую фазу после протезирующей пластики брюшной стенки // Вестник НМЦХ им. Н.И. Пирогова. – 2022; 17(3): 53-58. [Lukoynychyev EE, Izmajlov SG, Evsyukov DA, et al. Possibilities of influencing the systemic level of inflammation in the acute phase after abdominal wall prosthetic surgery. *Vestnik NMCzX im. N.I. Pirogova*. 2022; 17(3): 53-58. (In Russ.)] doi: 10.25881/2078255\_2022\_17\_3\_53.
5. Ермолов А.С., Коршовили В.Т., Благовестнов Д.А. // Послеоперационные вентральные грыжи – нерешенные вопросы хирургической тактики // Журнал им. Н.И. Пирогова. – 2018. – №10. – С.81-86. [Ermolov AS, Koroshvili VT, Blagovestnov DA. Postoperative ventral hernias – unresolved issues of surgical tactics. *Zhurnal im. N.I. Pirogova*. 2018; 10: 81-86. (In Russ.)] doi: 10.17116/hirurgia201810181.
6. Кульберг Н.С., Решетников Р.В., Новик В.П. и др. Вариабельность заключений при интерпретации КТ-снимков: один за всех и все за одного // Digital Diagnostics. – 2021. – Т.2 – №2. – С.105-118. [Kul'berg NS, Reshetnikov RV, Novik VP, et al. Variability in CT interpretation: one for all and all for one. *Digital Diagnostics*. 2021; 2(2): 105-118. (In Russ.)] doi: 10.17816/DD60622.
7. Wang R, Mu Z, Wang J, et al. ASF-LKUNet: Adjacent-scale fusion U-Net with large kernel for multi-organ segmentation. *Comput Biol Med*. 2024; 181: 109050. doi: 10.1016/j.combiomed.2024.109050.
8. Qin H, Long Y, Shengwei T, Cheng Z, YingYing Y, Lei Z. SEDyConv: Spatially enhanced multi-dimensional dynamic convolution for medical multi-organ segmentation in CTs. *Knowledge-Based Systems*. 2025; 323: 113707. doi: 10.1016/j.knsys.2025.113707.
9. Muysoms FE, Miserez M, Berrevoet F, et al. Classification of primary and incisional abdominal wall hernias. *Hernia*. 2009; 13(4): 407-14. doi: 10.1007/s10029-009-0518-x.
10. Нуднов Н.В., Коробов А.В., Скачков А.А. и др. Оценка качества работы искусственного интеллекта в выявлении дегенеративных заболеваний пояснично-крестцового отдела позвоночника // Вестник рентгенологии и радиологии. – 2024. – Т.105 – №1. – С.20-28. [Nudnov NV, Korobov AV, Skachkov AA, et al. Evaluation of the performance of artificial intelligence in identifying degenerative diseases of the lumbosacral spine. *Vestnik rentgenologii i radiologii*. 2024; 105(1): 20-28. (In Russ.)] doi: 10.20862/0042-4676-2024-105-1-20-28.