

УДК 004.932.2

DOI: [10.26102/2310-6018/2025.48.1.040](https://doi.org/10.26102/2310-6018/2025.48.1.040)

Сегментация объемных образований печени на мультифазных КТ-изображениях с использованием фреймворка nnU-Net

А.А. Куликов¹, И.Л. Каширина¹, Е.Ф. Савкина²

¹МИРЭА – Российский технологический университет, Москва, Российская Федерация

²Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы, Москва, Российская Федерация

Резюме. В статье представлено исследование, посвященное применению фреймворка nnU-Net (v2) для автоматической сегментации и классификации объемных образований печени на компьютерной томографии органов брюшной полости. Основное внимание уделено влиянию размера батча и использования данных разных фаз контрастирования на точность классификации таких образований, как киста, гемангиома, карцинома и фокальная нодулярная гиперплазия (ФНГ). В ходе экспериментов были использованы размеры батча 2, 3 и 4, а также данные из двух фаз контрастного усиления – артериальной и портально-венозной. Результаты показали, что оптимальный размер батча составляет 3 или 4, в зависимости от патологии, а использование данных с двух фаз контрастирования значительно улучшает точность и чувствительность классификации объемных образований, особенно для карцином и кист. Достигнутые наилучшие показатели чувствительности составили 100 % для карцином, 94 % для кист, 81% для гемангиом и 84% для ФНГ. Статья подтверждает эффективность применения nnU-Net v2 для решения задач сегментации и классификации медицинских изображений, а также подчеркивает важность выбора правильных параметров обучения и данных для достижения наилучших результатов в медицинской диагностике.

Ключевые слова: nnU-Net v2, компьютерная томография, образования печени, размер батча, сегментация, классификация, медицинские изображения, фазы контрастирования, карцинома.

Благодарности: Статья подготовлена в рамках НИОКР «Разработка платформы повышения качества ИИ-Сервисов для медицинской диагностики» (№ ЕГИСУ: 123031400006-0) в соответствии с Приказом от 21.12.2022 г. № 1196 «Об утверждении государственных заданий, финансовое обеспечение которых осуществляется за счет средств бюджета города Москвы, государственным бюджетным (автономным) учреждениям, подведомственным Департаменту здравоохранения города Москвы, на 2023 год и плановый период 2024 и 2025 годов» Департамента здравоохранения города Москвы.

Для цитирования: Куликов А.А., Каширина И.Л., Савкина Е.Ф. Сегментация объемных образований печени на мультифазных КТ-изображениях с использованием фреймворка nnU-Net. *Моделирование, оптимизация и информационные технологии.* 2025;13(1). URL: <https://moitvivr.ru/ru/journal/pdf?id=1853> DOI: 10.26102/2310-6018/2025.48.1.040

Segmentation of liver volumetric lesions in multiphase CT images using the nnU-Net framework

A.A. Kulikov¹, I.L. Kashirina¹, E.F. Savkina²

¹MIREA – Russian Technological University, Moscow, the Russian Federation

²Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department, Moscow, the Russian Federation

Abstract. The article presents a study on the application of the nnU-Net (v2) framework for automatic segmentation and classification of liver space-occupying lesions on abdominal computed tomography. The main attention is paid to the effect of the batch size and the use of data from different contrast phases on the classification accuracy of such lesions as cysts, hemangiomas, carcinomas, and focal nodular hyperplasia (FNH). During the experiments, batch sizes of 2, 3, and 4 were used, as well as data from two contrast phases – arterial and venous. The results showed that the optimal batch size is 3 or 4, depending on the pathology, and the use of data from two contrast phases significantly improves the accuracy and sensitivity of space-occupying lesions classification, especially for carcinomas and cysts. The achieved best sensitivity rates were 100% for carcinomas, 94% for cysts, 81% for hemangiomas, and 84% for FNH. The paper confirms the effectiveness of nnU-Net v2 for solving medical image segmentation and classification problems and highlights the importance of choosing the right training parameters and data to achieve the best results in medical diagnostics.

Keywords: nnU-Net v2, CT images, liver pathologies, batch size, segmentation, classification, medical images, contrast phases, carcinoma.

Acknowledgements: This paper was prepared as a part of the research and development effort titled "Development of a platform for improving the quality of AI services for clinical diagnostics" (USIS No.: 123031400006-0) in accordance with the Order No. 1196 dated December 21, 2022 "On approval of state assignments funded by means of allocations from the budget of the city of Moscow to the state budgetary (autonomous) institutions subordinate to the Moscow Health Care Department, for 2023 and the planned period of 2024 and 2025" issued by the Moscow Health Care Department.

For citation: Kulikov A.A., Kashirina I.L., Savkina E.F. Segmentation of liver volumetric lesions in multiphase CT images using the nnU-Net framework. *Modeling, Optimization and Information Technology*. 2025;13(1). (In Russ.). URL: <https://moitvvt.ru/ru/journal/pdf?id=1853> DOI: 10.26102/2310-6018/2025.48.1.040

Введение

Компьютерная томография (КТ) является одним из ключевых методов диагностической визуализации, ежедневно генерирующим огромные объемы данных в виде многослойных изображений. Врачам-рентгенологам необходимо анализировать сотни срезов для каждого пациента, что делает процесс диагностики патологий в органах трудоемким и потенциально подверженным ошибкам. Особенно это касается КТ-изображений печени, которая является крупным внутренним органом, имеет восемь анатомических сегментов. Современные методы искусственного интеллекта (ИИ) и машинного обучения предлагают эффективное решение этой проблемы через автоматическую обработку КТ-снимков. Применение нейронных сетей для классификации и сегментации изображений печени не только ускоряет процесс анализа, но и помогает выявлять мельчайшие патологические изменения, которые могут быть пропущены при визуальном осмотре, что существенно повышает точность диагностики заболеваний печени. Так, например, исследователи в работе [1] продемонстрировали эффективность применения глубоких сверточных нейронных сетей архитектуры U-Net для выявления патологий печени на КТ-изображениях, достигнув точности 89 % на небольшом наборе данных. В работе [2] рассматриваются различные подходы к улучшению базовой архитектуры U-Net, используемой для сегментации медицинских изображений. Основное внимание уделяется модификациям, направленным на повышение точности и устойчивости моделей при работе с медицинскими данными. Особый интерес представляет работа [3], где исследовалось влияние использования данных мультифазного контрастирования на точность сегментации опухолей печени.

Фреймворк nnU-Net, представленный в работах [4, 5], зарекомендовал себя как надежное решение для различных задач медицинской сегментации, демонстрируя state-of-the-art результаты на множестве наборов данных. Однако влияние параметров

обучения и особенностей входных данных на производительность этого фреймворка при сегментации патологий печени остается недостаточно изученным.

Целью данного исследования является оценка эффективности фреймворка nnU-Net v2 для автоматической сегментации патологий печени на КТ-изображениях с контрастным усилением. В частности, исследуется влияние числа эпох и размера батча на стабильность обучения и конечную точность модели, а также анализируется роль различных фаз контрастного усиления в повышении качества сегментации. Полученные результаты могут быть использованы для оптимизации параметров обучения подобных моделей и улучшения их практического применения в клинической практике.

Материалы и методы

Фреймворк nnU-Net основан на сверточной сети архитектуры U-Net, разработанной в 2015 году исследователями из Университета Фрайбурга [6]. U-Net была изначально предназначена для сегментации медицинских изображений, особенно в задачах, где объем доступных данных ограничен, что часто встречается в медицинской области. U-Net часто используется для сегментации органов и различных патологий на изображениях, полученных с использованием методов КТ, МРТ [7].

Архитектура U-Net, получившая свое название благодаря характерной U-образной форме, состоит из двух основных частей: энкодера и декодера, связанных между собой остаточными соединениями (skip connections). Энкодер включает последовательность сверточных слоев, объединенных с max-pooling операциями, что обеспечивает постепенное уменьшение пространственного разрешения. В свою очередь, декодер выполняет обратную задачу, восстанавливая пространственное разрешение посредством применения операций обратных сверток. Важной особенностью U-Net являются остаточные соединения, которые передают информацию напрямую из энкодера в декодер, соединяя соответствующие слои обеих частей сети. Это предотвращает потерю важных деталей во время сжатия данных и значительно улучшает качество восстановления мелких объектов [8]. Архитектура U-Net отличается универсальностью применения: помимо медицинской визуализации, она успешно используется в различных областях, включая сегментацию спутниковых снимков и обнаружение дефектов на различных поверхностях [9].

В 2019 году был разработан фреймворк nnU-Net [4] для автоматизированной настройки архитектуры и гиперпараметров модели U-Net. Фреймворк стал важным инструментом в медицинской визуализации, т. к. позволяет использовать преимущества U-Net для различных типов данных без необходимости ручного подбора параметров. Фреймворк автоматически анализирует данные, выбирает оптимальные настройки для обучения. Одной из ключевых особенностей фреймворка является автоматическая адаптация параметров U-Net, таких как глубина сети, размер свертки, размер входного изображения и т. д., в зависимости от особенностей обучающего набора данных. nnU-Net автоматически настраивает предобработку, включая нормализацию и аугментацию изображений. Фреймворк подходит как для 2D, так и для 3D изображений, к которым можно отнести КТ и МРТ снимки. Для каждого типа данных создается своя оптимальная конфигурация. Благодаря инкапсулированным процессам предобработки, обучения, и прогнозирования, фреймворк nnU-Net на сегодняшний день является одним из стандартов медицинской сегментации.

Архитектура фреймворка nnU-Net представлена на Рисунке 1. К ее особенностям относится то, что она автоматически учитывает физический размер вокселей (трехмерных пикселей) для каждого типа данных и использует как обычные свертки, так и анизотропные свертки для 3D данных.

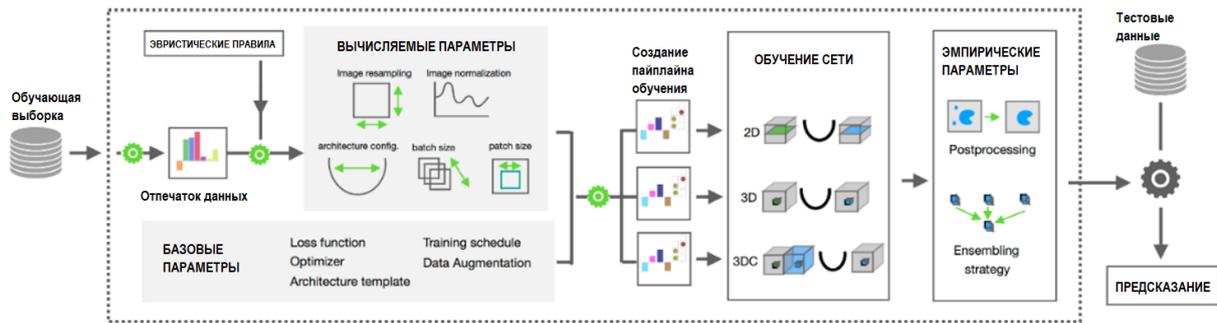


Рисунок 1 – Архитектура nnU-Net
 Figure 1 – nnU-Net architecture

Фреймворк nnU-Net предлагает три основных типа моделей. Модель 2D работает со срезами трехмерных изображений по отдельности, обрабатывая их как двумерные изображения. Она требует меньше вычислительных ресурсов и хорошо подходит для задач, в которых контекст в плоскости среза важнее объемного контекста. Модель 3D full resolution (3d_fullres) обрабатывает полноразмерные трехмерные патчи, сохраняя исходное разрешение изображений. Эта модель способна захватывать полный объемный контекст, однако требует больше памяти GPU. Третий вариант – модель low resolution, которая работает с уменьшенным разрешением входных данных. Это позволяет ей обрабатывать большие патчи при тех же требованиях к памяти и захватывать более широкий контекст за счет увеличенного поля обзора. Однако такой подход может приводить к потере деталей из-за пониженного разрешения. Часто эта модель используется в каскадном (3DC) режиме совместно с full resolution версией.

Несмотря на то, что nnU-Net – это архитектура, которая автоматически адаптируется к специфике данных, исследования [3, 10] подтверждают, что использование данных из разных фаз контрастного усиления может значительно улучшить обнаружение объемных образований на КТ снимках, а исследование по изменению размера батча [9] показывает, что он влияет на скорость обучения и качество результатов. Поэтому в данном исследовании была предпринята попытка ручной настройки некоторых важных параметров nnU-Net с целью повышения качества сегментации и классификации патологий.

Для экспериментов использовались данные мультифазных КТ-снимков печени, предоставленные Центром диагностики и телемедицины (ЦДиТ)¹. Снимки были размечены специалистами для сегментации четырех классов патологий: киста; гемангиома; карцинома; фокальная нодулярная гиперплазия (ФНГ). В Таблице 1 показан состав обучающей и тестовой выборки. Набор данных состоял из компьютерных томограмм брюшной полости, где каждое КТ-исследование включало серию аксиальных срезов с экспертной разметкой целевых патологических изменений. Общий объем выборки составил 643 исследования, из которых 401 было отнесено к обучающему набору и 242 – к тестовому. В обоих наборах присутствовали как случаи с единичными патологиями, так и с их сочетанием, при этом по 100 исследований в каждом наборе не содержали патологических изменений (норма). Для повышения диагностической точности анализировались две фазы контрастного усиления: артериальная (ART – arterial phase) и портально-венозная (PV – portal venous phase). Артериальная фаза (ART) – изображения, полученные через 25–30 секунд после введения контрастного препарата. Портально-венозная фаза (PV) – изображения, полученные через 60–70 секунд после

¹ Васильев Ю.А., Арзамасов К.М., Пестренин Л.Д. и др. MosMedData: КТ с наличием и отсутствием признаков образований печени и их сегментацией: заявл. 13.12.2024; опубл. 18.12.2024. Свидетельство о государственной регистрации базы данных № 2024626116.

внутривенного введения контрастного вещества. Эти фазы наиболее информативны для выявления очаговых образований печени.

Таблица 1 – Обучающая и тестовая выборки
Table 1 – Training and test samples

Патология	Обучающая выборка	Тестовая выборка
Патологии отсутствуют	100	100
Киста	107	55
Гемангиома	65	32
Карцинома (ГЦК, HCR)	108	51
ФНГ	55	32

Тестируемые настройки включали количество эпох (1000, 1200), используемую фазу для каждого изображения (ART или PV) и размер батча (2, 3, 4). В исследовании сравниваются модели 3d_fullres и 2D. Для 3d_fullres модели тестировались размеры батча 2, 3 и 4 (рекомендуемый фреймворком размер – 2). Для 2D модели использовался размер батча 12, рекомендованный фреймворком для этой конфигурации. Для каждой настройки проводились эксперименты для двух фаз. Модели были обучены на графическом процессоре (GPU) H100. Изображения предварительно были обрезаны с использованием маски печени, (полученной отдельной моделью сегментации) и прошли регистрацию (совмещение фаз контрастирования) с помощью библиотеки itk-elastix. Эти преобразования позволили улучшить обучение за счет использования предварительно обрезанных и совмещенных изображений, что снижает влияние ненужных областей и фокусирует модель на целевых объектах. Для обучения модели 3d_fullres использовалось 8гб памяти GPU. Время обучения каждой модели составляло примерно 48 часов, что связано с большими размерами файлов, представляющих каждое КТ-исследование.

Результаты

В Таблице 2 представлены результаты проведенных экспериментов с моделью 3d_fullres с разным размером батча на разных фазах, в течение 1000 эпох, рекомендуемых фреймворком по умолчанию. Как можно увидеть, наивысшая точность классификации (Accuracy) достигается для карциномы – до 0,908. Лучшие показатели чувствительности (Sensitivity) также у карциномы – до 1,000 в некоторых моделях. Специфичность (Specificity) наиболее высока у ФНГ – до 0,927. В целом, модели показывают достаточно высокую эффективность. Согласно ГОСТ², модель имеет приемлемое качество, ее можно использовать, если ее метрики точности, чувствительности и специфичности превосходят 0,81.

При анализе эффективности фаз ART и PV для различных патологий можно отметить следующие закономерности. Для кистозных образований ART фаза демонстрирует более высокие показатели точности и специфичности, а PV фаза обеспечивает несколько лучшую чувствительность. В целом для диагностики кист более предпочтительным является использование ART фазы. В случае гемангиом заметно преимущество PV фазы, особенно в отношении чувствительности, что делает ее оптимальным выбором для диагностики данной патологии. При диагностике карциномы обе фазы демонстрируют высокие показатели эффективности, но PV фаза обеспечивает лучшие результаты по чувствительности, а ART фаза может давать более высокую

² Национальный стандарт РФ ГОСТ Р 59921.1-2022. Системы искусственного интеллекта в клинической медицине. Часть 1. Клиническая оценка (утв. и введен в действие приказом Федерального агентства по техническому регулированию и метрологии от 28 июня 2022 г. N 545-ст). Москва: Российский институт стандартизации; 2022. 14 с.

специфичность. Для ФНГ более предпочтительной оказывается ART фаза, которая обеспечивает более стабильные результаты и лучшую специфичность. В целом можно заключить, что ART фаза наиболее эффективна для диагностики кист и ФНГ, в то время как PV фаза показывает лучшие результаты при выявлении гемангиом и карцином.

Таблица 2 – Результаты сегментации патологий (размер батча 2, 3 и 4)
Table 2 – Pathology segmentation results (batch size 2, 3, and 4)

Модель	Патология	Батч	Accuracy	Sensitivity	Specificity
1, фаза ART	Киста	2	0,852	0,836	0,857
	Гемангиома	2	0,857	0,781	0,849
	Карцинома	2	0,903	0,940	0,893
	ФНГ	2	0,869	0,781	0,883
2, фаза ART	Киста	3	0,848	0,818	0,857
	Гемангиома	3	0,831	0,750	0,844
	Карцинома	3	0,882	0,940	0,866
	ФНГ	3	0,899	0,812	0,912
3, фаза ART	Киста	4	0,857	0,800	0,874
	Гемангиома	4	0,844	0,719	0,863
	Карцинома	4	0,882	0,940	0,866
	ФНГ	4	0,878	0,781	0,893
4, фаза ART	Киста	3	0,835	0,836	0,835
	Гемангиома	3	0,806	0,812	0,805
	Карцинома	3	0,857	0,960	0,829
	ФНГ	3	0,819	0,844	0,815
4, фаза PV	Киста	3	0,840	0,945	0,809
	Гемангиома	3	0,790	0,688	0,806
	Карцинома	3	0,903	1,000	0,877
	ФНГ	3	0,782	0,688	0,796
5, фаза ART	Киста	4	0,890	0,818	0,912
	Гемангиома	4	0,814	0,812	0,815
	Карцинома	4	0,882	0,960	0,861
	ФНГ	4	0,861	0,750	0,878
5, фаза PV	Киста	4	0,857	0,927	0,836
	Гемангиома	4	0,815	0,688	0,835
	Карцинома	4	0,908	1,000	0,882
	ФНГ	4	0,874	0,531	0,927

Таким образом, для достижения максимальной точности диагностики предпочтительнее использовать комбинированный подход с применением обеих фаз исследования. На Рисунке 2 проиллюстрирован пример различия в результатах сегментации карциномы на ART (слева) и PV (в центре) фазах.

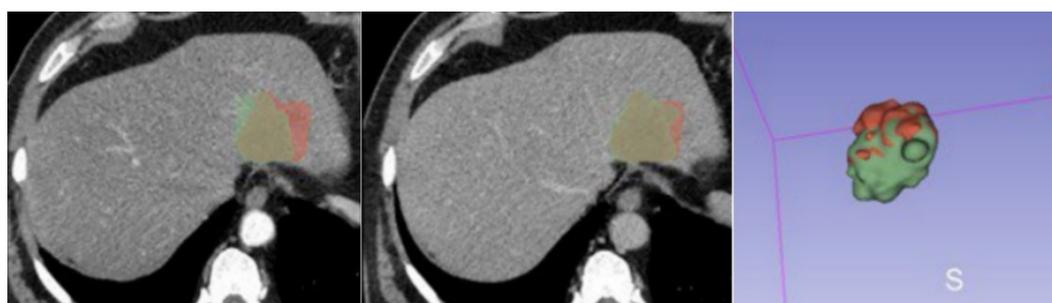


Рисунок 2 – Сравнение предсказаний модели на фазах ART и PV
Figure 2 – Comparison of model predictions in the ART and PV phases

Красным выделена истинная разметка, зеленым – предсказание модели. Справа найденная патология изображена в 3D формате. Видно, что на фазе PV предсказание модели оказалось точнее.

На Рисунке 3 в качестве иллюстрации показана разница значений метрики ROC-AUC для модели 5 при использовании данных одних и тех же исследований с разных фаз контрастирования.

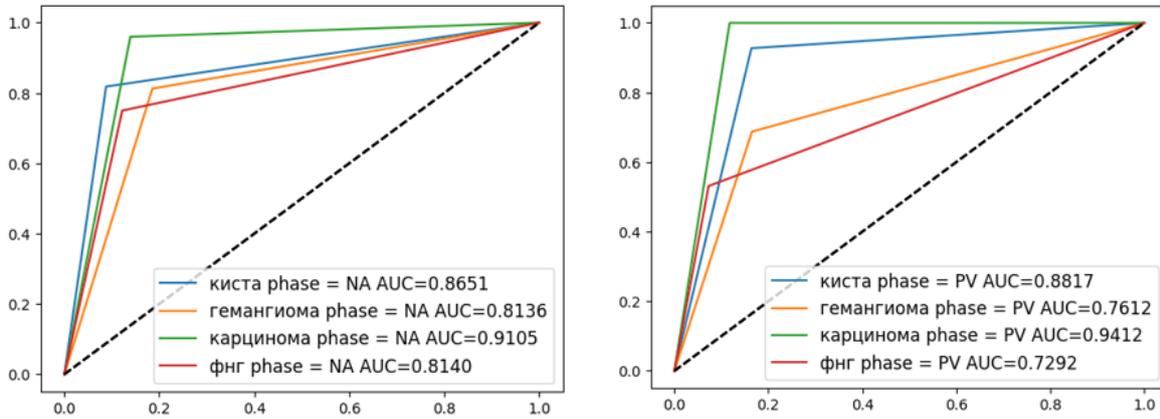


Рисунок 3 – Метрика ROC-AUC для модели 5
Figure 3 – ROC-AUC metric for model 5

Что касается влияния размера батча, то можно заметить, что удовлетворяющие требованиям ГОСТ значения метрик по каждой патологии достигаются при размерах батча 3 и 4, что говорит о том, что изменение данного параметра (по сравнению с настройками, автоматически задаваемыми архитектурой nnU-Net) может привести к улучшению метрик.

В Таблице 3 представлены результаты 2D модели, с настройками, предлагаемыми фреймворком для данной конфигурации: размером батча 12, числом эпох 1000.

Таблица 3 – Результаты сегментации патологий 2D модели (размер батча 12)
Table 3 – Results of segmentation of pathologies of the 2d model (batch 12)

Модель	Патология	Accuracy	Sensitivity	Specificity
6, фаза ART	Киста	0,700	0,800	0,670
	Гемангиома	0,688	0,875	0,659
	Карцинома	0,494	1,000	0,358
	ФНГ	0,692	0,906	0,659
6, фаза PV	Киста	0,710	0,836	0,672
	Гемангиома	0,630	0,750	0,612
	Карцинома	0,513	1,000	0,380
	ФНГ	0,744	0,625	0,762

Видно, что 2D модель существенно уступает в точности 3d_fullres, поэтому далее она не тестировалась.

Следующий эксперимент был направлен на оценку влияния увеличения числа эпох по сравнению с кастомным значением 1000. В Таблице 4 представлены результаты 3d_fullres модели, с размером батча 3, обученной в течение 1200 эпох (то есть, по сути, это модель 4, доученная еще в течение 200 эпох).

Сравним полученные результаты с результатами модели 4. По метрике Accuracy модель 7 показывает в целом более высокие результаты (0,840–0,891), модель 4 имеет несколько более низкие показатели (0,782–0,903). По Sensitivity (чувствительность)

модель 7 демонстрирует высокие показатели, особенно для карциномы. Модель 4 также имеет хорошие показатели, но в среднем немного ниже. По Specificity (специфичность) модель 7 (фаза PV) показывает стабильно высокие результаты (0,820–0,908), модель 4 имеет более низкие показатели (0,796–0,877). В целом, можно сделать вывод о том, что увеличение числа эпох до 1200 пока еще не приводит к переобучению модели.

Таблица 4 – Результаты сегментации патологий 3d_fullres(размер батча 3, 1200 эпох)
Table 4 – 3d_fullres pathology segmentation results (batch size 3, epoch 1200)

модель	Патология	Accuracy	Sensitivity	Specificity
7, фаза ART	Киста	0,857	0,836	0,863
	Гемангиома	0,819	0,781	0,824
	Карцинома	0,869	0,960	0,845
	ФНГ	0,840	0,844	0,839
7, фаза PV	Киста	0,849	0,945	0,820
	Гемангиома	0,828	0,656	0,854
	Карцинома	0,891	1,000	0,861
	ФНГ	0,874	0,656	0,908

Судя по графику функции потерь модели 7 (Рисунок 4), есть потенциал для дальнейшего увеличения точности за счет добавления числа эпох.

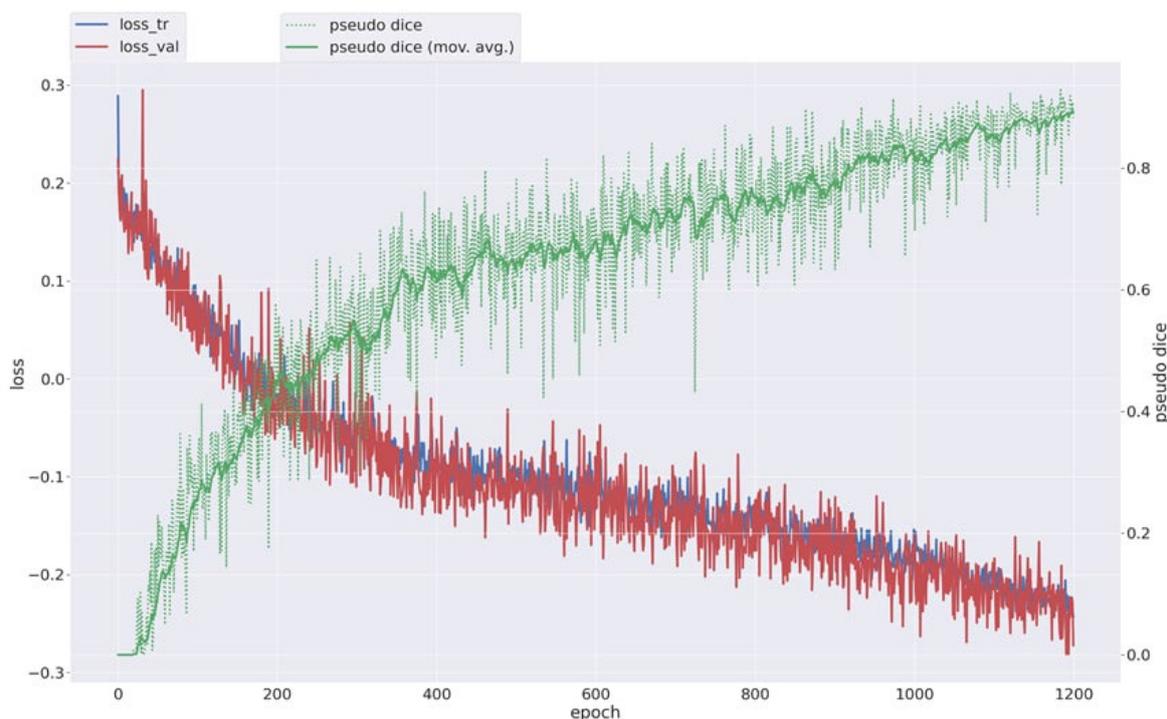


Рисунок 4 – Графики функции потерь на обучающей (синим) и тестовой (красным) выборке, а также метрики точности модели сегментации dice (зеленым)

Figure 4 – Graphs of the loss function on the training (blue) and test (red) samples, as well as the accuracy metrics of the dice segmentation model (green)

Обсуждение

Проведенные эксперименты показывают, что использование фреймворка nnU-Net v2 с оптимизированными параметрами позволяет достичь высокой точности сегментации и классификации объемных образований печени. Полученные результаты

согласуются с данными предыдущих исследований, но при этом имеют ряд преимуществ. Например, чувствительность 100 % для карцином превосходит показатели базовой U-Net (89 % в работе [1]), что подтверждает эффективность автоматизированной настройки гиперпараметров. Однако стоит отметить, что в исследовании [10] применение механизмов внимания улучшило сегментацию мелких опухолей, что указывает на дальнейший потенциал модификации архитектуры nnU-Net для повышения точности прогнозов.

Практическая значимость исследования заключается в потенциальной возможности существенного сокращения времени анализа КТ-снимков – с нескольких часов ручной работы до нескольких минут автоматизированной обработки. Например, 100 % чувствительность для карцином минимизирует риск пропуска злокачественных образований, что критически важно для их ранней диагностики. Однако на текущем этапе модель предлагается как вспомогательный инструмент, дополняющий, но не заменяющий экспертизу рентгенолога.

Применение двух фаз контрастного усиления значительно увеличивает объем доступных данных для обучения, что способствует лучшему выявлению патологических изменений благодаря многомерному анализу структуры ткани. Данные, полученные на разных фазах, позволяют улучшить качество сегментации патологии. Артериальная фаза (ART) лучше визуализирует гипervasкулярные патологии (карциному), тогда как венозная (PV) эффективна для гиповаскулярных образований (кисты). Это согласуется с клиническими рекомендациями, где мультифазное сканирование считается «золотым стандартом» диагностики.

В данной серии экспериментов, было получено, что оптимальный размер батча для определения ФНГ 3, для остальных патологий 4. Размер батча 3, 4 связан с балансом между стабильностью результатов обучения и эффективным использованием памяти GPU. Для ФНГ меньший батч обеспечивает более точную настройку весов из-за неоднородности структуры патологии.

Заключение

Исследование подтвердило эффективность nnU-Net v2 для автоматической сегментации и классификации объемных образований печени на мультифазных КТ-изображениях. На основе анализа результатов предложены следующие рекомендации:

- для карцином и кист рекомендуется использовать батч 4, 1200 эпох, комбинация фаз ART+PV;
- для гемангиом и ФНГ рекомендуется использовать батч 3, 1200 эпох, акцент на фазу PV и ART соответственно.

Дальнейшие исследования будут направлены на внедрение механизмов внимания, расширение набора фаз контрастирования и сравнение с другими архитектурами (Transformer-based моделями).

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Sato M., Jin Z., Suzuki K. Semantic Segmentation of Liver Tumor in Contrast-enhanced Hepatic CT by Using Deep Learning with Hessian-based Enhancer with Small Training Dataset Size. In: *2021 IEEE 18th International Symposium on Biomedical Imaging, 13–16 April 2021, Nice, France*. IEEE; 2021. pp. 34–37. <https://doi.org/10.1109/ISBI48211.2021.9433929>
2. Достовалова А.М., Горшенин А.К., Старичкова Ю.В., Арзамасов К.М. Сравнительный анализ модификаций нейросетевых архитектур U-Net в задаче сегментации медицинских изображений. *Digital Diagnostics*. 2024;5(4):833–853.

- <https://doi.org/10.17816/DD629866>
Dostovalova A.M., Gorshenin A.K., Starichkova Ju.V., Arzamasov K.M. Comparative analysis of modifications of U-Net neuronal network architectures in medical image segmentation. *Digital Diagnostics*. 2024;5(4):833–853. (In Russ.). <https://doi.org/10.17816/DD629866>
3. Huang W., Liu W., Zhang X., et al. LIDIA: Precise Liver Tumor Diagnosis on Multi-Phase Contrast-Enhanced CT via Iterative Fusion and Asymmetric Contrastive Learning. In: *Medical Image Computing and Computer Assisted Intervention – MICCAI: 27th International Conference: Proceedings, Part IX, 06–10 October 2024, Marrakesh, Morocco*. Cham: Springer; 2024. pp. 394–404. https://doi.org/10.1007/978-3-031-72114-4_38
 4. Isensee F., Jaeger P.F., Kohl S.A.A., Petersen J., Maier-Hein K.H. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nature Methods*. 2021;18:203–211. <https://doi.org/10.1038/s41592-020-01008-z>
 5. Isensee F., Wald T., Ulrich C., et al. nnU-Net Revisited: A Call for Rigorous Validation in 3D Medical Image Segmentation. In: *Medical Image Computing and Computer Assisted Intervention – MICCAI: 27th International Conference: Proceedings, Part IX, 06–10 October 2024, Marrakesh, Morocco*. Cham: Springer; 2024. pp. 488–498. https://doi.org/10.1007/978-3-031-72114-4_47
 6. Ronneberger O., Fischer Ph., Brox Th. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015: 18th International Conference: Proceedings, Part III, 05–09 October, 2015, Munich, Germany*. Cham: Springer; 2015. pp. 234–241. https://doi.org/10.1007/978-3-319-24574-4_28
 7. Wang J., Zhang X., Guo L., Shi Ch., Tamura Sh. Multi-scale attention and deep supervision-based 3D UNet for automatic liver segmentation from CT. *Mathematical Biosciences and Engineering*. 2023;20(1):1297–1316. <https://doi.org/10.3934/mbe.2023059>
 8. He K., Zhang X., Ren Sh., Sun J. Deep Residual Learning for Image Recognition. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 27–30 June 2016, Las Vegas, NV, USA*. IEEE; 2016. pp. 770–778. <https://doi.org/10.1109/CVPR.2016.90>
 9. Ковун В.А., Каширина И.Л. Использование нейронных сетей U-Net и W-Net в металлографическом анализе образцов стали. *Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии*. 2022;(1):101–110. <https://doi.org/10.17308/sait.2022.1/9205>
Kovun V.A., Kashirina I.L. Usage of U-Net and W-Net neural network architectures for steel samples metallographic analysis. *Proceedings of Voronezh State University. Series: Systems Analysis and Information Technologies*. 2022;(1):101–110. (In Russ.). <https://doi.org/10.17308/sait.2022.1/9205>
 10. Wang W., Wang F., Chen Q., et al. Phase Attention Model for Prediction of Early Recurrence of Hepatocellular Carcinoma With Multi-Phase CT Images and Clinical Data. *Frontiers in Radiology*. 2022;2. <https://doi.org/10.3389/fradi.2022.856460>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Куликов Александр Анатольевич, кандидат технических наук, доцент, кафедра технологий искусственного интеллекта, МИРЭА – Российский технологический университет, Москва, Российская Федерация.

Alexander A. Kulikov, Candidate of Engineering Sciences, Associate Professor, Department of Artificial Intelligence Technologies, MIREA – Russian Technological University, Moscow, the Russian Federation.

e-mail: kulikov_aa@mirea.ru
ORCID: [0000-0002-8443-3684](https://orcid.org/0000-0002-8443-3684)

Каширина Ирина Леонидовна, доктор технических наук, профессор, кафедра технологий искусственного интеллекта, МИРЭА – Российский технологический университет, Москва, Российская Федерация.

e-mail: kash.irina@mail.ru
ORCID: [0000-0002-8664-9817](https://orcid.org/0000-0002-8664-9817)

Irina L. Kashirina, Doctor of Engineering Sciences, Professor, Department of Artificial Intelligence Technologies, MIREA – Russian Technological University, Moscow, the Russian Federation.

Савкина Екатерина Феликсовна, инженер, младший научный сотрудник, отдела радиомики и радиогеномики, Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы, Москва, Российская Федерация;

e-mail: SavkinaEF@zdrav.mos.ru
ORCID: [0000-0001-9165-0719](https://orcid.org/0000-0001-9165-0719)

Ekaterina F. Savkina, Junior Researcher, Department of Radiomics and Radiogenomics, Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department, Moscow, the Russian Federation.

Статья поступила в редакцию 13.03.2025; одобрена после рецензирования 24.03.2025; принята к публикации 25.03.2025.

The article was submitted 13.03.2025; approved after reviewing 24.03.2025; accepted for publication 25.03.2025.