



ISSN 1607-0763 (Print); ISSN 2408-9516 (Online)

<https://doi.org/10.24835/1607-0763-1483>

Оценка диагностической ценности глубокого машинного обучения для автоматизированной сегментации паренхимы поджелудочной железы и ее гипо- и гиперваскулярных образований по КТ-изображениям с помощью U-net нейросети

© **Замятина К.А.^{1, 2*}, Жарикова А.В.¹, Кондратьев Е.В.¹, Усталов А.А.¹,
Староверов Н.Е.³, Нефедьев Н.А.⁴, Гожева А.Р.⁵, Шмелева С.А.¹,
Кармазановский Г.Г.^{1, 6}**

¹ ФГБУ “Национальный медицинский исследовательский центр хирургии им. А.В. Вишневского” Минздрава России; 117997 Москва, ул. Большая Серпуховская, д. 27, Российская Федерация

² Филиал “Онкологический центр №1” ГБУЗ города Москвы “Городская клиническая больница имени С.С. Юдина ДЗ города Москвы”; 117152 Москва, Загородное шоссе, 18А, Российская Федерация

³ ФГАОУ ВО “Санкт-Петербургский государственный электротехнический университет “ЛЭТИ” им. В.И. Ульянова (Ленина)”; 197022 Санкт-Петербург, ул. Профессора Попова, д. 5, лит. Ф, Российская Федерация

⁴ ФГБУ высшего образования и науки “Санкт-Петербургский национальный исследовательский академический университет имени Ж.И. Алфёрова Российской академии наук”; 194021 Санкт-Петербург, ул. Хлопина, д. 8/3, Российская Федерация

⁵ ФГБОУ ВО “Санкт-Петербургский государственный педиатрический медицинский университет” Минздрава России; 194100 Санкт-Петербург, ул. Литовская, д. 2, Российская Федерация

⁶ ФГАОУ ВО РНИМУ им. Н.И. Пирогова Минздрава России; 117997 Москва, ул. Островитянова, д. 1, Российская Федерация

Цель исследования: создание и оценка эффективности технологии сегментации паренхимы поджелудочной железы (ПЖ), а также сегментации и детекции ее гипер- и гиповаскулярных образований на компьютерных томограммах органов брюшной полости с использованием глубокого машинного обучения.

Материал и методы. Для обучения алгоритмов были использованы КТ-исследования из базы данных НМИЦ хирургии им. А.В. Вишневского – общий объем около 150 исследований (артериальная и портальная фазы исследования). Для валидации полученных алгоритмов был подготовлен тестовый набор данных из 46 анонимизированных КТ-исследований (артериальная и портальная фазы исследования), независимо оцененных врачами-экспертами. В качестве основной сегментационной нейросети (ИНС) используется pp-UNet (M. Antonelli и соавт., 2022).


Результаты. Средняя точность тестового набора данных для модели, определяющей сегментационные маски ПЖ на КТ-изображениях, AUC составила – 0,8 для портальной фазы и – 0,85 для артериальной фазы, сегментационные маски образований поджелудочной железы – 0,6.

Заключение. Автоматизированная сегментация структуры паренхимы ПЖ с использованием технологий глубокого машинного обучения показала высокую точность. Сегментация гипо- и гиперваскулярных образований ПЖ требует совершенствования. Совпадение масок показало достаточно низкий результат, однако во всех случаях место расположения патологического образования было отмечено алгоритмом правильно. Совершенствование обучающего дата-сета и используемого алгоритма может увеличить точность алгоритма.

При детекции образований ПЖ ложноотрицательных результатов получено не было, во всех случаях ИНС детектировала “подозрительные” области паренхимы ПЖ. Это может помочь снизить пропуски патологий ПЖ по компьютерным томограммам, а дальнейшую их оценку может осуществлять сам врач-рентгенолог.

Ключевые слова: КТ; поджелудочная железа; образования поджелудочной железы; машинное обучение; искусственные нейронные сети; сегментация; трансферное обучение

Авторы подтверждают отсутствие конфликтов интересов.



Для цитирования: Замятина К.А., Жарикова А.В., Кондратьев Е.В., Усталов А.А., Староверов Н.Е., Неведьев Н.А., Гожева А.Р., Шмелева С.А., Кармазановский Г.Г. Оценка диагностической ценности глубокого машинного обучения для автоматизированной сегментации паренхимы поджелудочной железы и ее гипо- и гиперваскулярных образований по КТ-изображениям с помощью U-net нейросети. *Медицинская визуализация*. 2024; 28 (3): 12–21. <https://doi.org/10.24835/1607-0763-1483>

Поступила в редакцию: 09.06.2024.

Принята к печати: 09.07.2024.

Опубликована online: 04.09.2024.

Deep Machine Learning for Automatic Segmentation of the Pancreatic Parenchyma and its hypo- and hypervascular lesions on CT Images

© Ksenia A. Zamyatina^{1, 2*}, Alexandra V. Zharikova¹, Evgeniy V. Kondratev¹, Andrey A. Ustalov¹, Nikolay E. Staroverov³, Nikolay A. Nefedev⁴, Alla R. Gozheva⁵, Sofia A. Shmeleva¹, Grigory G. Karmazanovsky^{1, 6}

¹ A.V. Vishnevsky National Medical Research Center of Surgery of the Ministry of Healthcare of the Russian Federation; 27, Bol'shaya Serpukhovskaya str., Moscow 117997, Russian Federation

² Branch "Oncology Center No. 1" S.S. Yudin City Clinical Hospital of Moscow Healthcare Department; Moscow 117152, Zagorodnoye shosse, 18A, Russian Federation

³ St. Petersburg Electrotechnical University "LETI"; 5-F, Professor Popov str., St. Petersburg 197022, Russian Federation

⁴ Alferov Federal State Budgetary Institution of Higher Education and Science Saint Petersburg National Research Academic University of the Russian Academy of Sciences (Alferov University); 8/3, Hlopina str., St. Petersburg 194021, Russian Federation

⁵ St. Petersburg State Pediatric Medical University of the Ministry of Healthcare of the Russian Federation; 2, Litovskaya str., St. Petersburg 194100, Russian Federation

⁶ Pirogov Russian National Research Medical University; 1, Ostriviyanova str., Moscow 117997, Russian Federation

Objective of the study. To develop and evaluate the effectiveness of a technology for segmenting the pancreatic parenchyma and its hyper- and hypovascular lesions on abdominal computed tomography (CT) scans using deep machine learning.

Materials and methods. CT scans from the database of the A.V. Vishnevsky National Medical Research Center of Surgery were used for training and testing the algorithms – a total number of approximately 150 studies (arterial and venous phases). A test dataset of 46 anonymized CT scans (arterial and venous phases) was prepared for validation of the obtained algorithms, independently assessed by expert physicians. The primary segmentation neural network used is nn-UNet (M. Antonelli et al., 2022).

Results. The average accuracy of the test dataset for the model determining segmentation masks of the pancreas on CT images had an AUC of 0.8 for the venous phase and 0.85 for the arterial phase. The segmentation masks of pancreatic formations had an AUC of 0.6.

Conclusion. Automated segmentation of the pancreatic parenchyma structure using deep machine learning technologies demonstrated high accuracy. However, the segmentation of hypo- and hypervascular pancreatic lesions requires improvement. The overlap of the masks showed a rather low result, but in all cases, the location of the pathological formation was correctly identified by the algorithm. Enhancing the training dataset and the algorithm used could increase the accuracy of the algorithm.

No false negative results were obtained when detecting pancreatic formations; in all cases, the INS detected "suspicious" areas of the pancreatic parenchyma. This can help reduce the omission of pancreatic pathologies in CT scans, and their further assessment can be carried out by the radiologist himself.

Keywords: CT; pancreas; pancreatic lesions; machine learning; deep convolutional neural networks; segmentation; transfer learning

Conflict of interest. The authors declare no conflict of interest. The study had no sponsorship.

For citation: Zamyatina K.A., Zharikova A.V., Kondratev E.V., Ustalov A.A., Staroverov N.E., Nefedev N.A., Shmeleva S.A., Gozheva A.R., Karmazanovsky G.G. Deep Machine Learning for Automatic Segmentation of the Pancreatic Parenchyma and its hypo- and hypervascular lesions on CT Images. *Medical Visualization*. 2024; 28 (3): 12–21. <https://doi.org/10.24835/1607-0763-1483>

Received: 09.06.2024.

Accepted for publication: 09.07.2024.

Published online: 04.09.2024.



Введение

“Золотым стандартом” диагностики образований поджелудочной железы (ПЖ), в том числе злокачественных, является компьютерная томография (КТ) органов брюшной полости (ОБП) с внутривенным болюсным контрастированием [1]. Самой распространенной злокачественной опухолью ПЖ является протоковая аденокарцинома [2].

Несмотря на значительные исследовательские усилия, рак ПЖ связан с неблагоприятным прогнозом и 5-летней выживаемостью всего 10%. Ранние симптомы заболевания в основном неспецифичны. Повышения выживаемости можно добиться за счет раннего выявления, благодаря которому больше людей получают более радикальное хирургическое лечение на ранних стадиях заболевания [3]. Но на ранних стадиях рак ПЖ может быть слабо заметен на КТ-изображениях, особенно при небольших размерах, и пропущен неопытным врачом либо в большом потоке исследований. Использование искусственного интеллекта (ИИ) уже показало отличные результаты в разных областях лучевой диагностики и стало полезным инструментом для стратификации рисков и “помощником” в диагностике различных патологий [4]. Так как в условиях резкого роста количества выполняемых рентгенологических исследований и увеличения нагрузки на врачей-рентгенологов диагностическая точность исследований снижается и повышается количество пропущенной патологии и ошибок при оценке распространенности опухолей, применение алгоритмов глубокого машинного обучения может стать решением упомянутых проблем [5], тем более что аналогичные работы уже описаны – искусственная нейросеть (ИНС), способная с достаточно большой точностью выявлять визуально незаметные опухоли небольшого размера (даже менее 1 см) с точностью до 0,75% [5], более крупные образования с точностью до 98% [5,6].

Однако нужно иметь в виду, что существует разница между функцией обнаружения образования и его сегментации (построения сегментационной маски с нахождением границ опухоли). Сегментация оценивается при сопоставлении двух масок, обычно одна из них построена опытным врачом-рентгенологом, а вторая – это маска, сгенерированная ИНС. Основной валидационной метрикой для оценки совпадения сегментационных масок является коэффициент сходства Dice (DSC). DSC – это индекс пространственного перекрытия и метрика проверки воспроизводимости, измеряет совпадение между двумя сегментациями (вокселями масок) – A и B и определяется как





Рис. 1. Коэффициент сходства Dice (DSC), представляющий собой пространственное перекрытие и воспроизводимость, где $DSC = 2$ (пересекаемая область)/(сумма областей A и B), адаптировано из работы K. Zou и соавт. (2004) [7].

Fig. 1. Dice similarity coefficient (DSC) representing spatial overlap and reproducibility, where $DSC = 2(\text{overlapping area})/(\text{sum of areas A and B})$, adapted from Zou K. et al. (2004) [7].

$DSC(A, B) = 2(A \cap B) / (A + B)$, где $\cap$ – пересечение (рис. 1). Значение DSC находится в диапазоне от 0, указывающего на отсутствие пространственного перекрытия между двумя наборами результатов двоичной сегментации, до 1, указывающей на полное перекрытие, обычно указывается либо в процентах, либо в долях до единицы [7].

Повышение точности сегментации может помочь в нахождении точных границ, распространенности опухоли и, соответственно, в стадировании, планировании хирургического лечения и даже прогнозировании выживаемости и/или раннего рецидива. Подтверждают это исследование Н. Ni и соавт. (2023) [8], где ИИ достаточно точно строит сегментационную маску ПЖ, анализирует полученные данные, в том числе клинические, с целью дальнейшего прогнозирования рецидива рака ПЖ после хирургического лечения, а также результаты работы Т. Mahmoudi и соавт. (2022) [9] по сегментации внутрипротоковой аденокарциномы, которая достигла DSC – 60,6. С 2021 г. подобных работ много, цели и задачи, а также результаты которых достаточно схожи [10, 11].

Кроме того, для повышения точности ИИ можно дополнительно использовать методику математического анализа изображения – радиомику, что потенциально позволит еще больше повысить его точность, особенно на таком “сложном” для визуализации органе и его патологии, как ПЖ.



Например, в исследовании Q. Miao и соавт. (2024), где точность ИИ в сочетании радиомикой в оценке периваскулярной инвазии внутрипротоковой аденокарциномы ПЖ была сопоставима с результатами оценки изображений опытными абдоминальными рентгенологами [12]. Также использование радиомики вместе с нейросетью перспективно для построения карты вероятности принадлежности данной опухоли к определенному виду или даже определения степени ее дифференцировки [13].

Потенциал развития данных направлений автоматизированного анализа изображений огромен. Но обучение ИНС сегментации требует значительного объема работы, и моделям ИИ необходимы большие наборы данных для обучения и тестирования, что требует участия нескольких клинических центров в их формировании.

Первым этапом в обучении ИНС выявлять патологию на медицинских изображениях, в том числе опухолевидные образования в анализируемом органе, является построение сегментационной маски самого органа. Особенно это актуально для ПЖ, так как она представляет собой небольшой орган, занимающий лишь очень малую часть (~1,3%) каждого КТ-исследования. Поэтому поиск опухоли ПЖ только в ее паренхиме, а не во всем КТ-изображении, сильно повышает точность и скорость работы ИНС [10]. Это доказывает ряд исследований. Например, N. Alves и соавт. (2022) сравнили между собой 3 обученных ими ИНС – первая сегментировала только опухоль (*nnUnet_T*), вторая – опухоль и ПЖ (*nnUnet_TP*) и третья – опухоль, ПЖ и анатомические структуры гепатодуоденальной области (*nnUnet_MS*). Выше всех точность была у третьей, она показала лучший результат – ROC-AUC 0,914, а ниже всех точность была у первой ИНС. Это также доказывает, что для повышения точности работы ИНС необходимо прежде научиться ее сегментировать сам орган [14]. Главным недостатком этих исследований является то, что проверка точности ИНС проводилась на валидационной выборке того же центра (тот же томограф и условия постобработки изображений), что в значительной степени могло завязать показатели ее точности, в то время как на внешних данных точность с высокой вероятностью будет ниже.

Однако даже первый этап предобучения ИНС – сегментация ПЖ вызывает много сложностей, так как сам по себе орган имеет разную форму, размеры, не говоря уже о патологических новообразованиях. Помимо всего, нужно учитывать вариативность разметки между разными рентгенологами, она может зависеть от опыта и других факторов.

Настоящее исследование – лишь начало большой работы в разработке алгоритмов машинного обучения для помощи в диагностике образований ПЖ.

Цель исследования: разработать и протестировать алгоритмы построения сегментационных масок ПЖ и ее новообразований на различных фазах КТ-исследования с контрастным усилением с использованием нейросетевой архитектуры U-Net, оценить функцию обнаружения ИНС образований ПЖ по данным КТ ОБП.

Материал и методы

Сбор и предобработка данных, создание обучающей и тестовой выборки

Всего в исследование было включено 196 пациентов, каждому из которых была выполнена мультиспиральная компьютерная томография (МСКТ) ОБП с внутривенным болюсным введением контрастного препарата. Исследование проводилось с использованием стандартного протокола для МСКТ ОБП и реконструкции soft и high-resolution на мультidetекторном компьютерном томографе Philips Ingenuity CT 64 (были использованы следующие параметры сканирования: коллимация 64 × 0,625, реконструкция 1 мм, инкремент 0,5 мм). Исследование проводили в положении больного лежа на спине с запрокинутыми за голову руками. По сканограмме планировали зону сканирования, включающую в себя брюшную полость и забрюшинное пространство. В протокол сканирования обязательно входили нативная, артериальная, портальная и выделительная фазы контрастирования, некоторым пациентам была выполнена дополнительная панкреатическая фаза.

Для обучения алгоритмов машинного обучения использовали артериальную и портальную фазы КТ-исследований 150 пациентов, взятых из базы данных НМИЦ хирургии им. А.В. Вишневского: 45 случаев с аденокарциномой ПЖ (гиповаскулярные образования), 45 – с нейроэндокринными опухолями (гиперваскулярные образования) и 60 – с ПЖ без образований.

В валидационную выборку было включено 3 набора случаев: 20 КТ-исследований пациентов с неизменной ПЖ и с образованиями (10 артериальных фаз и 10 портальных фаз исследований), 11 КТ-исследований пациентов только с образованиями ПЖ и 15 КТ-исследований – с образованиями (6 случаев) и без образований – 9.

В исследование не включали кейсы со структурой паренхимы ПЖ, представленной отдельными “кусочками” железистой ткани в жировой, как бывает при выраженном стеатозе ПЖ.




Рис. 2. Примеры сегментационных масок образований ПЖ на компьютерных томограммах, которые с помощью программного обеспечения 3D-Slicer пришлось корректировать и дорабатывать.

Fig. 2. Examples of segmentation masks of pancreatic formations on CT tomograms, which had to be corrected and additionally marked up using 3D Slicer software.





Рис. 3. КТ-исследование ОБП, артериальная фаза исследования с наложенной сегментационной маской образования ПЖ (скрин экрана слева). Предобработка входных данных – исследование обрезается до “bounding box”, то есть ограничительный параллелепипед, в котором находится маска образования и ПЖ (скрин экрана справа).

Fig. 3. CT examination of the abdominal cavity, arterial phase of the examination with a superimposed segmentation mask of the RV formation (screenshot on the left). Preprocessing of input data – the examination is cut to the “bounding box”, i.e. the limiting parallelepiped in which the mask of the formation and the RV are located (screenshot on the right).



Оценка и сегментация полученных изображений производились в модуле просмотра DICOM-изображений Philips IntelliSpace Portal (Philips Medical Systems, Cleveland), для сегментации использовали инструмент, определяющий контуры органа по типу “магнитного лассо”, выгружались маски в формате Stl. В дальнейшем производили корректировку масок и экспорт в подходящий формат с помощью другого программного обеспечения 3D Slicer (рис. 2) [15]. С помощью него же проводили выгрузку сегментационных масок в файловый формат NiftI.

Сегментацию проводили 2 врача-рентгенолога (опыт работы более 5 лет) с выделением границ ПЖ на артериальной и венозной фазах каждого исследования в вышеописанном программном пакете Intellispace Portal V. компании Philips. Выделяли всю паренхиму ПЖ, если в ней было образование, его включали в общую разметку, но исключали общий желчный проток, видимые кровеносные сосуды и жировое пространство вокруг ПЖ. Затем проводили сегментацию образований ПЖ на КТ-изображениях, использовались портальная фаза – для гиповаскулярных образований, артериальная фаза – для гиперваскулярных.

Обучение сети

Перед началом обучения необходима предобработка данных. Во время предобработки проверяется набор данных: наличие всех масок

и снимков, согласованность размеров и положения масок в исследовании (через ПО 3D-Slicer), происходит обрезание фона изображения (области, которые не несут полезной информации и содержат константные значения), снимок приводится к единой системе координат, происходит нормализация снимка (рис. 3).

Далее подготовленный набор данных отправляли для обучения ИНС. Первым этапом в ИНС для обучения загружали сегментационные маски ПЖ (в том числе пациентов с образованиями) и соответствующие DICOM-файлы КТ-исследований. Вторым этапом в уже обученную на предыдущем этапе ИНС загружали сегментационные маски образований – гиперваскулярных и гиповаскулярных с соответствующими DICOM-файлами фаз КТ-исследований, то есть использовали трансферное обучение, с помощью которого ИНС дообучается сегментировать образования.

Исходные DICOM-файлы были преобразованы в трехмерные массивы.

Данные представлены в виде пар трехмерных массивов. В первом элементе пары в каждом вокселе хранятся характеристики плотности, во втором – метка, равная 0 в случае “фона” (то есть если это не ПЖ), 1 – если паренхима органа.

В качестве основной сегментационной ИНС использовалась U-Net [16] (рис. 4).

U-Net считается одной из стандартных архитектур ИНС для задач сегментации изображений.




Рис. 4. Структура классической сверточной нейросети U-Net.

Fig. 4. Structure of the classical convolutional neural network U-Net.




Рис. 5. КТ-исследование в артериальную фазу. Слева – аксиальный срез, справа – фронтальный. Определяются сегментационные маски: синяя – разметка врачом, красная – прогнозируемая ИНС, розовым цветом обозначена зона совпадения.

Fig. 5. CT examination in the arterial phase. On the left – axial section, on the right – frontal. Segmentation masks are determined: blue – markings by the doctor, red – predicted by the INS, the coincidence zone is marked in pink.

Архитектура UNet представляет собой U-образную дугу, на левой части которой входное изображение кратно уменьшается, а на правой части, наоборот, увеличивается до исходного размера (см. рис. 4). За счет операций свертки на выходе ИНС получает уже не исходное изображение, а сегментационную маску, которая показывает, к какому классу относится соответствующий воксель изображения.

Валидация нейронной сети

После первого этапа обучения нейросети nnU-net сегментации ПЖ в нее загружались DICOM-файлы валидационной выборки из 20 кейсов с ПЖ без образований и с образованиями (10 исследований в артериальную фазу и затем отдельно 10 в портальную фазу), а полученные сегментационные маски органа сравнивались с разметкой этих же кейсов врачами-рентгенологами.

После второго этапа обучения загружалась выборка из 11 DICOM-файлов КТ-исследований с образованиями ПЖ и аналогичным образом сравнивались сегментационные маски образований.

Для тестирования дообученной ИНС в функции детекции образований ПЖ загрузили 15 DICOM-файлов КТ-исследований, 9 из которых были с образованиями и 6 – без образований. По наличию сегментационных масок определяли, нашла ли ИНС в конкретном случае образование или нет.

В качестве метрик оценки качества разметки нейросети использовались диагностическая точность, чувствительность и предиктивное значение положительного результата с соответствующими 95% точными доверительными интервалами (95% ДИ).

Результаты и обсуждение

Средняя точность сегментации ИНС паренхимы ПЖ в артериальную фазу КТ-исследования (DICE) составила до 0,846, в портальную – до 0,803, в среднем по всем 20 кейсам и фазам – 0,82, пример совпадений сегментационных масок на компьютерных томограммах (рис. 5).

Это ниже, чем в некоторых аналогичных зарубежных работах, например, чем в TotalSegmentator – DICE 0,943 [17], но и объем обучающего дата-сета в нашем исследовании был значительно меньше.

Средняя точность сегментации гиповаскулярных и гиперваскулярных образований ПЖ – 0,61, но мы убеждены, что точность можно повысить, если учесть и доработать некоторые нюансы нашего исследования.

Частота ложноположительной разметки опухоли составила 40% [16,3; 67,7], диагностическая точность нейросети и предиктивное значение положительного результата нейросети – 60% [32,3; 83,7], чувствительность – 100% [66,4; 100], специфичность – 0% [95% ДИ 0; 45,9]. Данные результаты можно объяснить поставленной перед ИНС задачей поиска патологических изменений в структуре паренхимы ПЖ, при этом во всех случаях ИНС будет находить какие-либо подозрительные участки, которые будут ей отмечены. При тестировании ИНС на третьей тестовой выборке во всех случаях она сегментировала какие-либо зоны ПЖ на компьютерных томограммах (см. таблицу): в 9 случаях они совпали с истинными образованиями ПЖ по данным КТ, в остальных 6 случаях была ложноположительная разметка (протоки, жировые включения в паренхиме). Отмеченные участки должны быть оценены врачом-рентгенологом внимательно для окончательного решения о наличии патоло-




Таблица. Отражение количества ложноотрицательных и ложноположительных детекций образований ПЖ на третьей тестовой выборке

Table. The number of false negative and false positive detections of pancreatic lesions on the third test sample

	Сегментационная маска образования построена Segmentation mask formation built	Сегментационная маска образования не получена Segmentation mask of formation not received
Случаи с образованием ПЖ Cases with pancreatic formation	9 положительных 9 positive	0 ложноотрицательных 0 false negatives
Случаи без образования ПЖ Cases without pancreatic formation	6 ложноположительных 6 false positive	0 отрицательных 0 negative

гии. Следует отметить, что при тестировании ИНС не было выявлено ни одного ложноотрицательного случая, когда ИНС пропустила бы новообразование, что свидетельствует о ее высокой эффективности. Это может быть полезно в клинической практике для врача-рентгенолога при большом количестве исследований или при его небольшом опыте для того, чтобы минимизировать пропуски патологии, в том числе образований ПЖ.

Можно выделить следующие недостатки нашей работы: небольшая выборка (база данных из одного центра), использование только одного вида ИНС без сравнения с другими типами, использование только артериальной и портальной фаз исследования, а для образований по одному виду фаз исследования (артериальная фаза – для гиповаскулярных, портальная фаза – для гиповаскулярных), исключение пациентов с выраженным стеатозом ПЖ (когда ее структура представлена отдельными “участками” в жировой плотности строме) и отсутствие ее тестирования в условиях рутинной работы центра.

Тем не менее при сравнении с упомянутыми выше работами [10, 11, 12, 14] в целом наши результаты не сильно уступают, а результаты сегментации органа считаются отличными [9], несмотря на то что структуры гепатодуоденальной зоны не сегментировали отдельно как в работе [14], то есть при дополнительном их сегментировании результаты могут быть лучше.

Объем обучающих данных

В последних работах используются все большие по количеству наборы данных для обучения сетей, а также с разных медицинских центров или дата-сетов в открытом доступе (MSD [12], TCIA [18] и др.). Прослеживается тенденция, что с увеличением количества случаев увеличивается точность работы большинства нейросетей и применимость их в дальнейшем на различных базах данных, хотя есть новые виды нейросетей, сочета-

ющие в себе дополнительные модули и функции, которые требуют меньшее количество обучающих исследований с разметкой для получения высоких результатов [19].

Применение других типов нейросетей

Существуют нейросети-трансформеры U-netr (например, SwinUnet [19]), разница между обычной U-net и U-netr заключается в том, что U-net использует полностью сверточную архитектуру кодера-декодера, тогда как вторая – кодер-трансформер и декодер с пропускными соединениями. Трансформатор в архитектуре U-netr позволяет сети учитывать в своем обучении разные области входных данных и формировать долгосрочные зависимости, которые не фиксируются сверточной нейронной сетью, используемой в архитектуре U-net. Таким образом, с точки зрения получения результатов сеть-трансформер U-netr превосходит традиционную сверточную U-net для задач 3D-сегментации. Однако U-netr в вычислительном отношении затратнее из-за использования трансформаторного энкодера.

Еще одним преимуществом использования кодировщика-трансформера является то, что он может обрабатывать входные карты объектов переменных размеров без понижающей дискретизации. В традиционной 3D-архитектуре U-net необходимо уменьшить дискретизацию входных карт объектов, чтобы уменьшить вычислительные затраты сети. Однако понижение дискретизации может привести к потере пространственного разрешения, что ведет к снижению точности сегментации. В U-netr преобразователь-кодер генерирует набор пространственных характеристик для каждой входной карты объектов, которая может захватывать пространственную информацию без понижения разрешения. Это позволяет сети поддерживать пространственное разрешение входных карт объектов и, наоборот, улучшать точность сегментации.



Заключение

Таким образом, данная работа показывает высокую эффективность разработанной и обученной нами модели ИНС в сегментации паренхимы поджелудочной железы на компьютерных томограммах и выявлении подозрительных на патологию участков паренхимы поджелудочной железы, а также перспективу дальнейшего изучения эффективности нейросетей в сегментации поджелудочной железы и сегментации и детекции ее образований.

Источник финансирования. Авторы заявляют об отсутствии внешнего финансирования при проведении поисково-аналитической работы и подготовке статьи.

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Участие авторов

Замятина К.А. – концепция и дизайн исследования, проведение исследования, написание текста, сбор и обработка данных, участие в научном дизайне.

Жарикова А.В. – концепция и дизайн исследования, проведение исследования, написание текста, сбор и обработка данных, участие в научном дизайне.

Кондратьев Е.В. – ответственность за целостность всех частей статьи, утверждение окончательного варианта статьи, подготовка, создание опубликованной работы.

Усталов А.А. – концепция и дизайн исследования, проведение исследования, статистическая обработка данных, сбор и обработка данных.

Староверов Н.Е. – проведение исследования, анализ и интерпретация полученных данных.

Нефедьев Н.А. – проведение исследования, анализ и интерпретация полученных данных.

Гожева А.Р. – обзор публикаций по теме статьи, подготовка и редактирование текста.

Шмелева С.А., – концепция и дизайн исследования, проведение исследования, статистическая обработка данных.

Кармазановский Г.Г. – ответственность за целостность всех частей статьи, утверждение окончательного варианта статьи, подготовка, создание опубликованной работы.

Authors' participation

Zamyatina K.A. – concept and design of the study, conducting research, writing text, collection and analysis of data, participation in scientific design.

Zharikova A.V. – concept and design of the study, conducting research, writing text, collection and analysis of data, participation in scientific design.

Kondratev E.V. – responsibility for the integrity of all parts of the article, approval of the final version of the article.

Ustalov A.A. – concept and design of the study, conducting research, statistical analysis, collection and analysis of data.

Staroverov N.E. – conducting research, analysis and interpretation of the obtained data.

Nefedev N.A. – conducting research, analysis and interpretation of the obtained data.

Shmeleva S.A. – concept and design of the study, text preparation and editing.

Gozheva A.R. – review of publications, text preparation and editing, conducting research, statistical analysis.

Karmazanovsky G.G. – responsibility for the integrity of all parts of the article, approval of the final version of the article.

Список литературы [References]

1. Isensee F., Petersen J., Klein A. et al. nnU-Net: Self-adapting Framework for U-Net-Based Medical Image Segmentation. *arXiv*; 2018; 2. <https://arxiv.org/abs/1809.10486>. <https://doi.org/10.48550/arXiv.1809.10486>
2. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *arXiv*; 2015; 2. <https://arxiv.org/abs/1505.04597>. <https://doi.org/10.48550/arXiv.1505.04597>
3. Kenner B., Chari S.T., Kelsen D. et al. Artificial Intelligence and Early Detection of Pancreatic Cancer: 2020 Summative Review. *Pancreas*. 2021; 50 (3): 251–279. <https://doi.org/10.1097/MPA.0000000000001762>
4. Mello-Thoms C., Mello C.A.B. Clinical applications of artificial intelligence in radiology. *Br. J. Radiol.* 2023; 96 (1150): 20221031. <https://doi.org/10.1259/bjr.20221031>
5. Anghel C., Grasu M.C., Anghel D.A. et al. Pancreatic Adenocarcinoma: Imaging Modalities and the Role of Artificial Intelligence in Analyzing CT and MRI Images. *Diagnostics (Basel)*. 2024; 14 (4): 438. <https://doi.org/10.3390/diagnostics14040438>
6. Chu L.C., Park S., Kawamoto S. et al. Application of Deep Learning to Pancreatic Cancer Detection: Lessons Learned From Our Initial Experience. *J. Am. Coll. Radiol.* 2019; 16 (9 Pt B): 1338–1342. <https://doi.org/10.1016/j.jacr.2019.05.034>
7. Zou K.H., Warfield S.K., Bharatha A. et al. Statistical validation of image segmentation quality based on a spatial overlap index. *Academic radiology*. 2004; 11 (2): 178–189. [https://doi.org/10.1016/s1076-6332\(03\)00671-8](https://doi.org/10.1016/s1076-6332(03)00671-8)
8. Ni H., Zhou G., Chen X. et al. Predicting Recurrence in Pancreatic Ductal Adenocarcinoma after Radical Surgery Using an AX-Unet Pancreas Segmentation Model and Dynamic Nomogram. *Bioengineering (Basel)*. 2023; 10 (7): 828. <https://doi.org/10.3390/bioengineering10070828>
9. Mahmoudi T., Kouzahan Z.M., Radmard A.R. et al. Segmentation of pancreatic ductal adenocarcinoma (PDAC) and surrounding vessels in CT images using deep convolutional neural networks and texture descriptors. *Sci. Rep.* 2022; 12 (1): 3092. <https://doi.org/10.1038/s41598-022-07111-9>
10. Antonelli M., Reinke A., Bakas S. et al. The Medical Segmentation Decathlon. *Nat Commun.* 2022; 13: 4128. <https://doi.org/10.1038/s41467-022-30695-9>
11. Li J., Qi L., Chen Q. et al. A dual meta-learning framework based on idle data for enhancing segmentation of pancreatic cancer. *Medical Image Analysis*. 2022; 78: 102342. <https://doi.org/10.1016/j.media.2021.102342>
12. Miao Q., Wang X., Cui J. et al. Artificial intelligence to predict T4 stage of pancreatic ductal adenocarcinoma using CT imaging. *Comput. Biol. Med.* 2024; 171: 108125. <https://doi.org/10.1016/j.compbiomed.2024.108125>



13. Tikhonova V.S., Karmazanovsky G.G., Kondratyev E.V. et al. Radiomics model-based algorithm for preoperative prediction of pancreatic ductal adenocarcinoma grade. *Eur. Radiol.* 2023; 33 (2): 1152–1161. <https://doi.org/10.1007/s00330-022-09046-1>
14. Alves N., Schuurmans M., Litjens G. et al. Fully Automatic Deep Learning Framework for Pancreatic Ductal Adenocarcinoma Detection on Computed Tomography. *Cancers (Basel)*. 2022; 14 (2): 376. <https://doi.org/10.3390/cancers14020376>
15. Fedorov A., Beichel R., Kalpathy-Cramer J. et al. 3D Slicer as an image computing platform for the Quantitative Imaging Network. *Magn. Reson. Imaging*. 2012; 30 (9): 1323–1341. <https://doi.org/10.1016/j.mri.2012.05.001>
16. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation, in Medical Image Computing and Computer-Assisted Intervention. *MICCAI*. 2015, Springer, 9351 (2015): 234–241. https://doi.org/10.1007/978-3-319-24574-4_28
17. Wasserthal J., Breit H.C., Meyer M.T. et al. TotalSegmentator: Robust Segmentation of 104 Anatomic Structures in CT Images. *Radiol. Artif. Intell.* 2023; 5 (5): e230024. <https://doi.org/10.1148/ryai.230024>
18. Roth H., Farag A., Turkbey E.B. et al. Data From Pancreas-CT (Version 2) [Data set]. *The Cancer Imaging Archive*. 2016. <https://doi.org/10.7937/K9/TCIA.2016.tNB1kqBU>
19. Cai Y., Long Y., Han Z. et al. Swin Unet3D: a three-dimensional medical image segmentation network combining vision transformer and convolution. *BMC Med. Inform. Decis. Mak.* 2023; 23 (1): 33. <https://doi.org/10.1186/s12911-023-02129-z>

Для корреспонденции*: Замятина Ксения Андреевна – e-mail: catos-zama@mail.ru

Замятина Ксения Андреевна – аспирант по специальности “лучевая диагностика” ФГБУ “НМИЦ хирургии им. А.В. Вишневского” Минздрава России, Москва. <https://orcid.org/0000-0002-1643-6613>. E-mail: catos-zama@mail.ru

Жарикова Александра Витальевна – ординатор по специальности “лучевая диагностика” ФГБУ “НМИЦ хирургии им. А.В. Вишневского” Минздрава России, Москва. <https://orcid.org/0000-0001-8117-6670>. E-mail: zha-vit@yandex.ru

Кондратьев Евгений Валерьевич – канд. мед. наук, старший научный сотрудник ФГБУ “НМИЦ хирургии им. А.В. Вишневского” Минздрава России, Москва. <https://orcid.org/0000-0001-7070-3391>. E-mail: evgenykondratiev@gmail.com

Усталов Андрей Александрович – ординатор по специальности “рентгенология” ФГБУ “НМИЦ хирургии им. А.В. Вишневского” Минздрава России, Москва. <https://orcid.org/0009-0005-9267-8584>. E-mail: andreiustalov@gmail.com

Староверов Николай Евгеньевич – канд. техн. наук, ассистент кафедры электронных приборов и устройств Санкт-Петербургского государственного электротехнического университета “ЛЭТИ” им. В.И. Ульянова (Ленина), Санкт-Петербург. <https://orcid.org/0000-0002-4404-5222>. E-mail: nik0205st@mail.ru

Нефедьев Николай Алексеевич – аспирант по специальности “теоретическая информатика, кибернетика” ФГБУ ВО и науки “Санкт-Петербургский национальный исследовательский Академический университет имени Ж.И. Алфёрова Российской академии наук”, Санкт-Петербург. <https://orcid.org/0009-0004-6601-8884>. E-mail: Nikolay-Nefedev@yandex.ru

Гожева Алла Романовна – студентка ФГБОУ ВО “Санкт-Петербургский государственный педиатрический медицинский университет” Минздрава России, Санкт-Петербург. <https://orcid.org/0009-0004-9295-9821>. E-mail: gozhevaaa@mail.ru

Шмелева София Антоновна – ординатор первого года по специальности “рентгенология” ФГБУ “НМИЦ хирургии им. А.В. Вишневского” Минздрава России, Москва. <https://orcid.org/0009-0007-5724-2763>. E-mail: sofiaantonovna@gmail.com

Кармазановский Григорий Григорьевич – академик РАН, доктор мед. наук, профессор, заведующий отделом лучевых методов диагностики и лечения ФГБУ “НМИЦ хирургии им. А.В. Вишневского” Минздрава России; профессор кафедры лучевой диагностики и терапии медикобиологического факультета ФГБОУ ВО РНИМУ им. Н.И. Пирогова Минздрава России, Москва. <https://orcid.org/0000-000293570998>. Email: karmazanovsky@ixv.ru

Contact*: Ksenia A. Zamyatina – e-mail: catos-zama@mail.ru

Ksenia A. Zamyatina – Resident of A.V. Vishnevsky National Medical Research Center of Surgery the Ministry of Health of the Russian Federation, Moscow. <https://orcid.org/0000-0002-1643-6613>. E-mail: catos-zama@mail.ru

Alexandra V. Zharikova – Resident Physician of radiology department, A.V. Vishnevsky National Medical Research Centre of Surgery, Moscow. <https://orcid.org/0000-0001-8117-6670>. E-mail: zha-vit@yandex.ru

Evgeniy V. Kondratev – Cand. of Sci. (Med.), senior researcher officer of A.V. Vishnevsky National Medical Research Centre of Surgery, Moscow. <https://orcid.org/0000-0001-7070-3391>. E-mail: evgenykondratiev@gmail.com

Andrey A. Ustalov – postgraduate student, Radiology Department of A.V. Vishnevsky National Medical Research Centre of Surgery, Moscow. <https://orcid.org/0009-0005-9267-8584>. eLibrary SPIN: 5058-5207. E-mail: andreiustalov@gmail.com

Nikolay E. Staroverov – Cand. of Sci. (Techn.), assistant at the department of electronic devices in Saint-Petersburg State Electrotechnical University, St.-Petersburg. <https://orcid.org/0000-0002-4404-5222>. E-mail: nik0205st@mail.ru

Nikolay A. Nefedev – postgraduate student, Department of Theoretical Computer Science and Cybernetics, Alferov Federal State Budgetary Institution of Higher Education and Science Saint Petersburg National Research Academic University of the Russian Academy of Sciences, St.-Petersburg. <https://orcid.org/0009-0004-6601-8884>. E-mail: Nikolay-Nefedev@yandex.ru

Alla R. Gozheva – student of Federal State Budgetary Educational Institution Of Higher Education Saint-Petersburg State Pediatric Medical University, St.-Petersburg. <https://orcid.org/0009-0004-9295-9821>. E-mail: gozhevaaa@mail.ru

Sofia A. Shmeleva – first year postgraduate student, Radiology Department of A.V. Vishnevsky National Medical Research Centre of Surgery, Moscow. <https://orcid.org/0009-0007-5724-2763>. E-mail: sofiaantonovna@gmail.com

Grigory G. Karmazanovsky – Russian Academy of Sciences (RAS) Full Member, Doct. of Sci. (Med.), Professor, Head of the Diagnostic Radiology Department at the A.V. Vishnevsky National Medical Research Center of Surgery; Professor of radiology department, Pirogov Russian national research medical university, Moscow. <https://orcid.org/0000-0002-9357-0998>. E-mail: karmazanovsky@ixv.ru