

## Искусственный интеллект в технологиях сегментации и классификации нейроонкологических очагов

А.Ю. Летягин<sup>1,2</sup>, Б.Н. Тучинов<sup>1</sup>, Е.В. Амелина<sup>1</sup>, Е.Н. Павловский<sup>1</sup>, С.К. Голушко<sup>1</sup>,  
М.Е. Амелин<sup>1,3</sup>, Д.А. Рзаев<sup>3</sup>

<sup>1</sup> Новосибирский государственный университет  
630090, г. Новосибирск, ул. Пирогова, 1

<sup>2</sup> НИИ клинической и экспериментальной лимфологии –  
филиал ФИЦ Институт цитологии и генетики СО РАН  
630060, г. Новосибирск, ул. Тимакова, 2

<sup>3</sup> Федеральный нейрохирургический центр Минздрава России  
630048, г. Новосибирск, ул. Немировича-Данченко, 132/1

### Резюме

Исследование посвящено анализу результативности современных подходов к формированию диагностической технологии анализа МРТ-изображений в нейроонкологии, построенной на основе искусственного интеллекта (ИИ) и компьютерного зрения. Такие подходы необходимы для быстрого и диагностически эффективного анализа в целях реализации принципа индивидуализированной медицины. **Материал и методы.** Выполнен анализ результативности выбора технологий ИИ для формирования процессов сегментации и классификации нейроонкологических МРТ-изображений. ИИ был обучен на собственной аннотированной базе данных (SBT Dataset), содержащей около 1000 клинических случаев на основе архивных данных предоперационных МРТ-исследований в ФГБУ «Федеральный нейрохирургический центр» (Новосибирск), у пациентов с астроцитомой, глиобластомой, менингиомой, невриномой и с метастазами соматических опухолей, с гистологическим и гистохимическим послеоперационным подтверждением. **Результаты и их обсуждение.** Результативность и эффективность разработанных технологий проверена в ходе международных соревнований BraTS, в которых предлагалось сегментировать и классифицировать случаи из набора данных по нейроонкологическим пациентам, подготовленного организаторами соревнования. **Заключение.** Предложенные в статье методологические подходы в разработке диагностических систем на основе ИИ и принципов компьютерного зрения показали высокую эффективность на уровне десятки мировых лидеров и могут использоваться для разработки программно-аппаратных комплексов для диагностической нейрорадиологии с функциями «помощника врача».

**Ключевые слова:** МРТ, нейроонкология, искусственный интеллект, сегментация опухоли, классификация опухолей головного мозга.

**Конфликт интересов.** Авторы заявляют об отсутствии конфликта интересов.

**Автор для переписки:** Летягин А.Ю., e-mail: letyagin-andrey@yandex.ru

**Для цитирования:** Летягин А.Ю., Тучинов Б.Н., Амелина Е.В., Павловский Е.Н., Голушко С.К., Амелин М.Е., Рзаев Д.А Искусственный интеллект в технологиях сегментации и классификации нейроонкологических очагов. *Сибирский научный медицинский журнал.* 2024;44(1):32–38. doi: 10.18699/SSMJ20240104

## Artificial intelligence in technologies for segmentation and classification of neuro-oncological lesions

A.Yu. Letyagin<sup>1,2</sup>, B.N. Tuchinov<sup>1</sup>, E.V. Amelina<sup>1</sup>, E.N. Pavlovsky<sup>1</sup>, S.K. Golushko<sup>1</sup>,  
M.E. Amelin<sup>1,3</sup>, D.A. Rzaev<sup>3</sup>

<sup>1</sup> Novosibirsk State University  
630090, Novosibirsk, Pirogova st., 1

<sup>2</sup> Research Institute of Clinical and Experimental Lymphology –  
Branch of the Institute of Cytology and Genetics of SB RAS  
630060, Novosibirsk, Timakova st., 2

<sup>3</sup> Federal Neurosurgical Center of the Ministry of Health of Russia  
630048, Novosibirsk, Nemirovicha-Danchenko st., 132/1

## Abstract

The study is devoted to considering the effectiveness of modern approaches to the development of diagnostic technology for analyzing MRI images in neuro-oncology, based on artificial intelligence (AI) and computer vision. Such approaches are necessary for rapid and diagnostically effective analysis to implement the principle of individualized medicine. **Material and methods.** An analysis of the effectiveness of the choice of AI technologies for the formation of processes of segmentation and classification of neuro-oncological MRI images has been presented. AI was trained on its own annotated database (SBT Dataset), containing about 1000 clinical cases based on archival data from preoperative MRI studies at the Federal Neurosurgical Center (Novosibirsk, Russian Federation), in patients with astrocytoma, glioblastoma, meningioma, neuroma, and with metastases of somatic tumors, with histological and histochemical postoperative confirmation. **Results and discussion.** The effectiveness and efficiency of the developed technologies was tested during the international BraTS competition, in which it was proposed to segment and classify cases from a dataset of neuro-oncological patients prepared by the competition organizers. **Conclusions.** The methodological approaches proposed in the article in the development of diagnostic systems based on AI and the principles of computer vision have shown high efficiency at the level of dozens of world leaders and can be used to develop software and hardware systems for diagnostic neuroradiology with the functions of a “doctor’s assistant.”

**Key words:** MRI, neuro-oncology, artificial intelligence, tumor segmentation, classification of brain tumors.

**Conflict of interests.** The authors declare no conflict of interest.

**Correspondence author:** Letyagin A.Yu., e-mail: letyagin-andrey@yandex.ru

**Citation:** Letyagin A.Yu., Tuchinov B.N., Amelina E.V., Pavlovsky E.N., Golushko S.K., Amelin M.E., Rzaev D.A. Artificial intelligence in technologies for segmentation and classification of neuro-oncological lesions. *Sibirskij nauchnyj meditsinskij zhurnal = Siberian Scientific Medical Journal*. 2024;44(1):32–38 [In Russian]. doi: 10.18699/SSMJ20240104

## Введение

Предоперационная диагностика в нейроонкологии с контрастным усилением Gd-содержащими препаратами имеет системные проблемы из-за схожих визуализационных признаков (биомаркеров) на МРТ-изображениях, выполненных на клинических МРТ-сканерах с индукцией магнитного поля 1,5–3,0 Тл. Классификация опухолей ЦНС в 5-м издании ВОЗ основана на гистологических характеристиках опухолей, хотя после 2016 г. все больше ориентируются на молекулярно-генетические параметры опухолей. Максимально корректная предоперационная характеристика, близкая к патогистологической и молекулярно-генетической, определяет тактику и объем оперативного пособия. Биопсийный материал становится доступным только в послеоперационном периоде, поэтому предоперационная МРТ с Gd-контрастированием является международным признанным «золотым» стандартом. В «ручном» режиме сегментация нейроонкологических очагов является важной, но трудоемкой и сложной частью диагностики из-за неявных различий в форме, размере, расположении и параметрах контрастирования.

Имеются дву- и трехмерные архитектуры сверточных нейронных сетей. Первые быстрее для задач сегментации изображений, последние позволяют улучшить качество сегментации, но требуют больших вычислительных затрат (с повышением времени обучения и снижением

скорости работы). Разработана автоматическая система сегментации на основе искусственного интеллекта (ИИ) с помощью программы 3D Slicer (<https://www.slicer.org/>), обеспечивающая достаточно быструю и точную сегментацию опухоли в реальном масштабе времени, что важно для диагностики и планирования оперативного пособия. На основе модели пациента и модели информационного обмена между членами коллектива разработчиков базы данных (SBT Dataset, более 900 клинических случаев) отстроена процедура сегментации с контролем двумя сертифицированными нейрорадиологами. SBT Dataset сопоставима по объему и уровню верификации с наиболее популярными мировыми базами [1].

Многоклассовая классификация опухолей головного мозга в виде автоматических алгоритмов на основе ИИ – популярная тема исследований. Как правило, они основаны на сетевых открытых данных, которые, однако, не являются репрезентативными для российских пациентов. Более того, в большинстве исследований показатель точности используется как единственный критерий оценки эффективности модели. Такая статистика игнорирует распределение классов в данных и может привести к неточным результатам. Мы попытались решить эти задачи, используя базу данных пациентов, живущих в России, для обучения, проверки и тестирования с разделением данных по идентификаторам случаев и с использованием различных метрик мульти-

классовой классификации. Также мы сравниваем и анализируем результаты производительности простой нейронной сети, обученной с нуля для конкретной задачи, с предварительно обученной глубокой нейронной сетью [2].

Цель работы – разработать и проанализировать эффективность технологий персонализированной диагностики МРТ-изображений нейронкологических заболеваний с использованием ИИ на основе методов глубокого машинного обучения. Для задачи сегментации изображений и классификации (дифференциальной диагностики) опухолей головного мозга использовались методы ИИ, основанные на внимании.

## Материал и методы

Процесс ИИ-сегментации начинается с присвоения меток (объектов) каждому вокселу на МРТ-изображении. На основании первичной разметки формировались производные классы, как принято в международных соревнованиях по тестированию программ ИИ для медицинской визуализации: ET (часть опухоли, поглощающая Gd-содержащий контраст) = EnTu; TC (tumor core – ядро опухоли) = ET + Necr + NenTu; WT (whole tumor – опухоль целиком) = TC + Ed. Использовалась кроссплатформенная бесплатная система сегментации, регистрации, планирования и навигации медицинских 3D-изображений – программный продукт с открытым исходным кодом 3D Slicer [3]. Применяли два варианта сегментации: ручной режим двумя высококвалифицированными независимыми экспертами-рентгенологами и автоматическая конвейерная ИИ-сегментация с оценкой масок сегментации также двумя экспертами-радиологами (в ряде случаев – с ручной коррекцией).

Технология ИИ-сегментации на основе 2D нейронной сети включала повоксельное вычитание T1 из T1C (с Gd-контрастированием); поиск максимального усиления сигнала (накопления контрастного препарата); включенные каналы: уникальный вход с фильтрацией и конструирование изображений с бинарным объединением данных из пакетов T1, T1C (Gd) и T2-FLAIR; создание псевдоцветного RGB-подобного 3-канального изображения с едиными координатами вокселей из трех базовых МРТ-технологий в одно псевдо-RGB-изображение; эксперименты на обучающей выборке проводились с 5-кратной перекрестной проверкой.

Основные методы и инструменты: язык программирования Python/CUDA; OpenCV – библиотека алгоритмов компьютерного зрения, обработки изображений и численных алгоритмов общего

назначения с открытым кодом; PyTorch – фреймворк машинного обучения для языка Python с открытым исходным кодом, созданный на базе Torch и использующийся для решения задач компьютерного зрения; Keras – открытая библиотека на языке Python, обеспечивающая взаимодействие с искусственными нейронными сетями и нейросетевой библиотекой TensorFlow; TensorFlow – библиотека для решения задач построения и тренировки нейронной сети, автоматического нахождения и классификации образов по аналогии с человеческим восприятием.

Использовались двумерные сети U-Net и LinkNet и трехмерные PSPNet и FPN, а также nnU-Net и TransBTS с разными базовыми сетями (backbones) – Resnet18, Resnet34, ResNet50, ResNet101, SeResNet50, SeResNet101, SeResNext50, SeResNext101.

Одна из наиболее успешных 2D-архитектур для сегментации LinkNet [4] сравнивалась по скорости и количеству параметров с DMFnet [5], легкая и быстрая архитектура на основе LinkNet и DMFNet с nnU-Net сравнивалась с 3D-архитектурой, использующей трансформеры TransBTS (победитель BraTS2020) [6]. Дополнительно проверялась целесообразность использования оптимизационных алгоритмов Adam, SGD (стохастический оптимизатор градиентного спуска), оптимизаторов RMSprop, Adagrad, Adadelta, Adamax, Nesterov Adam. Также применялась технология «увеличенного времени тестирования» (the test time augmentation, TTA) – метод компьютерного зрения для повышения точности модели за счет увеличения количества данных на этапе вывода (для каждого тестового изображения создавались версии, развернутые на определенные углы, и с увеличением краев для устранения артефактов негомогенности поля). Принципиальная схема проведения экспериментов представлена на рисунке.

## Результаты

В ходе обучения моделей сегментации было предположено, что срезы, включающие только отечную часть поражения, не информативны и могут быть исключены из тестового набора (принцип edema cut). Предположение реализовано с помощью технологии TTA. Это дало улучшение прогнозов на модели LinkNet: в исходном варианте Sx101 Initial точность по срезу (точность по случаю) была на уровне 0,7809 (0,85), а в модифицированном варианте Sx101+edema cut+TTA – 0,8939 (0,925). Поэтому принцип исключения отека использован нами и в других архитектурах ИИ. Выполнено сравнение эффектив-

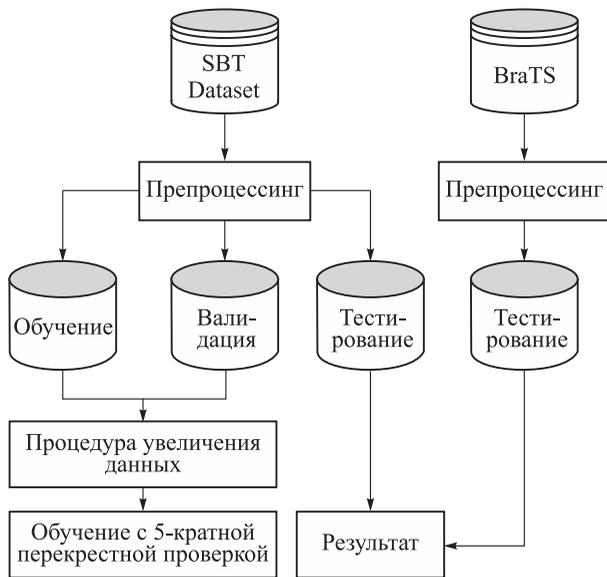


Схема проведения экспериментов: сначала выполняется предварительная обработка наборов данных для преобразования 3D-изображений МРТ в 2D-срезы опухолей, после этого проводится обучение и проверка с сегментацией и без нее, и затем – тестирование как на SBT Dataset, так и на открытых базах данных BraTS

Experimental design: first, preprocessing of data sets is performed to convert 3D MRI images into 2D tumor sections, then training and testing with and without segmentation are carried out, and then testing is carried out both on the SBT Dataset and on the open databases of BraTS

ности различных подходов 3D- и 2D-сетей ИИ, с предварительной обработкой чистых данных с самоконтролем, различных методов оптимизации постобработки и различных архитектур нейронных сетей. Прогнозирование элементов опухоли для каждого тестового объема МРТ-изображений производилось с использованием схемы «головоания» среди всех МРТ-срезов, включающих только объект интереса – опухоль.

SBT Dataset использовалась как инструмент обучения ИИ с последующим анализом тестовых наборов международных конкурсов BraTS 2020 и BraTS 2021. Основные результаты моде-

лей для сегментации оценены по метрикам точности Sensivity (чувствительность) и Specificity (специфичность), Dice для областей ET, TC и WT (соответственно Sens, Spec, DiceET, DiceTC и DiceWT). Наилучшие результаты получены на обучающей выборке из SBT Dataset (363 пациента), для анализа выборки BraTS 2020 из 494 пациентов (табл. 1).

В другом случае соревновательный набор данных BraTS 2021 состоял из 2000 случаев глиом, включая части обучения (1251) и проверки (219), а данные тестирования приведены на примере SBT Dataset v.2 2021 г. (во всех случаях это были МРТ-изображения по технологиям T1; T1C; T2; T2-FLAIR). Реализация выполнялась с нахождением границ (сегментации) описанных выше структур (табл. 2).

По результатам, представленным в табл. 1 и 2, можно заключить следующее: LinkNet показал худшие результаты, чем другие архитектуры, на данных BraTS 2021, но «вышел» на 2-е место на данных SBT; nnU-net показал отличные результаты на обоих наборах данных, что еще раз подтверждает стабильность метода; DMFnet – быстрый и стабильный метод, хорошо работал с обоими наборами данных; TransBTS – многообещающий подход-трансформер, хорошо показал себя на данных BraTS 2021 (сегментация глиом), но дал худший результат по сравнению с другими при увеличении количества типов и классов опухолей. Это может указывать на проблему при обучении методов с помощью Transformers: чем больше классов, тем больше данных нужно для обучения этой архитектуры.

Разработанные и обученные нами модели ИИ с различной архитектурой (табл. 3) проверялись на тестовом наборе конкурса BraTS 2021, и усложнение архитектуры с добавлением блока самоконтроля (nn-Unet with self-supervised) в сочетании двух технологий (nn-Unet + DMFnet и nn-Unet with self-supervised + DMFnet) позволило достичь уровня Dice 0,9242 для сегментации всего объема опухоли [7].

Таблица 1. Результаты сегментации на соревновательном наборе данных BraTS 2020 Challenge

Table 1. Segmentation results on the BraTS 2020 Challenge competitive dataset

Модель архитектуры ИИ / Результат	DiceET	DiceTC	DiceWT	Sens	Spec
LinkNet	0,614	0,758	0,871	0,790	0,998
nnU-net	0,771	0,836	0,916	0,868	0,999
DMFNet	0,742	0,812	0,893	0,848	0,998
TransBTS	0,764	0,817	0,897	0,846	0,999

Примечание. Обучение моделей ИИ с различной архитектурой выполнено на примере SBT v.1 2020 г., все показатели являются средними результатами для 5-кратного повторения.

**Таблица 2.** Результаты сегментации на примере SBT v.2 2021 года после обучения на наборе данных BraTS 2021

**Table 2.** Segmentation results using the example of SBT v.2 2021, after training on the BraTS 2021 data set. AI models with different architectures

Модель архитектуры ИИ / Результат	DiceET	DiceTC	DiceWT	Sens	Spec
LinkNet	0,826	0,826	0,911	0,872	1,000
nnU-net	0,846	0,867	0,917	0,881	1,000
DMFNet	0,796	0,827	0,900	0,851	1,000
TransBTS	0,756	0,753	0,858	0,868	1,000

**Примечание.** Модели ИИ с различной архитектурой, все показатели являются средними результатами для 5-кратного повторения.

**Таблица 3.** Результаты ИИ-сегментации с различной архитектурой на проверочном наборе данных конкурса BraTS 2021

**Table 3.** AI segmentation results with different architectures on the validation dataset of the BraTS 2021 competition

Архитектура	Число подходов	Dice ET	Dice TC	Dice WT
LinkNet	15	0,763	0,828	0,9020
nn-Unet + DMFnet	70	<b>0,8498</b>	0,8768	0,9229
nn-Unet with self-supervised + DMFnet	73	0,8474	<b>0,8820</b>	<b>0,9242</b>

Также в рамках задачи сегментации опухолей головного мозга разработан и протестирован 2D-подход – как на SBT Dataset, так и в рамках соревнований BraTS 2020 и BraTS 2021. Решалась дополнительная исследовательская задача по оценке меры неопределенности при сегментации субрегионов глиом. Выявлены методы «уверенности», которые: (а) «уверены», когда верны, и (б) «не уверены», когда неверны. Неопределенности были связаны метриками Dice. Значения неопределенности нормализовались от 0 до 100 по всему набору данных, где «0» представлял наиболее надежный прогноз, а «100» – наиболее неопределенный. Формировались три карты неопределенности, содержащие метки классов для каждого вокселя. Карты неопределенности должны быть связаны с областями ET, TC и WT [8–10]. Данная исследовательская задача моделирует диагностическую работу радиологов и нейрохирургов при определении границ сегментов, накапливающих и не накапливающих контрастный препарат, некроза в опухолях головного мозга и перифокального (перитуморального) отека. Достигнуты уровни 0,866, 0,869 и 0,921 для оценок Dice ET, TC и WT соответственно.

Для задачи классификации опухолей также выполнено сравнение эффективности различных архитектур магистральных 3D- и 2D-нейронных сетей (на основе ИИ) с предварительной обработкой чистых данных с самоконтролем и различными методами оптимизации постобработки. Прогнозирование класса опухоли для каждого

тестового объема МРТ-изображений производилось с использованием схемы «голосования» среди всех срезов, включающих только опухоль (по результатам сегментации) [11]. Мультиклассовый классификатор оценивался с использованием следующих метрик: ACC – точность, измеряет общую оценку того, насколько хорошо модель предсказывает весь набор данных (показатель интуитивно понятен, но он игнорирует распределение классов); F1 – средневзвешенное значение точности и полноты (чувствительности), объединяет данные показатели в рамках понятия среднего гармонического, обычно используется, когда данные искажены; Sens – чувствительность, показывает вероятность точного предсказания действительно положительных образцов текущего класса; Spec – специфичность, показывает вероятность правильного классифицирования фактических отрицательных образцов; PRE – прецизионная точность, показывает долю спрогнозированных положительных образцов текущего класса, которые являются правильными. Все показатели варьируют от 0 до 1 (чем выше, тем лучше), а матрица ошибок используется при тестировании для анализа и сравнения производительности.

Для изучения производительности нейронной сети с предварительно обученной моделью в задаче классификации опухолей головного мозга были обучены нейронная сеть SplNet и последний слой предварительно обученной сети VGG16 с двумя наборами данных: SBT Dataset с сег-

Таблица 4. Значения показателей оценки для четырех моделей

Table 4. Values of evaluation indicators for four model

Модель	ACC	F1	Sens	Spec	PRE
SplNet	0,8599	0,856	0,8599	0,9533	0,872
SplNet_noseg	0,5574	0,5155	0,5574	0,8525	0,5182
VGG	0,8951	0,8943	0,8951	0,965	0,9045
VGG_noseg	0,8087	0,8082	0,8087	0,9362	0,8186

ментацией по семантическим признакам и SBT Dataset без сегментации. Эти модели были названы SplNet, VGG, SplNet\_noseg и VGG\_noseg соответственно. Установлено, что SplNet и VGG, обученные с помощью сегментации, превосходят модели без сегментации (табл. 4). Получается, что сегментация опухоли в виде набора семантических признаков (биомаркеров) «направляет» модель к соответствующим областям на изображениях и предоставляет классификаторам полезную информацию о внутренней структуре опухоли.

Результаты, полученные на выборке данных 255 пациентов из SBT Dataset, подтверждают стабильность и надежность ИИ-технологии для четырех типов опухолей (менингиома, невринома, глиобластома и астроцитомы), что важно с клинической точки зрения для решения задач сегментации и классификации.

### Заключение

Повышение точности и своевременности медицинской визуализации в реальной клинической практике нейрохирургии – актуальная проблема для решения с помощью ИИ. Поиск и сегментация (контурирование) «подозрительных» патологических объектов может выполняться автоматически через многомерные измерения на медицинских трехмерных МРТ-изображениях, с формализацией количественных показателей, с более точной и быстрой интерпретацией, как инструмент принятия решений для врача-нейрорадиолога. Для обучения, валидации и тестирования сети целесообразно предварительно исключать из баз данных T2-взвешенные изображения, и также FLAIR-изображения с областями отека и срезы, не содержащие опухоль. Для улучшения процесса классификации (дифференциальной диагностики) опухолей мозга с помощью сверхточной нейронной сети (CNN) целесообразно использовать сегментацию опухолей на стандартные зоны опухолевого процесса в качестве исходных дополнительных семантических признаков. Разработана нейронная сеть из четырех сверточных слоев для извлечения признаков и двух линейных слоев для классификации. Классификатор, обученный с помощью предваритель-

ной сегментации, достигает достаточно высоких показателей точности – 0,92, чувствительности – 0,934, специфичности – 0,91 и оценки F1 – 0,90.

### Список литературы / References

1. Амелина Е.В., Летягин А.Ю., Тучинов Б.Н., Толстокулаков Н.Ю., Амелин М.Е., Павловский Е.Н., Гроза В.В., Голушко С.К. Особенности создания базы данных нейроонкологических 3D МРТ-изображений для обучения искусственного интеллекта. *Сиб. науч. мед. ж.* 2022;42(6):51–59. [In Russian]. doi: 10.18699/SSMJ20220606

Amelina E.V., Letyagin A.Yu., Tuchinov B.N., Tolstokulakov N.Yu., Amelin M.E., Pavlovsky E.N., Groza V.V., Golushko S.K. Specific features of designing a database for neuro-oncological 3D MRI images to be used in training artificial intelligence. *Sibirskij nauchnyj medicinskij zhurnal = Siberian Scientific Medical Journal.* 2022;42(6):51–59. [In Russian]. doi: 10.18699/SSMJ20220606

2. Sao Khue L.M., Pavlovskiy E. Improving brain tumor multiclass classification with semantic features. *2022 Ural-Siberian Conference on Computational Technologies in Cognitive Science, Genomics and Biomedicine (CSGB): proc. conf., 4–8 July, 2022. Novosibirsk.* P. 150–154. doi: 10.1109/CSGB56354.2022.9865366

3. Fedorov A., Beichel R., Kalpathy-Cramer J., Finet J., Fillion-Robin J.C., Pujol S., Bauer C., Jennings D., Fennessy F.M., Sonka M., Buatti J., Aylward S.R., Miller J.V., Pieper S., Kikinis R. 3D Slicer as an image computing platform for the quantitative imaging network. *Magn. Reson. Imaging.* 2012;30(9):1323–1341. doi: 10.1016/j.mri.2012.05.001

4. Chaurasia A., Culurciello E. Linknet: exploiting encoder representations for efficient semantic segmentation. *arXiv.* 2017;1707.03718. doi: 10.48550/arXiv.1707.03718

5. Chen C., Liu X., Ding M., Zheng J., Li J. 3D Dilated multi-fiber network for real-time brain tumor segmentation in MRI. *Medical Image Computing and Computer Assisted Intervention – MICCAI 2019: conf. paper. Lecture Notes in Computer Science (LNCS), vol. 11766. Springer, Cham.* 12–20. doi: 1007/978-3-030-32248-9\_21

6. Chen J., Lu Y., Yu Q., Luo X., Adeli E., Wang Y., Lu L., Yuille A.L., Zhou Y. TransUNet: Transformers make strong encoders for medical image segmen-

tation. *arXiv*. 2021;2102.04306. doi: 10.48550/arXiv.2102.04306

7. Pnev S., Groza V., Tuchinov B., Amelina E., Pavlovskiy E., Tolstokulakov N., Amelin M., Golushko S., Letyagin A. Brain tumor segmentation with self-supervised enhance region post-processing. *International MICCAI Brainlesion Workshop: proc. conf., virtual, online, 27.09.2021*. Springer, Cham, 2022. 267–275. doi: 10.1007/978-3-031-09002-8\_24

8. McKinley R., Rebsamen M., Dätwyler K., Meier R., Radojewski P., Wiest R. Uncertainty-driven refinement of tumor-core segmentation using 3D-to-2D networks with label uncertainty. *arXiv*. 2020;2012:06436. doi: 10.48550/arXiv.2012.06436

9. McKinley R., Wepfer R., Aschwanden F., Grun-der L., Muri R., Rummel C., Verma R., Weisstanner C., Reyes M., Salmen A., Chan A., Wagner F., Wiest R.

Simultaneous lesion and brain segmentation in multiple sclerosis using deep neural networks. *Sci. Rep.* 2021;11(1):1087. doi: 10.1038/s41598-020-79925-4

10. Vu M.H., Nyholm T., Löfstedt T. Multi-decoder networks with multi-denoising inputs for tumor segmentation. *arXiv*. 2020;2012:03684. doi: 10.48550/arXiv.2012.03684

11. Pnev S., Groza V., Tuchinov B., Amelina E., Pavlovskiy E., Tolstokulakov N., Amelin M., Golushko S., Letyagin A. Multi-Class brain tumor segmentation via 3d and 2d neural networks. *19th International Symposium on Biomedical Imaging (ISBI): proc. symp., 28–31 March 2022, Kolkata, India. IEEE, 2022. 1-5. INSPEC Accession Number: 21760341. doi: 10.1109/ISBI52829.2022.9761538*

#### Сведения об авторах:

**Летягин Андрей Юрьевич**, д.м.н., проф., ORCID: 0000-0002-9293-4083, e-mail: letyagin-andrey@yandex.ru

**Тучинов Баир Николаевич**, ORCID: 0000-0002-8931-9848, e-mail: bairt@nsu.ru

**Амелина Евгения Валерьевна**, к.ф.-м.н., ORCID ID: 0000-0001-7537-3846, e-mail: amelina.evgenia@gmail.com

**Павловский Евгений Николаевич**, к.ф.-м.н., ORCID: 0000-0001-6976-1885, e-mail: pavlovskiy@post.nsu.ru

**Голушко Сергей Кузьмич**, д.ф.-м.н., проф., ORCID: 0000-0002-0207-7648, e-mail: s.k.golushko@gmail.com

**Амелин Михаил Евгеньевич**, к.м.н., ORCID: 0000-0002-5933-6479, e-mail: amelin81@gmail.com

**Рзаев Джамиль Афатович**, д.м.н., ORCID: 0000-0002-3885-3004, e-mail: jamilrzaev@gmail.com

#### Information about the authors:

**Andrey Yu. Letyagin**, doctor of medical sciences, professor, ORCID: 0000-0002-9293-4083;

e-mail: letyagin-andrey@yandex.ru

**Bair N. Tuchinov**, ORCID: 0000-0002-8931-9848, e-mail: bairt@nsu.ru

**Evgenia V. Amelina**, candidate of physical and mathematical sciences, ORCID: 0000-0001-7537-3846,

e-mail: amelina.evgenia@gmail.com

**Evgeny N. Pavlovsky**, candidate of physical and mathematical sciences, ORCID: 0000-0001-6976-1885,

e-mail: pavlovskiy@post.nsu.ru

**Sergey K. Golushko**, doctor of physical and mathematical sciences, professor, ORCID: 0000-0002-0207-7648,

e-mail: s.k.golushko@gmail.com

**Mikhail E. Amelin**, candidate of medical sciences, ORCID: 0000-0002-5933-6479, e-mail: amelin81@gmail.com

**Jamil A. Rzaev**, doctor of medical sciences, ORCID: 0000-0002-3885-3004, e-mail: jamilrzaev@gmail.com

Поступила в редакцию 16.09.2023

Принята к публикации 29.11.2023

Received 16.09.2023

Accepted 29.11.2023