

## Применение алгоритма компьютерного зрения для определения очагов демиелинизации при рассеянном склерозе на МРТ-изображениях

Б.Н. Тучинов<sup>1,2</sup>, В. Суворов<sup>1,2</sup>, К.О. Моторин<sup>1</sup>, Е.Н. Павловский<sup>1,2</sup>, Л.М. Василькив<sup>1,2</sup>, Ю.А. Станкевич<sup>1,2</sup>, А.А. Тулупов<sup>1,2</sup>

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

<sup>2</sup> Институт «Международный томографический центр» СО РАН  
630090, г. Новосибирск, ул. Институтская, 3а

### Резюме

Исследование направлено на анализ современных алгоритмов для диагностики поражений при рассеянном склерозе на МРТ-изображениях. Рассеянный склероз, тяжелое заболевание центральной нервной системы, занимает первое место среди причин инвалидности у пациентов молодого трудоспособного возраста. В связи с развитием технологий компьютерного зрения и машинного обучения растет актуальность применения данных технологий для медицинской диагностики. Такие подходы необходимы для эффективной разработки и внедрения диагностических систем с использованием искусственного интеллекта. **Материал и методы.** В статье представлены особенности диагностики рассеянного склероза на МРТ-изображениях, существующие наборы данных: ISBI-2015, MSSEG-2016, MSSEG-2021; существующие алгоритмы и модели сегментации поражений: U-Net, nnU-Net, TransUnet, TransBTS, UNETR, Swin UNETR. **Результаты и их обсуждение.** Проведено обучение и сравнение архитектур и моделей nnU-Net, UNETR, Swin UNETR на ISBI-2015 с различными параметрами и функциями потерь, использованы четыре последовательности МРТ: T2-взвешенное изображение, T2-FLAIR, PD, MPAGE. Сегментация поражений одобрена тремя аттестованными опытными нейрорадиологами. **Заключение.** Описанные в статье подходы, включая процессы обработки данных, обучения моделей, анализ результатов, были сосредоточены на выборе и разработке высококачественных алгоритмов компьютерного зрения для определения поражений при рассеянном склерозе на МРТ-изображениях. Выявление и сегментация очагов демиелинизации является необходимым этапом для диагностики заболевания, а также для расчета и интерпретации более значимых показателей тяжести и прогрессирования заболевания.

**Ключевые слова:** рассеянный склероз, компьютерное зрение, демиелинизация, сегментация изображений, МРТ, медицинская визуализация.

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

**Финансирование.** Исследование проведено в рамках проекта Российского научного фонда № 23-15-00377.

**Автор для переписки:** Тучинов Б.Н., e-mail: bairt@nsu.ru

**Для цитирования:** Тучинов Б.Н., Суворов В., Моторин К.О., Павловский Е.Н., Василькив Л.М., Станкевич Ю.А., Тулупов А.А. Применение алгоритма компьютерного зрения для определения очагов демиелинизации при рассеянном склерозе на МРТ-изображениях. *Сибирский научный медицинский журнал*. 2024;44(1):107–115. doi: 10.18699/SSMJ20240111

## Application of a computer vision algorithm to identify foci of demyelination in multiple sclerosis on MRI images

B.N. Tuchinov<sup>1,2</sup>, V. Suvorov<sup>1,2</sup>, K.O. Motorin<sup>1</sup>, E.N. Pavlovsky<sup>1,2</sup>, L.M. Vasilkiv<sup>1,2</sup>, Yu.A. Stankevich<sup>1,2</sup>, A.A. Tulupov<sup>1,2</sup>

<sup>1</sup> Novosibirsk State University

630090, Novosibirsk, Pirogova st., 1

<sup>2</sup> International Tomography Center of SB RAS

630090, Novosibirsk, Institutskaya st., 3a

## Abstract

The research was aimed at analyzing modern algorithms for diagnosing lesions in multiple sclerosis on MRI images. Multiple sclerosis is a severe disease of the central nervous system and ranks first among the causes of disability in patients of young working age. In connection with the development of computer vision and machine learning technologies, the relevance of using these technologies for medical diagnostics is growing. Such approaches are necessary for the effective development and implementation of diagnostic systems using artificial intelligence. Modern algorithms and models for lesion segmentation were selected and implemented. **Material and methods.** The paper presents CV features of diagnosing multiple sclerosis on MRI images, existing data sets: ISBI-2015, MSSEG-2016, MSSEG-2021; existing algorithms and models for lesion segmentation: U-Net, nnU-Net, TransUnet, TransBTS, UNETR, Swin UNETR. **Results and discussion.** The architectures and models of nnU-Net, UNETR, Swin UNETR were trained and compared at ISBI-2015 with various parameters and loss functions. Four MRI sequences were used: T2-WI, T2-FLAIR, PD, MPRAGE. Lesion segmentation was approved by certified experienced neuroradiologists. **Conclusions.** The approaches described in the paper including data processing, model training, and results analysis, focused on the selection and development of high-quality computer vision algorithms for identifying multiple sclerosis lesions in MRI images. Identification and segmentation of demyelination foci is a necessary step for diagnosing the disease, as well as for calculating and interpreting more meaningful indicators of disease severity and progression.

**Key words:** multiple sclerosis, computer vision, demyelination, image segmentation, MRI, medical imaging.

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

**Financing.** The research was supported by Russian Science Foundation № 23-15-00377.

**Correspondence author:** Tuchinov B.N., e-mail: bairt@nsu.ru

**Citation:** Tuchinov B.N., Suvorov V., Motorin K.O., Pavlovskiy E.N., Vasilkiv L.M., Stankevich Yu.A., Tulupov A.A. Application of a computer vision algorithm to identify foci of demyelination in multiple sclerosis on MRI images. *Sibirskij nauchnyj medicinskij zhurnal = Siberian Scientific Medical Journal*. 2024;44(1):107–115. [In Russian]. doi: 10.18699/SSMJ20240111

## Введение

Рассеянный склероз (РС) является наиболее распространенным демиелинизирующим заболеванием центральной нервной системы (ЦНС) и занимает первое место среди причин инвалидности у пациентов молодого трудоспособного возраста. РС поражает белое вещество головного и спинного мозга [1] и патоморфологически характеризуется повреждением миелиновых оболочек, что в свою очередь приводит к нарушению передачи нервных импульсов. Для данного заболевания характерно волнообразное течение с чередующимися периодами обострений и ремиссий. На начальных этапах заболевания отмечаются эпизоды неврологического нарушения, сопровождающиеся полным или частичным восстановлением без признаков прогрессирования, однако в дальнейшем происходит конверсия в прогрессирующую форму с нарастанием выраженности неврологического дефицита и степени инвалидизации. В последнее десятилетие во всем мире наблюдается устойчивая тенденция к увеличению частоты демиелинизирующих заболеваний, расширяются возрастные рамки дебюта демиелинизации – от 15 до 55 лет.

Существует большая вариабельность клинических проявлений РС, так как он может поражать различные отделы головного и спинного мозга и вызывать различную клиническую картину. Однако можно выделить наиболее харак-

терные ранние симптомы: нарушение чувствительности и боли в конечностях или туловище, шаткость при ходьбе, нистагм, нарушение зрения, мышечная слабость, головокружение, нарушение мочеиспускания. Диагностика основывается прежде всего на неврологическом осмотре с выявлением данных о мультифокальном поражении вещества головного и спинного мозга с использованием дополнительных лабораторных исследований, включающих проведение люмбальной пункции для анализа спинномозговой жидкости, метода вызванных потенциалов, анализа крови, а также МРТ для визуализации очагов демиелинизации. Данные методы диагностики приобретают особую значимость с точки зрения наблюдения за развитием заболевания и оценки состояния пациентов.

Учитывая развитие современных алгоритмов искусственного интеллекта и аппаратно-программного обеспечения сопутствующих методов диагностики демиелинизирующих заболеваний ЦНС, следует рассчитывать на повышение качества диагностики, выявления риска и прогнозирования развития патологического процесса. Основными задачами компьютерного зрения при анализе медицинских изображений являются детектирование, классификация и сегментация областей интереса, прогнозирование состояний.

Цель работы – проанализировать существующие современные методы компьютерного зрения

для медицинской визуализации при диагностике поражений РС на МРТ-снимках. Данная работа выполняется в рамках проекта РФФ № 23-15-00377 по разработке междисциплинарного подхода к динамической оценке радиологических и клинико-лабораторных проявлений РС на основе систем искусственного интеллекта (глубокого машинного обучения).

## Материал и методы

### Диагностика РС

МРТ головного и спинного мозга является наиболее информативным, безопасным и неинвазивным методом диагностики РС, обладает высокой разрешающей способностью и позволяет выявить очаги демиелинизации в трех плоскостях: аксиальной, сагиттальной и фронтальной. В последнее десятилетие широко используется МРТ с внутривенным введением гадолиний-содержащих контрастных веществ для улучшения визуализации очагов, позволяющих выявить мелкие очаги, которые неотчетливо визуализируются на нативных изображениях, оценить степень повреждения гематоэнцефалического барьера, а также дифференцировать очаги по степени их активности (рис. 1).

Очаги демиелинизации имеют округлую или овальную форму, их размеры варьируют от нескольких миллиметров до нескольких сантиметров в диаметре, с типичной локализацией: юкстокортикальные отделы – повреждение U-волокон (очаги тесно прилежат к кортикальным отделам долей головного мозга); перивентрикулярные отделы – визуализируются множественные очаги, в том числе «пальцы Доусона» (очаги овальной формы, расположенные перпендикулярно к желудочкам и тесно к ним прилегающие, результат воспаления, развившегося вокруг проникающих венул); мозолистое тело; инфра-

тенториально (в структуре ствола и мозжечка). Очаги демиелинизации характеризуются разной степенью повышения сигнала от структуры на T2-взвешенном изображении (T2-ВИ) и снижением сигнала на T1-ВИ. Резко гипоинтенсивные на T1-ВИ очаги по типу «черных дыр» указывают на хроническую стадию повреждения белого вещества с разрушением аксонов и необратимыми изменениями.

Основными критериями диагностики РС являются критерии Макдональда [2]. Поэтому большое значение имеет динамическое наблюдение, как правило, с интервалом 6–12 месяцев на аппарате с напряженностью магнитного поля не менее 1,5 Тл. В данной работе мы сконцентрировались на очаговых изменениях в белом веществе головного мозга.

### Компьютерное зрение для диагностики

Автоматическая сегментация поражений РС имеет большое значение для исследований клинических специалистов, будучи полезной для определения клинических критериев текущего состояния (постановка диагноза) и прогнозирования течения РС; сегментация важна для точного количественного анализа, необходимого для мониторинга прогрессирования заболевания. Поэтому выявление очагов демиелинизации и их сегментация является необходимым этапом для диагностики заболевания, а также для расчета и интерпретации более значимых показателей тяжести и прогрессирования заболевания.

В работе С. Zeng et al. [3] представлен обзор публикаций, использующих методы глубоких нейронных сетей для задачи сегментации очагов на МРТ-изображениях. Поскольку подходы глубокого обучения лидируют в сегментации трехмерных изображений, в ходе исследовательской работы нами изучены современные подходы и источники данных.

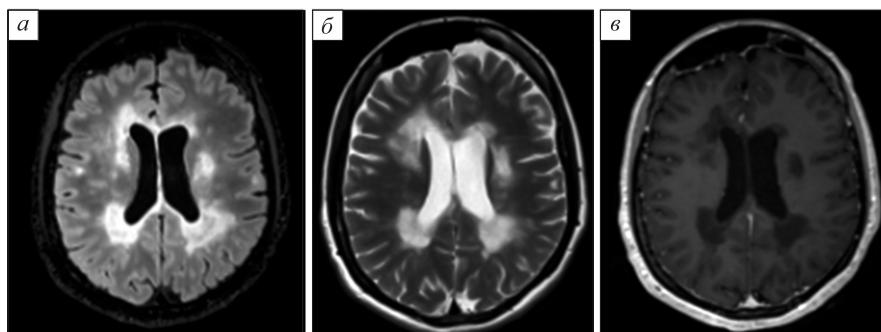


Рис. 1. Примеры МРТ-изображений: а – FLAIR, б – T2-взвешенное изображение, в – T1-взвешенное изображение, полученное после введения контрастного вещества

Fig. 1. Examples of MRI scans: а – FLAIR, б – T2 weighted image, в – T1 weighted image with contrast agent

### Наборы данных

Для проведения исследований имеется несколько наборов данных МРТ пациентов с РС с масками сегментации (табл. 1).

### Существующие методы

Методы глубокого обучения заняли ведущее место в задаче сегментации трехмерных изображений. Основная группа подходов основана на архитектуре U-net [7], разработанной для сегментации медицинских изображений и до сих пор широко используемой. Архитектура сети представляет собой последовательность слоев свертки и пулинга, которые сначала уменьшают пространственное разрешение картинки, а затем увеличивают его, предварительно объединив с данными входного изображения и пропустив через другие слои свертки. Данный подход показал отличные результаты и стал основой для множества новых модификаций данной архитектуры.

В работе [8] представлена архитектура нейронной сети, занявшей первое место на конкурсе Международного симпозиума по биомедицинской визуализации (ISBI-2015) по сегментации

поражений при РС. Архитектура представляет собой полносвязную сверточную нейронную сеть, похожую на U-сеть, с dense-блоками. Для модели использован метод послойного анализа (2,5D). Для обучения применяются наборы из трех срезов (один центральный и два соседних), имеющие хотя бы один воксель поражения РС для центрального среза. Таким образом, модель получает пространственную информацию по двум осям  $x, y$ , а также локальную информацию по оси  $z$ . Срезы делаются в трех проекциях – аксиальной, корональной и сагитальной.

Следующий хорошо зарекомендовавший себя подход для сегментации 3D-изображений – nnU-Net [9]. Он представляет собой самонастраивающийся фреймворк – набор алгоритмов и методов машинного обучения (предварительная обработка, сетевая архитектура, обучение и постобработка). При инициализации задается набор исходных параметров, на основе которых nnU-Net корректирует модель и метод обучения для получения наилучших результатов. Автонастройка nnU-Net основана на разделении параметров конфигурации на три типа: фиксированные, основанные

Таблица 1. Базы данных по схожей тематике

Table 1. Databases on similar topics

База данных	Описание			Количество случаев для обучения	Количество случаев для контроля
	Задача	Данные	Источник		
Longitudinal White Matter Lesion Segmentation of Multiple Sclerosis Challenge, ISBI-2015 [4]	Сегментация пораженного РС	Пакеты T2-ВИ, T2-Flair, PD и MPRAGE МР-томограмм	3.0 T Philips	5 пациентов, от 4 до 6 наблюдений на каждого пациента (всего 21 МРТ-исследование)	14 пациентов, от 4 до 6 наблюдений на каждого пациента (всего 61 МРТ-исследование)
Multiple Sclerosis lesion segmentation challenge, MS-SEG-2016 [5]	Сегментация пораженного РС	Пакеты 2D T2-ВИ, 3D T2-Flair, 3D T1-ВИ и 3D T1C МР-томограмм	4 сканера: GE Discovery 3T, Philips Ingenia 3T, Siemens Aera 1.5T, Siemens Verio 3T	15 пациентов (15 МРТ-исследований)	38 пациентов (38 МРТ-исследований)
Multiple Sclerosis new lesions segmentation challenge, MS-SEG-2021 [6]	Сегментация новых пораженного РС	Пакеты 3D T2-Flair МР-томограмм	15 сканеров: три GE: Optima MR450w 1.5T; SIGNA HDx 3T; SIGNA HDxt 1.5T; шесть Philips: 1 – Ingenia 1.5T; 2 – Ingenia 3T; 1 – Achieva dStream 3T; 1 – Achieva 1.5T; 1 – Achieva 3T; шесть Siemens: 1 – Aera 1.5T; 1 – Skyra 3T; 1 – Verio 3T, 1 – Prisma 3T; 2 – Avanto 1.5T	40 пациентов, по два наблюдения в двух временных точках (разметка только для второй временной точки). Всего 80 МРТ-исследований	60 пациентов (всего 120 МРТ-исследований)

на правилах и эмпирические параметры. В качестве моделей рассматриваются три варианта: 2D U-Net, 3D U-Net и каскад из двух моделей 3D U-Net. Метод был протестирован на 23 наборах данных для задачи сегментации медицинских изображений и на всех показал один из лучших результатов.

В последнее время идея использования трансформеров перешла из домена обработки текстов и достигла положительных результатов во многих задачах компьютерного зрения; в частности, использован и модифицирован подход Vision Transformer (ViT) [10]. TransUnet представляет собой модель, подобную U-Net, и использует трансформеры для сокращения пути. В качестве входных данных он принимает сглаженные 2D-фрагменты 3D-изображения, затем сначала применяются сверточные сети (CNN) в качестве средства извлечения признаков, а после этого – трансформеры для понижающей дискретизации, образуя гибридный подход CNN-Transformer. Для расширенного пути используется каскадный повышающий преобразователь, который представляет собой несколько этапов повышения дискретизации, аналогичный исходной модели U-net.

TransBTS – еще один подход, основанный на трансформерах, который впервые использовался в задаче сегментации опухолей головного мозга. Модель показала один из лучших результатов на наборе данных BraTS Challenge. В декодере применяется 3D CNN для извлечения локальной 3D-информации, затем для токенов формируются карты признаков и вводятся в преобразователи для создания глобальных признаков. Прогрессивная повышающая дискретизация используется для соответствия размеру входного изображения. Данная модель аналогична модели TransUNet, но имеет ряд отличий:

1. TransUNet – это 2D-модель, которая слой за слоем обрабатывает 3D-изображение, в то время как TransBTS позволяет использовать пространственную информацию между слоями.

2. TransUNet использует модель ViT, предварительно обученную на больших наборах данных, а TransBTS можно обучать с самого начала.

Новый современный подход к сегментации трехмерных изображений, основанный на преобразователях, UNETR [11], превосходит модели TransBTS и TransUNet в задаче сегментации опухолей головного мозга. В нем входное изображение делится на фрагменты одинакового размера, а стек преобразователей напрямую используется в качестве пути кодирования. Закодированные представления подключаются к декодеру пропускными соединениями. Одним из главных преимуществ этой модели является то, что, демон-

стрируя сопоставимую сложность модели, она превосходит предыдущие модели в ряде задач сегментации.

Swin UNETR [12] использует для кодирования изображений вариацию архитектуры трансформера (Swin Transformer, shifted windows), которая является более естественной адаптацией механизма внимания для моделей компьютерного зрения. В основе этой архитектуры лежат принципы, во многом напоминающие методику CNN. Матрицы внимания вычисляются только в пределах фиксированного окна, осуществляется реализация принципа локальности сверточных сетей. Таким образом, снижается алгоритмическая сложность обработки мелких деталей на изображении, которые важны в задачах сегментации. Пространственные размеры промежуточных результатов на каждом шаге уменьшаются с помощью операции, аналогичной пулингу. Такая специализированная архитектура справляется с задачами компьютерного зрения лучше, чем традиционный трансформер.

### Функции потерь и метрики

Одним из основных параметров при использовании глубоких нейронных сетей является оптимальный выбор функции потерь и метрик качества обучения модели и алгоритмов. Мы рассмотрели следующие несколько вариантов и подходов:

1. DICE – одна из наиболее распространенных метрик для измерения качества модели семантической сегментации. Функция потерь Dice loss определяется как

$$D(g, y) = 1 - \frac{(2y\delta + \epsilon)}{(y + g + \epsilon)},$$

где  $g$  и  $y$  – основные истинные и прогнозируемые значения соответственно;  $\epsilon$  – коэффициент сглаживания.

2. Чтобы аппроксимировать распределение вероятностей двух областей, используется бинарная перекрестная энтропия (BCE, Binary Cross Entropy):

$$BCE(g, y) = -\frac{1}{I} \sum_{i=1}^I g_i \log y_i$$

для формирования функции потерь – DiceCE:

$$L(g, y) = D(g, y) + BCE(g, y).$$

3. Для устранения дисбаланса классов во время обучения введена Focal loss [13], которая применяет модулирующий термин к потере перекрестной энтропии, чтобы сосредоточить обучение на трудно классифицированных примерах:

$$FL(p_i) = -(1 - p_i)^\gamma \log(p_i),$$

где  $p_i$  – вероятность класса;  $\gamma$  – фокусирующий параметр.

Для оценки качества реализованной модели рассматриваются следующие метрики:

1. Метрика Дайс (DS) – мера сходства между прогнозируемой и истинной площадью:

$$DS = \frac{2TP}{2TP + FP + FN},$$

где  $TP$ ,  $FP$  и  $FN$  – истинно положительное, ложноположительное и ложноотрицательное значения соответственно.

2. Расстояние Хаусдорфа (HD) – измеряет, насколько далеко друг от друга находятся два подмножества метрического пространства:

$$d_H(X, Y) = \max \left\{ \sup_{x \in X} \inf_{y \in Y} d(x, y), \sup_{y \in Y} \inf_{x \in X} d(x, y) \right\},$$

где  $X$  и  $Y$  – прогнозируемые и основные области истинности соответственно.

3. Прецизионная точность – доля соответствующих вокселей среди извлеченных вокселей:

$$\text{Precision} = \frac{TP}{TP + FP}.$$

4. Полнота – доля релевантных извлеченных вокселей:

$$\text{Recall} = \frac{TP}{TP + FN}.$$

## Результаты и их обсуждение

В данной работе сравниваются архитектуры и модели UNETR, nnU-Net, Swin UNETR. Для проведения экспериментов выбран набор данных ISBI-2015. Для обучения взяты данные от четырех пациентов (17 изображений МРТ), а также данные последнего пациента для валидации (четыре изображения МРТ).

### Дизайн экспериментов

На вход моделям представлялся набор из четырех модальностей МРТ-последовательностей (FLAIR, T2, PD, MPRAGE) с размером кадра 96 и вероятностью того, что центральный пиксель является повреждением, составляющим 50 %. Численные эксперименты проведены с разными функциями потерь: DICE loss, DiceCE loss, Focal loss, Tversky focal loss ( $\alpha = 0,3$ ;  $\beta = 0,7$ ) и комбинация Tversky focal loss и BCE.

Для UNETR размер батча 16. Модель обучается на 25000 итерациях, и выбирается лучшая модель с точки зрения Dice Score. Для оценки используется метод скользящего окна с площадью перекрытия 25 %. Модель Swin UNETR обучалась в течение 300 эпох по алгоритму AdamW с параметром регуляризации  $10^{-4}$  с размером батча 2. Коэффициент обучения с начальным значением  $10^{-2}$  настраивался в ходе обучения с помощью косинусного отжига (cosine annealing). Входные изображения были разделены на пересекающиеся участки размером  $128 \times 128 \times 128$  с центрами в случайных точках изображения. Модель nnU-Net в конфигурации 3d\_fullres обучалась в течение

500 эпох с использованием метода Нестерова ( $\mu = 0,99$ ). Коэффициент обучения корректируется по полиномиальному алгоритму со степенью  $\gamma = 0,9$ . Размер участков изображения настраивается автоматически таким образом, чтобы в видеопамять поместилось хотя бы два элемента. В табл. 2 представлены результаты экспериментов с различными функциями потерь на одном пациенте с четырьмя наблюдениями (по времени).

Как видно из результатов, значения метрик для разных параметров и изображений отличаются в разные стороны, поэтому каждое значение необходимо хорошо проанализировать. Границы метрик DS, Precision, Recall = [0,1], HD = [0, ...]. Как уже было отмечено, специфика задачи сильно влияет на производительность метрик. В табл. 2 выделенные значения по метрике DS (основная метрика для оценки качества для задачи сегментации) – лучшие результаты комбинации архитектуры nnU-Net с функциями потерь Tversky focal loss и DiceCE. Рассмотрев значения HD, можно сделать вывод, что для всех экспериментов значения метрики достаточно высоки. Такие показатели можно объяснить тем, что РС характеризуется наличием на МРТ-изображении нескольких небольших очагов. В этом отношении модель может давать ложноположительный или истинно отрицательный прогноз поражения, что существенно повлияет на значение показателя. Рассмотрим пример на рис. 2. Поскольку расстояние Хаусдорфа показывает близость двух предсказанных областей, неправильно предсказанное поражение приводит к большому импакту, с помощью которого области сегментации должны быть увеличены, чтобы перекрывать друг друга. Имея низкие значения этой метрики, можно сделать вывод, что модель практически не ошибается в поиске областей поражений, что крайне сложно для исследуемой задачи.

Еще одна ценная методика – метрика Дайс, показывающая, как измерить сходство двух сегментированных областей. Высокие значения могут привести к выводу, что прогнозируемые области имеют большую область пересечения с основной картой сегментации. На рис. 3 показаны примеры хорошего и плохого пересечения сегментации, полученные с помощью модели с фокальной функцией потерь во втором случае: на изображениях есть области, которые достаточно правильно сегментированы полученной моделью, а есть места (около желудочков мозга), для которых правильный прогноз затруднен.

Прецизионная точность дает оценку количества правильно предсказанных вокселей, спрогнозированных как поражение, метрика полноты – количества правильно предсказанных вокселей с

Таблица 2. Результаты на контрольной (валидационной) выборке

Table 2. Results on the control (validation) set

Архитектура и функция потерь	Метрика	Образец 1	Образец 2	Образец 3	Образец 4	Среднее
UNETR (DiceCE loss)	DS	0,596	0,673	<b>0,708</b>	0,678	0,664
	HD	40,50	40,03	48,20	48,22	44,25
	Precision	0,586	0,731	0,755	0,707	0,695
	Recall	0,606	0,623	0,667	0,640	0,634
UNETR (Focal loss)	DS	0,527	0,638	0,596	0,648	0,602
	HD	40,02	39,20	32,70	33,38	36,32
	Precision	0,459	0,645	0,509	0,623	0,559
	Recall	0,620	0,641	0,720	0,676	0,664
UNETR (Dice loss)	DS	0,589	0,702	0,473	0,407	0,543
	HD	41,37	0,52	49,10	49,10	47,89
	Precision	0,550	0,794	0,345	0,281	0,492
	Recall	0,649	0,629	0,755	0,736	0,692
Swin UNETR (Dice loss)	DS	0,371	0,469	0,417	0,449	0,426
	HD	38,41	34,93	41,41	43,89	39,66
	Precision	0,360	0,606	0,375	0,421	0,440
	Recall	0,383	0,382	0,470	0,481	0,429
Swin UNETR (Tversky focal loss)	DS	0,430	0,539	0,450	0,463	0,470
	HD	31,65	39,62	43,29	47,39	40,49
	Precision	0,383	0,539	0,357	0,375	0,414
	Recall	0,490	0,539	0,608	0,604	0,560
Swin UNETR (BCE + Tversky focal loss)	DS	0,316	0,483	0,381	0,388	0,392
	HD	43,83	44,11	44,77	47,11	44,95
	Precision	0,210	0,365	0,255	0,260	0,272
	Recall	0,639	0,714	0,755	0,765	0,718
nnU-Net (BCE + Tversky focal loss)	DS	0,685	0,766	0,718	0,730	0,725
	HD	8,25	5,39	7,07	5,10	6,45
	Precision	0,696	0,858	0,669	0,663	0,721
	Recall	0,674	0,692	0,775	0,812	0,738
nnU-Net (Tversky focal loss)	DS	<b>0,703</b>	<b>0,770</b>	0,726	0,727	0,731
	HD	8,54	5,66	7,07	6,00	6,82
	Precision	0,739	0,894	0,703	0,706	0,760
	Recall	0,670	0,676	0,751	0,749	0,711
nnU-Net (DiceCE)	DS	0,694	0,758	<b>0,739</b>	<b>0,763</b>	<b>0,739</b>
	HD	8,12	6,16	7,00	5,00	6,57
	Precision	0,748	0,918	0,726	0,754	0,786
	Recall	0,647	0,645	0,752	0,773	0,704

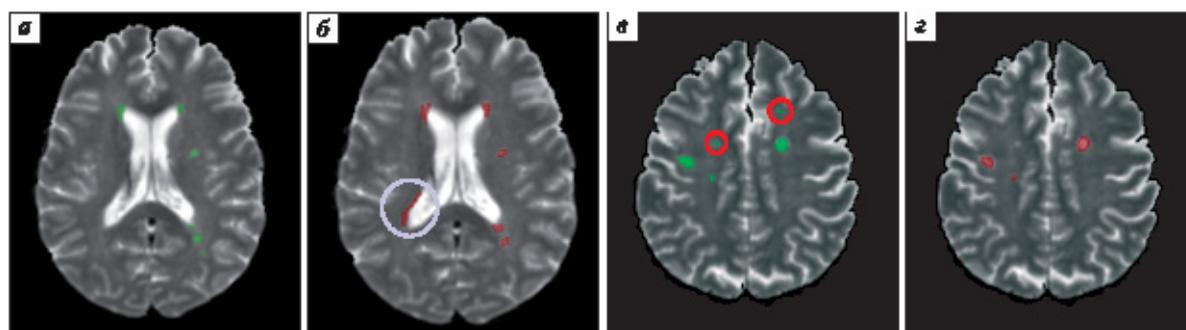
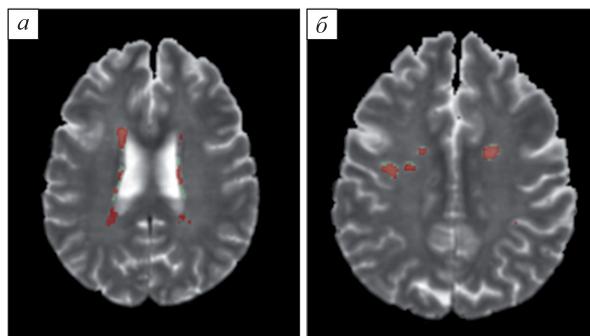


Рис. 2. Пример предсказания ложноположительного (а, б) и ложноотрицательного поражения (в, з): а, в – реальное, б, з – предсказанное

Fig. 2. False positive (a, b) and false negative (v, z) lesion prediction example: a, v – ground truth, б, з – prediction



**Рис. 3.** Разница между наложенными результатами: а – хорошее, б – плохое пересечение

**Fig. 3.** Different segmentation overlaps results: a – good, б – bad overlap example

поражением. Эти метрики также важны для оценки качества модели. Оценки высокой точности не гарантируют хорошее качество модели, а могут только показать, действительно ли прогнозируемые области являются поражениями. Данный показатель не дает информации об участках поражения, которые предсказаны как здоровые элементы.

Как видно из наших данных, модель nnU-Net показала лучшие средние значения по всем показателям. Полученные результаты сегментации поражений были клинически оценены и одобрены тремя аттестованными опытными нейрорадиологами.

### Заключение

Проведен аналитический обзор современных методов для анализа данных МРТ при РС. Выбраны и реализованы современные алгоритмы и модели сегментации поражений на архитектурах UNETR, nnU-Net, Swin UNETR. Проведены эксперименты на открытых исследовательских данных (ISBI-2015). Полученные базовые результаты 0,543 по метрике Дайс для детектирования и выделения структурных очаговых изменений в веществе головного мозга на ограниченном наборе данных улучшены до значения 0,739. В дальнейшем планируется расширить набор данных для проведения экспериментов, создать собственный набор, сопоставимый по объему и характеру материалов с известными мировыми аналогами.

### Список литературы / References

1., Кротенкова И.А., Брюхов В.В., Коновалов Р.Н., Захарова М.Н., Кротенкова М.В. Магнитно-резонансная томография в дифференциальной диагностике рассеянного склероза и других демиелинизирующих заболеваний. *Вестн. рентгенол. и радиол.* 2019;100(4):229–236. doi: 10.20862/0042-4676-2019-100-4-229-236

Krotenkova I.A., Bryukhov V.V., Kononov R.N., Zakharova M.N., Krotenkova M.V. Magnetic resonance imaging in the differential diagnosis of multiple sclerosis and other demyelinating diseases. *Vestnik rentgenologii i radiologii = Bulletin of Roentgenology and Radiology.* 2019;100(4):229–236. [In Russian]. doi: 10.20862/0042-4676-2019-100-4-229-236

2. Thompson A.J., Banwell B.L., Barkhof F., Carroll W.M., Coetzee T., Comi G., Correale J., Fazekas F., Filippi M., Freedman M.S., ... Cohen J.A. Diagnosis of multiple sclerosis: 2017 revisions of the McDonald criteria. *Lancet Neurol.* 2018;17(2):162–173. doi: 10.1016/S1474-4422(17)30470-2

3. Zeng C., Gu L., Liu Z., Zhao S. Review of deep learning approaches for the segmentation of multiple sclerosis lesions on brain MRI. *Front. Neuroinform.* 2020;14:610967. doi: 10.3389/fninf.2020.610967

4. Carass A., Roy S., Jog A., Cuzzocreo J.L., Magrath E., Gherman A., Button J., Nguyen J., Prados F., Sudre C.H., ... Pham D.L. Longitudinal multiple sclerosis lesion segmentation: resource and challenge. *Neuroimage.* 2017;148:77–102. doi: 10.1016/j.neuroimage.2016.12.064

5. Commowick O., Istace A., Kain M., Laurent B., Leray F., Simon M., Pop S.C., Girard P., Amélie R., Ferré J.C., ... Barillot C. Objective evaluation of multiple sclerosis lesion segmentation using a data management and processing infrastructure. *Sci. Rep.* 2018;8(1):13650. doi: 10.1038/s41598-018-31911-7

6. Commowick O., Cervenansky F., Cotton F., Dojat M. MSSEG-2 challenge proceedings: Multiple sclerosis new lesions segmentation challenge using a data management and processing infrastructure. *24th International Conference on Medical Image Computing and Computer Assisted Intervention: proc. conf., Strasbourg, France, Sep 2021.* P. 1–118.

7. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015: proc. conf., Munich, Germany, October 5–9, 2015. Part III 18.* Springer International Publishing, 2015. doi: 10.48550/arXiv.1505.04597

8. Zhang H., Valcarcel A.M., Bakshi R., Chu R., Bagnato F., Shinohara R.T., Hett K., Oguz I. Multiple sclerosis lesion segmentation with tiramisù and 2.5D stacked slices. *Med. Image Comput. Comput. Assist. Interv.* 2019;11766:338–346. doi: 10.1007/978-3-030-32248-9\_38

9. Isensee F., Jaeger P.F., Kohl S.A., Petersen J., Maier-Hein K.H. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nat. Methods.* 2021;18(2):203–211. doi: 10.1038/s41592-020-01008-z

10. Dosovitskiy A., Beyer L., Kolesnikov A., Weissenborn D., Zhai X., Unterthiner T., Dehghani M., Minderer M., Heigold G., Gelly S., Uszkoreit J., Houlsby N. (2020). An image is worth 16×16 words: Trans-

formers for image recognition at scale. *arXiv preprint arXiv*. 2010.11929.

11. Hatamizadeh A., Tang Y., Nath V., Yang D., Myronenko A., Landman B., Roth H., Xu D. UNETR: Transformers for 3D medical image segmentation. *In: Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*. 2022. P. 574–584

12. Hatamizadeh A., Nath V., Tang Y., Yang D., Roth H.R., Xu D. Swin UNETR: Swin transformers for

semantic segmentation of brain tumors in MRI images. *In: International MICCAI Brainlesion Workshop*. Cham: Springer International Publishing, 2021. P. 272–284. doi: 10.48550/arXiv.2201.01266

13. Lin T.Y., Goyal P., Girshick R., He K., Dollár P. Focal loss for dense object detection. *In: Proceedings of the IEEE international conference on computer vision*. 2017. P. 2980–2988. doi:10.1109/ICCV.2017.324

#### Сведения об авторах:

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

**Суворов Виктор**, ORCID: 0009-0007-1128-8053, e-mail: vic.suvorov@yahoo.com

**Моторин Кирилл Олегович**, e-mail: k.motorin@g.nsu.ru

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

**Василькив Любовь Михайловна**, к.м.н., ORCID: 0000-0003-1838-8130, e-mail: vasilkiv@tomo.nsc.ru

**Станкевич Юлия Александровна**, к.м.н., ORCID: 0000-0002-7959-5160, e-mail: stankevich@tomo.nsc.ru

**Тулупов Андрей Александрович**, д.м.н., проф., чл.-корр. РАН, ORCID: 0000-0002-1277-4113, e-mail: taa@tomo.nsc.ru

#### Information about the authors:

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

**Victor Suvorov**, ORCID: 0009-0007-1128-8053, e-mail: vic.suvorov@yahoo.com

**Kirill O. Motorin**, e-mail: k.motorin@g.nsu.ru

**Evgeny N. Pavlovskiy**, candidate of physical and mathematical sciences, ORCID: 0000-0001-6976-1885, e-mail: pavlovskiy@post.nsu.ru

**Liubov M. Vasilkiv**, candidate of medical sciences, ORCID: 0000-0003-1838-8130, e-mail: vasilkiv@tomo.nsc.ru

**Yuliya A. Stankevich**, candidate of medical sciences, ORCID: 0000-0002-7959-5160, e-mail: stankevich@tomo.nsc.ru

**Andrey A. Tulupov**, doctor of medical sciences, professor, corresponding member of the RAS, ORCID: 0000-0002-1277-4113, e-mail: taa@tomo.nsc.ru

*Поступила в редакцию 15.09.2023*

*После доработки 13.11.2023*

*Принята к публикации 19.11.2023*

*Received 15.09.2023*

*Revision received 13.11.2023*

*Accepted 19.11.2023*