



УДК 832-004.2:004.932.72

DOI: <https://doi.org/10.35693/SIM636947>

© This work is licensed under CC BY 4.0

© Authors, 2024

Автоматическая сегментация очагов демиелинизации при рассеянном склерозе

А.В. Захаров¹, И.В. Широлапов¹, Е.В. Хивинцева¹, М.С. Сергеева¹, Н.П. Романчук¹, Д.А. Дедык¹,
Д.Д. Мельникова¹, А.М. Андреев¹, А.И. Мавлетова¹, А.О. Щепетов¹, Jude Hemanth²

¹ФГБОУ ВО «Самарский государственный медицинский университет» Минздрава России
(Самара, Российская Федерация)

²Институт технологий и наук Карунья (Коимбатур, Индия)

Аннотация

Цель – оценить эффективность использования алгоритма YOLOv8 для автоматической сегментации очагов демиелинизации различной локализации у пациентов с рассеянным склерозом.

Материал и методы. В исследование включены 120 пациентов с клинически достоверным диагнозом «рассеянный склероз», которым была проведена МРТ с контрастированием. Были проанализированы МРТ пациентов с различным типом течения заболевания. Для анализа использовались T1-, T2-взвешенные и FLAIR последовательности. Алгоритм YOLOv8 был адаптирован для медицинских данных и обучен на размеченных вручную МРТ-снимках. Оценка производительности модели проводилась с использованием метрик точности (Precision), полноты (Recall) и F1-мера.

Результаты. Модель YOLOv8 показала высокие результаты сегментации: точность – 0,79, полнота – 0,73, F1 мера – 0,61. Модель эффективно иден-

тифицировала очаги демиелинизации различной локализации, типичной для рассеянного склероза. Остается необходимость в повышении полноты для минимизации пропуска поражений. Тестирование на независимых данных подтвердило стабильность результатов модели.

Выводы. Алгоритм YOLOv8 демонстрирует высокий потенциал для автоматической сегментации очагов демиелинизации у пациентов с рассеянным склерозом. Данная методика может быть успешно внедрена в клиническую практику, что позволит ускорить диагностику и улучшить контроль за прогрессированием заболевания. Для дальнейшего повышения точности и полноты сегментации возможна оптимизация модели через использование методов усиления данных и гибридных архитектур.

Ключевые слова: магнитно-резонансная томография, рассеянный склероз, сегментация, глубокое обучение.

Конфликт интересов: не заявлен.

Для цитирования:

Захаров А.В., Широлапов И.В., Хивинцева Е.В., Сергеева М.С., Романчук Н.П., Дедык Д.А., Мельникова Д.Д., Андреев А.М., Мавлетова А.И., Щепетов А.О., Hemanth J. **Автоматическая сегментация очагов демиелинизации при рассеянном склерозе.** Наука и инновации в медицине. 2024;9(4):284-290. DOI: <https://doi.org/10.35693/SIM636947>

Сведения об авторах

Захаров А.В. – канд. мед. наук, доцент, директор НИИ нейронаук.
ORCID: <https://orcid.org/0000-0003-1709-6195>
E-mail: a.v.zaharov@samsmu.ru

Широлапов И.В. – канд. мед. наук, доцент, заведующий лабораторией трансляционных исследований и персонализированной медицины.
ORCID: <https://orcid.org/0000-0002-7670-6566>
E-mail: i.v.shirolapov@samsmu.ru

Хивинцева Е.В. – канд. мед. наук, доцент кафедры неврологии и нейрохирургии.
ORCID: <https://orcid.org/0000-0002-1878-7951>
E-mail: e.v.hivinceva@samsmu.ru

Сергеева М.С. – канд. биол. наук, доцент, ведущий специалист НИИ нейронаук.
ORCID: <https://orcid.org/0000-0002-0926-8551>
E-mail: m.s.sergeeva@samsmu.ru

Романчук Н.П. – канд. мед. наук, доцент, заведующий лабораторией нейроморфных систем НИИ нейронаук.
ORCID: <https://orcid.org/0000-0003-3522-6803>
E-mail: n.p.romanchuk@samsmu.ru

Дедык Д.А. – инженер передовой инженерной школы.
ORCID: <https://orcid.org/0009-0000-7902-6964>
E-mail: d.a.dedyk@samsmu.ru

Мельникова Д.Д. – инженер передовой инженерной школы.
ORCID: <https://orcid.org/0009-0000-6516-8216>
E-mail: d.d.melnikova@samsmu.ru

Андреев А.М. – инженер передовой инженерной школы.
ORCID: <https://orcid.org/0009-0002-0292-930X>
E-mail: a.m.andreev@samsmu.ru

Мавлетова А.И. – инженер передовой инженерной школы.
ORCID: <https://orcid.org/0009-0007-4429-7554>
E-mail: a.i.mavletova@samsmu.ru

Щепетов А.О. – инженер передовой инженерной школы.
ORCID: <https://orcid.org/0009-0009-5925-6426>
E-mail: a.o.schepetov@samsmu.ru

Hemanth J. – профессор.
ORCID: <https://orcid.org/0000-0002-6091-1880>
E-mail: judehemanth@karunya.edu

Автор для переписки

Захаров Александр Владимирович

Адрес: Самарский государственный медицинский университет, ул. Чапаевская, 89, г. Самара, Россия, 443099.
E-mail: a.v.zaharov@samsmu.ru

Список сокращений

МРТ – магнитно-резонансная томография; ПИТПС – препараты, изменяющие течение рассеянного склероза; РС – рассеянный склероз; ЦНС – центральная нервная система; CNN – англ. convolutional neural network; EDSS – англ. Expanded Disability Status Scale; nnU-Net – англ. 'no-new-Net'; SVMs – англ. Support Vector Machines; U-сеть – англ. ultra long сеть.

Получено: 12.10.2024

Одобрено: 01.11.2024

Опубликовано: 26.11.2024

Automatic segmentation of demyelination lesions in multiple sclerosis

Aleksandr V. Zakharov¹, Igor V. Shirolapov¹, Elena V. Khivintseva¹, Mariya S. Sergeeva¹,
Natalya P. Romanchuk¹, Dmitrii A. Dedyk¹, Darya D. Melnikova¹, Arsenii M. Andreev¹,
Aleksandra I. Mavletova¹, Anton O. Shchepetov¹, Jude Hemanth²

¹Samara State Medical University (Samara, Russian Federation)

²Karunya Institute of Technology and Sciences (Coimbatore, India)

Abstract

Aim – to evaluate the effectiveness of the YOLOv8 algorithm for automatic segmentation of demyelination lesions in various locations in patients with multiple sclerosis.

Material and methods. The study included 120 patients with a clinically confirmed diagnosis of multiple sclerosis who underwent contrast-enhanced MRI. The MRI data from patients with different types of disease progression were analyzed. T1-weighted, T2-weighted, and FLAIR sequences were used for the analysis. The YOLOv8 algorithm was adapted for medical imaging and trained on manually annotated MRI scans. Model performance was evaluated using precision, recall, and F1-Score metrics.

Results. The YOLOv8 model demonstrated high segmentation performance with a precision of 0.79, recall of 0.73, and F1-Score of 0.65. The model effectively identified demyelination lesions in various locations typical

for multiple sclerosis. However, there remains a need to improve recall to minimize the missed lesions. Testing on independent data confirmed the stability of the results of the model.

Conclusion. The YOLOv8 algorithm shows significant potential for automatic segmentation of demyelination lesions in multiple sclerosis patients. This method could be successfully implemented in clinical practice, enabling faster diagnosis and improved monitoring of disease progression. Further optimization of the model, through data augmentation techniques and hybrid architectures, may enhance both segmentation accuracy and recall.

Keywords: magnetic resonance imaging, multiple sclerosis, segmentation, deep learning.

Conflict of Interest: nothing to disclose.

Citation

Zakharov AV, Shirolapov IV, Khivintseva EV, Sergeeva MS, Romanchuk NP, Dedyk DA, Melnikova DD, Andreev AM., Mavletova AI, Shchepetov AO, Hemanth J. **Automatic segmentation of demyelination lesions in multiple sclerosis.** *Science and Innovations in Medicine.* 2024;9(4):284-290.

DOI: <https://doi.org/10.35693/SIM636947>

Information about authors

Aleksandr V. Zakharov – PhD, Associate professor,

Head of the Neurosciences Research Institute.

ORCID: <https://orcid.org/0000-0003-1709-6195>

E-mail: a.v.zakharov@samsmu.ru

Igor V. Shirolapov – PhD, Associate professor, Head of laboratory.

ORCID: <https://orcid.org/0000-0002-7670-6566>

E-mail: i.v.shirolapov@samsmu.ru

Elena V. Khivintseva – PhD, Associate professor of the Department of Neurology and Neurosurgery.

ORCID: <https://orcid.org/0000-0002-1878-7951>

E-mail: e.v.hivinceva@samsmu.ru

Mariya S. Sergeeva – PhD, Associate professor.

ORCID: <https://orcid.org/0000-0002-8266-8551>

E-mail: m.s.sergeeva@samsmu.ru

Natalya P. Romanchuk – PhD, MD, Associate professor, Head of the laboratory of neuromorphic systems, research institute of neurosciences.

ORCID: <https://orcid.org/0000-0003-3522-6803>

E-mail: n.p.romanchuk@samsmu.ru

Dmitrii A. Dedyk – engineer of the advanced engineering school.

ORCID: <https://orcid.org/0009-0000-7902-6964>

E-mail: d.a.dedyk@samsmu.ru

Darya D. Melnikova – engineer of the advanced engineering school.

ORCID: <https://orcid.org/0009-0000-6516-8216>

E-mail: d.d.melnikova@samsmu.ru

Arsenii M. Andreev – engineer of the advanced engineering school.

ORCID: <https://orcid.org/0009-0002-0292-930X>

E-mail: a.m.andreev@samsmu.ru

Aleksandra I. Mavletova – engineer of the advanced engineering school.

ORCID: <https://orcid.org/0009-0007-4429-7554>

E-mail: a.i.mavletova@samsmu.ru

Anton O. Shchepetov – engineer of the advanced engineering school.

ORCID: <https://orcid.org/0009-0009-5925-6426>

E-mail: a.o.schepetov@samsmu.ru

Hemanth Jude – PhD, Professor.

ORCID: <https://orcid.org/0000-0002-6091-1880>

E-mail: judehemanth@karunya.edu

Corresponding author

Aleksander V. Zakharov

Address: Samara State Medical University, 89 Chapaevskaya st., Samara, Russia, 443099.

E-mail: a.v.zakharov@samsmu.ru

Received: 12.10.2024

Accepted: 01.11.2024

Published: 26.11.2024

ВВЕДЕНИЕ

Рассеянный склероз (РС) – нейровоспалительное заболевание центральной нервной системы (ЦНС), вызывающее демиелинизацию и повреждение нейронов. Данное заболевание сопровождается частой инвалидизацией среди молодых людей (в возрасте 18–40 лет) [1]. Прогрессирование инвалидизации у пациентов с РС оказывает существенное влияние на социальное, экономическое и индивидуальное благополучие. Ежегодное экономическое бремя РС в США оценивается в 85 млрд долл. США. Аналогичные данные были получены и в ЕС, где ежегодные средние расходы варьируются от 22 800 евро (при легкой форме заболевания) до 57 500 евро (при тяжелой форме заболевания) по паритету покупательной способности, причем прямые медицинские расходы составляют до 68% от этих общих расходов [2]. Своевременная диагностика является важным фактором снижения прогрессии инвалидизации заболевания, по причине раннего назначения терапии препаратами, изменяющими течение заболевания (ПИТРС) [3].

Формирование диагноза РС опирается на диагностические критерии Макдональда 2017 года [4], которые обеспечивают повышенную точность диагностики данного заболевания на основе клинических, визуализационных и иммунологических показателей. Основным тезисом данных критериев является обнаружение диссеминации клинических или инструментальных признаков в пространстве и/или времени [4].

Диссеминация в пространстве характеризуется появлением очагов демиелинизации в следующих анатомических

областях ЦНС: перивентрикулярная область мозга, корковая или юкстакортикальная область мозга, инфратенториальная область мозга или спинной мозг, что указывает на мультифокальное поражение. Распространение в пространстве может быть показано одним или несколькими T2-гиперинтенсивными очагами, характерными для РС, по крайней мере в двух из четырех областей ЦНС [5]. Распространение во времени описывает развитие или появление новых очагов демиелинизации в ЦНС с течением времени.

Ключевым инструментом для диагностики и наблюдения за больными РС и основным компонентом постоянно обновляемых диагностических критериев РС является МРТ [6].

Процесс выявления и сегментации поражений при РС обычно выполняется вручную опытными нейрорадиологами, что является трудоемкой и подверженной ошибкам задачей [6]. Поэтому существует необходимость в разработке автоматизированных инструментов для облегчения этой процедуры.

На данный момент работы в направлении автоматизации сегментации очагов демиелинизации с использованием алгоритмов машинного обучения позволили получить достаточно впечатляющие результаты для начала внедрения их в рутинную клиническую практику [7, 8].

Для обнаружения и сегментации повреждений было разработано множество других автоматических методов. Так, были использованы такие методы, как «к-ближайший сосед» [9, 10], метод опорных векторов (англ. Support Vector Machines, SVMs) [11, 13], «Марковские случайные

поля» [14, 15], «случайный лес» [16, 17] или специальные алгоритмы, основанные на интенсивности [18–21]. Преобладала категория глубоких нейронных сетей высокого уровня, которые наиболее часто представлены сверточными нейронными сетями (англ. convolutional neural network, CNN) в виде U-сетей [22]. Предложена модификация данной сети – nnU-Net [23] – метод, который автоматически настраивает этапы предварительной обработки, архитектуру, обучение и постобработку для лучшей адаптации к свойствам набора данных и доступному оборудованию.

Таким образом, в большинстве исследований на данный момент в автоматической сегментации МРТ данных используются алгоритмы глубокого обучения с использованием архитектуры U-сети [24] в ее модификации 2D и 3D [25].

Несмотря на накапливающиеся данные МРТ, решить проблему получения качественных и устойчивых метрик работы алгоритмов сегментации для использования в клинической практике на данный момент не удалось. Поэтому отдельные исследовательские группы продолжают поиск оптимальных архитектур нейронных сетей, предварительной обработки данных МРТ, синтетических данных [26], использование нескольких архитектур или подходов для их обучения [27, 28].

Обнаружение и сегментация новых поражений РС остаются очень сложными задачами. В настоящее время автоматические методы могут быть более чувствительными для обнаружения новых поражений, но дают больше ложноположительных результатов по сравнению с ручной сегментацией радиологами, имеющими опыт оценки данных МРТ пациентов с РС [8].

ЦЕЛЬ

Использование нового алгоритма глубокого обучения YOLOv8 для обнаружения очагов демиелинизации в субкортикальной, инфратенториальной, перивентрикулярной и юкстакортикальной локализациях, а также подсчета их объема.

МАТЕРИАЛ И МЕТОДЫ

Исследование одобрено этическим комитетом ФГБОУ ВО «Самарский государственный медицинский университет» Минздрава России (протокол №52 от 12.12.2023 г.).

В исследование включено 120 пациентов с активным и стабильным течением РС, установленным в соответствии с критерием Макдональда 2017 года [4]. Средний возраст пациентов составил 35,7 ±10,2 года, распределение по полу было равномерным. Активность заболевания устанавливалась на основании наличия одного обострения в течение предыдущего года или двух обострений в течение последних двух лет у пациентов с ремиттирующим и вторично-прогрессирующим с обострениями РС. У пациентов с первично-прогрессирующим течением активность определялась прогрессированием заболевания в течение последнего года. У пациентов со стабильным течением заболевания обострений или усиления заболевания в указанный период времени не было [4]. У пациентов с активным течением наблюдалось нарастание неврологического дефицита не менее чем на 2 балла по одной из функциональных шкал (например, зрительной, стволовой, пирамидной, сенсорной, координационной) или не менее

EDSS (функциональные системы)							
Зрительная	Стволовая	Пирамидная	Мозжечковая	Сенсорная	Тазовые функции	Церебральные функции	Балл EDSS
0-2 (0)	0-3 (1)	1-4 (2)	0-4 (2)	0-3 (1)	0-3 (1)	0-2 (1)	1,0-7,0 (3,0)

Примечания. Среднее значение (мин.-макс.).

Таблица 1. Показатели баллов по шкале EDSS пациентов с РС
Table 1. EDSS scores of patients with MS

чем на 1 балл по двум функциональным системам. Также могло наблюдаться прогрессирование инвалидизации по шкале EDSS (англ. Expanded Disability Status Scale, EDSS) [29]: нарастание не менее чем на 1 балл, если исходный EDSS был ниже 4,0 балла или нарастание не менее чем на 0,5 балла, если исходный EDSS был 4,0 и выше [30]. У пациентов с прогрессирующим течением наблюдается нарастание неврологического дефицита на 1 балл по шкале EDSS [4]. Неврологический осмотр и оценка по шкале EDSS [31] проводились сертифицированным неврологом с опытом ведения больных рассеянным склерозом более 10 лет. Неврологический статус пациентов согласно шкале EDSS представлен в **таблице 1**.

У 18 пациентов наблюдалось активное течение рецидивирующе-ремиттирующего течения РС, у 68 пациентов активность не наблюдалась в течение последних двух лет, 30 пациентов имели вторично-прогрессирующее течение с обострениями РС, у остальных 4 пациентов наблюдалось первично-прогрессирующее течение заболевания.

Исследование проводилось с использованием магнитно-резонансного томографа (МРТ) с напряженностью магнитного поля 1,5 Т. Для улучшения визуализации активных очагов демиелинизации применялся контрастный агент на основе гадолиния, который вводился внутривенно.

Протокол МРТ для оценки очагов демиелинизации включал последовательности: T1-взвешенные изображения (T1WI) – проводились до и после введения контрастного вещества для выявления активных очагов и оценки накопления контраста; T2-взвешенные изображения (T2WI) – использовались для выявления хронических и новых очагов демиелинизации за счет высокой чувствительности к изменениям в тканевой структуре; FLAIR (Fluid Attenuated Inversion Recovery) – применялась для подавления сигнала от жидкости и лучшего выявления гиперинтенсивных очагов в белом веществе, особенно вблизи желудочков мозга; DWI (Diffusion Weighted Imaging) – проводилась для оценки диффузии воды в тканях и дифференциации активных очагов от хронических; PD-взвешенные изображения (англ. Proton Density) – использовались для дополнительной характеристики демиелинизированных зон и их отличия от нормальной ткани.

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Для сегментации изображений МРТ у пациентов с РС использовалась нейронная сеть YOLOv8. YOLOv8 (англ. You Only Look Once, версия 8) является последней итерацией семейства моделей YOLO, предназначенной для задач обнаружения и сегментации объектов в режиме реального времени. Эта архитектура характеризуется

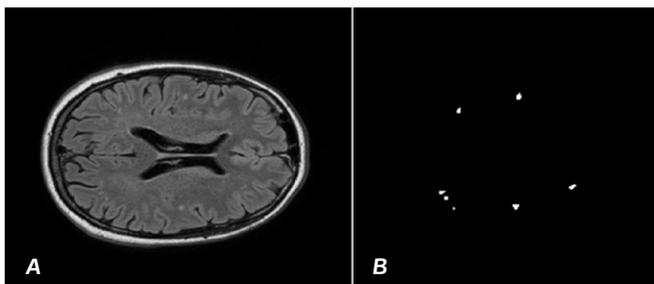


Рисунок 1. А – МРТ T2 режим с очага демиелинизации. В – «маска» очагов демиелинизации, полученная в результате сегментации врачом-радиологом.

Figure 1. A – MRI T2 mode with a focus of demyelination. B – “mask” of demyelination foci obtained as a result of segmentation by a radiologist.

высокой скоростью обработки и точностью предсказаний, что делает ее подходящей для анализа медицинских изображений, где важна не только точность, но и эффективность обработки больших объемов данных при детекции одновременно нескольких классов объектов. В нашем исследовании выступали очаги демиелинизации субкортикальной, юстакортикальной, перивентрикулярной и инфратенториальной локализаций.

В этом исследовании использована архитектура YOLOv8 с модификациями, предназначенными для улучшения производительности на медицинских данных. Модель была предварительно обучена на большом наборе изображений (ImageNet) с последующей дообученной на специализированном наборе данных, состоящем из размеченных МРТ изображений пациентов с РС. Эти изображения включали

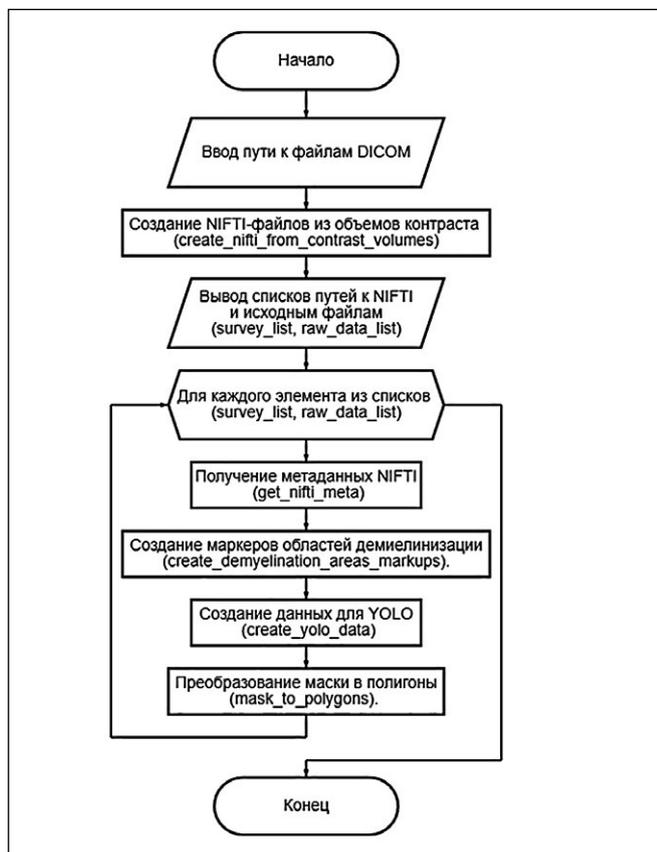


Рисунок 2. Блок-схема алгоритма создания обучающей выборки.

Figure 2. Flowchart of the algorithm for creating a training sample.

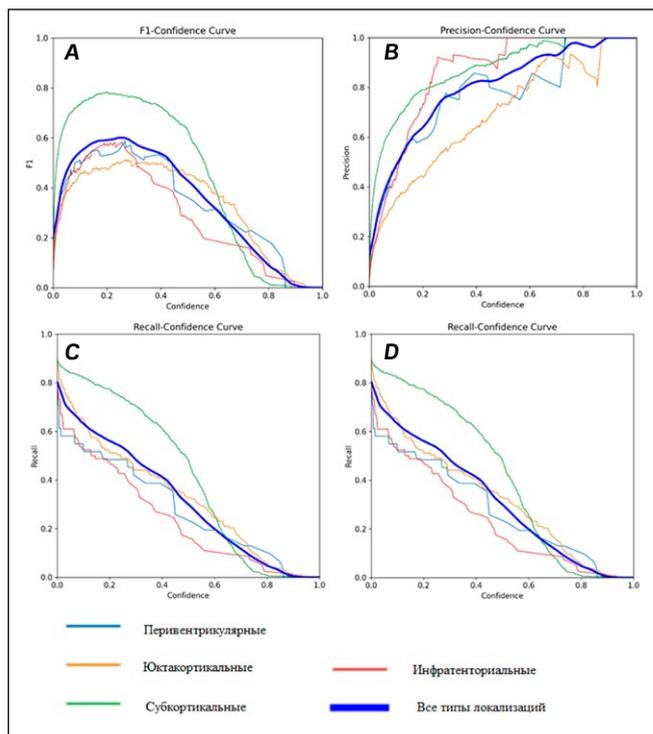


Рисунок 3. Метрики, характеризующие качество модели, полученной на тестовой выборке. А – график функции F1 от аргумента Confidence; В – график функции Precision от аргумента Confidence; С – график функции Accuracy versus the argument Confidence; D – график функции от аргумента Recall.

Figure 3. Metrics characterizing the quality of the model obtained on the test sample. A – function of the F1 graph from the Confidence argument; B – graph of the function Accuracy versus the argument Confidence; C – graph function Confidence from the argument Recall; D – graph function Precision by argument Recall.

несколько последовательностей МРТ (T1-взвешенные, T2-взвешенные, FLAIR), что обеспечило более полное представление о морфологии поражений.

Архитектура модели включает в себя следующие блоки.

1. Backbone – используется модифицированная версия CSPNet (англ. Cross Stage Partial Network) для извлечения признаков с различных уровней абстракции. CSPNet разделяет поток данных на две части: одна часть проходит через последовательные слои свертки, в то время как другая часть пересылается на более поздние этапы. Это помогает уменьшить вычислительные затраты и улучшить сходимость модели [32].

2. Neck – для объединения признаков с различных уровней используется FPN (англ. Feature Pyramid Network) вместе с PAN (англ. Path Aggregation Network). FPN помогает объединять признаки с низким и высоким разрешением, а PAN улучшает передачу информации по всей сети, что критично для точной сегментации.

3. Head – выходной слой включает адаптивные якорные блоки (англ. Anchor Boxes) и сверточные слои, которые предсказывают классы объектов, их местоположение и маски сегментации. В данной модификации YOLOv8 для задач медицинской сегментации также был использован блок глубокого сверточного слоя для повышения чувствительности к мелким деталям поражений [33].

Для обучения модели использовались изображения размером 512x512 пикселей. Обучение проводилось с использованием стохастического градиентного спуска с

Локализация очагов демиелинизации	Precision	Recall	F1-Score	Confidence
Перивентрикулярные (1)	0,82	0,76	0,59	0,85
Юкстакортикальные (2)	0,80	0,71	0,52	0,82
Субкортикальные (3)	0,78	0,70	0,79	0,80
Инфратенториальные (4)	0,76	0,68	0,58	0,78
Все типы очагов	0,79	0,73	0,61	0,81

Таблица 2. Показатели метрик полученной модели относительно классификации отдельных очагов демиелинизации

Table 2. Metrics of the resulting model regarding the classification of individual demyelination lesions

импульсом 0,9 и начальной скоростью обучения 0,001. Датасет был разделен на обучающую и тестовую выборки в соотношении 90/30. В результате сегментации очагов демиелинизации врачом-радиологом были получены изображения (рисунок 1), на основе которых сформированы «маски» для обучения алгоритма YOLOv8.

Блок-схема полного алгоритма создания обучающей выборки, включающей в себя все этапы первичной подготовки, их стандартизация исходя из особенностей различий в матрице самого изображения, представлена на рисунке 2.

Для оценки качества сегментации использовались метрики Intersection over Union (IoU) и Dice Score.

В результате обучения модели на данных из 30 исследований, в каждом из которых содержится приблизительно по 86 снимков в среднем (2580 снимков в целом).

Полученная модель обладает хорошей способностью распознавать области демиелинизации на МРТ снимках с высокой точностью и уверенностью. Однако модель может быть улучшена с целью минимизации пропуска положительных случаев. Метрики полученной модели изображены на рисунке 3.

Сводная таблица метрик, характеризующих качество полученной модели по отдельным типам очагов демиелинизации, представлена в таблице 2.

Одним из основных показателей качества работы модели является матрица ошибок, показанная на рисунке 4. Классификатор работает с четырьмя классами, каждый из которых соответствует отдельному типу очагов демиелинизации и классу, объединяющим все типы очагов демиелинизации. Предсказания модели соответствуют строкам, истина соответствует столбцам. На тестовых данных модель предсказала 258 областей, из которых 210 соответствуют действительности, а оставшиеся 48 – ложноположительные результаты.

Матрица ошибок помогает визуализировать и понять, какие классы модель определяет правильно, а какие вызывают затруднения. Это критически важно для дальнейшей оптимизации модели и улучшения ее производительности.

Таким образом, можно сказать, что оценка метрик precision, recall, F1-Score и confidence позволяет детально анализировать качество работы модели и ее способность различать области интереса на медицинских изображениях. Их улучшение необходимо для получения более устойчивой модели, позволяющей использовать результаты своей работы в клинической или исследовательской практике. Эти метрики обеспечивают всестороннюю оценку модели и помогают в дальнейшем улучшении ее параметров и алгоритмов, что критически важно для

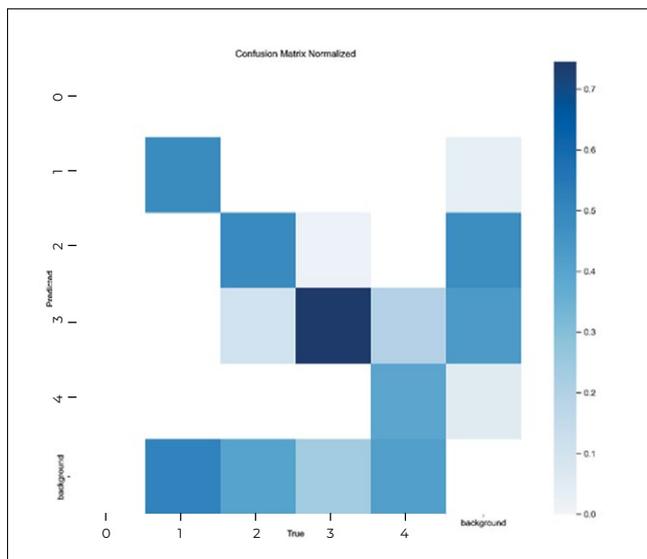


Рисунок 4. Матрица ошибок модели (0 – все типы очагов демиелинизации; 1 – перивентрикулярные; 2 – юкстакортикальные; 3 – субкортикальные; 4 – инфратенториальные).

Figure 4. Confusion Matrix (0 – all types of demyelination lesions; 1 – periventricular; 2 – juxtacortical; 3 – subcortical; 4 – infratentorial).

разработки эффективной системы поддержки принятия врачебных решений для диагностики и лечения РС.

■ ЗАКЛЮЧЕНИЕ

Применение алгоритма глубокого обучения YOLOv8 для автоматической сегментации очагов демиелинизации у пациентов с рассеянным склерозом продемонстрировало высокие показатели точности и эффективности, что подтверждает потенциал данного подхода для клинической практики. Однако, несмотря на достигнутые результаты, существует несколько направлений, по которым модель может быть улучшена.

Во-первых, показатели полноты сегментации (Recall) остаются ниже, чем требуется, что говорит о возможности пропуска отдельных очагов демиелинизации. Для повышения полноты сегментации можно рассмотреть использование гибридных архитектур, комбинирующих YOLOv8 с другими моделями, например, U-Net или nnU-Net, которые продемонстрировали свою эффективность в медицинской сегментации. Объединение преимуществ разных архитектур может улучшить способность модели обнаруживать мельчайшие и трудноразличимые очаги. Также перспективным направлением является внедрение механизмов ансамблирования моделей, когда результаты нескольких алгоритмов объединяются для улучшения общей точности и полноты.

Во-вторых, одним из путей дальнейшей оптимизации может быть использование методов усиления данных (англ. data augmentation) и генерации синтетических изображений. Модели глубокого обучения часто зависят от объема и разнообразия данных, и увеличение набора данных за счет генерации новых МРТ-снимков, особенно для редких или труднодоступных случаев, может повысить точность сегментации и снизить вероятность ложноположительных результатов. Использование генеративно-сопоставительных сетей (англ. Generative adversarial network,

GANs) для создания таких синтетических данных может стать эффективным подходом в этом направлении.

Кроме того, модель может выиграть от применения методов адаптации домена (англ. domain adaptation). Этот подход позволяет алгоритмам, обученным на одном наборе данных, эффективно работать на других наборах, отличающихся по качеству или методам сканирования. В условиях реальной клинической практики часто используются различные аппараты МРТ с разными техническими характеристиками, что может влиять на качество изображений. Адаптация модели под разные наборы данных, возможно, через использование механизмов трансферного обучения (англ. transfer learning), позволит повысить универсальность и надежность ее работы.

Возможные направления дальнейшего применения модели включают интеграцию ее в комплексные системы поддержки принятия врачебных решений. Автоматическая сегментация очагов демиелинизации может использоваться не только для диагностики, но и для мониторинга прогрессирования заболевания и оценки эффективности

терапии. Например, регулярное использование МРТ с автоматической сегментацией может помочь врачам в динамическом наблюдении за состоянием пациентов, своевременном выявлении новых очагов и оценке изменений в уже существующих. Это позволит быстрее корректировать терапию и предотвращать развитие осложнений.

Еще одним перспективным направлением является использование модели для обучения специалистов. Алгоритмы автоматической сегментации могут служить основой для образовательных систем, позволяя молодым врачам и радиологам тренироваться на реальных медицинских данных, сравнивая свои результаты с результатами, полученными алгоритмом. Это может способствовать повышению уровня профессиональной подготовки и снижению человеческого фактора в диагностике.

Таким образом, внедрение и дальнейшая оптимизация моделей автоматической сегментации, таких как YOLOv8, могут значительно улучшить качество диагностики РС, ускорить процессы обработки данных и снизить нагрузку на медицинский персонал. ▀

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ	ADDITIONAL INFORMATION
<p>Соблюдение этических норм. Исследование одобрено этическим комитетом ФГБОУ ВО «Самарский государственный медицинский университет» Минздрава России (протокол №52 от 12.12.2023 г.).</p>	<p>Compliance with ethical standards. The study was approved by the Ethics Committee of the Samara State Medical University (Protocol No. 52 dated 12.12.2023).</p>
<p>Источник финансирования. Исследование проводилось без спонсорской поддержки.</p>	<p>Study funding. This research received no external funding.</p>
<p>Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с содержанием настоящей статьи.</p>	<p>Conflict of interest. The authors declare that there are no obvious or potential conflicts of interest associated with the content of this article.</p>
<p>Участие авторов. А.В. Захаров – формулирование идеи и целей исследования, разработка методологии; проведение экспериментов, исследований или сбора данных; редактирование, корректировка и подготовка текста к публикации; общее руководство проектом. И.В. Широлапов – разработка методик или процедур, используемых в исследовании; написание первоначального текста статьи; организация и координация проекта. Е.В. Хивинцева – проведение экспериментов и сбора данных. М.С. Сергеева – предоставление необходимых ресурсов, включая материалы, инструменты, оборудование, данные или другой доступ. Н.П. Романчук – управление данными, их организация, аннотирование и обеспечение доступности для анализа. Д.А. Дедык, Д.Д. Мельникова, А.М. Андреев, А.И. Мавлетова, А.О. Щепетов – программирование, создание программного обеспечения, написание кода, тестирование и техническая поддержка. Jude Hemanth – проверка результатов экспериментов; воспроизведение исследований и валидация анализа данных; применение математических, статистических или вычислительных методов для анализа данных; редактирование, корректировка и подготовка текста к публикации. Все авторы одобрили финальную версию статьи перед публикацией, выразили согласие нести ответственность за все аспекты работы, подразумевающую надлежащее изучение и решение вопросов, связанных с точностью или добросовестностью любой части работы.</p>	<p>Contribution of individual authors. A.V. Zakharov – formulation of the idea and aims of the study, development of methodology; conducting the experiments, research, or collecting data; editing, proofreading, and preparing the text for publication; general project management. I.V. Shirolapov – development of the methods or procedures used in the study; writing the initial text of the article; organization and coordination of the project. E.V. Khivintseva – conducting the experiments and collecting data. M.S. Sergeeva – provision of necessary resources, including materials, instruments, equipment, data, or other access. N.P. Romanchuk – data management, organization, annotation, and ensuring availability for analysis. D.A. Dedyk, D.D. Melnikova, A.M. Andreev, A.I. Mavletova, A.O. Shchepetov – programming, software creation, coding, testing, and technical support. Jude Hemanth – verification of experimental results; reproducing studies and validating data analysis; application of mathematical, statistical, or computational methods to analyze data; editing, proofreading and preparing text for publication. All authors gave their final approval of the manuscript for submission, and agreed to be accountable for all aspects of the work, implying proper study and resolution of issues related to the accuracy or integrity of any part of the work.</p>

ЛИТЕРАТУРА / REFERENCES

1. Jakimovski D, Bittner S, Zivadinov R, et al. Multiple sclerosis. *The Lancet*. 2024;403(10422):183-202.
DOI: [https://doi.org/10.1016/S0140-6736\(23\)01473-3](https://doi.org/10.1016/S0140-6736(23)01473-3)
2. Kaisey M, Solomon AJ. Multiple Sclerosis Diagnostic Delay and Misdiagnosis. *Neurologic Clinics*. 2024;42(1):1-13.
DOI: <https://doi.org/10.1016/j.ncl.2023.07.001>
3. Giovannoni G, Butzkueven H, Dhib-Jalbut S, et al. Brain health: time matters in multiple sclerosis. *Multiple Sclerosis and Related Disorders*. 2016;9:5-48.
DOI: <https://doi.org/10.1016/j.msard.2016.07.003>
4. Thompson AJ, Banwell BL, Barkhof F, et al. Diagnosis of multiple sclerosis: 2017 revisions of the McDonald criteria. *The Lancet Neurology*. 2018;17(2):162-173.
DOI: [https://doi.org/10.1016/S1474-4422\(17\)30470-2](https://doi.org/10.1016/S1474-4422(17)30470-2)
5. Wattjes MP, Ciccarelli O, Reich DS, et al. 2021 MAGNIMS–CMSC–NAIMS consensus recommendations on the use of MRI in patients with multiple sclerosis. *The Lancet Neurology*. 2021;20(8):653-670.
DOI: [https://doi.org/10.1016/S1474-4422\(21\)00095-8](https://doi.org/10.1016/S1474-4422(21)00095-8)
6. Egger C, Opfer R, Wang C, et al. MRI FLAIR lesion segmentation in multiple sclerosis: Does automated segmentation hold up with manual annotation? *NeuroImage: Clinical*. 2017;13:264-270.
DOI: <https://doi.org/10.1016/j.nicl.2016.11.020>
7. Diaz-Hurtado M, Martínez-Heras E, Solana E, et al. Recent advances in the longitudinal segmentation of multiple sclerosis lesions on magnetic resonance imaging: a review. *Neuroradiology*. 2022;64(11):2103-2117.
DOI: <https://doi.org/10.1007/s00234-022-03019-3>
8. Commowick O, Combès B, Cervenansky F, Dojat M. Editorial: Automatic methods for multiple sclerosis new lesions detection and segmentation. *Front Neurosci*. 2023;17:1176625.
DOI: <https://doi.org/10.3389/fnins.2023.1176625>
9. Fartaria MJ, Bonnier G, Roche A, et al. Automated detection of white matter and cortical lesions in early stages of multiple sclerosis. *Magnetic Resonance Imaging*. 2016;43(6):1445-1454.
DOI: <https://doi.org/10.1002/jmri.25095>
10. Todea AR, Melie-Garcia L, Barakovic M, et al. A Multicenter Longitudinal MRI Study Assessing LeMan-PV Software Accuracy in the Detection of White Matter Lesions in Multiple Sclerosis Patients. *Magnetic Resonance Imaging*. 2023;58(3):864-876.
DOI: <https://doi.org/10.1002/jmri.28618>
11. A. Abdullah B. Multi-Sectional Views Textural Based SVM for MS Lesion Segmentation in Multi-Channels MRIs. *TOBEJ*. 2012;6(1):56-72.
DOI: <https://doi.org/10.2174/1874230001206010056>
12. ElSebely R, Yousef AH, Salem AA, Abdullah B. Automatic Segmentation of Multiple Sclerosis Lesions in Brain MR Images Using Ensemble Machine Learning. In: *2021 International Mobile, Intelligent, and Ubiquitous Computing Conference (MIUCC)*. IEEE; 2021:28-33.
DOI: <https://doi.org/10.1109/MIUCC52538.2021.9447657>
13. HosseiniPanah S, Zamani A, Emadi F, HamtaeiPour F. Multiple Sclerosis Lesions Segmentation in Magnetic Resonance Imaging using Ensemble Support Vector Machine (ESVM). *J Biomed Phys Eng*. 2019;9(6):699-710.
DOI: <https://doi.org/10.31661/jbpe.v0i0.986>
14. Schmidt P, Gaser C, Arsic M, et al. An automated tool for detection of FLAIR-hyperintense white-matter lesions in Multiple Sclerosis. *NeuroImage*. 2012;59(4):3774-3783.
DOI: <https://doi.org/10.1016/j.neuroimage.2011.11.032>
15. Galimzianova A, Lesjak Ž, Rubin DL, et al. Locally adaptive magnetic resonance intensity models for unsupervised segmentation of multiple sclerosis lesions. *J Med Imag*. 2017;5(1):011007.
DOI: <https://doi.org/10.1117/1.JMI.5.1.011007>
16. Geremia E, Clatz O, Menze BH, et al. Spatial decision forests for MS lesion segmentation in multi-channel magnetic resonance images. *NeuroImage*. 2011;57(2):378-390.
DOI: <https://doi.org/10.1016/j.neuroimage.2011.03.080>
17. Dwyer MG, Bergsland N, Ramasamy DP, et al. Salient Central Lesion Volume: A Standardized Novel Fully Automated Proxy for Brain FLAIR Lesion Volume in Multiple Sclerosis. *Journal of Neuroimaging*. 2019;29(5):615-623.
DOI: <https://doi.org/10.1111/jon.12650>
18. Tran P, Thoprakarn U, Gourieux E, et al. Automatic segmentation of white matter hyperintensities: validation and comparison with state-of-the-art methods on both Multiple Sclerosis and elderly subjects. *NeuroImage: Clinical*. 2022;33:102940.
DOI: <https://doi.org/10.1016/j.nicl.2022.102940>
19. Cavado E, Tran P, Thoprakarn U, et al. Validation of an automatic tool for the rapid measurement of brain atrophy and white matter hyperintensity: QyScore®. *Eur Radiol*. 2022;32(5):2949-2961.
DOI: <https://doi.org/10.1007/s00330-021-08385-9>
20. Brune S, Høgestøl EA, Cengija V, et al. LesionQuant for Assessment of MRI in Multiple Sclerosis – A Promising Supplement to the Visual Scan Inspection. *Front Neurol*. 2020;11:546744.
DOI: <https://doi.org/10.3389/fneur.2020.546744>
21. Valcarcel AM, Muschelli J, Pham DL, et al. TAPAS: A Thresholding Approach for Probability Map Automatic Segmentation in Multiple Sclerosis. *NeuroImage: Clinical*. 2020;27:102256.
DOI: <https://doi.org/10.1016/j.nicl.2020.102256>
22. Basaran BD, Matthews PM, Bai W. New lesion segmentation for multiple sclerosis brain images with imaging and lesion-aware augmentation. *Front Neurosci*. 2022;16:1007453.
DOI: <https://doi.org/10.3389/fnins.2022.1007453>
23. Isensee F, Jaeger PF, Kohl SAA, et al. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nat Methods*. 2021;18(2):203-211.
DOI: <https://doi.org/10.1038/s41592-020-01008-z>
24. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. Vol. 9351. *Lecture Notes in Computer Science*. Springer International Publishing. 2015:234-241.
DOI: https://doi.org/10.1007/978-3-319-24574-4_28
25. Hitziger S, Ling WX, Fritz T, et al. Triplanar U-Net with lesion-wise voting for the segmentation of new lesions on longitudinal MRI studies. *Front Neurosci*. 2022;16:964250.
DOI: <https://doi.org/10.3389/fnins.2022.964250>
26. Andresen J, Uzunova H, Ehrhardt J, et al. Image registration and appearance adaptation in non-correspondent image regions for new MS lesions detection. *Front Neurosci*. 2022;16:981523.
DOI: <https://doi.org/10.3389/fnins.2022.981523>
27. Kamraoui RA, Mansencal B, Manjon JV, Coupé P. Longitudinal detection of new MS lesions using deep learning. *Front Neuroimaging*. 2022;1:948235.
DOI: <https://doi.org/10.3389/fnimg.2022.948235>
28. Salem M, Ryan MA, Oliver A, et al. Improving the detection of new lesions in multiple sclerosis with a cascaded 3D fully convolutional neural network approach. *Front Neurosci*. 2022;16:1007619.
DOI: <https://doi.org/10.3389/fnins.2022.1007619>
29. Kurtzke JF. Rating neurologic impairment in multiple sclerosis: An expanded disability status scale (EDSS). *Neurology*. 1983;33(11):1444-1444.
DOI: <https://doi.org/10.1212/WNL.33.11.1444>
30. Kurtzke JF. Clinical definition for multiple sclerosis treatment trials. *Ann Neurol*. 1994;36(1):73-79.
DOI: <https://doi.org/10.1002/ana.410360717>
31. Kurtzke JF. On the origin of EDSS. *Multiple Sclerosis and Related Disorders*. 2015;4(2):95-103.
DOI: <https://doi.org/10.1016/j.msard.2015.02.003>
32. Wang CY, Mark Liao HY, Wu YH, et al. CSPNet: A New Backbone that can Enhance Learning Capability of CNN. In: *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. IEEE; 2020:1571-1580.
DOI: <https://doi.org/10.1109/CVPRW50498.2020.00203>
33. Bochkovskiy A, Wang CY, Liao HY. YOLOv4: Optimal Speed and Accuracy of Object Detection. Published online 2020.
DOI: <https://doi.org/10.48550/ARXIV.2004.10934>