



УДК 004.89+616.711.7-007.254-053.1-073.75+616-07
<https://doi.org/10.56871/ViM.2026.26.75.001>

Оценка эффективности алгоритмов глубокого обучения для выявления признаков *spina bifida occulta* на рентгенограммах позвоночника

Вероника Евгеньевна Казаринова¹, Андрей Сергеевич Гацук¹,
Кирилл Михайлович Арзамасов^{1, 2, 3}, Юрий Александрович Васильев¹

¹ Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы, 127051, г. Москва, ул. Петровка, д. 24, стр. 1, Российская Федерация

² МИРЭА — Российский технологический университет, 119454, г. Москва, пр. Вернадского, д. 78, Российская Федерация

³ Самарский государственный медицинский университет, 443099, г. Самара, ул. Чапаевская, д. 89, Российская Федерация

Для цитирования: Казаринова В.Е., Гацук А.С., Арзамасов К.М., Васильев Ю.А. Оценка эффективности алгоритмов глубокого обучения для выявления признаков *spina bifida occulta* на рентгенограммах позвоночника.

Визуализация в медицине. 2026;8(2):6–16. <https://doi.org/10.56871/ViM.2026.26.75.001>.

Поступила: 22.05.2026

Одобрена: 01.07.2026

Принята к печати: 10.08.2026

Резюме. Введение. *Spina bifida occulta* — скрытый порок развития позвоночника, часто остающийся недиагностированным до появления неврологических симптомов. Разработка системы автоматизированного выявления данной патологии на рентгенограммах с использованием нейросетей требует обоснованного выбора архитектуры, обеспечивающей оптимальную диагностическую точность. **Цель исследования** — оценить эффективность алгоритмов глубокого обучения (ResNet50, EfficientNet-B7, RT-DETR-L, YOLO версий 8–12) для выявления признаков *spina bifida occulta* на рентгенограммах шейного, грудного и пояснично-крестцового отделов позвоночника. **Материалы и методы.** Сформирован ретроспективный размеченный набор данных из 1732 рентгенограмм позвоночника (360 — шейный, 141 — грудной, 1231 — пояснично-крестцовый отдел), собранных за период 2022–2024 гг. Баланс классов «патология» : «норма» составил 50:50. Проведена автоматическая обрезка области позвоночного столба с использованием визуально-языковой модели Qwen3-VL. Обучающая подвыборка увеличена в 3 раза методами аугментации. Модели обучены и протестированы с расчетом чувствительности, специфичности, точности и AUC (ROC-анализ). **Результаты.** Лучшие результаты для шейного отдела достигнуты моделью YOLOv9t (AUC=0,926 [95% доверительный интервал (ДИ) 0,816–1,000]); для грудного — YOLOv10n и YOLOv11n (AUC=0,982 [95% ДИ 0,933–1,000]); для пояснично-крестцового — YOLOv8m (AUC=0,956 [95% ДИ 0,923–0,989]). ResNet50 и EfficientNet-B7 показали существенно более низкую эффективность (AUC — до 0,839). Модели YOLO обеспечивают не только классификацию изображений, но и детекцию порока на рентгенограммах в виде ограничивающих рамок. **Заключение.** Архитектуры семейства YOLO превосходят альтернативные модели глубокого обучения для выявления *spina bifida occulta* на рентгенограммах. Полученные метрики позволяют рекомендовать YOLOv9t, YOLOv10n, YOLOv11n и YOLOv8m в качестве основы для разработки программного обеспечения для автоматизированного выявления *spina bifida occulta* на рентгенограммах шейного, грудного и пояснично-крестцового отделов позвоночника.

Ключевые слова: *spina bifida occulta*, рентгенография позвоночника, искусственный интеллект

✉ Вероника Евгеньевна Казаринова. E-mail: KazarinovaVE@zdrav.mos.ru

© Коллектив авторов, 2026

<https://doi.org/10.56871/ViM.2026.26.75.001>

Evaluating the performance of deep learning algorithms for detecting *spina bifida occulta* on spinal radiographs

Veronika E. Kazarinova¹, Andrey S. Gatsuk¹, Kirill M. Arzamasov^{1,2,3}, Yuriy A. Vasilev¹

¹ Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of Moscow Healthcare Department, 24/1, Petrovka str., Moscow, 127051, Russian Federation

² MIREA — Russian Technological University, 78 Vernadskogo ave., Moscow, 119454, Russian Federation

³ Samara State Medical University, 89 Chapaevskaya str., Samara, 443099, Russian Federation

For citation: Kazarinova V.E., Gatsuk A.S., Arzamasov K.M., Vasilev Yu.A. Evaluating the performance of deep learning algorithms for detecting *Spina Bifida Occulta* on spinal radiographs. *Visualization in Medicine*. 2026;8(2):6–16. (In Russ.).

<https://doi.org/10.56871/ViM.2026.26.75.001>.

Received: 22.05.2026

Revised: 01.07.2026

Accepted: 10.08.2026

Abstract. Introduction. *Spina bifida occulta* is a latent congenital spinal defect that often remains undiagnosed until neurological symptoms appear. The development of a system for the automated detection of this pathology on radiographs using neural networks requires a sound choice of architecture that ensures optimal diagnostic performance. **Aim** — to evaluate the performance of deep learning algorithms (ResNet50, EfficientNet-B7, RT-DETR-L, and YOLO versions 8–12) for detecting *spina bifida occulta* on cervical, thoracic, and lumbosacral spine radiographs. **Materials and methods.** A retrospective, labeled dataset was compiled from 1,732 spinal radiographs (360 cervical, 141 thoracic, and 1,231 lumbosacral) acquired between 2022 and 2024. The dataset was balanced 50:50 between pathological and normal cases. Automatic cropping of the spinal column region was performed using the Qwen3-VL vision-language model. The training subset was expanded threefold using data augmentation techniques. The models were trained and tested using sensitivity, specificity, accuracy, and area under the receiver operating characteristic curve (AUC-ROC). **Results.** For the cervical spine, the best performance was achieved by the YOLOv9t model (AUC=0.926 [95% confidence interval (CI): 0.816–1.000]); for the thoracic spine, by YOLOv10n and YOLOv11n (AUC=0.982 [95% CI: 0.933–1.000]); and for the lumbosacral spine, by YOLOv8m (AUC=0.956 [95% CI: 0.923–0.989]). ResNet50 and EfficientNet-B7 demonstrated significantly lower performance, yielding AUC values not exceeding 0.839. YOLO models enabled both image classification and defect localization on radiographs using bounding boxes. **Conclusion.** YOLO architectures outperform alternative deep learning models for detecting SBO on radiographs. These metrics support the integration of YOLOv9t, YOLOv10n, YOLOv11n, and YOLOv8m into software for automated detection of *Spina Bifida Occulta* on cervical, thoracic, and lumbosacral radiographs.

Keywords: *spina bifida occulta*, spine radiography, artificial intelligence

✉ Veronika E. Kazarinova. E-mail: KazarinovaVE@zdrav.mos.ru

© 2026 by the authors

ВВЕДЕНИЕ

Spina bifida occulta (SBO) представляет собой скрытую форму врожденного дефекта нервной трубки, характеризующуюся незаращением дужек одного или нескольких позвонков без пролапса нервных структур или мозговых оболочек в дефект, что принципиально отличает ее от более тяжелых форм, таких как миелоцистоцеле или миеломенингоцеле [1]. Порок преимущественно локализуется в пояснично-крестцовом отделе позвоночного столба (позвонки L_v–S₁ — до 70% случаев), реже — в шейном или грудном отделах, что связано с особенностями формирования позвоночного канала в период внутриутробного развития [2, 3].

В популяционных исследованиях оценка распространенности SBO значительно варьирует: от 2 до 54% в общей популяции [4–6]. Несмотря на то что большинство случаев протекает бессимптомно и может сопровождаться лишь отдельными кожными стигмами [7], у части пациентов с возрастом развиваются и прогрессируют неврологические проявления: хроническая дорсалгия, парестезии и онемение нижних конечностей, гиперрефлексия или мышечная слабость, а также нейрогенная дисфункция мочевого пузыря и/или кишечника [8–12].

Пренатальное выявление SBO с помощью ультразвукового исследования (УЗИ) затруднено из-за отсутствия характерных эхографических изменений анатомических структур. После рождения ребенка SBO чаще всего является случайной находкой при рентгенографии (РГ), выполненной по другому поводу. При появлении неврологических симптомов целенаправленную диагностику проводят с помощью РГ или магнитно-резонансной томографии (МРТ).

Внедрение технологий искусственного интеллекта (ИИ) в здравоохранении соответствует Национальной стратегии Российской Федерации на период до 2030 г. и успешно реализуется в рамках «Эксперимента по использованию инновационных технологий в области компьютерного зрения для анализа медицинских изображений и дальнейшего применения этих технологий в системе здравоохранения» [13]. Вместе с тем применение ИИ для диагностики SBO до настоящего времени остается нереализованным направлением.

Таким образом, актуальной задачей является создание программного обеспечения (ПО) для автоматизированного выявления SBO (шейной, грудной и пояснично-крестцовой локализаций) на РГ позвоночника у пациентов всех возрастов. Первым шагом на пути разработки такого ПО становится выбор архитектуры нейросети, обеспечивающей

наилучший баланс чувствительности, специфичности и общей точности при работе с данными медицинской визуализации.

ЦЕЛЬ ИССЛЕДОВАНИЯ

Оценить эффективность алгоритмов глубокого обучения по выявлению признаков SBO на РГ позвоночника.

МАТЕРИАЛЫ И МЕТОДЫ

1. Набор данных

Для обучения и тестирования алгоритмов глубокого обучения были сформированы три набора данных, структурированных по отделам позвоночного столба [14, 15].

В исследование были включены результаты РГ шейного, грудного или пояснично-крестцового отделов позвоночника в прямой проекции, выполненной при оказании плановой медицинской помощи в амбулаторных условиях или в условиях стационара пациентам мужского и женского пола всех возрастов:

- имеющие рентгенологические признаки SBO на изображении и заключение врача-рентгенолога о наличии SBO в протоколе описания исследования;
- не имеющие рентгенологических признаков SBO на изображении, в протоколе описания исследования врачом-рентгенологом SBO не указана. Критериями исключения были следующие:
- низкое качество исследования;
- затрудненная визуализация в связи с техническими дефектами, двигательными артефактами или артефактами инородных объектов на уровне исследования.

Поиск, выгрузку и анонимизацию исследований из Единого радиологического информационного сервиса Единой медицинской информационно-аналитической системы (ЕРИС ЕМИАС) осуществляли с использованием «Платформы подготовки наборов данных» [16].

Разметку проводили на платформе CVAT: контуры признаков SBO выделял вручную врач-рентгенолог и сохранял в виде координат ограничивающих рамок, а случаи без патологии маркировали тегом «норма».

Итоговая выборка составила 1732 размеченные рентгенограммы (360 — шейный отдел позвоночника, 141 — грудной отдел, 1231 — пояснично-крестцовый отдел), собранные за период с 01.01.2022 по 31.12.2024 г. Баланс классов «патология» : «норма» был равен ~50:50. Минимальный возраст пациентов составил 2 года, максимальный —




Рис. 1. Распределение пациентов по полу и возрасту (рисунок авторов данной статьи)
Fig. 1. Distribution of patients by gender and age (figure by the authors of this article)

90 лет, средний возраст — 34,7 года, медианный возраст — 30, мода — 17. Распределение по полу следующее: 1025 пациентов женского пола, 682 — мужского (рис. 1).

2. Предварительная обработка данных

На этапе предварительной обработки данных применяли метод автоматической обрезки области интереса — позвоночного столба — с использованием визуально-языковой модели qwen3-vl:8b-instruct. Модели был задан системный промпт, предписывающий выделить исключительно костные структуры позвоночного столба, расположенные по центру изображения, и вернуть координаты ограничивающих рамок в формате [x1, y1, x2, y2]. На основе полученных координат выполняли кадрирование оригинального изображения (рис. 2).

Полученные изображения были разделены на обучающую, валидационную и тестовую подвыборки в соотношении 80:10:10. К обучающей подвыборке применяли методы аугментации данных, что позволило увеличить ее объем в 3 раза.

3. Обучение и тестирование нейросетей

Для выявления SBO на РГ были исследованы следующие архитектуры нейросетей: ResNet50, EfficientNet-B7, YOLO (версии 8x/n/m, 9t/m/e, 10x/n/m, 11n/x/m, 12n/m) и RT-DETR-L. Обучение проводили на обучающей подвыборке с оценкой точности классификации на валидационной подвыборке после каждой эпохи. Модели сохранялись при достижении максимальной точности с применением механизма ранней остановки по лучшему состоянию.

Диагностическую точность оценивали на тестовой подвыборке с помощью ROC-анализа [17]. Рас-




Рис. 2. Пример обработки данных: а — исходное изображение; б — результат обрезки изображения по области интереса (фото авторов)

Fig. 2. An example of data processing: a — the original image; b — the result of cropping the image by region of interest (photos by the authors)

считывали следующие метрики при оптимальном пороге классификации, определенном по максимальному индексу Юдена: точность, чувствительность и специфичность, а также площадь под ROC-кривой (AUC).

РЕЗУЛЬТАТЫ

Метрики моделей, полученных в результате исследования, представлены в табл. 1–3. На рис. 3–5 продемонстрированы совмещенные графики ROC-




Рис. 3. ROC-кривые моделей на наборе данных шейного отдела позвоночника (рисунок авторов данной статьи)

Fig. 3. ROC curves of models on a dataset of the cervical spine (figure by the authors of this article)

кривых для всех сравниваемых моделей по каждому отделу позвоночного столба.

Шейный отдел

Лучший результат достигнут моделью YOLOv9t: точность — 0,919, чувствительность — 0,923, специфичность — 0,917, AUC=0,926. Высокие показатели также у YOLOv12n (AUC=0,913), YOLOv11m (AUC=0,901) и YOLOv8m (AUC=0,901).

Наименьшую эффективность показали EfficientNetB7 (AUC=0,699) и ResNet50 (AUC=0,727).

Грудной отдел

Наиболее высокие результаты получены для YOLOv10n и YOLOv11n: обе модели достигли точности 0,933 и AUC=0,982. Худшие результаты у ResNet50 (AUC=0,482), что указывает на случайный уровень распознавания.

Поясничный отдел

Лучшая модель — YOLOv8m: точность — 0,918, чувствительность — 0,945, специфичность — 0,896, AUC=0,956. Сравнимые результаты показали

Таблица 1

Метрики моделей на наборе данных шейного отдела позвоночника

Table 1

Metrics of models based on a dataset of the cervical spine

Модель / Model	Точность [95% ДИ] / Accuracy [95% CI]	Специфичность [95% ДИ] / Specificity [95% CI]	Чувствительность [95% ДИ] / Sensitivity [95% CI]	AUC [95% ДИ] / AUC [95% CI]
EfficientNetB7	0,730 [0,587–0,873]	0,913 [0,798–1,000]	0,429 [0,169–0,688]	0,699 [0,516–0,882]
ResNet50	0,757 [0,619–0,895]	0,957 [0,873–1,000]	0,429 [0,169–0,688]	0,727 [0,552–0,901]
RT-DETR-L	0,865 [0,755–0,975]	0,957 [0,873–1,000]	0,714 [0,478–0,951]	0,860 [0,734–0,987]
YOLOv8n	0,865 [0,755–0,975]	1,000 [1,000–1,000]	0,615 [0,351–0,880]	0,869 [0,731–1,000]
YOLOv8m	0,838 [0,719–0,957]	0,875 [0,743–1,000]	0,769 [0,540–0,998]	0,901 [0,804–0,997]
YOLOv8x	0,811 [0,685–0,937]	0,958 [0,878–1,000]	0,538 [0,267–0,809]	0,766 [0,592–0,940]
YOLOv9t	0,919 [0,831–1,000]	0,917 [0,806–1,000]	0,923 [0,778–1,000]	0,926 [0,816–1,000]
YOLOv9m	0,838 [0,719–0,957]	1,000 [1,000–1,000]	0,538 [0,267–0,809]	0,824 [0,677–0,970]
YOLOv9e	0,865 [0,755–0,975]	1,000 [1,000–1,000]	0,615 [0,351–0,880]	0,798 [0,628–0,968]
YOLOv10n	0,811 [0,685–0,937]	0,792 [0,629–0,954]	0,846 [0,650–1,000]	0,859 [0,740–0,978]
YOLOv10m	0,838 [0,719–0,957]	0,958 [0,878–1,000]	0,615 [0,351–0,880]	0,804 [0,629–0,980]
YOLOv10x	0,865 [0,755–0,975]	0,958 [0,878–1,000]	0,692 [0,441–0,943]	0,849 [0,709–0,990]
YOLOv11n	0,811 [0,685–0,937]	0,826 [0,671–0,981]	0,786 [0,571–1,000]	0,863 [0,734–0,992]
YOLOv11m	0,838 [0,719–0,957]	0,833 [0,684–0,982]	0,846 [0,650–1,000]	0,901 [0,795–1,000]
YOLOv11x	0,757 [0,619–0,895]	0,833 [0,684–0,982]	0,615 [0,351–0,880]	0,734 [0,550–0,918]
YOLOv12n	0,865 [0,755–0,975]	0,875 [0,743–1,000]	0,846 [0,650–1,000]	0,913 [0,800–1,000]
YOLOv12m	0,838 [0,719–0,957]	0,875 [0,743–1,000]	0,769 [0,540–0,998]	0,901 [0,804–0,997]

Таблица составлена авторами / The table is compiled by the authors




Рис. 4. ROC-кривые моделей на наборе данных грудного отдела позвоночника (рисунок авторов данной статьи)
Fig. 4. ROC curves of models on a dataset of the thoracic spine (figure by the authors of this article)




Рис. 5. ROC-кривые моделей на наборе данных пояснично-крестцового отдела позвоночника (рисунок авторов данной статьи)
Fig. 5. ROC curves of models on a dataset of the lumbosacral spine (figure by the authors of this article)

Таблица 2

Метрики моделей на наборе данных грудного отдела позвоночника

Table 2

Metrics of models based on the thoracic spine dataset				
Модель / Model	Точность [95% ДИ] / Accuracy [95% CI]	Специфичность [95% ДИ] / Specificity [95% CI]	Чувствительность [95% ДИ] / Sensitivity [95% CI]	AUC [95% ДИ] / AUC [95% CI]
EfficientNetB7	0,800 [0,598–1,000]	0,714 [0,380–1,000]	0,875 [0,646–1,000]	0,839 [0,625–1,000]
ResNet50	0,600 [0,352–0,848]	1,000 [1,000–1,000]	0,250 [0,000–0,550]	0,482 [0,154–0,810]
RT-DETR-L	0,867 [0,695–1,000]	1,000 [1,000–1,000]	0,750 [0,450–1,000]	0,893 [0,723–1,000]
YOLOv8n	0,800 [0,598–1,000]	1,000 [1,000–1,000]	0,625 [0,290–0,960]	0,857 [0,656–1,000]
YOLOv8m	0,800 [0,598–1,000]	1,000 [1,000–1,000]	0,625 [0,290–0,960]	0,857 [0,662–1,000]
YOLOv8x	0,733 [0,510–0,957]	0,857 [0,598–1,000]	0,625 [0,290–0,960]	0,768 [0,511–1,000]
YOLOv9t	0,733 [0,510–0,957]	0,714 [0,380–1,000]	0,750 [0,450–1,000]	0,696 [0,399–0,994]
YOLOv9m	0,933 [0,807–1,000]	1,000 [1,000–1,000]	0,875 [0,646–1,000]	0,964 [0,881–1,000]
YOLOv9e	0,667 [0,428–0,905]	0,714 [0,380–1,000]	0,625 [0,290–0,960]	0,589 [0,265–0,914]
YOLOv10n	0,933 [0,807–1,000]	1,000 [1,000–1,000]	0,875 [0,646–1,000]	0,982 [0,933–1,000]
YOLOv10m	0,733 [0,510–0,957]	1,000 [1,000–1,000]	0,500 [0,154–0,846]	0,714 [0,435–0,994]
YOLOv10x	0,667 [0,428–0,905]	0,571 [0,205–0,938]	0,750 [0,450–1,000]	0,643 [0,340–0,946]
YOLO11n	0,933 [0,807–1,000]	1,000 [1,000–1,000]	0,875 [0,646–1,000]	0,982 [0,933–1,000]
YOLO11m	0,867 [0,695–1,000]	0,857 [0,598–1,000]	0,875 [0,646–1,000]	0,893 [0,723–1,000]
YOLO11x	0,733 [0,510–0,957]	1,000 [1,000–1,000]	0,500 [0,154–0,846]	0,625 [0,299–0,951]
YOLO12n	0,867 [0,695–1,000]	1,000 [1,000–1,000]	0,750 [0,450–1,000]	0,839 [0,613–1,000]
YOLO12m	0,933 [0,807–1,000]	0,857 [0,598–1,000]	1,000 [1,000–1,000]	0,946 [0,830–1,000]

Таблица составлена авторами / The table is compiled by the authors

Таблица 3

Метрики моделей на наборе данных пояснично-крестцового отдела позвоночника

Table 3

Metrics of models based on the dataset of the lumbosacral spine

Модель / Model	Точность [95% ДИ] / Accuracy [95% CI]	Специфичность [95% ДИ] / Specificity [95% CI]	Чувствительность [95% ДИ] / Sensitivity [95% CI]	AUC [95% ДИ] / AUC [95% CI]
EfficientNetB7	0,762 [0,687–0,838]	0,672 [0,559–0,784]	0,873 [0,785–0,961]	0,805 [0,728–0,883]
ResNet50	0,697 [0,615–0,778]	0,537 [0,418–0,657]	0,891 [0,809–0,973]	0,761 [0,678–0,845]
RT-DETR-L	0,697 [0,615–0,778]	0,582 [0,464–0,700]	0,836 [0,739–0,934]	0,702 [0,608–0,797]
YOLOv8n	0,877 [0,819–0,935]	0,821 [0,729–0,913]	0,945 [0,885–1,000]	0,944 [0,908–0,981]
YOLOv8m	0,918 [0,869–0,967]	0,896 [0,822–0,969]	0,945 [0,885–1,000]	0,956 [0,923–0,989]
YOLOv8x	0,869 [0,809–0,929]	0,910 [0,842–0,979]	0,818 [0,716–0,920]	0,933 [0,893–0,974]
YOLOv9t	0,893 [0,839–0,948]	0,910 [0,842–0,979]	0,873 [0,785–0,961]	0,924 [0,876–0,972]
YOLOv9m	0,803 [0,733–0,874]	0,761 [0,659–0,863]	0,855 [0,761–0,948]	0,869 [0,803–0,934]
YOLOv9e	0,836 [0,770–0,902]	0,910 [0,842–0,979]	0,745 [0,630–0,861]	0,882 [0,822–0,942]
YOLOv10n	0,828 [0,761–0,895]	0,866 [0,784–0,947]	0,782 [0,673–0,891]	0,909 [0,858–0,959]
YOLOv10m	0,861 [0,799–0,922]	0,896 [0,822–0,969]	0,818 [0,716–0,920]	0,923 [0,877–0,970]
YOLOv10x	0,893 [0,839–0,948]	0,896 [0,822–0,969]	0,891 [0,809–0,973]	0,946 [0,909–0,983]
YOLO11n	0,828 [0,761–0,895]	0,806 [0,711–0,901]	0,855 [0,761–0,948]	0,888 [0,831–0,946]
YOLO11m	0,852 [0,790–0,915]	0,866 [0,784–0,947]	0,836 [0,739–0,934]	0,930 [0,889–0,972]
YOLO11x	0,885 [0,829–0,942]	0,881 [0,803–0,958]	0,891 [0,809–0,973]	0,927 [0,877–0,977]
YOLO12n	0,885 [0,829–0,942]	0,866 [0,784–0,947]	0,909 [0,833–0,985]	0,942 [0,904–0,981]
YOLO12m	0,820 [0,751–0,888]	0,851 [0,765–0,936]	0,782 [0,673–0,891]	0,868 [0,802–0,933]

Таблица составлена авторами / The table is compiled by the authors

YOLOv10x (AUC=0,946), YOLOv8n (AUC=0,944), YOLOv12n (AUC=0,942) и YOLOv11x (AUC=0,927). Эффективность EfficientNetB7 (AUC=0,805) и ResNet50 (AUC=0,761) была ниже, однако они превосходили свои же результаты на шейном отделе. RT-DETR-L показал невысокие метрики (AUC=0,702) из-за низкой специфичности (0,582).

ОБСУЖДЕНИЕ

Проведено обучение и тестирование 17 моделей глубокого обучения для выявления SBO на РГ трех отделов позвоночника: шейного, грудного и пояснично-крестцового. Результаты свидетельствуют о существенном превосходстве в данной задаче моделей семейства YOLO: YOLOv9t и YOLOv8m — лидеры по выявлению SBO на РГ шейного и пояснично-крестцового отделов позвоночника соответственно, а на РГ грудного отдела позвоночника сразу несколько YOLO-моделей достигли AUC >0,95. Модели ResNet50, EfficientNetB7 и RT-DETR-L уступили YOLO по всем метрикам, особенно по чувствительности.

Высокие показатели ROC-анализа свидетельствуют об эффективности бинарной классификации лидирующих моделей, что может быть использовано для автоматизированной сортировки иссле-

дований на «норму» и «патологию». Это один из возможных сценариев внедрения ПО на основе технологий ИИ в лучевую диагностику [18]. Однако в клинической практике при диагностике SBO наиболее релевантный сценарий внедрения ИИ — система поддержки принятия врачебных решений. В этом случае важна не только вероятность наличия заболевания, но и пространственная локализация порока. Модели ResNet50 и EfficientNetB7 по своей архитектуре не предназначены для детекции объектов на изображении: они обеспечивают только выходной вектор вероятностей. Чтобы компенсировать это ограничение применяют, например, метод Gradient-weighted Class Activation Mapping (GradCAM), который позволяет визуализировать области входного изображения, оказавшие наибольшее влияние на классификационное решение (рис. 6). Важно подчеркнуть, что, хотя GradCAM зачастую демонстрирует косвенное соответствие между значимой областью и реальной локализацией патологии на РГ, это не является полноценной детекцией. Во-первых, тепловая карта GradCAM не имеет строгих границ, во-вторых, ее пространственное разрешение ограничено размером карт признаков, который уменьшается с глубиной сверточных слоев. Следовательно, GradCAM пригоден при




Рис. 6. Пример предсказания патологии моделью EfficientNetB7: *a* — изображение с истинной разметкой; *б* — тепловая карта GradCAM (фото авторов)

Fig. 6. Example of pathology prediction by the EfficientNetB7 model: *a* — an image with true markup; *b* — a GradCAM heat map (photos by the authors)




Рис. 7. Пример предсказания патологии моделью YOLOv9t: синим прямоугольником оконтурены признаки *spina bifida occulta*, числовое значение отображает степень уверенности (фото авторов)

Fig. 7. Example of pathology prediction by the YOLOv9t model: *Spina Bifida Occulta* signs are outlined in a blue rectangle, the numerical value shows the degree of confidence (photos by the authors)

интерпретации результатов в формате «объяснимо-го ИИ», но не может заменить алгоритмы детекции.

Модели семейства YOLO и RT-DETR-L относятся к классу нейросетей для детекции объектов. Как показано на рис. 7, на выходе они генерируют степень уверенности в наличии патологии и координаты ограничивающих рамок порока, что имеет большую диагностическую ценность.

Следует отметить, что в мировой практике существуют решения для диагностики *spina bifida* по данным УЗИ [19–22]. Однако они ограничены задачами пренатального выявления открытой формы порока — *spina bifida aperta*. Единственная известная работа, посвященная анализу РГ позвоночника, фокусируется исключительно на SBO пояснично-крестцовой локализации [23]. Лучшая модель в этом исследовании достигла точности 85,5%, чувствительности — 80,8%, специфичности — 89,7% и AUC=0,92, что сопоставимо с результатами нашего исследования. Однако эта разработка решает лишь задачу классификации РГ без детекции SBO на снимке. Таким образом, в отличие от перечисленных ра-

бот, наше исследование нацелено на решение более широкой клинической задачи: разработка охватывает шейный, грудной и пояснично-крестцовый отделы позвоночника. Более того, мы переходим от простой классификации к детекции SBO, что позволяет получить более значимую клиническую информацию.

ЗАКЛЮЧЕНИЕ

В ходе исследования оценена эффективность 17 алгоритмов глубокого обучения для выявления SBO на РГ шейного, грудного и пояснично-крестцового отделов позвоночника. Установлено, что модели семейства YOLO превосходят ResNet50, EfficientNet-B7 и RT-DETR-L по метрикам диагностической точности в данной задаче. Для шейного отдела лучший результат показала модель YOLOv9t, для грудного лучшими были YOLOv10n и YOLOv11n, для пояснично-крестцового — YOLOv8m.

Практическим выводом является преимущество детекционных архитектур (YOLO, RT-DETR-L) над классификационными (ResNet, EfficientNet)

в данной задаче, поскольку первые позволяют не только классифицировать РГ, но и предоставлять пространственную локализацию порока (координаты ограничивающих рамок). Методы построения тепловых карт, например, GradCAM, не могут служить полноценной заменой детекции.

Таким образом, архитектуры семейства YOLO могут быть рекомендованы в качестве основы для разработки ПО для автоматизированного выявления SBO на РГ. Полученные ROC-кривые и метрики диагностической точности демонстрируют потенциал применения методов глубокого обучения в диагностике SBO.

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Вклад авторов. Все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией.

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

Источник финансирования. Данная статья подготовлена авторским коллективом в рамках научно-исследовательской работы «Искусственный интеллект для одновременного анализа изображений и ЭМК (мультимодальный ИИ)» в соответствии с приказом от 27.11.2025 г. № 1213 «Об утверждении государственных заданий, финансовое обеспечение которых осуществляется за счет средств бюджета города Москвы, государственным бюджетным (автономным) учреждениям, подведомственным Департаменту здравоохранения города Москвы, на 2026 год и плановый период 2027 и 2028 годов» Департамента здравоохранения города Москвы.

Этическая экспертиза. Данное исследование одобрено независимым этическим комитетом при ГБУЗ «НПКЦ ДиТ ДЗМ» (выписка из протокола № 01/2026 от 22 января 2026 г.).

ADDITIONAL INFORMATION

Author contribution. All authors made a substantial contribution to the conception of the study, acquisition, analysis, interpretation of data for the work, drafting and revising the article, final approval of the version to be published and agree to be accountable for all aspects of the study.

Competing interests. The authors declare that they have no conflicts of interest.

Funding. This article was prepared by a group of authors as a part of the research and development effort titled “Artificial intelligence for synchronous evaluation of images and EHR (multimodal AI)”, in accordance with the

Order No. 1213 dated November 27, 2025 “On approval of state assignments funded by means of allocations from the budget of the city of Moscow to the state budgetary (autonomous) institutions subordinate to the Moscow Health Care Department, for 2026 and the planned period of 2027 and 2028” issued by the Moscow Health Care Department.

Ethical statement. This study was approved by the Independent Ethics Committee of the State Budget Funded Health Care Institution of the City of Moscow “Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Health Care Department” (extract from protocol No. 01/2026 dated January 22, 2026).

ЛИТЕРАТУРА

1. Schindelmann K.H., Paschereit F., Steege A., Stoltenburg-Didinger G., Kaendl A.M. Systematic classification of Spina bifida. *J Neuropathol Exp Neurol.* 2021;80(4):294–305. <https://doi.org/10.1093/jnen/nlab007>. EDN: DEOKYD.
2. Sipos T.C., Denes L., Brinzaniuc K., Sipos R.S., Raduly G., Pap Z. Study of Spina bifida occulta based on age, sex and localization. *ARS Medica Tomitana.* 2019;25(3):95–99. <https://doi.org/10.2478/arsm-2019-0020>.
3. Заточная В.В. Формирование позвоночного канала в эмбриогенезе человека. *Морфологические ведомости.* 2018;26(1):33–37. [https://doi.org/10.20340/mv-mn.18\(26\).01.33-37](https://doi.org/10.20340/mv-mn.18(26).01.33-37). EDN: XYTINV.
4. Härle A. Incidence of Spina bifida occulta and its importance in orthopaedic diseases. In: Spina bifida — neural tube defects: Basic research, interdisciplinary diagnostics and treatment, results and prognosis. P. Gless, J. Lorber, D. Voth, eds. Berlin, Boston: De Gruyter; 1986. P. 249–256. <https://doi.org/10.1515/9783110850307-032>.
5. Fidas A., MacDonald H.L., Elton R.A., Wild S.R., Chisholm G.D., Scott R. Prevalence and patterns of spina bifida occulta in 2707 normal adults. *Clin Radiol.* 1987;38(5):537–542. [https://doi.org/10.1016/s0009-9260\(87\)80150-2](https://doi.org/10.1016/s0009-9260(87)80150-2).
6. Eubanks J.D., Cheruvu V.K. Prevalence of sacral spina bifida occulta and its relationship to age, sex, race, and the sacral table angle: an anatomic, osteologic study of three thousand one hundred specimens. *Spine.* 2009;34(15):1539–1543. <https://doi.org/10.1097/BRS.0b013e3181a98560>.
7. Bessis D. Cutaneous signs of occult cranial and spinal dysraphism. *Ann Dermatol Venereol.* 2020;147(8-9):504–519. <https://doi.org/10.1016/j.annder.2020.02.011>. EDN: BLFVKO.
8. Mirzaei S., Khoshkholghsima M., Sabaghzadeh A., Kurdkandi H.Z. Cervicothoracic (C₆, C₇ & T₁) spina bifida occulta — A case report. *Int J Surg Case Rep.* 2024;117:109477. <https://doi.org/10.1016/j.ijscr.2024.109477>. EDN: DJAPBA.
9. Sakti Y.M., Lanodiyu Z.A., Sakadewa G.P., Cein C.R., Baskara A.A.N.N., Rahayu B.F.P. Spina bifida occulta at the lumbar spine level manifested as chronic low back pain and unpredictable neurologic deficit: A case report. *Int J Surg Case Rep.* 2024;116:109320. <https://doi.org/10.1016/j.ijscr.2024.109320>. EDN: NMEPSY.

10. Goto T., Sakai T., Sato N., Katoh S., Sairyo K. An adolescent athlete with low back pain associated with Spina bifida occulta at the thoracolumbar junction: A case report. *J Med Invest.* 2019;66(1.2):199–200. <https://doi.org/10.2152/jmi.66.199>.
11. Taskaynatan M.A., Izci Y., Ozgul A., Hazneci B., Dursun H., Kalyon T.A. Clinical significance of congenital lumbosacral malformations in young male population with prolonged low back pain. *Spine.* 2005;30(8):E210–E213. <https://doi.org/10.1097/01.brs.0000158950.84470.2a>.
12. Muranaka I., Kyoda Y., Nofuji S. et al. A case of neuropathic lower urinary tract dysfunction due to Spina bifida occulta discovered at the age of 19 years and successfully treated with multidisciplinary therapy. *Hinyokika Kyo.* 2024;70(2):55–59. https://doi.org/10.14989/ActaUrolJap_70_2_55.
13. Васильев Ю.А., Владимирский А.В., Арзамасов К.М. и др. Искусственный интеллект в лучевой диагностике: Per Aspera Ad Astra. М.: НПКЦ ДиТ ДЗМ; 2025. 493 с. EDN: OOWUTV.
14. Свидетельство о государственной регистрации базы данных № 2025622039 Российская Федерация. MosMedData: рентгенография шейного и грудного отдела позвоночника с наличием или отсутствием Spina Bifida: заявл. 11.04.2025; опублик. 12.05.2025. Ю.А. Васильев, А.В. Владимирский, О.В. Омелянская и др.; заявитель ГБУЗ «НПКЦ ДиТ ДЗМ».
15. Свидетельство о государственной регистрации базы данных № 2024625146 Российская Федерация. MosMedData: рентгенография пояснично-крестцового отдела позвоночника с наличием или отсутствием Spina Bifida у взрослых: № 2024624865: заявл. 31.10.2024; опублик. 13.11.2024. Ю.А. Васильев, А.В. Владимирский, О.В. Омелянская и др.; заявитель ГБУЗ «НПКЦ ДиТ ДЗМ».
16. Васильев Ю.А., Владимирский А.В., Омелянская О.В. и др. Автоматизированная платформа для формирования наборов данных в лучевой диагностике. *Менеджер здравоохранения.* 2025;(7):52–67. <https://doi.org/10.21045/1811-0185-2025-7-52-67>. EDN: YAVSYA.
17. Kirpichev Yu., Vasilev Yu., Vladzmyrsky A. et al. Free web tool for comprehensive ROC analysis. *Biological Communications.* 2025;70(3):215–222. <https://doi.org/10.21638/spbu03.2025.305>. EDN: RTOVSR.
18. Васильев Ю.А., Владимирский А.В., Арзамасов К.М. и др. Внедрение медицинских изделий с технологиями искусственного интеллекта в лучевую диагностику: методические рекомендации. Ч. 1. Сценарии и оценка эффективности. М.: НПКЦ ДиТ ДЗМ; 2025. 32 с. EDN: MKJYJC.
19. Asha R., Subashka Ramesh S.S. An optimized modified faster region convolutional neural network for Spina bifida identification from ultrasound images. *Biomed Signal Process Control.* 2023;86:105253. <https://doi.org/10.1016/j.bspc.2023.105253>. EDN: KZVSBL.
20. Asha R., Subashka Ramesh S.S. Segmentation and classification of fetal Spina bifida using DED with FM2DCN. *Multimed Tools Appl.* 2024;83(25):66981–66999. <https://doi.org/10.1007/s11042-024-18160-9>. EDN: RKUKQI.
21. Omopintemi A.H., David A.O., Adeyemi O.A. Machine learning algorithm for classification of infant congenital anomaly. In: Intelligent Sustainable Systems (WorldS4 2024). Lecture notes in networks and systems. Vol. 1178. A. Nagar, D.S. Jat, D. Mishra, A. Joshi, eds. Springer, Singapore; 2025. P. 265–276. https://doi.org/10.1007/978-981-97-9559-8_23.
22. Chen L., Tian Y., Deng Y. Neural network algorithm-based three-dimensional ultrasound evaluation in the diagnosis of fetal Spina bifida. *Scientific Programming.* 2021;1:3605739. <https://doi.org/10.1155/2021/3605739>. EDN: LVIUJS.
23. Duran S., Üreten K., Maraş Y. et al. Automatic detection of Spina bifida occulta with deep learning methods from plain pelvic radiographs. *Res Biomed Eng.* 2023;39(3):655–661. <https://doi.org/10.1007/s42600-023-00296-6>. EDN: EEZHWM.

REFERENCES

1. Schindelmann K.H., Paschereit F., Steege A., Stoltenburg-Didinger G., Kaindl A.M. Systematic classification of Spina bifida. *J Neuropathol Exp Neurol.* 2021;80(4):294–305. <https://doi.org/10.1093/jnen/nlab007>. EDN: DEOKYD.
2. Sipos T.C., Denes L., Brinzaniuc K., Sipos R.S., Raduly G., Pap Z. Study of Spina bifida occulta based on age, sex and localization. *ARS Medica Tomitana.* 2019;25(3):95–99. <https://doi.org/10.2478/arsm-2019-0020>.
3. Zatochnaya V.V. The formation of the spinal canal in the human embryogenesis. *Morphological Newsletter.* 2018;26(1):33–37. (In Russ.). [https://doi.org/10.20340/mv-mn.18\(26\).01.33-37](https://doi.org/10.20340/mv-mn.18(26).01.33-37). EDN: XYTINV.
4. Härle A. Incidence of Spina bifida occulta and its importance in orthopaedic diseases. In: Spina bifida — neural tube defects: Basic research, interdisciplinary diagnostics and treatment, results and prognosis. P. Gless, J. Lorber, D. Voth, eds. Berlin, Boston: De Gruyter; 1986. P. 249–256. <https://doi.org/10.1515/9783110850307-032>.
5. Fidas A., MacDonald H.L., Elton R.A., Wild S.R., Chisholm G.D., Scott R. Prevalence and patterns of spina bifida occulta in 2707 normal adults. *Clin Radiol.* 1987;38(5):537–542. [https://doi.org/10.1016/s0009-9260\(87\)80150-2](https://doi.org/10.1016/s0009-9260(87)80150-2).
6. Eubanks J.D., Cheruvu V.K. Prevalence of sacral spina bifida occulta and its relationship to age, sex, race, and the sacral table angle: an anatomic, osteologic study of three thousand one hundred specimens. *Spine.* 2009;34(15):1539–1543. <https://doi.org/10.1097/BRS.0b013e3181a98560>.
7. Bessis D. Cutaneous signs of occult cranial and spinal dysraphism. *Ann Dermatol Venereol.* 2020;147(8-9):504–519. <https://doi.org/10.1016/j.annder.2020.02.011>. EDN: BLFVKO.
8. Mirzaei S., Khoshkholghsima M., Sabaghzadeh A., Kurdkan-di H.Z. Cervicothoracic (C₆, C₇ & T₁) spina bifida occulta — A case report. *Int J Surg Case Rep.* 2024;117:109477. <https://doi.org/10.1016/j.ijscr.2024.109477>. EDN: DJAPBA.
9. Sakti Y.M., Lanodiyyu Z.A., Sakadewa G.P., Cein C.R., Baskara A.A.N.N., Rahayu B.F.P. Spina bifida occulta at the lumbar spine level manifested as chronic low back pain and unpredictable neurologic deficit: A case report. *Int J Surg Case Rep.* 2024;116:109320. <https://doi.org/10.1016/j.ijscr.2024.109320>. EDN: NMEPSY.
10. Goto T., Sakai T., Sato N., Katoh S., Sairyo K. An adolescent athlete with low back pain associated with Spina bifida occulta

- at the thoracolumbar junction: A case report. *J Med Invest*. 2019;66(1.2):199–200. <https://doi.org/10.2152/jmi.66.199>.
11. Taskaynatan M.A., Izci Y., Ozgul A., Hazneci B., Dursun H., Kalyon T.A. Clinical significance of congenital lumbosacral malformations in young male population with prolonged low back pain. *Spine*. 2005;30(8):E210–E213. <https://doi.org/10.1097/01.brs.0000158950.84470.2a>.
 12. Muranaka I., Kyoda Y., Nofuji S. et al. A case of neuropathic lower urinary tract dysfunction due to Spina bifida occulta discovered at the age of 19 years and successfully treated with multidisciplinary therapy. *Hinyokika Kyo*. 2024;70(2):55–59. https://doi.org/10.14989/ActaUrolJap_70_2_55.
 13. Vasilev Yu.A., Vladzimirskyy A.V., Arzamasov K.M. et al. Artificial intelligence in diagnostic radiology: Per Aspera Ad Astra. Moscow: Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of Moscow Healthcare Department; 2025. 493 p. (In Russ.). EDN: OOWUTV.
 14. Certificate of State registration of the database No. 2025622039 Russian Federation. MosMedData: radiography of the cervical and thoracic spine with or without Spina Bifida. The application 11.04.2025, publ. 12.05.2025. Yu.A. Vasilev, A.V. Vladzimirskyy, O.V. Omelyanskaya et al.; the applicant Moscow Center for Diagnostics and Telemedicine. (In Russ.).
 15. Certificate of State registration of the database No. 2024625146 Russian Federation. MosMedData: radiography of the lumbosacral spine with or without Spina Bifida in adults: No. 2024624865. The application 31.10.2024, publ. 13.11.2024. Yu.A. Vasilev, A.V. Vladzimirskyy, O.V. Omelyanskaya et al.; the applicant Moscow Center for Diagnostics and Telemedicine. (In Russ.).
 16. Vasilev Yu.A., Vladzimirskyy A.V., Omelyanskaya O.V. et al. Platform for automated generation of radiological datasets. *Manager zdavoohranenia*. 2025;(7):52–67. (In Russ.). <https://doi.org/10.21045/1811-0185-2025-7-52-67>. EDN: YAVSYA.
 17. Kirpichev Yu., Vasilev Yu., Vladzimirskyy A. et al. Free web tool for comprehensive ROC analysis. *Biological Communications*. 2025;70(3):215–222. <https://doi.org/10.21638/spbu03.2025.305>. EDN: RTOVSR.
 18. Vasilev Yu.A., Vladzimirskyy A.V., Arzamasov K.M. et al. Implementation of medical devices incorporating artificial intelligence technologies in diagnostic imaging: methodological recommendations. Part 1. Scenarios and performance assessment. Moscow: Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of Moscow Healthcare Department; 2025. 32 p. (In Russ.). EDN: MKJYJC.
 19. Asha R., Subashka Ramesh S.S. An optimized modified faster region convolutional neural network for *Spina bifida* identification from ultrasound images. *Biomed Signal Process Control*. 2023;86:105253. <https://doi.org/10.1016/j.bspc.2023.105253>. EDN: KZVSBL.
 20. Asha R., Subashka Ramesh S.S. Segmentation and classification of fetal Spina bifida using DED with FM2DCN. *Multimed Tools Appl*. 2024;83(25):66981–66999. <https://doi.org/10.1007/s11042-024-18160-9>. EDN: RKUKQI.
 21. Omopintemi A.H., David A.O., Adeyemi O.A. Machine learning algorithm for classification of infant congenital anomaly. In: Intelligent Sustainable Systems (WorldS4 2024). Lecture notes in networks and systems. Vol. 1178. A. Nagar, D.S. Jat, D. Mishra, A. Joshi, eds. Springer, Singapore; 2025. P. 265–276. https://doi.org/10.1007/978-981-97-9559-8_23.
 22. Chen L., Tian Y., Deng Y. Neural network algorithm-based three-dimensional ultrasound evaluation in the diagnosis of fetal Spina bifida. *Scientific Programming*. 2021;1:3605739. <https://doi.org/10.1155/2021/3605739>. EDN: LVIUJS.
 23. Duran S., Üreten K., Maraş Y. et al. Automatic detection of Spina bifida occulta with deep learning methods from plain pelvic radiographs. *Res Biomed Eng*. 2023;39(3):655–661. <https://doi.org/10.1007/s42600-023-00296-6>. EDN: EEZHWM.

ОБ АВТОРАХ

✉ **Вероника Евгеньевна Казаринова** — младший научный сотрудник. E-mail: KazarinovaVE@zdrav.mos.ru; <https://orcid.org/0009-0001-3568-8138>; SPIN: 5901-5577

Андрей Сергеевич Гацук — младший научный сотрудник. E-mail: GatsukAS@zdrav.mos.ru; <https://orcid.org/0009-0000-0549-4204>; SPIN: 3120-6428

Кирилл Михайлович Арзамасов — д.м.н., руководитель научного отдела, Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы; доцент кафедры технологий искусственного интеллекта, МИРЭА — Российский технологический университет; доцент кафедры лучевой диагностики и лучевой терапии, Самарский государственный медицинский университет. E-mail: ArzamasovKM@zdrav.mos.ru; <https://orcid.org/0000-0001-7786-0349>; SPIN: 3160-8062

Юрий Александрович Васильев — д.м.н., доцент, главный врач. E-mail: VasilevYA1@zdrav.mos.ru; <https://orcid.org/0000-0002-5283-5961>; SPIN: 4458-5608

AUTHORS' INFO

✉ **Veronika E. Kazarinova** — Junior Researcher. E-mail: KazarinovaVE@zdrav.mos.ru; <https://orcid.org/0009-0001-3568-8138>; SPIN: 5901-5577

Andrey S. Gatsuk — Junior Researcher. E-mail: GatsukAS@zdrav.mos.ru; <https://orcid.org/0009-0000-0549-4204>; SPIN: 3120-6428

Kirill M. Arzamasov — Dr. Sci. (Med.), Head of the Scientific Department, Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies of Moscow Healthcare Department; Associate Professor of the Department of Artificial Intelligence Technologies, MIREA — Russian Technological University; Associate Professor of the Department of Radiation Diagnostics and Radiation Therapy, Samara State Medical University. E-mail: ArzamasovKM@zdrav.mos.ru; <https://orcid.org/0000-0001-7786-0349>; SPIN: 3160-8062

Yuriy A. Vasilev — Dr. Sci. (Med.), Associate Professor, Medical Director. E-mail: VasilevYA1@zdrav.mos.ru; <https://orcid.org/0000-0002-5283-5961>; SPIN: 4458-5608