

УДК 616-036.8-08-06 (075)

<http://doi.org/10.22328/2079-5343-2026-17-2-31-42>

ВОЗМОЖНОСТИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В КЛАССИФИКАЦИИ ПАТОЛОГИЙ ПОЗВОНОЧНИКА НА СОВРЕМЕННОМ ЭТАПЕ РАЗВИТИЯ: СИСТЕМАТИЧЕСКИЙ ОБЗОР

^{1,2}К. О. Васильев[✉], ¹В. Л. Лукинов[✉], ^{1,2}В. В. Рерих[✉]

¹Новосибирский научно-исследовательский институт травматологии и ортопедии имени Я. Л. Цивьяна, г. Новосибирск, Россия

²Новосибирский государственный медицинский университет, г. Новосибирск, Россия

ВВЕДЕНИЕ: Большой объем информации, в том числе растущая численность населения и количество исследований значительно повышает нагрузку на врача любой специальности, в частности на врача-рентгенолога. Цифровизация исследований позволяет облегчить процессы диагностики, ведь грамотное программное обеспечение помогает специалисту быстрее обнаружить патологический процесс, а значит быстрее начать столь необходимое лечение. Одной из наиболее быстро развивающихся и важных моделей программного обеспечения для этих целей являются нейросети.

ЦЕЛЬ: Определение возможностей нейросетей в вертебологии на современном этапе их развития в области такой функции нейросетей, как классификация.

МАТЕРИАЛЫ И МЕТОДЫ: При помощи протокола PRISMA был произведен поиск в базе данных Pubmed за период с января 2017 по 31 декабря 2023 г. при помощи ключевых слов.

РЕЗУЛЬТАТЫ: Для систематического обзора было отобрано 34 статьи, в которых описывалась такая функция нейросетей, как классификация.

ОБСУЖДЕНИЕ: По результатам анализа источников литературы сделаны выводы о полезности применения искусственного интеллекта на современном этапе развития в вертебологии в такой функции, как классификация.

ЗАКЛЮЧЕНИЕ: Для такой функции нейросети, как классификация, в отношении патологических изменений позвоночника не все так однозначно. В выявлении дегенеративных изменений хорошие результаты касаются в основном только центрального стеноза позвоночного канала, а результаты выявления стенозов боковых карманов и фораминальных стенозов неопределенные. Что касается переломов позвоночника, то здесь наметился абсолютный лидер — GoogleNet. За GoogleNet лидирует две сети — DCNN собственной разработки (Germann C. et al.) и комбинации многослойного перцептрона и методик 3D-радиомики (Chiari-Correia N.S. et al.). В задачи классификации опухолей позвоночника выделяется только одна сеть — ResNet 50, результаты же прочих архитектур значительно отстают и нуждаются в дальнейшей доработке.

КЛЮЧЕВЫЕ СЛОВА: искусственный интеллект, нейросети, вертебология, позвоночник, классификация

* Для корреспонденции: Васильев Константин Олегович, e-mail: vasiliev_ko@mail.ru

Для цитирования: Васильев К.О., Лукинов В.Л., Рерих В.В. Возможности искусственного интеллекта в классификации патологий позвоночника на современном этапе развития: систематический обзор // *Лучевая диагностика и терапия*. 2026. Т. 17, № 2. С. 31–42, doi: <http://doi.org/10.22328/2079-5343-2026-17-2-31-42>.

POSSIBILITIES OF ARTIFICIAL INTELLIGENCE IN CLASSIFICATION OF SPINAL PATHOLOGIES AT THE PRESENT STAGE OF DEVELOPMENT: A SYSTEMATIC REVIEW

^{1,2}Konstantin O. Vasilyev[✉], ¹Viktor L. Lukinov[✉], ^{1,2}Vitaly V. Rerikh[✉]

¹Novosibirsk Research Institute of Traumatology and Orthopedics named after Ya. L. Tsiyvan, Novosibirsk, Russia

²Novosibirsk State Medical University, Novosibirsk, Russia

INTRODUCTION: A large amount of information, including a growing population and the number of studies significantly increases the workload of a doctor of any specialty, including a radiologist. Digitalization of research makes it possible to facilitate diagnostic processes, because competent software helps a specialist to quickly detect a pathological process, and therefore — to start much-needed treatment faster. One of the most developing and important software models for these purposes is neural networks.

OBJECTIVE: To determine the capabilities of neural networks in vertebralology at the current stage of their development in the field of such a neural network function as classification.

MATERIALS AND METHODS: Using the PRISMA protocol, a search was performed in the Pubmed database for the period from January 2017 to December 31, 2023 using keywords.

RESULTS: For the systematic review, 34 articles were selected that described such a neural network function as classification.

DISCUSSION: Based on the analysis of literature sources, conclusions were drawn about the usefulness of using artificial intelligence at the current stage of development in vertebrology in such a function as classification.

CONCLUSION: The classification function of neural networks for pathological changes in the spine is not so clear-cut. Good results in detecting degenerative changes are primarily limited to central spinal stenosis, while the results for detecting lateral recess and foraminal stenosis are inconclusive. For spinal fractures, GoogleNet has emerged as the clear leader. Two networks follow GoogleNet: a proprietary DCNN (Germann C. et al.) and a combination of a multilayer perceptron and 3D radiomics techniques (Chiari-Correia N. S. et al.). Only one network, ResNet 50, excels in the classification of spinal tumors, while the results of other architectures lag significantly behind and require further refinement.

KEYWORDS: artificial intelligence, neural networks, vertebrology, spine, classification.

* **For correspondence:** Konstantin O. Vasiliev, e-mail: vasiliev_ko@mail.ru

For citation: Vasilyev K.O., Lukinov V.L., Rerikh V.V. Possibilities of artificial intelligence in classification of spinal pathologies at the present stage of development: a systematic review // *Diagnostic radiology and radiotherapy*. 2026. Vol. 17, No. 2. P. 31–42, <http://doi.org/10.22328/2079-5343-2026-17-2-31-42>.

Введение. Большой объем информации, в том числе растущая численность населения и количество исследований значительно повышает нагрузку на врача любой специальности, в частности на врача-рентгенолога. Цифровизация исследований позволяет облегчить процессы диагностики, ведь грамотное программное обеспечение помогает специалисту быстрее обнаружить патологический процесс, а значит — быстрее начать столь необходимое лечение [1]. Также искусственный интеллект помогает снизить количество ошибок при анализе большого количества данных, стандартизировать протоколы исследований, а еще интегрироваться с системой PACS и телемедициной [2].

Нейросетевые технологии активно внедряются в лучевую диагностику, демонстрируя различную степень успешности в разных медицинских специализациях: в неврологии и нейрохирургии [3], онкологии [4], кардиологии [5], пульмонологии [6].

Несмотря на широкое применение нейросетей, вертебрология является той частью медицины, где применение высокого интеллекта не получило такого широкого распространения, как в других областях. Основными причинами являются недостаток информации ввиду сложного анатомического строения позвоночника, трудности дифференциальной диагностики некоторых патологий, дефицита базы данных, разнообразия протоколов визуализации позвоночника, недостаток цифровой грамотности, а также ограниченное количество врачей-вертебрологов [7].

Цель. Определить возможности нейросетей в вертебрологии на современном этапе их развития в области такой функции нейросетей, как классификация.

Материалы и методы. Выполнен систематический обзор источников литературы по методу PRISMA-ScR [8] за период с января 2017 по 31 декабря 2023 г. при помощи базы данных Pubmed.

Ключевые слова, по которым производился поиск в аннотации или заголовке: («deep learning» OR «neural network» OR «artificial Intelligence») AND («spine») AND («classification»). Виды лучевых методов исследования, при помощи которых проводилось обучение в описываемых в статьях: рентгенография, компьютерная томография и магнитно-резонансная томография. Ключевые слова были выбраны в связи с их вероятностью наличия в заголовке интересующих статей. После поиска по ключевым словам литературные источники были детально изучены.

Результаты. По заданным ключевым словам первоначально был отобран 201 источник литературы. Публикаций после удаления дубликатов — 103. При скрининге были исключены статьи в количестве 48 по следующим критериям: аннотации без полнотекстных статей. Далее полнотекстные статьи были оценены на приемлемость, с исключением источников, попадающих под следующие критерии: относящиеся к искусственному интеллекту, но без использования нейросетей; без использования лучевых методов диагностики; не содержащие данные о классификации; не содержащие в классификации упоминаний о следующих нозологиях: дегенеративные изменения позвоночника, травмы позвоночника, опухоли позвоночника. Итоговое количество статей, включенных в обзор — 34. Среди них 1 статья I уровня доказательности (систематический обзор: [9], остальные 33 — III и IV уровня доказательности. Этапы отбора представлены на рис. 1. Итоговое количество статей, относящихся к дегенеративным изменениям — 13, к переломам — 15, к опухолевой патологии — 6. Распределение источников литературы по нозологиям представлено на рис. 2.

Обсуждение. Классификация. Задачей классификации является определить принадлежность выявленных изменений к какому-либо классу [10].

В отношении применения нейросетей, например, к магнитно-резонансной томографии позвоночника, таким примером является бинарная классификация стеноза позвоночного канала: стеноз присутствует или стеноз отсутствует [11]. В данной ситуации используется только два класса (наличие или отсутствие), но их количество, в зависимости от поставленной задачи, может увеличиваться.

именно глубокое обучение. Методов машинного поверхностного обучения достаточно много. К ним относятся: линейный дискриминантный анализ, логистическая регрессия, наивный байсовский классификатор, метод опорных векторов, метод k-ближайших соседей, решающие деревья, в том числе случайный лес и метод градиентного бустинга [13]. К методам глубокого обучения относятся нейросети.



Рис. 1. Этапы поиска и отбора источников литературы для систематического обзора
Fig. 1. Stages of searching and selecting literature sources for a systematic review




Рис. 2. Распределение источников литературы по нозологиям
Fig. 2. Distribution of literature sources by nosology

Существует множество методов классификации, но все они основаны на принципах машинного обучения. Где-то используются методы поверхностного обучения [12], но в большинстве случаев используется

Основные разделы, которые будут описаны в рамках классификации: дегенеративные изменения, переломы и опухоли. Источники литературы и анализируемые параметры представлены в таблице.

Дегенеративные изменения. Среди всего многообразия дегенеративной патологии позвоночника нейросети используется преимущественно для оценки дегенеративного стеноза позвоночного канала [14–21], но также встречаются работы по оценке дегенеративных листезов [16], грыж и протрузий [15, 17], дегенеративных изменений структуры межпозвонкового диска по Pfirrmann, снижения высоты межпозвонковых дисков, дефектов замыкательных пластинок, изменений костного мозга тел позвонков по Modic [16], остеофитов, фораминального стеноза [22]. В 12 из 13 статей использовалась модальность МРТ, в 1 из 13 упоминалась рентгенография. В 6 из 3 работ использовались комбинации нейросетей, причем в одном случае комбинация сразу из четырех нейросетей [22]. В оставшихся 5 из 13 работ использовалась одна нейросеть. Среди архитектур в 3 из 13 работ использовалась комбинация U-Net с другими сетями (где U-Net отвечает за сегментацию, а вторая сеть непосредственно за классификацию), в 6 из 13 работ Faster R-CNN и ее модификации, в 1 из 13 —

Таблица
Table

Литературные источники обнаружения и их характеристики
Literary sources of detection and their characteristics

Вид патологии	№	Год	Авторы	Используемая сеть	Вид лучевого исследования	Объем базы данных (кол-во исследований по модальности)
	2	3	4	5	6	7
Генеративные изменения	1	2017	A. Jamaludin et al. [16]	CNN: SpineNet	MPT	2009
	2	2018	Z. Han et al. [19]	Recurrent Generative Adversarial Network (RGAN)	MPT	253
	3	2018	J. T. Lu et al. [17]	U-Net+ a spine-curve fitting method +CNN	MPT	4075; — 2853 для обучения; — 611 для валидации; — 611 для внутреннего тестирования
	4	2020	Lewandrowski et al. [21]	CNN	MPT	3625; — 3560 для обучения и валидации; — 65 для внутреннего тестирования
	5	2020	D. Won et al. [18]	Faster R-CNN + VGG network	MPT	542
	6	2021	J. T. P. D. Hallinan et al. [14]	Faster R-CNN (Resnet 101) + CNN для классификации	MPT	446;
	7	2021	N. C. Lehen et al. [15]	Модифицированная U-Net-ResNet50	MPT	1646;
	8	2021	Z. Merali et al. [20]	Faster R-CNN; ResNet-50	MPT	289;
	9	2022	K. T. Gao et al. [23]	V-Net+nearest-neighbor algorithm	MPT	75
	10	2023	M. S. Ghauri et al. [22]	Комбинация 4-х нейросетей: TensorFlow, EfficientNet, ResNet-50, and PyTorch	Rg	967; — 773 для обучения; — 97 для валидации тестирования
Переломы	11	2023	W. Zhang et al. [24]	Faster-N CNN; ResNeXt101	MPT	1115
	12	2023	U. U. Bharadwaj et al. [25]	Big Transfer (BiT) ResNet-50 CNN	MPT	200; — 150 для обучения; — 20 для валидации; — 30 для тестирования
	13	2023	W. Liawrungueang et al. [26]	CNN + YOLOv4	MPT	1000; — 800 для обучения — 200 для внутреннего тестирования
	1	2017	A. Bar et al. [31]	CNN (VGG Net)+RNN (LSTM-model).	KT	1643
	2	2018	N. Tomita [33]	CNN (ResNet34)+ LSTM	KT	1432; — 1168 для обучения; — 135 для валидации; — 129 для внутреннего тестирования
	3	2019	S. Derkatch et al. [34]	Inception-ResNet-V2+DenseNet.	Rg	12 742; — 7646 для обучения; — 1274 для валидации; — 3822 для внутреннего тестирования
	4	2021	J. E. Small et al [32]	CNN	KT	665
	5	2022	A. Boonrod et al. [37]	CNN — YOLO	Rg	269; — 229 для обучения; — 40 для внутреннего тестирования

Проложение таблицы

1	2	3	4	5	6	7
Опухоли	6	2022	X. G. Chen et al. [38]	CNN: Faster RCNN	КТ	935: — 815 для обучения; — 120 для валидации; — 198 для внутреннего тестирования
	7	2022	S. A. Doerr et al. [30]	R-CNN + Faster R-CNN	КТ	111 исследований, разбитых на отдельные изображения: — 5000 изображений для обучения; — 500 для тестирования (получены путем аугментации)
	8	2022	Q. Dong et al. [27]	CNN: GoogleNet.	Rg	15 524: — 11 876 для обучения; — 1319 для валидации; — 2329 для внутреннего тестирования
	9	2022	L.R. Yeh et al. [39]	CNN: ResNet50	MPT	190 (кросс-валидация)
	10	2022	C. Germann et al. [28]	DCNN	MPT	1056: — 834 для обучения; — 104 для валидации и внутреннего тестирования
	11	2023	J. Zhang et al. [35]	CNN: U-GCN	КТ	1217
	12	2023	Q. Dong et al. [36]	Модель, основанная на ансамблевом усреднении (ensemble algorithms): GoogleNet (Inception v1)+ + Inception-ResNet-v2+ EfficientNet-B	Rg	1896: — 847 для обучения — 307 для валидации — 742 для тестирования
	13	2023	B. Liu et al. [40]	Two-Stream Compare and Contrast Network (TSCCN) на основе CNN ResNet-18	MPT	245
	14	2023	N. S. Chiari-Correia et al. [29]	Многослойный перцептрон multilayer perceptron (MLP) с использованием методов 3D-радиомки	MPT	91
	15	2023	F. Xu et al. [41]	CNN: ResNet-18	Rg	1904; — 873 для обучения; — 292 для внутреннего тестирования; — 378 для внешней валидации; — 57 для проспективного тестирования
	1	2019	N. Lang et al. [42]	CNN+convolutional long short term memory network (CLSTM)	MPT	61
	2	2022	K. Chen et al. [43]	CNN (Multi-view Attention-Guided Network (MAGN)	MPT	217
	3	2022	J.T.P.D. Hallinan et al. [44]	CNN (ResNet 50)	MPT	247: 177 для обучения и валидации; 38 для внутреннего тестирования; 32 для внешнего тестирования
	4	2022	X. Xiong et al. [45]	CNN	MPT	107: — 75 для обучения; — 32 для валидации и внутреннего тестирования
	5	2023	J. T. Hallinan et al. [46]	ResNeXt50	КТ	463: 354 для обучения и валидации; 66 для внутреннего тестирования; 43 для внешнего тестирования
6	2023		S. Ito et al. [47]	YOLOv4	MPT	200

Продолжение таблицы						
Вид патологии	Точность	Средняя классовая точность (average class accuracy)	Чувствительность	Специфичность	AUR ROC	Отношение рисков (hazard ratio)
I	8	9	10	11	12	13
Генеративные изменения	—	Для изменения структуры м/п дисков, снижения высоты м/п дисков, спондилолистеза, спинального стеноза, дефектов замыкательных пластинок, изменения тел позвонков по Модик: 70,1 %, 75,4 %, 95,4 %, 94,7 %, 86,7 %, 88,3 %, 89,7 %, 89,1 % соответственно	—	—	—	—
	96,2 %	—	86,0 %	89,1 %	0,983 (95 % ДИ, 0,971–0,992) для стеноза позвоночного канала и 0,961 (95 % ДИ, 0,955–0,967) для фораминального стеноза	—
	—	70,6 % для позвоночного канала и 67,1 % для межпозвонковых отверстий	—	—	0,808	0,355–0,738
	77,5–83,0 %	—	73,3 %	88,40 %	—	—
	—	—	—	Центральный канал 97,0 % (95 % ДИ, 96,0–97,8), боковой карман 96,7 % (95 % ДИ, 95,0–97,9), фораминальное отверстие 91,2 % (95 % ДИ, 85,4–95,3)	—	0,92–0,98
Внутреннее тестирование	Грыжа диска 86,82 % (95 % ДИ, 0,84–0,89), спинальный стеноз 98,09 % (95 % ДИ, 0,97–0,99), выбухание диска 75,56 % (95 % ДИ, 0,73–0,78), компрессия корешков 90,54 % (95 % ДИ, 0,89–0,92), спондилолистез 87,61 % (0,85–0,89)	—	88,0 %	89 %	0,94	—
	89 %	—	67 %	89 %	0,88	—
	Внутреннее тестирование 87,70 % (95 % ДИ, 86,59–88,86 %), внешнее тестирование 74,23 % (95 % ДИ, 74,23 % (71,83–76,75 %))	—	94,12 %	96,98 %	Внутреннее тестирование 0,87 (95 % ДИ, 0,87–0,88), внешнее тестирование 0,79 (95 % ДИ, 0,76–0,81)	—
95 %						0,80 (95 % ДИ 0,76–0,82)

Продолжение таблицы

I	8	9	10	11	12	13	14
Переломы	89,10% 89,2% (95% ДИ 82,5–93,9)	—	83,90% 85,2% (95% ДИ 78,0–90,9) 87,4% (95% ДИ 86,3–88,5) 76% (95% ДИ 68,0–83,0) 80% 88,4% (95% ДИ 40,80–84,60)	93,8% 95,8% (95% ДИ 91,2–98,7) 88,4% (95% ДИ 87,4–89,4) 97% (95% ДИ 95,0–98,0) 72% (95% ДИ 68,30–98,80)		1,7 (95% ДИ 1,3–2,2)	0,77 (95% ДИ 0,74–0,79)
	86,40% Бинарная классификация — наличие или отсутствие перелома точность 95,1% Точность морфологии повреждения 86,3% Точность в отношении классификации «нет повреждения заднего связочного комплекса» и «подозрение на повреждение заднего связочного комплекса» 86,8%	—	—				0,85
	99,50% (95% ДИ 99,4–99,6)	—	—		0,99 (95% ДИ 0,98–0,99)		
	96,2% (95% ДИ 0,948–0,973)	—	94,1% (95% ДИ 0,903–0,968)	96,9% (95% ДИ 0,954–0,980)	0,945		
	—	—	54,5% (95% ДИ 47,4–61,4)	99,7% (95% ДИ 99,4–99,9)	0,948 (95% ДИ 0,926–0,968)		
	96,2% 93,3%	—	93,0% 93,3%	99,2% 93,3%	0,992 0,97		
	85,0% для внутреннего тестирования; 82,9% для проспективного тестирования	—	При проспективном тестировании 65,8% для острого перелома; 87,1% для хронического перелома; 60,0% для патологического перелома	88,9% для острого перелома; 74,4% для хронического перелома; 94,2% для патологического перелома	0,780 для острого перелома (95% ДИ 0,777–0,781), 0,836 для хронического (95% ДИ 0,834–0,838), 0,796 для патологического (95% ДИ 0,793–0,800)		
	Первой нейросети 71%, второй нейросети 81% 81,0%	—	Первой нейросети 60%, второй нейросети 75% —	Первой нейросети 76%, второй нейросети 83% —	0,78		
	—	—	97,6% для внутреннего тестирования (95% ДИ 91,7–99,7), 89,9% для внешнего (95% ДИ 84,4–94,0)	93,6% для внутреннего тестирования (95% ДИ 91,9–95,0), 98,1% для внешнего (95% ДИ 96,7–99,1)			0,92 внутреннего тестирования (95% ДИ 0,91–0,94) 0,94 для внешнего 0,94 (95% ДИ 0,92–0,96)
	81,5%	—	87,9%	79,0%			
Опухоли							

Окончание таблицы					
1	8	9	10	11	12
			Для любой степени компрес- сии внутреннее тестирова- ние 87,13 (95% ДИ 84,28–89,63), внешнее тестирование 96,45 (95% ДИ 93,58–98,29); для вы- сокой степени компрессии внутреннее тестирование 93,38 (95% ДИ 89,85–95,97), внешнее тестирование 96,61 (95% ДИ 92,77–98,75)	Для любой степени компрес- сии внутреннее тестирова- ние 95,43 (95% ДИ 94,58–96,19), внешнее тес- тирование 93,26 (95% ДИ 91,74–94,57); для высокой степени компрессии внут- реннее тестирование 95,47 (95% ДИ 94,67–96,18), внешнее тестирование 96,02 (95% ДИ 94,85–96,99)	Для любой степени компрес- сии внутреннее тестирова- ние 0,913 (95% ДИ 0,899–0,926), внешнее тестирование 0,949 (95% ДИ 0,936–0,961); для вы- сокой степени компрессии внутреннее тестирование 0,944 (95% ДИ 0,929–0,959), внешнее тестирование 0,963 (95% ДИ 0,949–0,977)
	84,1%				13
					14
					Внутреннее тестирование 0,872 (95% ДИ 0,859–0,886), внешнее тестирование 0,844 (95% ДИ 0,822–0,865)

SpineNet, в 1 из 13 — Recurrent Generative Adversarial Network, в 2 из 13 — CNN собственной разработки.

Основными метриками качества, используемыми в литературе при оценке дегенеративных изменений, являются: диагностическая точность, средняя классовая точность, чувствительность и специфичность. В трех работах также встречается площадь под ROC-кривой (AUC ROC) [20, 21] и в трех работах — каппа Gwet [14, 16, 21].

Имеются сложности для прямого сравнения эффективности описанных нейросетей в связи с непостоянством наборов метрик в различных исследованиях. Так, точность классификации в отношении стеноза позвоночного канала в двух из трех работ была на достаточно высоком уровне — 96,2% (Han Z. et al. [19]) и 98,09% (Lehnen N.C. et al. [15]). Такой параметр, как средняя классовая точность, представленный в двух работах, в отношении стеноза позвоночного канала достигает высоких показателей только у одного из авторов — 95,4% [16] с нейросетью SpineNet, в то время как у второго автора показатель данного параметра оказывается на низком уровне — 70,6% [17].

Чувствительность и специфичность описываемых сетей в классификации патологии позвоночного канала наибольшей оказалась у одного из авторов — 90,9% и 98,5% соответственно [14] с комбинации сетей Faster R-CNN (Resnet 101) + CNN. От него незначительно отстают Z. Merali и соавт. [20] (88,0% и 89,9%), Z. Han и соавт. [19] (86,00% и 89,10%) соответственно с сетями ResNet-50 и Recurrent Generative Adversarial Network.

При сравнении возможностей искусственного интеллекта и врачей [14–16, 18, 20, 23–26] практически всегда возможности нейросетей находятся на уровне врача-эксперта. Лишь в одном из исследований [15] показатели точности нейросети приближались к показателям опытного врача, но проигрывали в выявлении малозначимой патологии позвоночного канала.

Общие выводы касательно применения искусственного интеллекта в классификации дегенеративных изменений позвоночника следующие: в текущем виде алгоритмы ИИ могут использоваться для автоматического анализа и поиска патологических изменений, однако они не могут полностью заменить врача и требуют проверки находок экспертом для отсева ложноположительных результатов, особенно в случае незначительных выбуханий диска или листезов. Искусственный интеллект может выступать в роли «второго мнения», брать на себя рутинную работу по первичному анализу и сортировке снимков, что позволяет врачу сконцентрироваться на более сложных случаях.

Переломы. Возможности нейросетей в выявлении переломов позвоночника набирают популярность за исследуемые шесть лет. Для их классификации используются как комбинации нейросетей в 8 из 16

источников, так и одна нейросеть в остальных 7 из 16. В указанных работах используется большое количество архитектур: в 5 из 16 источников — это ResNet, в 2 из 16 — Faster RCNN. Все остальные уникальные архитектуры нейросетей представлены в единичном экземпляре. Лучевые модальности, используемые в литературе, представлены в следующем соотношении: рентгенография — 5 из 15, КТ — 7 из 15, МРТ — 3 из 15.

В качестве сравниваемых метрик в 13 из 15 работ используется диагностическая точность, в 10 из 15 — чувствительность и специфичность. Абсолютным лидером по точности является GoogleNet (Dong Q. [27]) с показателем 99,5%, при этом учитывается, что в качестве лучевого метода исследования использовалась классическая рентгенография. Однако, несмотря на высокую точность, показатели чувствительности оказались умеренными, что приемлемо для скринингового исследования, но часть переломов при этом все равно может быть пропущена. За GoogleNet лидируют две сети — DCNN собственной разработки (Germann C. et al. [28]) и комбинации многослойного перцептрона и методик 3D-радиомики (Chiari-Correia N.S. et al. [29]) с показателями точности в 96,2% и 93,3% соответственно. В обеих работах в качестве метода лучевой диагностики использовалась МРТ.

Возможности бинарной классификации (наличие или отсутствие перелома) всегда оказываются выше, чем при мультиклассовой (определение типа перелома) классификации. В качестве примера можно привести работу S. A. Doege и соавт. [30] с комбинацией нейросетей R-CNN + Faster R-CNN. Точность выявления перелома составляет 95,1%, но только при бинарной классификации, точность же выявления морфологии повреждения составляет 86,3%.

Существует проблема при классификации остеопоротических переломов [31–36]. В то время как нейросеть успешно справляется с обнаружением остеопоротических переломов, определение их давности — остроты или консолидации — остается для неё сложной задачей. Между тем, именно эта информация имеет критическое значение для клинициста.

При сравнении возможностей искусственного интеллекта и врачей-рентгенологов [28, 37–41] в большинстве случаев возможности нейросетей находятся на уровне опытного врача, но в одной из статей (Liu B. et al. [40]) нейросеть TSCCN, написанная на основе ResNet-18, показала объективно лучшие результаты в отношении точности и специфичности.

В целом, выводы по использованию искусственного интеллекта при переломах позвоночника следующие: авторы рекомендуют применять нейросети для классификации переломов в качестве помощника врача-рентгенолога, а именно для снижения нагрузки на врачей, проведения скрининга, приоритизации списков исследования.

Опухолевое поражение. Литературных источников по применению нейросетей для классификации

опухолей позвоночника не так много. Во всех представленных случаях [42–47] используются различные архитектуры. В $\frac{1}{6}$ работ используется комбинация нейросетей (CNN+convolutional long short term memory network (CLSTM)) [42], в остальных $\frac{5}{6}$ — одна нейросеть. В качестве сравниваемых метрик качества в $\frac{2}{6}$ статей используется диагностическая точность и в $\frac{1}{6}$ — чувствительность и специфичность, в $\frac{3}{6}$ — диагностическая точность, чувствительность и специфичность. Среди модальностей преобладает МРТ — $\frac{5}{6}$; в $\frac{1}{6}$ части работ используется КТ.

В двух статьях, выполненных одной исследовательской группой (Hallinan J.T.P.D. et al. [44, 46]) для двух модальностей (МРТ и КТ) с нейросетью ResNet 50, показатели чувствительности и специфичности были на довольно высоком уровне: 97,6% и 98,1% для МРТ и 96,45% и 93,26% для КТ. При сравнении с врачом нейросеть на МРТ и КТ показала результаты на уровне опытного врача и даже превосходила некоторых специалистов с небольшим опытом. Таким образом, основной клинический тезис двух статей заключается в том, что такая модель искусственного интеллекта может служить системой автоматического оповещения, которая повышает выявляемость опухолевого стеноза позвоночного канала на ранних этапах. В целом, описанная архитектура нейросети обладает высоким потенциалом для дальнейшего исследования и возможного применения в работе врача.

Результаты оставшихся четырех работ имеют довольно низкие метрики качества и не могут на данный момент рассматриваться в качестве применения в клинической практике.

Заключение. На основании полученных данных для такой функции нейросети, как классификация, в отношении патологических изменений позвоночника не все однозначно. В выявлении дегенеративных изменений хорошие результаты касаются в основном только центрального стеноза позвоночного канала [14–16, 19], а результаты выявления стенозов боковых карманов и фораминальных стенозов неопределенные. Что касается переломов позвоночника, то здесь наметился абсолютный лидер — GoogleNet [27]. За GoogleNet лидирует две сети — DCNN собственной разработки (Germann C. et al. [28]) и комбинации многослойного перцептрона и методик 3D-радиомики (Chiari-Correia N.S. et al. [29]). В задачи классификации опухолей позвоночника выделяется только одна сеть — ResNet 50 [44, 46], результаты же прочих архитектур значительно отстают и нуждаются в дальнейшей доработке.

Нейросети играют важную роль в классификации некоторой патологии позвоночника, позволяя автоматически анализировать медицинские изображения, такие как рентгенограммы, компьютерные и магнитно-резонансные томограммы.

По нашему мнению, при направленном развитии нейросетей вероятность их использования для классифицирования вертебральной патологии будет

выше, и потому это будет большим подспорьем в работе врача-рентгенолога в скрининге, а в дальнейшем и в более точной верификации морфологических изменений с количественной их оценкой.

Сведения об авторах:

Васильев Константин Олегович — врач-рентгенолог отделения лучевой диагностики федерального государственного бюджетного учреждения «Новосибирский научно-исследовательский институт травматологии и ортопедии имени Я.Л. Цивьяна» Министерства здравоохранения Российской Федерации; 630091, Новосибирск, ул. Фрунзе, д. 17; ассистент кафедры лучевой диагностики стоматологического факультета федерального государственного бюджетного образования учреждения высшего образования «Новосибирский государственный медицинский университет»; 630091, Новосибирск, ул. Красный проспект, д. 52; e-mail: vasiliev_ko@mail.ru; ORCID 0009-0006-2726-1392;

Перих Виктор Викторович — доктор медицинских наук, врач травматолог-ортопед, начальник научно-исследовательского отделения патологии позвоночника федерального государственного бюджетного учреждения «Новосибирский научно-исследовательский институт травматологии и ортопедии имени Я.Л. Цивьяна» Министерства здравоохранения Российской Федерации; 630091, Новосибирск, ул. Фрунзе, д. 17; профессор кафедры травматологии и ортопедии федерального государственного бюджетного образования учреждения высшего образования «Новосибирский государственный медицинский университет»; 630091, Новосибирск, ул. Красный проспект, д. 52; e-mail: rvv_nsk@mail.ru; ORCID 0000-0001-8545-0024;

Лукинов Виталий Леонидович — кандидат физико-математических наук, ведущий научный сотрудник научно-исследовательского отдела проектной и инновационной деятельности федерального государственного бюджетного учреждения «Новосибирский научно-исследовательский институт травматологии и ортопедии имени Я.Л. Цивьяна» Министерства здравоохранения Российской Федерации; 630091, Новосибирск, ул. Фрунзе, д. 17; e-mail: vitaliy.lukinov@sscc.ru; ORCID 0000-0002-3411-508X.

Information about authors:

Konstantin O. Vasiliev — radiologist of the department of radiation diagnostics of the federal state budgetary institution «Novosibirsk Research Institute of Traumatology and Orthopedics named after Ya. L. Tsivyan» Ministry of Health of Russia; 630091, Novosibirsk, st. Frunze, 17; Assistant at the Department of Radiation Diagnostics of the Dental Faculty of the Federal State Budgetary Education Institution of Higher Education «Novosibirsk State Medical University», 630091, Novosibirsk, st. Krasny Prospekt, 52; e-mail: vasiliev_ko@mail.ru; ORCID 0009-0006-2726-1392;

Viktor V. Rerikh — Dr. of Sci. (Med.), traumatologist-orthopedist, head of the research department of spine pathology of the federal state budgetary institution Novosibirsk Research Institute of Traumatology and Orthopedics named after Ya. L. Tsivyan» Ministry of Health of Russia, 630091, Novosibirsk, st. Frunze, 17; Professor of the Department of Traumatology and Orthopedics of the Federal State Budgetary Education of the Institution of Higher Education «Novosibirsk State Medical University»; e-mail: rvv_nsk@mail.ru; ORCID 0000-0001-8545-0024;

Vitaliy L. Lukinov — Cand. of Sci. (Phys. and Math.), leading researcher of the research department of project and innovation activities of the federal state budgetary institution Novosibirsk Research Institute of Traumatology and Orthopedics named after Ya. L. Tsivyan» Ministry of Health of Russia, 630091, Novosibirsk, st. Frunze, 17; Professor of the Department of Traumatology and Orthopedics of the Federal State Budgetary Education of the Institution of Higher Education «Novosibirsk State Medical University»; e-mail: vitaliy.lukinov@sscc.ru; ORCID 0000-0002-3411-508X.

Вклад авторов: Все авторы подтверждают соответствие своего авторства, согласно международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией). Наибольший вклад распределен следующим образом: концепция и план исследования — *К. О. Васильев, В. В. Перих*, сбор и обработка данных — *К. О. Васильев, Л. В. Лукинов*, подготовка рукописи — *К. О. Васильев, В. В. Перих*.

Authors' contributions: All authors confirm the compliance of their authorship, according to the international criteria of the ICMJE (all authors made a significant contribution to the development of the concept, conduct of the research and preparation of the article, read and approved the final version before publication). Special contribution: concept and design of the study — *KOV, VVR*, data collection and processing — *KOV, VLL*, preparation of the manuscript — *KOV, VVR*.

Потенциальный конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Disclosure: the authors declare that they have no competing interests.

Поступила/Received: 16.10.2025

Принята к печати/Accepted: 29.05.2026

Опубликована/Published: 29.06.2026

ЛИТЕРАТУРА / REFERENCES

1. Jamshidi M., Rajabian M., Avery M.B. et al. A novel self-expanding primarily bioabsorbable braided flow-diverting stent for aneurysms: initial safety results // *Journal of neurointerventional surgery*. 2020. Vol. 12, No. 7. P. 700–705. doi: 10.1136/neurintsurg-2019-015555.
2. Swart N., Maroni R., Muldrew B. et al. Economic evaluation of Cytosponge®-trefol factor 3 for Barrett esophagus: A cost-utility analysis of randomised controlled trial data // *EClinicalMedicine*. 2021. Vol. 37. doi: 10.1016/j.eclim.2021.100969.
3. Albers G.W., Marks M.P., Kemp S. et al. Thrombectomy for Stroke at 6 to 16 Hours with Selection by Perfusion Imaging: Albers G.W., Marks M.P., Kemp S. et al. // *N. Engl. J. Med.* 2018. Vol. 378. P. 708–718 // *Journal of Emergency Medicine*. 2018. Vol. 55, No. 1. P. 151. doi: 10.1056/NEJMoa1713973
4. Thong L.T., Chou H.S., Chew H.S.J., Lau Y. Diagnostic test accuracy of artificial intelligence-based imaging for lung cancer screening: A systematic review and meta-analysis // *Lung Cancer*. 2023. Vol. 176. P. 4–13. doi: 10.1016/j.lungcan.2022.12.002.
5. Gautam N., Saluja P., Malkawi A. et al. Current and future applications of artificial intelligence in coronary artery disease // *Healthcare. MDPI*. 2022. Vol. 10, No. 2. P. 232. doi: 10.3390/healthcare10020232.

6. Roberts M., Driggs D., Thorpe M. et al. Common pitfalls and recommendations for using machine learning to detect and prognosticate for COVID-19 using chest radiographs and CT scans // *Nature Machine Intelligence*. 2021. Vol. 3, No. 3. P. 199–217. doi: 10.1038/s42256-021-00307-0.
7. Wang Z., Liu X., Hu X. et al. Age-related changes in cervical sagittal alignment: based on 625 Chinese asymptomatic subjects // *European Spine Journal*. 2023. Vol. 32, No. 5. P. 1607–1615. doi: 10.1007/s00586-023-07632-5.
8. Tricco A.C., Lillie E., Zarin W., O'Brien K.K., Colquhoun H., Levac. PRISMA extension for scoping reviews (PRISMA-ScR): checklist and explanation // *Annals of internal medicine*. 2018. Vol. 169, No. 7. P. 467–473. doi: 10.7326/M18-0850.
9. Liawrungrueang W., Kim P., Kotheeranurak V., Jitpakdee K., Sarasombath. Automatic detection, classification, and grading of lumbar intervertebral disc degeneration using an artificial neural network model // *Diagnostics*. 2023. Vol. 13, No. 4. P. 663. doi: 10.3390/diagnostics13040663.
10. Mastouri R., Khelifa N., Neji H., Hantous-Zannad S. A bilinear convolutional neural network for lung nodules classification on CT images // *International Journal of Computer Assisted Radiology and Surgery*. 2021. Vol. 16. P. 91–101. doi: 10.1007/s11548-020-02283-z.
11. Merali Z., Wang J.Z., Badhiwala J.H. et al. A deep learning model for detection of cervical spinal cord compression in MRI scans // *Scientific reports*. 2021. Vol. 11, No. 1. P. 1–11. doi: 10.1038/s41598-021-89848-3.
12. Kumar K.K., Gopal T.V. A novel approach to self order feature reweighting in CBIR to reduce semantic gap using Relevance Feedback // *2014 International Conference on Circuits, Power and Computing Technologies [ICCPCT-2014]*. 2014. P. 1437–1442. doi: 10.1109/ICCPCT.2014.7054919.
13. Абдуллина К.М., Спивак А.И. Применение нейронной сети архитектуры U-Net для задачи локализации нарушений целостности цифровых изображений // *Научно-технический вестник информационных технологий, механики и оптики*. 2020. Т. 20, № 3. С. 425–431. [Abdullina K.M., Spivak A.I. Application of the U-Net neural network architecture for the problem of localizing integrity violations of digital images. *Scientific and Technical Bulletin of Information Technologies, Mechanics and Optics*, 2020, Vol. 20, No. 3, pp. 425–431 (In Russ.)]. doi: 10.17586/2226-1494-2020-20-3-425-431.
14. Hallinan J.T.P.D., Zhu L., Yang K. et al. Deep learning model for automated detection and classification of central canal, lateral recess, and neural foraminal stenosis at lumbar spine MRI // *Radiology*. 2021. Vol. 300, No. 1. P. 130–138. doi: 10.1148/radiol.2021204289.
15. Lehn N.C., Haase R., Faber J. et al. Detection of degenerative changes on MR images of the lumbar spine with a convolutional neural network: a feasibility study // *Diagnostics*. 2021. Vol. 11, No. 5. P. 902. doi: 10.3390/diagnostics11050902.
16. Jamaludin A., Lootus M., Kadir T. et al. ISSLS prize in bioengineering science 2017: Automation of reading of radiological features from magnetic resonance images (MRIs) of the lumbar spine without human intervention is comparable with an expert radiologist // *European spine journal*. 2017. Vol. 26, No. 5. P. 1374–1383. doi: 10.1007/s00586-017-4956-3.
17. Lu J. T., Pedemonte S., Bizzo B. et al. Deep Spine: Automated lumbar vertebral segmentation, disc-level designation, and spinal stenosis grading using deep learning // *Machine Learning for Healthcare Conference // PMLR*. 2018. P. 403–419. doi: 10.48550/arXiv.1807.10215.
18. Won D., Lee H.J., Lee S.J., Park S.H. Spinal stenosis grading in magnetic resonance imaging using deep convolutional neural networks // *Spine*. 2020. Vol. 45, No. 12. P. 804–812. doi: 10.1097/BRS.0000000000003377.
19. Han Z., Wei B., Leung S., Chung J., Li S. Towards automatic report generation in spine radiology using weakly supervised framework // *Medical Image Computing and Computer Assisted Intervention – MICCAI*. 2018: 21st International Conference, Granada, Spain, September 16–20, 2018, Proceedings, Part IV 11. Springer International Publishing, 2018. P. 185–193. doi: 10.1007/978-3-030-00937-3_22.
20. Merali Z., Wang J.Z., Badhiwala J.H. et al. A deep learning model for detection of cervical spinal cord compression in MRI scans // *Scientific reports*. 2021. Vol. 11, No. 1. P. 1–11. doi: 10.1038/s41598-021-89848-3.
21. Lewandrowski K.U., Muraliedharan N., Eddy S.A. et al. Feasibility of deep learning algorithms for reporting in routine spine magnetic resonance imaging // *International Journal of Spine Surgery*. 2020. Vol. 14, No. s3. P. S86–S97. doi: 10.14444/7131.
22. Ghauri M.S., Reddy A.J., Tak N. et al. Utilizing deep learning for X-ray imaging: detecting and classifying degenerative spinal conditions // *Cureus*. 2023. Vol. 15, No. 7. doi: 10.7759/cureus.41582.
23. Gao K. T., Tibrewala R., Hess M., Bharadwaj U.U., Inamdar G. et al. Automatic detection and voxel-wise mapping of lumbar spine Modic changes with deep learning // *JOR spine*. 2022. Vol. 5, No. 2. P. e1204. doi: 10.1002/jsp2.1204.
24. Zhang W., Chen Z., Su Z. et al. Deep learning-based detection and classification of lumbar disc herniation on magnetic resonance images // *JOR spine*. 2023. Vol. 6, No. 3. P. e1276. doi: 10.1002/jsp2.1276.
25. Bharadwaj U.U., Christine M., Li S. et al. Deep learning for automated, interpretable classification of lumbar spinal stenosis and facet arthropathy from axial MRI // *European radiology*. 2023. Vol. 33, No. 5. P. 3435–3443. doi: 10.1007/s00330-023-09483-6.
26. Liawrungrueang W., Kim P., Kotheeranurak V., Jitpakdee K., Sarasombath P. Automatic detection, classification, and grading of lumbar intervertebral disc degeneration using an artificial neural network model // *Diagnostics*. 2023. Vol. 13, No. 4. P. 663. doi: 10.3390/diagnostics13040663.
27. Dong Q. Deep Learning Classification of Spinal Osteoporotic Compression Fractures on Radiographs using an Adaptation of the Genant Semiquantitative Criteria // *Academic radiology*. 2022. Vol. 29, No. 12. P. 1819–1832. doi: 10.1016/j.acra.2022.02.020.
28. Germann C., Meyer A. N., Staib M., Sutter R., Fritz B. Performance of a deep convolutional neural network for MRI-based vertebral body measurements and insufficiency fracture detection // *European Radiology*. 2023. Vol. 33, No. 5. P. 3188–3199. doi: 10.1007/s00330-022-09354-6.
29. Chiari-Correia N.S., Nogueira-Barbosa M.H., Chiari-Correia R.D., Azevedo-Marques P.M. A 3D radiomics-based artificial neural network model for benign versus malignant vertebral compression fracture classification in MRI // *Journal of Digital Imaging*. 2023. Vol. 36, No. 4. P. 1565–1577. doi: 10.1007/s10278-023-00847-4.
30. Doerr S. A., Weber-Levine C., Hersch A.M. et al. Automated prediction of the Thoracolumbar Injury Classification and Severity Score from CT using a novel deep learning algorithm // *Neurosurgical focus*. 2022. Vol. 52, No. 4. P. E5. doi: 10.3171/2022.1.FOCUS21745.
31. Bar A., Wolf L., Amitai O.B., Toledano E., Elnekave E. Compression fractures detection on CT // *Medical imaging 2017: computer-aided diagnosis // SPIE*. 2017. Vol. 10134. P. 1036–1043. doi: 10.1117/12.2249635.
32. Small J.E., Osler P., Paul A.B., Kunst M. CT cervical spine fracture detection using a convolutional neural network // *American Journal of Neuroradiology*. 2021. Vol. 42, No. 7. P. 1341–1347. doi: 10.3174/ajnr.A7094.

33. Tomita N., Cheung Y.Y., Hassanpour S. Deep neural networks for automatic detection of osteoporotic vertebral fractures on CT scans // *Computers in biology and medicine*. 2018. Vol. 98. P. 8–15. doi: 10.1016/j.combiomed.2018.05.011.
34. Derkach S., Kirby C., Kimelman D. et al. Identification of vertebral fractures by convolutional neural networks to predict nonvertebral and hip fractures: a registry-based cohort study of dual X-ray absorptiometry // *Radiology*. 2019. Vol. 293, No. 2. P. 405–411. doi: 10.1148/radiol.2019190201.
35. Zhang J., Liu F., Xu J. et al. Automated detection and classification of acute vertebral body fractures using a convolutional neural network on computed tomography // *Frontiers in endocrinology*. 2023. Vol. 14. P. 1132725. doi: 10.3389/fendo.2023.1132725.
36. Dong Q., Luo G., Lane N.E. et al. Generalizability of deep learning classification of spinal osteoporotic compression fractures on radiographs using an adaptation of the modified-2 algorithm-based qualitative criteria // *Academic radiology*. 2023. Vol. 30, No. 12. P. 2973–2987. doi: 10.1016/j.acra.2023.04.023.
37. Boonrod A. et al. Diagnostic accuracy of deep learning for evaluation of C-spine injury from lateral neck radiographs // *III*. 2022. Vol. 8, No. 8. doi: 10.1016/j.heliyon.2022.e10372.
38. Chen X.G., Liu Y.A. classification method for thoracolumbar vertebral fractures due to basketball sports injury based on deep learning // *Computational and mathematical methods in medicine*. 2022. Vol. 2022, No. 1. P. 8747487. doi: 10.1155/2022/8747487.
39. Yeh L.R., Zhang Y., Chen J.H. et al. A deep learning-based method for the diagnosis of vertebral fractures on spine MRI: retrospective training and validation of ResNet // *European Spine Journal*. 2022. P. 1–9. doi: 10.1007/s00586-022-07121-1.
40. Liu B., Jin Y., Feng S. et al. Benign vs malignant vertebral compression fractures with MRI: a comparison between automatic deep learning network and radiologist's assessment // *European Radiology*. 2023. Vol. 33, No. 7. P. 5060–5068. doi: 10.1007/s00330-023-09713-x.
41. Xu F., Xiong Y., Ye G. et al. Deep learning-based artificial intelligence model for classification of vertebral compression fractures: A multicenter diagnostic study // *Frontiers in Endocrinology*. 2023. Vol. 14. P. 1025749. doi: 10.3389/fendo.2023.1025749.
42. Lang N., Zhang Y., Zhang E. et al. Differentiation of spinal metastases originated from lung and other cancers using radiomics and deep learning based on DCE-MRI // *Magnetic resonance imaging*. 2019. Vol. 64. P. 4. doi: 10.1016/j.mri.2019.02.013.
43. Chen K., Cao J., Zhang X. et al. Differentiation between spinal multiple myeloma and metastases originated from lung using multi-view attention-guided network // *Frontiers in Oncology*. 2022. Vol. 12. P. 981769. doi: 10.3389/fonc.2022.981769.
44. Hallinan J.T.P.D., Zhu L., Zhang W. et al. Deep learning model for classifying metastatic epidural spinal cord compression on MRI // *Frontiers in Oncology*. 2022. Vol. 12. P. 849447. doi: 10.3389/fonc.2022.849447.
45. Xiong X., Wang J., Hu S. et al. Differentiating between multiple myeloma and metastasis subtypes of lumbar vertebra lesions using machine learning-based radiomics // *Frontiers in Oncology*. 2021. Vol. 11. P. 601699. doi: 10.3389/fonc.2021.601699.
46. Hallinan J.T.P.D., Zhu L., Zhang W. et al. Deep learning assessment compared to radiologist reporting for metastatic spinal cord compression on CT // *Frontiers in Oncology*. 2023. Vol. 13. P. 1151073. doi: 10.3389/fonc.2023.1151073.
47. Ito S., Nakashima H., Segi N. et al. Automated detection and diagnosis of spinal schwannomas and meningiomas using deep learning and magnetic resonance imaging // *J. Clin. Med*. 2023. Vol. 12, No. 15. P. 5075. doi: 10.3390/jcm12155075.

Уважаемые коллеги!



Библиотека журнала «Лучевая диагностика и терапия» пополнилась руководством для врачей, которое предназначено для подготовки врачей — лучевых диагностов и врачей-клиницистов по вопросам современных подходов к получению и анализу лучевых изображений, в соответствии с критериями, принятыми в международной клинической практике, а также требованиями, предъявляемыми к формированию структурированных отчетов. Такой подход обеспечивает повышение качества выполняемых исследований, интерпретации изображений и достоверности заключений, а также способствует улучшению междисциплинарной коммуникации.

Настоящее издание является логическим продолжением руководств для врачей «Современные стандарты анализа лучевых изображений» (2017), «Современные классификации RADS и принципы построения заключения» (2018), «Современные стандарты анализа лучевых изображений и принципы построения заключения» (2019), «Современные стандарты анализа лучевых изображений и алгоритмы построения заключения» (2020–2025).

При его подготовке были использованы материалы, обсуждавшиеся на одноименной Международной ежегодной телеконференции 12 декабря 2025 г. (Санкт-Петербург).

Руководство для врачей «Современные стандарты анализа лучевых изображений и принципы построения заключения. Том IX» может использоваться для подготовки в системе последипломного и дополнительного профессионального образования, а также в системе ОМС и ДМС для контроля качества оказываемой медицинской помощи.

Приобрести книгу можно
на сайте издательства <https://www.bmosc-spb.ru>.