

ЛЕКЦИИ И ОБЗОРЫ / LECTURES AND REVIEWS

УДК 616.721.1-089-073.756.8:004.896

<http://dx.doi.org/10.22328/2079-5343-2025-16-1-7-18>**ВОЗМОЖНОСТИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В СЕГМЕНТАЦИИ И ДЕТЕКЦИИ ИЗОБРАЖЕНИЙ ПОЗВОНОЧНИКА НА СОВРЕМЕННОМ ЭТАПЕ РАЗВИТИЯ: СИСТЕМАТИЧЕСКИЙ ОБЗОР**^{1,2}К. О. Васильев^{✉*}, ^{1,2}В. В. Рерих[✉], ¹Е. А. Угольникова[✉]¹Новосибирский научно-исследовательский институт травматологии и ортопедии имени Я. Л. Цивьяна, Новосибирск, Россия²Новосибирский государственный медицинский университет, Новосибирск, Россия

ВВЕДЕНИЕ: С самого начала теоретического обоснования создания искусственного интеллекта возникали идеи о создании электронного помощника для врача. Наиболее эффективными для решения такой задачи в медицинской диагностике являются комплексные системы, основанные на одном из самых продвинутых методов искусственного интеллекта — нейросетях. Дизайн исследования: систематический обзор.

ЦЕЛЬ: Определение возможностей нейросетей на современном этапе их развития в области таких задач, как сегментация и детекция изображений позвоночника.

МАТЕРИАЛЫ И МЕТОДЫ: При помощи протокола PRISMA был произведен поиск в базе данных Pubmed за период с января 2017 по 31 декабря 2022 г. при помощи ключевых слов, по которым производился поиск в аннотации или заголовке: («deep learning» OR «neural network» OR «artificial intelligence») AND («spine») AND («detection» OR «segmentation»).

РЕЗУЛЬТАТЫ: Для систематического обзора было отобрано 30 статей, в которых описывались такие функции нейросетей, как сегментация и детекция при анализе лучевых изображений позвоночника.

ОБСУЖДЕНИЕ: По результатам анализа источников литературы сделаны выводы о полезности применения искусственного интеллекта на современном этапе развития в вертебрологии.

ЗАКЛЮЧЕНИЕ: Нейросети достаточно хорошо справляются с задачами сегментации и детекции в вертебрологии. При задачах сегментации присутствует однозначный лидер — U-Net и ее различные модификации. По детекции ведущими архитектура являются: SCRL, 3D FCN, CNN собственной разработки и комбинация сетей Mask R-CNN+ResNet101. Программное обеспечение, основанное на работах искусственного интеллекта, может помочь как рентгенологу, так и врачу-вертебрологу снизить нагрузку и упростить работу путем автоматизации и полуавтоматизации диагностического процесса.

КЛЮЧЕВЫЕ СЛОВА: искусственный интеллект, нейросети, вертебрология, позвоночник, сегментация, обнаружение

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

Для цитирования: Васильев К.О., Рерих В.В., Угольникова Е.А. Возможности искусственного интеллекта в сегментации и детекции изображений позвоночника на современном этапе развития: систематический обзор // *Лучевая диагностика и терапия*. 2025. Т. 16, № 1. С. 7–18, doi: <http://dx.doi.org/10.22328/2079-5343-2025-16-1-7-18>.

THE CAPABILITIES OF ARTIFICIAL INTELLIGENCE IN SEGMENTATION AND DETECTION OF SPINAL IMAGES AT THE CURRENT STAGE OF DEVELOPMENT: A SYSTEMATIC REVIEW^{1,2}Konstantin O. Vasilyev^{✉*}, ¹Viktor V. Rerikh[✉], ¹Ekaterina A. Ugolnikova[✉]¹Novosibirsk Research Institute of Traumatology and Orthopedics named after Ya. L. Tsiyvan, Novosibirsk, Russia²Novosibirsk State Medical University, Novosibirsk, Russia

INTRODUCTION: From the very beginning of the theoretical substantiation of the creation of artificial intelligence, there were ideas about creating an electronic assistant for a doctor. The most effective for solving such a problem in medical diagnostics are

complex systems based on one of the most advanced methods of artificial intelligence — neural networks. Study design: a systematic review.

OBJECTIVE: Determining the capabilities of neural networks at the current stage of their development in the field of such tasks as segmentation and detection of spine images.

MATERIALS AND METHODS: Using the PRISMA protocol, a search was performed in the Pubmed database for the period from January 2017 to December 31, 2022 using keywords «deep learning» OR «neural network» OR «artificial Intelligence», AND («spine») AND («detection» OR «segmentation»).

RESULTS: For the systematic review, 30 articles were selected that described such functions of neural networks as segmentation and detection in the analysis of spinal images.

DISCUSSION: Based on the analysis of literature sources, conclusions were made about the usefulness of using artificial intelligence at the current stage of development in vertebratology.

CONCLUSION: Neural networks cope quite well with the tasks of segmentation and detection in vertebratology. In segmentation tasks, there is a clear leader — U-Net and its various modifications. In detection, the leading architectures are: SCRL, 3D FCN, CNN of our own design and a combination of Mask R-CNN+ResNet101 networks. Software based on the work of artificial intelligence can help both a radiologist and a vertebratologist reduce the load and simplify the work by automating and semi-automating the diagnostic process.

KEYWORDS: artificial intelligence, neural networks, vertebratology, spine, segmentation, detection

* **For correspondence:** Konstantin O. Vasilyev, e-mail: vasilyev_ko@mail.ru

For citation: Vasilyev K.O., Rerikh V.V., Ugolnikova E.A. The capabilities of artificial intelligence in segmentation and detection of spinal images at the current stage of development: a systematic review // *Diagnostic radiology and radiotherapy*. 2025. Vol. 16, No. 1. P. 7–18, <http://dx.doi.org/10.22328/2079-5343-2025-16-1-7-18>.

Введение. За последние 100 лет медицина значительно шагнула вперед. Если раньше можно было довольствоваться сбором жалоб и клиническим осмотром, то XX век наравне со знаменитыми открытиями в области ядерной физики знаменит еще появлением целого набора высокотехнологических инструментальных методов исследования, таких как рентгенология, компьютерная томография, магнитно-резонансная томография, ультразвуковая диагностика, позитронно-эмиссионная томография, без которых уже довольно трудно представить работы врача в условиях современного медицинского учреждения. Несмотря на технический прогресс, нагрузка на врача-рентгенолога неуклонно растет, при условии того, что всегда существует некий дефицит кадров. С самого начала теоретического обоснования создания искусственного интеллекта возникали идеи о создании электронного помощника для врача, который бы не только в чем-то помогал ему, но и даже мог его вполне заменить. С наступлением XXI века, с развитием машинного обучения, некогда существовавшие на бумаге физиков и математиков-теоретиков рассуждения о виртуальном ассистенте становятся вполне возможными. Наиболее эффективными для решения задач в медицинской диагностике являются комплексные системы, основанные на одном из самых продвинутых методов искусственного интеллекта — искусственных нейронных сетях.

В 1942 г. была выпущена совместная работа МакКаллока и Питца, в которой описан принцип вычислений в нейронных сетях на основе результатов физиологии нервной системы и математической логики. Ученые рассказали, что сеть, составленная

из большого количества таких элементарных процессорных единиц, с синхронно работающими синаптическими связями, могут выполнить практически любые вычисления. Эта статья стала настоящим успехом и причиной зарождения таких областей, как искусственный интеллект и нейронные сети. В 1958 г. была создана первая нейросеть под названием перцептрон. За следующие 50 лет происходил значительный прогресс в развитии машинного обучения, постепенно внедрялись в практику более сложные методы анализа изображений.

На сегодня испытания с нейросетями проходят в самых различных областях медицины: пульмонологии (определение объема поражения легочной ткани при COVID-19 пневмонии), кардиологии (диагностика ишемической болезни сердца), онкологии (выявление объемных образований различной локализации — в легких, головном мозге, печени, почках, предстательной железе с их дифференцировкой на доброкачественные и злокачественные), гастроэнтерологии (прогнозирование абдоминального сепсиса у пациентов с острым панкреатитом), травматологии и ортопедии (прогнозирование результатов отдаленного лечения остеомиелита) [1–4].

Однако, несмотря на прогресс нейросетей, в некоторых областях, таких как вертебрология, существует определенный дефицит информации, связанный со сложным строением, функционированием и недостаточным количеством специалистов в данной области.

Целью данного обзора литературы является определение возможностей нейросетей на современном этапе их развития в области таких задач, как сегментация и обнаружение изображений позвоночника.

Материалы и методы. Выполнен систематический обзор источников литературы по методу PRISMA-ScR [5] за период с января 2017 по 31 декабря 2022 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 («detection» OR «segmentation»). В качестве модальностей использовались лучевые методы исследования, с использованием которых возможно обучение нейросетей на современном этапе развития, таких как классическая рентгенография, компьютерная томография, магнитно-резонансная томография. Ключевые слова были выбраны в связи с их вероятностью наличия в заголовке интересующих статей. Согласно ключевым словам, были выбраны интересующие публикации, а затем более детально изучены.

Результаты. По заданным ключевым словам первоначально было отобрано 311 источников литературы. Публикаций после удаления дубликатов осталось 172 источника. При скрининге были исключены статьи в количестве 111 со следующими критериями: 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 содержащих данных о сегментации и обнаружении. Итоговое количество статей, включенных в обзор, 30. Среди них 4 статьи I уровня доказательности (систематические обзоры [6–9]), остальные 26 — III и IV уровня доказательности. Этапы отбора представлены на рисунке. После всех этапов итого-

Сегментация. Сегментация — это процесс определения границ и областей объектов на изображениях.

В случае медицинских изображений сегментация — этап анализа изображения, целью которого является выделение зоны интереса, что повышает точность и аккуратность анализа [10]. Задачей сегментации медицинских изображений является присвоение всем пикселям или вокселям изображения уникальной метки, характеризующей принадлежность вокселя к той или иной анатомической структуре.

Сегментация может проводиться двумя способами: поверхностное обучение и глубокое обучение. В подходах, основанных на поверхностном обучении, используются предварительно определенные функции с применением одного из определяющих методов, таких как метод опорных векторов, деревья решений, метод ближайших соседей. Главное, что стоит запомнить при описании методов поверхностного обучения — это то, что в них используются такие базовые параметры, как цвет, форма, текстура изображения. Множество базовых параметров являются строго предметно ориентированными, поэтому когда появляются дополнительные сложные параметры, у поверхностного машинного обучения начинают появляться проблемы, возникает так называемое непонимание информации, или, говоря языком программирования, возникает семантический разрыв (semantic gap) [11]. В такой ситуации на помощь приходит глубокое машинное обучение, к которому относятся нейросети [12].

В настоящее время существует две общие категории задач сегментации изображений: семантическая сегментация (semantic segmentation) и сегментация

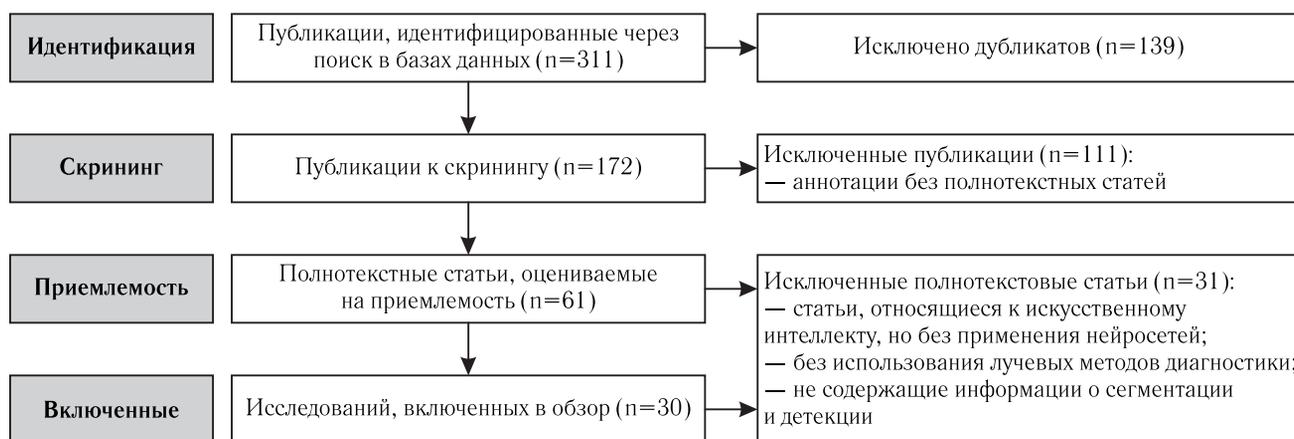


Рисунок. Этапы поиска и отбора источников литературы для систематического обзора
Figure. Stages of searching and selecting literature sources for a systematic review

вое количество литературных источников, относящихся к задачам сегментации, равняется 17, относящихся к задачам обнаружения — 13.

Обсуждение. Основные задачи нейросетей. Основными задачами нейросетей, представленными в данном обзоре, являются сегментация и обнаружение.

экземпляров (instance segmentation). Семантическая сегментация изображения — определение принадлежности всех пикселей на изображении к определенному классу. По сравнению с семантической сегментацией сегментация экземпляров определяет пиксели, принадлежащие каждому объекту определенного класса, по отдельности [13].

Одной из актуальнейших задач в современной медицине является сегментация позвоночника на медицинских изображениях, поскольку именно данные изображения чаще страдают от артефактов, размытия, избыточного шума и низкой контрастности.

При анализе 17 источников литературы в 16 из 17 работ при сегментации использовалась одна нейросеть, в 1 из 17 случаев — комбинация двух сетей — U-Net+FCN (Al Arifi и соавт. [14]). Источники литературы и основные анализируемые параметры представлены в табл. 1.

По типу архитектуры в большинстве случаев (10 из 17) использовалась U-Net и ее модификации ([14–23]); во всех остальных случаях (7 из 10) использовались различные типы сетей, среди которых: 3D CNN собственной разработки [24], Spine-GAN [25], 3D FCN — MsFCN [26], RIMNet [27], MIPNet [28], BiLuNet [29], Mask Region-based CNN [30].

Наиболее распространенной нейросетью для сегментации является U-Net, предложенная Ronneberger [31] в 2015 г. U-Net относится к классу сверточных нейронных сетей (CNN) и имеет стандартную архитектуру [32]. Сеть содержит сверточную (слева) и разверточную части (справа), и поэтому данная архитектура визуально похожа на английскую букву «U».

Наиболее часто используемые показатели в области техники сегментации и классификации медицинских изображений с помощью нейронных сетей представляют собой показатели коэффициент Дайса (Dice Similarity Coefficient — DC) [33] и коэффициент Жаккара (Intersection Over Union Metric — IoU). При анализе статистических показателей, в 12/17 случаев применялся коэффициент Дайса, в 4/17 случаев — mIoU, в 2/17 случаев IoU, точность, чувствительность и специфичность в 2/17 случаев, средняя точность сегментации в 2/17 случаев. Исходя из вышеописанной ситуации, самым распространенным параметром является коэффициент Дайса, в связи с этим основное сравнение будет производиться по нему.

М. Kolařík и соавт. [18] на основе комбинаций классической 2D U-Net и 3D U-Net и добавления взаимосвязи между слоями, обрабатывающими элементы одного и того же размера, создали собственную разработку — 3D Dense-U-Net. Отличие этой сети в том, что она способна обрабатывать данные медицинского изображения в оригинальном разрешении и достигать более высокой точности, чем стандартная U-Net или 3D U-Net. Взаимосвязи помогли сети быстрее обучаться и получать более высокий уровень детализации. Таким образом был получен также один из самых высоких показателей среди как 2D-, так и 3D-сетей с DC 97,08%.

Одной из важнейших проблем при разработке и обучении нейросети является тот факт, что с увеличением количества слоев сети точность сначала постепенно увеличивается, а затем быстро ухудшается. Новая идея для решения данной проблемы получила название глубокое остаточное обучение (deep resi-

dual learning). Решением данной проблемы является создание соединений быстрого доступа (shortcut connections), когда на выход подаются успешные данные двух сверточных слоев с обходом входных данных следующего слоя. Именно эта особенность легла в основу ResNet. Для повышения точности сегментации была разработана комбинированная нейросеть — ResNet-UNet [34]. Именно данную архитектуру применили R. F. Masood и соавт. [23] и получили один из самых высоких показателей DC для сетей, работающих с двумерными изображениями — 97,0%.

Кроме того, стоит отметить модифицированную 3D U-Net — SPINECT со значением DC — 94,5% (G. Fan и соавт. [16]) и классическую 3D U-Net с DC — 93,8% (M. Rak и соавт. [22]). По показателю mIoU примерно со схожими результатами отличаются сети U-Net (J. Huang и соавт. [17]) — 94,7% и 92,6% и Multi-Input PointNet (MIPNet) — 93,4–96,0% (X. Huo и соавт. [26]). Сравнение по прочим статистическим параметрам невозможно в связи с тем, что они крайне редко используются в анализируемой литературе.

Обнаружение. Обнаружение объекта (object detection) — определение местоположения интересующего объекта. Обнаружение, как и сегментация, может выполняться при помощи поверхностных методов машинного обучения, таких как структура обнаружения объектов Виолы-Джонса, гистограмма ориентированных градиентов или преобразование масштабно-инвариантных функций, так и с помощью методов глубокого обучения, к которым относятся нейросети.

Нейросети для обнаружения объектов можно разделить на две базовые архитектуры: двухэтапный Region-based Convolution Neural Network [35] и одноэтапный Single Shot MultiBox Detector [36]. Все они являются подтипами CNN.

Стоит отметить, что существует большая разнообразность нейросетей, использованных именно для данной задачи, но все они так или иначе являются подвидом данных архитектур. Первый вид архитектуры использует следующие этапы: разбивка всего изображения на регионы, в которых могут располагаться интересующие объекты, при этом происходит генерация порядка 2000 регионов. Затем каждый регион подается как входящая информация для свертывающей нейронной сети, которая извлекает необходимый набор векторов и передает его на алгоритм опорных векторов SVM (support vector machine), где уже и происходит обнаружение.

Второй одноэтапный метод Single Shot MultiBox Detector использует метод регрессии. С помощью данного метода находится и определяется охватывающая рамка (coordinate box) и вероятность принадлежности к определенному классу объектов каждого пикселя на всем изображении. Указанный второй тип архитектуры является более предпочтительным, так как он более быстрый и более точный.

Таблица 1

Table 1

Литературные источники сегментации и их характеристики

Literary sources of segmentation and their characteristics

| № | Год | Авторы | Вид сети | Модальность | Объем базы данных | Коэффициент Дайса (DC) | mIoU | IoU | Точность | Чувствительность | Специфичность | Средняя точность сегментации |
|---|------|------------------------|--|-------------|--|-----------------------------------|--|-----------|----------|------------------|---------------|----------------------------------|
| 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 |
| 1 | 2017 | Ladvas и соавт. [24] | 3D CNN | MPT | 51 томограмма | 81,00% | — | — | — | — | — | — |
| 2 | 2018 | Al Arif и соавт. [14] | U-Net + FCN | Rg | 296 рентгенограмм: — 124 для тренировки; — 172 для тестирования | 84,00% | — | — | — | — | — | — |
| 3 | 2018 | Z. Nan и соавт. [25] | Spine-GAN | MPT | 253 томограммы | 87,10% | — | — | 96,2% | 89,10% | 86,00% | — |
| 4 | 2018 | S. Kim и соавт. [15] | Модифицированная U-Net — Boundary Specific U-Network (BSU-Net) | MPT | 25 томограмм: — 20 для тренировки; — 5 для тестирования | 89,44% | — | — | — | — | — | — |
| 5 | 2018 | Li и соавт. [26] | 3D FCN — MsFCN | MPT | 12 томограмм | 91,34% | — | — | — | — | — | — |
| 6 | 2019 | G. Fan и соавт. [16] | Модифицированная 3D U-Net — SPINECT | КТ | 50 томограмм; — 32 для тренировки; — 8 для валидации; — 10 для тестирования | Для костей и нервов 94,5% и 90,5% | Для костей 89,7% и для нервов 82,7% | — | — | — | — | Для костей 94%, для нервов 91,8% |
| 7 | 2019 | J. Huang и соавт. [17] | U-Net | MPT | 100 томограмм: — 50 для обучения; — 50 для тестирования | — | mIoU 94,7% и 92,6% для позвоночника и м/п дисков | — | — | — | — | — |
| 8 | 2019 | Kolarik и соавт. [18] | 3D Dense-U-Net | КТ | 10 томограмм: — 9 для обучения; | 97,08% | — | 94,3±0,5% | — | — | — | — |

| | | Продолжение таблицы 1 | | | | | | | | | | |
|----|------|--------------------------|-------------------------------|---------|--|--|--|---|----|----|----|----|
| 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 |
| 8 | 2019 | Коларик и соавт. [18] | 3D U-Net | МРТ | — 1 для тестирования 64+23 томограммы (2 тес-та) | 93,80% | — | — | — | — | — | — |
| 9 | 2019 | M. Rak и соавт. [22] | U-Net + Parametric level set | МРТ, КТ | МРТ: 20 томограмм КТ: 73 томограммы | 90,37% для м/п дисков (МРТ) и 94,7% для позвонков (КТ) | — | — | — | — | — | — |
| 11 | 2021 | P. Das и соавт. [27] | FCN — RIMNet. | МРТ | 24 томограммы: — 16 для обучения — 8 для тестирования | 91,70% | — | — | — | — | — | — |
| 12 | 2021 | Y. Fang и соавт. [20] | U-Net | КТ | 1449 томограмм: — 586 для обучения; — 863 для тестирования (3 отдельные когорты по 463, 200, 200 исследований) | 82,3% | — | — | — | — | — | — |
| 13 | 2021 | X. Huo и соавт. [28] | Multi-Input PointNet (MIPNet) | КТ | 242 томограммы | — | mLoU 93,4–96,0% | — | — | — | — | — |
| 14 | 2021 | V. L. Tran и соавт. [29] | Multi-Task CNN — BiLuNet | Rg | 750 рентгенограмм: — 600 для обучения — 150 для тестирования | — | mIoU 84,10%, 83,67%, 80,35%, 78,67% для позвоночника, крестца, второй, третьей, четвертой, пятой, шестой, седьмой, восьмой, девятой, десятой, одиннадцатой, двенадцатой позвонков | — | — | — | — | — |

Окончание таблицы 1

| 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 |
|----|------|---------------------------|-------------------------------|-----|---|-------|---|-------|---------------|---------------|---------------|--------|
| 15 | 2021 | Q. Zhang и соавт. [21] | CNN — BN-U-Net | MPT | 22 томограммы для тестирования | — | — | — | 94,54 ± 3,56% | 88,76 ± 2,67% | 86,27 ± 6,23% | — |
| 16 | 2022 | R.F. Masood и соавт. [23] | ResNet-U-net | MPT | 514 томограмм | 97,0% | — | 86,0% | — | — | — | — |
| 17 | 2022 | L. Zhang и соавт. [30] | Mask Region-based CNN (R-CNN) | Rg | 250 рентгенограмм: — 170 для обучения; — 10 для валидации; — 70 для тестирования | — | — | — | — | — | — | 96,80% |

Распознавание особенно актуально при исследованиях изображений позвоночника, так как необходимо не только установить границы самого позвонка, но и определить его принадлежность в шейному, грудному или поясничному отделу, а также его порядковый номер. Автоматическое обнаружение позволяет решить такие проблемы, как затрата времени, жесткие требования к укладке, проекционные наложения и различные артефакты, ухудшающие качество изображения [37].

Из представленных работ в 5/13 случаев применялись комбинации нейросетей, в 8/13 — только одна нейросеть. В 2/13 случаев использовалась Faster R-CNN [38, 39], во всех остальных случаях — нейросети различных архитектур [40–50], в том числе CNN собственной разработки (табл. 2).

К наиболее распространенным статистическим показателям, описывающим задачу обнаружения, являются: точность, коэффициент обнаружения (Identification rate — ID Rate) и ошибка локализации (localization error).

ID Rate встречается в 5/13 работ, в 6/13 работах — localisation error, в 3/13 работ — точность. В связи с разнообразием метрик сравнение будет проводиться по Identification rate и localisation error. По ID rate лидирует Sequential Conditional Reinforcement Learning network (D. Zhang и соавт. [48]) с показателем в 96,3% и 3D FCN (Y. Chen и соавт. [46]) с показателем в 94,67%.

D. Zhang и соавт. [48] впервые предложил сеть обучения с последовательным условным подкреплением (Sequential Conditional Reinforcement Learning network — SCRL) для одновременного обнаружения и сегментации позвонков на МР-изображениях позвоночника. В частности, SCRL сочетает в себе три подсети:

1) сеть обучения анатомическому моделированию с подкреплением (Anatomy-Modeling Reinforcement Learning Network — AMRL) динамически взаимодействует с изображением и фокусирует область внимания на телах позвонков;

2) полностью связанная остаточная нейронная сеть (Fully-Connected Residual Neural Network — FC-ResNet) изучает глобальную контекстную информацию о телах позвонков, включая как подробные низкоуровневые функции, так и абстрактные высокоуровневые функции, чтобы определить точную ограничивающую рамку;

3) Y-образная сеть (Y-shaped network — Y-Net) изучает всестороннюю подробную информацию о текстуре тел, включая многомасштабные, грубые и точные функции, чтобы отделить границу тела позвонка от области внимания.

Y. Chen и соавт. [46] предложили нейросеть, ключевым модулем которой является трехмерная FCN, обученная сквозным образом на уровне позвоночника для захвата контекстной информации из трехмерных КТ-изображений. Увеличение объема

Таблица 2

Table 2

Литературные источники обнаружения и их характеристики

Literary sources of detection and their characteristics

| № | Год | Авторы | Используемая сеть | Вид лучевого исследования, модальность | Объем базы данных | Уровень обнаружения — Identification rate (ID Rate) | Ошибка локализации (localisation error) | Точность | Полнота (recall) | Шанс успеха (success rate) | Двуточечная ошибка (the minimum average point to point error) |
|---|------|-----------------------------|--|--|---|---|---|----------|------------------|----------------------------|---|
| 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 |
| 1 | 2017 | D. Forsberg и соавт. [40] | CNN | МРТ | 750 томограмм: — 450 для тренировок; — 150 для валидации; — 150 для тестирования | — | 2,6 мм | — | — | — | — |
| 2 | 2017 | K.S. Kurachka и соавт. [41] | CNN | Rg | 160 рентгенограмм | — | — | 93,0% | — | — | — |
| 3 | 2017 | D. Yang и соавт. [42] | CNN: Deep Image-to-Image Network (DI2IN) | КТ | 1320 томограмм: — 1260 для обучения; — 60 для тестирования | 90,0% | 6,4 мм | — | — | — | — |
| 4 | 2018 | H. Liao и соавт. [43] | 3D FCN+RNN | КТ | 302 томограммы: — 242 для обучения; — 60 для тестирования | 88,30% | 6,47 мм | — | — | — | — |
| 5 | 2019 | R. Jakubisek и соавт. [44] | CNN+CNN | КТ | 392 томограммы: — 175 для обучения; — 84 для валидации; — 133 для тестирования | 89,40% | — | — | — | — | — |
| 6 | 2019 | Y. Zhou и соавт. [45] | CNN | МРТ | 1318 томограмм | — | — | 98,6% | — | — | — |
| 7 | 2020 | Y. Chen и соавт. [46] | 3D FCN | КТ | 242 томограммы | 94,67% | 3,15 мм | — | — | — | — |

| | | Окончание таблицы 2 | | | | | | | | | |
|----|------|---------------------------------|--|-----|--|--------|--------|---|---|-------|-----------------|
| 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 |
| 8 | 2020 | T. Roggen и соавт. [47] | Mask R-CNN+ResNet1101 | Rg | 12 рентгенограмм, доведенных путем аугментации до 903 | — | 1,5 мм | — | — | — | — |
| 9 | 2020 | D. Zhang и соавт. [48] | Sequential Conditional Reinforcement Learning network SCRL | MPT | 240 томограмм | 96,30% | 3,1 мм | — | — | — | — |
| 10 | 2021 | J.T.P.D. Hallinan и соавт. [38] | Faster R-CNN+CNN | MPT | 466 томограмм: — 396 для обучения; — 40 для валидации; — 30 для тестирования | — | — | — | Для центрального канала, бокового кармана и фораминального отверстия 99,7%, 99,3% и 99,3% | — | — |
| 11 | 2021 | Y. Huang и соавт. [39] | Faster R-CNN+ Faster R-CNN | КТ | 302 томограммы | — | — | Для всего позвоночника 97,0%, для отдельного позвонка 91,0% | — | — | — |
| 12 | 2021 | K. C. Kim и соавт. [49] | CNN: Pose-Net | Rg | 797 рентгенограмм: — 637 для обучения; — 160 для тестирования | — | — | — | — | 96,2% | 12,988 пикселей |
| 13 | 2022 | Y. Wang и соавт. [50] | CNN (MultiIA-UNet) | Rg | 688 рентгенограмм | — | — | — | — | — | — |

вычислений из-за ввода полноразмерных изображений компенсируется уменьшением масштаба входных данных и использованием вспомогательной FCN для компенсации потери деталей. Кроме того, скрытая марковская модель (the hidden Markov model — НММ) накладывает пространственные и последовательные ограничения для более высокой надежности и более четкой интерпретации выходных данных сети.

Что касается такого параметра, как localisation error, то лидирует комбинация нейросетей Mask R-CNN+ResNet101 (Т. Roggen и соавт. [47]) со значением в 1,5 мм и CNN собственной разработки (D. Forsberg и соавт. [40]) со значением в 2,6 мм.

Заключение. На основании полученных данных можно сделать вывод, что нейросети достаточно хорошо справляются с задачами сегментации и обнаружения в вертебрологии. Для осуществления сег-

ментации присутствует однозначный лидер — U-Net и ее различные модификации. По детекции представлено гораздо меньше статей, но общий уровень обнаружения находится статистически на достаточно высоком уровне с наличием ведущих типов архитектур: SCRL, 3D FCN, CNN собственной разработки и комбинация сетей Mask R-CNN+ResNet101.

Нужно учитывать, что на основании выполнения таких базовых задач, как сегментация и детекция, строятся и диагностические алгоритмы для классификации различных патологий позвоночника и количественного измерения ортопедических параметров. Программное обеспечение, использующее информацию данных нейросетей, может помочь как рентгенологу, так и врачу-вертебрологу снизить нагрузку и упростить работу путем автоматизации и полуавтоматизации диагностического процесса.

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» Министерства здравоохранения Российской Федерации; 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;

Угольниковка Екатерина Алексеевна — младший научный сотрудник отделения биостатистики, 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: gjekoolis@gmail.com; ORCID 0000-0003-3438-819X.

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;

Ekaterina A. Ugolnikova — junior researcher at the Department of Biostatistics, 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; e-mail: gjekoolis@gmail.com; ORCID 0000-0003-3438-819X.

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 математический анализ данных — *К.О. Васильев, У.А. Угольниковка*, 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). The largest contributions are distributed as follows: concept and design of the study — *KOV, VVR*, collection and mathematical analysis of data — *KOV, UAU*, 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: 18.03.2024 г.

Принята к печати/Accepted: 29.11.2024 г.

Опубликована/Published: 29.03.2025 г.

ЛИТЕРАТУРА / REFERENCES

1. Sarki R., Ahmed K., Wang H., Zhang Y., Wang K. Automated detection of COVID-19 through convolutional neural network using chest x-ray images // *PLoS ONE*. 2022. Vol. 17, No. 1. e0262052. doi: 10.1371/journal.pone.0262052
2. Kann B.H., Hosny A., Aerts H. Artificial intelligence for clinical oncology // *Cancer Cell*. 2021. Vol. 39, No. 12. P. 916–927. doi: 10.1016/j.ccell.2021.04.002.
3. Gerussi A., Scaravaglio M., Cristoferi L. et al. Artificial intelligence for precision medicine in autoimmune liver disease // *Front Immunol*. 2022. Vol. 13, No. 11. P. 966329. doi: 10.3389/fimmu.2022.966329.
4. Kröner P.T., Engels M.M., Glicksberg B.S. et al. Artificial intelligence in gastroenterology: A state-of-the-art review // *World J. Gastroenterol*. 2021. Vol. 40, No. 27. P. 6794–6824. doi: 10.3748/wjg.v27.i40.6794.
5. 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.
6. Vrtovec T., Ibragimov B. Spinopelvic measurements of sagittal balance with deep learning: systematic review and critical evaluation // *European Spine Journal*. 2022. Vol. 31, No. 8. P. 2031–2045. doi: 10.1007/s00586-022-07155-5.
7. Qu B., Cao J., Qian C. et al. Current development and prospects of deep learning in spine image analysis: a literature review // *Quant. Imaging Med. Surg*. 2022. Vol. 12. P. 3454–3479. doi: 10.21037/qims-21-939.
8. Lundervold A.S. An overview of deep learning in medical imaging focusing on MRI // *Zeitschrift für Medizinische Physik*. 2019. Vol. 29, No. 2. P. 102–127. doi: 10.1016/j.zemedi.2018.11.002.
9. Goedmakers C.M.W., Pereboom L.M., Schoones J.W., de Leeuw den Bouter M.L., Remis R.F. et al. Machine learning for image analysis in the cervical spine: Systematic review of the available models and methods // *Brain & Spine*. 2022. Vol. 2, No. 14. P. 101666. doi: 10.1016/j.bas.2022.101666.
10. Wang R., Lei T., Cui R., Zhang B., Meng H., Nandi A. Medical image segmentation using deep learning: A survey // *IET Image Processing*. 2022. Vol. 16, No. 5. P. 1243–1267. doi: 10.1049/ipr2.12419
11. Ashraf R., Habib M.A., Akram M. et al. Deep convolution neural network for big data medical image classification // *IEEE Access*. 2020. Vol. 8. P. 105659–105670. doi: 10.1109/ACCESS.2020.2998808.
12. Далечина А.В., Беляев М.Г., Тюрина А.Н., Золотова С.В., Пронин И.Н., Голанов А.В. Методы машинного обучения в сегментации глиом для планирования стереотаксической лучевой терапии // *Лучевая диагностика и терапия*. 2019. № 2. С. 24–31. [Dalechina A.V., Beljaev M.G., Tjurina A.N., Zolotova S.V., Pronin I.N., Golanov A.V. Machine learning methods in glioma segmentation for planning stereotactic radiotherapy. *Diagnostic radiology and radiotherapy*, 2019, No. 2, pp. 24–31 (In Russ.).] doi: 10.22328/2079-5343-2019-10-2-24-31.
13. Litjens G., Kooi T., Bejnordi B.E., Setio A.A.A., Ciampi F. et al. A survey on deep learning in medical image analysis // *Medical image analysis*. 2017. Vol. 42. P. 60–88. doi: 10.1016/j.media.2017.07.005.
14. Al Arif S. M. R., Knapp K., Slabaugh G. Fully automatic cervical vertebrae segmentation framework for X-ray images // *Computer methods and programs in biomedicine*. 2018. Vol. 157. P. 95–111. doi: 10.1016/j.cmpb.2018.01.006.
15. Kim S., Bae W.C., Masuda K., Chung C.B., Hwang D. Fine-grain segmentation of the intervertebral discs from MR spine images using deep convolutional neural networks: BSU-Net // *Applied sciences*. 2018. Vol. 8, No. 9. P. 1656. doi: 10.3390/app8091656.
16. Fan G., Liu H., Wu Z. et al. Deep learning-based automatic segmentation of lumbosacral nerves on CT for spinal Intervention: a translational Study // *American Journal of Neuroradiology*. 2019. Vol. 40, No. 6. P. 1074–1081. doi: 10.3174/ajnr.A6070.
17. Huang J., Shen H., Wu J. et al. Spine Explorer: a deep learning based fully automated program for efficient and reliable quantifications of the vertebrae and discs on sagittal lumbar spine MR images // *The Spine Journal*. 2020. Vol. 20, No. 4. P. 590–599. doi: 10.1016/j.spinee.2019.11.010.
18. Kolařík M., Burget R., Uher V., Říha K., Dutta M.K. Optimized high resolution 3D dense-U-Net network for brain and spine segmentation // *Applied Sciences*. 2019. Vol. 9, No. 3. P. 404. doi: 10.3390/app9030404.
19. Rehman F., Ali Shah F.I., Riaz N., Gilani S.O. A robust scheme of vertebrae segmentation for medical diagnosis // *IEEE Access*. 2019. Vol. 7. P. 120387–120398. doi: 10.1109/ACCESS.2019.2936492.
20. Fang Y., Li W., Chen X. et al. Opportunistic osteoporosis screening in multi-detector CT images using deep convolutional neural networks // *European Radiology*. 2021. Vol. 31, No. 4. P. 1831–1842. doi: 10.1007/s00330-020-07312-8.
21. Zhang Q., Du Y., Wei Z., Liu H., Yang X., Zhao D. Spine medical image segmentation based on deep learning // *Journal of Healthcare Engineering*. 2021. Vol. 2021. P. 1917946. doi: 10.1155/2021/1917946.
22. Rak M., Steffen J., Meyer A., Hansen C., Tönnies K.D. Combining convolutional neural networks and star convex cuts for fast whole spine vertebra segmentation in MRI // *Computer Methods and Programs in Biomedicine*. 2019. Vol. 177. P. 47–56. doi: 10.1016/j.cmpb.2019.05.003.
23. Masood R. F., Taj I. A., Khan M. A., Qureshi M. A., Hassan T. Deep learning based vertebral body segmentation with extraction of spinal measurements and disorder disease classification // *Biomedical Signal Processing and Control*. 2022. Vol. 71. P. 103230. doi: 10.1016/j.bspc.2021.103230.
24. Lavdas I., Glocker B., Kamnitsas K. et al. Fully automatic, multiorgan segmentation in normal whole body magnetic resonance imaging (MRI), using classification forests (CF s), convolutional neural networks (CNN s), and a multi-atlas (MA) approach // *Medical physics*. 2017. Vol. 44, No. 10. P. 5210–5220. doi: 10.1002/mp.12492.
25. Han Z., Wei B., Mercado A., Leung S., Li S. Spine-GAN: Semantic segmentation of multiple spinal structures // *Medical image analysis*. 2018. Vol. 50. P. 23–35. doi: 10.1016/j.media.2018.08.005.
26. Li X., Dou Q., Chen H. et al. 3D multi-scale FCN with random modality voxel dropout learning for intervertebral disc localization and segmentation from multi-modality MR images // *Medical image analysis*. 2018. Vol. 45. P. 41–54. doi: 10.1016/j.media.2018.01.004.
27. Das P., Pal C., Acharyya A., Chakrabarti A., Basu S. Deep neural network for automated simultaneous intervertebral disc (IVDs) identification and segmentation of multi-modal MR images // *Computer Methods and Programs in Biomedicine*. 2021. Vol. 205. P. 106074. doi: 10.1016/j.cmpb.2021.106074.

28. Huo X., Cui G., Tan J., Shao K. Automatic measurement of axial vertebral rotation in 3D vertebral models // *Biomedical Physics and Engineering Express*. 2021. Vol. 7, No. 6. P. 065034. doi: 10.1088/2057-1976/ac2c55.
29. Tran V.L., Lin H.Y., Liu H.W. MBNet: A multi-task deep neural network for semantic segmentation and lumbar vertebra inspection on X-ray images // *Proceedings of the Asian Conference on Computer Vision*. 2020. doi: 10.1007/978-3-030-69541-5_38.
30. Zhang Q., Du Y., Wei Z. et al. Spine medical image segmentation based on deep learning // *Journal of Healthcare Engineering*. 2021. Vol. 2021. P. 1917946. doi: 10.1155/2021/1917946.
31. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation // *Medical Image Computing and Computer-Assisted Intervention*. 2015. P. 234–241. doi: 10.1007/978-3-319-24574-4_28.
32. 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 a neural network of the U-Net architecture for the task of localizing violations of the integrity 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.
33. Хамад Ю.А., Симонов К.В., Кенц А.С. Алгоритмы сегментации и распознавания объектов на медицинских изображениях на основе шварлет-преобразования и нейронных сетей // *Информатизация и связь*. 2020. № 2. С. 35–45. [Hamad Yu.A., Simonov K.V., Kenc A.S. Algorithms for segmentation and recognition of objects in medical images based on shearlet transformation and neural networks. *Informatization and communication*, 2020, No. 2, pp. 35–45 (In Russ.)]. doi: 10.34219/2078-8320-2020-11-2-35-45.
34. Chang J., Xiao D., Mehdizadeh M. et al. Deep learning segmentation of hyperautofluorescent fleck lesions in Stargardt disease // *Scientific Reports*. 2020. Vol. 10, No. 1. P. 16491. doi: 10.1038/s41598-020-73339-y.
35. Sezer A. Mask Region-Based Convolutional Neural Network segmentation of the humerus and scapula from proton density-weighted axial shoulder magnetic resonance images // *Jt. Dis. Relat. Surg.* 2023. Vol. 20, No. 34. P. 583–589. doi: 10.52312/jdrs.2023.1291.
36. Heller N., Athianathen N., Kalapara A. et al. The kits19 challenge data: 300 kidney tumor cases with clinical context, ct semantic segmentations, and surgical outcomes // *arXiv preprint*. arXiv: 201904.00445.2019.
37. Zhao S., Wu X., Chen B., Li S. Automatic vertebrae recognition from arbitrary spine MRI images by a category-Consistent self-calibration detection framework // *Medical Image Analysis*. 2021. Vol. 67. P. 101826. doi: 10.1016/j.media.2020.101826.
38. 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.
39. Huang Y., Uneri A., Jones C.K. et al. 3D vertebrae labeling in spine CT an accurate, memory-efficient (Ortho2D) framework // *Physics in Medicine & Biology*. 2021. Vol. 66, No. 12. P. 125020. doi: 10.1088/1361-6560/ac07c7.
40. Forsberg D., Sjöblom E., Sunshine J.L. Detection and Labeling of Vertebrae in MR Images Using Deep Learning with Clinical Annotations as Training Data // *Journal of Digital Imaging*. 2017. Vol. 30. P. 406–412. doi: 10.1007/s10278-017-9945-x.
41. Kurochka K.S., Tsalka I.M. Vertebrae detection in X-ray images based on deep convolutional neural networks // *2017 IEEE 14th International Scientific Conference on Informatics. IEEE*. 2017. P. 194–196.
42. Yang D., Xiong T., Xu D., Huang Q., Liu D., Zhou S.K. et al. Automatic vertebra labeling in large-scale 3D CT using deep image-to-image network with message passing and sparsity regularization // *International Conference on Information Processing in Medical Imaging*. 2017. P. 633–644. doi: 10.1007/978-3-319-59050-9_50.
43. Liao H., Mesfin A., Luo J. Joint Vertebrae Identification and Localization in Spinal CT Images by Combining Short- and Long Range Contextual Information // *IEEE transactions on medical imaging*. 2018. Vol. 37. P. 1266–1275. doi: 10.1109/TMI.2018.2798293
44. Jakubicek R., Chmelik J., Ourednicek P., Jan J. Deep-learning-based fully automatic spine centerline detection in CT data // *41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. 2019. P. 2407–2410. doi: 10.1109/EMBC.2019.8856528.
45. Zhou Y., Liu Y., Chen Q., Gu G., Sui X. Automatic lumbar MRI detection and identification based on deep learning // *Journal of digital imaging*. 2019. Vol. 32, No. 3. P. 513–520. doi: 10.1007/s10278-018-0130-7.
46. Chen Y., Gao Y., Li K., Zhao L., Zhao J. Vertebrae identification and localization utilizing fully convolutional networks and a hidden Markov model // *IEEE Transactions on Medical Imaging*. 2019. Vol. 39, No. 2. P. 387–399. doi: 10.1109/TMI.2019.2927289.
47. Roggen T., Bobic M., Givenchi N., Scheib S.G. Deep Learning model for markerless tracking in spinal SBRT // *Physica Medica*. 2020. Vol. 74. P. 66–73. doi: 10.1016/j.ejmp.2020.04.029.
48. Zhang D., Chen B., Li S. Sequential conditional reinforcement learning for simultaneous vertebral body detection and segmentation with modeling the spine anatomy // *Medical Image Analysis*. 2021. Vol. 67. P. 101861. doi: 10.1016/j.media.2020.101861.
49. Kim K.C., Cho H.C., Jang T.J., Choi J.M., Seo J.K. Automatic detection and segmentation of lumbar vertebrae from X-ray images for compression fracture evaluation // *Computer Methods and Programs in Biomedicine*. 2021. Vol. 200. P. 105833. doi: 10.1016/j.cmpb.2020.105833.
50. Wang Yu., Huang L., Wu M. et al. Multi-input adaptive neural network for automatic detection of cervical vertebral landmarks on X-rays // *Computers in Biology and Medicine*. 2022. Vol. 146. P. 105576. doi: 10.1016/j.combiomed.2022.105576.