

<https://doi.org/10.21869/2223-1536-2026-16-1-77-92>

УДК 004.89+93

Пространственная локализация костных сарком на рентгенограммах с использованием одноэтапной нейросетевой модели

А. В. Киселев¹, Е. А. Кулешова¹, В. Д. Горелов¹,
Т. Н. Конаныхина¹✉, З. К. Чьямова¹

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: govtn@mail.ru

Резюме

Цель исследования – исследование возможности применения одноэтапной нейросетевой модели YOLOv8l-seg для автоматической пространственной локализации костных сарком на рентгенограммах.

Методы. Для обучения нейросетевой модели был синтезирован набор данных на основе аннотированных оцифрованных рентгенограмм с подтвержденными костными саркомами и рентгенограмм без патологии. Изображения в наборе данных были предобработаны (стандартизация размера и контрастности) и разделены на обучающую (1003 изображения) и валидационную (204 изображения) выборки. Для решения задачи сегментации экземпляров костных сарком использовалась нейросетевая модель YOLOv8l-seg с предобученными весами на наборе данных COCO. Процесс дообучения был реализован с применением метода глубокого трансферного обучения. Для предотвращения переобучения нейросетевой модели был применен метод ранней остановки, отслеживающий значение валидационной функции потерь.

Результаты. Тестирование нейросетевой модели проводилось на независимой тестовой выборке, состоявшей из 148 оцифрованных рентгенограмм с подтвержденными костными саркомами и рентгенограмм без патологии, которые не были задействованы на этапах обучения и валидации. Проведенная оценка эффективности показала, что в 78,2% случаев модель не только правильно классифицирует опухоль, но и с приемлемой точностью очерчивает ее пространственные границы, а значение метрики AUC-ROC, равное 0,951, подтверждает высокую дискриминативную способность модели в различении патологии от нормы. Данный результат, хотя и не является эталонным, подтверждает применимость предложенного подхода для решения задачи локализации и контурирования костных сарком на рентгенограммах.

Заключение. Исходя из результатов проведенного анализа, можно сделать вывод, что в отличие от моделей, предоставляющих лишь вероятностную оценку, основное преимущество предлагаемого решения заключается в сегментации экземпляров костных сарком, которая может быть непосредственно использована врачом-рентгенологом в качестве инструмента поддержки принятия решений.

Ключевые слова: костная саркома; рентгенограмма; нейросетевая модель; глубокое трансферное обучение; сегментация экземпляров.

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

Для цитирования: Пространственная локализация костных сарком на рентгенограммах с использованием одноэтапной нейросетевой модели / А. В. Киселев, Е. А. Кулешова, В. Д. Горелов, Т. Н. Конаныхина, З. К. Чьямова // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 77–92. <https://doi.org/10.21869/2223-1536-2026-16-1-77-92>

Поступила в редакцию 20.01.2026

Подписана в печать 18.02.2026

Опубликована 31.03.2026

Spatial localization of bone sarcomas on radiographs using a one-stage neural network model

Alexey V. Kiselev¹, Elena A. Kuleshova¹, Vladislav D. Gorelov¹,
Tatyana N. Konanykhina¹✉, Zoya K. Chyamova¹

¹ Southwest State University

50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: govtn@mail.ru

Abstract

The purpose of the research is to investigate the possibility of using the YOLOv8l-seg single-stage neural network model for automatic spatial localization of bone sarcomas on radiographs.

Methods. To train the neural network model, a data set was synthesized based on annotated digitized radiographs with confirmed bone sarcomas and radiographs without pathology. The images in the dataset were preprocessed (standardization of size and contrast) and divided into training (1003 images) and validation (204 images) samples. To solve the problem of segmentation of bone sarcoma instances, the YOLOv8l-seg neural network model with pre-trained weights on the COCO dataset was used. The retraining process was implemented using the deep transfer learning method. To prevent overfitting of the neural network model, an early stop method was applied that tracks the value of the validation loss function.

Results. The neural network model was tested on an independent test sample consisting of 148 digitized radiographs with confirmed bone sarcomas and X-rays without pathology, which were not involved in the training and validation stages. The efficiency assessment showed that in 78.2% of cases, the model not only correctly classifies the tumor, but also outlines its spatial boundaries with acceptable accuracy, and the AUC-ROC metric value of 0.951 confirms the high discriminative ability of the model in distinguishing pathology from the norm. This result, although not a reference, confirms the applicability of the proposed approach to solving the problem of localization and contouring of bone sarcomas on radiographs.

Conclusion. Based on the results of the analysis, it can be concluded that, unlike models that provide only a probabilistic estimate, the main advantage of the proposed solution lies in the segmentation of bone sarcoma instances, which can be directly used by a radiologist as a decision support tool.

Keywords: bone sarcoma; radiograph; neural network model; deep transfer learning; instance segmentation.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Kiselev A.V., Kuleshova E.A., Gorelov V.D., Konanykhina T.N., Chyamova Z.K. Spatial localization of bone sarcomas on radiographs using a one-stage neural network model. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = Proceedings

Введение

Злокачественные новообразования костной ткани, известные как костные саркомы (КС), отличаются значительным гистогенетическим полиморфизмом. Ключевыми особенностями данной группы заболеваний выступают высокая склонность к гематогенному метастазированию и, как следствие, преобладание неблагоприятных клинических исходов. Несмотря на исключительную редкость в общей онкологической практике (удельный вес этих опухолей не превышает 0,2%), проблема их диагностики и лечения сохраняет высокую медико-социальную значимость. Объясняется это тем, что основную группу пациентов формируют дети и молодежь, т. е. наиболее активная в социальном плане часть общества. Согласно эпидемиологическому регистру SEER (США), ежегодная заболеваемость КС составляет приблизительно 0,9 на 100000 человек. Что касается гистологической структуры, классификация Всемирной организации здравоохранения (ВОЗ) указывает на лидирующую позицию остеосаркомы, которая диагностируется в 35% случаев. Реже встречаются хондросаркома (25%) и саркома Юинга (16%) [1].

В настоящее время ранняя диагностика КС остаётся затруднённой вследствие схожести рентгенологических

проявлений с доброкачественными образованиями и воспалительными процессами [2]. Важность раннего выявления КС обусловлена высоким процентом пациентов с уже сформированными метастатическими очагами на момент первичной диагностики [3]. Эпидемиологические данные свидетельствуют, что у 5% больных к этому времени выявляется поражение регионарных лимфатических узлов, а у каждой третьей части пациентов (около 34%) обнаруживаются отдаленные метастазы, что существенно осложняет прогноз и ограничивает возможности терапии [4]. Метод стандартной рентгенографии предоставляет возможности для выявления структурных изменений костной ткани [5]. С его помощью могут быть визуализированы такие патологические проявления, как очаги деструкции кортикального слоя, реактивные изменения надкостницы, формирование опухолевого матрикса и распространение патологического процесса на прилежащие мягкие ткани [6].

Низкая распространенность первичных злокачественных новообразований костной ткани закономерно приводит к ограниченному клиническому опыту их диагностики в практике рентгенологов [7]. В этой связи разработка автоматизированных систем для анализа рентгенологических изображений

приобретает особую значимость. Внедрение подобных технологий способно повысить эффективность выявления заболеваний на начальных стадиях, а также снизить нагрузку на медицинский персонал [8]. Также это может помочь справиться с недостатком узких специалистов и повысить доступность качественной диагностики для населения, не зависящей от географического положения или экспертного опыта отдельных врачей [9]. В основе таких методов чаще всего лежат алгоритмы глубокого обучения, способные выявлять патологические изменения при анализе медицинских изображений [10]. Благодаря способности к автоматическому извлечению пространственных признаков сверточные нейронные сети демонстрируют высокую эффективность при обработке и анализе рентгенографических изображений [11]. Существует ряд исследований, где в основе таких методов лежат алгоритмы глубокого обучения, способные выявлять патологические изменения при анализе медицинских изображений. Например, в работе [12] авторами была предложена специализированная нейросетевая архитектура, основанная на модели DenseNet, для решения задачи трехклассовой классификации опухолей проксимального отдела бедренной кости (злокачественные, доброкачественные, отсутствие опухоли) на основе рентгенограмм. В ходе валидации модель продемон-

стровала результаты, которые оказались лучше средних показателей четырех врачей-рентгенологов.

В работе [13] авторами был проведен анализ эффективности применения различных архитектур глубокого обучения для диагностики костных опухолей на рентгенограммах. Авторы обучили и сравнили несколько моделей с использованием трансферного обучения – VGG16, VGG19, ResNet101 и DenseNet-201. Модели обучались на наборе данных, содержащем 1144 гистологических изображения, распределенных по трем категориям: «нет опухоли», «жизнеспособная опухоль» и «некротическая опухоль». Согласно результатам, полученным в ходе экспериментов, модель ResNet101 продемонстрировала наилучшие результаты (значение метрики AUC-ROC равное 0,946).

В [14] авторами был разработан алгоритм на основе архитектуры EfficientNet-B0 для классификации первичных опухолей костей по рентгенограммам. С помощью него авторы решали задачу трехклассовой классификации костных новообразований (доброкачественные, промежуточные, злокачественные). Точность модели не имела статистически значимых отличий от точности опытных рентгенологов, но превзошла менее опытных специалистов.

Результаты предшествующих исследований указывают на высокий потенциал применения моделей на основе архитектур глубокого обучения, для

раннего обнаружения и точной локализации КС в системах поддержки принятия врачебных решений.

Материалы и методы

Набор данных для обучения был синтезирован на основе аннотированных оцифрованных рентгенограмм с подтвержденными КС и рентгенограмм без патологии, отобранных из нескольких открытых источников (набор данных Osteosarcoma data from UT Southwestern/UT Dallas for Viable and Necrotic Tumor Assessment¹ и набор данных A Radiograph Dataset for the Classification, Localization, and Segmentation of Primary Bone Tumors) [15]. Изображения в этих наборах данных были проаннотированы с помощью специальных масок, необходимых для решения задачи сегментации экземпляров КС (рис. 1).

Поскольку данные были разнородны по качеству и параметрам визуализации, была проведена их предобработка, в ходе которой изображения приводились к единому размеру и стандартизировались по уровню контрастности. После этого все изображения были разделены на обучающую выборку, включающую в себя 1003 изображения и валидационную выборку, включающую в себя 204 изображения (в пропорции 83%

и 17% соответственно от общего количества изображений в наборе данных).

Для решения задачи сегментации экземпляров КС в рамках данного исследования использовалась НМ YOLOv8l-seg с предобученными весами на наборе данных COCO [16]. Данная НМ применяет одноэтапный подход, при котором процедуры детекции и сегментации выполняются за единый проход через нейронную сеть. Данная парадигма исключает необходимость генерации предварительных регионов интереса (Region of Interest – ROI), что обеспечивает сохранение контекстной информации по всему изображению. КС демонстрируют высокую вариабельность морфологических характеристик, включая полиморфизм контуров, гетерогенность внутренней структуры и существенные различия в размерах. Эта вариабельность морфологических характеристик КС является сложным комплексным паттерном. Одноэтапный подход, сохраняющий полный контекст, позволяет НМ анализировать этот паттерн целиком. Процесс дообучения был реализован с применением метода глубокого трансферного обучения [17]. Нижние слои модели, отвечающие за извлечение признаков, инициализировались предобученными весами и постепенно размораживались, в то время как верхние слои адаптировались под специфику изображений из обучающего набора данных. Гиперпараметры НМ подбирались эмпирически исходя из поведения функций потерь (рис. 2) и метрик качества, полученных в процессе

¹ Osteosarcoma data from UT Southwestern UT Dallas for Viable and Necrotic Tumor Assessment / P. Leavey, A. Sengupta, D. Rakheja, O. Daescu, H. B. Arunachalam, R. Mishra. URL: <https://www.cancerimagingarchive.net/collection/osteosarcoma-tumor-assessment/> (дата обращения: 16.12.2025).

обучения и валидации (рис. 3). Для предотвращения переобучения НМ был применен метод ранней остановки, отслеживающий значение валидационной функции потерь. Алгоритм автоматически прекращает итерационный процесс, если в течение 10 эпох не наблюдается

снижения данного показателя. При срабатывании условия ранней остановки происходит автоматическое восстановление весовых коэффициентов модели до состояния, соответствующего эпохе с минимальным значением функции потерь на валидационной выборке.




Рис. 1. Пример аннотированных изображений из набора данных с масками сегментации

Fig. 1. Example of annotated images from the dataset with segmentation masks




Рис. 2. Графики функций потерь, полученные в процессе обучения и валидации НМ

Fig. 2. Graphs of loss functions obtained during the training and validation of the NM




Рис. 3. Графики метрик качества сегментации экземпляров, полученные в процессе обучения и валидации НМ

Fig. 3. Graphs of the quality metrics of instance segmentation obtained during the training and validation of the NM

Для количественной оценки качества работы алгоритмов классификации и сегментации экземпляров применяется система метрик, основанных на анализе матрицы ошибок. Precision отражает долю истинно положительных примеров среди всех объектов, классифицированных моделью как положительные. Recall характеризует способность модели обнаруживать все релевантные объекты и вычисляется как доля истинно положительных срабатываний среди всех фактически положительных примеров. Precision и Recall рассчитываются по следующим формулам:

$$Precision = \frac{TP}{TP+FP}, \quad (1)$$

$$recall = \frac{TP}{TP+FN}, \quad (2)$$

где TP (True Positives) – количество правильно предсказанных положительных примеров; FP (False Positives) – ко-

личество неправильно предсказанных положительных примеров; FN (False Negatives) – количество неправильно предсказанных отрицательных примеров [18]; mAP (mean Average Precision) – среднее арифметическое значений площадей под кривой Precision – Recall по всем классам объектов в наборе данных для заданного порога IoU ; IoU – коэффициент пересечения ($A \cap B$) и объединения ($A \cup B$) площадей:

$$IoU = \frac{S(A \cap B)}{S(A \cup B)}; \quad (3)$$

A и B – предсказанная маска сегментации и настоящая маска сегментации соответственно, при этом $IoU = 0$, если A и B не пересекаются, $IoU = 1$ в случае идеального наложения [19].

При заданном пороге IoU равном 0,5 метрику mAP можно представить с помощью выражения

$$mAP(0,5) = \frac{(AP_{class1(IoU=0,5)} + AP_{class2(IoU=0,5)} + \dots + AP_{classN(IoU=0,5)})}{N}, \quad (4)$$

где $AP_{classx(IoU=0,5)}$ – это площадь под кривой Precision – Recall для конкретного класса x , вычисленная при усло-

вии, что предсказанная рамка считается правильно предсказанным положительным примером только в том случае, ес-

ли значение $\text{IoU} \geq 0,5$; N – общее количество классов.

Результаты и их обсуждение

Тестирование НМ проводилось на независимой тестовой выборке, состоявшей из 148 оцифрованных рентгенограмм с подтвержденными КС и рентге-

нограмм без патологии, которые не были задействованы на этапах обучения и валидации. Сохраненные визуализированные результаты тестирования, отображающие сегментированные области для классов «без патологий» (normal) и «костная саркома» (bone cancer), представлены на рисунках 4 и 5 соответственно.




Рис. 4. Визуализированные результаты сегментации экземпляров обученной НМ для класса normal

Fig. 4. Visualized results of segmentation of instances of the trained NM for the normal class

В качестве метрики для оценки способности НМ модели осуществлять пространственную локализацию КС применялась mAP(0,5). Данная метрика является комплексным показателем, учитывающим как точность классификации, так и качество локализации объектов. В процессе валидации НМ продемонстрировала значение mAP(0,5) равное 0,782 (см. рис. 3). Этот результат можно интерпретиро-

вать следующим образом: в 78,2% случаев модель не только правильно классифицирует опухоль, но и с приемлемой точностью очерчивает ее пространственные границы. Такой уровень эффективности можно считать удовлетворительным, если принимать во внимание высокую вариабельность морфологических характеристик костных опухолей и ограниченный объем размеченных данных.




Рис. 5. Визуализированные результаты сегментации экземпляров обученной НМ для класса bone cancer

Fig. 5. Visualized results of instance segmentation of the trained NM for the class bone cancer

Показатель качества классификации должен выбираться таким образом, чтобы он зависел как от ошибок как первого, так и второго рода, а недопустимо большие ошибки хотя бы одного вида снижали бы показатель качества классификации к недопустимым значениям [20]. Таким сбалансированным и строгим критерием является площадь под ROC-кривой (AUC-ROC), поэтому для оценки непосредственно классификационной составляющей модели был применен ROC-анализ. Результаты ROC-анализа предлагаемой НМ представлены ниже (рис. 6).

Значение метрики AUC-ROC равное 0,951 подтверждает высокую дискриминативную способность модели в различении патологии от нормы. Высо-

кое значение AUC-ROC, дополненное приемлемыми значениями mAP, позволяет утверждать, что модель обладает сбалансированной эффективностью как в аспекте классификации, так и в аспекте сегментации экземпляров КС на рентгенограммах.

Также было проведено сравнение предлагаемого решения с НМ из исследования [13]. Значения метрики AUC-ROC для НМ из [13] и для YOLOv8l-seg с применением методов глубокого трансферного обучения и ранней остановки приведены ниже (табл. 1).

Исходя из результатов проведенного анализа можно сделать вывод, что предложенная в исследовании модель YOLOv8l-seg с применением методов глубокого трансферного обуче-

ния и ранней остановки продемонстрировала наибольшее значение AUC-ROC (0,951) по сравнению с HM семейства VGG, DenseNet-201 и ResNet-101. Однако основное преимущество данного решения заключа-

ется в решении задачи сегментации экземпляров. Модель YOLOv8l-seg с применением методов глубокого трансферного обучения и ранней остановки обеспечивает приемлемую пространственную локализацию КС.




Рис. 6. Результаты ROC-анализа предлагаемой HM

Fig. 6. Results of ROC analysis proposed by NM

Таблица 1. Значения метрики AUC-ROC для HM и YOLOv8l-seg с применением методов глубокого трансферного обучения и ранней остановки

Table 1. AUC-ROC metric values for the NM and YOLOv8l-seg using deep transfer learning and early stopping methods

HM	Значение AUC-ROC
VGG16	0,909
VGG19	0,931
DenseNet-201	0,909
ResNet 101	0,946
YOLOv8l-seg с применением методов глубокого трансферного обучения и ранней остановки	0,951

Выводы

В данной работе исследована возможность применения одноэтапной нейросетевой модели YOLOv8l-seg для автоматической пространственной локализации КС на рентгенограммах.

Для обучения НМ был синтезирован набор данных на основе аннотированных оцифрованных рентгенограмм с подтвержденными КС и рентгенограмм без патологии. Для решения задачи сегментации экземпляров КС использовалась НМ YOLOv8l-seg с предобученными весами на наборе данных COCO. Процесс дообучения был реализован с применением метода глубокого трансферного обучения. Для предотвращения переобучения НМ был применен метод ранней остановки, отслеживающий значение валидационной функции потерь.

Проведенная оценка эффективности показала, что в 78,2% случаев модель не только правильно классифицирует опухоль, но и с приемлемой точностью очерчивает ее пространственные границы, а значение метрики AUC-ROC равное 0,951 подтверждает высокую дискриминативную способность модели в различении патологии от нормы. Данный результат, хотя и не является эталонным, подтверждает применимость предложенного подхода для решения задачи локализации и контурирования КС на рентгенограммах.

В отличие от моделей, предоставляющих лишь вероятностную оценку, основное преимущество предлагаемого решения заключается в сегментации экземпляров КС, которая может быть непосредственно использована врачом-рентгенологом в качестве инструмента поддержки принятия решений.

Список литературы

1. Алескерова Х. А., Романцова О. М., Хайруллова В. В. Дифференциальная диагностика телеангиэктатической остеосаркомы и аневризмальной костной кисты (обзор литературы) // Российский журнал детской гематологии и онкологии. 2024. Т. 11, № 2. С. 67-73. <https://doi.org/10.21682/2311-1267-2024-11-2-67-73>
2. Патофизиологические особенности клинической диагностики хондросарком / Н. В. Емельянова, А. В. Скворцова, Е. С. Милованова, О. Н. Ямщиков // International Journal of Medicine and Psychology. 2022. Т. 5, № 3. С. 124-132.
3. Mandat T. S., Metastatic High-Grade Intimal Sarcoma of the Middle Cranial Fossa // Journal on Oncology. 2022. Vol. 2, N 2. <https://doi.org/10.52768/2692-563x/1053>
4. Конторович Д. С., Пронькина Е. В., Нуднов Н. В. Внескелетная саркома Юинга малого таза (обзор литературы и клиническое наблюдение) // Медицинская визуализация. 2021. № 25(3). С. 150-156. <https://doi.org/10.24835/1607-0763-924>
5. Matcuk G., Waldman L., Fields B. K. Conventional radiography for the assessment of focal bone lesions of the appendicular skeleton: fundamental concepts in the modern imaging

era // Skeletal Radiol. 2025. Vol 54. P. 1391–1406. <https://doi.org/10.1007/s00256-024-04854-6>

6. Современные возможности и трудности диагностики костных сарком у детей / А. А. Очкурено, А. В. Петриченко, П. А. Романов [и др.] // Педиатрия. Журнал имени Г. Н. Сперанского. 2020. Т. 99, № 4. С. 56-62. <https://doi.org/10.24110/0031-403X-2020-99-4-56-62>

7. Булычева И. В., Федорова А. В. Основы алгоритма рентгеноморфологического исследования костных препаратов // Онкопатология. 2021. Т. 4, № 1(2). С. 18-31. <https://doi.org/10.17650/2618-7019-2021-4-1-2-18-31>

8. Анализ эффективности применения архитектуры U-net для классификации и сегментации глиомы на МРТ-снимках / А. В. Киселев, Е. А. Кулешова, М. О. Таныгин [и др.] // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 3. С. 104-120. <https://doi.org/10.21869/2223-1536-2024-14-3-104-120>

9. Брежнев А. В., Томакова Р. А., Черных Е. В. Информационная система для прогнозирования рецидивов инфаркта миокарда, реализованная как мобильное приложение // Информационное общество. 2023. № 1. С. 116-126. https://doi.org/10.52605/16059921_2023_01_116

10. Томакова Р. А., Дзюбин И. А., Брежнев А. В. Метод и алгоритм обучения сверточной нейронной сети, предназначенной для интеллектуальной системы распознавания меланомы // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. Т. 12, № 1. С. 65-83. <https://doi.org/10.21869/2223-1536-2022-12-1-65-83>

11. Метод анализа оцифрованных рентгеновских снимков грудной клетки для дифференциальной диагностики инфекционных заболеваний дыхательной системы / И. О. Мишин, М. О. Таныгин, А. В. Киселев [и др.] // Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии. 2024. № 4. С. 143-155. <https://doi.org/10.17308/sait/1995-5499/2024/4/143-155>

12. Femur Tumor Net: Bone tumor classification in the proximal femur using DenseNet model based on radiographs / C. Pan, L. Lian, J. Chen, R. Huang // Journal of Bone Oncology. 2023. Vol. 42. P. 7639. <https://doi.org/10.1016/j.jbo.2023.100504>

13. Application of the convolutional neural networks and supervised deep-learning methods for osteosarcoma bone cancer detection / S. Gawade, A. Bhansali, K. Patil, D. Shaikh // Healthcare Analytics. 2023. Vol. 3 (6). P. 100153. <https://doi.org/10.1016/j.health.2023.100153>

14. Deep learning-based classification of primary bone tumors on radiographs / Y. He, I. Pan, B. Bao, K. Halsey, M. Chang [et al.] // EBioMedicine: A preliminary study. 2020. Vol. 62. P. 103121. <https://doi.org/10.1016/j.ebiom.2020.103121>

15. A Radiograph Dataset for the Classification, Localization, and Segmentation of Primary Bone Tumors / S. Yao, Y. Huang, X. Wang, Y. Zhang, I. C. Paixao, Z. Wang [et al.] // Scientific Data. 2024. N 12(1). P. 88. <https://doi.org/10.1038/s41597-024-04311-y>
16. Основные подходы к подготовке визуальных данных для обучения нейросетевых алгоритмов / А. Г. Лапушкин, Д. А. Гаврилов, Н. Н. Щелкунов, Р. Н. Бакеев // Искусственный интеллект и принятие решений. 2021. № 4. С. 62-74. <https://doi.org/10.14357/20718594210406>
17. Iman M., Arabnia H. R., Rasheed K. A review of deep transfer learning and recent advancements // Technologies. 2023. Vol. 11(2). P. 1-14. <https://doi.org/10.3390/technologies11020040>
18. Методы нейросетевой детекции сельскохозяйственных животных в плотных динамических группах на изображениях / А. А. Жигалов, О. А. Иващук, Т. К. Бирюкова, В. И. Федоров // Искусственный интеллект и принятие решений. 2023. № 1. С. 55-66. <https://doi.org/10.14357/20718594230106>
19. Киселев А. В., Брусенцев Н. С., Кулешова Е. А. Анализ эффективности применения двухэтапных нейросетевых моделей для раннего обнаружения лесных пожаров // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 1. С. 8-23. <https://doi.org/10.21869/2223-1536-2024-14-1-8-23>
20. Модели латентных предикторов в интеллектуальных системах прогнозирования состояния живых систем / А. В. Киселев, О. В. Шаталова, З. У. Протасова [и др.] // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2020. Т. 10, № 1. С. 114-133.

References

1. Aleskerova Kh.A., Romantsova O.M., Khairullova V.V. Differencial'naya diagnostika teleangiektaticheskoy osteosarkomy i anevrizmal'noj kostnoj kisty (obzor literatury). *Rossiyskiy zhurnal detskoy gematologii i onkologii = Russian Journal of Pediatric Hematology and Oncology*. 2024;11(2):67-73. (In Russ.) <https://doi.org/10.21682/2311-1267-2024-11-2-67-73>
2. Emelyanova N.V., Skvortsova A.V., Milovanova E.S., Yamshchikov O.N. Patofiziologicheskie osobennosti klinicheskoy diagnostiki hondrosarkom. *International Journal of Medicine and Psychology*. 2022;5(3):124-132. (In Russ.)
3. Mandat T.S. Metastatic High-Grade Intimal Sarcoma of the Middle Cranial Fossa. *Journal on Oncology*. 2022;2(2). <https://doi.org/10.52768/2692-563x/1053>

4. Kontorovich D.S., Pronkina E.V., Nudnov N.V. Vneskeletnaya sarkoma Yuinga malogo taza (obzor literatury i klinicheskoe nablyudenie). *Meditinskaya vizualizatsiya = Medical Visualization*. 2021;(25):150-156. (In Russ.) <https://doi.org/10.24835/1607-0763-924>
5. Matcuk G., Waldman L., Fields B.K. Conventional radiography for the assessment of focal bone lesions of the appendicular skeleton: fundamental concepts in the modern imaging era. *Skeletal Radiol*. 2025;54:1391–1406. <https://doi.org/10.1007/s00256-024-04854-6>
6. Ochkurenko A.A., Petrichenko A.V., Romanov P.A., et al. Sovremennye vozmozhnosti i trudnosti diagnostiki kostnyh sarkom u detej. *Pediatrics. Zhurnal im. G.N. Speranskogo = Pediatrics. Journal named after G.N. Speransky*. 2020;99(4):56-62. (In Russ.) <https://doi.org/10.24110/0031-403X-2020-99-4-56-62>
7. Bulycheva I.V., Fedorova A.V. Osnovy algoritma rentgenomorfologicheskogo issledovaniya kostnyh preparatov. *Onkopatologiya = Oncopathology*. 2021;4(1):18-31. (In Russ.) <https://doi.org/10.17650/2618-7019-2021-4-1-2-18-31>
8. Kiselev A.V., Kuleshova E.A., Tanygin M.O., et al. Analiz effektivnosti primeneniya arhitektury U-net dlya klassifikatsii i segmentatsii gliomy na MRT-snimkah. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2024;14(3):104-120. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-3-104-120>
9. Brezhnev A.V., Tomakova R.A., Chernykh E.V. Informacionnaya sistema dlya prognozirovaniya recidivov infarkta miokarda, realizovannaya kak mobil'noe prilozhenie. *Informatsionnoye obshchestvo = Information Society*. 2023;(1):116-126. (In Russ.) https://doi.org/10.52605/16059921_2023_01_116
10. Tomakova R.A., Dzyubin I.A., Brezhnev A.V. Metod i algoritm obucheniya svertochnoj nejronnoj seti, prednaznachenoj dlya intellektual'noj sistemy raspoznavaniya melanomy. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2022;12(1):65-83. (In Russ.) <https://doi.org/10.21869/2223-1536-2022-12-1-65-83>
11. Mishin I.O., Tanygin M.O., Kiselev A.V. Metod analiza ocifrovannyh rentgenovskih snimkov grudnoj kletki dlya differentsial'noj diagnostiki infekcionnyh zabolevanij dyhatel'noj sistemy. *Vestnik Voronezhskogo gosudarstvennogo universiteta. Seriya: Sistemnyy analiz i informatsionnyye tekhnologii = Proceedings of Voronezh State University. Series: Systems Analysis and Information Technologies*. 2024;(4):143-155. (In Russ.) <https://doi.org/10.17308/sait/1995-5499/2024/4/143-155>

12. Pan C., Lian L., Chen J., Huang R. Femur Tumor Net: Bone tumor classification in the proximal femur using DenseNet model based on radiographs. *Journal of Bone Oncology*. 2023;42:7639. <https://doi.org/10.1016/j.jbo.2023.100504>
13. Gawade S., Bhansali A., Patil K., Shaikh D. Application of the convolutional neural networks and supervised deep-learning methods for osteosarcoma bone cancer detection. *Healthcare Analytics*. 2023;3:100153. <https://doi.org/10.1016/j.health.2023.100153>
14. He Y., Pan I., Bao B., Halsey K., Chang M., et al. Deep learning-based classification of primary bone tumors on radiographs. *EBioMedicine: A Preliminary Study*. 2020;62:103121. <https://doi.org/10.1016/j.ebiom.2020.103121>
15. Yao S., Huang Y., Wang X., Zhang Y., Paixao I. C., Wang Z., et al. A Radiograph Dataset for the Classification, Localization, and Segmentation of Primary Bone Tumors. *Scientific Data*. 2024;(12):88. <https://doi.org/10.1038/s41597-024-04311-y>
16. Lapushkin A.G., Gavrilov D.A., Shchelkunov N.N., Bakeev R.N. Osnovnye podhody k podgotovke vizual'nyh dannyh dlya obucheniya nejrosetevykh algoritmov. *Iskusstvennyy intellekt i prinyatiye resheniy = Artificial Intelligence and Decision Making*. 2021;(4):62-74. (In Russ.) <https://doi.org/10.14357/20718594210406>
17. Iman M., Arabnia H.R., Rasheed K. A review of deep transfer learning and recent advancements. *Technologies*. 2023;11(2):1-14. <https://doi.org/10.3390/technologies11020040>
18. Zhigalov A.A., Ivashchuk O.A., Biryukova T.K., Fedorov V.I. Metody nejrosetevoj detekcii sel'skohozyajstvennykh zhivotnykh v plotnykh dinamicheskikh gruppah na izobrazheniyah. *Iskusstvennyy intellekt i prinyatiye resheniy = Artificial Intelligence and Decision Making*. 2023;(1):55-66. (In Russ.) <https://doi.org/10.14357/20718594230106>
19. Kiselev A.V., Brusentsev N.S., Kuleshova E.A. Analiz effektivnosti primeneniya dvuhetapnykh nejrosetevykh modelej dlya rannego obnaruzheniya lesnykh pozharov. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2024;14(1):8-23. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-1-8-23>
20. Kiselev A.V., Shatalova O.V., Protasova Z.U., et al. Modeli latentnykh prediktorov v intellektual'nykh sistemah prognozirovaniya sostoyaniya zhivykh sistem. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2020;10(1):114-133. (In Russ.)

Информация об авторах / Information about the Authors

Киселев Алексей Викторович, кандидат технических наук, доцент, доцент кафедры вычислительной техники, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: kiselevalexey1990@gmail.com,
ORCID: 0000-0001-7228-0281

Alexey V. Kiselev, Candidate of Sciences (Engineering), Associate Professor, Associate Professor at the Department of Computer Engineering, Southwest State University, Kursk, Russian Federation,
e-mail: kiselevalexey1990@gmail.com,
ORCID: 0000-0001-7228-0281

Кулешова Елена Александровна, кандидат технических наук, доцент кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: lena.kuleshova.94@mail.ru,
ORCID: 0000-0002-8270-564X

Elena A. Kuleshova, Candidate of Sciences (Engineering), Associate Professor at the Department of Computer Engineering, Southwest State University, Kursk, Russian Federation,
e-mail: lena.kuleshova.94@mail.ru,
ORCID: 0000-0002-8270-564X

Горелов Владислав Дмитриевич, студент кафедры вычислительной техники, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: vladisgorr@gmail.com,
ORCID: 0009-0002-7315-3510

Vladislav D. Gorelov, Student at the Department of Computer Engineering, Southwest State University, Kursk, Russian Federation,
e-mail: vladisgorr@gmail.com,
ORCID: 0009-0002-7315-3510

Конаныхина Татьяна Николаевна, кандидат технических наук, доцент, доцент кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: govtn@mail.ru,
ORCID: 0000-0002-2755-0163

Tatyana N. Konanykhina, Candidate of Sciences (Engineering), Associate Professor, Associate Professor at the Department of Software Engineering, Southwest State University, Kursk, Russian Federation,
e-mail: govtn@mail.ru,
ORCID: 0000-0002-2755-0163

Чьямова Зоя Константиновна, студент кафедры информационной безопасности, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: zoyachyamova@gmail.com,
ORCID: 0009-0000-7734-052X

Zoya K. Chyamova, Student at the Department of Information Security, Southwest State University, Kursk, Russian Federation,
e-mail: zoyachyamova@gmail.com,
ORCID: 0009-0000-7734-052X