

Научная статья

УДК 616.727.2

<https://elibrary.ru/YVOSFP>

Применение анализа текстур рентгенограмм для определения признаков остеоартрита плечевого сустава

Александр Андреевич Жиялков[✉],
Елена Александровна Волокитина

Уральский государственный медицинский университет, Екатеринбург, Россия

✉ alexandrusma@mail.ru

Аннотация. Статья посвящена разработке метода автоматической идентификации остеоартрита плечевого сустава с помощью анализа текстур рентгенизображений. Остеоартрит — хроническое дегенеративное заболевание, которое оказывает значительное влияние на качество жизни, особенно при поражении плечевого сустава. Традиционные методы диагностики часто выявляют изменения только на поздних стадиях болезни, поэтому важна ранняя диагностика. Предложено использование методов машинного обучения (опорных векторов (SVM) и k -ближайших соседей (k NN)) для анализа рентгенограмм. Исследование включало R-снимки плечевых суставов 31 пациента; предварительная обработка изображений: улучшение контраста с помощью алгоритма CLAHE и использование матрицы совпадения уровней серого для извлечения текстурных характеристик. Результаты показали, что метод k NN продемонстрировал 100 %-ю точность в классификации нормальных изображений, в то время как SVM — 79 %-ю точность. Для аномальных изображений оба метода показали 100 %-ю результативность. Отмечены высокая эффективность такого алгоритма по сравнению с традиционными методами, а также важность дальнейших исследований для его улучшения и расширения выборки. Предложенный подход позволяет детально анализировать медицинские изображения, выявляя тонкие изменения в тканях, что особенно важно для ранней диагностики и оценки степени поражения. Необходимо проведение дальнейших исследований в этой области, чтобы улучшить диагностику и лечение остеоартрита плечевого сустава.

Ключевые слова: остеоартрит, анализ текстур, синовиальная полость, кубическая SVM, k NN, машинное обучение, GLCM

Благодарности. Авторы выражают благодарность Дарье Александровне Акуло-

вой, кандидату медицинских наук, директору Екатеринбургского медицинского центра, за предоставленную возможность использования архива рентгеновских снимков для проведения исследования.

Для цитирования: Жиляков А. А., Волокитина Е. А. Применение анализа текстур рентгенограмм для определения признаков остеоартрита плечевого сустава // Вестник УГМУ. 2024. № 2. С. 40–52. EDN: <https://elibrary.ru/YVOSFP>.

Original article

Application of Radiograph Texture Analysis to Identify Signs of Osteoarthritis of the Shoulder Joint

Aleksandr A. Zhiljakov[✉], Elena A. Volokitina

Ural State Medical University, Ekaterinburg, Russia

✉ alexandrusma@mail.ru

Abstract. The article is devoted to the development of a method for automatic identification of osteoarthritis of the shoulder joint using texture analysis of X-ray images. Osteoarthritis is a chronic degenerative disease that has a significant impact on quality of life, especially when the shoulder joint is affected. Traditional diagnostic methods often detect changes only at late stages of the disease, so early diagnosis is important. In this paper, we proposed the use of machine learning techniques such as support vector method (SVM) and k -nearest neighbours (k NN) method to analyse radiographs. The study included radiographs of the shoulder joint of 31 patients. Image preprocessing included contrast enhancement using the CLAHE algorithm and the use of grey level matching matrix (GLCM) to extract texture features. The results showed that the k NN method showed 100 % accuracy in classifying normal images, while SVM showed 79 % accuracy. For abnormal images, both methods showed 100 % performance. The high performance of this algorithm compared to traditional methods was highlighted and the importance of further research to improve the algorithm and expand the sample was emphasised. The proposed approach allows detailed analysis of medical images, revealing subtle changes in tissues, which is especially important for early diagnosis and assessment of the extent of lesions. We believe that further research in this area is needed to improve the diagnosis and treatment of osteoarthritis of the shoulder joint.

Keywords: osteoarthritis, texture analysis, synovial cavity, cubic SVM, k NN, machine learning, GLCM

Acknowledgments. The authors are grateful to Daria A. Akulova, Cand. Sci. (Med.), Director of the Ekaterinburg Medical Centre, for the opportunity to use the archive of X-ray images for the study.

For citation: Zhiljakov AA, Volokitina EA. Application of radiograph texture analysis to identify signs of osteoarthritis of the shoulder joint. *USMU Medical Bulletin*. 2024;(2):40–52.

(In Russ.). EDN: <https://elibrary.ru/YVOSFP>.

Введение

Остеоартрит (ОА) — это хроническое дегенеративное заболевание, которое проявляется постепенной деструкцией суставного хряща, склерозом субхондральной и кистозной трансформацией губчатой кости, формированием остеофитов и хроническим воспалением синовиальной оболочки. Патология оказывает значительное влияние на качество жизни пациентов, особенно когда поражен ключевой для выполнения повседневных действий сустав, такой как плечевой [1].

Плечевой сустав, обладающий широким диапазоном движений, является одним из наиболее подвижных и функционально важных суставов в человеческом теле. Его сложная анатомия и высокая механическая активность делают его уязвимым для различных травматических и дегенеративных повреждений [2].

Традиционные методы диагностики ОА, такие как рентгеновские исследования, позволяют визуализировать следующие изменения: уменьшение суставной щели, наличие остеофитов и костную деформацию. Однако они часто становятся заметными только на поздних стадиях болезни [3]. Ранняя диагностика и оценка степени поражения хряща в плечевом суставе крайне важны для своевременного начала адекватной терапии и предотвращения дальнейшего прогрессирования заболевания [4–6].

В этом контексте шкала Келлгрена — Лоуренса представляет собой один из инструментов для классификации степени ОА по рентгеновским признакам. Однако корреляция между данными рентгенологического исследования и клиническими симптомами, такими как боль и ограничение подвижности, остается предметом научных исследований [7, 8].

С развитием технологий радиомики появилась возможность детально анализировать медицинские изображения и извлекать из них количественные данные. Это открывает новые перспективы для оценки структурных изменений в костной и хрящевой тканях на ранних стадиях ОА. А. Мунавар и др. (*англ.* A. Munawar et al.) предложили способ, предполагающий сочетание методов опорных векторов (*англ.* Support Vector Machine, SVM) и *k*-ближайших соседей (*англ.* *k*-Nearest Neighbors Algorithm, *k*NN) в качестве классификатора, который демонстрировал бы наиболее стабильные результаты по сравнению с другими методами [7]. Предварительная подготовка данных предполагала улучшение изображения с помощью контрастно-ограниченного адаптивного уравнивания гистограммы (*англ.* Contrast-Limited Adaptive Histogram Equalization, CLAHE), а также определение центральной области синовиальной полости, которая находится между головкой плечевой кости и суставной впадиной лопатки. Из областей улучшенного изображения костных тканей сустава были извлечены четыре текстурные характеристики: контраст, корреляция, энергия и одно-

родность.

В последних работах часто упоминается матрица совпадения уровней серого (*англ.* Gray-Level Co-occurrence Matrix, GLCM), которая представляет собой статистический метод, учитывающий пространственное распределение пикселей [9, 10]. В этих статьях также сообщается, что GLCM является мощным инструментом в области анализа изображений и извлечения текстурных характеристик, который позволяет оценить, насколько часто определенные комбинации уровней яркости (серого) встречаются на изображении. В проведенных исследованиях показано, что использование GLCM для анализа рентгеновских изображений позволяет точнее классифицировать стадии ОА и предсказать его прогрессирование.

Предполагается, что в контексте анализа медицинских изображений GLCM может быть использован для выявления тонких изменений в структуре тканей, которые могут быть невидимы при обычном визуальном осмотре, что особенно актуально при изучении заболеваний, таких как ОА, где ранняя диагностика и точная оценка степени поражения могут значительно улучшить результаты лечения. Такой подход позволяет не только уточнить диагноз, но и оценить эффективность лечебных вмешательств, адаптированных к конкретной стадии заболевания плечевого сустава.

Цель исследования — разработка метода автоматической идентификации ОА плечевого сустава на основе анализа текстуры рентгеновских изображений.

Задачи исследования:

- 1) предварительная обработка изображений — улучшение контраста изображения для маркировки области суставной полости;
- 2) сегментация — точное определение области суставной полости на изображении;
- 3) извлечение текстурных признаков — анализ текстурных характеристик пикселей в суставе с использованием GLCM;
- 4) классификация — использование полученных текстурных признаков суставных концов для стратификации их изображений как нормальных или пораженных ОА.

Материалы и методы

Стандарты и одобрения. Экспериментальный дизайн ретроспективного поперечного исследования выбран для разработки и тестирования методов автоматической идентификации группы признаков ОА плечевого сустава на основе анализа текстуры рентгеновских изображений. В работе использовались анонимизированные рентгенограммы плечевого сустава, что исключает возможность идентификации участников. В связи с этим получение индивидуального информированного согласия пациентов не требовалось. Исследование проведено в соответствии с этическими нормами, изложенными в Хельсинкской декларации, и принципами конфиденциальности данных, но не было рассмотрено независимым этическим комитетом, т. к. оно

не предполагает риска для участников.

Участники. В исследование были включены пациенты в возрасте от 25 до 50 лет, испытывающие боль в плече и направленные на рентгенографию плечевого сустава в течение 5 месяцев (с сентября 2020 г. по февраль 2021 г.). Исключались пациенты с историей вывихов или проведенных операций на плечевом суставе, а также другими заболеваниями, которые могли бы повлиять на анатомическое строение плеча.

Методика рентгенографии. Использовалось стандартное рентгенологическое оборудование — универсальная цифровая система для проведения рентгенографии Siemens AXIOM Aristos MX. Для получения снимков пациент располагался лицом к детектору рентгеновского излучения, руки вытянуты вдоль тела. Плечо позиционировалось таким образом, чтобы обеспечить оптимальное расположение плечевого сустава для полной и центрированной визуализации головки плечевой кости и лопатки на снимке. Параметры съемки (напряжение, сила тока, время экспозиции) корректировалось в зависимости от антропометрических данных пациента для минимизации дозы облучения при сохранении высокого качества изображения, необходимого для достоверной диагностики. Каждый снимок подвергался тщательной оценке квалифицированным специалистом в области радиологии. Оценивались четкость визуализации анатомических структур плечевого сустава, корректность проекции и отсутствие артефактов, способных исказить результаты анализа.

Первичная обработка и анализ рентгенограмм. Анализ рентгенограмм плечевых суставов проведен с использованием специализированного бесплатного программного обеспечения GIMP 2.10.38* и LIFEx 7.6.3**. Процесс начался с преобразования цветных RGB-изображений*** в серую шкалу, что существенно упрощает последующую обработку данных. В процессе конвертации было уделено внимание улучшению контрастности изображений, качество которых могло быть снижено из-за внешних помех и низкой начальной контрастности.

Для коррекции контраста использовался алгоритм CLAHE, который эффективно оптимизировал контрастность, разделяя изображение на мелкие сегменты размером 8×8 пикселей. Эта технология позволяет улучшать контраст на уровне этих маленьких участков, делая общее изображение более четким и насыщенным. Дополнительно применена билинейная интерполяция для устранения возможных артефактов, возникающих при усилении контраста в отдельных плитках.

После улучшения качества изображений проведена пороговая обработ-

* GIMP — программа для работы с изображениями GNU (*англ.* GNU Image Manipulation Program).

** LIFEx. URL: <https://www.lifexsoft.org> (date of access: 08.05.2024).

*** RGB — цветовая модель, построенная на сочетании аддитивных первичных цветов: красного, зеленого, синего (*англ.* Red, Green, Blue).

ка, которая позволила создать бинарные изображения, где фрагменты, относящиеся к суставным полостям, представлены белым цветом, а костные структуры — черным. Это значительно упрощает задачу сегментации и анализа характеристик сустава.

Далее в рамках подготовки данных к более глубокому анализу была использована ограничительная рамка, чтобы исключить ошибки сегментации, связанные с темными участками изображения, не содержащими информацию о костной ткани. Инверсия последующего изображения помогла детально разграничить костные и суставные структуры, что важно для точности диагностических выводов.

При анализе текстурных свойств из оцифрованных рентгеновских снимков использовалась GLCM, позволяющая выявить такие параметры, как контраст, корреляция, энергия и однородность. Эти метрики обладали важным диагностическим значением, поскольку позволяют оценивать неравномерность текстуры костной ткани, что может указывать на различные патологические состояния. Контраст, который представляет собой разницу в интенсивности между двумя примыкающими пикселями изображения, составил (0,0690; 0,1181). Корреляция — мера, показывающая, как пиксель коррелирует с соседним на всем изображении, — находилась в диапазоне (0,9876; 0,9788). Энергия, которая представляет собой сумму квадратов элементов, равнялась (0,1457; 0,1321), а однородность, которая измеряет близость распределения элементов в GLCM к диагонали GLCM, равна (0,9655; 0,9410). Приведенные значения являются диапазоном [11].

Определение центра суставной полости как зоны наибольшей концентрации белых пикселей позволило получить ключевую точку для дальнейшего анализа структурных изменений в суставе. Это место демонстрирует основную область интереса при изучении дегенеративных изменений или травм. Анализ гистограммы использовался для количественной оценки распределения пикселей по уровням интенсивности, что дает возможность оценить степень однородности или изменения внутри суставной полости. В дополнение к определению центра исследованы периферийные области сустава, чтобы улавливать более тонкие изменения в его структуре, которые могут указывать на начальные стадии развития патологических процессов.

Алгоритмы машинного обучения SVM и k NN выбраны в связи с их способностью эффективно обрабатывать высокоразмерные данные, в т. ч. сложные изображения медицинских снимков. SVM использует метод, основанный на оптимизации разделительной гиперплоскости в пространстве признаков, что обеспечивает максимизацию ширины зазора между классами. Это позволяет достичь устойчивости классификации по отношению к вариативности изображений, что особенно важно при вариациях, обусловленных различиями анатомического строения исследуемых объектов. В то же время использование k NN дополняет SVM, т. к. этот метод фокусируется на ана-

лизе локальных паттернов в данных, основываясь на голосовании ближайших соседей в признаковом пространстве. Благодаря этому можно уточнить классификацию, делая ее более чувствительной к мелким, но диагностически значимым отличиям снимков.

В процессе исследования проведены эксперименты для настройки параметров алгоритмов. Параметрическая оптимизация включала в себя регулировку таких аспектов, как степень регуляризации в SVM и число соседей в k NN. Эти манипуляции с параметрами позволили улучшить способность моделей различать состояния здоровых и пораженных суставов на основе анализируемых изображений. Рассмотрение взаимного влияния различных настроек параметров дало возможность точнее адаптировать алгоритмы под существующий набор медицинских данных, что повысило точность и валидность итоговой системы классификации.

Статистический анализ. Статистический анализ проводился с помощью программного обеспечения SPSS Statistics 23.0. Использовалась описательная статистика для определения средних значений и стандартных отклонений, а также коэффициент внутриклассовой корреляции (*англ.* Intraclass Correlation Coefficient, ICC) для оценки воспроизводимости между наблюдателями. Значимость различий между измерениями проверялась с использованием t -теста, с установленным порогом статистической значимости $P < 0,05$.

Результаты и обсуждение

В рамках научной дискуссии о значении исследований в области диагностики ОА плечевого сустава [12] особое внимание стоит уделить анализу рентгеновских изображений с использованием методов машинного обучения. Результаты нашего исследования подтверждают высокую точность автоматизированной классификации рентгенограмм плечевого сустава с помощью k NN и SVM, что позволило достичь высокой точности классификации, особенно для нормальных изображений, где k NN продемонстрировал 100%-ю точность, в то время как SVM — 79%-ю точность. Для аномальных изображений оба метода показали 100%-ю результативность. Предыдущие исследования также демонстрировали потенциал машинного обучения, но не достигали такой высокой точности в классификации аномальных снимков [11].

Достижение 100 %-й точности при классификации аномальных изображений требует использования комплексных стратегий, основанных на методах машинного обучения и обработки данных. Правильный выбор алгоритма классификации является фундаментальным. В исследовании применялись алгоритмы k NN и метод SVM, которые зарекомендовали себя как высокоэффективные в этой области.

Регулярная валидация и тестирование модели, включая кросс-валидацию, помогают минимизировать ошибки и переобучение, обеспечивая более устойчивые и надежные результаты классификации. Настройка гиперпара-

метров модели позволяет адаптировать ее к конкретной задаче, что включает выбор типа ядра, параметры регуляризации для SVM, а также оптимальное число соседей для k NN. Обучение модели на более крупной и разнообразной выборке данных способствует улучшению ее общей производительности. Использование достаточного количества изображений различных типов помогает модели лучше различать нормальные и аномальные признаки.

Применение ансамблевых моделей или комбинаций различных алгоритмов также может повысить точность. Например, сочетание k NN и SVM может использовать сильные стороны каждого метода для улучшения общей точности. Эти стратегии совместно значительно повышают точность модели, тем самым обеспечивая надежное и эффективное решение для автоматизированной диагностики ОА и других патологий. Метод SVM и алгоритм k NN представляют собой два популярных метода машинного обучения, каждый из которых обладает уникальными преимуществами и недостатками.

SVM демонстрирует высокую эффективность при работе с данными, содержащими большее количество признаков по сравнению с числом образцов [13]. Использование метода ядра позволяет SVM справляться как с линейно, так и нелинейно разделяемыми данными, что делает его универсальным инструментом для решений задач классификации и регрессии. Кроме того, SVM характеризуется высокой обобщающей способностью на новых данных благодаря встроенной регуляризации, которая помогает избежать переобучения. SVM также эффективно справляется с несбалансированным набором данных, используя возможности регулирования весов классов или методов, таких как One-Class SVM. Однако SVM имеет и свои недостатки, среди которых меньшая интерпретируемость, т. к. решения, основанные на поддерживающих векторах, могут быть сложны для понимания в многомерных пространствах. Кроме того, процесс обучения SVM может быть медленнее, чем k NN, особенно на больших наборах данных, из-за необходимости решения задач квадратичной оптимизации.

Метод k NN выделяется своей простотой и интуитивностью. Алгоритм легко понимаем и делает прогнозы на основе близости к соседним точкам без необходимости предварительного предположения о распределении данных. Интерпретируемость k NN также является его сильной стороной, поскольку результаты получают на основе ближайших соседей, что делает видимым процесс прогнозирования. Тем не менее k NN также имеет свои ограничения. Во-первых, результаты алгоритма сильно зависят от выбора параметра k . Неверный выбор значения k может сделать модель либо слишком чувствительной к шуму, либо сглаживать границы между классами. Во-вторых, вычислительные затраты при использовании k NN могут быть высокими, т. к. на этапе предсказания требуется вычисление расстояний до всех объектов тренировочного набора, что делает алгоритм медленным и ресурсоемким на больших объемах данных. Наконец, k NN чувствителен к масштабу при-

знаков, из-за чего необходимо проводить предварительную нормализацию или стандартизацию данных, чтобы различие в масштабах признаков не искажило результаты.

Выбор между SVM и k NN должен основываться на характеристиках набора данных и специфике задачи. SVM является предпочтительным для обработки больших и сложных данных с высоким числом признаков, тогда как k NN более применим для небольших и легко интерпретируемых задач. Таким образом, применение каждого алгоритма должно быть тщательно обосновано с учетом требований к эффективности, интерпретируемости и доступным вычислительным ресурсам.

Не менее важно применение техники CLAHE, которая улучшает визуализацию как крупных структур, так и мелких патологических изменений на изображении. Благодаря ей алгоритмы машинного обучения способны точнее анализировать и классифицировать изображения. Также существенное значение имеет извлечение и использование текстурных характеристик, например GLCM. Это позволяет значительно повысить точность классификации, т. к. алгоритмы получают детальную информацию о структуре изображения.

Сравнение наших результатов с данными предыдущих исследований подтверждает, что анализ текстурных характеристик действительно эффективен для автоматизированной диагностики ОА. Например, использование GLCM для классификации ОА коленного сустава уже показало свою эффективность. Наше исследование дополняет предыдущие работы за счет внедрения специализированного алгоритма обработки изображений, включающего CLAHE и метод определения центральной части суставной полости. Эти дополнительные этапы повышения точности извлечения текстурных характеристик улучшили качество классификации.

Примеры эффективного использования GLCM. Использование GLCM в предыдущих исследованиях продемонстрировало значительные успехи в медицинской диагностике. Например, работа, посвященная диагностике ОА коленного сустава, показала, что GLCM позволяет эффективно классифицировать степени заболевания, особенно при сравнении с традиционными методами анализа изображений [8]. Другие исследования описывали применение GLCM для анализа текстур тканей в онкологии, где этот метод помог улучшить точность обнаружения раковых клеток. Эти примеры подтверждают эффективность GLCM в задачах медицинской диагностики, что подкрепляет наши выводы о его применении для анализа наличия патологии плечевого сустава.

CLAHE и его преимущества. Включение CLAHE в наше исследование имело ключевое значение для улучшения визуализации структур и мелких патологических изменений на рентгенограммах [14, 15]. CLAHE помогает избежать проблем, связанных с однородным улучшением контраста, таких

как потеря деталей в участках с высоким контрастом. Улучшенная визуализация позволяет алгоритмам машинного обучения точнее извлекать текстурные признаки, что в итоге повышает точность классификации. Это преимущество CLANE подтверждено в ряде предшествующих исследований, где использование этого метода приводило к повышению качества изображений и улучшению результатов диагностического анализа.

Ограничения исследования. Несмотря на полученные положительные результаты, наше исследование имеет определенные ограничения. Во-первых, размер выборки составил всего 31 рентгенограмму, что ограничивает возможность экстраполяции результатов на всю популяцию пациентов с ОА плечевого сустава [16]. Малая выборка не позволяет полностью учесть разнообразие физиологических и патологических состояний, что может привести к смещению и несоответствию результатов в более широкой клинической практике. В предыдущих работах [14, 15] также отмечалось, что увеличение размера выборки положительно влияет на точность и надежность моделей машинного обучения, что подчеркивает необходимость расширения выборки в дальнейшем. Во-вторых, качество исходных изображений варьировалось в зависимости от нестандартизированного протокола их получения, что могло повлиять на результаты. Для устранения этого ограничения в будущем стоит разработать стандартизированные протоколы получения рентгенограмм, что позволит минимизировать вариабельность и повысить достоверность результатов.

Рекомендации для дальнейших исследований. Для дальнейших исследований рекомендуется увеличить размер выборки и использовать комбинированные алгоритмы машинного обучения. Бóльшая выборка позволит лучше охарактеризовать разнообразие случаев ОА и повысить обобщающую способность модели. Применение комбинированных алгоритмов, таких как ансамбль методов машинного обучения, может помочь увеличить точность и устойчивость классификации. Также важно изучить влияние различных методов предварительной обработки изображений на качество классификации. Исследования показали, что разные методы предварительной обработки могут значительно влиять на извлечение текстурных признаков и, следовательно, точность диагнозов [4, 5, 8]. Например, использование различных техник фильтрации, алгоритмов улучшения контрастности и методов сегментации может улучшить качество изображений и повысить точность моделей машинного обучения в клинической практике.

Особое внимание также стоит уделить разработке и внедрению методов автоматизированного анализа, способных адаптироваться к различным стадиям ОА, что позволит создать более точные и индивидуализированные диагностические инструменты. Это включает в себя исследование новых текстурных характеристик, которые могут быть специфичны для определенных стадий заболевания, а также тестирование различных комбинаций характе-

ристик для улучшения качества классификации.

Заключение

Предложенный алгоритм, основанный на анализе текстурных характеристик рентгеновских снимков плечевого сустава с использованием GLCM, демонстрирует высокую точность классификации ОА. Метод обладает потенциалом для автоматизированной диагностики, что может существенно упростить и ускорить процесс диагностики заболевания. Однако необходимо продолжить исследования для совершенствования алгоритма и его адаптации к различным анатомическим особенностям плечевого сустава.

Список источников

1. Role of Global Femoral Cartilage in Assessing Severity of Primary Knee Osteoarthritis / N. F. W. Khalil, S. El-sherif, M. M. A. El Hamid [et al.] // *Egyptian Rheumatology and Rehabilitation*. 2022. Vol. 49, Iss. 1, Art. No. 16. DOI: <https://doi.org/10.1186/s43166-022-00115-3>.
2. Imaging of the Acromioclavicular Joint: Anatomy, Function, Pathologic Features, and Treatment / D. V. Flores, P. K. Goes, C. M. Gómez [et al.] // *RadioGraphics*. 2020. Vol. 40, No. 5. P. 1355–1382. DOI: <https://doi.org/10.1148/rg.2020200039>.
3. Выбор метода использования регионарной анестезии плечевого сплетения межлестничным доступом при артроскопических операциях на плечевом суставе / С. В. Крылов, И. Н. Пасечник, М. В. Капырина, К. Ю. Уколов // *Уральский медицинский журнал*. 2019. № 7. С. 138–144. EDN: <https://elibrary.ru/vrukpu>.
4. Diagnostics of Articular Cartilage Damage Based on Generated Acoustic Signals Using ANN — Part II: Patellofemoral Joint / R. Karpiński, P. Krakowski, J. Jonak [et al.] // *Sensors*. 2022. Vol. 22, Iss. 10, Art. No. 3765. DOI: <https://doi.org/10.3390/s22103765>.
5. Diagnostics of Articular Cartilage Damage Based on Generated Acoustic Signals Using ANN — Part I: Femoral-Tibial Joint / R. Karpiński, P. Krakowski, J. Jonak [et al.] // *Sensors*. 2022. Vol. 22, Iss. 6, Art. No. 2176. DOI: <https://doi.org/10.3390/s22062176>.
6. Крылов В. А. Хирургия плечевого сустава в условиях травматологического отделения многопрофильной ЦГБ малого города // *Уральский медицинский журнал*. 2022. Т. 21, № 2. С. 97–100. DOI: <https://doi.org/10.52420/2071-5943-2022-21-2-97-100>.
7. Association Between Pain and Radiological Changes in Patients with Knee Osteoarthritis / A. Munawar, M. M. A. Durrani, M. W. Akhtar [et al.] // *Journal of Health and Rehabilitation Research*. 2024. Vol. 4, Iss. 1. P. 608–612. DOI: <https://doi.org/10.61919/jhrr.v4i1.406>.
8. AB1174 Knee Symptoms are More Strongly Associated with Quadriceps

- Muscle Strength than Grip Strength or Muscle Mass: The Road Study / S. Muraki, T. Akune, H. Oka [et al.] // *Annals of the Rheumatic Diseases*. 2015. Vol. 74, Suppl. 2. P. 1295–1296. DOI: <https://doi.org/10.1136/annrheumdis-2015-eular.2961>.
9. LIFEx: A Freeware for Radiomic Feature Calculation in Multimodality Imaging to Accelerate Advances in the Characterization of Tumor Heterogeneity / C. Nioche, F. Orlhac, S. Boughdad [et al.] // *Cancer Research*. 2018. Vol. 78, Iss. 16. P. 4786–4789. DOI: <https://doi.org/10.1158/0008-5472.CAN-18-0125>.
 10. Andrade D., Gifford H., Das M. Multi-modality GLCM Image Texture Feature for Segmentation and Tissue Classification // *Medical Imaging 2023 : Physics of Medical Imaging : Proceedings* / Ed. by R. Fahrig, J. M. Sabol, L. Yu. SPIE, 2023. P. 124634P. Vol. 12463. DOI: <https://doi.org/10.1117/12.2659078>.
 11. Husain A., Vishvakarma V. P. RES-KELM Fusion Model Based on Non-iterative Deterministic Learning Classifier for Classification of Covid19 Chest X-Ray Images // *Journal of Intelligent Systems*. Vol. 32, Iss. 1, Art. No. 20220235. DOI: <https://doi.org/10.1515/jisys-2022-0235>.
 12. Лечебная физкультура при повреждении ротаторной манжеты плеча / Д. Н. Бобунов, В. Д. Михайлов, М. С. Овсянников [и др.] // *Уральский медицинский журнал*. 2019. № 14. С. 92–99. EDN: <https://elibrary.ru/iaegcp>.
 13. Kaur P. P., Singh S. Classification of Herbal Plant and Comparative Analysis of SVM and KNN Classifier Models on the Leaf Features Using Machine Learning // *Soft Computing for Intelligent Systems* / Ed. by N. Marriwala, C. C. Tripathi, S. Jain, S. Mathapathi. Singapore : Springer, 2021. P. 227–239. DOI: https://doi.org/10.1007/978-981-16-1048-6_17.
 14. Balasubramanian K., Kishore R., Krishnamoorthy G. D. Optimal Knee Osteoarthritis Diagnosis Using Hybrid Deep Belief Network Based on Swarm Optimization Method // *Concurrency and Computation: Practice and Experience*. 2022. Vol. 34, Iss. 13, Art. No. e6913. DOI: <https://doi.org/10.1002/cpe.6913>.
 15. Messaoudene K., Harrar K. Computerized Diagnosis of Knee Osteoarthritis from X-Ray Images Using Combined Texture Features: Data from the Osteoarthritis Initiative // *International Journal of Imaging Systems and Technology*. 2024. Vol. 34, Iss. 2, Art. No. e23063. DOI: <https://doi.org/10.1002/ima.23063>.
 16. AI-Assisted Tuberculosis Detection and Classification from Chest X-Rays Using a Deep Learning Normalization-Free Network Model / V. Acharya, G. Dhiman, K. Prakasha [et al.] // *Computational Intelligence and Neuroscience*. 2022. Vol. 2022, Art. No. 2399428. DOI: <https://doi.org/10.1155/2022/2399428>.

Информация об авторах

Александр Андреевич Жиляков[✉] — студент лечебно-профилактического факультета, Уральский государственный медицинский университет (Екатеринбург, Россия). E-mail: alexandrusma@mail.ru. ORCID: <https://orcid.org/0000-0002-5251-0411>.

Елена Александровна Волокитина — доктор медицинских наук, профессор, заведующий кафедрой травматологии и ортопедии, Уральский государственный медицинский университет (Екатеринбург, Россия). E-mail: volokitina_elena@rambler.ru. ORCID: <https://orcid.org/0000-0001-5994-8558>.

Information about the authors

Aleksandr A. Zhiljakov[✉] — Specialist's Degree Student of the Faculty of General Medicine, Ural State Medical University (Ekaterinburg, Russia). E-mail: alexandrusma@mail.ru. ORCID: <https://orcid.org/0000-0002-5251-0411>.

Elena A. Volokitina — Doctor of Sciences (Medicine), Professor, Head of the Department of Traumatology and Orthopedics, Ural State Medical University (Ekaterinburg, Russia). E-mail: volokitina_elena@rambler.ru. ORCID: <https://orcid.org/0000-0001-5994-8558>.