

УДК 004.932

DOI: [10.26102/2310-6018/2021.33.2.012](https://doi.org/10.26102/2310-6018/2021.33.2.012)

Нейросетевые решения на основе архитектуры U-Net для автоматической сегментации хрящевой ткани лучезапястного сустава на МР изображениях

Е.А. Бруй, Н.А. Владимиров

Университет ИТМО, Санкт-Петербург, Российская Федерация

Резюме: Сегментация хрящевой ткани на трехмерных магнитно-резонансных (МР) изображениях используется в задачах определения стадии дегенеративных и воспалительных заболеваний суставов. Для лучезапястного сустава ручная сегментация является крайне трудоемкой задачей в связи с его сложным устройством. Это обуславливает актуальность разработки полностью автоматических методов сегментации. Единственный предложенный ранее автоматический метод основан на глубоком обучении. Он обеспечивает неоднородную точность сегментации в зависимости от положения среза внутри трехмерного изображения. Целью данной работы является повышение точности автоматической сегментации хрящевой ткани на боковых срезах МР изображений лучезапястного сустава при помощи применения глубоких сверточных нейронных сетей (СНС). В работе рассматривались две архитектуры СНС: классическая U-Net и усеченная версия U-Net, в которой был удален последний блок сверток в пути уменьшения размерности. Точность сегментации была оценена при помощи трехмерного и двумерного коэффициентов Соренсена-Дайса (DSC), а также при помощи расчета площади под кривой точность-полнота (AUC-PR). Результаты сравнивались с опубликованными ранее данными для автоматического метода сегментации хрящевой ткани лучезапястного сустава при помощи СНС, обученной на основе патчей, а также с опубликованными результатами для процедуры ручной сегментации. Использование архитектур на основе U-Net позволило значительно повысить точность автоматической сегментации. Усеченная архитектура U-Net показала наилучшую производительность в терминах времени (0.05 с на срез) и самую высокую точность сегментации (2D DSC=0.77, AUC-PR=0.844) среди рассмотренных СНС для тестовой выборки изображений. Для срезов, не содержащих хрящевую ткань, при использовании данной архитектуры коэффициент DSC повысился от 0.21 до 0.75. Таким образом, переход к использованию архитектуры на основе U-Net обеспечил более однородную сегментацию трехмерных изображений, чем метод с применением сверточной нейронной сети, обучавшейся на основе патчей.

Ключевые слова: глубокое обучение, магнитно-резонансная томография, лучезапястный сустав, хрящевая ткань, остеоартрит, ревматоидный артрит, сегментация

Для цитирования: Бруй Е.А., Владимиров Н.А. Нейросетевые решения на основе архитектуры U-Net для автоматической сегментации хрящевой ткани лучезапястного сустава на МР изображениях. *Моделирование, оптимизация и информационные технологии*. 2021;9(2).
Доступно по: <https://moitvvt.ru/ru/journal/pdf?id=953> DOI: 10.26102/2310-6018/2021.33.2.012.

Neural network solutions based on U-Net architecture for automatic wrist joint cartilage segmentation in MR images

E.A. Brui, N.A. Vladimirov

ITMO University, Saint-Petersburg, Russian Federation

Abstract: Segmentation of cartilage tissue in 3D magnetic resonance (MR) images is used to determine the stage of degenerative and inflammatory joints diseases. For the wrist joint, manual segmentation is of immense complexity task due to its complex structure. It determines the relevance of the development

of fully automatic segmentation methods. The only automated method previously proposed is based on deep learning. It provided non-uniform segmentation accuracy depending on the slice position within the 3D image. This work aims to improve the accuracy of automatic segmentation of cartilage tissue in lateral slices of wrist joint MR images using deep convolutional neural networks (CNN). Two CNN architectures were considered: a classical U-Net architecture and a truncated version of U-Net, in which the last block of convolutions was removed in the way of decreasing the dimension. The segmentation accuracy was assessed using 3D and 2D Sørensen–Dice coefficients (DSC), as well as by calculating the area under the precision-recall curve (AUC-PR). The results were compared with previously published data for an automated method of cartilage segmentation of the wrist joint using a patch-based CNN, as well as with published results for a manual segmentation procedure. The use of U-Net-based architectures has significantly improved the automatic segmentation accuracy. The truncated U-Net architecture showed the best performance in terms of time (0.05 s per slice) and the highest segmentation accuracy (2D DSC = 0.77, AUC-PR = 0.844) among the reviewed CNNs for the test dataset of images. For sections without cartilage, the DSC increased from 0.21 to 0.75 using this architecture. Thus, the use of the U-Net architecture provided more uniform segmentation of 3D images than the method using the patch-based convolutional neural network.

Keywords: deep learning, magnetic resonance imaging, wrist joint, cartilage, osteoarthritis, rheumatoid arthritis, segmentation

For citation: Brui E.A., Vladimirov N.A. Neural network solutions based on U-Net architecture for automatic wrist joint cartilage segmentation on MR images. *Modeling, Optimization and Information Technology*. 2021;9(1). Available from: <https://moitvvt.ru/ru/journal/pdf?id=953> DOI: 10.26102/2310-6018/2021.33.2.012 (In Russ).

Введение

Повреждение хрящевой ткани является ключевым проявлением, как дегенеративных заболеваний суставов, в первую очередь, остеоартрита (ОА), так и хронических воспалительных заболеваний суставов, например, ревматоидного артрита (РА) [1]. Обычные рентгенографические методы позволяют оценивать степень дегенерации хряща лишь опосредованно через сужение суставной щели [2]. В то же время, МРТ обеспечивает контраст мягких тканей, который можно использовать для прямой оценки состояния хряща. По этой причине, МРТ суставов имеет больший потенциал для отслеживания изменений состояния хрящевой ткани во времени и/или для оценки эффективности проводимой терапии, чем рентгенография или компьютерная томография [3]. Измерение сужения суставной щели на МР-изображениях было добавлено в систему RAMRIS (англ. Rheumatoid Arthritis Magnetic Resonance Imaging Scoring System – МРТ Система Оценки Ревматоидного Артрита), с целью включить оценку степени разрушения хрящевой ткани в диагностику РА. Однако, такая методика исследования требует измерения толщины хряща между всеми суставными поверхностями сустава вручную на тщательно выбранном срезе. Для коленного сустава это подразумевает измерение в четырех точках, тогда как для лучезапястного сустава это приводит к пятнадцати измерениям из-за гораздо более сложной структуры сустава по сравнению с коленным. Кроме того, эта оценка обеспечивает только грубое измерение толщины хрящевой ткани в фиксированных точках и, следовательно, не обладает чувствительностью для выявления ранних отклонений.

Для МР-оценки потери хряща в суставах было предложено несколько альтернативных критериев, такие как площадь поперечного сечения хряща [4] и объем хряща [5]. Анализ количественного изменения хрящевой ткани требует точной сегментации изображений. Золотым стандартом применительно к измерению параметров хряща считается ручная сегментация. Однако, ручная сегментация является

очень трудоемкой и утомительной задачей, и ее надежность может ограничиваться разницей подходов между специалистами, которые ее проводят. Для повышения скорости и воспроизводимости сегментации хряща было предложено большое разнообразие компьютерных подходов. Среди них особенный интерес вызывают подходы, основанные на глубоком обучении, которые обеспечивают быструю и надежную сегментацию. Недавно сверточные нейронные сети (СНС) были успешно применены для сегментации хрящевой ткани на МР-изображениях коленного сустава. Такие методы продемонстрировали высокие значения коэффициента подобия Соренсена-Дайса [6] относительно сегментаций, сделанных вручную: 0.82 [7] и 0.91 [8] (для «плоской» архитектуры и для U-Net [10] архитектуры, соответственно). Все это подчеркивает перспективность подходов глубокого машинного обучения для полностью автоматической сегментации структур суставов.

Учитывая высокую эффективность подходов, основанных на СНС, для сегментации структур коленных суставов, было проведено предварительное исследование, чтобы выяснить, могут ли глубокие СНС быть полезными при разработке методов автоматической сегментации хряща лучезапястного сустава [9]. Сегментация хряща лучезапястного сустава на МР-изображениях, проведенная с помощью «плоской» СНС с обучением на основе патчей (PB-CNN) обеспечила эффективную по времени альтернативу ручной сегментации. Тем не менее, данное исследование продемонстрировало неоднородность точности сегментации в зависимости от положения среза МР-изображения в суставе. Наилучшие показатели были достигнуты для срединных поперечных сечений запястья, на которых хрящевая ткань характеризуется наиболее четко определенной и связной структурой. Наихудшие результаты наблюдались в срезах, расположенных вдали от срединного сечения, в которых количество хряща низкое, и он становится менее узнаваемым сетью из-за плохо определенных морфологических признаков. Это привело к снижению точности сегментации для всего трехмерного набора срезов и, как следствие, к ошибке в измерении объема хряща.

Целью настоящей работы является повышение точности автоматической сегментации хрящевой ткани на боковых срезах МР-изображений лучезапястного сустава. Для этой цели в качестве основы была использована архитектура нейронной сети U-Net, хорошо зарекомендовавшая себя в трехмерной сегментации изображений коленного сустава [8].

Методы и материалы.

В качестве обучающей и тестовой выборки была использована база из 20-ти маркированных трехмерных МР-изображений (импульсная последовательность 3D VIBE, поле обзора - 97 x 120 мм², размер матрицы - 260 x 320), полученная ранее в рамках разработки «плоской» СНС [9]. Всего для обучения использовалось 284 оригинальных корональных среза. Двумерные изображения были обрезаны до размера 256x256. Далее к данным изображениям применялись методы аугментации для увеличения гетерогенности обучающих данных. Использовались четыре типа преобразований: вертикальное отображение, горизонтальное отображение, поворот на произвольный угол, и искажение сетки. Такая аугментация позволила увеличить обучающий набор данных до 1136 изображений. 7% этих изображений были использованы для валидации тренировочного процесса и расчета функции потерь. Другой набор из 10-ти трехмерных изображений, содержащий 260 двумерных срезов, был использован для тестирования сети.

В настоящем исследовании для автоматической сегментации хряща лучезапястного сустава использовались две архитектуры СНС. Первая СНС была основана на классической архитектуре U-Net. Особенностью данной архитектуры является обработка всего изображения целиком [10]. Учитывая небольшое количество обучающих данных, в архитектуру были добавлены слои исключения (dropout) и шума (noise), для того чтобы избежать переобучения. Для сокращения времени обучения в архитектуру были добавлены слои пакетной нормализации (batch normalization). Такие параметры, как вероятность исключения, уровень шума, коэффициент скорости обучения и размер пакета были оптимизированы путем поиска по сетке параметров. Для обучения была использована логарифмическая функция потерь (кросс-энтропия). В качестве второго варианта архитектуры была рассмотрена усеченная версия U-Net. В отличие от оригинальной сети, в ней был удален последний блок сверток в пути уменьшения размерности, что сделало СНС менее глубокой, но в то же время уменьшило количество обучаемых параметров, что обычно является полезным при обучении на ограниченном количестве данных. Усеченная U-Net обучалась с теми же параметрами, что и классическая, кроме вероятности исключения и уровня шума, которые были скорректированы.

Все СНС были созданы на языке Python 3.6.4, с использованием библиотек нейронных сетей с открытым исходным кодом TensorFlow 1.7.0 и Keras 2.1.5. Обучение проводилось на рабочей станции с графическим процессором Nvidia Tesla K80, тестирование проводилось на персональном компьютере с графическим процессором Nvidia GTX 1050.

Маски хряща, полученные нейронными сетями при обработке тестового набора данных, сравнивались с соответствующими масками, полученными в результате предварительной разметки врачом-рентгенологом вручную [9]. Соответствующие коэффициенты подобия Соренсена-Дайса (DSC) [6] были рассчитаны для каждого из трехмерных изображений в целом (3D DSC) и на послойной основе (2D DSC). Далее, как было предложено ранее [9], среднее значение 2D DSC вычислялось для каждой из 4-х зон: зона № 1 охватывала срезы, не содержавшие хрящ, зона № 2 охватывала боковые срезы с относительным количеством хряща (относительно срединного среза этого трехмерного изображения, содержавшего максимальное количество хряща) от 0 до 33%, зона № 3 - от 34% до 66%, и зона № 4 - от 67% до 100%. Отдельно рассматривались срединные срезы, которые ранее было предложено использовать для измерения площади поперечного сечения хрящевой ткани сустава [4]. Эти результаты сравнивались с соответствующими результатами для разработанной ранее «плоской» СНС [9]. Точность сегментации на срединных срезах сравнивали также с опубликованными результатами процедуры ручной сегментации [9].

Также в качестве дополнительной метрики точности сегментации был рассчитан параметр AUC-PR (англ. area under the curve precision-recall - площадь под кривой точность-полнота). Под точностью подразумевается количество верно классифицированных пикселей из общего количества пикселей классифицированных, как хрящ. Под полнотой подразумевается количество верно классифицированных пикселей из общего количества пикселей хряща.

Результаты

Оптимальные параметры обучения, которые обеспечили наивысшую точность сегментации при обучении сети U-Net, были следующими: размер пакета - 32, скорость обучения - $0.5e-3$, уровень шума - 0.3, вероятность исключения - 0.4. Финальная

архитектура сети представлена на Рисунке 1(а). Для усеченной сети U-Net оптимальный уровень шума составлял 0.2, а вероятность исключения – 0.35. Архитектура усеченной U-Net изображена на Рисунке 1(б).

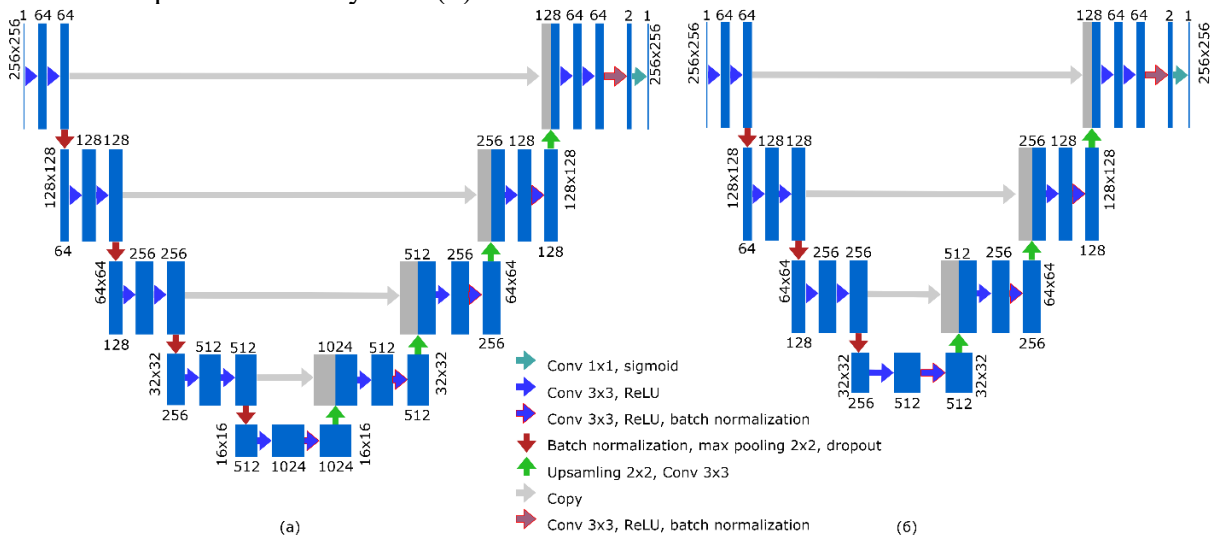


Рисунок 1 – Исследуемые архитектуры нейронных сетей: (а) классическая архитектура U-Net; (б) усеченная версия U-Net, в которой удален последний блок свертки в пути уменьшения размерности.

Figure 1 – The studied architectures of neural networks: (a) classical U-Net architecture; (b) truncated version of U-Net, in which the deepest block of convolutions has been removed.

Результаты сегментации изображений на позоновой основе для предлагаемых нейронных сетей и для «плоской» сети представлены в Таблице 1.

Таблица 1 – Коэффициент Соренсена-Дайса (DSC), усредненный по зонам с разным процентным содержанием хрящевой ткани. Коэффициент рассчитан для масок хрящевой ткани, полученных при помощи предложенных в настоящей работе нейронных сетей, в сравнении с нейронной сетью на основе патчей [9]

Table 1 – Sorensen-Dice coefficient (DSC), averaged over zones with different percentage of cartilage tissue. The coefficient is calculated for masks of cartilage tissue obtained using the neural networks proposed in this work, in comparison with the patch-based neural network [9]

Зона	#1 (0%)	#2 (0%-33%)	#3 (34%-66%)	#4 (67%-100%)
PB-CNN[9]	0.21	0.60	0.63	0.73
U-Net	0.69	0.70	0.67	0.78
Усеченная U-Net	0.75	0.68	0.70	0.80

Точность сегментации при помощи обеих сетей на основе U-Net была выше, чем у сети на основе патчей для всех зон. Особенно выросла точность сегментации для боковых зон, которые содержали меньше хрящевой ткани. Таким образом, эти сети обеспечивали более однородную точность сегментации трехмерного изображения. Пример сегментации обеими исследуемыми сетями различных срезов из одного трехмерного изображения представлен на Рисунке 2.

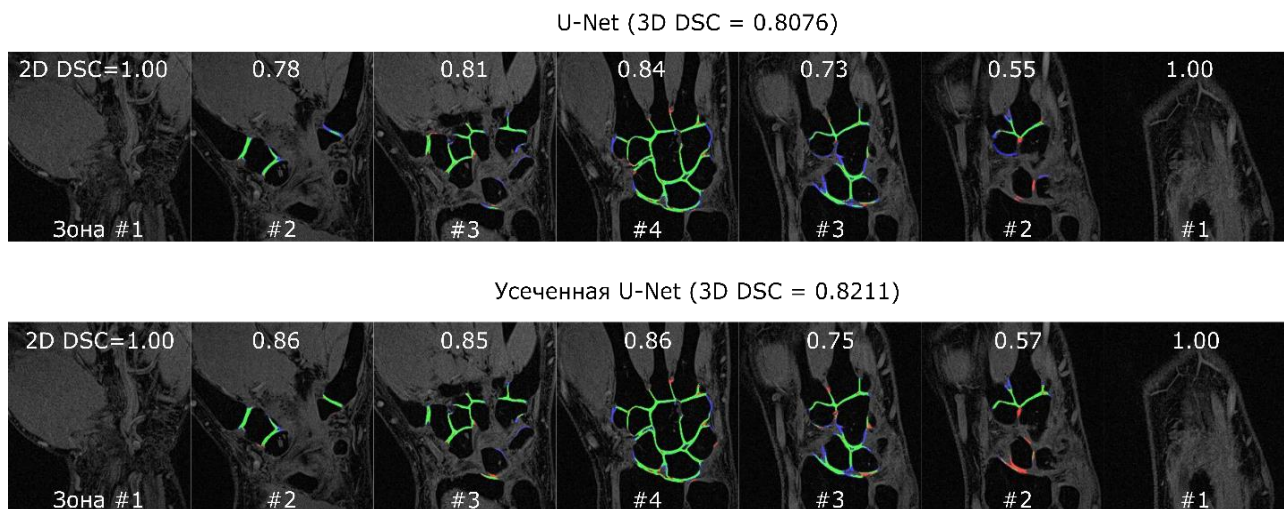


Рисунок 2 – Иллюстрация работы нейронных сетей на примере нескольких слоев одного трехмерного изображения: верхний ряд – для архитектуры U-Net, нижний – для усеченной архитектуры U-Net. 3D DSC – трехмерный коэффициент Соренсена-Дайса для трехмерной маски хряща при сравнении с данными ручной сегментации. В верхней части каждого изображения указан двумерный DSC для маски хряща на соответствующем срезе. В нижней части каждого изображения указана зона, к которой оно относится. Зеленым отмечены пиксели, верно, классифицированные как хрящ, красным – неверно классифицированные как хрящ, синим - неверно классифицированные как фон.

Figure 2 – An illustration of performance of neural networks on several layers of one three-dimensional image: the upper row is for the U-Net architecture, the lower one is for the truncated U-Net architecture. 3D DSC - 3D Sorensen-Dice coefficient for 3D cartilage mask when compared with manual segmentation data. At the top of each image is the 2D DSC for the cartilage mask on the corresponding slice. The zone to which it belongs is indicated at the bottom of each image. Green indicates pixels that are correctly classified as cartilage, red is for the pixels incorrectly classified as cartilage, and blue - for incorrectly classified as background.

Усредненное по набору тестовых данных значение коэффициента 3D DSC, а также усредненное значение 2D DSC для срединных срезов получилось самым высоким в случае использования усеченной U-Net: 0.77 и 0.85, соответственно (Таблица 2).

Результаты сегментации срединных срезов при использовании усеченной архитектуры U-Net (2D DSC=0.85) оказались сравнимы с результатами ручной сегментации [9], считающейся эталонным методом: ранее было показано, что коэффициент 2D DSC между масками хряща лучезапястного сустава, полученными двумя разными экспертами-рентгенологами варьировался в промежутке от 0.78 до 0.88, а при сегментации одним и тем же экспертом с промежутком между сессиями сегментации в одну неделю – 0.90. Усеченная U-Net также показала лучшую производительность по времени (Рисунок 2) – 0.05 с на срез. Дополнительная характеристика точности сегментации – AUC-PR – также была выше для этой архитектуры, чем для классической U-Net: для набора тестовых данных – 0.844, для набора срединных срезов – 0.929.

Таблица 2 – Результаты сегментации хрящевой ткани на МР изображениях лучезапястного сустава при помощи рассмотренных в настоящей работе нейронных сетей, в сравнении с нейронной сетью на основе патчей [9], а также с процедурой ручной сегментации [9]. DSC – коэффициент Соренсена-Дайса. AUC-PR - площадь под кривой точность-полнота.

Table 2 – Results of cartilage tissue segmentation on MR images of the wrist joint using the neural networks considered in this work in comparison with the patch-based neural network [9], as well as with manual procedures [9]. DSC is the Sorensen-Dice coefficient. AUC-PR is the area under the precision-recall curve.

Метод	Средний 3D DSC на всем тестовом наборе	Средний 2D DSC на срединных срезах	AUC-PR на всем тестовом наборе	AUC-PR на срединных срезах	Количество обучаемых параметров	Время обучения	Время обработки одного изображения
U-Net	0.75	0.83	0.824	0.907	$34.5 \cdot 10^6$	1.7 ч	0.09 с
Усеченная U-Net	0.77	0.85	0.844	0.929	$8.6 \cdot 10^6$	1 ч	0.05 с
PВ-CNN [9]	0.69	0.81	-	-	$72.5 \cdot 10^3$	74.4 ч	1.28 с
Ручной интер-врачебный [9]	-	0.78 - 0.88	-	-	-	-	300 с
Ручной интра-врачебный [9]		0.90					

Обсуждение

Полученные результаты показали, что усеченная U-Net является лучшим кандидатом среди исследованных сетей на роль автоматического инструмента для измерения объема хряща запястья на изображениях 3D VIBE. Для дальнейшего повышения точности сегментации авторы работы планируют перейти к трехмерному варианту усеченной U-Net, который может позволить использовать трехмерные особенности хрящевой ткани лучезапястного сустава для ее более точного распознавания нейронной сетью.

Ограничением данного исследования является обучение нейронных сетей на основе ограниченного количества данных, полученных в одном медицинском учреждении на одном магнитно-резонансном томографе. Для обеспечения устойчивости метода к различным изменениям входных данных (пространственное разрешение, локализация сустава на изображении, контраст тканей), необходимо использовать для обучения данные, полученные в различных медицинских организациях.

Заключение

В настоящем исследовании мы сравнили архитектуру U-Net и ее усеченный вариант с ранее описанной «плоской» сверточной нейронной сетью, обученной на основе патчей, в качестве автоматических инструментов для сегментации хрящевой ткани на трехмерных МР изображениях лучезапястных суставов. Переход к использованию архитектуры U-Net вместе с аугментацией обучающих данных

обеспечил улучшенную и более однородную точность сегментации трехмерных изображений, чем метод, предложенный ранее. Усеченная архитектура U-Net показала наилучшую производительность в терминах времени и точности сегментации.

Благодарности

Работа поддержана Российским Научным Фондом (номер гранта 18-79-10167)

ЛИТЕРАТУРА

1. Pap T., Korb-Pap A. Cartilage damage in osteoarthritis and rheumatoid arthritis—two unequal siblings. *Nature Reviews Rheumatology*. 2015;11(10):606–615. <https://10.1038/nrrheum.2015.95>
2. Moser T., Dosch J., Moussaoui A., Buy X., Gangi A., Dietemann J. Multidetector CT arthrography of the wrist joint: How to do it. *RadioGraphics*. 2008;28(3):787–800. DOI:10.1148/rg.283075087
3. Li A.E., Lee S.K., Rancy S.K., Burge A.J., Potter H.G., Wolfe S.W. Comparison of magnetic resonance imaging and radiographs for evaluation of carpal osteoarthritis. *Journal of Wrist Surgery*. 2017;6(2):120-125. DOI:10.1055/s-0036-1592140
4. Zink J.V., Souteyrand P., Guis S., Chagnaud C., Fur Y.L., Militianu D., et al. Standardized quantitative measurements of wrist cartilage in healthy humans using 3T magnetic resonance imaging. *World journal of orthopedics*. 2015;6(8):641-648. <https://doi:10.5312/wjo.v6.i8.641>
5. Peterfy C.G., van Dijke C.F., Lu Y., Nguyen A., Connick T.J., Kneeland J.B., et al. Quantification of the volume of articular cartilage in the metacarpophalangeal joints of the hand: accuracy and precision of three-dimensional MR imaging. *American Journal of Roentgenology*. 1995;165(2):371–375. <https://10.2214/ajr.165.2.7618560>
6. Dice L.R. Measures of the Amount of Ecologic Association Between Species. *Ecology*. 1945;26(3):297-302.
7. Prasoon A., Petersen K., Igel C., Lauze F., Dam E., Nielsen M. Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural network. *Advanced Information Systems Engineering*. 2013;16(2):246-53. https://10.1007/978-3-642-40763-5_31
8. Panfilov E., Tiulpin A., Juntunen M., Casula V., Nieminen M., Saarakkala S. Automatic knee cartilage and menisci segmentation from 3D-DESS MRI using deep semi-supervised learning. *Osteoarthritis and Cartilage*. 2019;27(1):390–391. DOI:10.1016/j.joca.2019.02.391
9. Brui E., Efimtcev A.Y., Fokin V.A., Fernandez R., Levchuk A.G., Ogier A.C., et al. Deep learning-based fully automatic segmentation of wrist cartilage in MR images. *NMR in Biomedicine*. 2020;33(8):1-13. DOI:10.1002/nbm.4320
10. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *MICCAI 2015. Lecture Notes in Computer Science*. 2015;9351:234-241. DOI:10.1007/978-3-319-24574-4_28

REFERENCES

1. Pap T., Korb-Pap A. Cartilage damage in osteoarthritis and rheumatoid arthritis—two unequal siblings. *Nature Reviews Rheumatology*. 2015;11(10):606–615. <https://10.1038/nrrheum.2015.95>

2. Moser T., Dosch J., Moussaoui A., Buy X., Gangi A., Dietemann J. Multidetector CT arthrography of the wrist joint: How to do it. *RadioGraphics*. 2008;28(3):787–800. DOI:10.1148/rg.283075087
3. Li A.E., Lee S.K., Rancy S.K., Burge A.J., Potter H.G., Wolfe S.W. Comparison of magnetic resonance imaging and radiographs for evaluation of carpal osteoarthritis. *Journal of Wrist Surgery*. 2017;6(2):120-125. DOI:10.1055/s-0036-1592140
4. Zink J.V., Souteyrand P., Guis S., Chagnaud C., Fur Y.L., Militianu D., et al. Standardized quantitative measurements of wrist cartilage in healthy humans using 3T magnetic resonance imaging. *World journal of orthopedics*. 2015;6(8):641-648. <https://doi.org/10.5312/wjo.v6.i8.641>
5. Peterfy C.G., van Dijke C.F., Lu Y., Nguyen A., Connick T.J., Kneeland J.B., et al. Quantification of the volume of articular cartilage in the metacarpophalangeal joints of the hand: accuracy and precision of three-dimensional MR imaging. *American Journal of Roentgenology*. 1995;165(2):371–375. <https://doi.org/10.2214/ajr.165.2.7618560>
6. Dice L.R. Measures of the Amount of Ecologic Association Between Species. *Ecology*. 1945;26(3):297-302.
7. Prasoon A., Petersen K., Igel C., Lauze F., Dam E., Nielsen M. Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural network. *Advanced Information Systems Engineering*. 2013;16(2):246-53. https://doi.org/10.1007/978-3-642-40763-5_31
8. Panfilov E., Tiulpin A., Juntunen M., Casula V., Nieminen M., Saarakkala S. Automatic knee cartilage and menisci segmentation from 3D-DESS MRI using deep semi-supervised learning. *Osteoarthritis and Cartilage*. 2019;27(1):390–391. DOI:10.1016/j.joca.2019.02.391
9. Brui E., Efimtcev A.Y., Fokin V.A., Fernandez R., Levchuk A.G., Ogier A.C., et al. Deep learning-based fully automatic segmentation of wrist cartilage in MR images. *NMR in Biomedicine*. 2020;33(8):1-13. DOI:10.1002/nbm.4320
10. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *MICCAI 2015. Lecture Notes in Computer Science*. 2015;9351:234-241. DOI:10.1007/978-3-319-24574-4_28
- 11.

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Бруй Екатерина Алексеевна, инженер
Университет ИТМО, Физико-Технический
Факультет, Санкт-Петербург, Российская
Федерация

e-mail: e.brui@metalab.ifmo.ru

ORCID: [0000-0001-8726-3214](https://orcid.org/0000-0001-8726-3214)

Владимиров Никита Александрович, инженер
Университет ИТМО, Физико-Технический
Факультет, Санкт-Петербург, Российская
Федерация

e-mail: nikita.vladimirov@metalab.ifmo.ru

Brui Ekaterina Alekseevna, Engineer,
ITMO University, Department Of Physics
And Engineering, St. Petersburg, Russian
Federation

Vladimirov Nikita Aleksandrovich,
Engineer, ITMO University, Department Of
Physics And Engineering, St. Petersburg,
Russian Federation