ОРИГИНАЛЬНАЯ СТАТЬЯ

ПРАКТИКА ИСПОЛЬЗОВАНИЯ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РАСПОЗНАВАНИЯ ОБРАЗОВ (ПАТТЕРНОВ) СОСТОЯНИЯ ВИСОЧНО-НИЖНЕЧЕЛЮСТНОГО СУСТАВА ПРИ АНАЛИЗЕ ДАННЫХ КОНУСНО-ЛУЧЕВОЙ КОМПЬЮТЕРНОЙ ТОМОГРАФИИ

Чибисова М.А.[1,3], Котина Е.Д.[4], Павлов А.В.[2], Корчагин Д.С.[4], Куюмчьян С.Ю.[3], Придвижкина Т.С.[3], Ильин Ф.Ю.[2], Ермолаева Л.А.[2]

1 – ФГБОУ ВО СЗГМУ им. И.И. Мечникова. г. Санкт-Петербург, Россия.
2 – ФГБОУ ВО СПБГУ, медицинский институт, кафедра терапевтической стоматологии. г. Санкт-Петербург, Россия.
3 – КВМТ им. Н.И. Пирогова ФГБОУ ВО СПБГУ. г. Санкт-Петербург, Россия.
4 – ФГБОУ ВО СПБГУ, Факультет прикладной математики – процессов управления, г. Санкт-Петербург, Россия.

Цель исследования. На основании данных конусно-лучевой компьютерной томографии (КЛКТ) произвести сегментацию, анализ геометрии и паттернов костных структур височно-нижнечелюстного сустава (ВНЧС) при помощи искусственной нейронной сети.

Материалы и методы. В настоящей работе были использованы данные КЛКТ с захватом ВНЧС в открытом и закрытом положении сустава, обработка данных в формате DICOM, экстракция файлов и создание масок для захвата паттернов (образов) геометрии ВНЧС, плотности кортикального и губчатого слоёв сустава и формирование базы данных масок суставного отростка нижней челюсти с целью дальнейшего распознавания нейросетью новых входных данных.

Результаты и обсуждение. Согласно результатам количественной оценки, сегментация суставной головки ВНЧС выполнена с метриками Dice = 0.99 и IoU = 0.98. Для суставной впадины значения метрик составили Dice = 0.79 и IoU = 0.68. Различия между результатами на обучающей и валидационной выборках незначительны, что подтверждается схожими значениями метрик и отсутствием выраженной переадаптации модели к обучающим данным. Визуальный анализ сегментированных масок соответствует количественным показателям и демонстрирует стабильность результатов на различных изображениях. Полученные данные позволяют перейти к следующему этапу – извлечению и анализу геометрических характеристик идентифицированных структур.

Анализ сегментированных масок суставной головки (мыщелкового отростка ветви нижней челюсти) и суставной впадины височной кости предусматривает вычисление геометрических параметров, имеющих диагностическую значимость и применяемых для оценки морфологического состояния височно-нижнечелюстного сустава. Среди таких параметров: высота суставной головки ветви нижней челюсти и суставной ямки височной кости, передний и задний суставные углы, ширина суставной щели и другие показатели линейно-угловых измерений ВНЧС. Эти характеристики являются важными индикаторами состояния височно-нижнечелюстного сустава, поскольку изменения в них могут свидетельствовать о различных заболеваниях.

Заключение. Диагностический потенциал искусственных нейронных сетей, как технологии искусственного интеллекта, несомненно, представляет собой важный и дополнительный элемент для диагностики. Так как интерпретация, чтение данных КЛКТ для врача-стоматолога и описание КЛКТ для врача-рентгенолога требует повышенной внимательности и квалификации соответственно для того, чтобы не допустить диагностических ошибок, при этом, в большинстве случаев необходимо дополнительное «второе мнение» искусственного интеллекта. Однако с внедрением новых технологий специалистам требуется не только их освоение, но и контроль правильности ответов для машинного зрения, поэтому окончательный диагноз и заключение ставится только врачом.

Ключевые слова: искусственная нейронная сеть, паттерн, височно-нижнечелюстной сустав (ВНЧС), конусно-лучевая компьютерная томография (КЛКТ).

Контактный автор: Павлов А.В., e-mail: tlocke@bk.ru

Для цитирования: Чибисова М.А., Котина Е.Д., Павлов А.В., Корчагин Д.С., Куюмчьян С.Ю., Придвижкина Т.С., Ильин Ф.Ю., Ермолаева Л.А. Практика использования искусственных нейронных сетей для распознавания образов (паттернов) состояния височно-нижнечелюстного сустава при анализе данных конусно-лучевой компьютерной томографии. REJR 2025; 15(4):63-74. DOI: 10.21569/2222-7415-2025-15-4-63-74.

Статья получена: 10.02.25 Статья принята: 26.11.25

THE PRACTICE OF USING ARTIFICIAL NEURAL NETWORKS TO RECOGNIZE IMAGES (PATTERNS) OF THE TMJ STATE DURING CBCT

Chibisova M.A.[1,3], Kotina E.D.[4], Pavlov A.V.[2], Korchagin D.S.[4], Kuyumchian S.Yu.[3], Pridvizhkina T.S.[3], Ermolaeva L.A.[2]

1 – I.I. Mechnikov North-Western State Medical University.

2 –Department of Therapeutic, Dentistry Medical Institute, St. Petersburg State University.

3 – N.I. Pirogov high-tech medical clinic, St. Petersburg State University.

4 – Faculty of applied mathematics – operation procedure, St. Petersburg State University. Saint-Petersburg, Russia.

Purpose. To perform segmentation, geometry analysis and patterns of bone structures of the temporomandibular joint (TMJ) based on the data of cone beam computed tomography (CBCT), using an artificial neural network.

Materials and methods. In this work, we used CBCT data with TMJ capture in the open and closed position of the joint, DICOM data processing, file extraction and creation of masks to capture patterns (images) of TMJ geometry, density of cortical and spongy layers of the joint, and the formation of a database of masks of the articular process of the mandible in order to further recognize new input data by the neural network.

Results and discussion. According to the results of the quantitative assessment, the segmentation of the articular head was performed with the metrics Dice = 0.99 and IoU = 0.98. For the articular cavity, the metric values were Dice = 0.79 and IoU = 0.68. The differences between the results in the training and validation samples are insignificant, which is confirmed by similar metric values and the absence of pronounced readjustment of the model to the training data. The visual analysis of segmented masks corresponds to quantitative indicators and demonstrated stability of the results in various images. The data obtained allows us to proceed to the next stage – the extraction and analysis of the geometric characteristics of the identified structures.

The analysis of segmented masks of the articular head (condylar process of the mandibular branch) and the articular cavity of the temporal bone allows calculation of geometric parameters of diagnostic significance and used to assess the morphological state of the temporomandibular joint. These parameters include the height of the articular head of the mandibular branch and the articular fossa of the temporal bone, the anterior and posterior articular angles, the width of the articular fissure, and other indicators of linear angular measurements of the TMJ. These characteristics are important indicators of the condition of the temporomandibular joint, since changes in them may indicate various diseases.

Conclusion. The diagnostic potential of artificial neural networks as artificial intelligence technologies is undoubtedly an important and additional element for diagnostics. Since the interpretation and reading of CBCT data for a dentist and the description of CBT for a radiologist require increased attention and qualifications, respectively, in order to avoid diagnostic errors, in most cases an additional "second opinion" of artificial intelligence is needed. However, with the introduction of new technologies, specialists need not only to master them, but also to control the correctness of machine vision answers, so the final diagnosis and conclusion is made only by a doctor.

Keywords: artificial neural network, pattern, temporomandibular joint, TMJ, cone beam computed tomography, CBCT.

Corresponding author: Pavlov A.V., e-mail: tlocke@bk.ru

For citation: Chibisova M.A., Kotina E.D., Pavlov A.V., Korchagin D.S., Kuyumchian S.Yu., Pridvizhkina T.S., Ermolaeva L.A. The practice of using artificial neural networks to recognize images (patterns) of the TMJ state during CBCT. REJR 2025; 15(4):63-74. DOI: 10.21569/2222-7415-2025-15-4-63-74.

Received: **10.02.25** **Accepted:** **26.11.25**

Височно-нижнечелюстной сустав (ВНЧС) – уникальный парный орган зубочелюстной системы, объединяющий все звенья жевательного аппарата. Сустав нижней челюсти кроме своей парности и сложности перемещения имеет и сложное строение: суставная головка, инконгруентная суставная впадина, капсула сустава и суставной диск [1, 2].

Так как ВНЧС имеет сложную анатомию и физиологически способен компенсировать различные механические изменения зубочелюстной системы, врачам-стоматологам и врача-рентгенологам бывает сложно обнаружить проявления патологии [1-3]. Высокотехнологические методы лучевых исследований в амбулаторной стоматологической практике – КЛКТ и МРТ – позволяют детально рассмотреть мягкие и твёрдые ткани нижнечелюстного сустава [3, 4]. Однако степень изменения тканей ВНЧС бывает сложно распознаваема и человеческим глазом, поэтому для решения вопроса о детекции паттернов или образов патологических изменений можно воспользоваться технологиями искусственного интеллекта [4-6]. Нейросети, позволяющие распознавать, детектировать и дифференцировать паттерны (образы) патологических изменений ВНЧС на трёхмерных лучевых методах исследования помогут врачам-стоматологам и врачам-рентгенологам в систематизации и персонализации подходов к диагностике и планированию лечения пациентов с различными заболеваниями ВНЧС [7-12].

Цель исследования.

На основании данных конусно-лучевой компьютерной томографии (КЛКТ) произвести сегментацию, анализ геометрии и паттернов костных структур височно-нижнечелюстного сустава (ВНЧС) при помощи искусственной нейронной сети.

Материалы и методы.

В настоящей работе были использованы данные КЛКТ челюстно-лицевой области с захватом ВНЧС в открытом и закрытом состоянии, обработка данных в формате DICOM, экстракция файлов и создание масок для захвата паттернов (образов) геометрии ВНЧС, плотности кортикального и губчатого слоёв сустава и формирование базы данных масок суставного отростка нижней челюсти и суставной впадины височной кости с целью дальнейшего распознавания нейросетью новых входных данных. Мы использовали для анализа нейросетью данные КЛКТ зубного ряда и ВНЧС 65 пациентов, среди них 45 женщин и 20 мужчин, в возрасте от 25 до 47 лет. Данные пациенты с различными стоматологическими заболеваниями проходили обследование в амбулаторных учреждениях г. Санкт-Петербурга и Ленинградской области.

Результаты и обсуждение.

Процесс сегментации сталкивается с рядом сложностей. Во-первых, границы между анатомическими структурами на КТ-изображениях не всегда четко различимы, что может затруднить автоматическое выделение нужных областей. Визуальные особенности структур могут варьироваться из-за различий в плотности костной ткани, а также влияния артефактов сканирования. Во-вторых, анатомически невозможно задать универсальный паттерн сегментации, поскольку форма и размеры костных структур различаются у пациентов разного пола и возраста.

Это означает, что даже при ручной разметке возникает определенная степень субъективности при определении границ объектов. В данной статье для решения данной задачи используются методы сегментации на основе нейронных сетей.

Нейросетевые методы позволяют автоматизировать процесс сегментации анатомических структур, ожидается, что это будет способствовать стандартизации диагностики и повышению качества воспроизводимости результатов.

Корректное выделение головки суставного отростка и инконгруентной суставной впадины позволяет проводить последующий количественный анализ, включая измерение плотности тканей (по шкале Хаунсфилда), геометрических характеристик и выявление патологических изменений (рис. 1).

Предобработка данных.

Важной особенностью является работа с данными в формате DICOM, который со-

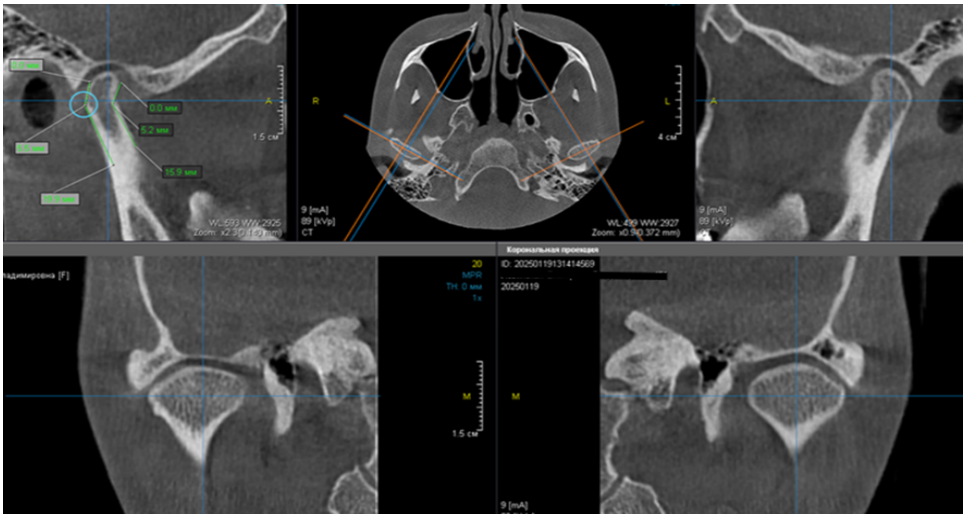

Рис. 1 а (Fig. 1 a)

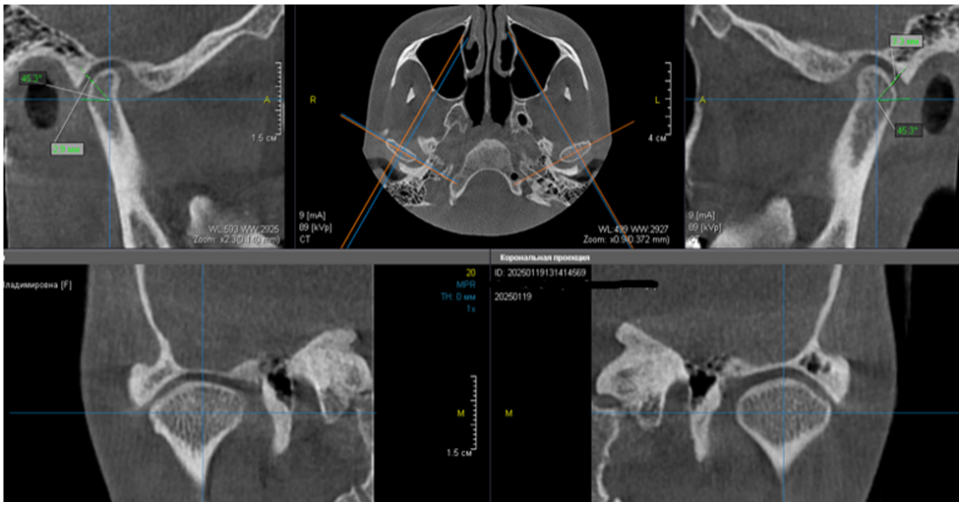

Рис. 1 б (Fig. 1 b)

Рис. 1. КЛКТ височно-нижнечелюстных суставов, сагиттальная и корональная плоскости.

Линейно-угловые измерения размеров ВНЧС с двух сторон: измерения мыщелкового отростка ветви нижней челюсти, суставной впадины височной кости и размеров суставной щели. Пациентка Л., 48 лет.

Fig. 1. CBCT, TMJ, sagittal and coronal planes.

Linear-angular measurements of TMJ sizes from two sides: measurements of the condylar process of mandibular ramus, of the articular fosse of the temporal bone and the size of the joint space. Patient L, 48 years old.

держит не только изображения, но и метаданные, включая параметры сканирования. Обработка таких данных требует предобработки, включая нормализацию интенсивностей и аугментацию для увеличения разнообразия обучающего набора. Ограниченность датасета (базы данных) создает сложности в обучении модели, так как небольшая выборка может привести к переобучению и снижению её способности к обобщению.

Все изображения в датасете приводятся к размеру 512×512, что является стандартной практикой для нейросетевых моделей, поскольку они требуют стандартизированных входных данных. Это не только помогает избежать ошибок при обработке, но и ускоряет процесс обучения. Датасет включает сагиттальные срезы КЛКТ правой и левой части ВНЧС и разделён на три части: 70% данных – для тренировки, 20% – для валидации и 10% – для тестирования, что гарантирует корректную оценку производительности

модели.

Модель сегментации.

Для решения задачи сегментации требуется нейросетевая модель, обладающая высокой точностью сегментации, устойчивостью к вариациям в данных и способностью эффективно работать с небольшими размеченными выборками.

U-Net представляет собой одну из наиболее успешных архитектур для сегментации медицинских изображений. Её ключевые преимущества включают симметричную энкодер-декодерную структуру, обеспечивающую последовательное извлечение и восстановление пространственной информации. Пропускные соединения (skip-connections) между соответствующими слоями энкодера и декодера помогают сохранять детали изображения, что критически важно для точной сегментации анатомических структур. Важным достоинством является эффективность при малом объеме размеченных данных, что делает U-Net особенно ценной для медицинских задач, где разметка затруднена. Гибкость архитектуры позволяет адаптировать такие её параметры, как количество уровней и фильтров, под конкретные условия.

В данной работе реализована модификация U-Net, включающая входной сверточный блок, четыре уровня энкодера и декодера, билинейную интерполяцию или транспонированные свертки для апсемплинга, а также финальный сверточный слой для получения карты сегментации. Входной блок состоит из двойной сверточной операции с нормализацией и активацией LeakyReLU, что улучшает сходимость модели. Энкодер включает последовательность сверток и операций субдискретизации через MaxPool2D, что позволяет сети постепенно извлекать более абстрактные признаки изображения. В декодере применяются транспонированные свертки или билинейная интерполяция для восстановления пространственного разрешения, а пропускные соединения помогают передавать детальные признаки из энкодера. Выходной сверточный слой с ядром 1×1 формирует окончательную карту сегментации.

Несмотря на популярность U-Net, существуют альтернативные подходы к сегментации медицинских изображений. Fully Convolutional Networks (FCN) используют только сверточные слои, что позволяет выполнять сегментацию изображений произвольного размера, но отсутствие симметричной декодерной части и пропускных соединений снижает точность восстановления мелких деталей. DeepLabV3+ улучшает традиционные сверточные сети за счет использования атросных (разреженных) сверток и модуля ASPP (Atrous Spatial Pyramid Pooling), что эффективно работает с высокоуровневыми признаками, но может терять точность на границах объектов. SegNet так же основана на энкодер-декодерной структуре, но использует механизм запоминания индексов макспулинга вместо пропускных соединений, что делает её декодер менее информативным. Современные модели на основе трансформеров, такие как Swin-Unet, обладают высокой мощностью для работы с глобальным контекстом изображения, но требуют значительных вычислительных ресурсов и объемов данных для обучения.

Выбор U-Net обоснован её сбалансированностью между точностью, вычислительной эффективностью и возможностью работы с ограниченными размеченными данными. Её архитектура с энкодером, декодером, пропускными соединениями и сверточными блоками на каждом этапе позволяет эффективно сегментировать анатомические структуры на КТ ВНЧС, делая её обоснованным решением для данной задачи.

Обучение модели.

Современные нейросетевые методы анализа медицинских изображений требуют тщательной настройки процесса обучения. От выбора параметров, функции потерь и метрик оценки зависит не только точность сегментации, но и стабильность работы модели. В данном разделе подробно рассматривается процесс обучения модели U-Net для сегментации суставной головки и инконгруентной суставной впадины ВНЧС, включая выбор гиперпараметров, функции потерь и стратегий нормализации данных.

Процесс обучения нейросетевой модели направлен на минимизацию ошибки предсказаний с использованием градиентного спуска. Реализован полный цикл обучения, включающий тренировку, валидацию, логирование результатов и сохранение чекпойнтов модели. Обучение осуществляется с использованием следующего набора компонентов.

Модель представляет собой архитектуру U-Net, специально разработанную для сегментации медицинских изображений, которая обладает симметричной структурой, состоящей из энкодера и декодера, что позволяет эффективно восстанавливать пространственную информацию. В качестве оптимизатора используется Adam с параметрами: скорость обучения (learning rate) 1e^(-3), параметр весового распада (weight decay) 1e^(-6), а также коэффициенты η_1=0.8, и

η_2=0.999, что позволяет адаптивно корректировать градиенты и ускорять сходимость модели.

Функция потерь представлена модифицированным Dice Loss, который предназначен для многоклассовой сегментации. Он вычисляет коэффициент схожести между предсказанной и истинной масками по формуле:

$$Dice = \frac{2\sum(targets \cdot probas)+\epsilon}{\sum targets+\sum probas+\epsilon},$$

где targets – истинные маски, probas – предсказанные вероятности, ϵ – малое число для предотвращения деления на ноль. Этот подход позволяет учитывать баланс между классами и снижает влияние разницы в размерах сегментируемых областей.

В качестве метрики для оценки качества сегментации используется Intersection over Union (IoU). IoU рассчитывается как отношение площади пересечения предсказанной и истинной маски к их объединенной площади:

$$IoU = \frac{TP}{TP + FP + FN},$$

где TP – количество истинно положительных пикселей, FP – количество ложноположительных пикселей, FN – количество ложноотрицательных пикселей. Данная метрика отражает степень совпадения сегментации с эталонными масками.

Для контроля процесса обучения применяется динамическое изменение скорости обучения, позволяющее избегать застревания в локальных минимумах. Обучение осуществляется батчами, размером 16, при этом для параллельной обработки данных используется 4 рабочих потока. Число эпох обучения составляет 150.

Процесс обучения модели включает перевод модели в режим тренировки, последовательную обработку батчей изображений, вычисление функции потерь, обновление весов с помощью оптимизатора и коррекцию скорости обучения. После каждой эпохи выполняется валидация, в ходе которой модель переводится в режим оценки, отключается вычисление градиентов, и на основе предсказаний вычисляется функция потерь и метрика. Полученные результаты логируются в TensorBoard, что позволяет визуализировать динамику изменения ошибки и качества сегментации. Лучшие веса модели сохраняются в процессе обучения для последующего использования.

Согласно результатам количественной оценки, сегментация суставной головки выполнена с метриками Dice = 0.99 и IoU = 0.98. Для инконгруентной суставной впадины значения метрик составили Dice = 0.79 и IoU = 0.68. Различия между результатами на обучающей и валидационной выборках незначительны, что подтверждается схожими значениями метрик и отсутствием выраженной переадаптации модели к обучающим данным. Визуальный анализ сегментированных масок (рис. 2) соответствует количественным показателям и демонстрирует стабильность результатов на различных изображениях. Полученные данные позволяют перейти к следующему этапу – извлечению и анализу геометрических характеристик идентифицированных структур.

Определение геометрических параметров и текстурный анализ.

Анализ и автоматизация.

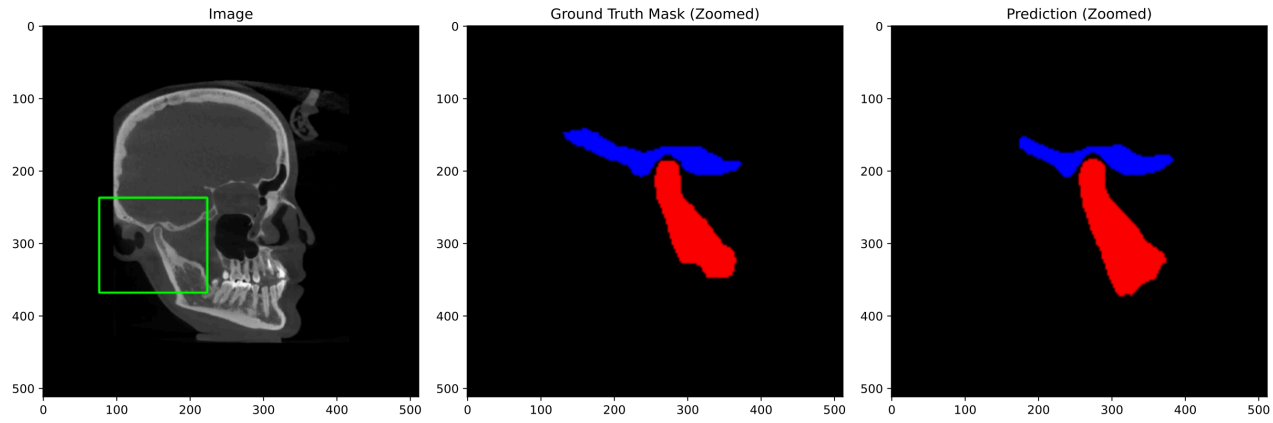

Рис. 2 (Fig. 2)

Рис. 2. Разметка ВНЧС для искусственной нейронной сети. Маска изображения ВНЧС.

Fig. 2. Marking of TMJ for an artificial neural network. TMJ Image Mask.

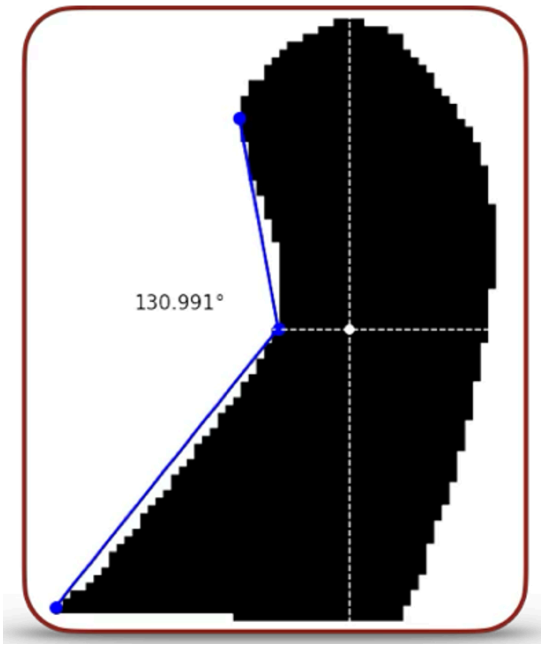

Рис. 3 (Fig. 3)

Рис. 3. Измерение на маске ВНЧС переднего суставного угла.

Fig. 3. Measurement on the TMJ mask of the anterior articular angle.

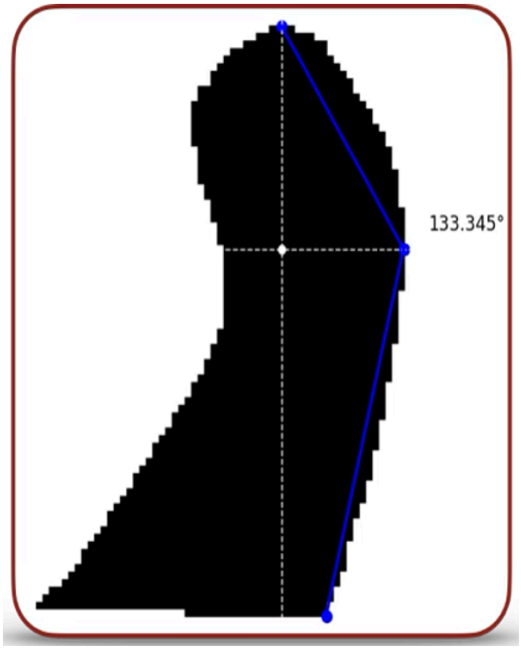

Рис. 4 (Fig. 4)

Рис. 4. Измерение заднего суставного угла на маске ВНЧС.

Fig. 4. Measurement of the posterior articular angle on the TMJ mask.

Автоматизация извлечения геометрических параметров на основе сегментированных изображений значительно повышает объективность и воспроизводимость анализа, снижая зависимость от субъективной оценки специалиста. Такой подход позволяет обрабатывать большие объёмы данных с минимальными временными затратами, что особенно актуально в условиях амбулаторной клинической практики и при проведении масштабных исследований. Использование нейросетевых методов обеспечивает стандартизированную процедуру выделения анатомических структур, на основе которой становится возможным последующее количественное и качественное описание их формы и положения

Анализ сегментированных масок суставной головки и инконгруентной суставной впадины предусматривает вычисление геометрических параметров, имеющих диагностическую значимость и применяемых для оценки морфологического состояния височно-нижнечелюстного сустава. Среди таких параметров – высота головки ветви нижней челюсти и ямки височной кости, передний и задний суставные углы, ширина суставной щели и другие показатели. Эти характеристики являются важными индикаторами состояния височно-нижнечелюстного сустава, поскольку изменения в них могут свидетельствовать о различных заболеваниях.

Высота головки нижней челюсти, например, является одним из основных параметров, определяемых в сагиттальной плоскости. Она измеряется от точки пересечения вертикальной и горизонтальной осей до самой высокой точки головки. Снижение этого показателя может быть связано с дегенеративными изменениями или травмами, в то время как его увеличение может указывать на компенсаторные процессы или аномалии развития. Передний (рис. 3) и задний (рис. 4) суставные углы так же имеют клиническую значимость. Передний угол характеризует положение переднего края головки нижней челюсти, а задний – положение её задней части в отношении ветви нижней челюсти. Эти углы могут изменяться при смещении суставной головки, что важно при диагностике вывихов/подвывихов, гипермобильности и нестабильности сустава. Ширина суставной щели ВНЧС, измеряемая в разных точках сагиттальной плоскости, позволяет судить о симметрии суставных поверхностей и распределении нагрузки. Совокупность указанных и дополнительных геомет-

Таблица №1. Средние значения параметров ВНЧС по данным КЛКТ у мужчин и женщин.

№	Параметр	Женщины		Мужчины	
		M±σ	m	M±σ	m
1	Высота головки нижней челюсти (мм)	6,91±1,30 6,89±1,10	0,28 0,23	7,64±1,07 7,02 ±1,08	0,23 0,24
2	Задний суставной угол (⁰)	128,13±8,18 127,86±7,29	0,81 0,73	R 131,57±9,04 L 129,97±15,82	0,97 1,71
3	Передний суставной угол (⁰)	139,76±12,53 138,54±13,62	1,25 1,36	142,06±12,51 141,86±12,65	1,35 1,36
4	Ширина суставной щели в верхнем отделе (мм)	2,52±0,73 2,46±0,63	0,07 0,06	3,03±0,78 3,10±0,68	0,08 0,07
5	Ширина суставной щели в переднем отделе (мм)	2,12±0,73 2,16±1,18	0,07 0,12	2,31±0,63 2,13±0,62	0,07 0,07

Ссылка: Фадеев Р.А., Чибисова М.А., Овсянников К.А., Прозорова Н.В., Кузакова А.В., Зубарева А.А., Зубарев Д.В., Голубятников М.В. Анализ височно-нижнечелюстного сустава поданным дентальной компьютерной томографии. Ученое пособие. СПбб Человек, 2021. 48 с. [1, 2].

рических параметров используется для выявления воспалительных, деструктивных и диспластических изменений, а также нарушений функции сустава, что имеет решающее значение для постановки диагноза и выбора тактики лечения (табл. №1).

Можно также рассмотреть гистограмму распределения значений единиц Хаунсфилда (HU) в пределах выделенных структур ВНЧС. Гистограмма позволяет оценить структуру костной ткани и может быть использована для выявления таких патологий, как снижение плотности, участки пористости или, наоборот, зоны уплотнения. В дальнейшем такой подход может лечь в основу количественного анализа состояния кости и дифференциальной диагностики.

В приведённых выше клинических случаях с фиксацией геометрии и плотности костной ткани в кортикальном слое и губчатом слое головки и шейки ВНЧС отображены маски и графики плотности в единицах Хаунсфилда (HU) относительной рентгенологической плотности костной ткани (рис. 4 - рис. 8). По данным двух клинических случаев можно сделать выводы о разности плотности костной ткани по данным КЛКТ (экстракция из DICOM-файлов) в кортикальном и губчатом слое. Такая разница, очевидно, выходит из анатомической особенности строения костной ткани ВНЧС. Отметим, что по таким данным геометрии и плотности организации костной ткани в перспективах для врачей-стоматологов и для врачей-рентгенологов создавать и пополнять базы данных по статусу структур ВНЧС для автоматизированного осмотра машинным зрением. Такой подход позволяет клиницистам взглянуть с новых ракурсов на рентгенологическую картину ВНЧС, позволяя в будущем находить закономерности патологических изменений сустава нижней челюсти.

Заключение.

Диагностический потенциал искусственных нейронных сетей, как технологии искусственного интеллекта, несомненно, представляет собой важный и вспомогательный элемент для диагностики. Так как интерпретация или чтение данных КЛКТ требует повышенной внимательности от врача-стоматолога и врача-рентгенолога соответственно для того, чтобы не пропустить патологию и поставить правильный диагноз, при этом в большинстве случаев является оптимальным «второе мнение» искусственного интеллекта. Однако с внедрением новых технологий, специалистам требуется не только их освоение, но и контроль правильности ответов для машинного зрения, поэтому окончательный диагноз и заключение ста

Рис. 5 а (Fig. 5 a)

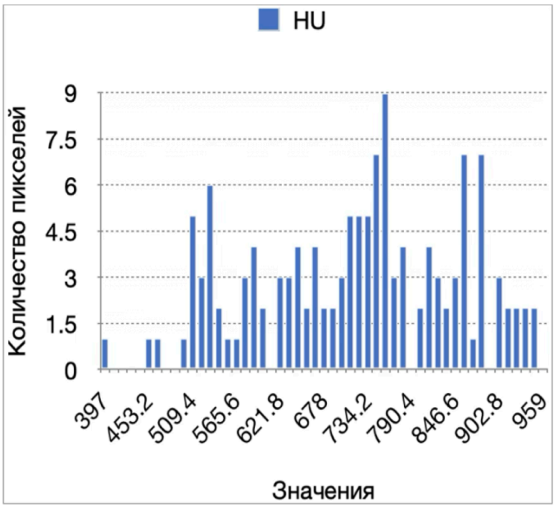

Рис. 5 б (Fig. 5 b)

Рис. 5. **а – КЛКТ, б – диаграмма.**

Измерение плотности костной ткани в кортикальном слое головки височно-нижнечелюстного сустава. Пациентка В., 39 лет.

Fig. 5. **a – CBCT, b – diagram.**

Measurement of bone density in the cortical layer of the head of the temporomandibular joint. Patient V., 39 y.o.

Рис. 6 а (Fig. 6 a)

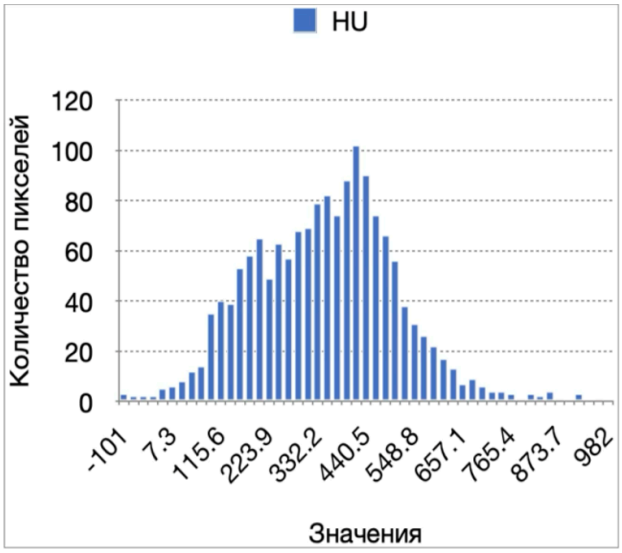

Рис. 6 б (Fig. 6 b)

Рис. 6. **а – КЛКТ, б – диаграмма.**

Измерение плотности костной ткани в губчатом слое головки височно-нижнечелюстного сустава.

Fig. 6. **a – CBCT, b – diagram.**

Measurement of bone density in the spongy layer of the head of the temporomandibular joint.

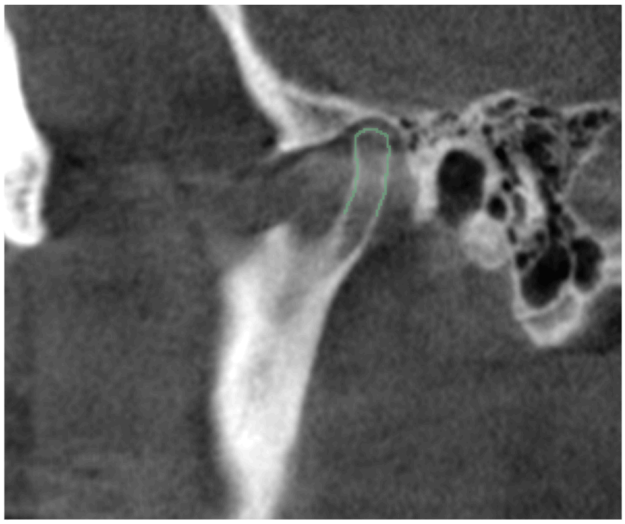

Рис. 7 а (Fig. 7 a)

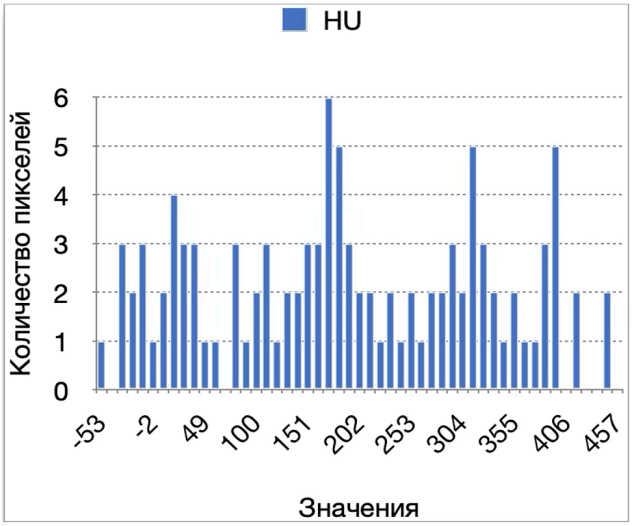

Рис. 7 б (Fig. 7 b)

Рис. 7. **а – КЛКТ, б – диаграмма.**

Измерение плотности костной ткани в кортикальном слое головки височно-нижнечелюстного сустава. Пациент А., 33 года.

Fig. 7. **a – CBCT, b – diagram.**

Measurement of bone density in the cortical layer of the head of he temporomandibular joint. Patient A, 33 y.o.

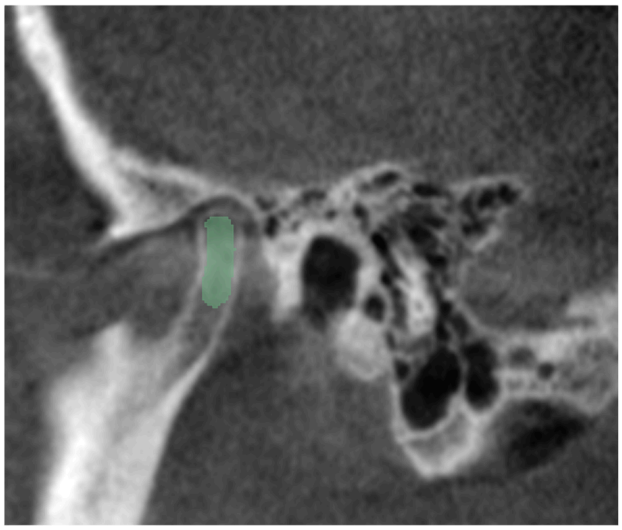

Рис. 8 а (Fig. 8 a)

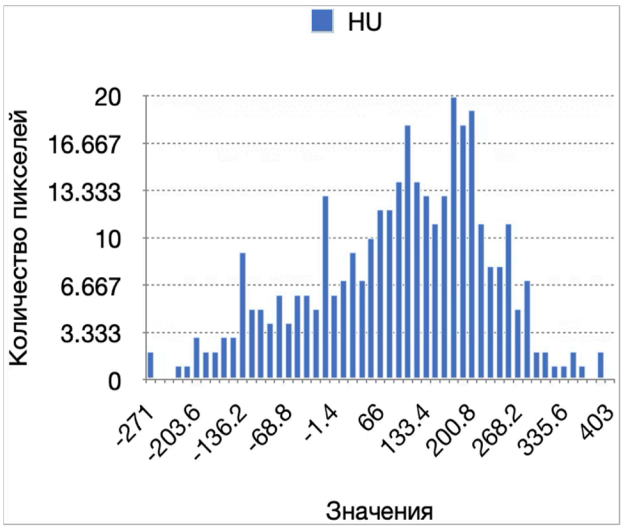

Рис. 8 б (Fig. 8 b)

Рис. 8. **а – КЛКТ, б – диаграмма.**

Измерение плотности костной ткани в губчатом слое головки височно-нижнечелюстного сустава.

Fig. 8. **a – CBCT, b – diagram.**

Measurement of bone density in the spongy layer of the head of the temporomandibular joint.

вится только врачом.

Источник финансирования и конфликт интересов.

Авторы данной статьи подтвердили отсутствие финансовой поддержки исследования и конфликта интересов, о которых необходимо сообщить.

Список литературы:

1. Фадеев Р.А., Чибисова М.А., Зотова Н.Ю., Кузакова А.В. Метод обследования височно-нижнечелюстных суставов с помощью дентальной компьютерной томографии. СПб., ООО «МЕД Издательство», 2016. 24 с.

2. Фадеев Р.А., Чибисова М.А., Овсянников К.А., Прозорова Н.В., Кузакова А.В., Зубарева А.А., Зубарев Д.В., Голубятников М.В. Анализ височно-нижнечелюстного сустава по данным дентальной компьютерной томографии. Ученое пособие. СПб, Человек, 2021. 48 с.

3. Al-Saleh MA, Alsufyani NA, Saltaji H, Jaremko JL, Major PW. MRI and CBCT image registration of temporomandibular joint: a systematic review. J Otolaryngol Head Neck Surg. 2016; 45 (1): 30. Doi: 10.1186/s40463-016-0144-4. PMID: 27164975; PMCID: PMC4863319.

4. Wu M, Almeida FT, Friesen R. A Systematic Review on the Association Between Clinical Symptoms and CBCT Findings in Symptomatic TMJ Degenerative Joint Disease. J Oral Facial Pain Headache. 2021; 35 (4): 332-345. Doi: 10.11607/ofph.2953. PMID: 34990502.

5. Xiong X, Gao X, Zhong J, Hu S, Li Y, Zheng Y, Liu Y. Bibliometric Analysis of Research on Temporomandibular Joint and Occlusion from 2000 to 2022. J Pain Res. 2023; 16: 2847-2860. Doi: 10.2147/JPR.S418362. PMID: 37605745; PMCID: PMC10440111.

6. Zhong J, Gao X, Hu S, Yue Y, Liu Y, Xiong X. A worldwide bibliometric analysis of the research trends and hotspots of bruxism in adults during 1991-2021. J Oral Rehabil. 2024; 51 (1): 5-14. Doi: 10.1111/joor.13577. Epub 2023 Aug 27. PMID: 37635333.

7. Mao WY, Fang YY, Wang ZZ, Liu MQ, Sun Y, Wu HX, Lei J, Fu KY. Automated diagnosis and classification of temporomandibular joint degenerative disease via artificial intelligence using CBCT imaging. J Dent. 2025; 154: 105592. doi: 10.1016/j.jdent.2025.105592. Epub 2025 Jan 25. PMID: 39870190.

8.Аржанцев А.П. Рентгеноскиалогические проявления дисфункциональных и органических изменений в височно-нижнечелюстных суставах. REJR. 2025; 15(1):6-20. DOI: 10.21569/2222-7415-2025-15-1-6-20.

9. Vinayahalingam S, Berends B, Baan F, Moin DA, van Luijn R, Bergé S, Xi T. Deep learning for automated segmentation of the temporomandibular joint. J Dent. 2023; 132: 104475. doi: 10.1016/j.jdent.2023.104475. Epub 2023 Mar 2. PMID: 36870441.

10. Almashraqi AA, Sayed BA, Mokli LK, Jaafari SA, Halboub E, Parveen S, Al-Ak'hali MS, Alhammadi MS. Recommendations for standard criteria for the positional and morphological evaluation of temporomandibular joint osseous structures using cone-beam CT: a systematic review. Eur Radiol. 2024; 34 (5): 3126-3140. doi: 10.1007/s00330-023-10248-4. Epub 2023 Oct 25. PMID: 37878020; PMCID: PMC11126469.

11. Wahidi J, Zuniga JR. Can cone-beam CT evaluation of the temporomandibular joint (TMJ) be the standard criteria for the positional and morphological evaluation of TMJ osseous structures? Eur Radiol. 2024; 34 (5): 3123-3125. doi: 10.1007/s00330-024-10673-z. Epub 2024 Mar 7. PMID: 38451325.

12. Serova N.S., Sokkar A.A., Pavlova O.Yu., Medhat A., Babkova A.A., Israelyan Sh.O., Kuzmenkov D.V. Radiology of tempromandibular joint after the orthodontic treatment. REJR. 2022; 12(2):21-34. DOI: DOI: 10.21569/2222-7415-2022-12-2-21-34.

References:

1. Fadeev R.A., Chibisova M.A., Zotova N.Yu., Kuzakova A.V. Method of examination of temporomandibular joints using dental computed tomography. St. Petersburg, OOO "MED Izdatelstvo", 2016. 24 p. (in Russian).

2. Fadeev R.A., Chibisova M.A., Ovsyannikov K.A., Prozorova N.V., Kuzakova A.V., Zubareva A.A., Zubarev D.V., Golubyatnikov M.V. Analysis of the temporomandibular joint according to dental computed tomography data. Scientific manual. St. Petersburg, Chelovek, 2021. 48 p. (in Russian).

3. Al-Saleh MA, Alsufyani NA, Saltaji H, Jaremko JL, Major PW. MRI and CBCT image registration of temporomandibular joint: a systematic review. J Otolaryngol Head Neck Surg. 2016; 45 (1): 30. Doi: 10.1186/s40463-016-0144-4. PMID: 27164975; PMCID: PMC4863319.

4. Wu M, Almeida FT, Friesen R. A Systematic Review on the Association Between Clinical Symptoms and CBCT Findings in Symptomatic TMJ Degenerative Joint Disease. J Oral Facial Pain Headache. 2021; 35 (4): 332-345. Doi: 10.11607/ofph.2953. PMID: 34990502.

5. Xiong X, Gao X, Zhong J, Hu S, Li Y, Zheng Y, Liu Y. Bibliometric Analysis of Research on Temporomandibular Joint and Occlusion from 2000 to 2022. J Pain Res. 2023; 16: 2847-2860. Doi: 10.2147/JPR.S418362. PMID: 37605745; PMCID: PMC10440111.

6. Zhong J, Gao X, Hu S, Yue Y, Liu Y, Xiong X. A worldwide bibliometric analysis of the research trends and hotspots of bruxism in adults during 1991-2021. J Oral Rehabil. 2024; 51 (1): 5-14. Doi: 10.1111/joor.13577. Epub 2023 Aug 27. PMID: 37635333.

7. Mao WY, Fang YY, Wang ZZ, Liu MQ, Sun Y, Wu HX, Lei J, Fu KY. Automated diagnosis and classification of temporomandibular joint degenerative disease via artificial intelligence using CBCT imaging. J Dent. 2025; 154: 105592. doi: 10.1016/j.jdent.2025.105592. Epub 2025 Jan 25. PMID: 39870190.

8. Arzhantsev A.P. Roentgenosciatic manifestations of dys-

functional and organic changes in the temporomandibular joints. REJR. 2025; 15(1):6-20. DOI: 10.21569/2222-7415-2025-15-1-6-20 (in Russian).

9. Vinayahalingam S, Berends B, Baan F, Moin DA, van Luijn R, Bergé S, Xi T. Deep learning for automated segmentation of the temporomandibular joint. J Dent. 2023; 132: 104475. doi: 10.1016/j.jdent.2023.104475. Epub 2023 Mar 2. PMID: 36870441.

10. Almashraqi AA, Sayed BA, Mokli LK, Jaafari SA, Halboub E, Parveen S, Al-Ak'hali MS, Alhammadi MS. Recommendations for standard criteria for the positional and morphological evaluation of temporomandibular joint osseous structures using cone-beam CT: a systematic review. Eur Radiol. 2024; 34 (5): 3126-3140. doi: 10.1007/s00330-023-10248-4. Epub 2023 Oct 25. PMID: 37878020; PMCID: PMC11126469.

11. Wahidi J, Zuniga JR. Can cone-beam CT evaluation of the temporomandibular joint (TMJ) be the standard criteria for the positional and morphological evaluation of TMJ osseous structures? Eur Radiol. 2024; 34 (5): 3123-3125. doi: 10.1007/s00330-024-10673-z. Epub 2024 Mar 7. PMID: 38451325.

12. Serova N.S., Sokkar A.A., Pavlova O.Yu., Medhat A., Babkova A.A., Israelyan Sh.O., Kuzmenkov D.V. Radiology of tempromandibular joint after the orthodontic treatment. REJR. 2022; 12(2):21-34. DOI: DOI: 10.21569/2222-7415-2022-12-2-21-34.