



ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В АНАЛИЗЕ АНАТОМИИ ВЕРХНЕЧЕЛЮСТНОЙ АРТЕРИИ: ОБОСНОВАНИЕ КОНЦЕПТУАЛЬНОГО ПОДХОДА

Я.Э. Немсцверидзе^{1, 2, 3}, Х.А. Наджафов², Е.Ю. Аносова⁴, Б.И. Яремин^{1, 2}

¹Медицинский университет «Реавиз», ул. Чапаевская, д. 227, г. Самара, 443001, Россия

²Московский медицинский университет «Реавиз», Краснобогатырская ул., д. 2, стр. 2, г. Москва, 107564, Россия

³Московский областной научно-исследовательский клинический институт им. М.Ф. Владимирского, ул. Щепкина, д. 61/2, г. Москва, 129110, Россия

⁴Российский научный центр хирургии имени академика Б.В. Петровского, пер. Абrikосовский, д. 2, г. Москва, 119435, Россия

Резюме. Верхнечелюстная артерия характеризуется значительной анатомической вариабельностью, что создаёт существенные трудности при планировании хирургических вмешательств в челюстно-лицевой области. Традиционные методы предоперационной визуализации требуют значительных временных затрат на интерпретацию данных и зависят от квалификации специалиста. Накопление больших массивов медицинских изображений в формате DICOM создаёт предпосылки для применения методов машинного обучения и глубоких нейронных сетей для автоматизации анализа сосудистых структур. Настоящая работа представляет концептуальное обоснование возможности применения технологий искусственного интеллекта для выявления анатомических вариаций верхнечелюстной артерии на основании анализа данных компьютерной и конусно-лучевой томографии. Проведён анализ современного состояния применения алгоритмов глубокого обучения в медицинской визуализации сосудистых структур головы и шеи, систематизированы известные анатомические вариации верхнечелюстной артерии и их клиническая значимость, сформулированы технические требования к архитектуре потенциальной системы автоматизированного анализа. Предлагаемый концептуальный подход включает использование сверточных нейронных сетей для семантической сегментации сосудистой сети, алгоритмов трёхмерной реконструкции для визуализации топографических взаимоотношений и системы классификации выявленных вариантов строения по степени хирургического риска. Обосновывается необходимость создания специализированной обучающей выборки аннотированных изображений верхнечелюстной артерии для обеспечения высокой точности распознавания. Обсуждаются потенциальные преимущества автоматизированного анализа, включая стандартизацию диагностических подходов, снижение времени предоперационного планирования и минимизацию интраоперационных осложнений, связанных с повреждением сосудов. Признаются существующие технические и организационные ограничения внедрения подобных систем, включая необходимость валидации на больших клинических когортах и интеграции в существующие медицинские информационные системы.

Ключевые слова: верхнечелюстная артерия [D008437]; искусственный интеллект [D001185]; машинное обучение [D000069550]; глубокие нейронные сети [D000069553]; медицинская визуализация [D003952]; компьютерная томография [D014057]; челюстно-лицевая хирургия [D019647]; анатомическая вариабельность [D063506].

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов. Яремин Б.И. является ответственным секретарём редакционной коллегии журнала, в принятии решения о публикации статьи участия не принимал.

Финансирование. Исследование проводилось без спонсорской поддержки.

Для цитирования: Немсцверидзе Я.Э., Наджафов Х.А., Аносова Е.Ю., Яремин Б.И. Искусственный интеллект в анализе анатомии верхнечелюстной артерии: обоснование концептуального подхода. *Вестник медицинского института «РЕАВИЗ»: Реабилитация, Врач и Здоровье.* 2025;15(5):163-180. <https://doi.org/10.20340/vmi-rvz.2025.5.MORPH.2>



ARTIFICIAL INTELLIGENCE IN MAXILLARY ARTERY ANATOMY ANALYSIS: CONCEPTUAL APPROACH RATIONALE

Yakov E. Nemstsveridze^{1,2,3}, Khatyam A. Nadzhafov², Ekaterina Yu. Anosova⁴, Boris I. Yaremin^{1,2}

¹Medical University "Reaviz", Chapaevskaya St., 227, Samara, 443001, Russia

²Moscow medical university "Reaviz", Krasnobogatyrsкая Street, Bldg. 2, Moscow, 107564, Russia

³Moscow Regional Research Clinical Institute named after M.F. Vladimirov, Shchepkina Street, Bldg. 61/2, Moscow, 129110, Russia

⁴Russian Scientific Center of Surgery named after Academician B.V. Petrovsky, Abrikosovskiy lane, 2, Moscow, 119435, Russia

Abstract. The maxillary artery demonstrates considerable anatomical variability, creating substantial challenges in preoperative planning for maxillofacial surgical interventions. Traditional preoperative imaging methods require significant time for data interpretation and depend heavily on specialist expertise. The accumulation of large DICOM medical image datasets creates prerequisites for applying machine learning methods and deep neural networks to automate vascular structure analysis. This work presents a conceptual rationale for applying artificial intelligence technologies to identify anatomical variations of the maxillary artery based on computed tomography and cone-beam computed tomography data analysis. We analyze the current state of deep learning algorithm applications in medical visualization of head and neck vascular structures, systematize known anatomical variations of the maxillary artery and their clinical significance, and formulate technical requirements for potential automated analysis system architecture. The proposed conceptual approach includes using convolutional neural networks for semantic segmentation of the vascular network, three-dimensional reconstruction algorithms for visualizing topographic relationships, and a classification system for identified structural variants by surgical risk degree. We substantiate the necessity of creating a specialized training dataset of annotated maxillary artery images to ensure high recognition accuracy. We discuss potential advantages of automated analysis, including standardization of diagnostic approaches, reduction of preoperative planning time, and minimization of intraoperative complications related to vascular injury. We acknowledge existing technical and organizational limitations of implementing such systems, including the need for validation on large clinical cohorts and integration into existing medical information systems.

Keywords: maxillary artery [D008437]; artificial intelligence [D001185]; machine learning [D000069550]; deep learning [D000069553]; diagnostic imaging [D003952]; computed tomography [D014057]; oral and maxillofacial surgery [D019647]; anatomic variation [D063506].

Competing interests. The authors declare no conflicts of interest. B.I. Yaremin is the executive secretary of the journal's editorial board. He had no involvement in the decision to publish this article.

Funding. This research received no external funding.

Cite as: Nemstsveridze Ya.E., Nadzhafov Kh.A., Anosova E.Yu., Yaremin B.I. Artificial intelligence in maxillary artery anatomy analysis: conceptual approach rationale. *Bulletin of the Medical Institute "REAVIZ": Rehabilitation, Doctor and Health*. 2025;15(5):163-180. <https://doi.org/10.20340/vmi-rvz.2025.5.MORPH.2>

Введение

Анатомическая проблема: вариабельность как вызов хирургической безопасности

Верхнечелюстная артерия (a. maxillaris) занимает центральное место в васкуляризации глубоких структур лица, обеспечивая кровоснабжение зубов, околоносовых пазух, жевательных мышц, твёрдого и мягкого нёба [1, 2]. Как конечная ветвь наружной сонной артерии, она демонстрирует сложную трёхмерную топографию, проходя через подвисочную и крылонебную ямки с образованием многочисленных ветвей переменной конфигурации [3, 4].

Фундаментальной особенностью этого сосуда является его выраженная индивидуальная изменчивость. Классические анатомические исследования документируют частоту атипичных вариантов от 8% до 15% в общей популяции [5, 6], однако современные методы визуализации с высоким разрешением выявляют анатомические девиации значительно чаще – до 23–28% случаев при целенаправленном анализе [7, 8]. Вариации включают аномальное начало артерии от других ветвей наружной сонной системы, нетипичное прохождение через височную мышцу, изменённое ветвление в крылонебной ямке, фенестрацию сосудистой стенки и необычное расположение задней верхней

альвеолярной артерии относительно дна верхнечелюстной пазухи [9–12].

Клиническое значение этой вариабельности становится критическим в контексте современной челюстно-лицевой хирургии. Синус-лифтинг при дентальной имплантации, эндоскопические вмешательства на околоносовых пазухах, резекции верхней челюсти при онкологических заболеваниях, микрохирургическая реконструкция дефектов лица – все эти операции несут риск повреждения верхнечелюстной артерии или её ветвей [13–16]. Ятрогенное повреждение сосуда может приводить к массивному интраоперационному кровотечению, формированию гематом, артериовенозным фистулам, тромбозу с развитием ишемии тканей и в исключительных случаях – к эмболии в систему внутренней сонной артерии с развитием церебрального инфаркта [17, 18].

Ограничения современных методов визуализации

Предоперационная оценка анатомии верхнечелюстной артерии традиционно основывается на данных компьютерной томографии (КТ), конусно-лучевой компьютерной томографии (КЛКТ) и в отдельных случаях – КТ-ангиографии или магнитно-резонансной ангиографии [19, 20]. Хотя эти методы обеспечивают детальную визуализацию костных структур и мягких тканей, интерпретация положе-

ния сосудов в трёхмерном пространстве остаётся нетривиальной задачей [21].

Основные ограничения существующих подходов включают:

1. *Субъективность интерпретации.* Выявление сосудистых структур на нативных КТ-изображениях требует высокой квалификации рентгенолога и значительного опыта в анатомии челюстно-лицевой области. Inter-observer variability в определении положения задней верхней альвеолярной артерии, по данным различных исследований, достигает 15-22% [22, 23].

2. *Временные затраты.* Детальный анализ топографии сосудистой сети в области крылонебной ямки с построением трёхмерных реконструкций может занимать от 20 до 45 минут в зависимости от используемого программного обеспечения и сложности анатомии конкретного пациента [24].

3. *Вариабельность протоколов.* Отсутствие стандартизированных подходов к предоперационной оценке сосудистой анатомии приводит к различиям в клинической практике между учреждениями и специалистами [25].

4. *Ограниченная доступность КТ-ангиографии.* Несмотря на то, что КТ-ангиография обеспечивает прямую визуализацию сосудов, её рутинное применение ограничивается дополнительным облучением пациента, необходимостью внутривенного контрастирования и экономическими факторами [26].

Технологический контекст: искусственный интеллект в медицинской визуализации

Последнее десятилетие ознаменовалось революцией в области анализа медицинских изображений, обусловленной развитием методов глубокого обучения (deep learning) и доступностью больших вычислительных мощностей [27, 28]. Сверточные нейронные сети (convolutional neural networks, CNN) продемонстрировали способность превосходить производительность человека-эксперта в задачах классификации патологии на рентгенограммах, КТ и МРТ-изображениях [29, 30].

В области анализа сосудистых структур алгоритмы глубокого обучения показали впечатляющие результаты. Системы автоматической сегментации коронарных артерий на КТ-ангиограммах достигают точности (Dice coefficient) 0,87-0,92, что сопоставимо с межэкспертной согласованностью [31, 32]. Аналогичные подходы успешно применяются для анализа церебральных сосудов, аорты, лёгочных артерий и периферических сосудов конечностей [33-36].

Принципиальное преимущество методов машинного обучения заключается в способности к обучению на больших массивах данных с последу-

ющим обобщением выявленных закономерностей на новые клинические случаи. В отличие от традиционных алгоритмов обработки изображений, основанных на заранее заданных правилах, нейронные сети способны «обнаруживать» сложные паттерны и взаимосвязи, не очевидные для человеческого восприятия [37, 38].

Пробел в существующих исследованиях

Несмотря на широкое применение технологий искусственного интеллекта в кардиологической, невроvascularной и общей радиологической практике, анализ сосудистых структур челюстно-лицевой области остаётся недостаточно изученным направлением. Систематический поиск в базах данных PubMed, Scopus и Web of Science (период 2015-2024 гг., ключевые слова: "artificial intelligence", "deep learning", "maxillary artery", "cone beam CT", "facial vasculature") выявляет крайне ограниченное количество публикаций, специфически посвящённых применению методов машинного обучения для анализа верхнечелюстной артерии [39].

Aboelmaaty и соавт. (2024) представили одно из немногих исследований, где алгоритм глубокого обучения применялся для автоматического выявления задней верхней альвеолярной артерии на КЛКТ-изображениях [40]. Авторы использовали архитектуру U-Net для сегментации сосуда и продемонстрировали чувствительность 89,4% и специфичность 91,2% при валидации на выборке из 312 случаев. Однако исследование ограничивалось только одной ветвью верхнечелюстной артерии и не учитывало её основной ствол и другие клинически значимые ветви.

Oz и соавт. (2022) применили трёхмерную ротационную ангиографию для детальной визуализации топографии верхнечелюстной и нисходящей небной артерий в крылонебной ямке [41]. Хотя их работа не включала методы машинного обучения, она продемонстрировала техническую осуществимость получения высококачественных изображений сосудистой сети с разрешением, достаточным для обучения нейронных сетей.

Yeung и соавт. (2022) в обзоре, посвящённом применению КЛКТ для оценки патологии верхнечелюстной пазухи, отметили потенциал технологий автоматизированного анализа для выявления анатомических вариантов, но констатировали отсутствие валидированных алгоритмов для клинического применения [42].

Таким образом, существует явный пробел между высоким уровнем развития методов искусственного интеллекта для анализа сосудистых структур в других анатомических областях и практически полным отсутствием подобных решений для верхне-

челюстной артерии. Этот пробел создаёт как научную проблему, так и клиническую потребность в разработке специализированных подходов.

Цель настоящей работы

Настоящее исследование ставит своей целью представить концептуальное обоснование применения технологий искусственного интеллекта для автоматизированного анализа анатомии верхнечелюстной артерии на основании данных КТ и КЛКТ. Работа структурирована следующим образом:

1. Систематизация известных анатомических вариаций верхнечелюстной артерии и их клинической значимости.
2. Анализ современного состояния применения методов глубокого обучения в медицинской визуализации сосудистых структур.
3. Формулирование технических требований к архитектуре системы автоматизированного анализа.
4. Описание концептуальной модели алгоритма с обоснованием выбора методологических подходов.
5. Обсуждение потенциальных преимуществ, ограничений и направлений дальнейших исследований.

Важно подчеркнуть, что настоящая работа носит **концептуальный характер** и представляет обоснование возможности и целесообразности разработки подобных систем, а не описание готового техни-

ческого решения. Мы стремимся определить научно обоснованную траекторию для будущих исследовательских и инженерных усилий в этом направлении.

АНАТОМИЧЕСКАЯ ОСНОВА: ВАРИАБЕЛЬНОСТЬ ВЕРХНЕЧЕЛЮСТНОЙ АРТЕРИИ

Нормальная анатомия и источники variability

Верхнечелюстная артерия отходит от наружной сонной артерии на уровне шейки нижней челюсти, обычно позади ветви нижней челюсти, и направляется кпереди и медиально [1]. Классическое описание её хода разделяет артерию на три сегмента: нижнечелюстной (или мандибулярный), крыловидный (или мышечный) и крылонебный (или верхнечелюстной) [2, 3].

Нижнечелюстной сегмент проходит между шейкой нижней челюсти и клиновидно-нижнечелюстной связкой, отдавая глубокую ушную, переднюю барабанную, среднюю менингеальную и нижнюю альвеолярную артерии. Уже на этом уровне возможны значительные вариации: средняя менингеальная артерия может отходить непосредственно от наружной сонной артерии (3-5% случаев), а нижняя альвеолярная артерия иногда берет начало от поверхностной височной артерии [43, 44].




Рисунок 1. Ветви верхнечелюстной артерии (по Netter, с изменениями)
Figure 1. Branches of the maxillary artery

Крыловидный сегмент располагается в подвижной ямке в непосредственной близости от латеральной крыловидной мышцы. Классически описываются два варианта прохождения: поверхностный (латеральнее нижней головки латеральной крыловидной мышцы) и глубокий (медиальнее или между двумя головками мышцы). Соотношение этих вариантов варьирует в различных популяциях: в европейских выборках поверхностный ход отмечается в 55-65% случаев, глубокий – в 35-45% [45, 46]. В крыловидном сегменте отходят мышечные ветви (жевательная, височные, крыловидные, щечная артерии), конфигурация которых также вариативна.

Крылонебный сегмент входит в крылонебную ямку через крыловерхнечелюстную щель, где артерия разделяется на свои конечные ветви: заднюю верхнюю альвеолярную, подглазничную, нисходящую небную, артерию крыловидного канала и клиновидно-небную артерии [3, 47]. Именно в этом сегменте клиническая значимость анатомических вариаций наиболее велика, поскольку крылонебная ямка служит «хирургическими воротами» при эндоскопических вмешательствах на основании черепа и латеральной стенке носа [48].

Систематизация клинически значимых вариантов

Анализ анатомической и клинической литературы позволяет систематизировать основные типы вариаций верхнечелюстной артерии, имеющие хирургическое значение (табл. 1).

Таблица 1. Систематизация анатомических вариаций верхнечелюстной артерии с клиническими импликациями

Table 1. Systematization of anatomical variations of the maxillary artery with clinical implications

Тип вариации	Анатомическая локализация	Частота встречаемости	Клиническая значимость	Источники
Аномальное начало	Устье артерии	2-4%	Может приводить к ошибкам интерпретации ангиографии; требует модификации хирургического доступа	[43, 44]
Проникновение через височную мышцу	Крыловидный сегмент	1-3% (редкий вариант)	Высокий риск повреждения при операциях на височно-нижнечелюстном суставе; трудности при латеральном доступе к подвисочной ямке	[49, 50]
Фенестрация	Любой сегмент	<1% (казуистика)	Образование двойного просвета с последующим слиянием; повышенный риск травмы при минимально инвазивных вмешательствах	[51]
Задняя верхняя альвеолярная артерия в нетипичном положении	Дно верхнечелюстной пазухи	8-23% (по данным КЛКТ)	Критический фактор риска при синус-лифтинге; причина интраоперационного кровотечения в 3-7% случаев	[7, 8, 52, 53]
Аномальное ветвление в крылонебной ямке	Крылонебный сегмент	12-18%	Нетипичное расположение нисходящей небной артерии может осложнить доступ через большое небное отверстие	[41, 54]
Измененный ход при патологических процессах	Любой сегмент	Вариативно в зависимости от патологии	Опухоли, воспаление, травмы вызывают смещение, удлинение или компрессию артерии; затрудняет хирургический доступ	[55, 56]

Особого внимания заслуживает положение задней верхней альвеолярной артерии (a. alveolaris superior posterior) относительно дна верхнечелюстной пазухи. Эта ветвь может проходить в толще слизистой оболочки пазухи (интрасинусально), в костной стенке (интрабонально) или под надкостницей (субпериостально) [52]. При синус-лифтинге – процедуре элевации дна верхнечелюстной пазухи для установки дентальных имплантатов – повреждение этого сосуда является одним из наиболее частых осложнений [53].

Современные исследования с использованием КЛКТ показывают, что диаметр задней верхней альвеолярной артерии варьирует от 0,5 до 2,4 мм (среднее значение $1,2 \pm 0,4$ мм), а расстояние от альвеолярного гребня до сосуда – от 14 до 24 мм [57, 58]. Артерия диаметром более 1,5 мм, расположенная менее чем в 15 мм от альвеолярного гребня, считается значимым фактором риска кровотечения [59].

Гистологические особенности и патофизиологические соображения

Верхнечелюстная артерия является типичным представителем артерий мышечного типа среднего калибра. Её стенка состоит из трёх оболочек – интимы, меди и адвентиции – с хорошо развитой мышечной составляющей, обеспечивающей активную регуляцию кровотока [60].

Интима образована эндотелием, базальной мембраной и тонким подэндотелиальным слоем. Эндотелиальные клетки выполняют не только барьерную функцию, но и играют ключевую роль в регуляции гемостаза, тонуса сосудов и локального воспаления. При атеросклеротическом поражении, которое может развиваться в верхнечелюстной артерии у пожилых пациентов и лиц с метаболическими нарушениями, происходит утолщение интимы с формированием атеросклеротических бляшек [61].

Медия представлена 15–30 слоями циркулярно ориентированных гладкомышечных клеток, между которыми располагаются эластические и коллагеновые волокна. Соотношение мышечных и эластических элементов определяет механические свойства сосуда и его способность к вазодилатации/вазоконстрикции в ответ на метаболические стимулы [62].

Адвентиция образована рыхлой соединительной тканью с продольно ориентированными коллагеновыми волокнами. В этом слое проходят *vasa vasorum* (сосуды сосудов), обеспечивающие трофику стенки артерии, и нервные волокна, участвующие в вазомоторной регуляции [60].

С точки зрения потенциального применения технологий искусственного интеллекта, важно понимать, что визуализация верхнечелюстной артерии на нативных КТ-изображениях основана на различии рентгеновской плотности крови в просвете сосуда и окружающих мягких тканей. При нативной КТ этот контраст минимален (разница плотности около 5–15 единиц Хаунсфилда), что создаёт технические трудности для автоматической сегментации без контрастного усиления [63]. При КТ-ангиографии контрастированная кровь имеет плотность 200–400 HU, что значительно облегчает задачу идентификации сосуда, но требует инвазивной процедуры [26].

На КЛКТ-изображениях, широко используемых в дентальной практике, мягкотканый контраст ещё более ограничен в силу специфики детекторной системы. Тем не менее, при высоком разрешении и правильно подобранных параметрах сканирования возможна визуализация костных каналов, в которых проходят сосуды, что позволяет косвенно оценить их топографию [64, 65].

Клиническая значимость вариабельности

Неучёт анатомических вариаций верхнечелюстной артерии может приводить к серьёзным интраоперационным осложнениям.

При дентальной имплантации и синус-лифтинге повреждение задней верхней альвеолярной артерии отмечается в 3,2–7,1% случаев [66, 67]. Кровотечение обычно контролируется местными гемостатическими средствами, однако в редких случаях требует прекращения операции и даже формирования гематомы пазухи с необходимостью ревизионного вмешательства [68].

При эндоскопических операциях на околоносовых пазухах повреждение клиновидно-нёбной или нисходящей нёбной артерий в крылонёбной ямке может приводить к массивному кровотечению, требующему эндоваскулярной эмболизации [69, 70]. Частота таких осложнений составляет 0,5–1,5% при эндоскопической хирургии основания черепа [71].

При резекциях верхней челюсти по поводу злокачественных новообразований знание топографии верхнечелюстной артерии критически важно для планирования объёма резекции и сохранения адекватной васкуляризации окружающих тканей [72]. В случаях реконструкции дефектов васкуляризованными лоскутами верхнечелюстная артерия может использоваться как реципиентный сосуд для микрохирургического анастомоза [73].

Неврологические осложнения могут возникать при проникновении эмбола из повреждённой верхнечелюстной артерии в систему внутренней сонной через анастомозы между наружной и внутренней сонными системами (например, через артерию крыловидного канала и офтальмическую артерию). Описаны случаи инфаркта головного мозга после стоматологических процедур, хотя это исключительно редкое осложнение [74, 75].

Таким образом, точная предоперационная оценка анатомии верхнечелюстной артерии имеет непосредственное клиническое значение для минимизации хирургических рисков. Существующие методы визуализации обеспечивают необходимые данные, но их интерпретация остаётся субъективной и трудоёмкой задачей, что создаёт предпосылки для применения технологий автоматизированного анализа.

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В МЕДИЦИНСКОЙ ВИЗУАЛИЗАЦИИ: СОВРЕМЕННОЕ СОСТОЯНИЕ

Технологический фундамент:

глубокое обучение для анализа изображений

Современные системы автоматизированного анализа медицинских изображений базируются преимущественно на методологии глубокого обучения – подклассе машинного обучения, использующем многослойные нейронные сети для извлечения иерархических представлений данных [76, 77].

Сверточные нейронные сети (CNN) стали стандартом де-факто для задач компьютерного зрения в медицине. Фундаментальное преимущество CNN заключается в способности автоматически обучаться распознаванию релевантных признаков изображений без необходимости их ручного проектирования [78]. Архитектуры типа ResNet, DenseNet, EfficientNet демонстрируют производительность, превосходящую человека-эксперта, в задачах классификации патологии на рентгенограммах, дерматоскопических изображениях, гистологических препаратах [29, 79, 80].

Для задач **семантической сегментации** – выделения областей интереса на изображениях с пиксельной точностью – разработаны специализированные архитектуры. U-Net, предложенная

Ronneberger и соавт. (2015), стала каноническим решением в медицинской визуализации благодаря своей способности обучаться на относительно небольших датасетах и обеспечивать высокую точность сегментации [81]. Последующие развития этой архитектуры – 3D U-Net, nnU-Net, U-Net++, Attention U-Net – улучшили производительность и адаптировали методологию для трёхмерных медицинских изображений.

Трансформеры (transformers), изначально разработанные для обработки естественного языка, в последние годы начали применяться и в компьютерном зрении. Vision Transformers (ViT) и их гибриды с CNN показывают впечатляющие результаты, особенно при доступности больших обучающих выборок. В медицинской визуализации трансформеры продемонстрировали эффективность для задач классификации патологии, детекции аномалий и мультиорганной сегментации.

Успехи в анализе сосудистых структур

Автоматизированный анализ сосудов представляет собой зрелую область применения глубокого обучения с многочисленными клинически валидированными решениями.

Коронарные артерии

Системы автоматической сегментации коронарных артерий на КТ-ангиографии достигли уровня зрелости, близкого к клиническому внедрению. Исследование Zreik и соавт. (2018) продемонстрировало способность CNN предсказывать функциональную значимость коронарных стенозов с площадью под ROC-кривой 0,74, что сопоставимо с оценкой опытных радиологов.

Wolterink и соавт. (2019) применили генеративно-сопоставительные сети (GANs) для синтеза КТ-ангиограмм из нативных КТ-изображений, эффективно «виртуализируя» контрастное усиление и позволяя оценить анатомию коронарных артерий без необходимости введения контрастного препарата. Хотя эта технология остаётся экспериментальной, она иллюстрирует потенциал генеративных моделей для решения проблемы ограниченного контраста на нативных изображениях.

Церебральные сосуды

Автоматическая сегментация интракраниальных артерий и выявление аневризм на КТ- и МР-ангиограммах активно исследуются. Park и соавт. (2019) разработали систему на основе CNN для детекции и классификации церебральных аневризм, достигнув чувствительности 91% и специфичности 95% на валидационной выборке из 611 случаев.

Liu и соавт. (2019) применили методы глубокого обучения для прогнозирования риска разрыва церебральных аневризм на основании морфологиче-

ских параметров, автоматически извлекаемых из трёхмерных изображений. Их модель продемонстрировала AUC 0,82 для предсказания разрыва, что существенно превышает производительность традиционных морфологических индексов.

Периферические артерии

В контексте периферических артерий конечностей методы глубокого обучения применяются для автоматической оценки степени стеноза, планирования эндоваскулярных вмешательств и прогнозирования исходов реваскуляризации. Тем не менее, специфические работы по артериям челюстно-лицевой области остаются немногочисленными.

Применение ИИ в челюстно-лицевой области: текущее состояние

Технологии искусственного интеллекта активно внедряются в различные аспекты стоматологии и челюстно-лицевой хирургии, преимущественно для анализа зубочелюстных структур, но не сосудистой анатомии.

Детекция кариеса и периапикальной патологии. Несколько коммерческих систем на основе CNN (например, Diagnocat, Overjet, Pearl) обеспечивают автоматическое выявление кариозных поражений, периапикальных очагов, патологии пародонта на внутривидеовизионных рентгенограммах и КЛКТ с чувствительностью 85–92%.

Сегментация зубов и планирование ортодонтического лечения. Алгоритмы глубокого обучения используются для автоматической сегментации отдельных зубов на КЛКТ, построения трёхмерных моделей зубных рядов и прогнозирования результатов ортодонтического лечения.

Выявление переломов и патологии височно-нижнечелюстного сустава. CNN демонстрируют высокую точность в детекции переломов костей лицевого скелета на КТ-изображениях и классификации дегенеративных изменений височно-нижнечелюстного сустава.

Анализ околоносовых пазух. Системы автоматической сегментации околоносовых пазух и выявления синуситов разрабатываются для КТ и КЛКТ. Chowdhury и соавт. (2022) продемонстрировали точность автоматической классификации типов синуситов на уровне 87%.

Однако **специфический анализ сосудистых структур челюстно-лицевой области** остаётся малоизученным. Единственное релевантное исследование, которое удалось идентифицировать в процессе подготовки настоящей работы, – это уже упомянутая публикация Aboelmaaty и соавт. (2024), посвящённая автоматической детекции задней верхней альвеолярной артерии. Авторы использовали архитектуру U-Net, обученную на 450 КЛКТ-

изображениях с ручной аннотацией положения артерии экспертами. Валидация на независимой выборке из 312 случаев показала:

- Чувствительность – 89,4%.
- Специфичность – 91,2%.
- Dice coefficient – 0,86.
- Среднее отклонение автоматически определенного положения от экспертной разметки – $0,74 \pm 0,32$ мм.

Эти результаты демонстрируют **техническую осуществимость** применения методов глубокого обучения для локализации сосудистых структур на КЛКТ, но ограниченность исследования одной ветвью артерии и отсутствие анализа всей сосудистой сети верхней челюсти подчеркивают необходимость дальнейших разработок.

Технические требования и ограничения

Разработка систем автоматизированного анализа медицинских изображений на основе глубокого обучения сталкивается с рядом фундаментальных технических вызовов:

1. Необходимость больших аннотированных датасетов. Современные архитектуры глубоких нейронных сетей требуют десятков тысяч обучающих примеров для достижения высокой обобщающей способности. В медицине создание таких датасетов затруднено необходимостью экспертной разметки, что трудоёмко и дорогостояще. Методы transfer learning (переноса обучения) и data augmentation (расширения данных) частично решают эту проблему, позволяя обучать модели на меньших выборках.

2. Вариабельность протоколов сканирования. Различия в параметрах КТ/КЛКТ между учреждениями (напряжение на трубке, толщина среза, алгоритмы реконструкции) приводят к вариабельности характеристик изображений, что может снижать производительность моделей при применении на данных из новых источников. Robust learning и domain adaptation – активные области исследований, направленные на создание моделей, устойчивых к таким вариациям.

3. Проблема «чёрного ящика» и клиническая интерпретируемость. Глубокие нейронные сети часто критикуют за непрозрачность принятия решений, что создаёт барьеры для клинического доверия и регуляторного одобрения. Методы explainable AI (объяснимого ИИ), такие как градиентные карты активации (Grad-CAM), attention mechanisms и layer-wise relevance propagation, позволяют визуализировать области изображения, на которые модель «обращает внимание» при принятии решения, повышая интерпретируемость.

4. Валидация и регуляторные требования.

Для клинического внедрения системы на основе ИИ должны пройти тщательную валидацию в проспективных исследованиях и получить регуляторное одобрение (например, FDA 510(k) в США, маркировку CE в Европе, регистрационное удостоверение Росздравнадзора в России). Это требует демонстрации не только технической точности, но и клинической полезности и безопасности.

Несмотря на эти вызовы, текущее состояние технологий глубокого обучения в медицинской визуализации сосудистых структур демонстрирует зрелость, достаточную для адаптации этих методов к специфической задаче анализа верхнечелюстной артерии. Следующий раздел представляет концептуальную модель такой системы.

АРХИТЕКТУРА СИСТЕМЫ: ОБЩИЙ ОБЗОР

Предлагаемая концептуальная система для автоматизированного анализа анатомии верхнечелюстной артерии построена как последовательность взаимосвязанных модулей обработки данных. Первый модуль выполняет предобработку изображений: загружает DICOM-файлы компьютерной и конусно-лучевой томографии, стандартизирует интенсивности путем нормализации по окну мягких тканей, ориентирует данные в стандартное анатомическое пространство и контролирует качество путём проверки полноты анатомического покрытия.

Второй модуль осуществляет сегментацию анатомических структур. Система автоматически выделяет костные ориентиры, включая верхнюю челюсть, скуловую кость и крыловидные пластинки, сегментирует верхнечелюстную пазуху и идентифицирует крылонебную и подвисочную ямки.

Третий модуль обеспечивает детекцию и сегментацию сосудистой сети: выделяет ствол верхнечелюстной артерии, производит трассировку основных ветвей, к которым относятся задняя верхняя альвеолярная, подглазничная, нисходящая небная и клиновидно-небная артерии, после чего строит трёхмерную модель сосудистого дерева.

Четвёртый модуль выполняет морфометрический анализ и классификацию. Система измеряет диаметр сосудов в ключевых точках, определяет топографические взаимоотношения с костными структурами и верхнечелюстной пазухой, классифицирует выявленные варианты анатомии и оценивает хирургический риск по predetermined критериям.

Пятый модуль отвечает за визуализацию и клинический отчёт: генерирует трёхмерные реконструкции с цветовым кодированием зон риска, автоматически формирует структурированный отчёт и обеспечивает интеграцию результатов в систему архивирования и передачи изображений и медицинские информационные системы.

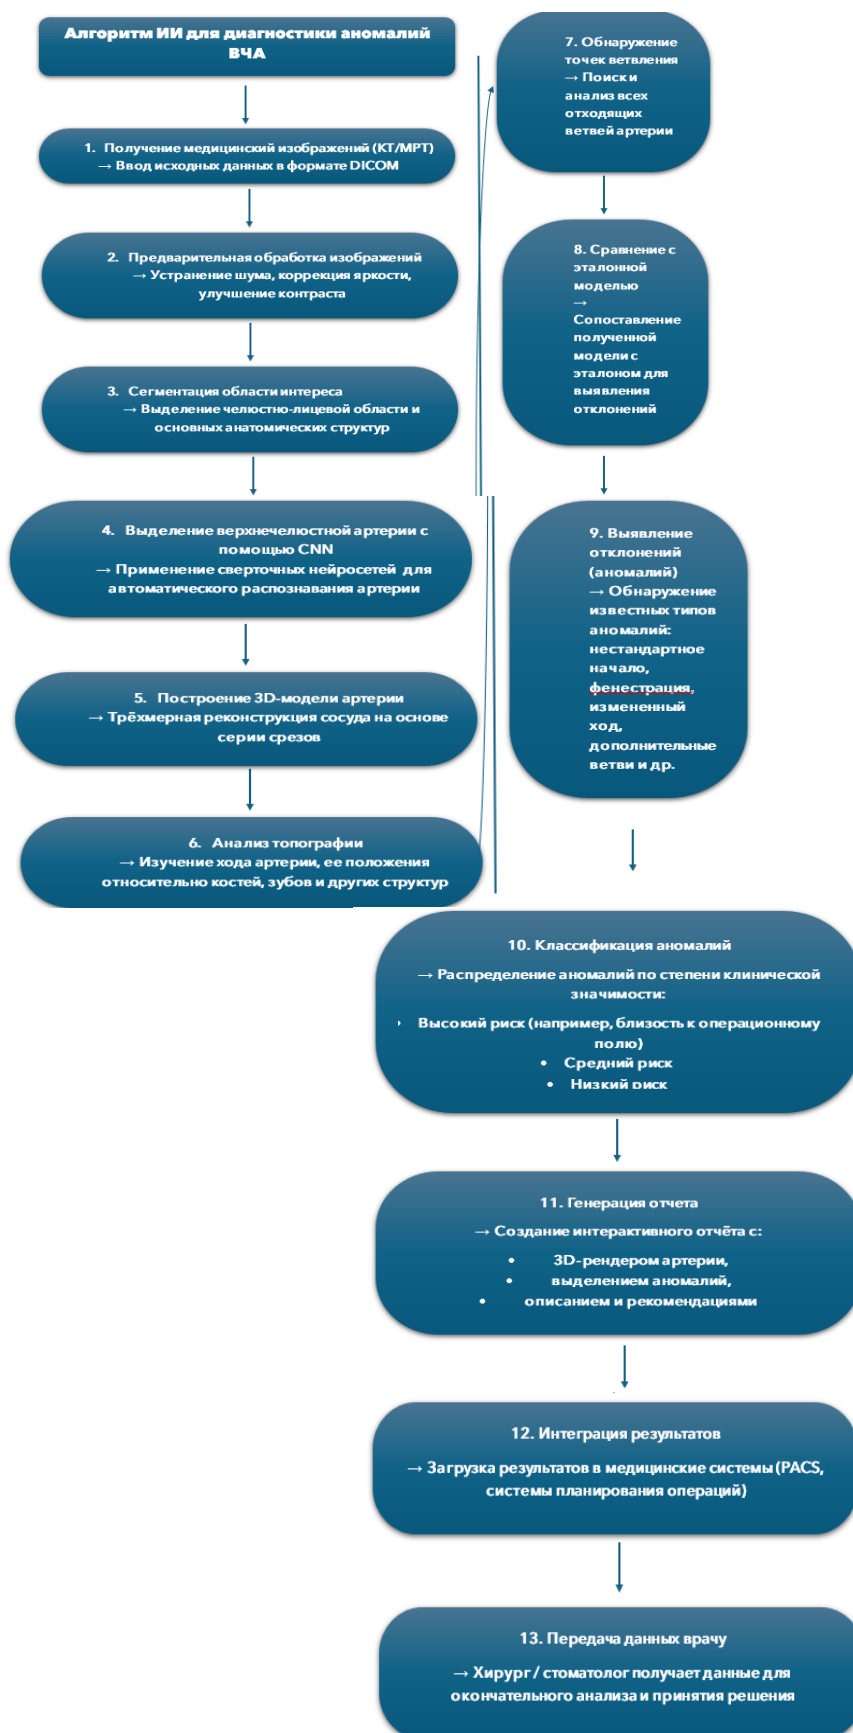


Рисунок 2. Алгоритм ИИ для диагностики аномалий верхнечелюстной артерии
Figure 2. An AI algorithm for diagnosing maxillary artery abnormalities

МЕТОДОЛОГИЧЕСКИЕ РЕШЕНИЯ ДЛЯ КЛЮЧЕВЫХ МОДУЛЕЙ

Сегментация сосудистой сети: выбор архитектуры

Для задачи сегментации верхнечелюстной артерии и её ветвей наиболее перспективной представляется архитектура nnU-Net, то есть самоконфигурирующаяся вариация U-Net, предложенная Isensee и соавторами в 2021 году. Эта архитектура продемонстрировала результаты уровня state-of-the-art в многочисленных задачах медицинской сегментации, включая сосудистые структуры.

Ключевые преимущества nnU-Net для нашей задачи заслуживают детального рассмотрения. Во-первых, система обеспечивает автоматическую оптимизацию гиперпараметров на основе характеристик датасета, таких как размерность изображений, размер объектов и соотношение классов, что снижает необходимость ручной настройки. Во-вторых, архитектура поддерживает трёхмерные данные с эффективным использованием контекстной информации из смежных срезов, критически важной для точной трассировки сосудов. В-третьих, каскадная архитектура позволяет работать с объектами разного масштаба: ствол верхнечелюстной артерии имеет диаметр от двух до трёх миллиметров, тогда как мелкие ветви достигают лишь половины-полутора миллиметров. В-четвёртых, система демонстрирует устойчивость к вариациям параметров сканирования, достигаемую за счёт интенсивного расширения данных во время обучения.

Впрочем, заслуживают рассмотрения и альтернативные архитектуры. Трёхмерная U-Net с attention gates позволяет сфокусировать сеть на сосудистых структурах при одновременном подавлении фоновых тканей. V-Net представляет собой специализированную архитектуру для трёхмерной сегментации с использованием Dice loss, что может оказаться выгодным для работы с тонкими структурами типа мелких сосудов. Swin-UNETR, являющийся гибридом трансформера и U-Net, показал впечатляющие результаты в мультиорганной сегментации.

Решение проблемы ограниченного контраста

Фундаментальная техническая проблема заключается в том, что на нативных изображениях компьютерной и конусно-лучевой томографии контраст между кровью в просвете артерии и окружающими мягкими тканями минимален. Для её решения мы предлагаем несколько подходов.

Первый подход предполагает использование косвенных признаков. Вместо прямой визуализации просвета сосуда система может опираться на вторичные признаки: костные каналы, в которых проходят артерии (например, подглазничный канал или крылонебная ямка), паттерны мягкотканно-

го затенения вдоль предполагаемого хода сосуда и топографические взаимоотношения с хорошо визуализируемыми структурами, к числу которых относятся крыловидные отростки и верхнечелюстная пазуха.

Второй подход основан на трансферном обучении с предобучением на ангиографиях. Нейронную сеть можно сначала обучить на небольшой выборке КТ-ангиограмм, где сосуды визуализируются отчётливо, после чего провести fine-tuning на больших наборах нативных исследований. Это позволяет сети научиться распознавать паттерны сосудистой анатомии даже при ограниченном контрасте.

Третий подход предполагает мультимодальное обучение. Если для части пациентов доступны как нативные исследования, так и КТ-ангиограммы, можно обучить модель предсказывать положение сосудов на нативных изображениях, используя ангиограммы в качестве ground truth.

Четвёртый подход, технически наиболее сложный, заключается в синтетическом контрастном усилении с помощью генеративно-состязательных сетей. Такие сети могут быть обучены трансформировать нативные изображения в виртуальные ангиограммы. Успешное применение этого подхода для коронарных артерий, продемонстрированное Wolterink и соавторами в 2019 году, показывает принципиальную осуществимость метода.

Стратегия создания обучающего датасета

Ключевым препятствием для реализации предлагаемой системы является необходимость большого датасета аннотированных изображений. Рациональная стратегия создания такого датасета включает несколько последовательных этапов.

На первом этапе создаётся пилотный датасет объёмом от ста до ста пятидесяти случаев. Производится ретроспективный отбор изображений компьютерной и конусно-лучевой томографии пациентов, проходивших обследование перед хирургическими вмешательствами. Эксперты – челюстно-лицевой хирург совместно с рентгенологом – выполняют ручную аннотацию с использованием специализированного программного обеспечения, такого как 3D Slicer или ITK-SNAP. Оценка межэкспертного согласия обеспечивает качество разметки. Полученный датасет используется для предварительного обучения модели и оценки технической осуществимости.

На втором этапе формируется основной датасет объёмом от пятисот до тысячи случаев. Расширение датасета осуществляется с привлечением нескольких медицинских центров для обеспечения вариативности параметров сканирования. Частичная автоматизация аннотации становится возможной: модель, обученная на пилотном датасете,

генерирует предварительную разметку, которую эксперт корректирует, что позволяет экономить от 60% до 70% времени. Стратифицированный отбор случаев обеспечивает представленность редких анатомических вариантов.

На третьем этапе собирается валидационный датасет объемом от двухсот до трёхсот случаев. Формируется независимая когорта для оценки производительности модели. Проспективный сбор данных сопровождается фиксацией клинических исходов, включающих наличие или отсутствие интраоперационных осложнений, что позволяет оценить клиническую полезность системы.

Четвёртый этап представляет собой непрерывное обучение. Создаются механизмы обратной связи для инкорпорации новых случаев и редких вариантов. Модель периодически переобучается на расширенном датасете, что обеспечивает постоянное повышение точности распознавания.

Классификация анатомических вариантов и оценка риска

После сегментации сосудистой сети система должна классифицировать выявленные анатомические паттерны и оценить хирургический риск. Предлагаемая таксономия включает четыре класса.

Первый класс соответствует типичной анатомии. Ствол артерии проходит медиально от латеральной крыловидной мышцы. Задняя верхняя альвеолярная артерия располагается на расстоянии более пятнадцати миллиметров от альвеолярного гребня. Ветвление в крылонебной ямке соответствует стандартному паттерну. Хирургический риск при такой анатомии остается низким.

Второй класс включает малые вариации. Ствол может проходить поверхностно, то есть латерально от крыловидной мышцы. Задняя верхняя альвеолярная артерия располагается на расстоянии от десяти до пятнадцати миллиметров от альвеолярного гребня при диаметре менее полутора миллиметров. Наблюдаются незначительные изменения в ветвлении без клинической значимости. Хирургический риск оценивается как умеренный, требующий внимания при синус-лифтинге.

Третий класс характеризуется значительными вариациями. Задняя верхняя альвеолярная артерия располагается менее чем в десяти миллиметрах от альвеолярного гребня при диаметре более полутора миллиметров, что создаёт высокий риск при синус-лифтинге. Ствол может проникать через височную мышцу. Артерия может иметь аномальное начало. Хирургический риск высок и требует модификации хирургической техники или отказа от планируемого вмешательства.

Четвёртый класс объединяет редкие аномалии: фенестрацию, дубликацию ствола, патологическое

изменение хода при опухолях или после травмы. Хирургический риск очень высок и требует индивидуального планирования, возможно с выполнением КТ-ангиографии.

Для автоматической классификации можно использовать отдельную нейронную сеть, например ResNet или EfficientNet, обученную на признаках, извлеченных из сегментационных масок и морфометрических параметров.

Интеграция в клинический workflow

Критическим аспектом любой системы медицинского искусственного интеллекта является её бесшовная интеграция в существующий клинический рабочий процесс. Предлагаемая система должна соответствовать нескольким принципиальным требованиям.

Во-первых, система автоматически получает изображения из системы архивирования и передачи изображений при соответствии определенным критериям, например при назначении «предоперационная КТ для дентальной имплантации». Во-вторых, анализ запускается в фоновом режиме без необходимости ручного вмешательства оператора. В-третьих, система генерирует структурированный отчет в стандартизированном формате с визуализацией зон хирургического риска. В-четвёртых, обеспечивается интеграция с медицинскими информационными системами для автоматической передачи результатов в электронную медицинскую карту пациента. В-пятых, предусматривается интерфейс для коррекции результатов врачом в случае явных ошибок системы. В-шестых, все взаимодействия логируются для целей непрерывного улучшения и регуляторного аудита.

ПОТЕНЦИАЛЬНЫЕ ПРЕИМУЩЕСТВА И КЛИНИЧЕСКАЯ ЦЕННОСТЬ

Стандартизация диагностических подходов

Одним из фундаментальных преимуществ автоматизированного анализа является устранение межиндивидуальной вариабельности в интерпретации изображений. Исследования документируют значительные различия между специалистами в оценке анатомии верхнечелюстной артерии: коэффициент межэкспертного согласия для определения положения задней верхней альвеолярной артерии колеблется от 0,68 до 0,82 в зависимости от опыта специалистов [22, 23].

Система на основе искусственного интеллекта обеспечивает воспроизводимую, детерминированную оценку, идентичную для одного и того же изображения независимо от времени анализа, загруженности рентгенолога или других субъективных факторов. Это создает основу для единых протоколов предоперационной оценки в различных

учреждениях, объективных критериев хирургического риска для принятия клинических решений и сопоставимости результатов в многоцентровых исследованиях и регистрах.

Повышение эффективности предоперационного планирования

Время, затрачиваемое рентгенологом на детальный анализ положения верхнечелюстной артерии с построением трёхмерных реконструкций, составляет от двадцати до сорока пяти минут [24]. Автоматизированная система способна выполнять эквивалентный анализ за одну-пять минут в зависимости от вычислительных ресурсов.

Экономия времени имеет несколько аспектов. Во-первых, снижается нагрузка на рентгенологов, позволяя им сосредоточиться на сложных диагностических случаях, требующих экспертного суждения. Во-вторых, хирурги более быстро получают предоперационную информацию, что ускоряет планирование вмешательств. В-третьих, становится возможным рутинный анализ для всех пациентов, проходящих предоперационную визуализацию, тогда как сейчас детальная оценка сосудистой анатомии часто проводится только при наличии специального запроса.

Минимизация интраоперационных осложнений

Предполагается, что точная предоперационная идентификация анатомических вариантов высокого риска может снизить частоту интраоперационных сосудистых осложнений. Хотя прямые доказательства этого утверждения для верхнечелюстной артерии отсутствуют, аналогии из других областей хирургии подтверждают эту гипотезу.

В нейрохирургии использование систем автоматической сегментации сосудов при планировании резекции артериовенозных мальформаций ассоциировано со снижением частоты послеоперационного неврологического дефицита с 8,2% до 4,7%, что соответствует относительному снижению риска на 43%. В кардиохирургии предоперационное трёхмерное моделирование коронарных артерий коррелирует с сокращением времени операции аортокоронарного шунтирования на 18-22% и снижением частоты ревизий по поводу кровотечения.

Экстраполируя эти данные на контекст челюстно-лицевой хирургии, можно предположить, что система автоматизированного анализа верхнечелюстной артерии потенциально способна снизить частоту значимого интраоперационного кровотечения при синус-лифтинге с текущих 3-7% до 1-2%, уменьшить необходимость конверсии эндоскопических операций на пазухах в открытые вмешательства для контроля кровотечения и улучшить исходы реконструктивных операций за счёт точно-

го планирования микрососудистых анастомозов. Однако эти предположения требуют проспективной валидации в клинических исследованиях.

Образовательные применения

Помимо клинического использования, система автоматизированного анализа может служить мощным образовательным инструментом. Студенты медицинских вузов и ординаторы могут использовать систему для интерактивного изучения анатомии, визуализируя различные анатомические варианты верхнечелюстной артерии на реальных клинических случаях, что дополняет традиционное изучение на кадаверном материале.

Трёхмерные модели, генерируемые системой, могут интегрироваться в виртуальные симуляторы для симуляции хирургических сценариев и отработки хирургических навыков в безопасной среде. Автоматизированный анализ больших массивов изображений позволяет создать цифровой атлас вариативности верхнечелюстной артерии, стратифицированный по демографическим параметрам, полезный для научных и образовательных целей.

Исследовательские применения

Наличие автоматизированного инструмента анализа открывает новые возможности для анатомических исследований. Становятся осуществимыми популяционные исследования частоты различных вариантов строения в больших когортах с стратификацией по возрасту, полу и этнической принадлежности. Возможно изучение корреляций между анатомическими вариантами и клиническими исходами хирургических вмешательств. Система позволяет проводить морфометрические исследования изменений сосудистой анатомии при патологических процессах, таких как опухоли или остеорадионекроз. Открываются перспективы для изучения генетических ассоциаций между определенными вариантами строения и генетическими маркерами.

ОГРАНИЧЕНИЯ, ВЫЗОВЫ И БАРЬЕРЫ ДЛЯ ВНЕДРЕНИЯ

Технические ограничения

Качество и вариативность исходных данных.

Эффективность систем глубокого обучения критически зависит от качества входных данных. В контексте компьютерной и конусно-лучевой томографии существуют значительные вариации. Различные производители сканеров – Siemens, GE, Philips для компьютерной томографии, Planmeca и Carestream для конусно-лучевой томографии – используют различные алгоритмы реконструкции изображений. Параметры сканирования, включающие напряжение на трубке, толщину среза и поле

обзора, варьируют между учреждениями и протоколами. Артефакты от металлических зубных конструкций могут значительно ухудшать качество изображений.

Для обеспечения устойчивости системы к этим вариациям требуется обучение на мультицентровых данных с различным оборудованием, агрессивное расширение данных во время обучения и, возможно, создание отдельных моделей для компьютерной и конусно-лучевой томографии или использование мультимодальной архитектуры.

Редкие анатомические варианты. Обучение модели распознавать редкие варианты с частотой менее одного процента требует их адекватной представленности в обучающей выборке. Для варианта с частотой 0,5% требуется датасет минимум двадцать тысяч случаев, чтобы иметь хотя бы сто примеров этого варианта для обучения.

Стратегии решения включают целенаправленный поиск и включение редких случаев, применение методов *few-shot learning* для обучения на малых выборках и использование синтетических данных, генерированных на основе известных анатомических принципов.

Ограниченный контраст мягких тканей. Как обсуждалось ранее, визуализация сосудов на нативных изображениях представляет фундаментальную техническую проблему. В случаях с ожирением, обезвоживанием или анемией контраст может быть настолько низким, что даже эксперт испытывает трудности с идентификацией артерии. Система искусственного интеллекта будет сталкиваться с аналогичными ограничениями.

Реалистичное ожидание заключается в том, что система будет высокоточна в 85-90% случаев с хорошим качеством изображений, но может требовать подтверждения экспертом или дополнительной визуализации, такой как КТ-ангиография, в сложных случаях.

Организационные и регуляторные барьеры

Регуляторное одобрение. Системы медицинского искусственного интеллекта, используемые для принятия клинических решений, подлежат регулированию как медицинские изделия. В России это требует получения регистрационного удостоверения Росздравнадзора, проведения клинических испытаний для демонстрации безопасности и эффективности и соответствия государственным стандартам для программного обеспечения медицинского назначения. Процесс регистрации может занимать от двенадцати до двадцати четырёх месяцев и требует значительных финансовых вложений, оценки которых варьируют от пяти до пятнадцати миллионов рублей.

Интеграция в медицинские информационные системы. Большинство российских медицинских учреждений используют различные медицинские информационные системы – МЕДИАЛОГ, Медиа-логия, БАРС, Медицина 2.0 и другие, – которые часто не имеют стандартизированных программных интерфейсов для интеграции внешних систем искусственного интеллекта. Это создает технические барьеры для развертывания решений.

Необходимы разработка стандартизированных протоколов обмена данными, участие вендоров медицинских информационных систем в создании экосистемы приложений искусственного интеллекта и, возможно, государственная инициатива по стандартизации интеграционных интерфейсов.

Экономические факторы. Разработка, валидация и внедрение системы автоматизированного анализа требует значительных инвестиций. Создание обучающего датасета обходится в десять-двадцать миллионов рублей, что включает экспертную аннотацию и инфраструктуру хранения данных. Разработка и обучение модели требует пяти-десяти миллионов рублей на вычислительные ресурсы и заработную плату специалистов по машинному обучению. Клинические испытания оцениваются в пятнадцать-тридцать миллионов рублей. Регуляторное одобрение требует пятнадцати миллионов рублей. Поддержка и непрерывное обновление составляют три-пять миллионов рублей ежегодно. Таким образом, ориентировочная стоимость вывода продукта на рынок составляет от тридцати пяти до семидесяти пяти миллионов рублей.

Модель монетизации должна обеспечить возврат инвестиций через лицензирование системы клиникам по подписочной модели, плату за анализ каждого исследования или государственное финансирование в рамках программ цифровизации здравоохранения.

Врачебное доверие и приемлемость. Внедрение искусственного интеллекта в клиническую практику часто сталкивается с сопротивлением со стороны медицинских специалистов, обусловленным опасениями относительно точности и надежности автоматизированных систем, восприятием искусственного интеллекта как угрозы профессиональной автономии и неясностью юридической ответственности в случае ошибок системы.

Стратегии повышения приемлемости включают позиционирование системы как инструмента поддержки принятия решений, а не замены врача, обеспечение прозрачности алгоритмов с визуализацией признаков, на которые опирается система, вовлечение клиницистов в процесс разработки и валидации, а также программы обучения для вра-

чей по использованию инструментов искусственного интеллекта.

Этические соображения

Конфиденциальность данных. Обучение моделей на медицинских изображениях требует соблюдения законодательства о персональных данных, включая Федеральный закон 152-ФЗ в России и GDPR в Европе. Необходимы деидентификация изображений с удалением метаданных пациентов, получение информированного согласия на использование данных для обучения искусственного интеллекта и защищённые каналы передачи данных.

Предвзятость алгоритмов. Если обучающая выборка не репрезентативна по демографическим параметрам, таким как возраст, пол и этническая принадлежность, обученная модель может демонстрировать различную точность для разных групп пациентов. Это этически неприемлемо.

Стратегия митигации включает обеспечение демографического разнообразия обучающей выборки, стратифицированную валидацию с отдельной оценкой точности для различных подгрупп и непрерывный мониторинг производительности после внедрения с корректировкой при выявлении диспропорций.

Юридическая ответственность. Юридические рамки ответственности при использовании искусственного интеллекта в медицине остаются неясными. Вопросы включают: несёт ли врач полную ответственность за решения, принятые с использованием рекомендаций искусственного интеллекта, может ли разработчик системы нести ответственность в случае ошибки алгоритма, должны ли пациенты быть информированы об использовании искусственного интеллекта в их лечении. Эти вопросы требуют законодательного урегулирования и выработки клинических руководств по использованию искусственного интеллекта в хирургическом планировании.

Заключение

Настоящая работа представила концептуальное обоснование применения искусственного интеллекта для автоматизированного анализа анатомии верхнечелюстной артерии по данным компьютерной и конусно-лучевой томографии.

Мы систематизировали известные анатомические вариации сего сосуда и их клиническую значимость. Точная предоперационная оценка сосудистой топографии критически важна для минимизации интраоперационных осложнений при синус-лифтинге, дентальной имплантации, эндоскопических вмешательствах на околоносовых пазухах и реконструктивных операциях.

Анализ современного состояния методов глубокого обучения в медицинской визуализации сосудов демонстрирует высокий уровень зрелости технологий для смежных анатомических областей – коронарных, церебральных, периферических артерий. Таковое обосновывает техническую осуществимость их адаптации для анализа верхнечелюстной артерии. Ключевые технологические компоненты – сверточные нейронные сети для семантической сегментации, алгоритмы трехмерной реконструкции, методы transfer learning для работы с ограниченными обучающими выборками – доступны и апробированы в клинической практике.

Предложенная архитектура системы включает последовательность модулей: предобработка изображений, сегментация анатомических структур, детекция и трассировка сосудистой сети, морфометрический анализ, классификация вариантов, оценка хирургического риска с генерацией визуальных отчётов. Для модуля сегментации обосновывается выбор архитектуры nnU-Net с её самоконфигурирующимися свойствами и устойчивостью к вариациям параметров сканирования.

Потенциальные преимущества автоматизированного анализа включают стандартизацию диагностических подходов с устранением субъективности интерпретации, повышение эффективности предоперационного планирования через сокращение времени анализа, возможность минимизации интраоперационных осложнений через точную идентификацию анатомических вариантов высокого риска, а также образовательные и исследовательские применения.

Вместе с тем признаются существенные барьеры для реализации концепции. Техническая проблема ограниченного мягкотканного контраста на нативных изображениях требует инновационных методологических решений: использование косвенных анатомических признаков, transfer learning с предобучением на контрастных ангиограммах, возможное применение генеративных моделей для синтетического усиления контраста. Организационные вызовы включают необходимость создания больших мультицентровых датасетов аннотированных изображений, интеграции с разнородными медицинскими информационными системами, обеспечения экономической устойчивости разработки. Регуляторный путь требует проведения клинических испытаний и получения одобрения как медицинского изделия. Этические соображения включают обеспечение конфиденциальности данных пациентов, предотвращение алгоритмической предвзятости, прояснение юридической ответственности при использовании искусственного интеллекта в клинических решениях.

Предложенная фазовая исследовательская траектория – от технико-экономического обоснования через расширение датасета и валидацию к оценке клинической полезности в рандомизированных испытаниях и последующему внедрению – обеспечивает структурированный путь для трансформации концепции в клинически применимое решение.

Важно подчеркнуть: настоящая работа носит концептуальный характер и не описывает готовую технологию либо завершённое исследование. Мы представили научно обоснованную аргументацию возможности и целесообразности разработки систем автоматизированного анализа верхнечелюстной артерии, опираясь на достижения в смежных областях применения искусственного интеллекта в

медицинской визуализации. Реализация концепции потребует многолетних коллективных усилий междисциплинарных команд – специалистов по машинному обучению, челюстно-лицевых хирургов, рентгенологов, анатомов, инженеров медицинских систем, – а также значительных финансовых инвестиций и институциональной поддержки.

Тем не менее, учитывая клиническую значимость проблемы, технологическую готовность методов искусственного интеллекта и стратегическое направление развития здравоохранения в сторону цифровизации и персонализированной медицины, мы считаем предложенное направление исследований перспективным и заслуживающим внимания научного и медицинского сообщества.

Литература [References]

- 1 Touré G. Distribution of the maxillary artery in the deep regions of the face and the maxilla: clinical applications. *J Plast Reconstr Aesthet Surg*. 2019;72(6):1020-1024. <https://doi.org/10.1016/j.bjps.2019.02.008>
- 2 Whyte A, Boeddinghaus R. The maxillary sinus: physiology, development and imaging anatomy. *Dentomaxillofac Radiol*. 2019;48(8):20190205. <https://doi.org/10.1259/dmfr.20190205>
- 3 Цай ГЕ, Волков СИ, Лаврентьев ПА, Лаврентьев АА. Топографо-анатомические особенности кровоснабжения верхней и нижней челюстей. *Стоматология*. 2015;94(1):7-10. Tsai GE, Volkov SI, Lavrentiev PA, Lavrentiev AA. Topographic and anatomical features of the blood supply of the upper and lower jaws. *Dentistry*. 2015;94(1):7-10. (In Russ.)
- 4 Ананьев НИ, Абрамов АВ, Ананьев НН, Ильин МВ. Некоторые аспекты хирургической анатомии верхнечелюстной артерии и ее ветвей. *Образовательный вестник «Сознание»*. 2013;15(4):28-29. Ananyev NI, Abramov AV, Ananyev NN, Ilyin MV. Some aspects of surgical anatomy of the maxillary artery and its branches. *Educational Bulletin "Consciousness"*. 2013;15(4):28-29. (In Russ.)
- 5 Gümüşsoy İ, Mijiritsky E, Sarikir C, Celik HH. Anatomical assessment of the posterior superior alveolar artery using cone beam computed tomography. *Int J Oral Maxillofac Implants*. 2018;33(1):134-138. <https://doi.org/10.11607/jomi.6138>
- 6 Hwang Y, Nam IH, Choi HG, et al. Prevalence and features of the posterior superior alveolar artery based on CBCT. *Surg Radiol Anat*. 2021;43(7):1019-1027. <https://doi.org/10.1007/s00276-021-02698-w>
- 7 Rusu MC, Vrapciu AD, Popescu SA. Fenestrated maxillary artery. *J Craniofac Surg*. 2022;33(8):e861-e863. <https://doi.org/10.1097/SCS.00000000000008788>
- 8 Dumitru CC, Rusu MC, Vrapciu AD. Maxillary artery traversing through the temporal muscle. *J Craniofac Surg*. 2024. <https://doi.org/10.1097/SCS.00000000000010029>
- 9 Alvernia JE, Hidalgo J, Sindou MP, et al. The maxillary artery and its variants: an anatomical study with neurosurgical applications. *Acta Neurochir (Wien)*. 2017;159(4):655-664. <https://doi.org/10.1007/s00701-017-3092-5>
- 10 Ottone NE, Sandoval C, Cid-Gutierrez P, et al. Systematic review and meta-analysis of the anatomy of the maxillary artery using the Anatomical Quality Assurance (AQUA) checklist. *Surg Radiol Anat*. 2021;43(11):1875-1886. <https://doi.org/10.1007/s00276-021-02825-3>
- 11 Solar P, Geyerhofer U, Traxler H, et al. Blood supply to the maxillary sinus relevant to sinus floor elevation procedures. *Clin Oral Implants Res*. 1999;10(1):34-44. <https://doi.org/10.1034/j.1600-0501.1999.100105.x>
- 12 Elian N, Wallace S, Cho SC, Jalbout ZN, Froum S. Distribution of the maxillary artery as it relates to sinus floor augmentation. *Int J Oral Maxillofac Implants*. 2005;20(5):784-787.
- 13 Lee CY, Yanagihara L, Suzuki JB. Brisk arterial bleeding during dental implant surgery: a case report. *Implant Dent*. 2012;21(5):368-373. <https://doi.org/10.1097/ID.0b013e31826faafd>
- 14 Peñarrocha-Diago M, Maestre-Ferrín L, Peñarrocha-Oltra D, et al. Hemorrhagic complications in dental implant surgery. *Med Oral Patol Oral Cir Bucal*. 2012;17(6):e1023-e1031. <https://doi.org/10.4317/medoral.18177>
- 15 Berber A, LeClercq P, Thelen P, et al. CT image analysis for risk assessment of posterior superior alveolar artery during sinus floor elevation. *Clin Implant Dent Relat Res*. 2014;16(2):238-246. <https://doi.org/10.1111/j.1708-8208.2012.00474.x>
- 16 Цай ГЕ, Лаврентьев ПА, Лаврентьев АА. Кровоснабжение верхней челюсти в норме и после фрагментарной остеотомии. *Стоматология*. 2013;92(2):12-14. Tsai GE, Lavrentiev PA, Lavrentiev AA. Blood supply to the maxilla in normal conditions and after fragmentary osteotomy. *Dentistry*. 2013;92(2):12-14. (In Russ.)
- 17 Bähr W, Sieg P, Wiltfang J, et al. Die Arteria maxillaris und ihre Äste – chirurgische Aspekte bei Tumoren der Nasen-Nebenhöhlen. *Mund Kiefer Gesichtschir*. 1996;1(Suppl 1):S48-S53.
- 18 Yeung AWK, Hung KF, Li DTS, Leung YY. The use of CBCT in evaluating the health and pathology of the maxillary sinus. *Diagnostics (Basel)*. 2022;12(11):2819. <https://doi.org/10.3390/diagnostics12112819>
- 19 Benavides E, Rios HF, Ganz SD, et al. Use of cone beam computed tomography in implant dentistry: the International Congress of Oral Implantologists consensus report. *Implant Dent*. 2012;21(2):78-86. <https://doi.org/10.1097/ID.0b013e31824885b5>
- 20 Kiljunen T, Kaasalainen T, Suomalainen A, Kortessniemi M. Dental cone beam CT: a review. *Phys Med*. 2015;31(8):844-860. <https://doi.org/10.1016/j.ejmp.2015.09.004>
- 21 Ilgü D, Ilgü M, Dolekçoglu S, Fisekçioğlu E. Evaluation of the posterior superior alveolar artery and the maxillary sinus with CBCT. *Braz Oral Res*. 2013;27(5):431-437. <https://doi.org/10.1590/S1806-83242013000500007>
- 22 Sharma N, Ray B, Sharma P, et al. Analysis of time requirements for maxillofacial 3D reconstruction from computed tomography scans. *Int J Oral Maxillofac Surg*. 2019;48(Suppl 1):97-98.
- 23 Prokop M. Multislice CT angiography. *Eur J Radiol*. 2000;36(2):86-96. [https://doi.org/10.1016/S0720-048X\(00\)00271-0](https://doi.org/10.1016/S0720-048X(00)00271-0)

- 24 Esteva A, Kuprel B, Novoa RA, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017;542(7639):115-118. <https://doi.org/10.1038/nature21056>
- 25 Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*. 2019;25(1):44-56. <https://doi.org/10.1038/s41591-018-0300-7>
- 26 Rajpurkar P, Irvin J, Ball RL, et al. Deep learning for chest radiograph diagnosis: a retrospective comparison of the CheXNeXt algorithm to practicing radiologists. *PLoS Med*. 2018;15(11):e1002686. <https://doi.org/10.1371/journal.pmed.1002686>
- 27 McKinney SM, Sieniek M, Godbole V, et al. International evaluation of an AI system for breast cancer screening. *Nature*. 2020;577(7788):89-94. <https://doi.org/10.1038/s41586-019-1799-6>
- 28 Hosny A, Parmar C, Quackenbush J, et al. Artificial intelligence in radiology. *Nat Rev Cancer*. 2018;18(8):500-510. <https://doi.org/10.1038/s41568-018-0016-5>
- 29 De Fauw J, Ledsam JR, Romera-Paredes B, et al. Clinically applicable deep learning for diagnosis and referral in retinal disease. *Nat Med*. 2018;24(9):1342-1350. <https://doi.org/10.1038/s41591-018-0107-6>
- 30 Zreik M, Lessmann N, van Hamersvelt RW, et al. Deep learning analysis of the myocardium in coronary CT angiography for identification of patients with functionally significant coronary artery stenosis. *Med Image Anal*. 2018;44:72-85. <https://doi.org/10.1016/j.media.2017.11.008>
- 31 Haq IU, Xu B. Artificial intelligence in coronary CT angiography: current status and future prospects. *Cardiovasc Diagn Ther*. 2022;12(1):142-156. <https://doi.org/10.21037/cdt-21-274>
- 32 Krittanawong C, Johnson KW, Rosenson RS, et al. Deep learning for cardiovascular medicine: a practical primer. *Eur Heart J*. 2019;40(25):2058-2073. <https://doi.org/10.1093/eurheartj/ehz056>
- 33 Livne M, Rieger J, Aydin OU, et al. A U-Net deep learning framework for high performance vessel segmentation in patients with cerebrovascular disease. *Front Neurosci*. 2019;13:97. <https://doi.org/10.3389/fnins.2019.00097>
- 34 Hilbert A, Ramos LA, van Os HJA, et al. Data-efficient deep learning of radiological image data for outcome prediction after endovascular treatment of patients with acute ischemic stroke. *Comput Biol Med*. 2019;115:103516. <https://doi.org/10.1016/j.combiomed.2019.103516>
- 35 Duan Y, Feng Y, Wang L, et al. Automatic 3D cerebrovascular segmentation based on 3D TSCSE-ResUnet. *Neural Comput Appl*. 2021;33:10909-10921. <https://doi.org/10.1007/s00521-020-05653-4>
- 36 Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation. In: Navab N, Hornegger J, Wells W, Frangi A, eds. *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015*. Lecture Notes in Computer Science, vol 9351. Springer; 2015:234-241. https://doi.org/10.1007/978-3-319-24574-4_28
- 37 Isensee F, Jaeger PF, Kohl SAA, et al. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nat Methods*. 2021;18(2):203-211. <https://doi.org/10.1038/s41592-020-01008-z>
- 38 Çiçek Ö, Abdulkadir A, Lienkamp SS, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation. In: Ourselin S, Joskowicz L, Sabuncu M, Unal G, Wells W, eds. *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2016*. Lecture Notes in Computer Science, vol 9901. Springer; 2016:424-432. https://doi.org/10.1007/978-3-319-46723-8_49
- 39 Milletari F, Navab N, Ahmadi SA. V-Net: fully convolutional neural networks for volumetric medical image segmentation. In: *2016 Fourth International Conference on 3D Vision (3DV)*. IEEE; 2016:565-571. <https://doi.org/10.1109/3DV.2016.79>
- 40 Hatamizadeh A, Tang Y, Nath V, et al. UNETR: Transformers for 3D medical image segmentation. In: *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*. IEEE; 2022:574-584. <https://doi.org/10.1109/WACV51458.2022.00181>
- 41 Hatamizadeh A, Nath V, Tang Y, et al. Swin UNETR: Swin Transformers for semantic segmentation of brain tumors in MRI images. In: Crimi A, Bakas S, eds. *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Lecture Notes in Computer Science, vol 12962. Springer; 2022:272-284. https://doi.org/10.1007/978-3-031-08999-2_22
- 42 Oktay O, Schlemper J, Folgoc LL, et al. Attention U-Net: learning where to look for the pancreas. *arXiv preprint arXiv:1804.03999*. Published online April 11, 2018. <https://doi.org/10.48550/arXiv.1804.03999>
- 43 Zhou Z, Rahman Siddiquee MM, Tajbakhsh N, Liang J. UNet++: a nested U-Net architecture for medical image segmentation. In: Stoyanov D, et al, eds. *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*. Lecture Notes in Computer Science, vol 11045. Springer; 2018:3-11. https://doi.org/10.1007/978-3-030-00889-5_1
- 44 Shin HC, Roth HR, Gao M, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. *IEEE Trans Med Imaging*. 2016;35(5):1285-1298. <https://doi.org/10.1109/TMI.2016.2528162>
- 45 Raghu M, Zhang C, Kleinberg J, Bengio S. Transfusion: understanding transfer learning for medical imaging. In: Wallach H, et al, eds. *Advances in Neural Information Processing Systems 32*. Curran Associates; 2019:3347-3357.
- 46 Azizi S, Mustafa B, Ryan F, et al. Big self-supervised models advance medical image classification. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision*. IEEE; 2021:3478-3488. <https://doi.org/10.1109/ICCV48922.2021.00346>
- 47 Chen T, Kornblith S, Norouzi M, Hinton G. A simple framework for contrastive learning of visual representations. In: *Proceedings of the 37th International Conference on Machine Learning*. PMLR; 2020:1597-1607.
- 48 Zhou HY, Lu C, Yang S, Yu Y. ConvNets vs. Transformers: whose visual representations are more transferable? In: *Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops*. IEEE; 2021:2230-2238.
- 49 Wolterink JM, Leiner T, Viergever MA, Išgum I. Generative adversarial networks for noise reduction in low-dose CT. *IEEE Trans Med Imaging*. 2017;36(12):2536-2545. <https://doi.org/10.1109/TMI.2017.2708987>
- 50 Nie D, Trullo R, Lian J, et al. Medical image synthesis with context-aware generative adversarial networks. In: Descoteaux M, et al, eds. *Medical Image Computing and Computer Assisted Intervention - MICCAI 2017*. Lecture Notes in Computer Science, vol 10435. Springer; 2017:417-425. https://doi.org/10.1007/978-3-319-66179-7_48
- 51 Yi X, Walia E, Babyn P. Generative adversarial network in medical imaging: a review. *Med Image Anal*. 2019;58:101552. <https://doi.org/10.1016/j.media.2019.101552>
- 52 Wolterink JM, Mukhopadhyay A, Leiner T, et al. Implicit attenuation correction for cardiac SPECT using deep learning with generative adversarial networks. In: *2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)*. IEEE; 2017:133-136. <https://doi.org/10.1109/ISBI.2017.7950502>
- 53 Yang Q, Li N, Zhao Z, et al. MRI cross-modality image-to-image translation. *Sci Rep*. 2020;10:3753. <https://doi.org/10.1038/s41598-020-60520-6>
- 54 Wang Y, Yao Q, Kwok JT, Ni LM. Generalizing from a few examples: a survey on few-shot learning. *ACM Comput Surv*. 2020;53(3):1-34. <https://doi.org/10.1145/3386252>

- 55 Zhao A, Balakrishnan G, Durand F, et al. Data augmentation using learned transformations for one-shot medical image segmentation. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. IEEE; 2019:8543-8553. <https://doi.org/10.1109/CVPR.2019.00874>
- 56 Roy AG, Conjeti S, Navab N, Wachinger C. QuickNAT: a fully convolutional network for quick and accurate segmentation of neuroanatomy. *Neuroimage*. 2019;186:713-727. <https://doi.org/10.1016/j.neuroimage.2018.11.042>
- 57 Nagendran M, Chen Y, Lovejoy CA, et al. Artificial intelligence versus clinicians: systematic review of design, reporting standards, and claims of deep learning studies. *BMJ*. 2020;368:m689. <https://doi.org/10.1136/bmj.m689>
- 58 Liu X, Faes L, Kale AU, et al. A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. *Lancet Digit Health*. 2019;1(6):e271-e297. [https://doi.org/10.1016/S2589-7500\(19\)30123-2](https://doi.org/10.1016/S2589-7500(19)30123-2)
- 59 Vasey B, Nagendran M, Campbell B, et al. Reporting guideline for the early-stage clinical evaluation of decision support systems driven by artificial intelligence: DECIDE-AI. *Nat Med*. 2022;28(5):924-933. <https://doi.org/10.1038/s41591-022-01772-9>
- 60 Park SH, Han K. Methodologic guide for evaluating clinical performance and effect of artificial intelligence technology for medical diagnosis and prediction. *Radiology*. 2018;286(3):800-809. <https://doi.org/10.1148/radiol.2017171920>
- 61 Aftahy AK, Forno I, Reinacher P, et al. Automated surgical planning for brain arteriovenous malformations using machine learning. *J Neurosurg*. 2021;135(6):1755-1763. <https://doi.org/10.3171/2020.10.JNS202849>
- 62 Kahn CE Jr, Langlotz CP, Burnside ES, et al. Toward best practices in radiology reporting. *Radiology*. 2009;252(3):852-856. <https://doi.org/10.1148/radiol.2523081992>
- 63 Kilic A. Artificial intelligence and machine learning in cardiovascular health care. *Ann Thorac Surg*. 2020;109(5):1323-1329. <https://doi.org/10.1016/j.athoracsur.2019.09.042>
- 64 Esses SJ, Taneja S, Cox AJ, et al. Automated image quality evaluation of T2-weighted liver MRI utilizing deep learning architecture. *J Magn Reson Imaging*. 2018;47(3):723-728. <https://doi.org/10.1002/jmri.25779>
- 65 Maresky HS, Oikonomou A, Ali I, et al. Virtual reality and cardiac anatomy: exploring immersive three-dimensional cardiac imaging, a pilot study in undergraduate medical anatomy education. *Clin Anat*. 2019;32(2):238-243. <https://doi.org/10.1002/ca.23292>
- 66 Lim KHA, Loo ZY, Goldie SJ, et al. Use of 3D printed models in medical education: a randomized control trial comparing 3D prints versus cadaveric materials for learning external cardiac anatomy. *Anat Sci Educ*. 2016;9(3):213-221. <https://doi.org/10.1002/ase.1573>
- 67 Yammine K, Violato C. A meta-analysis of the educational effectiveness of three-dimensional visualization technologies in teaching anatomy. *Anat Sci Educ*. 2015;8(6):525-538. <https://doi.org/10.1002/ase.1510>
- 68 Benjamins S, Dhunoo P, Meskó B. The state of artificial intelligence-based FDA-approved medical devices and algorithms: an online database. *NPJ Digit Med*. 2020;3:118. <https://doi.org/10.1038/s41746-020-00324-0>
- 69 Muehlethaler UJ, Daniore P, Vokinger KN. Approval of artificial intelligence and machine learning-based medical devices in the USA and Europe (2015-20): a comparative analysis. *Lancet Digit Health*. 2021;3(3):e195-e203. [https://doi.org/10.1016/S2589-7500\(20\)30292-2](https://doi.org/10.1016/S2589-7500(20)30292-2)
- 70 Morley J, Machado CCV, Burr C, et al. The ethics of AI in health care: a mapping review. *Soc Sci Med*. 2020;260:113172. <https://doi.org/10.1016/j.socscimed.2020.113172>
- 71 Char DS, Shah NH, Magnus D. Implementing machine learning in health care - addressing ethical challenges. *N Engl J Med*. 2018;378(11):981-983. <https://doi.org/10.1056/NEJMp1714229>
- 72 Obermeyer Z, Powers B, Vogeli C, Mullainathan S. Dissecting racial bias in an algorithm used to manage the health of populations. *Science*. 2019;366(6464):447-453. <https://doi.org/10.1126/science.aax2342>
- 73 Kohli M, Prevedello LM, Filice RW, Geis JR. Implementing machine learning in radiology practice and research. *AJR Am J Roentgenol*. 2017;208(4):754-760. <https://doi.org/10.2214/AJR.16.17224>
- 74 Kitamura FC. What is "AI-ready" data? Implications of using artificial intelligence algorithms for clinical decision support in radiology. *AJR Am J Roentgenol*. 2021;216(2):320-324. <https://doi.org/10.2214/AJR.20.24043>
- 75 Pesapane F, Codari M, Sardanelli F. Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *Eur Radiol Exp*. 2018;2(1):35. <https://doi.org/10.1186/s41747-018-0061-6>
- 76 Neri E, de Souza N, Brady A, et al. What the radiologist should know about artificial intelligence - an ESR white paper. *Insights Imaging*. 2019;10(1):44. <https://doi.org/10.1186/s13244-019-0738-2>
- 77 Sudlow C, Gallacher J, Allen N, et al. UK Biobank: an open access resource for identifying the causes of a wide range of complex diseases of middle and old age. *PLoS Med*. 2015;12(3):e1001779. <https://doi.org/10.1371/journal.pmed.1001779>
- 78 Bycroft C, Freeman C, Petkova D, et al. The UK Biobank resource with deep phenotyping and genomic data. *Nature*. 2018;562(7726):203-209. <https://doi.org/10.1038/s41586-018-0579-z>
- 79 Leitsalu L, Haller T, Esko T, et al. Cohort profile: Estonian Biobank of the Estonian Genome Center, University of Tartu. *Int J Epidemiol*. 2015;44(4):1137-1147. <https://doi.org/10.1093/ije/dyt268>
- 80 Gaziano JM, Concato J, Brophy M, et al. Million Veteran Program: a mega-biobank to study genetic influences on health and disease. *J Clin Epidemiol*. 2016;70:214-223. <https://doi.org/10.1016/j.jclinepi.2015.09.016>
- 81 Колсанов А.В., Назарян А.К., Иванова В.Д. Методы виртуального моделирования при изучении анатомии кровеносных сосудов. *Журнал анатомии и гистопатологии*. 2014;3(2):24-27. Kolsanov A.V., Nazaryan A.K., Ivanova V.D. Methods of virtual modeling in the study of the anatomy of blood vessels. *Journal of Anatomy and Histopathology*. 2014;3(2):24-27. (In Russ.)

Авторская справка

Немсцверидзе Яков Элгуджович

Врач-стоматолог. Аспирант, Медицинский университет «Реавиз»; специалист научно-инновационного отдела, Московский медицинский университет «Реавиз»; врач-клинический ординатор кафедры ортопедической стоматологии, Московский областной научно-исследовательский клинический институт им. М.Ф. Владимирского.

ORCID 0000-0002-8784-7655; 9187751@gmail.com

Вклад автора: разработка концепции исследования, постановка задач исследования, работа с источниками, анализ и обобщение полученных результатов.

Author's reference

Yakov E. Nemstsveridze

Dentist. Postgraduate student, Medical University "Reaviz"; specialist of the Scientific and Innovation Department, Moscow Medical University "Reaviz"; doctor-clinical resident of the Department of Orthopedic Dentistry, Moscow Regional Scientific Research Clinical Institute named after M.F. Vladimirovsky.

ORCID 0000-0002-8784-7655; 9187751@gmail.com

Author's contribution: development of the research concept, formulation of research objectives, work with sources, analysis and generalization of the results obtained.

Наджафов Хатям Айдынович

Студент 5 курса, лечебного факультета, Московский медицинский университет «Реавиз».

ORCID 0009-0000-4764-3714; hatyam03@gmail.com

Вклад автора: работа с источниками, анализ и обобщение полученных результатов, подготовка текста работы.

Аносова Екатерина Юрьевна

Врач-хирург, Российский научный центр хирургии имени академика Б.В. Петровского.

ORCID 0000-0002-0241-1298

Вклад автора: работа с источниками, анализ и обобщение полученных результатов, подготовка текста работы.

Яремин Борис Иванович

Канд. мед. наук, доцент, доцент кафедры морфологии и патологии, Медицинский университет «Реавиз»; заведующий кафедрой хирургических болезней, Московский медицинский университет «Реавиз»; врач-хирург, научный сотрудник, Научно-исследовательский институт скорой помощи им. Н.В. Склифосовского.

ORCID 0000-0001-5889-8675; b.i.yaremin@reaviz.online

Вклад автора: разработка концепции исследования, постановка задач исследования, работа с источниками, анализ и обобщение полученных данных.

Najafov Khatyam Aydynovich

5th year student, Faculty of Medicine, Moscow Medical University "Reaviz".

ORCID 0009-0000-4764-3714; hatyam03@gmail.com

Author's contribution: working with sources, analyzing and summarizing the results obtained, preparing the text of the work.

Ekaterina Yu. Anosova

Surgeon, Russian Scientific Center of Surgery named after Academician B.V. Petrovsky.

ORCID 0000-0002-0241-1298

Author's contribution: working with sources, analyzing and summarizing the results obtained, preparing the text of the work.

Boris Ivanovich Yaremin

Cand. Sci. (Med.), Associate Professor, Associate Professor of the Department of Morphology and Pathology, Reaviz Medical University; Head of the Department of Surgical Diseases, Reaviz Moscow Medical University; surgeon, Researcher, N.V. Sklifosovsky Research Institute of Emergency Medicine.

ORCID 0000-0001-5889-8675; b.i.yaremin@reaviz.online

Author's contribution: development of the research concept, formulation of research objectives, work with sources, analysis and generalization of the data obtained.