

<https://doi.org/10.34883/PI.2026.16.1.035>



Рафиков В.О.¹, Наурдинова М.Х.², Савинкина Ю.Д.¹, Жук С.П.¹, Фиданян Е.Е.¹,
Коршунова А.Ю.¹, Москвитина А.В.³, Гусейнов Н.А.⁴ ✉

¹ Первый Московский государственный медицинский университет
имени И.М. Сеченова, Москва, Россия

² Российский национальный исследовательский медицинский университет
имени Н.И. Пирогова, Москва, Россия

³ Ставропольский государственный медицинский университет, Ставрополь, Россия

⁴ Российский университет дружбы народов имени Патриса Лумумбы, Москва,
Россия

Искусственный интеллект и машинное обучение в диагностике и прогнозировании воспалительных заболеваний околоносовых пазух: систематический обзор литературы

Конфликт интересов: не заявлен.

Вклад авторов: все авторы внесли равноценный вклад в подготовку статьи.

Подана: 16.10.2025

Принята: 23.02.2026

Контакты: qi.mozg@mail.ru

Резюме

Введение. Воспалительные заболевания околоносовых пазух представляют собой одну из наиболее распространенных патологий в современной оториноларингологии, поражающую от 10 до 15% взрослого населения развитых стран. Традиционные методы визуализации характеризуются субъективностью интерпретации и зависимостью от квалификации специалиста. На фоне роста объема лучевых исследований и дефицита врачей-рентгенологов возрастает потребность в технологических решениях на основе искусственного интеллекта и машинного обучения для автоматизации анализа медицинских изображений и поддержки принятия клинических решений.

Цель. Анализ современного состояния исследований по применению искусственного интеллекта и машинного обучения в диагностике и прогнозировании воспалительных заболеваний околоносовых пазух, обобщение данных о диагностической точности существующих разработанных моделей.

Материалы и методы. Обзор выполнен в соответствии с рекомендациями PRISMA 2020. Проведен поиск литературы за период 2019–2024 гг. в базах PubMed, Google Scholar и eLibrary с использованием ключевых слов, связанных с искусственным интеллектом, машинным обучением и диагностикой синусита. Первичный поиск выявил 481 публикацию, после отбора по критериям включения в анализ вошло 18 оригинальных исследований с общим объемом выборки 15212 пациентов.

Результаты. Включенные в анализ исследования продемонстрировали высокую диагностическую точность моделей машинного обучения, варьирующую от 75,7 до 99,7% в зависимости от типа визуализации и методологии. Наиболее высокие

показатели достигнуты при анализе данных конусно-лучевой компьютерной томографии (точность 99,7%, чувствительность 100%, специфичность 99,3%). Модели успешно применялись для дифференциальной диагностики эозинофильного и неэозинофильного вариантов ХРС с точностью от 85,3 до 98,5%, а также для различения одонтогенного гайморита и других форм синусита. Прогностические модели показали точность от 69,23 до 84,62% в предсказании рецидивов после хирургического лечения. Сравнительные исследования подтвердили, что алгоритмы машинного обучения демонстрируют сопоставимую или превосходящую точность по сравнению с врачами-специалистами.

Заключение. Искусственный интеллект и машинное обучение представляют перспективное направление для повышения точности диагностики, стандартизации интерпретации результатов исследований и прогнозирования исходов лечения воспалительных заболеваний околоносовых пазух. Для широкого клинического внедрения необходимы многоцентровые проспективные исследования и разработка стандартизированных протоколов применения.

Ключевые слова: искусственный интеллект, машинное обучение, глубокое обучение, риносинусит, гайморит, диагностика, прогнозирование

Rafikov V.¹, Naurdinova M.², Savinkina Yu.¹, Zhuk S.¹, Fidanyan E.¹, Korshunova A.¹, Moskvitina A.³, Guseynov N.⁴ ✉

¹ Sechenov First Moscow State Medical University, Moscow, Russia

² Pirogov Russian National Research Medical University, Moscow, Russia

³ Stavropol State Medical University, Stavropol, Russia

⁴ Peoples' Friendship University of Russia named after Patrice Lumumba, Moscow, Russia

Artificial Intelligence and Machine Learning in the Diagnosis and Prognosis of Inflammatory Diseases of the Paranasal Sinuses: A Systematic Literature Review

Conflict of interest: nothing to declare.

Authors' contribution: all authors made equal contributions to the preparation of the article.

Submitted: 16.10.2025

Accepted: 23.02.2026

Contacts: qi.mozg@mail.ru

Abstract

Introduction. Inflammatory diseases of the paranasal sinuses represent one of the most common pathologies in modern otorhinolaryngology, affecting 10 to 15% of the adult population in developed countries. Traditional imaging methods are characterized by subjective interpretation and dependence on specialist qualifications. Against the background of increasing volume of radiological examinations and shortage of radiologists, there is a growing need for technological solutions based on artificial intelligence and machine learning for automation of medical image analysis and clinical decision support.

Purpose. To analyze the current state of studies concerning the implementation of artificial intelligence and machine learning in the diagnosis and prediction of inflammatory diseases of the paranasal sinuses, and to summarize data on the diagnostic reliability of existing models.

Materials and methods. The review was conducted in accordance with PRISMA 2020 guidelines. A literature search was performed for the period 2019–2024 in PubMed, Google Scholar, and eLibrary databases using keywords related to artificial intelligence, machine learning, and rhinosinusitis diagnosis. The initial search identified 481 publications; after selection according to inclusion criteria, 18 original studies with a total sample size of 15,212 patients were included in the analysis.

Results. The included studies demonstrated high diagnostic accuracy of machine learning models, ranging from 75.7 to 99.7% depending on the type of imaging and methodology. The highest performance was achieved in cone-beam computed tomography analysis (accuracy 99.7%, sensitivity 100%, and specificity 99.3%). Models were successfully applied for differential diagnosis of eosinophilic and non-eosinophilic variants of chronic rhinosinusitis with accuracy ranging from 85.3 to 98.5%, as well as for distinguishing odontogenic maxillary sinusitis from other forms. Prognostic models showed accuracy from 69.23 to 84.62% in predicting recurrence after surgical treatment. Comparative studies confirmed that machine learning algorithms demonstrate comparable or superior accuracy compared to medical specialists.

Conclusion. Artificial intelligence and machine learning represent a promising direction for improving diagnostic accuracy, standardizing interpretation of examination results, and predicting treatment outcomes in inflammatory diseases of the paranasal sinuses. For widespread clinical implementation, multicenter prospective studies and elaboration of standardized application protocols are required.

Keywords: artificial intelligence, machine learning, deep learning, rhinosinusitis, sinusitis, diagnosis, prognosis

■ ВВЕДЕНИЕ

Воспалительные заболевания околоносовых пазух представляют собой одну из наиболее распространенных патологий в современной оториноларингологии и продолжают оставаться значимой проблемой общественного здравоохранения во всем мире [1, 2]. Согласно эпидемиологическим данным, различными формами риносинусита (РС) страдает от 10 до 15% взрослого населения развитых стран, при этом отмечается устойчивая тенденция к росту заболеваемости [3, 4]. В Российской Федерации ежегодно регистрируется более 10 миллионов случаев острого РС, из которых почти 20% пациентов требуют экстренной госпитализации [5, 6]. Хронические формы синусита вместе с другими хроническими заболеваниями верхних дыхательных путей составляют значительную часть структуры первичной заболеваемости всего населения [7].

Высокая распространенность воспалительных заболеваний околоносовых пазух определяет значительную нагрузку на систему здравоохранения и обуславливает необходимость совершенствования методов диагностики и прогнозирования течения данной патологии. Своевременная и точная диагностика синуситов имеет

важное значение для выбора оптимальной лечебной тактики, предотвращения развития осложнений и улучшения качества жизни пациентов. Традиционные методы визуализации, включающие рентгенографию и компьютерную томографию (КТ) околоносовых пазух, остаются основополагающими инструментами в диагностическом алгоритме, однако их интерпретация часто характеризуется субъективностью и зависит от квалификации и опыта специалиста [8–10].

На фоне постоянного роста объема выполняемых лучевых исследований и усугубляющегося кадрового дефицита врачей-рентгенологов возрастает потребность в технологических решениях, способных повысить эффективность диагностического процесса. Искусственный интеллект (ИИ) и методы машинного обучения (МО) представляют собой перспективное направление для автоматизации анализа медицинских изображений, стандартизации интерпретации результатов исследований и поддержки принятия клинических решений. За последние 5 лет наблюдается экспоненциальный рост числа научных публикаций, посвященных разработке и валидации алгоритмов на основе ИИ для диагностики различных заболеваний по данным лучевых методов исследования [11–13].

Применение ИИ-технологий в диагностике воспалительных заболеваний околоносовых пазух охватывает широкий спектр задач, включая автоматическую сегментацию анатомических структур, выявление патологических изменений, дифференциальную диагностику различных форм синуситов и прогнозирование исходов лечения [14–16]. Несмотря на значительное количество исследований в данной области, большинство из них характеризуется ретроспективным дизайном, ограниченными размерами выборок и отсутствием внешней валидации на независимых данных. Более того, существует выраженная гетерогенность в методологических подходах к разработке и оценке моделей, что затрудняет сравнение результатов различных исследований и формулирование обоснованных выводов о клинической применимости разработанных решений.

■ ЦЕЛЬ ИССЛЕДОВАНИЯ


Анализ современного состояния исследований по применению ИИ и МО в диагностике и прогнозировании воспалительных заболеваний околоносовых пазух, обобщение данных о диагностической точности существующих разработанных моделей.

■ МАТЕРИАЛЫ И МЕТОДЫ

Обзор выполнен в соответствии с рекомендациями PRISMA 2020 для систематических обзоров [17]. Проведен поиск литературы за последние 5 лет (2019–2024 гг.) в базах PubMed, Google Scholar и eLibrary. Использовались комбинации ключевых слов на английском языке: artificial intelligence, machine learning, deep learning, sinusitis, rhinosinusitis, diagnosis, prediction – и на русском: «искусственный интеллект», «машинное обучение», «гайморит», «синусит», «риносинусит», «диагностика», «прогнозирование». Были отобраны только оригинальные исследования на людях, опубликованные в рецензируемых журналах на русском и английском языках, в которых представлены результаты применения ИИ/МО для диагностики воспалительных заболеваний околоносовых пазух (острого или хронического РС) или прогностической оценки (например, исходы лечения, риск рецидива). Обзорные

статьи и метаанализы исключались из анализа. Также не включались единичные клинические случаи.

Первичный поиск выявил 481 публикацию в базах данных. После удаления дубликатов и предварительного отбора по аннотациям было полнотекстово проанализировано 160 работ. Из них критерии включения удовлетворили 22 исследования. После повторного скрининга остались 18 исследований, данные которых обобщены в данном обзоре. Мы извлекли информацию о типе примененных моделей ИИ, входных данных, точности диагностики либо прогностических метриках, а также оценили качество исследований и возможные ограничения. На рисунке представлена блок-схема отбора статей по протоколу PRISMA.



* Поиск литературы проводился в базах данных PubMed, Google Scholar, eLibrary (РИНЦ).

Блок-схема систематического обзора литературы, проведенного по протоколу PRISMA
PRISMA flowchart of the systematic literature review

■ РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Характеристика включенных в анализ исследований

В настоящий систематический обзор было включено 18 исследований, опубликованных в период с 2019 по 2024 г. (см. таблицу).

Основные характеристики включенных в обзор исследований (2019–2024 гг.)
Key characteristics of the studies included in the review (2019–2024)

Авторы и год публикации	Тип исследования	Размер выборки	Метод получения анализируемых изображений	Основные результаты
Alekseeva et al., 2023 [18]	Ретроспективное исследование с разработкой интеллектуальной системы поддержки принятия решений с использованием модели машинного обучения	КТ-изображения 162 пациентов (90 здоровых, 72 с одонтогенным гайморитом)	КТ	Точность разработанной модели для сегментации пазух составила 90,09%, чувствительность 94,2%, специфичность 96,3%, AUC=0,87. Разработана комплексная система для дифференциальной диагностики хронического одонтогенного гайморита, объединяющая анализ медицинских изображений с данными осмотра и опроса пациентов (через чат-бот)
Du et al, 2024 [19]	Ретроспективное исследование с использованием модели машинного обучения	Рентгенологические данные 251 пациента с ХРСсП (86 с эозинофильным и 165 с незозинофильным типом). Всего 29 993 КТ-изображения	КТ	Точность разработанной модели: 98,5% (обучающая выборка), 94,6% (валидационная), 94,3% (тестовая) для автоматического определения эндотипа ХРСсП. Чувствительность 96,1%, специфичность 96,4%
Gata et al, 2024 [20]	Проспективное исследование с использованием алгоритма машинного обучения	85 пациентов с ХРСсП, перенесших первичную эндоскопическую операцию на околоносовых пазухах	Рентгенологические исследования не анализировались. Проводился анализ следующих данных с помощью машинного обучения: демографические данные, уровень эозинофилов в крови, микроРНК-125b и микроРНК-203a-3p из ткани полипа, шкалы ОМШЛМ, SNOT-22, RHQ-9, POSE	Разработанный алгоритм машинного обучения предсказывал исходы операции через 18 месяцев с точностью 69,23% (на основе неинвазивных предоперационных параметров) и 84,62% (при включении значений микроРНК из клеток ткани полипа). МикроРНК-125b из ткани полипов значительно улучшила точность алгоритма и была определена как один из наиболее важных предикторов исхода заболевания. Алгоритм классифицировал пациентов на 3 категории на основе шкалы POSE: контролируемое течение (0–7), частичный контроль (8–15) или рецидив (16–32)
He et al., 2023 [21]	Ретроспективное исследование с использованием машинного обучения	Данные КТ околоносовых пазух 265 пациентов (200 для обучения модели, 65 для тестирования модели)	КТ	Разработанная модель многозадачного машинного обучения показала точность 81,3%, чувствительность 77,4% и специфичность 84,8% для прогнозирования рецидива ХРС

Продолжение таблицы

Hua et al., 2022 [22]	Ретроспективное исследование с применением машинного обучения	Данные КТ околоносовых пазух 878 пациентов (343 с эозинофильным РС и 535 с незозинофильным РС)	КТ	Разработанная модель показала точность 85,3%, чувствительность 75,4% и специфичность 89,1% для дифференциации эозинофильного и незозинофильного ХРС по данным предоперационной КТ. Модели, обученные на уровне пациентов, показали статистически значимо лучшие результаты ($p<0,01$) по сравнению с моделями, обученными на отдельных изображениях
Jeon et al., 2021 [23]	Ретроспективное исследование с применением машинного обучения	Данные КТ 1535 пациентов (1403 для обучения и валидации модели, 132 для тестирования модели)	Рентгенография, КТ	Разработанная модель машинного обучения показала AUC 0,71 для выявления фронтита, 0,78 – этмоидита и 0,88 – гайморита. По уровню диагностики модель превзошла рентгенологов по части выявления этмоидита ($p=0,012$) и гайморита ($p=0,013$). Также модель не требовала ручной обрезки изображений, автоматически обнаруживала и классифицировала все 3 пазухи билатерально
Kim et al., 2019 [24]	Ретроспективное исследование с применением машинного обучения	Рентгенограммы околоносовых пазух 4860 пациентов для внутреннего набора данных (2430 здоровых и 2430 с синуситом) и 160 пациентов для внешнего набора данных (80 здоровых и 80 с синуситом)	Рентгенография, КТ	Алгоритм множественного решения с использованием 3 нейросетевых моделей показал значительно более точное обнаружение синусита по сравнению с отдельными моделями. Чувствительность и специфичность для алгоритма множественного решения составили 90,8 и 98,85% (внутренний набор данных) и 89,61 и 98,7% (внешний набор данных) соответственно
Kim et al., 2022 [25]	Ретроспективное исследование с применением машинного обучения	Рентгенологические данные 512 пациентов для обучения модели (254 с грибковым поражением пазухи, 128 с ХРС, 130 здоровых); данные 64 пациентов для внешней валидации (26 с грибковым поражением пазухи, 18 с ХРС, 20 здоровых)	КТ	Точность разработанной модели для дифференциации поражений ВЧП составила $87,5\pm2,3\%$ (внутренняя валидизация) и $88,4\pm3,1\%$ (внешняя валидизация). Точность ИИ превысила точность ординаторов-оториноларингологов ($84,6\pm11,3\%$). Чувствительность составила $87,6\pm3,2\%$, специфичность $85,2\pm4,6\%$

Продолжение таблицы

Kotaki et al., 2023 [26]	Ретроспективное исследование с применением машинного обучения	Данные 520 пациентов. 860 панорамных изображений (430 с синуситом, 430 здоровых) из института А для базовой модели; 180 снимков по Уотерсу и 180 панорамных снимков из института Б для трансферного обучения (50 пациентов с операцией)	Рентгенография, КТ	Для снимков по Уотерсу AUC разработанной модели составила 0,830 vs 0,780 базовой модели vs 0,806 у рентгенологов. Точность составила 82,5% (разработанная модель) vs 72,1% (базовая) vs 77,0% (рентгенологи). Для панорамных изображений данные показатели были выше у разработанной модели
Kuo et al., 2022 [27]	Ретроспективное исследование с применением машинного обучения	Данные КТ-исследований 175 пациентов (из них 50 пациентов прошли хирургическое лечение)	КТ	Полуавтоматическая сегментация пазух с использованием машинного обучения показала точность 91,57%, точность пикселей 99,75%. Разработанная модель позволяет принимать обоснованные решения о тактике лечения. Пациенты с ОМШЛМ $\geq 7,75$ имеют высокую вероятность улучшения после операции, тогда как при показателях ниже порога рекомендуется консервативное лечение синусита
Kuwana et al., 2021 [28]	Ретроспективное исследование с использованием машинного обучения	Данные 611 пациентов (587 здоровых пазух, 416 воспаленных и 171 пазуха с кистами)	КТ, КЛКТ	Разработанная модель имела чувствительность обнаружения 100% для здоровых и воспаленных пазух, 89–98% для пазух с кистами. Точность диагностики синусита составила 90–91%, чувствительность 85–88%, специфичность 91–96%. Для диагностики кист в пазухах точность модели составила 97–100%, чувствительность 80–100%, специфичность 100%
Lim et al., 2022 [29]	Ретроспективное исследование	587 пациентов (446 с синуситом, 141 здоровый); 1174 рентгеновских изображений околоносовых пазух	Рентгенография, КТ	AUC для классификации верхнечелюстного синусита по данным рентгенологических изображений составила 0,722; AUC для левостороннего и правостороннего гайморита – 0,750 и 0,700 соответственно. Разработанная модель с вспомогательным классификатором показала лучшие результаты диагностики гайморита

Продолжение таблицы

Massey et al., 2022 [30]	Ретроспективное исследование	88 пациентов с ХРС, перенесших ринохирургические операции	КТ	Конечным продуктом исследования является полностью автоматизированный алгоритм на основе нейронной сети. Процент остеита коррелировал со шкалой GOSS ($p<0,001$), при этом корреляция была значительно выше у пациентов с предшествующими хирургическими вмешательствами ($p<0,001$), что подтверждает его значение как маркера рецидивирующего заболевания и предиктора неблагоприятных хирургических исходов
Mori et al., 2021 [31]	Ретроспективное исследование с трансферным обучением	Рентгенологические изображения 710 пациентов с односторонними гайморитами из 2 учреждений	Рентгенография, КТ, КЛКТ	Разработанная модель показала точность 88,8%, чувствительность 87,5%, специфичность 90% для выявления гайморита. Разные диагностические модели показали сопоставимо высокие результаты
Murata et al., 2019 [32]	Ретроспективное исследование с применением машинного обучения	Обучающая выборка: рентгенограммы 400 пациентов (800 синусов: 400 здоровых и 400 воспаленных). Тестовая выборка: 90 пациентов (120 синусов: 60 здоровых и 60 воспаленных)	Рентгенография, КТ, КЛКТ	Диагностическая эффективность системы машинного обучения для выявления гайморита на панорамных рентгенограммах: точность 87,5%, чувствительность 86,7%, специфичность 88,3%. Эффективность ИИ по части диагностики гайморита сопоставима с опытными рентгенологами (точность 89,6%) и значительно превосходит ординаторов-стоматологов (точность 76,7%, $p<0,05$)
Oh et al., 2021 [33]	Ретроспективное исследование	Данные рентгенологических изображений 2822 пациентов (внутренняя выборка: 1824 для обучения, 298 для валидации) и 700 изображений для внешней валидации из 3 разных учреждений	Рентгенография	Точность разработанной автоматической системы диагностики синусита по данным рентгенограмм составила 79,87–84,67%, чувствительность 75–89%, специфичность 85–96%. Модель обеспечивает полностью автоматизированный процесс диагностики гайморита на обычных рентгенограммах
Serindere et al., 2022 [34]	Ретроспективное исследование	296 изображений (148 здоровых, 148 с синуситом) в тренировочной выборке; 130 изображений для внешней валидации	Рентгенография, КЛКТ	Для панорамных рентгенограмм средняя точность диагностики синусита составила 75,7%, чувствительность 75,7%, специфичность 75,7%, AUC 0,755. Для КЛКТ средняя точность составила 99,7%, чувствительность 100%, специфичность 99,3%, AUC 0,997. Диагностическая эффективность разработанной ИИ-модели для выявления гайморита была умеренно высокой на панорамных рентгенограммах и значительно выше на КЛКТ-изображениях ($p<0,05$)

Окончание таблицы

Xiong et al., 2024 [35]	Ретроспективное многоцентровое исследование	Данные КТ 437 пациентов (307 в обучающей выборке и 130 в независимой валидационной выборке)	КТ	Разработаны номограмма и 4 модели машинного обучения для прогнозирования эозинофильного ХРС по данным КТ. AUC номограммы 0,867 в обучающей выборке, 0,867 в тестовой выборке, 0,837 во внешней валидации
-------------------------	---	---	----	--

Примечание: ВЧП – верхнечелюстная пазуха; ИИ – искусственный интеллект; КЛКТ – конусно-лучевая компьютерная томография; КТ – компьютерная томография; ОМШЛМ – объемно-модифицированная шкала Лунда – Маккея; РС – риносинусит; ХРС – хронический риносинусит; ХРСсП – хронический риносинусит с полипом носа; AUC – Area Under ROC-Curve (площадь под характеристической кривой); GOSS – Global Osteitis Scoring Scale (глобальная шкала оценки степени остейта); PHQ-9 – Patient Health Questionnaire for Depression (опросник состояния здоровья пациента для выявления депрессии, состоящий из 9 вопросов); POSE – Perioperative Sinus Endoscopy (шкала интраоперационной эндоскопической оценки слизистой оболочки околоносовых пазух); SNOT-22 – Sino-Nasal Outcome Test (назальный опросник качества жизни, состоящий из 22 пунктов).

Все исследования имели ретроспективный дизайн, за исключением 1 проспективного исследования [20]. Общий объем выборки составил 15212 пациентов, за исключением исследования [34], где представлено только количество рентгенологических изображений, при этом размер выборок в отдельных исследованиях варьировал от 64 [20] до 5020 пациентов [24].

Основным направлением применения искусственного интеллекта и машинного обучения стала автоматизированная диагностика воспалительных заболеваний околоносовых пазух по данным лучевых методов исследования. Большинство исследований [18, 19, 21–23, 25, 27, 28, 30, 34, 35] использовали КТ околоносовых пазух в качестве источника данных для обучения моделей, тогда как 7 исследований применяли обычные рентгенограммы или панорамные снимки [24, 26, 29, 31–34]. Точность диагностики синуситов при использовании разработанных моделей машинного обучения варьировала от 75,7 до 99,7% [34] в зависимости от типа используемых изображений и методологии исследования. Наиболее высокие показатели точности были достигнуты при анализе данных КЛКТ, где точность составила 99,7% с чувствительностью 100% и специфичностью 99,3% [34]. При использовании стандартных компьютерных томограмм точность диагностических моделей находилась в диапазоне от 81,3 до 98,5%.

Значительная группа исследований была посвящена дифференциальной диагностике различных форм хронического риносинусита (ХРС). В 3 исследованиях [19, 22, 35] разработали модели для разграничения эозинофильного и неэозинофильного вариантов хронического риносинусита с полипами носа (ХРСсП). Точность таких моделей составила от 85,3 до 98,5%, при этом чувствительность достигала 96,1%, а специфичность 96,4%. Одно исследование продемонстрировало возможность дифференциации одонтогенного гайморита от других форм синусита с точностью 90,09%, чувствительностью 94,2% и специфичностью 96,3% [18]. Исследование Kim и соавт. [25] было посвящено различению грибкового поражения верхнечелюстной пазухи, ХРС и здоровой пазухи, где разработанная модель показала точность 87,5% при внутренней валидации и 88,4% при внешней валидации, превысив точность ординаторов-оториноларингологов.

Прогностическое направление применения машинного обучения было представлено в 4 исследованиях. Две работы фокусировались на прогнозировании рецидива ХРС после хирургического лечения, демонстрируя точность от 69,23 до 84,62%.

При этом включение биологических маркеров, таких как микроРНК-125b из ткани полипов, значительно улучшало точность прогностических моделей до 84,62% [20]. Модель многозадачного машинного обучения для прогнозирования рецидива показала точность 81,3% с чувствительностью 77,4% и специфичностью 84,8% [21]. Исследование Massey и соавт. [30] разработало автоматизированный алгоритм для количественной оценки остеита на компьютерных томограммах, при этом процент остеита значимо коррелировал со шкалой послеоперационных исходов и был определен как предиктор неблагоприятных хирургических результатов.

Несколько исследований провели сравнение эффективности разработанных моделей искусственного интеллекта с диагностической точностью врачей-специалистов [23, 25, 26, 31, 32]. Модели машинного обучения продемонстрировали сопоставимую или превосходящую точность по сравнению с опытными рентгенологами и значительно превосходили показатели врачей-ординаторов. В частности, 1 модель превзошла рентгенологов в выявлении этмоидита и гайморита с уровнем статистической значимости $p < 0,05$ [23].

Важным аспектом разработанных систем стала их способность к автоматизированной сегментации околоносовых пазух и классификации патологических изменений без необходимости ручной предобработки изображений [18, 23, 28, 30, 33].

Искусственный интеллект для рентгенологической диагностики гайморита

Рентгенография пазух. Одними из первых успешных примеров применения ИИ в диагностике гайморита стали работы корейских исследователей, обучивших нейросети распознавать затемнение пазух на рентгеновских снимках лучше специалистов. Так, модель на основе глубокого обучения, обученная на 9000 снимков, достигла площади под ROC-кривой (AUC – Area Under Curve) 0,93–0,88 на тестовых наборах, превзойдя показания 5 рентгенологов (AUC у врачей составила 0,75–0,89). Чувствительность и специфичность ИИ при выявлении гайморита на рентгенограммах оказались сопоставимы с экспертными, а согласие между алгоритмом и решениями большинства рентгенологов было высоким ($\kappa=0,82$) [36]. В последующем множественные модели позволили одновременно анализировать стандартные проекции по Уотерсу (для верхнечелюстных и гайморовых пазух) и по Колдвеллу (для лобных и решетчатых) без ручного кадрирования изображений. Например, многослойная нейросеть успешно определяла синусит сразу в 3 околоносовых пазухах и AUC на рентгенограммах в стандартных проекциях составила 0,71 для лобных, 0,78 для решетчатых и 0,88 для верхнечелюстных пазух. Производительность такой модели была сопоставима с врачебной, причем для воспаления решетчатых и верхнечелюстных пазух ИИ значимо превзошел рентгенологов по точности ($p=0,01$) [23]. Также было показано, что использование сразу 2 проекций (Уотерс+Колдвелл) улучшает обнаружение воспаления верхнечелюстной пазухи по сравнению с 1 проекцией [23]. Эти результаты показывают, что машинное обучение способно повысить информативность обычной рентгенографии – дешевого первичного метода диагностики синуситов, минимизируя риск пропуска скрытых патологий.

Ретроспективное исследование, проведенное в рамках Московского эксперимента, оценило диагностическую точность 4 российских ИИ-сервисов для выявления гайморита и фронтита на рентгенограммах околоносовых пазух. Все 4 исследованных ИИ-сервиса показали высокую диагностическую ценность. Площадь под

ROC-кривой (AUC) варьировала в диапазоне от 0,86 до 0,96, при этом общая точность составила от 0,86 до 0,91. Наилучшие результаты показал ИИ-сервис № 1 с AUC 0,96 и точностью 91%, чувствительностью 84% и специфичностью 98%. Минимальные значения были зафиксированы у ИИ-сервиса № 4, где AUC составила 0,86, точность 86%, чувствительность 78% и специфичность 94% [37].

Компьютерная томография. Методом выбора визуализации околоносовых пазух является КТ, обладающая высокой чувствительностью к воспалительным изменениям [23]. ИИ-технологии нашли широкое применение в автоматическом анализе КТ, включая распознавание ключевых зон и количественную оценку объема поражения. Одно из первых исследований использовало нейросеть Inception-V3 для классификации состояния остеомаксиллярного комплекса – важной области сообщения пазух с полостью носа [38]. Алгоритм, обученный на коронарных срезах КТ 239 пациентов, достиг 85% точности в определении обтурации остеомаксиллярного комплекса и показал AUC 0,87 на тестовой выборке. Это существенно превосходило случайный уровень ($p < 0,0001$) и подтверждало, что ИИ способен самостоятельно обнаруживать рентгенологические признаки гайморита [38]. Дальнейшее развитие получили системы автоматической сегментации пазух и измерения степени их затуманивания. Так, Massey и соавт. [30] провели клиническую валидацию алгоритма, рассчитывающего процент объемной обструкции каждой пазухи по данным КТ. В исследовании с участием 88 пациентов разработанный алгоритм с ИИ успешно сегментировал 100% КТ-сканов различного качества. Автоматически рассчитанный процент опакфикации пазух имел высокую корреляцию с классической шкалой Лунда – Маккея ($p = 0,85$). Также метрики ИИ умеренно коррелировали с эндоскопическими индексами ($p = 0,58$ со шкалой Лунда – Кеннеди), а оценка процентного утолщения кости соотносилась с индексом остейта ($p = 0,48$) [30]. Авторы отмечают, что объективный количественный анализ КТ с помощью ИИ позволяет унифицировать оценку тяжести синусита и может помочь прогнозировать необходимость хирургического вмешательства. В другой работе реализован похожий подход, где производилось полное 3D-сегментирование всех пазух с вычислением их объема и объема воспалительной ткани [27]. Вычисленный ИИ суммарный объем поражения оказался выше у пациентов, которым потребовалась операция (в среднем 11,65 против 4,34; $p < 0,001$), и лучше предсказывал улучшение симптомов синусита после хирургического лечения (согласно опроснику SNOT-22) по сравнению с традиционной шкалой Лунда – Маккея [27]. Это указывает на прогностическую ценность автоматизированного анализа КТ-изображений, так как большой объем поражения, по данным ИИ, ассоциируется с более выраженным эффектом от операции.

ИИ также применяется для распознавания специфических форм гайморита и осложнений на КТ. Например, обученные нейросети успешно дифференцируют эозинофильный и неэозинофильный тип ХРСсП по характерным изменениям на предоперационной КТ. В 2024 г. была представлена многоракурсная нейросетевая модель, обученная на данных КТ-изображений 192 пациентов с ХРСсП. Она автоматически обнаруживала и классифицировала эндотип воспаления на эозинофильный и неэозинофильный с AUC 0,991 и точностью 96% на тестовой выборке [39]. Аналогичные результаты получены и другими группами, сравнивавшими различные алгоритмы МО для предоперационного прогнозирования эозинофильного воспаления по результатам неинвазивных методов исследований (КТ, уровни маркеров) [35, 39].

Высокоточное распознавание эозинофильного гайморита имеет важное клиническое значение, так как этот эндотип характеризуется более тяжелым течением и требует иной лечебной тактики, предполагающей агрессивную противовоспалительную терапию, применение различных биологических и таргетных препаратов и др. Более того, прогностические модели на основе КТ способны предугадать риск рецидива после хирургического лечения хронического синусита. В исследовании Не и соавт. [21] разработана нейросеть, совмещающая сегментацию пазух и извлечение радиомикс-признаков для предсказания повторного развития полипов после операции. Комбинация машинного обучения с клиническими факторами была оформлена в виде номограммы, показавшей высокую точность прогноза рецидива (AUC 0,85–0,90) по данным многоцентровой выборки из 265 КТ-исследований [21]. Тем самым ИИ-инструменты могут помочь идентифицировать пациентов с высоким риском неблагоприятного исхода и оптимизировать тактику ведения, например предусмотреть более интенсивную послеоперационную терапию таким пациентам.

Отдельно следует отметить применение ИИ в лучевой диагностике одонтогенного гайморита и грибковых синуситов. Специально обученные модели успешно отличают на КТ или конусно-лучевой томографии (КЛКТ) гайморит, связанный с одонтогенной инфекцией, от риногенного, сегментируя патологический материал в верхнечелюстной пазухе [18]. Другая работа показала, что предварительная фильтрация КТ-изображений с помощью ИИ заметно повышает точность как автоматической, так и врачебной диагностики грибкового поражения пазухи (мицетомы) по данным КЛКТ [40].

В целом современные алгоритмы машинного обучения демонстрируют высокие показатели в распознавании различных форм синуситов на снимках – от банального катарального гайморита до осложненных вариантов. Важно, что ИИ может не только ставить бинарный диагноз «есть / нет синусита», но и количественно оценивать степень поражения пазух, автоматически рассчитывая объем воспаления и степень остеита [30]. Такие объективные метрики способны стандартизировать диагностический процесс, снизить субъективность описаний и служить надежными критериями для отслеживания динамики заболевания. Однако для внедрения этих решений в рутинную практику необходима их масштабная валидация на независимых данных и интеграция в радиологические рабочие станции.

Кроме того, методы МО используют для интеграции больших массивов клинической информации, таких как результаты анализов, уровень маркеров воспаления, ответы пациентов на опросники. В одном из исследований был разработан прогностический классификатор, отличающий эозинофильный эндотип синусита на основании сочетания лабораторных показателей (количество эозинофилов крови, общий IgE), концентрации оксида азота в слизистой носа и характерного соотношения тяжести поражения решетчатых и верхнечелюстных пазух на КТ [41]. Нейросетевая модель на этих 4 параметрах показала AUC 0,98, превзойдя по точности стандартную логистическую регрессию (AUC 0,90) [41]. Такие интегральные биомаркерные модели помогут неинвазивно определять фенотипы РС при первом визите, что важно для персонализированного подбора терапии и назначения системных кортикостероидов при эозинофильном воспалении.

Прогностические модели и персонализированное ведение

Одно из ключевых направлений применения МО – прогнозирование исходов и ответов на лечение у пациентов с синуситом. Помимо уже упомянутых моделей предсказания рецидивов по данным КТ, интерес представляют работы, анализирующие большие наборы клинических данных для прогнозов. К примеру, Raghavan и соавт. [42] попытались с помощью МО еще на этапе направления пациента к специалисту предсказать, обнаружится ли у него на КТ значимое воспаление пазух (шкала Лунда – Маккея ≥ 5) и соответствующие симптомы ХРС. Используя массив предвизитных анкет 543 пациентов, авторы обучили несколько алгоритмов на 57 переменных из анамнеза и опросников. Наилучшая модель (XGBoost) достигла AUC 0,80 при прогнозировании ХРС, определенного как ≥ 2 ключевых симптомов и шкала Лунда – Маккея ≥ 5 на КТ). При этом специфичность модели была очень высокой (97%), хотя чувствительность ограниченной (36%) [42]. То есть ИИ-алгоритм хорошо идентифицировал ложно обращающихся пациентов, у которых жалобы есть, а объективно признаков синусита нет, но пропускал часть истинных случаев. Тем не менее даже такая селективность может быть полезна, и, как отмечают авторы, при дополнительной проверке на расширенной выборке такой инструмент позволит отбирать пациентов, которым на самом деле показано проведение КТ, и избегать лишнего облучения у других [42]. Также ИИ-модели могут прогнозировать эффективность конкретных вмешательств. Например, с помощью анализа данных опросников и эндоскопической картины до операции можно попытаться оценить, насколько улучшатся симптомы после эндоскопической хирургии пазух. Отдельные пилотные работы применяли методы кластеризации и статистического обучения, чтобы выявить факторы, ассоциированные с хорошим исходом операции, например изолированное поражение решетчатых пазух, низкий балл обоняния и др. [43]. Такие попытки показывают, что МО способно выявлять скрытые паттерны в больших клинических базах данных синуситов, что в будущем может лечь в основу персонализированных алгоритмов ведения, предсказать, кому из пациентов операция принесет максимум улучшения, а кому – минимальное.

Обсуждая результаты современных исследований, важно учитывать ограничения и все еще открытые и нерешенные вопросы применения ИИ. Несмотря на впечатляющие показатели точности на отдельных выборках, большинство моделей ИИ для диагностики синусита пока находятся на этапе испытаний. Многие исследования – ретроспективные, одноцентровые, с относительно небольшими выборками, что может ограничивать обобщаемость выводов. Существует проблема стандартизации, то есть разные работы используют различные критерии диагностики и конечные точки, а также различные технические подходы к обучению моделей. Поэтому необходимы единые валидационные наборы данных и многоцентровые исследования, чтобы подтвердить воспроизводимость результатов ИИ-моделей на различных популяциях [44]. Кроме того, важным препятствием остаются «прозрачность» и интерпретируемость нейросетей. Так, клиницистам зачастую трудно понять, какими признаками руководствуется алгоритм, вынося тот или иной диагноз по снимку. Это порождает определенное недоверие и требует разработки методов объяснимого ИИ. Тем не менее уже сегодня очевидно, что ИИ способен стать ценным дополнением к опыту врача, беря на себя рутинную оценку изображений и анализ больших данных, а окончательные решения должны приниматься врачом с опорой на весь

контекст пациента. В частности, отмечается, что врачам важно критически оценивать информацию, предоставляемую ИИ, и использовать ее лишь как вспомогательный инструмент [44]. При правильной интеграции технологий ИИ в клиническую практику можно ожидать повышения точности и оперативности диагностики воспалительных заболеваний околоносовых пазух, более рационального отбора пациентов для проведения КТ-исследования и для хирургического лечения, а также улучшения долгосрочных исходов за счет ранней идентификации неблагоприятных форм заболевания.

■ ЗАКЛЮЧЕНИЕ

Искусственный интеллект и машинное обучение открывают новые возможности в диагностике и прогнозировании воспалительных заболеваний околоносовых пазух. Анализ изображений с помощью обученных нейросетей уже продемонстрировал качество, сравнимое или превосходящее экспертов. ИИ-модели уверенно распознают воспалительные изменения на рентгенограммах и КТ околоносовых пазух, автоматически рассчитывают объем поражения и могут выявлять скрытые патологические паттерны. Алгоритмы машинного обучения позволяют неинвазивно различать клинически значимые эндотипы и предсказывать риск рецидивов после лечения. Таким образом, ИИ-инструменты способны повысить стандартизацию диагностики, снизить нагрузку на врачей при разборе большого объема данных и помочь в выборе оптимальной тактики ведения пациентов. Однако для широкого практического применения требуются дальнейшие исследования и усовершенствования. Необходимо проводить многоцентровые проспективные испытания ИИ-моделей, убедившись в их надежности на разных группах пациентов и совместимости с различным оборудованием. Важным шагом будет разработка стандартизированных протоколов внедрения ИИ в работу лор-отделений. Также следует уделять внимание интерпретируемости алгоритмов, чтобы выводы ИИ были понятны и достоверны для клиницистов. Тем не менее уже сейчас очевидно, что интеграция искусственного интеллекта в диагностику – это перспективное направление, которое в ближайшем будущем может привести к новому качеству оказания помощи пациентам с синуситом. Врач-оториноларинголог, вооруженный поддержкой интеллектуальных систем, сможет быстрее и точнее ставить диагноз, прогнозировать течение болезни и индивидуализировать лечение, что в конечном счете улучшит исходы и качество жизни пациентов.

■ ЛИТЕРАТУРА/REFERENCES

1. Helliwell T. Inflammatory diseases of the nasal cavities and paranasal sinuses. *Diagn Histopathol (Oxf)*. 2010;16(6):255–264. doi: 10.1016/j.mpdhp.2010.03.008
2. Zhang L, Zhang R, Pang K, et al. Prevalence and risk factors of chronic rhinosinusitis among Chinese: A systematic review and meta-analysis. *Front Public Health*. 2023;10:986026. doi: 10.3389/fpubh.2022.986026
3. Eloy P, Poirier A.L., De Dorlodot C, et al. Actual concepts in rhinosinusitis: a review of clinical presentations, inflammatory pathways, cytokine profiles, remodeling, and management. *Curr Allergy Asthma Rep*. 2011;11(2):146–162. doi: 10.1007/s11882-011-0180-0
4. Schleimer R.P. Immunopathogenesis of chronic rhinosinusitis and nasal polyposis. *Annu Rev Pathol*. 2017;12:331–357. doi: 10.1146/annurev-pathol-052016-100401
5. Kochetkov P.A., Fatyanova E.I. Acute rhinosinusitis: actual approaches to diagnosis and treatment. *Medical Council*. 2017;(8):130–136. doi: 10.21518/2079-701X-2017-8-130-136. (in Russian)
6. Shkurakova E.A., Gavenene Y.N. Studies of sinusitis incidence in Novocherkassk. *Int Res J*. 2024;7(145). doi: 10.60797/IRJ.2024.145.72. (in Russian)
7. Huang F., Liu F., Zhen X., et al. Pathogenesis, diagnosis, and treatment of infectious rhinosinusitis. *Microorganisms*. 2024;12(8):1690. doi: 10.3390/microorganisms12081690

8. Beule A. Epidemiology of chronic rhinosinusitis, selected risk factors, comorbidities, and economic burden. *GMS Curr Top Otorhinolaryngol Head Neck Surg.* 2015;14:Doc11. doi: 10.3205/cto000126
9. Rudmik L, Smith T.L. Quality of life in patients with chronic rhinosinusitis. *Curr Allergy Asthma Rep.* 2011;11(3):247–252. doi: 10.1007/s11882-010-0175-2
10. Thakur P, Sharma M, Kotwal S, et al. Inter observer agreement among radiologists and otorhinolaryngologists on paranasal sinus computed tomography scans in chronic rhinosinusitis. *Indian J Otolaryngol Head Neck Surg.* 2022;74(4):501–509. doi: 10.1007/s12070-021-03016-7
11. Jing A.B., Garg N., Zhang J., et al. AI solutions to the radiology workforce shortage. *NPJ Health Syst.* 2025;2:20. doi: 10.1038/s44401-025-00023-6
12. Barragán-Montero A., Javald U., Valdés G., et al. Artificial intelligence and machine learning for medical imaging: a technology review. *Phys Med.* 2021;83:242–256. doi: 10.1016/j.ejmp.2021.04.016
13. Najjar R. Redefining radiology: a review of artificial intelligence integration in medical imaging. *Diagnostics (Basel).* 2023;13(17):2760. doi: 10.3390/diagnostics13172760
14. Liu Y.Y., Jiang S.P., Wang Y.B. Artificial intelligence optimizes the standardized diagnosis and treatment of chronic sinusitis. *Front Physiol.* 2025;16:1522090. doi: 10.3389/fphys.2025.1522090
15. Whangbo J., Lee J., Kim Y.J., et al. Deep learning-based multi-class segmentation of the paranasal sinuses of sinusitis patients based on computed tomographic images. *Sensors (Basel).* 2024;24(6):1933. doi: 10.3390/s24061933
16. Zhang Y., Wang J., Pan T., et al. Nasa1Seg: a dataset for automatic segmentation of nasal cavity and paranasal sinuses from 3D CT images. *Sci Data.* 2024;11(1):1329. doi: 10.1038/s41597-024-04176-1
17. Page M.J., McKenzie J.E., Bossuyt P.M., et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ.* 2021;372:n71. doi: 10.1136/bmj.n71
18. Alekseeva V., Nechyporenko A., Frohme M., et al. Intelligent decision support system for differential diagnosis of chronic odontogenic rhinosinusitis based on U-Net segmentation. *Electronics.* 2023;12(5):1202. doi: 10.3390/electronics12051202
19. Du W., Kang W., Lai S., et al. Deep learning in computed tomography to predict endotype in chronic rhinosinusitis with nasal polyps. *BMC Med Imaging.* 2024;24:25. doi: 10.1186/s12880-024-01203-w
20. Gata A., Raduly L., Budisan L., et al. Machine learning model predicts postoperative outcomes in chronic rhinosinusitis with nasal polyps. *Clin Otolaryngol.* 2024;49(7):776–784. doi: 10.1111/coa.14208
21. He S., Chen W., Wang X., et al. Deep learning radiomics-based preoperative prediction of recurrence in chronic rhinosinusitis. *iScience.* 2023;26(4):106527. doi: 10.1016/j.jisci.2023.106527
22. Hua H.L., Li S., Xu Y., et al. Differentiation of eosinophilic and non-eosinophilic chronic rhinosinusitis on preoperative computed tomography using deep learning. *Clin Otolaryngol.* 2022;47(6):1016–1024. doi: 10.1111/coa.13988
23. Jeon Y., Lee K., Sunwoo L., et al. Deep learning for diagnosis of paranasal sinusitis using multi-view radiographs. *Diagnostics (Basel).* 2021;11(2):250. doi: 10.3390/diagnostics11020250
24. Kim H.G., Lee K.M., Kim E.J., et al. Improvement diagnostic accuracy of sinusitis recognition in paranasal sinus X-ray using multiple deep learning models. *Quant Imaging Med Surg.* 2019;9(6):942–951. doi: 10.21037/qims.2019.05.15
25. Kim K.S., Kim B.K., Chung M.J., et al. Detection of maxillary sinus fungal ball via 3D CNN-based artificial intelligence: fully automated system and clinical validation. *PLoS One.* 2022;17(2):e0263125. doi: 10.1371/journal.pone.0263125
26. Kotaki S., Nishiguchi T., Araragi M., et al. Transfer learning in diagnosis of maxillary sinusitis using panoramic radiography and conventional radiography. *Oral Radiol.* 2023;39(3):467–474. doi: 10.1007/s11282-022-00658-3
27. Kuo C.F., Chiu Y.C., Ho C.H., et al. Automatic detection of chronic rhinosinusitis on computed tomography using deep learning. *Clin Otolaryngol.* 2022;47(1):90–97. doi: 10.1111/coa.13887
28. Kuwana N., Seo Y., Ohta T., et al. Development of a deep learning-based automatic detection system for sinusitis using paranasal sinus X-ray images. *Sci Rep.* 2020;10(1):10266. doi: 10.1038/s41598-020-67234-8
29. Lim H.K., Kim J.H., Lee Y.J., et al. Artificial intelligence algorithm for automatic diagnosis of maxillary sinusitis in panoramic radiographs. *Diagnostics (Basel).* 2022;12(11):2621. doi: 10.3390/diagnostics12112621
30. Massey C.J., Ramos L., Beswick D.M., et al. Clinical validation and extension of an automated, deep learning-based algorithm for quantitative sinus CT analysis. *AJNR Am J Neuroradiol.* 2022;43(9):1318–1324. doi: 10.3174/ajnr.A7616
31. Mori M., Aritji Y., Katsumata A., et al. A deep transfer learning approach for the detection and diagnosis of maxillary sinusitis on panoramic radiographs. *Odontology.* 2021;109(4):918–927. doi: 10.1007/s10266-021-00615-2
32. Murata M., Aritji Y., Ohashi Y., et al. Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral Radiol.* 2019;35(4):301–307. doi: 10.1007/s11282-018-0363-7
33. Oh J.H., Kim H.G., Lee K.M., et al. Effective end-to-end deep learning process in medical imaging using independent task learning: application for diagnosis of maxillary sinusitis. *Yonsei Med J.* 2021;62(12):1125–1135. doi: 10.3349/ymj.2021.62.12.1125
34. Serindere G., Bilgili E., Yesil C., et al. Evaluation of maxillary sinusitis from panoramic radiographs and cone-beam computed tomographic images using a convolutional neural network. *Imaging Sci Dent.* 2022;52(3):187–195. doi: 10.5624/isd.20210263
35. Xiong P., Chen J., Zhang Y., et al. Predictive modeling for eosinophilic chronic rhinosinusitis: nomogram and four machine learning approaches. *iScience.* 2024;27(2):108928. doi: 10.1016/j.jisci.2024.108928
36. Kim Y., Lee K.J., Sunwoo L., et al. Deep learning in diagnosis of maxillary sinusitis using conventional radiography. *Invest Radiol.* 2019;54(1):7–15. doi: 10.1097/RLI.0000000000000503
37. Bazhin A.V., Vladzimirov A.V., Arzamasov K.M., et al. Combined treatment of patients with rectal cancer with a high risk of tumor progression. *Vestn Ross Nauch Tsentr Rentgenoradiol.* 2025;2025(1):28–40. (in Russian)
38. Chowdhury N.J., Smith T.L., Chandra R.K., et al. Automated classification of osteomeatal complex inflammation on computed tomography using convolutional neural networks. *Int Forum Allergy Rhinol.* 2019;9(1):46–52. doi: 10.1002/alr.22196
39. Zou J., Lyu Y., Lin Y., et al. A multi-view fusion lightweight network for CRSwNPs prediction on CT images. *BMC Med Imaging.* 2024;24(1):12. doi: 10.1186/s12880-024-01296-3
40. Kim K., Lim C.Y., Shin J., et al. Enhanced artificial intelligence-based diagnosis using CBCT with internal denoising: clinical validation for discrimination of fungal ball, sinusitis, and normal cases in the maxillary sinus. *Comput Methods Programs Biomed.* 2023;240:107708. doi: 10.1016/j.cmpb.2023.107708
41. Zhou H., Fan W., Qin D., et al. Development, validation and comparison of artificial neural network and logistic regression models predicting eosinophilic chronic rhinosinusitis with nasal polyps. *Allergy Asthma Immunol Res.* 2023;15(1):67–82. doi: 10.4168/air.2023.15.1.67
42. Raghavan A.M., Abouelisha M.A., Prohntich I., et al. Using machine learning models to diagnose chronic rhinosinusitis: analysis of pre-treatment patient-generated health data to predict cardinal symptoms and sinonasal inflammation. *Am J Rhinol Allergy.* 2025;39(3):229–236. doi: 10.1177/19458924251322081
43. Lötsch J., Hintschich C.A., Petridis P., et al. Machine-learning points at endoscopic, quality of life, and olfactory parameters as outcome criteria for endoscopic paranasal sinus surgery in chronic rhinosinusitis. *J Clin Med.* 2021;10(18):4245. doi: 10.3390/jcm10184245
44. Loperfido A., Minniti R.M., Maiorano E., et al. Diagnostic applications of artificial intelligence in chronic rhinosinusitis: a systematic review. *Acta Biomed.* 2025;96(2):16298. doi: 10.23750/abm.v96i2.16298