ISSN: 2582-4686 SJIF 2021-3.261,SJIF 2022-2.889, 2024-6.875 ResearchBib IF: 10.25 / 2025

THE MULTIDISCIPLINARY JOURNAL OF SCIENCE AND TECHNOLOGY

VOLUME-6, ISSUE-2

МЕТОДОЛОГИЧЕСКИЕ ОСНОВЫ ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В СТОМАТОЛОГИИ

Ашурова С.А., Eurasian Multidisciplinary University
Хабилов Н.Л., Ташкентский Государственный Медицинский Университет

Аннотация

В статье представлен теоретико-методологический анализ применения искусственного интеллекта (ИИ) в стоматологии. Обоснована необходимость разграничения алгоритмической эффективности и клинической валидности как ключевого условия клинической интеграции ИИ-систем. Рассмотрены особенности использования методов машинного и глубокого обучения в стоматологической диагностике и планировании лечения, а также ограничения, связанные с переносимостью моделей, качеством данных и алгоритмической предвзятостью. Предложена концепция уровней методологической зрелости применения ИИ, отражающая переход от алгоритмической апробации к клинической валидации и системной интеграции. Разработана трёхкомпонентная модель «врач – алгоритм – цифровая инфраструктура», описывающая структуру гибридного клинического принятия решений. Показано, что устойчивость внедрения ИИ определяется не только техническими характеристиками алгоритмов, но и качеством клинической валидации, интерпретируемостью моделей и уровнем цифровой инфраструктуры здравоохранения.

Ключевые слова: искусственный интеллект, стоматология, машинное обучение, клиническая валидность, методологическая зрелость, алгоритмическая предвзятость.

ABSTRACT

This article presents a theoretical and methodological analysis of artificial intelligence (AI) applications in dentistry. The distinction between algorithmic performance and clinical validity is substantiated as a fundamental prerequisite for responsible clinical integration of AI systems. The use of machine learning and deep learning methods in dental diagnostics and treatment planning is examined, along with limitations related to model generalizability, data quality, and algorithmic bias. A framework of methodological maturity levels is proposed, reflecting the transition from algorithmic testing to clinical validation and systemic integration. A three-component model (“physician – algorithm – digital infrastructure”) is developed to describe the hybrid structure of AI-assisted clinical decision-making. It is demonstrated that sustainable implementation of AI depends not only on technical performance but also on clinical validation, model interpretability, and the maturity of digital healthcare infrastructure.

Keywords: artificial intelligence, dentistry, machine learning, clinical validity, methodological maturity, algorithmic bias.

Цель исследования

Целью настоящей работы является теоретико-методологическое обоснование принципов клинической интеграции ИИ-систем в стоматологии на основе разграничения алгоритмической эффективности и клинической валидности, а также концептуализация уровней методологической зрелости и разработка трёхкомпонентной схемы внедрения «врач

ISSN: 2582-4686 SJIF 2021-3.261,SJIF 2022-2.889, 2024-6.875 ResearchBib IF: 10.25 / 2025

– алгоритм – цифровая инфраструктура» для оценки практической готовности интеллектуальных решений.

Материалы и методы

Работа выполнена в формате теоретико-аналитического обзора научной литературы с применением концептуально-методологического и сравнительного подходов. В анализ включены публикации, индексированные в PubMed, Scopus и Web of Science, посвящённые теоретическим основаниям ИИ, методам машинного и глубокого обучения, вопросам интерпретируемости моделей, клинической валидации и интеграции цифровых решений в здравоохранение.

В анализ были включены эмпирические публикации за период 2000–2025 гг., а также фундаментальные работы более раннего периода. Поиск осуществлялся по ключевым словам: “artificial intelligence”, “machine learning”, “deep learning”, “explainable AI”, “clinical validation”, “generalizability”, “bias”, “federated learning”, “digital medicine”, “dentistry”.

Для методологического анализа отбирались исследования с чётким описанием дизайна, характеристик данных, используемых показателей оценки и процедур внешней валидации. Анализ проводился по направлениям: разграничение алгоритмической эффективности и клинической валидности; оценка воспроизводимости и переносимости; систематизация барьеров клинического внедрения; концептуализация уровневой модели методологической зрелости.

1. Теоретические основания и технологическая эволюция ИИ

Термин «искусственный интеллект» был предложен в рамках Дартмутского проекта (1). Одной из концептуальных основ стала работа А. Тьюринга «Computing Machinery and Intelligence» (2), в которой была сформулирована проблема имитации когнитивных процессов машинными системами.

В последующие десятилетия развитие ИИ сопровождалось переходом от символических и экспертных систем к статистическим и нейросетевым подходам. Существенный технологический скачок связан с развитием методов машинного обучения и увеличением вычислительных мощностей, позволивших моделям выявлять сложные статистические зависимости в больших массивах данных (3, 4).

В рамках машинного обучения выделяют контролируемые, неконтролируемые и полуконтролируемые методы (5, 6). Нейросетевые архитектуры продемонстрировали способность моделировать нелинейные зависимости высокой сложности (7; 8; 4). Это обусловило их широкое внедрение в медицинскую визуализацию, включая радиологию и стоматологию (9).

В здравоохранении ИИ рассматривается как инструмент повышения воспроизводимости диагностики, интеграции разнородных клинических данных и оптимизации процессов принятия решений (10; 11; 12). В стоматологии применение ИИ охватывает анализ рентгенологических изображений, оценку пародонтального статуса, ортодонтическое и ортопедическое планирование (13).

Однако накопленные данные показывают, что высокая алгоритмическая точность не гарантирует клинической эффективности, что требует перехода от демонстрации статистической результативности к клинической валидации и регулируемой интеграции (14; 15).

ISSN: 2582-4686 SJIF 2021-3.261,SJIF 2022-2.889, 2024-6.875 ResearchBib IF: 10.25 / 2025

THE MULTIDISCIPLINARY JOURNAL OF SCIENCE AND TECHNOLOGY

VOLUME-6, ISSUE-2

2. Алгоритмическая эффективность и клиническая валидность

Высокие показатели accuracy, AUC или Dice-коэффициента отражают степень статистического совпадения, но не всегда свидетельствуют о клинической применимости модели. Клиническая практика предполагает работу с неопределённостью, вариативностью данных и контекстуальными факторами, не полностью представленными в обучающей выборке.

В биомедицинских задачах применяются сверточные нейронные сети (16), методы опорных векторов (17), ансамблевые алгоритмы (18; 19), а также нечёткие системы (20). Выбор алгоритма определяется не только технической эффективностью, но и требованиями интерпретируемости и клинической ответственности.

С целью повышения прозрачности исследований разработаны стандарты отчётности: MI-CLAIM (14), CONSORT-AI и SPIRIT-AI (21; 22), TRIPOD+AI (23), CLAIM (24). Регуляторные принципы SaMD закреплены в документах IMDRF (2017), а ВОЗ подчёркивает необходимость обеспечения безопасности и прозрачности ИИ в здравоохранении (25, 26).

Особую сложность представляют задачи сегментации и делимитации анатомических границ, при которых расхождения между экспертной и алгоритмической разметкой могут иметь клинические последствия. Традиционные метрики не учитывают пороги допустимого геометрического отклонения, влияющие на лечебную тактику. Следовательно, оценка должна включать анализ клинической значимости расхождений, а не только формальное совпадение разметок.

3. Уровни методологической зрелости применения ИИ в стоматологии

Анализ современной литературы и практики внедрения интеллектуальных технологий позволяет рассматривать применение ИИ в стоматологии как поэтапный процесс, проходящий через уровни методологической зрелости. Эти уровни отражают не только технологическое развитие алгоритмов, но и степень их клинической и организационной интеграции. Методологическая зрелость в данном контексте понимается как совокупность доказательной обоснованности, воспроизводимости, переносимости и нормативной регламентированности применения ИИ-систем.

Первый уровень — алгоритмическая апробация — характеризуется оценкой статистической точности модели на ретроспективных данных. На данном этапе основное внимание уделяется корректному разделению обучающей и тестовой выборок, прозрачности процедур разметки и выбору адекватных метрик оценки. Однако клиническая интерпретация результатов либо отсутствует, либо носит формальный характер.

Второй уровень — клиническая валидация — предполагает сопоставление результатов алгоритма с экспертной оценкой и анализ клинически допустимых отклонений. Именно на этом этапе происходит фактическое разграничение статистической результативности и клинической состоятельности. Модель может демонстрировать высокие интегральные показатели, но при этом формировать клинически значимые ошибки в чувствительных зонах.

Третий уровень — системная интеграция — связан с включением ИИ в реальные клинические рабочие процессы. Он предполагает проспективную оценку эффективности, мониторинг стабильности модели, регламентированные процедуры обновления и документированное распределение ответственности. На данном этапе ключевым риском становится феномен автоматизированного смещения решений (automation bias), при котором клиницист склонен

ISSN: 2582-4686 SJIF 2021-3.261,SJIF 2022-2.889, 2024-6.875 ResearchBib IF: 10.25 / 2025

избыточно доверять алгоритмическому выводу. Поэтому системная интеграция требует не только технической стабильности модели, но и формирования культуры критической интерпретации алгоритмических рекомендаций.

Таким образом, переход между уровнями методологической зрелости отражает движение от демонстрации алгоритмической эффективности к формированию устойчивой клинической системы взаимодействия человека и алгоритма.

4. Системные ограничения данных и алгоритмическая предвзятость (расширенная версия)

Интеграция ИИ в стоматологическую практику во многом определяется качеством, полнотой и репрезентативностью клинико-диагностических данных. Стоматологическая информация представлена рентгенологическими изображениями, цифровыми 3D-моделями, клиническими протоколами и электронными медицинскими записями, которые нередко распределены между разрозненными и несовместимыми информационными системами. Такая фрагментарность затрудняет формирование однородных обучающих выборок и повышает риск систематических искажений (27).

Современные подходы, такие как федеративное обучение (28), направлены на расширение обучающих выборок без централизации данных, а методы few-shot learning (19) позволяют работать с ограниченным числом размеченных примеров. Тем не менее технологические решения не заменяют необходимости строгой клинической валидации, прозрачной отчётности и регламентированной оценки устойчивости моделей.

Инфраструктурная среда играет принципиальную роль в обеспечении устойчивого внедрения. В Республике Узбекистан процессы цифровизации здравоохранения институционально закреплены и сопровождаются развитием государственных информационных систем. Однако различия в технической оснащённости медицинских организаций, отсутствие унифицированных стандартов разметки стоматологических данных и ограниченная интероперабельность информационных систем сдерживают масштабирование ИИ-решений.

5. Концептуальная модель «врач – алгоритм – цифровая инфраструктура»

С методологической точки зрения применение ИИ в стоматологии следует рассматривать не как внедрение отдельного алгоритма, а как формирование трёхкомпонентной системы взаимодействия, объединяющей когнитивный, алгоритмический и инфраструктурный уровни. Когнитивный уровень представлен клиническим мышлением врача, основанным на профессиональной подготовке, клиническом опыте, знании патогенеза заболеваний и способности интерпретировать неоднозначные диагностические данные. Клиническое решение остаётся зоной профессиональной ответственности специалиста (29), что требует сохранения приоритета экспертной оценки при использовании алгоритмических рекомендаций.

Алгоритмический уровень включает методы машинного и глубокого обучения (3; 4), обеспечивающие выявление статистических закономерностей в больших массивах данных. Их преимуществом является воспроизводимость и масштабируемость, однако выводы зависят от структуры обучающих данных и не обладают самостоятельной причинной интерпретацией. Интерпретируемость и прозрачность алгоритмов становятся ключевыми условиями формирования клинического доверия.

ISSN: 2582-4686 SJIF 2021-3.261,SJIF 2022-2.889, 2024-6.875 ResearchBib IF: 10.25 / 2025

THE MULTIDISCIPLINARY JOURNAL OF SCIENCE AND TECHNOLOGY

VOLUME-6, ISSUE-2

Инфраструктурный уровень объединяет цифровые базы данных, стандарты отчётности, механизмы хранения и обмена медицинской информацией, а также нормативно-правовые условия внедрения (27; 28). Именно этот уровень определяет переносимость моделей между клиниками, устойчивость к систематическим смещениям данных и возможность масштабирования решений в реальной практике.

Взаимодействие трёх уровней формирует гибридную систему принятия решений, в которой алгоритм выступает инструментом аналитического усиления клинического мышления, но не его заменой. Устойчивость такой системы определяется степенью согласованности её компонентов и наличием механизмов контроля качества и переоценки алгоритмических решений.

Выводы

Внедрение ИИ в стоматологии представляет собой переход к гибридной модели клинического принятия решений, при которой алгоритмический анализ усиливает, но не заменяет профессиональное клиническое мышление.

Высокая алгоритмическая точность не является достаточным основанием для клинической интеграции без внешней валидации, анализа переносимости и оценки устойчивости модели в реальных условиях практики.

Методологическая зрелость применения ИИ определяется последовательным переходом от алгоритмической апробации к клинической валидации и далее — к системной интеграции. Ключевым условием устойчивого внедрения является согласованность когнитивного, алгоритмического и инфраструктурного уровней клинической системы, а также наличие регламентированных процедур мониторинга и переоценки алгоритмических решений.

Список литературы

1. McCarthy J, Minsky ML, Rochester N, Shannon CE. A proposal for the Dartmouth summer research project on artificial intelligence. 1955.

2. Turing AM. Computing machinery and intelligence. Mind. 1950;59:433–460. doi:10.1093/mind/LIX.236.433

3. Friedman J, Hastie T, Tibshirani R. The elements of statistical learning. New York: Springer; 2001.

4. LeCun Y, Bengio Y, Hinton G. Deep learning. Nature. 2015;521:436–444. doi:10.1038/nature14539

5. Hastie T, Tibshirani R, Friedman J. The elements of statistical learning. 2nd ed. New York: Springer; 2009.

6. Zhu X, Goldberg AB. Introduction to semi-supervised learning. Morgan & Claypool; 2009.

7. Hornik K. Approximation capabilities of multilayer feedforward networks. Neural Netw. 1991;4:251–257. doi:10.1016/0893-6080(91)90009-T

8. Schmidhuber J. Deep learning in neural networks: An overview. Neural Netw. 2015;61:85–117. doi:10.1016/j.neunet.2014.09.003

9. Kalra MK, et al. Machine learning in radiology. Radiology. 2020;295:517–529. doi:10.1148/radiol.2020191114

10. Hamet P, Tremblay J. Artificial intelligence in medicine. Metabolism. 2017;69:S36–S40. doi:10.1016/j.metabol.2017.01.011

11. Naylor CD. On the prospects for a (deep) learning health care system. JAMA. 2018;320:1099–1100. doi:10.1001/jama.2018.11129

ISSN: 2582-4686 SJIF 2021-3.261,SJIF 2022-2.889, 2024-6.875 ResearchBib IF: 10.25 / 2025

12. Topol E. Deep medicine: how artificial intelligence can make healthcare human again. New York: Basic Books; 2019.
13. Khanagar SB, Al-Ehaideb A, Maganur PC, et al. Developments, application, and performance of artificial intelligence in dentistry – A systematic review. J Dent Sci. 2021;16:508–522. doi:10.1016/j.jds.2020.06.019
14. Norgeot B, Quer G, Beaulieu-Jones BK, et al. Minimum information about clinical artificial intelligence modeling: the MI-CLAIM checklist. Nat Med. 2020;26(9):1320–1324. doi:10.1038/s41591-020-1041-y
15. Hagras H. Toward human-understandable, explainable artificial intelligence. Computer. 2018;51(9):28–36. doi:10.1109/MC.2018.3620965
16. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. Commun ACM. 2017;60:84–90.
17. Schölkopf B, Smola AJ. Learning with kernels: support vector machines, regularization, optimization, and beyond. Cambridge (MA): MIT Press; 2001.
18. Breiman L. Random forests. Mach Learn. 2001;45:5–32. Chen T, Guestrin C. XGBoost: A scalable tree boosting system. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016. p. 785–794. doi:10.1145/2939672.2939785
19. Ge R, Chen X, Chen Y. Few-shot learning for medical image analysis. Med Image Anal. 2022;75:102276. doi:10.1016/j.media.2021.102276
20. Zimmermann HJ. Fuzzy set theory—and its applications. 4th ed. New York: Springer; 2011.
21. Liu X, Rivera SC, Moher D, Calvert MJ, Denniston AK. Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: the CONSORT-AI extension. BMJ. 2020;370:m3164. doi:10.1136/bmj.m3164
22. Rivera SC, Liu X, Chan A-W, Denniston AK, Calvert MJ. Guidelines for clinical trial protocols for interventions involving artificial intelligence: the SPIRIT-AI extension. BMJ. 2020;370:m3210. doi:10.1136/bmj.m3210
23. Collins GS, Moons KGM, Dhiman P, et al. TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. BMJ. 2024;385:e078378. doi:10.1136/bmj-2023-078378
24. Mongan J, Moy L, Kahn CE Jr. Checklist for Artificial Intelligence in Medical Imaging (CLAIM): a guide for authors and reviewers. Radiol Artif Intell. 2020;2:e200029. doi:10.1148/ryai.2020200029
25. World Health Organization. Ethics and governance of artificial intelligence for health. Geneva: WHO; 2021.
26. World Health Organization. Regulatory considerations on artificial intelligence for health. Geneva: WHO; 2023.
27. Vest JR, Gamm LD. Health information exchange. J Am Med Inform Assoc. 2010;17:288–294. doi:10.1136/jamia.2010.003673
28. Rieke N, et al. The future of digital health with federated learning. NPJ Digit Med. 2020;3:119. doi:10.1038/s41746-020-00323-1
29. Israni ST, Verghese A. Humanizing artificial intelligence. JAMA. 2019;321(1):29–30. doi:10.1001/jama.2018.19398