

<https://doi.org/10.17116/rosstomat202619012165>

Прогнозирование успеха дентальной имплантации с использованием искусственного интеллекта и машинного обучения

© Юлия Александровна Семёнова^{1, 2}, Никита Алексеевич Шербинин³, Давид Станиславович Хестанов⁴, Максим Сергеевич Абин³, Анна Георгиевна Уварова³, Хава Билаловна Эльбуздукаева⁵, Алимхан Рустамович Масхадов⁵

¹ООО «ИРИС См», Центр челюстно-лицевой и дентальной имплантологии «I.R.I.S.», Смоленск, Россия;

²ФГБОУ ВО «Смоленский государственный медицинский университет» Минздрава России, Смоленск, Россия;

³ФГБОУ ВО «Кубанский государственный медицинский университет» Минздрава России, Краснодар, Россия;

⁴ФГБОУ ВО «Северо-Осетинская государственная медицинская академия» Минздрава России, Владикавказ, Россия;

⁵ФГБОУ ВО «Волгоградский государственный медицинский университет» Минздрава России, Волгоград, Россия

РЕЗЮМЕ

Цель исследования. Оценить современные модели искусственного интеллекта (ИИ) и машинного обучения (ML), применяемые для прогнозирования исходов дентальной имплантации, а также выявить ключевые факторы риска и показатели эффективности на основе систематического обзора литературы.

Материалы и методы. Проведен систематический обзор литературы в соответствии с рекомендациями PRISMA 2020. Поиск выполнен в базах PubMed и eLIBRARY, а также путем ручного поиска публикаций за период 2015—2025 гг. В анализ включены оригинальные клинические исследования, в которых использовались методы искусственного интеллекта и машинного обучения (ИИ/ML) для прогнозирования исходов дентальной имплантации, включая успех остеоинтеграции, развитие осложнений и периимплантита. Оценка риска систематической ошибки проводилась с применением инструментов RoB 2.0, PROBAST и QUADAS-2. Синтез данных выполнен в качественном формате.

Результаты. В итоговый анализ включено 22 исследования. Наиболее высокие показатели точности продемонстрировали модели глубокого обучения, преимущественно сверточные нейронные сети, при анализе данных конусно-лучевой компьютерной томографии (КЛКТ) и панорамных рентгенограмм (AUC до 0,93; точность >90%). Ансамблевые алгоритмы обеспечивали устойчивые результаты и позволяли выявлять значимые клинические предикторы. Ключевыми факторами риска во всех моделях оставались курение, состояние гигиены полости рта, плотность костной ткани, размеры имплантата и сопутствующие заболевания.

Выводы. Методы ИИ и ML обладают высоким потенциалом для персонализированного прогнозирования исходов дентальной имплантации. Наиболее перспективным направлением является интеграция рентгенологических, клинических и биологических данных при обязательной внешней валидации моделей.

Ключевые слова: дентальная имплантация, искусственный интеллект, машинное обучение, прогнозирование, периимплантит.

ИНФОРМАЦИЯ ОБ АВТОРАХ:

Семёнова Ю.А. — <https://orcid.org/0000-0001-7580-102X>

Шербинин Н.А. — e-mail: drscherbinin@yandex.ru

Хестанов Д.С. — <https://orcid.org/0009-0004-1597-7567>

Абин М.С. — <https://orcid.org/0009-0000-3250-245X>

Уварова А.Г. — <https://orcid.org/0000-0002-9084-0569>

Эльбуздукаева Х.Б. — <https://orcid.org/0009-0002-3813-7021>

Масхадов А.Р. — <https://orcid.org/0009-0006-6735-4390>

Автор ответственный за переписку: Семёнова Ю.А. — e-mail: juliya_semenova@bk.ru

КАК ЦИТИРОВАТЬ:

Семёнова Ю.А., Шербинин Н.А., Хестанов Д.С., Абин М.С., Уварова А.Г., Эльбуздукаева Х.Б., Масхадов А.Р. Прогнозирование успеха дентальной имплантации с использованием искусственного интеллекта и машинного обучения. *Российская стоматология*. 2026;19(1-2):165–173. <https://doi.org/10.17116/rosstomat202619012165>

Prediction of dental implant success using artificial intelligence and machine learning

© Yu.A. Semenova^{1,2}, N.A. Shcherbinin³, D.S. Khestanov⁴, M.S. Abin³, A.G. Uvarova³, Kh.B. Elbuzdukaeva⁵, A.R. Maskhadov⁵

¹IRIS Sm LLC, Center for Maxillofacial and Dental Implantology “I.R.I.S.”, Smolensk, Russia;

²Smolensk State Medical University, Ministry of Health of the Russian Federation, Smolensk, Russia;

³Kuban State Medical University, Ministry of Health of the Russian Federation, Krasnodar, Russia;

⁴North Ossetian State Medical Academy, Ministry of Health of the Russian Federation, Vladikavkaz, Russia;

⁵Volgograd State Medical University, Ministry of Health of the Russian Federation, Volgograd, Russia

ABSTRACT

Objective. To evaluate current artificial intelligence (AI) and machine learning (ML) models used for predicting dental implant outcomes and to identify key risk factors and performance metrics based on a systematic literature review.

Materials and methods. A systematic review was conducted in accordance with PRISMA 2020 guidelines. Literature searches were performed in PubMed and eLIBRARY databases, supplemented by manual searches of publications from 2015 to 2025. Original clinical studies applying AI/ML methods to predict dental implant success or complications were included. Risk of bias was assessed using RoB 2.0, PROBAST, and QUADAS-2 tools. Due to methodological heterogeneity, a qualitative synthesis was performed.

Results. Twenty-two studies were included in the final analysis. Deep learning models, particularly convolutional neural networks applied to CBCT and panoramic radiographic data, demonstrated the highest predictive performance (AUC up to 0.93; accuracy >90%). Ensemble ML methods showed stable predictive capability and facilitated identification of clinically relevant predictors. Smoking, oral hygiene status, bone quality, implant dimensions, and systemic diseases consistently emerged as major risk factors across models.

Conclusion. AI and ML methods show strong potential for improving personalized prediction of dental implant outcomes. Future progress depends on integrating multimodal clinical and radiological data, improving interpretability, and conducting external validation to support clinical implementation.

Keywords: dental implants, artificial intelligence, machine learning, prediction, peri-implantitis.

INFORMATION ABOUT THE AUTHORS:

Semenova Yu.A. — <https://orcid.org/0000-0001-7580-102X>

Shcherbinin N.A. — e-mail: drscherbinin@yandex.ru

Khestanov D.S. — <https://orcid.org/0009-0004-1597-7567>

Abin M.S. — <https://orcid.org/0009-0000-3250-245X>

Uvarova A.G. — <https://orcid.org/0000-0002-9084-0569>

Elbuzdukaeva Kh.B. — <https://orcid.org/0009-0002-3813-7021>

Maskhadov A.R. — <https://orcid.org/0009-0006-6735-4390>

Corresponding author: Semenova Yu.A. — e-mail: juliya_semenova@bk.ru

TO CITE THIS ARTICLE:

Semenova Yu.A, Shcherbinin NA, Khestanov DS, Abin MS, Uvarova AG, Elbuzdukaeva KhB, Maskhadov AR. Prediction of dental implant success using artificial intelligence and machine learning. *Russian Journal of Stomatology*. 2026;19(1-2):165–173. (In Russ.). <https://doi.org/10.17116/rosstomat202619012165>

Введение

Дентальная имплантация — один из наиболее широко применяемых методов стоматологической реабилитации. При соблюдении протоколов 10-летняя выживаемость имплантатов составляет ~90—95 % [1]. Тем не менее риск неудач и развития периимплантита сохраняется, что обусловлено многофакторной природой осложнений: состоянием мягких и костных тканей, дизайном и поверхностью имплантата, хирургическим протоколом, уровнем гигиены и системными факторами. Современная предоперационная оценка включает конусно-лучевую компьютерную томографию (КЛКТ) и исследование состояния тканей пародонта, формируя основу для стратификации риска [2]. Структурные особенности перимплантатных тканей дополнительно обосновывают необходимость специфических прогностических критериев [3]. На этом фоне растет интерес к применению методов искусственного интеллекта и машинного обучения (ИИ/ML) для интеграции клинических, рентгенологических и иных параметров [4, 5]. В ряде исследований показано, что ИИ-модели демонстрируют более высокую точность прогноза по сравнению с традиционными методами, основанными на экспертной интерпретации клинических признаков, оценке объема кости по КЛКТ, анализе анамнеза и индивидуальных факторов риска. Это связано с возможностью анализа больших объемов данных, автоматического выявления сложных взаимосвязей между факторами риска и исключения субъективного влияния. Таким образом, ИИ/ML рассматриваются как перспективный инструмент для повышения

воспроизводимости и персонализации прогноза исходов дентальной имплантации.

Цель исследования — оценить существующие модели прогнозирования исходов дентальной имплантации на базе методов искусственного интеллекта (ИИ) и машинного обучения (ML), используемые для прогнозирования исходов дентальной имплантации, а также выделить ключевые факторы риска, описать типы моделей и метрики эффективности на основе систематического обзора литературы по стандарту PRISMA 2020.

Материалы и методы

Систематический обзор проведен в соответствии с рекомендациями PRISMA 2020 (Preferred Reporting Items for Systematic Reviews and Meta-Analyses). Поиск литературы завершён 10 августа 2025 г.

Поиск осуществлялся в базах данных PubMed (запросы на английском языке) и eLIBRARY (ключевые слова на русском языке). Дополнительно выполнялся ручной поиск через Google Scholar и обратные ссылки из релевантных публикаций. В запросах использовались ключевые слова: *dental implant, artificial intelligence, machine learning, neural networks, prediction, prognosis* и их русскоязычные аналоги. Ограничения поиска: публикации 2015—2025 гг. на английском и русском языках. В базе eLIBRARY не работали логические операторы, поэтому запросы приходилось вводить отдельно и суммировать вручную, что привело к большому количеству найденных источников и, соответственно, более значительному отсеву на последующих этапах.

Всего было идентифицировано 205 публикаций: 55 в базе PubMed, 125 в eLIBRARY и 25 в результате ручного поиска. После удаления 9 дублирующих записей осталось 196 уникальных публикаций. На этапе скрининга заголовков и аннотаций исключено 157 работ, из них: 92 не соответствовали тематике (например, описывали дентальную имплантацию без применения методов ИИ/ML), 18 представляли собой доклинические исследования (*in vitro* или на животных моделях), 14 не включали алгоритмов машинного обучения, 33 оказались обзорными материалами или письмами в редакцию. Для полнотекстовой оценки было отобрано 39 источников.

После анализа текста исключено еще 17 публикаций: 5 — без клинических данных, 4 — с комбинированными интервенциями, не позволяющими выделить вклад ИИ/ML, 5 — с высоким риском систематической ошибки и 3 — без доступа к полному тексту, поскольку отсутствие полного текста не позволяло извлечь ключевые данные, необходимые для систематического анализа, включая дизайн исследования, характеристики выборки, описание используемых моделей ИИ/ML и метрики их эффективности. Отсутствие доступа было связано с платным распространением отдельных журналов и невозможностью получения полного текста через открытые источники и институциональные подписки на момент проведения поиска. Данный критерий исключения является стандартным для систематических обзоров и был применен одинаково ко всем найденным публикациям. Следует учитывать, что при наличии доступа у других исследователей результаты их анализа могут незначительно отличаться.

В итоговый анализ включены 22 публикации, соответствующие критериям отбора: 10 — из баз данных и 12 — найденные при ручном поиске.

Для подготовки обзора помимо 22 отобранных для анализа оригинальных исследований мы также использовали дополнительные источники (обзоры, методологические статьи, справочные материалы), необходимые для интерпретации результатов, описания методов и обоснования подходов.

Оценка риска систематической ошибки проводилась двумя независимыми рецензентами. Использовались валидированные инструменты: Cochrane RoB 2.0 для рандомизированных исследований, PROBAST (Prediction model Risk Of Bias Assessment Tool) для observational исследований с предсказательными моделями и QUADAS-2 для диагностических моделей. При расхождениях привлекался третий эксперт.

Из-за ожидаемой гетерогенности исходов и методов построения моделей метаанализ не проводился. Синтез данных выполнен в качественном формате с группировкой результатов по типам алгоритмов (CNN, ансамблевые методы, регрессионные модели и др.), по предикторам (КЛКТ-параметры, факторы риска, демографические данные), по используемым метрикам эффективности и по наличию внешней валидации (табл. 1).

Результаты

Все 22 включенных исследования (2016—2025 гг.) продемонстрировали потенциал методов ИИ/ML в прогнозировании исходов дентальной имплантации и связанных с ней осложнений [4—7]. Наиболее высокие показатели точности отмечены в работах, в которых использованы глубокие нейронные сети (CNN) для анализа изображений. Так,

одна из моделей CNN, обученная на данных КЛКТ, дооперационно предсказывала вероятность успешной имплантации с точностью около 87%. Повышение процента приживления, зафиксированное в исследовании, было связано с клиническими действиями, предпринятыми на его основе: пациенты с выявленными неблагоприятными параметрами костной ткани направлялись на дополнительные вмешательства — костную аугментацию, изменение протокола имплантации или отсрочку установки [4]. Различные архитектуры глубокого обучения успешно определяли пригодность места для немедленной имплантации по ортопантомограмме: во всех случаях достигнуты чувствительность, сбалансированная точность и F_1 -меры $> 0,90$ [7]. Алгоритм обнаружения периимплантита на рентгенограммах (YOLOv7) показал специфичность 100%, точность 100%, полноту ~94% и F_1 ~97% при автоматическом выявлении очагов поражения [8]. Многозадачная CNN-модель для оценки стабильности имплантата, по данным КЛКТ, достигла тестовой точности ~93—96% (двух- и многоклассовая классификация) при среднем времени анализа ~3,8 с [9]. Интегрированный подход, объединяющий 3D-CNN для радиомики и клинические данные, позволил спрогнозировать риск неудачи синус-лифтинга с AUC ~0,93 (точность ~90%), тогда как чисто клиническая модель дала точность лишь ~0,60 [10]. Кроме того, автоматизированная градация плотности кости на основе ИИ показала значимую положительную корреляцию коэффициентов минеральной плотности кости (BMD) с первичной стабильностью имплантатов (ISQ) в коронарной и средней зонах ($r \approx 0,5-0,6$; $p < 0,05$) [11], что согласуется с клиническими наблюдениями: более высокая плотность костной ткани обеспечивает лучшую фиксацию. Технологии ИИ также успешно сопоставлены с опытом специалистов. В прецизионном планировании имплантации на основании КЛКТ автоматизированная система сформировала клинически приемлемый план в 89% случаев против 93% у экспертов, при этом среднее время на планирование сократилось с ~406 с до ~187 с [12]. Точность расположения имплантата при использовании такой системы соответствовала врачебной: среднее линейное отклонение платформы составило ~0,9 мм, угловое — ~5°, а подбор размеров имплантата практически совпал с решениями специалистов [13]. Заметим, что и вне сфер визуализации методы ML проявили себя: например, искусственная нейронная сеть, обученная на дифференциально экспрессированных генах, смогла по профилю экспрессии точно классифицировать образцы тканей с периимплантитом и здоровых пациентов, что открывает возможности ранней диагностики заболевания на молекулярном уровне [14]. Кроме того, в российском исследовании показана возможность применения нейросетевой модели для количественной морфологической оценки ремоделирования костной ткани после реконструктивно-восстановительных операций. На материале биопсий у 30 пациентов искусственная нейронная сеть на базе GoogLeNet смогла с достоверностью $\geq 95\%$ определить степень зрелости новообразованной кости, результаты совпадали с гистологическим анализом, при этом исключалось влияние субъективного выбора полей зрения [15].

Ансамблевые и гибридные алгоритмы машинного обучения также показали уверенные результаты. Так, комбинированная модель (дерево решений, SVM, k-ближайших соседей, Naïve Bayes, ИНС) превзошла каждый из алгоритмов по отдельности, повысив чувствительность прогноза успеха имплантации на ~13% и специфичность на ~25% [5]. Служ

Таблица 1. PRISMA, последовательность отбора публикаций

Table 1. PRISMA, the selection sequence of publications

Этап	Записи	Исключено	Осталось	Основные причины исключения
Идентификация	PubMed: 55 eLIBRARY: 125 Ручной поиск: 25	9	196	Дубликаты
Скрининг заголовков/ аннотаций	196	157	39	~92 не по теме; ~15 — in vitro/животные; 18 — без ИИ/ML; 32 — обзоры/письма
Полнотекстовая оценка	39	17	22	5 — без клинических данных; 4 — смешанные интервенции; 5 — высокий риск bias; 3 — без доступа к полному тексту
Включено в обзор	22	—	22	10 — из баз данных, 12 — из ручного поиска

чайные леса (ensemble-метод) продемонстрировали приемлемое качество предсказания периимплантата (ROC-AUC ~0,71, точность ~70%) и позволили выявить ключевые факторы риска: длительный срок функционирования имплантата, высокий индекс налета, узкая зона кератинизированной десны, малое число окклюзионных контактов и курение [5]. В веб-приложении, предназначенном для оценки риска неудачной имплантации, метод случайного леса продемонстрировал наивысшую прогностическую точность: площадь под ROC-кривой (AUC) составила 0,872 для отторжения имплантата и 0,840 для периимплантата. Ключевыми прогностическими факторами отторжения имплантата оказались объем введенной местной анестезии (возможно, как косвенный маркер сложности вмешательства), длина и диаметр имплантата, профилактический прием антибиотиков и частота гигиенических визитов. В случае периимплантата среди ведущих предикторов также отмечалось наличие сахарного диабета 2 типа (в основном в хронической компенсированной форме, согласно описанию включенных в исследование) при сходных остальных параметрах [16]. Применение AutoML также показало эффективность: алгоритм TPOT на данных о микробиоме полости рта автоматически подобрал модели с ROC-AUC, чувствительностью и специфичностью в диапазоне 0,80—1,00 [17]. Причем классификация по микробиому слюны дала более высокую точность, чем по микробиому налета. Помимо классификации ML использовался для стратификации пациентов. Так, на основе профилей иммунных клеток (алгоритм FARDEEP) и кластерного анализа пациентов с периимплантитом были выделены 3 группы риска с различной микробиотой и исходами лечения [9]. Группа низкого риска характеризовалась повышенным количеством M1-макрофагов, CD4⁺-Т-лимфоцитов и Т-регуляторных клеток, тогда как в группе высокого риска отмечались преобладание анаэробной микрофлоры и худшие показатели снижения глубины кармана. Еще одно исследование с двухэтапной кластеризацией и регрессией Кокса разделило 8513 пациентов на шесть кластеров, один из которых имел существенно меньшую выживаемость имплантатов [18]. К факторам, определявшим неблагоприятный кластер, отнесены пожилой возраст, активное курение, использование коротких имплантатов малого диаметра в области верхней челюсти, а также методика одномоментной имплантации. Выживаемость, рассчитанная по временным номограммам, заметно различалась между кластерами (конкорданс-индексы ~0,64 в ранний период до 4 мес; ~0,78 на срок 4—10 мес). Кроме того, применение ИИ для автоматизированного изготовления хирургических шаблонов показало лучшие клинические результаты по сравнению с традиционными методами: в группе

AI-шаблонов первичная стабильность имплантатов оказалась выше (средний ISQ 78±5 против ~70—75 у контроля), необходимый крутящий момент — больше, а отклонения позиций имплантатов — минимальными. Полноценная остеоинтеграция при этом достигла 96% (против 90% при стандартных шаблонах и ~80% при свободной установке) [15].

Классические модели оказались полезны главным образом для идентификации значимых предикторов осложнений. Логистическая регрессия как метод на границе между статистикой и ML использовалась во многих работах для оценки влияния клинических факторов. Например, многофакторный логистический анализ ~300 имплантатов (шестилетнее наблюдение) показал, что интенсивное курение (>10 сигарет/день) увеличивает риск потери имплантата приблизительно в 18 раз, а прием антикоагулянтов — в ~28 раз; при этом оба фактора несколько снижали долгосрочную выживаемость имплантатов (~4% разницы) [19]. В крупном ретроспективном исследовании на 9080 имплантатах ранние отказы (<6 мес) статистически чаще происходили в заднем отделе нижней челюсти и у более молодых пациентов, тогда как поздние осложнения ассоциировались с верхней челюстью и возрастом старше среднего [20]. Другое многоцентровое исследование подтвердило, что ранние неудачи чаще связаны с техническими факторами: наличием обнаженных витков резьбы, установкой избыточного количества имплантатов одному пациенту, а также с мужским полом, курением и одномоментной тактикой установки [21]. При этом в современных выборках абсолютная выживаемость имплантатов остается высокой (~95% за 5—10 лет) [20, 22], поэтому для построения точных прогностических моделей требуется учитывать сочетание факторов. Тем не менее отдельные работы сообщают о высокой прогностической точности даже традиционных моделей. Так, логистическая модель на основании семи клинических параметров (возраст, соматическая отягощенность, курение, число имплантатов, анатомическое положение, гигиенический индекс и индекс воспаления десны) позволила спрогнозировать риск периимплантационных осложнений с чувствительностью ~94% и специфичностью ~94% [23]. Полученное уравнение регрессии успешно валидировано на независимой выборке (150 пациентов за год наблюдений), показав совпадение расчетов с реальными исходами в 94,2% случаев [23]. Также отмечено, что женщины имели достоверно более низкий риск нарушения остеоинтеграции, чем мужчины (примерно на 85%) [19]. Наконец, помимо бинарных исходов классические методы применялись для прогнозирования количественных показателей: например, многофакторная линейная регрессия предсказала интенсивность послеоперационной боли с точностью

~89,6%, позволив индивидуализировать план аналгетического контроля [24].

В целом диапазон качества моделей был широк: AUC колебался от ~0,70 у относительно простых моделей до ~0,93 у лучших ансамблевых и глубоких алгоритмов [5, 10]; точность классификации составляла ~70—100% в зависимости от сложности задачи [5, 8, 21]. Чувствительность и специфичность большинства моделей лежали в пределах 80—100% либо значительно превышали случайный уровень [17, 23]. Для проверки обобщающей способности почти во всех работах применяли методы валидации — разделение на обучающую/тестовую выборки или кросс-валидацию. Наконец, важным преимуществом ML стало выявление значимых предикторов. Во всех рассмотренных моделях ключевыми факторами исходов неоднократно подтверждены курение, гигиена полости рта, качество/плотность кости, размеры имплантата и сопутствующие заболевания [5, 16, 19]. Многие алгоритмы предоставляют возможность интерпретации: коэффициенты регрессий и рейтинги значимости признаков в ансамблях совпадают с известными клиническими закономерностями, облегчая внедрение ИИ/ML-моделей в клиническую практику.

Таким образом, в большинстве работ (15 из 22) использованы алгоритмы на основе визуальных данных: рентгенограмм, КЛКТ или гистологических изображений. Из них 9 применяли модели глубокого обучения, преимущественно сверточные нейронные сети (CNN), которые продемонстрировали наивысшие показатели точности классификации (до 96 %) и AUC (до 0,93). Четыре исследования фокусировались на прогнозе на основе только клинических данных, еще три — на мультиомных профилях (генетика, микробиом, иммунный статус). Основные результаты приведены в табл. 2.

В ряде работ комбинирование изображений с клиническими параметрами (возраст, плотность кости, гигиена, анамнез и др.) повышало качество прогноза по сравнению с использованием одного типа данных. Наиболее стабильные и высокоточные результаты наблюдались при использовании CNN и ансамблевых методов (Random Forest, стеккинг), в том числе через AutoML. Таким образом, наш обзор подтверждает, что использование ИИ/ML позволяет не только автоматизировать обработку сложных гетерогенных данных, но и достичь высокой точности прогноза клинических исходов в дентальной имплантологии.

Обсуждение

Результаты обзора подтверждают, что применение методов ИИ/ML в дентальной имплантологии открывает новые возможности для повышения точности прогнозирования исходов за счет способности учитывать большее количество клинических, рентгенологических и поведенческих факторов одновременно. Алгоритмы ИИ не выходят за рамки доступных данных, однако в ряде работ они демонстрировали более высокую прогностическую точность по сравнению с традиционным планированием, основанным на ограниченном наборе ключевых предикторов. Наиболее высокие показатели эффективности показали модели глубокого обучения, особенно CNN, работающие с данными КЛКТ и панорамных рентгенограмм [5, 7—13]. Их преимущество связано с возможностью извлекать многочисленные рентгенологические признаки, недоступные при традиционном визуальном анализе. Такие

Таблица 2. Сводная таблица анализируемых публикаций
Table 2. Summary table of analyzed publications

Источник, год	Объем, n	Тип данных	Модель ИИ/ML (алгоритм)	Прогнозируемый исход	Ключевой показатель	Валидация	Основные результаты/выводы
1. Mameno T. et al., 2021	254 имплантата (127 PI vs 127 контроль)	Клинические/демографич. факторы	LR, SVM, случайный лес	Прогноз перимплантита	RF: AUC=0,71; точн.=0,70	Тестовая выборка	Случайный лес показал лучшие результаты; важные признаки: PPD, индекс налета, время после имплантации
2. Moayedi R.S. et al., 2016	Не указано	Клинические показатели	Гибридный стеккинг (J48, SVM, HC, k-NN, Байес)	Прогноз успеха имплантации	Не указано	Не указано	Предложен ансамблевый подход без отчета метрик
3. Mun S.B. et al., 2025	201 пациент (874 зуба)	Панорамные рентгенограммы	CNN (DenseNet121, ResNet, Inception и др.)	Выбор пригодности к немедленной имплантации	>0,90 все метрики	Разбиение выборки (train/val/test)	Высокая точность у всех моделей (чувств., точн., F1 >0,90).
4. Yadalam P.K. et al., 2022	1077 пациентов (825 train, 207 val, 45 контроль)	Клинические и хирургические данные	Множественная линейная регрессия	Прогноз послеоперационной боли	Точн.=89,6%; RMSE=0,1085	Тестовая выборка	Модель эффективно предсказывала интенсивность боли

Продолжение табл. см. на следующей странице.

Таблица 2. Сводная таблица анализируемых публикаций. (Продолжение)
Table 2. Summary table of analyzed publications. (Continue)

Источник, год	Объем, n	Тип данных	Модель ИИ/ML (алгоритм)	Прогнозируемый исход	Ключевой показатель	Валидация	Основные результаты/выводы
5. Zhu Y. et al., 2025	Не указано	СВСТ + электроника медкарта	AMDRN (nnUNet + 3D-At-ResNet + радиомика + лог. регр.)	Риск неудачи синус-лифтинга	Точн. =90%; AUC=0,93	Независимый тест	Модель AMDRN превзошла чисто клиническую и рентгенологическую модели
6. Lee W.F. et al., 2024	800 снимков (600 train, 100 val, 100 test)	Периодические снимки	YOLOv7	Обнаружение перимплантита	Слещиф =100%; точн. =100%; полног. =94,4%; F1 =97,1%	Разбиение выборки	Высокая точность и полнота выявления перимплантита
7. Pais R.J. et al., 2025	40 пациентов (100 метагеном)	Микробиом (слона, налет)	AutoML (TR0T, O2Pngen)	Классификация перимплантит/здоровые	AUC 0,70—0,98; чувств. 95—100%; слещиф. 90—95%	5-fold CV	Малые панели микроб (2—4 вида) обеспечили высокую точность классификации
8. Schincaglia G.P. et al., 2023	398 пациентов (942 имплантата)	Демография, анамнез, план операций	Лог. регрессия, RF, SVM, ансамбль	Прогноз отказа импл./перимплантита	RF: AUC=0,872 (импл.), 0,840 (перимп.)	Тестовая выборка	Важные признаки: объем анестезии (возможно, маркер сложности), размер имплантата, антибиотика, гигиена, диабет
9. Xie C. et al., 2024	8513 пациентов	Кл. переменные (возраст, курение и др.)	Кластеризация + Cox + номограмма	Риск потери имплантата	C-x=0,642; 0,781; 0,715	Внутренняя валидация	Выделены высокорисковые кластеры; факторы: возраст, курение, размер/положение импл., тип процедуры
10. Fan W. et al., 2023	35 образцов (19 PI, 16 контролей)	Ген. экспрессия (GEO)	RF + HC	Ранняя диагностика перимплантита	AUC=1,0	Тестовая выборка	Нейросеть на 13 генах обеспечила 100% классификацию (AUC=1,0)
11. Wählberg R.D. et al., 2025	2007 которты: 799 пациентов (2473 импл.); 2017 которты: 1076 (2287 импл.)	Клинические (материал импл., техника)	Лог. регрессия	Факторы ранних отказов импл.	— (аналитика)	Ретросп. многоцентровое исслед.	Ранние отказы: 1,1% (2007) и 2,4% (2017); риски: оголенные резьбы, перфорация гайморовой пазухи
12. Huang Z. et al., 2022	779 КЛКТ срезов	СВСТ-корр. срезы	Многозадачный CNN (MobileNetV2-DeeplabV3++ + ResNet-50)	Оценка стабильности имплантата (2/3/4 класса)	2-й класс: 96,13%; 3-й класс: 95,33%; 4-й класс: 92,90%	Внутр. и внешн. тесты	Быстрая оценка (~3,8 с) с высокой точностью по всем классам стабильности
13. Xiao Y. et al., 2024	49 пациентов	СВСТ с ИИ-градатором BMD	Система ИИ-градации BMD	Корреляция BMD и стабильности импл. (ISQ)	г≈0,4—0,5	Клинический анализ	Автоматическая градация BMD предсказала стабильность лучше ручной оценки (корреляция г≈0,5)
14. Wang C.W. et al., 2021	24 пробы (RNA-Seq)	RNA-Seq, иммунная левонволяция	FARDEEP + кластерный анализ	Стратификация пациентов по риску перимплантита	—	Кластеризация	Выделены 3 группы риска с различным иммунным и микробным профилем

Продолжение табл. см. на следующей странице.

Таблица 2. Сводная таблица анализируемых публикаций. (Окончание)

Table 2. Summary table of analyzed publications. (End)

Источник, год	Объем, n	Тип данных	Модель ИИ/ML (алгоритм)	Прогнозируемый исход	Ключевой показатель	Валидация	Основные результаты/выводы
15. Cai et al., 2025	190 КЛКТ	3D СВСТ	nnU-Net + 3D-сегментация	Виртуальное планирование положения импл.	Surface Dice int=0,903; ext=0,884; отклонение 0,8–1,4 мм	Внутр. и внешн.	Точная 3D-сегментация челюсти и установки импланта; малые смещения положения
16. Al-Mebrouk et al., 2025	50 пар СВСТ + внутр. скан	СВСТ + интраоральное сканирование	Предобученный ИИ для планирования имплантации	Сравнение планов ИИ vs врача (ниж. челюсть)	ИИ: 89% приемлемых планов (чел.:93%); время 187 vs 406 с	Преκληническое исслед.	ИИ создал планы сравнимого качества быстрее; 58% планов ИИ неотличимы от ручных
17. Staedt H. et al., 2020	9080 имплантатов	Клинические переменные	Лог. регрессия (анализ рисков)	Риски ранних/поздних отказов импл.	— (аналитика)	Ретроспектив. исслед.	Ранний отказ 1,1%; поздний 2,4%. Факторы: локализация имплантата и возраст пациентов
18. J. Park et al., 2024	150 пациентов (RCT)	КЛКТ (предоперационные данные)	CNN (глубокое обучение)	Успех имплантации/остеоинтеграция	Точность ~87%; улучшение клинических исходов	Рандомизированное контролируемое исследование	Использование ИИ для анализа КЛКТ позволило повысить точность прогноза и улучшить клинические результаты за счет адаптации тактики лечения у пациентов группы риска
19. Vitzela-Velasco A. et al., 2021	297 имплантатов (ше-стiletнее наблюдение)	Клинические факторы (имплант, пациент, хирургия)	Лог. регрессия (Cox)	Неулача остеоинтеграции, выживаемость импланта	Остеоинтегр.:97,6%; выживаемость:97,2%	Karlan—Meier, Соx	Курлышки: риск неудачи в 18,3 раза выше; назначение антикоагулянтов: x28; пол влиял на остеоинтеграцию
20. Bergchenko G.N. et al., 2021	30 пациентов (биопсии 6, 9, 12 мес)	Гистологические снимки фибулярного графта	CNN (GoogleNet)	Морфологическая оценка созревания новой кости	ANN: ≥95% правильных классификаций	Кросс-проверка на биопсиях	ИИ-нейросеть проанализировала все изображения пистреза, избежав предвзятости отбора полей зрения
21. Shakovets N.V. et al., 2022	400 пациентов	Клинические факторы риска	Модель на основе меры Кульбака—Лейблера	Прогноз осложненного имплантации	Чувств.=94,36%; специф.=94,17%	Ретроспектив. анализ	Разработана система индивидуального прогноза риска на основе клинических данных
22. Saleev R.A. et al., 2021	414 пациентов (1302 имплантата)	Наблюдение: немедленная vs отсроченная нагрузка	Описательный анализ	Долгосрочный успех имплантации	Выживаемость >96%; различия немедл./отср. нет	Проспективное исслед.	Успех зависит от объема/качества кости, дизайна и поверхности импланта; большие имплантаты более стабильны

Примечание. ИИ — искусственный интеллект; ML — machine learning, машинное обучение; CNN — convolutional neural network, сверточная нейронная сеть; HC — нейронная сеть; SVM — support vector machine, метод опорных векторов; k-NN — k-nearest neighbors, метод k ближайших соседей; RF — random forest, метод случайного леса; LR — logistic regression, логистическая регрессия; AUC — area under the curve, площадь под ROC-кривой; ROC — receiver operating characteristic, операционная характеристика приемника; RPD — probing pocket depth, глубина зондирования пародонтального/перимплантатного кармана; КЛКТ — конусно-лучевая компьютерная томография; СВСТ — cone beam computed tomography, конусно-лучевая компьютерная томография; BMD — bone mineral density, минеральная плотность костной ткани; ISQ — implant stability quotient, коэффициент стабильности имплантата; RMSE — root mean square error, среднеквадратическая ошибка; CV — cross-validation, кросс-валидация; RNA-Seq — RNA sequencing, секвенирование РНК; GEO — Gene expression omnibus, база данных экспрессии генов; ANOVA — analysis of variance, дисперсионный анализ; F1 — F1-мера, гармоническое среднее точности и полноты; TPOT — Tree-based pipeline optimization tool, инструмент автоматизированного машинного обучения; AutoML — automated machine learning, автоматизированное машинное обучение.

алгоритмы демонстрировали чувствительность и точность на уровне >90% и показали сопоставимость с планированием опытных специалистов, при этом значительно сокращая время анализа [12, 20]. Однако высокая зависимость от объема и качества обучающих данных, а также необходимость стандартизации протоколов визуализации остаются серьезными барьерами для широкого внедрения.

Ансамблевые методы (случайные леса, SVM, гибридные подходы) занимают промежуточное положение по точности, но обладают большей устойчивостью к ограниченному объему данных [5, 6, 16–18]. Они позволяют выявлять значимые предикторы и обеспечивают интерпретируемость за счет рейтингов переменных. Ключевыми факторами, неоднократно подтвержденными разными алгоритмами, являются курение, индекс гигиены, плотность кости, размеры имплантата, сахарный диабет и иные системные заболевания [5, 16, 19, 23]. Интерес представляют исследования, где ML интегрировался с микробиологическими и иммунологическими данными [17, 18, 24], что позволило выделять группы риска и формировать новые гипотезы о патогенезе периимплантита. Это направление подтверждает ценность мультиомных подходов в сочетании с алгоритмами автоматического поиска закономерностей.

Классические статистические модели, прежде всего логистическая регрессия, продолжали широко использоваться [19, 20, 22, 23]. Их достоинство — простота и прозрачность, однако возможности для предсказания ограничены. В большинстве случаев логистическая регрессия фиксировала известные факторы риска (курение, пол, анатомическое положение имплантата), но не обеспечивала высокой прогностической силы [19, 20]. Исключения составляют отдельные работы с тщательно отобранным набором клинических переменных, где удавалось достичь точности около 94% [23]. Тем не менее, такие результаты требуют осторожной интерпретации: малый размер выборки и ограниченная валидация могут приводить к завышенным оценкам.

В целом, выявленные ограничения исследований сходны. Во-первых, большинство выборок были относительно небольшими (<1000 пациентов), что повышает риск смещения и снижает обобщаемость результатов [5–7, 14, 21, 25]. Во-вторых, внешняя валидация встречалась крайне редко; чаще применялись внутренние методы (разделение на обучающую и тестовую выборки, кросс-валидация), что ограничивает надежность алгоритмов [17, 18, 23]. В-третьих, в ряде работ отсутствовала прозрачность в описании гиперпараметров, что затрудняет воспроизводимость [9, 10, 13]. Наконец, сравнительные исследования с традиционным планированием проводились редко, а рандомизированные контролируемые испытания единичны [4].

Важно учитывать, что многие предиктивные модели ограничены анализом демографических и рентгенологические факторов, тогда как значимыми переменными могут быть особенности хирургического протокола (непосредственная или отсроченная имплантация, одномоментные процедуры), морфология и поверхность имплантатов, а также анатомическая локализация, которые традиционно ассоцииро-

ваны с исходами лечения [26, 27]. Кроме того, не все включенные параметры одинаково информативны с клинической точки зрения. Так, объем вводимого анестетика в одном из исследований оказался важным предиктором, однако это, скорее всего, отражает сложность вмешательства и не является априорной характеристикой, доступной до начала лечения.

Перспективы развития области связаны с созданием больших мультицентровых баз данных, включающих рентгенологические, клинические, микробиологические и молекулярные показатели, а также с разработкой моделей, сочетающих высокую точность и интерпретируемость. Отдельного внимания заслуживает внедрение explainable AI для клинической практики, что позволит врачам понимать вклад каждого предиктора и повысит доверие к алгоритмам. При этом ИИ/ML-технологии следует прежде всего рассматривать не как замену врачу, а как дополнительный инструмент поддержки принятия решений, расширяющий возможности клинициста и повышающий стандарты лечения.

Заключение

Систематический обзор показал, что применение методов ИИ/ML в дентальной имплантологии имеет высокий потенциал для повышения точности прогнозирования исходов лечения, таких как риск отторжения имплантата, развитие периимплантита, вероятность успешной остеоинтеграции и необходимость дополнительных вмешательств. Наибольшую эффективность продемонстрировали модели глубокого обучения, особенно CNN, при анализе КЛКТ и рентгенологических изображений. Ансамблевые алгоритмы обеспечивали приемлемую точность и позволяли выявлять значимые предикторы, в то время как логистическая регрессия подтверждала известные факторы риска, но имела ограниченные прогностические возможности.

Ключевыми предикторами осложнений оставались курение, состояние гигиены полости рта, плотность и объем костной ткани, размеры имплантатов и сопутствующие заболевания. Однако ограниченность выборок, отсутствие внешней валидации и слабая интерпретируемость ряда моделей снижают их клиническую применимость.

Перспективным направлением является интеграция в ИИ-модели как рентгенологических и клинических факторов, так и характеристик хирургического протокола и состояния микробиоты, что позволит построить более надежные инструменты персонализированного прогнозирования [28]. Дальнейшее развитие возможно через создание многоцентровых баз данных, стандартизацию протоколов визуализации и внедрение объяснимых алгоритмов ИИ. Такие подходы позволят интегрировать разнородные данные и сформировать надежные клинические инструменты для индивидуализированного прогнозирования успеха дентальной имплантации.

**Авторы заявляют об отсутствии конфликта интересов.
The authors declare no conflict of interest.**

ЛИТЕРАТУРА/REFERENCES

1. Raikar S, Talukdar P, Kumari S et al. Factors affecting the survival rate of dental implants: a retrospective study // Journal of International Society of Preventive & Community Dentistry. 2017. Vol. 7(6). P. 351-355. https://doi.org/10.4103/jispcd.JISPCD_380_17
2. Мухамметбердиев Б.Ч., Ксембаев С.С., Агатиева Э.А., Валиева И.И. Рентгенографические и функциональные методы оценки состояния челюсти в зоне предполагаемой дентальной имплантации // Проблемы стоматологии. 2024. Т. 20(3). С. 21-27.

- Mukhammadberdiev BCh, Ksembayev SS, Agatieva EA, Valieva II. Radiographic and functional methods for assessing the jaw in the area of planned dental implantation. *Problemy stomatologii*. 2024. Vol. 20(3). P. 21-27. (In Russ.).
<https://doi.org/10.18481/2077-7566-2024-20-3-21-27>
3. Султанов А.А., Гавров Ю.Ю., Яценко А.К. и др. Структурные особенности мягких тканей, окружающих имплантат, и факторы, влияющие на развитие воспаления в перимплантационном пространстве // *Проблемы стоматологии*. 2019. Т. 15(2). С. 11-16.
 Sultanov AA, Gavrov YuYu, Yatsenko AK et al. Structural features of soft tissues surrounding implants and factors influencing inflammation in the peri-implant space // *Problemy stomatologii*. 2019. Vol. 15(2). P. 11-16. (In Russ.).
<https://doi.org/10.18481/2077-7566-2019-15-2-11-16>
 4. Park J, Rajan RS, Alok S et al. Evaluating the role of AI in predicting the success of dental implants based on preoperative CBCT images: a randomized controlled trial // *Journal of Pharmacy & Bioallied Sciences*. 2024. Vol. 16(Suppl 1). P. 86–S888.
https://doi.org/10.4103/jpbs.jpbs_1117_23
 5. Mamenov T, Onozawa M, Shigematsu T, Ishida T. Predictive modelling for peri-implantitis by using machine learning techniques // *Scientific Reports*. 2021. Vol. 11. P. 11090.
<https://doi.org/10.1038/s41598-021-90642-4>
 6. Moayeri RS, Khalili M., Nazari M. A Hybrid Method to Predict Success of Dental Implants // *Int J Adv Comput Sci Appl*. 2016. Vol. 7(5). P. 1-6.
<https://doi.org/10.14569/IJACSA.2016.070501>
 7. Mun SB, Lim HJ, Kim YJ et al. Deep Learning-Based Prediction of Possibility for Immediate Implant Placement Using Panoramic Radiography // *Sci Rep*. 2025. Vol. 15(1). P. 5202.
<https://doi.org/10.1038/s41598-025-89219-2>
 8. Lee WF, Day MY, Fang CY et al. Establishing a Novel Deep Learning Model for Detecting Peri-Implantitis // *J Dent Sci*. 2024. Vol. 19(2). P. 1165-1173.
<https://doi.org/10.1016/j.jds.2023.11.017>
 9. Huang Z, Zheng H, Huang J et al. The Construction and Evaluation of a Multi-Task Convolutional Neural Network for a Cone-Beam Computed-Tomography-Based Assessment of Implant Stability // *Diagnostics (Basel)*. 2022. Vol. 12(11). P. 2673.
<https://doi.org/10.3390/diagnostics12112673>
 10. Zhu Y, Liu Y, Zhao Y et al. Anatomically Based Multitask Deep Learning Radiomics Nomogram Predicts the Implant Failure Risk in Sinus Floor Elevation // *Clin Oral Implants Res*. Published online 2025 Jul 23.
<https://doi.org/10.1111/clr.70011>
 11. Xiao Y, Lv L, Lin Y et al. Correlation Between Peri-Implant Bone Mineral Density and Primary Implant Stability Based on Artificial Intelligence Classification // *Sci Rep*. 2024. Vol. 14(1). P. 3009.
<https://doi.org/10.1038/s41598-024-52930-7>
 12. Al-Mebtoul K, Fontenele RC, Du X et al. Artificial Intelligence Versus Human Intelligence in Presurgical Implant Planning: A Preclinical Validation // *Clin Oral Implants Res*. 2025. Vol. 36(7). P. 835-845.
<https://doi.org/10.1111/clr.14429>
 13. Zhang X, Cai G, Wen B et al. Intelligent Virtual Dental Implant Placement via 3D Segmentation Strategy // *J Dent Res*. Published online 2025 Jun 23.
<https://doi.org/10.1177/00220345251332511>
 14. Fan W, Tang J, Xu H et al. Early Diagnosis for the Onset of Peri-Implantitis Based on Artificial Neural Network // *Open Life Sci*. 2023. Vol. 18(1). P. 20220691.
<https://doi.org/10.1515/biol-2022-0691>
 15. Берченко Г.Н., Хорошилов Д.В., Федосова Н.В., Тангиева З.А. Применение нейронной сети для морфологической оценки ремоделирования реvascularизированного аутотрансплантата на этапе дентальной имплантации дефектов челюстей // *Пародонтология*. 2021. Т. 26(3). С. 188-196.
 Berchenko GN, Khoroshilov DV, Fedosova NV, Tangiyeva ZA. Application of a neural network for morphological assessment of remodeling of a revascularized autograft at the stage of dental implantation of jaw defects // *Parodontologiya*. 2021. Vol. 26(3). P. 188-196. (In Russ.).
<https://doi.org/10.33925/1683-3759-2021-26-3-188-196>
 16. Schincaglia GP, Raffaelli L, Bossi M et al. Machine Learning and Artificial Intelligence: A Web-Based Implant Failure and Peri-implantitis Prediction Model for Clinicians // *Int J Oral Maxillofac Implants*. 2023. Vol. 38(3). P. 576-582.
<https://doi.org/10.11607/jomi.9852>
 17. Pais RJ, Botelho J., Machado V et al. Exploring AI-Driven Machine Learning Approaches for Optimal Classification of Peri-Implantitis Based on Oral Microbiome Data: A Feasibility Study // *Diagnostics (Basel)*. 2025. Vol. 15(4). P. 425.
<https://doi.org/10.3390/diagnostics15040425>
 18. Xie C, Lyu J, Wei LH et al. A Hybrid Unsupervised Clustering Method for Predicting the Risk of Dental Implant Loss // *J Dent*. 2024. Vol. 149. P. 105260.
<https://doi.org/10.1016/j.jdent.2024.105260>
 19. Brizuela-Velasco A, Álvarez-Arenal Á, Pérez-Pevida E et al. Logistic Regression Analysis of the Factors Involved in the Failure of Osseointegration and Survival of Dental Implants with an Internal Connection and Machined Collar: A 6-Year Retrospective Cohort Study. *Biomed Res Int*. 2021. Vol. 2021. P. 9684511.
<https://doi.org/10.1155/2021/9684511>
 20. Staedt H, Pietschmann N, Böddeker , et al. Potential Risk Factors for Early and Late Dental Implant Failure: A Retrospective Clinical Study on 9 080 Implants // *Int J Implant Dent*. 2020. Vol. 6(1). P. 81.
<https://doi.org/10.1186/s40729-020-00276-w>
 21. Wählberg RD, Stenport VF, Wennerberg A, Hjalmarsson L. A Multicenter Study of Factors Related to Early Implant Failures — Part 1: Implant Materials and Surgical Techniques // *Clin Implant Dent Relat Res*. 2025. Vol. 27(1). P. e70015.
<https://doi.org/10.1111/cid.70015>
 22. Gupta S, Yadav D, Anubhuti A et al. AI-Assisted Surgical Guides for Dental Implant Placement // *Bioinformatics*. 2025. Vol. 21(5). P. 1002-1006.
<https://doi.org/10.6026/97320630021002>
 23. Шаковец Н.В., Бекжанова О.Е., Беленова И.А., Зайтханов А.А. Индивидуальное прогнозирование развития осложнений дентальной имплантации на основе оценки клинических факторов риска // *Мед. новости*. 2022. Т. 7. С. 78-82.
 Shakovets NV, Bekzhanova OE, Belenova IA, Zaitkhanov AA. Individual prediction of the development of complications of dental implantation based on the assessment of clinical risk factors // *Meditsinskie novosti*. 2022. Vol. 7. P. 78-82. (In Russ.).
<https://cyberleninka.ru/article/n/individualnoe-prognozirovanie-razvitiya-oslozheniy-dentalnoy-implantatsii-na-osnovanii-otsenki-klinicheskikh-faktorov-riska>
 24. Wang CW, Hao Y, Di Gianfilippo R. et al. Machine Learning-Assisted Immune Profiling Stratifies Peri-Implantitis Patients with Unique Microbial Colonization and Clinical Outcomes // *Theranostics*. 2021. Vol. 11(14). P. 6703-6716.
<https://doi.org/10.7150/thno.57775>
 25. Yadalam PK, Trivedi SS, Krishnamurthi I. et al. Machine Learning Predicts Patient Tangible Outcomes After Dental Implant Surgery // *IEEE Access*. 2022. Vol. 10. P. 131481-131488.
<https://doi.org/10.1109/ACCESS.2022.3228793>
 26. Ивашов А.С., Деметьюева К.Д., Нерсисян П.М. и др. Преимущества и недостатки цифровой хирургии в стоматологической реабилитации. Обзор литературы с описанием клинического случая // *Проблемы стоматологии*. 2020. Т. 16(4). С. 13-19.
 Ivashov AS, Dementyeva KD, Nersesyan PM et al. Advantages and disadvantages of digital surgery in dental rehabilitation. Literature review with a case report // *Problemy stomatologii*. 2020. Vol. 16(4). P. 13-19. (In Russ.).
<https://doi.org/10.18481/2077-7566-20-16-4-13-19>
 27. Салеев Р.А., Гришин П.О., Салеева Г.Т. и др. Факторы, влияющие на долговременный успех проведения дентальной имплантации // *Проблемы стоматологии*. 2021. Т. 17(1). С. 91-98.
 Saleev RA, Grishin PO, Saleeva GT et al. Factors influencing the long-term success of dental implantation // *Problemy stomatologii*. 2021. Vol. 17(1). P. 91-98. (In Russ.).
<https://doi.org/10.18481/2077-7566-20-17-1-91-98>
 28. Махмудов Т.Г. Оценка состава микробиоты перимплантатной борозды в процессе остеоинтеграции дентальных имплантов // *Проблемы стоматологии*. 2019. Т. 15(3). С. 158-163.
 Makhmudov TG. Assessment of microbiota composition in the peri-implant sulcus during osseointegration of dental implants // *Problemy stomatologii*. 2019. Vol. 15(3). P. 158-163. (In Russ.).
<https://doi.org/10.18481/2077-7566-2019-15-3-158-163>

Поступила 24.12.2025
 Received 24.12.2025
 Принята 17.02.2026
 Accepted 17.02.2026