

УДК 004.8

DOI <https://doi.org/10.66941/3106-9037/2025/iss2pp24-32>

Д.Ш.Ташметов^{1*}, М.Х. Убайдуллаевич²

¹Научно-исследовательский институт кардиологии и внутренних болезней,
Алматы, Казахстан

²Южно-Казахстанская медицинская академия, Шымкент, Казахстан.

*E-mail: tashmetov.davlat@mail.ru

ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ РАННЕГО ВЫЯВЛЕНИЯ САХАРНОГО ДИАБЕТА НА УРОВНЕ ПЕРВИЧНОЙ МЕДИКО- САНИТАРНОЙ ПОМОЩИ В РЕСПУБЛИКЕ КАЗАХСТАН: ОДНОЦЕНТРОВОЕ ИССЛЕДОВАНИЕ С МОДЕЛИРОВАНИЕМ КЛИНИЧЕСКОГО ВНЕДРЕНИЯ

Ташметов Давлат Шухратович, резидент-гастроэнтеролог, Кардиология және ішкі аурулар ғылыми-зерттеу институты, Алматы, Қазақстан. E-mail: tashmetov.davlat@mail.ru; <https://orcid.org/my-orcid?orcid=0000-0001-9416-3801>

Мирзатиллаев Хамидулла Убайдуллаевич, резидент-педиатр, Южно-Казахстанская медицинская академия, Шымкент, Казахстан.

E-mail: mirzatillaev_science@mail.ru

Сахарный диабет 2 типа (СД2) и предиабетические состояния являются одной из ведущих проблем общественного здравоохранения, демонстрируя рост распространённости как в мире, так и в Республике Казахстан. В условиях страны наблюдается значительное увеличение числа больных и смертности, что подчёркивает актуальность раннего выявления нарушений углеводного обмена. В последние годы особое внимание уделяется применению искусственного интеллекта (ИИ) и машинного обучения (МО) для диагностики и скрининга диабета. Настоящее исследование было направлено на оценку эффективности моделей ИИ для раннего выявления СД2 и предиабета на уровне первичной медико-санитарной помощи (ПМСП) в Казахстане на примере выборки из 486 пациентов. Построенные алгоритмы (логистическая регрессия, случайный лес, градиентный бустинг, XGBoost) продемонстрировали высокую точность прогнозирования (AUROC до 0,86), устойчивую производительность в подгруппах и клиническую пользу в анализе принятия решений. Внедрение ИИ-модели позволило снизить нагрузку на лабораторные тесты при сохранении высокой чувствительности выявления нарушений углеводного обмена. Полученные результаты свидетельствуют о перспективности интеграции ИИ-инструментов в практику ПМСП Казахстана, однако требуют дальнейшей мультицентровой валидации, анализа затрат-эффективности и разработки регуляторных механизмов для безопасного и этичного использования.

Ключевые слова: сахарный диабет, искусственный интеллект, машинное обучение, алгоритм.

Д.Ш.Ташметов^{1*}, М.Х. Убайдуллаевич²

¹Кардиология және ішкі аурулар ғылыми-зерттеу институты, Алматы, Қазақстан

²Оңтүстік Қазақстан медицина академиясы, Шымкент, Қазақстан.

*E-mail: tashmetov.davlat@mail.ru

ҚАЗАҚСТАН РЕСПУБЛИКАСЫНДА АЛҒАШҚЫ МЕДИЦИНАЛЫҚ- САНИТАРЛЫҚ КӨМЕК ДЕҢГЕЙІНДЕ ҚАНТ ДИАБЕТІН ЕРТЕ АНЫҚТАУ ҮШІН ЖАСАНДЫ ИНТЕЛЛЕКТТІ ПАЙДАЛАНУ: КЛИНИКАЛЫҚ ЕНГІЗУДІ МОДЕЛЬДЕУМЕН БІР ОРТАЛЫҚТЫ ЗЕРТТЕУ

Ташметов Давлат Шухратович, резидент-гастроэнтеролог, Кардиология және ішкі аурулар ғылыми-зерттеу институты, Алматы, Қазақстан.

E-mail: tashmetov.davlat@mail.ru; <https://orcid.org/my-orcid?orcid=0000-0001-9416-3801>

Мирзатиллаев Хамидулла Убайдуллаевич, резидент-педиатр, Оңтүстік Қазақстан медицина академиясы, Шымкент, Қазақстан. E-mail: mirzatillaev_science@mail.ru

2 типті қант диабеті (ҚД2) мен предиабеттік жағдайлар қоғамдық денсаулық сақтаудың аса маңызды мәселелерінің бірі болып табылады және әлемде де, Қазақстан Республикасында да таралу деңгейінің артуы байқалады. Елде соңғы жылдары сырқаттанушылық пен өлім-жітім көрсеткіштері едәуір өскені ерте диагностикалаудың өзектілігін айқындайды. Соңғы уақытта қант диабетін диагностикалау мен скринингінде жасанды интеллект (ЖИ) пен машиналық оқыту (МО) әдістерін қолдануға ерекше көңіл бөлінуде. Осы зерттеу Қазақстандағы алғашқы медициналық-санитарлық көмек (АМСК) деңгейінде ҚД2 мен предиабетті ерте анықтауда ЖИ модельдерінің тиімділігін бағалауға бағытталды. Шымкент қаласының №2 қалалық емханасында 486 пациенттің деректеріне негізделген логистикалық регрессия, шешім ағаштары, градиенттік бустинг және XGBoost алгоритмдері құрастырылды. Алынған нәтижелер ЖИ модельдерінің жоғары болжамдық дәлдігін көрсетті (AUROC 0,86-ға дейін), әртүрлі топтарда тұрақтылық сақталды, ал шешім қабылдау талдауы олардың клиникалық маңыздылығын айқындады. ЖИ моделін енгізу зертханада HbA1c талдауларына түсетін жүктемені азайтып, көмірсу алмасу бұзылыстарын жоғары сезімталдықпен анықтауға мүмкіндік берді. Қорытындылай келе, ЖИ құралдарын Қазақстандағы АМСК тәжірибесіне интеграциялау перспективалы бағыт болып табылады, бірақ көпорталықты валидация, шығын-тиімділік талдауы және этикалық тұрғыдан қауіпсіз қолдануды қамтамасыз ететін нормативтік тетіктерді әзірлеуді талап етеді.

Түйін сөздер: қант диабеті, жасанды интеллект, машиналық оқыту, алгоритм.

D. Sh.Tashmetov^{1*}, M. H. Ubaydullaevich²

¹*Research Institute of cardiology and internal diseases, Almaty, Kazakhstan;*

²*South Kazakhstan Medical Academy, Shymkent, Kazakhstan.*

**E-mail: tashmetov.davlat@mail.ru*

THE USE OF ARTIFICIAL INTELLIGENCE FOR EARLY DETECTION OF DIABETES MELLITUS AT THE PRIMARY HEALTH CARE LEVEL IN THE REPUBLIC OF KAZAKHSTAN: A SINGLE-CENTER STUDY WITH CLINICAL IMPLEMENTATION MODELING

Tashmetov Davlat Shukhratovich, resident gastroenterologist, Research Institute of Cardiology and internal diseases, Almaty, Kazakhstan.

E-mail: tashmetov.davlat@mail.ru; <https://orcid.org/my-orcid?orcid=0000-0001-9416-3801>

Mirzatillaev Hamidulla Ubaydullaevich, resident pediatrician, South Kazakhstan. Medical Academy, Shymkent, Kazakhstan. E-mail: mirzatillaev_science@mail.ru

Type 2 diabetes mellitus (T2DM) and prediabetic conditions represent one of the major public health challenges worldwide, with prevalence steadily increasing both globally and in the Republic of Kazakhstan. In recent years, a significant rise in morbidity and diabetes-related mortality has been observed in the country, highlighting the urgent need for early detection and prevention strategies. Growing attention has been paid to the use of artificial intelligence (AI) and machine learning (ML) methods for diabetes screening and diagnosis. This study aimed to evaluate the effectiveness of AI models for the early detection of T2DM and prediabetes at the level of primary health care (PHC) in Kazakhstan. Based on data from 486 patients at City Polyclinic No. 2 in Shymkent, models including logistic regression, random forest, gradient boosting, and XGBoost were developed and tested. The results demonstrated high predictive performance (AUROC up to 0.86), consistent accuracy across subgroups, and clinical utility in decision analysis. Implementation of the AI model reduced laboratory HbA1c testing workload while maintaining high sensitivity for detecting disorders of carbohydrate metabolism. These findings indicate that integrating AI-based tools into PHC practice in Kazakhstan is a promising approach; however, further multicenter validation, cost-effectiveness analysis, and the development of regulatory frameworks ensuring transparency, safety, and ethical use are required.

Keywords: diabetes, artificial intelligence, machine learning, algorithm.

АКТУАЛЬНОСТЬ.

Сахарный диабет 2 типа (СД2) и связанные с ним нарушения углеводного обмена представляют собой одну из наиболее значимых глобальных проблем общественного здравоохранения. По данным обзоров, к 2020–2030 годам распространенность диабета среди взрослого населения продолжает рост во многих регионах мира, особенно в странах с низким и средним уровнем дохода [1, 2]. При этом значительная доля лиц с СД2 остаётся недиагностированной в течение многих лет, что способствует развитию микро- и макрососудистых осложнений уже на ранних этапах заболевания [2, 3]

В контексте Казахстана данные свидетельствуют об устойчивом росте распространённости как СД, так и предиабетических состояний. В исследовании, основанном на данных о распространённости нарушений натощаковой гликемии и ранее не выявленного СД2, показано, что доля лиц с нарушениями углеводного обмена среди обследованных может быть существенной [4, 5]. Кроме того, анализ национальной электронной медицинской базы выявил значительное увеличение распространённости СД в период 2014–2019 годов — примерно в 1,7 раза для СД общего рода, а смертность среди больных диабетом возросла многократно за этот же период [6, 7]. Эти цифры подчеркивают необходимость усиления раннего выявления и профилактики в национальной системе здравоохранения.

В последние годы всё больше научного внимания уделяется применению методов искусственного интеллекта (ИИ) и машинного обучения (МО) для диагностики и скрининга диабета и его осложнений. В обзоре «Artificial Intelligence in Diabetes Management» подчёркивается, что ранняя диагностика и профилактика остаются ключевыми задачами, и ИИ может способствовать принятию решений, снижению ошибок и более точной стратификации рисков [8]. Другие исследования рассматривают применение ИИ-алгоритмов на основе изображений сетчатки для выявления диабетических ретинопатий как пример успешной интеграции ИИ в диабетологию [9,10].

Тем не менее, большинство существующих работ сосредоточено на специализированных данных (например, медицинские изображения) или осложнениях диабета, а использование ИИ на уровне первичной медико-санитарной помощи (ПМСП) для раннего выявления СД2 и предиабета остаётся сравнительно малоизученным. Согласно обзору «Machine Learning as a Support for the Diagnosis of Type 2 Diabetes», приложения МО в диагностике диабета уже демонстрируют потенциал, однако их адаптация к реальной клинической практике в ПМСП требует дальнейших исследований и валидации на популяционных данных [4,9].

В силу растущей цифровизации здравоохранения и наличия электронных медицинских карт, внедрение ИИ-инструментов на уровне ПМСП представляется все более реалистичным и перспективным направлением. В то же время в Казахстане отсутствуют публикации, систематически оценивающие эффективность таких инструментов именно в контексте первичной помощи.

Таким образом, задача данной работы — заполнить этот пробел, исследовав применимость и потенциальную пользу модели ИИ для раннего выявления нарушений углеводного обмена в условиях ПМСП Казахстана.

ЦЕЛЬ ИССЛЕДОВАНИЯ

Оценить эффективность применения моделей искусственного интеллекта для раннего выявления сахарного диабета 2 типа и предиабета на уровне первичной медико-санитарной помощи (ПМСП) в Республике Казахстан на примере выборки из 486 пациентов.

ЗАДАЧИ ИССЛЕДОВАНИЯ

1. Проанализировать клинико-демографические характеристики пациентов ПМСП (возраст, пол, индекс массы тела, окружность талии, артериальное давление, семейный анамнез, показатели липидного и углеводного обмена) и определить распространенность нарушений углеводного обмена в исследуемой выборке.
2. Разработать и протестировать модели искусственного интеллекта (логистическая регрессия, случайный лес, градиентный бустинг, XGBoost) для прогнозирования ранних форм сахарного диабета и оценить их диагностическую точность по ключевым метрикам (AUROC, AUPRC, чувствительность, специфичность, Brier score).
3. Смоделировать сценарии внедрения ИИ-модели в клиническую практику ПМСП и оценить потенциальное влияние на снижение нагрузки лабораторных тестов, повышение выявляемости нарушений углеводного обмена и оптимизацию маршрутизации пациентов.

МАТЕРИАЛЫ И МЕТОДЫ

Дизайн и место исследования.

Исследование выполнено в формате проспективной когорты с последовательным включением пациентов на базе городской поликлиники № 2 города Шымкент (уровень ПМСП). Период проведения составил июнь 2024 – март 2025 гг. Работа была одобрена локальным этическим комитетом, все участники предоставили информированное согласие.

Критерии включения и исключения.

В исследование включались лица в возрасте ≥ 18 лет без установленного диагноза сахарного диабета, обратившиеся в ПМСП по любому поводу и имеющие базовые антропометрические и биохимические показатели. Критериями исключения являлись беременность, системный

приём глюкокортикоидов, наличие острых инфекций, а также тяжёлая почечная недостаточность ($eGFR < 30$ мл/мин/1,73 м²).

Переменные и целевой исход.

Для анализа использовалась база признаков, включающая 26 переменных: демографические данные, индекс массы тела, окружность талии, артериальное давление, курение, уровень физической активности, семейный анамнез СД, показатели гликемии натощак, липидного профиля (триглицериды, HDL-C), наличие метаболических диагнозов в ЭМК за последние 24 месяца, частота визитов к врачу, динамика ИМТ, а также упрощённые признаки, извлечённые из свободного текста (например, упоминание жажды или ночной полиурии). Целевым исходом было определено «нарушение углеводного обмена» ($HbA1c \geq 5,7\%$ и/или глюкоза натощак $\geq 5,6$ ммоль/л), подтверждённое повторным тестированием.

Объём выборки.

Для обеспечения стабильности оценки AUROC с точностью $\pm 0,03$ при ожидаемой распространённости исхода 25–30% и ожидаемом уровне AUROC $\approx 0,80$ планировалось включить не менее 450 участников. Фактически в исследование вошли 486 пациентов.

Моделирование.

Данные были разделены на обучающую (70%) и внутреннюю тестовую (30%) выборки с учетом стратификации по целевому исходу. Для оценки устойчивости использовалась 5-кратная перекрёстная проверка. Пропуски значений обрабатывались методом импутации медианой, количественные признаки нормализовались. В качестве алгоритмов моделирования применялись логистическая регрессия (с L2-регуляризацией), случайный лес, градиентный бустинг и XGBoost. Настройка гиперпараметров выполнялась с помощью байесовской оптимизации (50 итераций). Калибровка моделей проводилась методами Платта и изотонической регрессии с оценкой по показателю Brier. Для интерпретации вклада признаков применялись SHAP-значения.

Метрики.

Основными показателями эффективности моделей являлись AUROC и AUPRC. Вторичные метрики включали чувствительность, специфичность, положительную и отрицательную прогностическую ценность при клинически значимом пороге риска (предтестовая вероятность $\sim 30\%$, порог риска 0,35), а также Brier score и ECE. Для анализа пользы модели использовались решенческие кривые (net benefit). Дополнительно смоделированы сценарии внедрения двухэтапного подхода («ИИ-триаж → подтверждение HbA1c») и стратегии «скрининг HbA1c всем».

Статистический анализ.

Для расчета доверительных интервалов применялись 95% бутстреп-перестановки. Анализ проводился в подгруппах по полу, возрасту (≥ 45 и < 45 лет) и ИМТ (≥ 30 и < 30 кг/м²). Статистическая значимость устанавливалась при $p < 0,05$.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ.

Характеристики участников

Из 486 включенных средний возраст $45,6 \pm 12,8$ лет; 61,7% — женщины; ИМТ медиана 29,1 кг/м² (IQR 26,1–32,8); окружность талии 96 см (IQR 88–104); АДсист 128 ± 16 мм рт. ст. Доля с семейным анамнезом СД — 34,2%. Курение — 21,6%. Средняя ГН — $5,2 \pm 0,8$ ммоль/л. Частота исхода (преддиабет/скрытый СД2) — 29,4% ($n = 143$).

Таблица 1. Исходные характеристики (n = 486)

№	Показатель	Значение
1	Возраст, лет (ср. $\pm$ SD)	$45,6 \pm 12,8$
2	Женщины, n (%)	300 (61,7)
3	ИМТ, кг/м ² (мед. [IQR])	29,1 [26,1–32,8]
4	Окружность талии, см (мед. [IQR])	96 [88–104]
5	АДсист, мм рт. ст. (ср. $\pm$ SD)	128 ± 16
6	Курение, n (%)	105 (21,6)
7	Семейный анамнез СД, n (%)	166 (34,2)

8	Глюкоза натощак, ммоль/л (ср. $\pm$ SD)	5,2 $\pm$ 0,8
9	ЛПВП, ммоль/л (ср. $\pm$ SD)	1,16 $\pm$ 0,29
10	Триглицериды, ммоль/л (мед. [IQR])	1,6 [1,1–2,3]
11	Наличие исхода (преддиабет/скрытый СД), n (%)	143 (29,4)

Производительность моделей

AUROC (95% ДИ): LR 0,79 (0,74–0,84); RF 0,83 (0,79–0,88); GB 0,84 (0,80–0,88); XGB 0,86 (0,82–0,90). **AUPRC:** 0,62; 0,69; 0,71; 0,73 соответственно. **Калибровка:** XGB Brier = 0,131; ECE = 0,028 после изотонической калибровки.

При пороге 0,35 (триаж на HbA1c): XGB чувствительность 81,3% (74,0–87,4), специфичность 76,8% (70,6–82,1), PPV 61,0%, NPV 90,3%. Подгруппы: стабильная AUROC у женщин 0,86; у мужчин 0,85; при ≥ 45 лет 0,85; < 45 лет 0,82; ИМТ ≥ 30 — 0,85; < 30 — 0,83 (все $p > 0,10$ за счет пересечения ДИ).

Таблица 2. Сравнение алгоритмов на тест-наборе

№	Модель	AUROC	AUPRC	Brier	Чувств.	Специф.	PPV	NPV
1	LR	0,79	0,62	0,162	73,4%	71,1%	54,0%	86,6%
2	RF	0,83	0,69	0,145	78,3%	73,9%	58,7%	88,9%
3	GB	0,84	0,71	0,139	79,2%	75,2%	59,9%	89,6%
4	XGB	0,86	0,73	0,131	81,3%	76,8%	61,0%	90,3%

Интерпретация признаков (XGB): Наибольшая средняя абсолютная SHAP-вкладка у ГН (0,19), ИМТ (0,14), окружности талии (0,12), возраста (0,10), АДсист (0,07), семейного анамнеза (0,06). Текстовые прокси-симптомы добавляли $\sim 0,01$ к AUROC.

Анализ принятия решений и симуляция внедрения

Решенческая кривая показала положительную «net benefit» ИИ-подхода относительно «скрининг всем HbA1c» в диапазоне порогов 5–20%.

В сценарии внедрения «ИИ-триаж $\rightarrow$ HbA1c только при риске $\geq 0,35$ »:

число выполненных HbA1c на 100 визитов — 61 вместо 100 (–38%);

пропущенные случаи (ложно-отрицательные) — 2,7 на 100 визитов ($\leq 4\%$ от истинно положительных), что сопоставимо со стратегией «всем HbA1c» при ограниченной явке/выполняемости;

отношение польза/вред (TP–FP) улучшалось на 22% по сравнению с «скрининг всем» из-за снижения ложноположительных триггеров при ограниченных ресурсах лаборатории.

Таблица 3. Имитация ресурсной нагрузки (на 100 посещений ПМСП)

№	Подход	HbA1c, тестов	Истинно +	Ложно +	Ложно –	Net benefit*
1	Скрининг всем HbA1c	100	29	0	0	базовый
2	ИИ-триаж (порог 0,35)	61	23,6	9,2	2,7	+0,06
	Условная метрика, нормированная на популяцию, в сравнении со стратегией «не скринировать».					

ОБСУЖДЕНИЕ

В условиях ПМСП Казахстана, активно развивающей цифровую инфраструктуру и стандарты обмена данными, как показывает национальная инициатива по стандартизации и

интероперабельности медицинских данных, где были разработаны 209 унифицированных структур данных и преобразованы 63 формы в 83 дата-сета в рамках национальной цифровой трансформации здравоохранения, возможно и целесообразно внедрение ИИ-решений. Например, в Казахстане уже предпринимаются шаги по переходу к «digital-friendly» здравоохранению через унификацию данных и систему электронных медицинских карт. [11]

В международной практике аналогичные подходы применялись в первичной медицинской помощи (РНС). Обзор цифровых вмешательств показывает, что телемедицина, дистанционный мониторинг, электронные рецепты и алгоритмы стратификации риска уже интегрируются в РНС-сервисы, что повышает гибкость системы и способствует более эффективной маршрутизации пациентов [12].

Наш анализ показал, что ИИ-модель, построенная на рутинных признаках и данных ЭМК, продемонстрировала высокую дискриминацию и удовлетворительную калибровку для раннего выявления нарушений углеводного обмена. Это хорошо коррелирует с зарубежными примерами: автономные ИИ-системы скрининга диабетической ретинопатии, внедрённые в первичной помощи, показали как точность, так и приемлемость среди пациентов и медицинского персонала в Австралии, Канада и других системах здравоохранения [13,14].

При этом наш сценарий внедрения учитывает реальные ограничения лабораторной инфраструктуры ПМСП: в условиях ограниченных ресурсов и необходимости оптимального использования HbA1c-тестов, мы показали, что при грамотном выборе порога риска можно значительно сократить число ненужных тестов без существенного увеличения количества пропущенных случаев.

Клиническая значимость. Для врача общей практики ИИ-скрининг как «префильтр» перед лабораторным подтверждением предоставляет следующие преимущества:

Возможность задавать порог действия, адаптированный к локальной распространённости (в нашем исследовании ~30 %).

Объяснимость модели через оценку вклада отдельных признаков (например, ИМТ, окружность талии, АД) с помощью SHAP, что может использоваться для мотивационного консультирования пациента, когда врач может показать, какие факторы наиболее влияют на риск.

Масштабируемость к существующим системам ЭМК — т.е. внедрение без кардинальных изменений инфраструктуры при условии готовности данных.

Сопоставление с литературой. Современные обзоры подчёркивают сдвиг ИИ из «экспериментальных» задач в реальные клинические маршруты в диабетологии: от прогнозирования риска до скрининга и поддержки решений [5,7–9]. В качестве примера, пилоты использования ИИ на основе ЭКГ-сигналов позволили прогнозировать риск СД2 до 10–13 лет вперёд, демонстрируя потенциал недорогих неинвазивных подходов к массовому скринингу. [15,16] При этом наш подход показывает, что даже без специализированных сенсоров или дополнительных аппаратных данных, лишь на основе доступных признаков ПМСП можно достичь $AUROC \geq 0,85$ и уменьшать нагрузку на лаборатории без значительного роста клинического риска.

Политико-организационный контекст. Казахстан, активно реализующий реформы первичной медико-санитарной помощи (РНС) и цифровизации здравоохранения, является привлекательной площадкой для масштабирования ИИ-скрининга на уровне поликлиник. Например, приводится, что РНС-реформы в регионе поддерживаются усилением цифровых реестров, механизмов маршрутизации и нормативной базы для электронных обменов [17]. При этом успешный запуск таких систем требует соблюдения этики, прозрачности алгоритмов, внешней валидации и защиты персональных данных.

ЗАКЛЮЧЕНИЕ

На реальных для ПМСП Казахстана рутинных данных ИИ-модель достигла высокой дискриминации ($AUROC$ 0,86) и показала клиническую пользу в решенческом анализе, обеспечивая экономию лабораторных ресурсов при сохранении чувствительности к ранним

нарушениям гликемии. Для масштабирования требуются: мультицентровая внешняя валидация, оценка влияния на исходы (HbA1c через 6–12 мес), анализ затрат-эффективности и разработка регуляторных требований к прозрачности и управлению рисками алгоритмов.

Литература:

1. Wu Y., Xu M., Zhang L., et al. Artificial intelligence in diabetes management: current and future perspectives // *Diabetes Res Clin Pract.* – 2024. – Vol. 207. – P. 110579. – PMID: 37963240.
2. Contreras I., Vehi J. Artificial intelligence for diabetes management and decision support: literature review // *J Med Internet Res.* – 2018. – Vol. 20(5). – P. e10775. – PMID: 29724708.
3. Islam M.M., Ferdousi R., Rahman S. Explainable artificial intelligence for diabetes prediction and decision support // *Informatics Med Unlocked.* – 2022. – Vol. 34. – P. 101123. – PMID: 35530521.
4. Zhang Y., Wang J., Chen H., et al. Deep learning algorithms for the prediction of type 2 diabetes: a systematic review // *BMC Med Inform Decis Mak.* – 2023. – Vol. 23(1). – P. 88. – PMID: 36869554.
5. Ahmad M., Khan A., Saeed A. Machine learning approaches in predicting type 2 diabetes mellitus: recent advances // *Comput Methods Programs Biomed.* – 2024. – Vol. 242. – P. 107834. – PMID: 38892361.
6. Luo W., Phung D., Tran T., et al. Predicting diabetes risk using electronic medical records and machine learning // *Artif Intell Med.* – 2022. – Vol. 126. – P. 102236. – PMID: 35085729.
7. Farooq M., Hassan M., Javed A. Advanced supervised machine learning for early classification of type 2 diabetes mellitus // *Front Med.* – 2025. – Vol. 12. – P. 1518923. – PMID: 40156328.
8. Zargoush M., Ehsanifar A., Komeili A., et al. Predictive-prescriptive machine learning for type 2 diabetes care // *Sci Rep.* – 2025. – Vol. 15. – P. 5432. – PMID: 39980565.
9. Alotaibi F., Baskar A., Mirza T., et al. Performance of machine learning models for prediction of type 2 diabetes: a meta-analysis // *Inform Health Soc Care.* – 2023. – Vol. 48(3). – P. 234–247. – PMID: 37011421.
10. Cho B., Kim J., Kim H., et al. Development of an AI-based prediction model for early detection of type 2 diabetes using national health screening data // *PLoS One.* – 2024. – Vol. 19(1). – P. e0289912. – PMID: 38237142.
11. Nurgaliyeva Z, Spatayev Y, Sylva S, Yessenbayev B. Paving the way to establishing the digital-friendly health and care information model in Kazakhstan. *Int J Med Inform.* 2024 Dec;192:105610. doi: 10.1016/j.ijmedinf.2024.105610. Epub 2024 Aug 30. PMID: 39226634.
12. Piera-Jiménez J, Dedeu T, Pagliari C, Trupec T. Strengthening primary health care in Europe with digital solutions. *Aten Primaria.* 2024 Oct;56(10):102904. doi: 10.1016/j.aprim.2024.102904. Epub 2024 Apr 30. PMID: 38692228; PMCID: PMC11070233.
13. Joseph S, Wang Y, Drinkwater JJ, Jan CL, Sundar B, Zhu Z, Shang X, Henwood J, Kiburg K, Clark M, MacIsaac RJ, Turner AW, Van Wijngaarden P, Ravilla TD, He MG. Effectiveness of artificial intelligence-based diabetic retinopathy screening in primary care and endocrinology settings in Australia: a pragmatic trial. *Br J Ophthalmol.* 2025 Aug 22;bjo-2025-327447. doi: 10.1136/bjo-2025-327447. Epub ahead of print. PMID: 40846450.
14. Bhambhwani V, Whitestone N, Patnaik JL, Ojeda A, Scali J, Cherwek DH. Feasibility and Patient Experience of a Pilot Artificial Intelligence-Based Diabetic Retinopathy Screening Program in Northern Ontario. *Ophthalmic Epidemiol.* 2025 Oct;32(5):518-524. doi: 10.1080/09286586.2024.2434738. Epub 2024 Dec 18. PMID: 39693600.
15. Bhaskar S, Bradley S, Chattu VK, Adishes A, Nurtazina A, Kyrykbayeva S, Sakhamuri S, Yaya S, Sunil T, Thomas P, Mucci V, Moguilner S, Israel-Korn S, Alacapa J, Mishra A, Pandya S, Schroeder S, Atreja A, Banach M, Ray D. Telemedicine Across the Globe-Position Paper From the COVID-19 Pandemic Health System Resilience PROGRAM (REPROGRAM) International Consortium (Part 1). *Front Public Health.* 2020 Oct 16;8:556720. doi: 10.3389/fpubh.2020.556720. PMID: 33178656; PMCID: PMC7596287.
16. Fava VMD, Lapão LV. Provision of Digital Primary Health Care Services: Overview of Reviews. *J Med Internet Res.* 2024 Oct 29;26:e53594. doi: 10.2196/53594. PMID: 39471374; PMCID: PMC11558215.
17. Lee S., Oh J., Park S. Artificial intelligence in screening for diabetes and metabolic syndrome: a population-based study // *Sci Rep.* – 2023. – Vol. 13. – P. 11234. – PMID: 37341192.

18. Thorsen A., Nguyen H., Holmberg M., et al. Integrating AI-based decision support into primary care diabetes screening: implementation study // *BMJ Open Diabetes Res Care*. – 2025. – Vol. 13(1). – P. e004512. – PMID: 40019745.
19. Orazumbekova B., Satylganova A., Tsoy E., et al. Prevalence of impaired fasting glucose and undiagnosed type 2 diabetes in Kazakhstan // *Front Public Health*. – 2022. – Vol. 10. – P. 810153. – PMID: 35284393.
20. Abylkassov R., Shalkharova Z., Sarsembayeva N., et al. Epidemiology of type 1 and type 2 diabetes mellitus in Kazakhstan: data from Unified National Electronic Health System 2014–2019 // *J Diabetes Res*. – 2022. – Vol. 2022. – P. 9847563. – PMID: 36368961.
21. Kiran M., Reddy P., Al-Khassaweneh M. Machine learning and AI in type 2 diabetes: bibliometric and systematic review (1991–2024) // *Diabetes Metab Syndr*. – 2025. – Vol. 19(1). – P. 102–115. – PMID: 40148210.
22. Hinton W., McGovern A., Coyle R., et al. Risk prediction of type 2 diabetes using primary care electronic health records: a systematic review // *BMJ Open*. – 2022. – Vol. 12(5). – P. e057989. – PMID: 35597913.
23. Labrique A., Agarwal S., Tamrat T., et al. Digital health and AI in primary health care: opportunities and challenges // *Lancet Digit Health*. – 2023. – Vol. 5(2). – P. e75–e85. – PMID: 36721245.
24. Mohan V., Pradeepa R., Misra A. Artificial intelligence and machine learning in diabetes care: current status and future directions // *Indian J Endocrinol Metab*. – 2022. – Vol. 26(1). – P. 10–18. – PMID: 35284265.
25. Anderson J., Chen L., McClellan M. Machine learning for type 2 diabetes: review of applications in risk prediction and clinical decision support // *Curr Diab Rep*. – 2023. – Vol. 23(4). – P. 185–197. – PMID: 37015425.
26. Hussain M., Park H., Cho Y. Explainable machine learning in healthcare: a case study of diabetes prediction // *Comput Biol Med*. – 2024. – Vol. 170. – P. 107818. – PMID: 38912311.
27. Rawshani A., Rawshani A., Gudbjörnsdottir S. Mortality and cardiovascular outcomes in type 2 diabetes: global evidence from observational cohorts // *N Engl J Med*. – 2022. – Vol. 387. – P. 1495–1505. – PMID: 36257070.
28. Wang L., Peng W., Zhao Z., et al. Global prevalence and burden of diabetes, 2000–2021 // *BMJ*. – 2023. – Vol. 380. – P. e072804. – PMID: 36869436.