

ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ В ПЕРСОНАЛИЗИРОВАННОМ ПИТАНИИ НА ОСНОВЕ АНАЛИЗА СОСТАВА ПРОДУКТОВ

Э. Г. Тунян^{1,2,3,a}, Р. С. Сазиков^{1,2,3,b}, С. А. Харламов^{1,2,c}

¹ Сургутский государственный университет, г. Сургут, Российская Федерация

² ООО «ЕДРО», г. Сургут, Российская Федерация

³ Сургутский филиал федерального государственного автономного учреждения «Федеральный научный центр Научно-исследовательский институт системных исследований Национального исследовательского центра «Курчатовский институт», г. Сургут, Российская Федерация

^a ORCID: <https://orcid.org/0009-0003-3260-1310>, ✉ tunyan@edro.su

^b ORCID: <https://orcid.org/0009-0005-0078-0013>, sazikov@edro.su

^c ORCID: <https://orcid.org/0009-0000-5605-0531>, harlamov_sa@surgu.ru

Аннотация: системы поддержки принятия решений в области индивидуализированного питания развиваются на стыке ИИ и нутрициологии, опираясь на разнообразные данные: от химического состава продуктов и биомаркеров до изображений блюд и пользовательских предпочтений. В фокусе — создание рекомендаций, адаптированных к особенностям организма и реальному пищевому поведению, включая скрытое переедание вредных компонентов.

Современные архитектуры таких систем задействуют языковые модели, методы машинного обучения, компьютерное зрение и обработку естественного языка. Используются как классические пищевые базы, так и данные с носимых сенсоров, микробиота и визуальные сигналы. Заметна тенденция к объединению различных типов данных — от биомедицинских до визуальных — в рамках одной аналитической структуры, пусть и не всегда с заранее определенной архитектурой.

Публикации последних лет (2018–2025) свидетельствуют: при использовании персонализированных данных продвинутые алгоритмы демонстрируют более высокую точность оценок и зачастую оказываются результативнее в генерации диетических рекомендаций. Клинические наблюдения, проведенные в ряде проектов, фиксируют значимые улучшения: снижение выраженности симптомов СРК почти на 40 % и достижение ремиссии диабета 2 типа примерно у 73 % испытуемых.

В работе рассмотрены как практические решения — чат-боты с языковыми моделями и системы оценки нутриентного состава по фото, так и концептуальные сдвиги в понимании роли ИИ в питании. Основной вектор — переход от шаблонных рекомендаций к тонко настроенным вмешательствам, способным учитывать не только биометрию, но и повседневные контексты выбора пищи.

Ключевые слова: индивидуализированное питание, интеллектуальные системы поддержки принятия решений, персонализированная диета, искусственный интеллект, машинное обучение, большие данные в питании, анализ состава пищевых продуктов, пищевые добавки, переедание, рекомендательные системы, носимые устройства, нутригеномика, пищевые базы данных, профилактика хронических заболеваний, визуально-языковые модели, цифровое здоровье, пищевое поведение, метаболический профиль, сенсоры и трекинг питания, этика и приватность в ИИ.

Благодарности: работа выполнена в рамках государственного задания НИЦ «Курчатовский институт» — НИИСИ по теме № FNEF-2024-0001 «Создание и реализация доверенных систем искусственного интеллекта, основанных на новых математических и алгоритмических методах, моделях быстрых вычислений, реализуемых на отечественных вычислительных системах» (1023032100070-3-1.2.1).

Для цитирования: Тунян Э. Г., Сазиков Р. С., Харламов С. А. Интеллектуальные системы поддержки принятия решений в персонализированном питании на основе анализа состава продуктов. *Успехи кибернетики*. 2025;6(3):105–111.

Поступила в редакцию: 25.07.2025.

В окончательном варианте: 08.09.2025.

INTELLIGENT DECISION SUPPORT SYSTEMS FOR PERSONALIZED NUTRITION BASED ON THE ANALYSIS OF FOOD COMPOSITION

E. G. Tunyan^{1,2,3,a}, R. S. Sazikov^{1,2,3,b}, S. A. Kharlamov^{1,2,c}

¹ Surgut State University, Surgut, Russian Federation

² EDRO, OOO, Surgut, Russian Federation

³ Surgut Branch of Scientific Research Institute for System Analysis of the National Research Centre “Kurchatov Institute”, Surgut, Russian Federation

^a ORCID: <https://orcid.org/0009-0003-3260-1310>, ✉ tunyan@edro.su

^b ORCID: <https://orcid.org/0009-0005-0078-0013>, sazikov@edro.su

^c ORCID: <https://orcid.org/0009-0000-5605-0531>, harlamov_sa@surgu.ru

Abstract: personalized nutrition does not align well with traditional disciplinary boundaries, and attempts to define it narrowly have often failed. We analyzed how artificial intelligence and nutrition intersect and found that most current approaches operate as context-specific solutions rather than coherent systems. Existing platforms draw on diverse data sources such as food composition metrics, biometric updates, meal images, and user preferences, but their effective integration remains uncertain.

We observed a shift from fixed system architectures to modular and flexible configurations. Language models, probabilistic classifiers, and computer vision algorithms are increasingly combined to enhance responsiveness, though often at the expense of structural consistency.

The body of evidence for AI-driven personalized nutrition is expanding but remains inconsistent. Reported outcomes include reductions of up to 40% in irritable bowel syndrome symptoms and partial diabetes remission in more than 70% of participants. However, these results vary considerably across studies and are often influenced by external factors unrelated to nutrition.

Despite these limitations, the field continues to advance. Personalized nutrition is emerging not only as a technical application but also as a redefinition of dietary advice in a digital, data-driven environment.

Keywords: personalized nutrition, intelligent decision support systems, personalized diet, artificial intelligence, machine learning, big data in nutrition, food composition analysis, food additives, overeating, recommender systems, wearable devices, nutrigenomics, food databases, chronic disease prevention, visual-language models, digital health, eating behavior, metabolic profile, nutrition sensing and tracking, ethics and privacy in AI.

Acknowledgements: this study is a part of the FNEF-2024-0001 government order contracted to the Scientific Research Institute for System Analysis of the National Research Centre “Kurchatov Institute”, project No. 1023032100070-3-1.2.1 Development and Implementation of Trusted Artificial Intelligence Systems Based on new Mathematical Methods and Algorithms, Fast Computing Models for Domestic Computing Systems.

Cite this article: Tunyan E. G., Sazikov R. S., Kharlamov S. A. Intelligent Decision Support Systems for Personalized Nutrition Based on the Analysis of Food Composition. *Russian Journal of Cybernetics*. 2025;6(3):105–111.

Original article submitted: 25.07.2025.

Revision submitted: 08.09.2025.

Введение

Питание остается одним из ключевых факторов, определяющих состояние здоровья, однако в повседневной практике нередко недооцениваются риски, связанные с систематическим избытком соли, сахара и насыщенных жиров. Даже при наличии официальных рекомендаций большая часть этих веществ поступает в организм незаметно, через промышленно обработанные продукты. Самоконтроль в таких условиях оказывается затруднительным: добавленные сахара и трансжиры часто не распознаются потребителем [1].

Это делает особенно актуальным поиск инструментов, позволяющих не просто фиксировать пищевые привычки, но и соотносить их с индивидуальными показателями метаболического состояния. Персонализированное питание предлагает такой подход, опираясь не на усредненные нормы, а на адаптацию рекомендаций под генетику, микробиоту, биомаркеры и образ жизни. Тем не менее традиционные диетологические практики по-прежнему ориентированы на «среднего» пациента и не учитывают физиологическую разнородность.

Кроме физиологии, важным остается и поведенческий фактор: люди склонны занижать объемы потребляемого. Это усиливает интерес к цифровым решениям, способным интерпретировать рацион с опорой на объективные данные. Интеллектуальные системы могут восполнять ограниченные аналитические возможности человека: выявлять риски, распознавать связи между рационом и состоянием здоровья, адаптировать рекомендации под текущую картину.

Развитие технологий искусственного интеллекта (ИИ) значительно расширило возможности обработки пищевых данных. Современные системы обучаются на многомодальных источниках — от

таблиц состава продуктов до показаний сенсоров и лабораторных анализов. Благодаря этому удается выявлять устойчивые, но слабо различимые закономерности. Так, система может зафиксировать хроническое превышение уровня потребления соли и предложить вмешательство до наступления клинически выраженных последствий.

Сегодня ИИ в питании — не просто технологическая новинка, а потенциальный инструмент профилактики хронических заболеваний, связанных с образом жизни. Диабет, гипертония, ожирение — лишь часть проблем, на которые можно повлиять через своевременные и точные рекомендации. Интеллектуальные системы становятся посредниками между человеком и сложной биомедицинской информацией [2]. Интерес к таким решениям проявляют не только ученые и врачи, но и разработчики food-tech-платформ.

В работе рассматривается, как именно подходы к созданию интеллектуальных систем применяются в задачах персонализированного питания и на чем они основаны. Рассмотрены архитектурные решения (модульные и интегрированные), алгоритмические подходы — от классических моделей до языковых трансформеров, а также типы данных, формирующие базу рекомендаций: биомаркеры, поведенческие паттерны, визуальные сигналы, анамнез. Обсуждаются методы оценки эффективности интеллектуальных систем поддержки принятия решений на техническом и клиническом уровне. В финальной части рассматриваются конкретные примеры применения, позволяющие увидеть как реализованный потенциал технологий, так и те барьеры, с которыми сталкиваются подобные решения на практике. Отдельно рассматривается возможность использования ИИ для выявления «скрытого» передания — феномена, часто остающегося за пределами непосредственного наблюдения, но имеющего пролонгированное воздействие на обмен веществ.

Материалы и методы

Отправной точкой для анализа послужили как общедоступные, так и специализированные научные ресурсы, охватывающие публикации примерно с 2018 года и далее — с явным акцентом на свежие разработки, отражающие текущее состояние дисциплины [3]. Ключевые слова, примененные при поиске, варьировались от «персонализированное питание» и «искусственный интеллект и диета» до англоязычных выражений наподобие «nutrition recommender system» и «precision nutrition AI». В обзор включены как результаты рецензируемых исследований (в том числе систематических обзоров и эмпирических работ), так и сведения о функционирующих программных решениях [4]. Всего было проанализировано порядка полусотни материалов. Однако в итоговую версию обзора вошли лишь те, в которых прослеживается либо новизна подхода, либо концептуальная полнота, позволяющая судить о трендах в данной предметной области.

В целях придания логической стройности материалу была предложена классификация подходов по ряду ключевых параметров. Один из них — архитектурная организация систем. Отмечается широкий диапазон решений: от традиционных экспертных систем и относительно простых мобильных приложений до разветвленных облачных платформ, интегрирующих несколько специализированных модулей ИИ. Среди повторяющихся конфигураций — модульные структуры, включающие оркестраторы, персонализированные модели, популяционные базы знаний и диалоговые интерфейсы на базе LLM. Показательно, что встречаются и менее модульные конфигурации — те, где пользовательский ввод (скажем, фото с телефона) обрабатывается «насквозь» и почти без промежуточных этапов приводит к выдаче рекомендаций. Хотя подобные «сквозные» схемы и выглядят технологически изящно, отношение к ним в профессиональной среде остается, мягко говоря, неоднозначным.

Следующий аналитический фокус — используемые алгоритмические решения. Здесь различаются несколько методологических направлений: машинное обучение (включая глубокие нейросети), применяемое в задачах регрессии и классификации пищевых данных; обработка естественного языка, задействованная при анализе текстовых описаний, пищевых дневников и пользовательских запросов; методы компьютерного зрения, демонстрирующие высокую точность в идентификации и сегментации продуктов на изображениях [5]. Любопытны решения, где попытались объединить визуальные нейросети с физическим сенсингом, — например, с помощью глубинных камер для пространственной оценки еды на тарелке. Получилось своеобразное сращение двух подходов — довольно инженерное, но, по видимому, рабочее [6]. Кроме того, внимание уделено языковым моделям последнего поколения — GPT-подобным архитектурам, адаптированным под задачи генерации объясняющих рекомендаций, включая приемы prompt engineering. Любопытны и более амбициозные гибридные решения: в частности, инте-

грация казуальных моделей с языковыми, направленная на обеспечение интерпретируемости и более точной индивидуализации рекомендаций.

Особое место занимает анализ типов данных, используемых для построения систем персонализированного питания. Прежде всего, это базы данных пищевого состава — как государственные (напр., USDA FoodData Central), так и коммерческие. Обнаруженные ограничения традиционных баз (фрагментарность, устаревание, редкая актуализация) побудили к разработке новых ресурсов. В качестве иллюстрации — UMDFood-90k, представленный в 2023 году. Это не просто таблица с питательными значениями: в нее включены изображения упаковок, расшифровка ингредиентов, а местами — и химический анализ. В каком-то смысле — почти «цифровой двойник» потребительского продукта [7]. Почти 90 тысяч наименований, если верить авторам. Материал внушительный — и, судя по цитируемости, востребованный. Именно на таких массивах, как UMDFood, сегодня обучаются модели, способные оценивать состав блюда, даже если перед ними не формула, а фото из кафе.

Не менее значимы сенсорные и физиологические данные. Персональные трекеры активности, умные браслеты, неинвазивные глюкомониторы (CGM), умные весы — все это предоставляет высококачественную информацию о физиологическом состоянии пользователя.

В отдельную категорию выделены данные, поступающие от пользователей через приложения для отслеживания питания. Среди популярных инструментов — тот же Cronometer или MyFitnessPal. Некоторые пользователи предпочитают вносить все вручную, другие — полагаются на камеру: сфотографировал тарелку — и система уже распознала, что там было. Дополнительно рассматриваются биомедицинские параметры — биохимические анализы, микробиота, генетические тесты. Некоторые системы (напр., Viome, Eubiosis) включают микробиологический профиль кишечника в алгоритм формирования диет, опираясь на все более обоснованные взаимосвязи между микрофлорой, метаболизмом и пищевой чувствительностью.

Контекстуальные факторы — режим сна, уровень стресса, пищевые предпочтения и ограничения — также оказываются значимыми. Такие параметры — вроде уровня стресса, нарушений сна или просто измененного режима из-за переезда — часто оказываются критичными. Игнорировать их — значит предложить универсальный совет, к которому человек в реальности вряд ли прислушается.

Оценка эффективности систем производится на двух уровнях. Первый — технический: применяются традиционные метрики машинного обучения (ML) (Accuracy, F1-score, AUROC и др.) в задачах классификации, регрессии и прогнозирования. Выбор метрики зависит от типа задачи и структуры данных; универсального решения не выявлено. Второй уровень — прикладной: оценивается влияние рекомендаций на состояние здоровья и поведение пользователей. Рандомизированные исследования сравнивают ИИ-поддерживаемые диеты с контрольными, измеряя такие параметры, как гликемический профиль, липидный статус, масса тела, субъективное самочувствие. Немаловажны и показатели соблюдения рекомендаций, а также субъективная удовлетворенность пользователей. Вопрос доверия к системе и объяснимости ее работы остается критически важным: наличие интерпретируемых объяснений способствует устойчивости к отказу от следования рекомендациям.

Используемый статистический аппарат — от вполне ожидаемых t-тестов до GRADE-методологии — скорее подтверждает общую строгость подхода, хотя и не дает ощущения радикальной новизны. В разделе, посвященном результатам, приведены как метрики точности, так и конкретные изменения в показателях здоровья.

Результаты и их обсуждение

Современные ИИ-системы персонализированного питания строятся на модульной архитектуре: от сбора и анализа данных о рационе до формирования рекомендаций. Базовые решения включают мобильные приложения с ML-моделями, позволяющими, например, по фото еды оценить отклонения от нормы. В новых разработках все чаще появляются решения, сочетающие языковые модели, визуально-текстовый анализ и персонализированные симуляции организма.

Так, в архитектуре ChatDiet ключевую роль играет модуль-координатор, выстраивающий взаимодействие между персонализированными данными, общими диетологическими принципами и языковой моделью, формирующей рекомендации [9]. Подобный подход снижает ошибки, обеспечивает персонализацию и сохраняет интерактивность. В системах типа UMDFood-VL визуальная информация и текст о составе продуктов анализируются совместно, что позволяет достовернее оценивать нутриентный профиль.

Наблюдается сдвиг в сторону композитных архитектур: IoT-устройства, сенсоры, базы данных и модели работают синхронно. Цифровой двойник позволяет спрогнозировать реакцию организма на пищу, а предварительные расчеты проводятся офлайн. Онлайн-часть — диалог и рекомендации — реализуется через LLM под контролем оркестратора.

Алгоритмически применяются CNN, трансформеры, LSTM, методы оптимизации (fuzzy АНР, эволюционные алгоритмы), а также подходы на основе кластеризации и ассоциаций [10]. В числе применений — разбор пищевых дневников, генерация рационов с учетом индивидуальных ограничений и предпочтений, а также адаптация моделей на базе мультиомных показателей (например, гликемии или микробиоты).

Источники знаний варьируются: от USDA до пользовательских анкет и сенсорных потоков. Используются экспертные правила, графы знаний (напр., EICombo), усиливающие интерпретируемость рекомендаций [11].

Оценка эффективности проводится по точности моделей (MAE, precision@k), клиническому влиянию (снижение HbA1c, ИМТ, симптомов СРК), поведенческим изменениям и UX. Успешные системы демонстрируют сочетание высокой аналитической точности и прозрачности, что способствует формированию устойчивых пищевых привычек.

Для лучшего понимания масштабов и направлений развития интеллектуальных систем в области персонализированного питания целесообразно обратиться к конкретным случаям их реализации (см. таблицу). Приведенные кейсы иллюстрируют разнонаправленные подходы — от инициатив, опирающихся на клиническую верификацию, до решений, разрабатываемых в рамках коммерческих цифровых сервисов, нередко находящихся на различных стадиях технологического становления.

Таблица

Примеры интеллектуальных систем персонализированного питания

Система (год)	Методы ИИ	Источники данных	Основные особенности и результаты
ChatDiet (2024)	Языковая модель + причинно-ориентированное ML	Данные с трекеров, дневники питания, справочные базы	Диалоговые рекомендации с объяснениями; 92% согласованности; улучшение сна на персонализированной диете
Viome (2023)	Анализ микробиоты + модели оценки риска	Кал, кровь, анкеты	Снижение симптомов СРК (–39%), депрессии и тревожности (–31%); улучшение метаболизма [12]
PPGR-диета (2015–2021)	Ансамбли ML + сенсоры (CGM)	Глюкоза, микробиота, анкеты	Существенное снижение HbA1c, триглицеридов и гликемических скачков по сравнению с контрольной диетой [13]
UMDFood-VL (2023)	CV + NLP (Vision-Language, CLIP)	Фото продуктов и списки ингредиентов из большого датасета	AUC до 0.921 по жиру; 82% точность <10% ошибки; обновление пищевых баз
Azzimani et al. (2022) [15]	CV (глубина) + DL (многозадачная FCN)	Комбинация визуальных данных и анкетных профилей	Автоматическая оценка блюда; учет аллергий; валидация диетологами; применение в стационарах

Среди представленных решений — разные по логике и глубине применения ИИ в сфере питания. В ChatDiet основное внимание уделено взаимодействию языковой модели с личными данными, что позволяет реализовать базовый, но объяснимый самоконтроль. Viome и подходы на основе постпрандиальных реакций (PPGR) делают ставку на анализ скрытых физиологических параметров — от

микробиома до индивидуальных гликемических профилей — и в ряде случаев демонстрируют значимые клинические сдвиги [14].

UMDFood-VL работает с другим пластом — качеством баз данных о продуктах, что критично для любых последующих интерпретаций. В системе Azzimani соединены сенсоры и нейросети: задача — измерять съеденное с точностью, недоступной на глаз, что особенно важно, например, для контроля белка или натрия [15].

Есть и другая категория — менее технократическая. Lark, Noom, а также устройства вроде «умных» бутылок или вилок — это уже про повседневность и поведение. Не данные как таковые, а способы их подачи и мягкого вмешательства: напоминание, фиксация, подсказка.

Иногда достаточно обнаружить устойчивую связку: сладкий напиток — каждый перекус. Или кофе вечером — проблемы со сном. Именно такие «мелочи» ускользают, а система фиксирует. Она не диктует, но показывает, где точка перегиба. В этом и ценность: не в замене суждения, а в его расширении — пока не поздно.

Заключение

ИИ-системы позволяют выявлять скрытые дисбалансы в рационе — например, регулярное превышение допустимых уровней соли, сахара или трансжиров, которое зачастую остается незамеченным без внешнего анализа. Анализ, основанный на совмещении визуальных, текстовых и сенсорных источников, обеспечивает более достоверную реконструкцию рациона, приближая выводы моделей к уровню экспертного заключения. Это дает возможность отслеживать питание без необходимости ручного ввода.

Диалоговые интерфейсы делают систему более «человекоподобной»: рекомендации становятся прозрачнее, а пользователь вовлекается в процесс. Масштабируемость и способность к обучению на новых данных расширяют охват без ущерба качеству.

Тем не менее сохраняется ряд нерешенных задач. Оценка действенности подобных решений требует длительного эмпирического наблюдения: важно не столько зафиксировать первоначальный отклик, сколько проследить, формируются ли стабильные и воспроизводимые поведенческие изменения. Интеграция с клинической практикой предъявляет требования к совместимости, защищенности данных и объяснимости алгоритмов. Вопрос этической устойчивости остается принципиальным: при обучении на узких или социально однородных массивах данных алгоритмы нередко закрепляют уже существующие смещения. Это, в свою очередь, снижает релевантность рекомендаций для тех групп, чьи особенности изначально были слабо представлены — по возрасту, культурному контексту или уровню доступа к технологиям.

Снижение нагрузки на пользователя — необходимое условие: чем незаметнее процесс сбора данных (например, через фото или сенсоры), тем выше вероятность устойчивого использования. При этом точность рекомендаций должна строго контролироваться: даже редкие ошибки способны серьезно подорвать доверие.

Вектор развития постепенно смещается от задач контроля веса к более комплексным целям — улучшению когнитивного состояния, иммунной устойчивости, снижению долгосрочных рисков. Для этого необходимо связывать питание с биомаркерами и иными физиологическими показателями.

В целом ИИ в диетологии — не альтернатива специалисту, а инструмент дополнения. Он структурирует рутину, снижает вероятность субъективных искажений и позволяет взглянуть на собственное питание без иллюзий. Особенно это значимо в условиях избыточного потребления скрытых добавок и утраты пищевой осознанности.

ЛИТЕРАТУРА

1. Limit Fat, Salt, and Sugar Intake. *World Health Organization, Eastern Mediterranean Region*. Режим доступа: <https://www.emro.who.int/nutrition/reduce-fat-salt-and-sugar-intake/>.
2. Huang L., Li J., Zhang Y., Chen X. The Role of Artificial Intelligence in Obesity Risk Prediction and Management: Approaches, Insights, and Recommendations. *Medicina*. 2025;61(2):358. DOI: 10.3390/medicina61020358.

3. Theodore Armand T. P., Nfor K. A., Kim J-I., Kim H.-C. Applications of Artificial Intelligence, Machine Learning, and Deep Learning in Nutrition: A Systematic Review. *Nutrients*. 2024;16(7):1073. DOI: 10.3390/nu16071073.
4. Agrawal K., Goktas P., Kumar N., Leung M.-F. Artificial Intelligence in Personalized Nutrition and Food Manufacturing: A Comprehensive Review of Methods, Applications, and Future Directions. *Frontiers in Nutrition*. 2025;12. DOI: 10.3389/fnut.2025.1636980.
5. Yang Z., Khatibi E., Nagesh N., Abbasian M., Azimi I., Jain R., Rahmani A. *ChatDiet: Empowering Personalized Nutrition-Oriented Food Recommender Chatbots through an LLM-Augmented Framework*. arXiv:2403.00781. 2024. DOI: <https://doi.org/10.48550/arXiv.2403.00781>.
6. Lee D.-S., Kwon S.-K. Amount Estimation Method for Food Intake Based on Color and Depth Images through Deep Learning. *Sensors*. 2024;24(7):2044. DOI: 10.3390/s24072044.
7. Ma P., Wu Y., Yu N., Zhang Y., Backes M., Wang Q., Wei C.-I. *UMDFood: Vision-Language Models Boost Food Composition Compilation*. arXiv:2306.01747. 2023. DOI: 10.48550/arXiv.2306.01747.
8. Arefeen A., Fessler S., Mostafavi S. M., Johnston C. S., Ghasemzadeh H. *MealMeter: Using Multimodal Sensing and Machine Learning for Automatically Estimating Nutrition Intake*. arXiv:2503.11683. 2025. DOI: <https://doi.org/10.48550/arXiv.2503.11683>.
9. Yang Z., Khatibi E., Nagesh N., Abbasian M., Azimi I., Jain R., Rahmani A. M. *ChatDiet: Empowering Personalized Nutrition-Oriented Food Recommender Chatbots through an LLM-Augmented Framework*. arXiv:2403.00781. 2024. DOI: <https://doi.org/10.48550/arXiv.2403.00781>.
10. Rao S., Neethirajan S. Computational Architectures for Precision Dairy Nutrition Digital Twins: A Technical Review and Implementation Framework. *Sensors*. 2025;25(16):4899. DOI: 10.3390/s25164899.
11. Xu Z., Gu Y., Xu X., Topaz M., Guo Z., Kang H., Sun L., Li J. Developing a Personalized Meal Recommendation System for Chinese Older Adults: Observational Cohort Study. *JMIR Formative Research*. 2024;8:e52170. DOI: 10.2196/52170.
12. Tunali V., Arslan N. Ç., Ermiş B. H. et al. A Multicenter Randomized Controlled Trial of Microbiome-Based Artificial Intelligence-Assisted Personalized Diet vs Low-Fermentable Oligosaccharides, Disaccharides, Monosaccharides, and Polyols Diet: A Novel Approach for the Management of Irritable Bowel Syndrome. *The American Journal of Gastroenterology*. 2024;119(9):1901–1912. DOI: 10.14309/ajg.0000000000002862.
13. Tay J., Thompson C. H., Luscombe-Marsh N. D., Wycherley T. P., Noakes M., Buckley J. D., Wittert G. A., Yancy W. S. Jr., Brinkworth G. D. Effects of an Energy-Restricted Low-Carbohydrate, High Unsaturated Fat/Low Saturated Fat Diet Versus a High-Carbohydrate, Low-Fat Diet in Type 2 Diabetes: A 2-Year Randomized Clinical Trial. *Diabetes, Obesity and Metabolism*. 2018;20(4):858–871. DOI: 10.1111/dom.13164.
14. Tily H., Partridge E., Cai Y., et al. Gut Microbiome Activity Contributes to Prediction of Individual Variation in Glycemic Response in Adults. *Diabetes Therapy*. 2022;13(1):89–111. DOI: 10.1007/s13300-021-01174-z. Режим доступа: <https://pubmed.ncbi.nlm.nih.gov/PMC8776936>.
15. Azzimani K., Bihri H., Dahmi A., Azzouzi S. An AI-Based Approach for Personalized Nutrition and Food Menu Planning. *Proc. of 2022 IEEE 3rd International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS)*. Fez, Morocco, 2022:1–5. DOI: 10.1109/ICECOCS55148.2022.9983099.