

УДК 004.89:613.2

<https://doi.org/10.31548/humanhealth.3.2026.67>

ПЕРСОНАЛІЗОВАНА НУТРИЦІОЛОГІЯ ТА ШТУЧНИЙ ІНТЕЛЕКТ: СУЧАСНІ ПІДХОДИ, РЕГУЛЯТОРНІ ВИКЛИКИ ТА КЛІНІЧНА ЕФЕКТИВНІСТЬ

Зінаїда Андріївна Бурова

кандидат технічних наук, доцент

<https://orcid.org/0000-0002-4712-6298>

Максим Миколайович Гудзенко

кандидат технічних наук, доцент

<https://orcid.org/0000-0001-7959-3627>

Юлія Петрівна Крижова

кандидат технічних наук, доцент

<https://orcid.org/0000-0003-1165-8898>

*Національний університет біоресурсів і природокористування України,
03041, вул. Героїв Оборони 15, м. Київ, Україна*

Денис Володимирович Гайдучек

аспірант

<https://orcid.org/0009-0009-2780-3827>

*Національний університет харчових технологій,
01033, вул. Володимирська 68, м. Київ, Україна*

Анотація. Цифровізація охорони здоров'я стимулює перехід від узагальнених моделей дієтології до персоналізованої нутриціології. Традиційні підходи не враховують індивідуальних варіацій у метаболізмі, що знижує їхню ефективність у профілактиці хронічних захворювань. Мета роботи – аналіз систем штучного інтелекту у створенні персоналізованих дієтичних рекомендацій, оцінка їхньої клінічної ефективності, викликів стандартизації та етичних аспектів впровадження. У роботі застосовано систематичний аналіз наукових джерел, метод порівняльного аналізу клінічних досліджень, зокрема рандомізовані контрольовані випробування та концептуальне моделювання операційного потоку даних. Встановлено, що персоналізація дієти є динамічним 5-кроковим циклом: збір мультимодальних даних, аналіз із залученням штучного інтелекту, прогнозування, генерація рекомендацій та зворотний зв'язок у реальному часі. Показано, що певні моделі штучного інтелекту (XGBoost, Stacking) показують точність прогнозування метаболічних ризиків до 96,07%. Оцінення раціону за допомогою комп'ютерного зору та глибокого навчання підвищує точність ідентифікації продуктів на 30% при врахуванні національного контексту та геолокації.

Клінічні дані підтверджують, що дієтичні рекомендації, розроблені із застосуванням моделей штучного інтелекту, забезпечують зменшення симптомів синдрому подразненого кишечника на 39% та ремісію діабету 2 типу у 72,7% пацієнтів. Таким чином, доведено ефективність залучення технологій штучного інтелекту у створенні персоналізованих рекомендацій для поліпшення здоров'я й зменшення симптомів хронічних захворювань, зокрема, результати показують суттєве покращення метаболічних показників та якості життя пацієнтів.

Також акцентовано на необхідності стандартизації даних та розвитку регуляторних вимог для успішного впровадження персоналізованої нутриціології у клінічну практику. Висвітлюються питання етики, пов'язані з конфіденційністю та відповідальністю у застосуванні штучного інтелекту, а також важливість пояснюваного штучного інтелекту для підвищення довіри пацієнтів

до технологічних рішень у сфері здоров'я. У підсумку окреслено перспективи розвитку персоналізованої нутриціології як нової парадигми у харчуванні, що має потенціал значно вдосконалити підходи до здоров'я і благополуччя людей.

Ключові слова: персоніфікована дієта, машинне навчання, глибоке навчання, аналіз мікробіому, біомаркери метаболізму, пояснюваний штучний інтелект.

UDC 004.89:613.2

<https://doi.org/10.31548/humanhealth.3.2026.67>

PERSONALIZED NUTRITION AND ARTIFICIAL INTELLIGENCE: MODERN APPROACHES, REGULATORY CHALLENGES, AND CLINICAL EFFICACY

Zinaida Burova

PhD in Technical Sciences, Associate Professor

<https://orcid.org/0000-0002-4712-6298>

Maksym Hudzenko

PhD in Technical Sciences, Associate Professor

<https://orcid.org/0000-0001-7959-3627>

Yuliia Kryzhova

PhD in Technical Sciences, Associate Professor

<https://orcid.org/0000-0003-1165-8898>

*National University of Life and Environmental Sciences of Ukraine,
03041, 15 Heroiv Oborony St., Kyiv, Ukraine*

Denis Gaiduchek

Postgraduate Student

<https://orcid.org/0009-0009-2780-3827>

*National University of Food Technologies,
01033, 68 Volodymyrska St., Kyiv, Ukraine*

Abstract. The digitalization of healthcare is driving a shift from generalized dietary models to personalized nutrition. Traditional approaches fail to account for individual metabolic variations, which reduces their effectiveness in chronic disease prevention. The objective of this paper is to analyze artificial intelligence systems in generating personalized dietary recommendations, evaluate their clinical efficacy, address data standardization challenges, and explore ethical implementation aspects. The study employs a systematic review of scientific sources, a comparative analysis of clinical trials—specifically randomized controlled trials—and conceptual modeling of the operational data flow. It was established that dietary personalization operates as a dynamic 5-step loop: multimodal data collection, AI-driven analysis, prediction, recommendation generation, and real-time feedback. Certain artificial intelligence models (XGBoost, Stacking) demonstrated a metabolic risk prediction accuracy of up to 96.07%. Dietary assessment utilizing computer vision and deep learning improves food recognition accuracy by 30% when accounting for national context and geolocation.

Clinical data confirm that dietary recommendations developed using artificial intelligence models achieve a 39% reduction in irritable bowel syndrome symptoms and a 72.7% diabetes type 2 remission rate. Thus, the efficacy of incorporating artificial intelligence technologies into personalized recommendations for health improvement and symptom reduction in chronic diseases has been proven, with results demonstrating significant enhancements in patients' metabolic parameters and life quality.

The necessity of data standardization and regulatory framework development for the successful

implementation of personalized nutrition into clinical practice is also emphasized. Ethical issues regarding privacy and accountability in AI applications are highlighted, alongside the importance of explainable artificial intelligence in fostering patient trust in digital health solutions. Ultimately, the prospects for personalized nutrition as a new paradigm in dietary science with the potential to substantially improve public health and well-being approaches are outlined.

Keywords: precision diet, machine learning, deep learning, microbiome analysis, metabolic biomarkers, explainable artificial intelligence.

ВСТУП. Цифровізація та масштабне використання технологій штучного інтелекту наразі спостерігається в усіх аспектах нашої життєдіяльності. У сфері охорони здоров'я в Україні маємо впровадження системи HELSI, перехід на електронні картки пацієнтів та поступове формування індивідуального підходу до кожного пацієнта. Так само еволюціонують підходи в нутриціології – від традиційних до Персоніфікованої Нутриціології.

Традиційні підходи в нутриціології зазвичай спираються на спрощені середньостатистичні моделі, які мають узагальнений підхід для груп людей, не враховуючи при цьому велику різноманітність індивідуальних реакцій на типізовані рекомендації щодо дієтичного харчування. Це обмеження призводить до недостатньої ефективності в управлінні складними хронічними захворюваннями та покращенні загального самопочуття окремої особи. Такі моделі є застарілими та не здатні адекватно враховувати особливі взаємозв'язки між генетичними, фенотипічними факторами та способом життя, що й стало основою для розвитку концепції Персоніфікованої Нутриціології (PN – Precision Nutrition, або «точна» нутриціологія) (Verma et al., 2018; Martynchuk et al., 2025; Agrawal et al., 2025).

PN передбачає розроблення дієтичних рекомендацій, які враховують індивідуальні особливості кожної людини на основі комплексного аналізу її генетики, фенотипу (таких як біомаркери та мікробіом), а також поведінкових аспектів. Це потребує використання технологій, здатних об'єднувати та аналізувати великі обсяги різноманітних даних. Саме тут у нагоді стають сучасні інструменти штучного інтелекту (AI – Artificial Intelligence) та технології Big Data («великих даних»), оскільки саме за їх допомогою можливо проводити масштабне кількісне оцінення індивідуальних реакцій, яка була недоступною у традиційних методах.

Big Data у контексті персоніфікованої нутриціології охоплює не лише великі обсяги інформації, а й швидкісне збирання даних, що відбувається в реальному часі за допомогою різних носимих пристроїв – це можуть бути смарт-годинники та кільця, фітнес-трекери тощо. Крім того, важливим є різноманіття джерел цих даних, що й робить Big Data важливим інструментом для індивідуалізації підходів до харчування.

Штучний інтелект, в свою чергу, використовує й опрацьовує великі масиви отриманих даних для створення прогностичних моделей, які адаптуються до особливостей метаболізму та поведінкових закономірностей кожної людини (Martynchuk et al., 2025). AI також допомагає виявляти складні зв'язки між харчуванням і клінічними результатами, що є складним, а подекуди й неможливим завданням для ручного опрацювання з використанням традиційних методів аналізу. Отже, Big Data постачає необхідні дані, а штучний інтелект перетворює їх на детальні рекомендації щодо харчування, адаптовані до індивідуальних потреб.

Згідно аналізу досліджень фахівців, модель персоналізованої нутриціології, керованої AI, узагальнено можна представити динамічним 5-кроковим процесом, що забезпечує постійну адаптацію рекомендацій до фізіологічних змін індивіда. Основні етапи наступні:

1. збирання даних: агрегацію мультимодальних даних (генетичні біомаркери, характеристики мікробіому та харчові звички особи);

2. AI-аналіз: застосування алгоритмів машинного навчання для виявлення патернів у отриманих даних, що дозволяють визначити, які фактори найбільше впливають на здоров'я пацієнта;

3. прогнозування: моделювання індивідуальних реакцій на харчові компоненти, що допомагає передбачити вплив на здоров'я особи конкретних продуктів;

4. генерація рекомендацій: створення адаптивних дієтичних планів з врахуванням унікальних потреб пацієнта;

5. зворотний зв'язок: моніторинг результатів в реальному часі для внесення коректив у дієту згідно з прогресом пацієнта.

Інфографіку моделі персоналізованої нутриціології, керованої AI, представлено на рис. 1.



Рисунок 1. Операційний потік персоналізації на основі AI

Найважливішим параметром в цій моделі є її циклічність. Оскільки людський організм постійно змінюється, тому й дієта не може бути статичною. Завдяки постійному зворотному зв'язку (крок 5) штучний інтелект не просто видає разову пораду, а безперервно навчається на індивідуальних реакціях організму – оцінює рівень цукру, сон чи самопочуття і миттєво підлаштовує раціон під нові потреби. Це перетворює харчування з одноразової фіксованої дієти на живу адаптивну систему, яка змінюється разом із людиною та допомагає досягати реальних результатів у довгостроковій перспективі.

ОГЛЯД ЛІТЕРАТУРИ. Застосування штучного інтелекту в нутриціології наразі є однією з найбільш обговорюваних тем у рецензованій літературі, що відображено в ключових систематичних оглядах, індексованих у Scopus та Web of Science, зокрема, авторів Zale and Mathioudakis (2022), Yang (2022) Detopoulou et al. (2023), Mansouri et al. (2023), Fonseca et al. (2025). Ці дослідження підтверджують трансформаційний потенціал технологій у клінічних умовах. У фокусі більшості досліджень, з огляду на завдання персоналізації, є інтеграція різноманітних джерел даних та здатність AI розпізнавати складні біологічні патерни. Більшість систем AI, які наразі застосовуються для персоналізованих дієтичних рекомендацій, використовують алгоритми машинного навчання (ML – Machine Learning), а деякі впроваджують глибоке навчання (DL – Deep Learning) та гібридні підходи, інтегруючи ML із системами

Інтернету Речей (IoT – Internet of Things) для надання рекомендацій у режимі реального часу (Gaiduchek et al., 2025)

В огляді Li et al. (2025) представлено ґрунтовний аналіз щодо використання AI та ML для оцінки раціону харчування на основі зображень та сенсорів з подальшим впровадженням у персоніфікованій нутриціології. В роботі Rafie et al. (2025) описано створення, впровадження та практичну значущість прогностичних моделей («предиктивного моделювання») у сфері громадського здоров'я, епідеміології та безпеки харчових продуктів.

Аналіз клінічних досліджень (Wang et al., 2020; Rafie et al., 2025), проведених у формі систематичного огляду, що включає 11 досліджень, серед яких Рандомізовані контрольовані випробування (РКВ), показує обнадійливі результати щодо клінічної ефективності персоналізованих дієт, згенерованих AI, а саме:

- впливи, керовані AI, призвели до покращення метаболічного здоров'я, глікемічного контролю та психологічного благополуччя пацієнтів (Wang et al., 2020)

- зафіксовано значні позитивні результати у лікуванні хронічних захворювань, зокрема зменшення тяжкості симптомів синдрому подразненого кишечника (СПК) на 39% (Gavaì and van Hillegersberg, 2025)

- рівень ремісії діабету 2 типу становив 72,7% серед пацієнтів (Gavaì and van Hillegersberg, 2025)

- у дев'яти дослідженнях, які мали контрольні групи, шість продемонстрували статистично значуще покращення результатів у групах, які отримували дієтичні рекомендації на основі AI, два знайшли порівнянні або кращі результати в групах AI, і лише одне дослідження не виявило різниці (Gavaì and van Hillegersberg, 2025)

Ці клінічні дані, що базуються на РКВ та систематичних оглядах, свідчать про те, що дієтичні втручання, згенеровані AI на основі аналізу біомаркерів (зокрема, це рівень глюкози в крові та склад мікробіому кишечника), мають потенціал перевершити традиційні підходи, надаючи високоперсоналізовані, науково обґрунтовані рекомендації (Wang et al., 2020).

МАТЕРІАЛИ ТА МЕТОДИ. Для розробки ефективних персоналізованих рекомендацій системи штучного інтелекту потребують доступу до різноманітних даних, які включають біологічні, клінічні та поведінкові характеристики конкретної людини. Розглянемо для прикладу архітектуру даних, яка була запропонована Romero-Tapiador et al. (2023) в моделі AI4FoodDB («AI-for-Food-DataBase»). Для успішного впровадження нутриціологічних заходів автори доводять необхідність поєднати до десяти основних наборів даних, які відображають різні типи інформації, отриманої в процесі комплексного дослідження (рис. 2)

Ці набори даних можна розділити на дві основні категорії:

1. **Клінічні та фізіологічні дані** – це об'єктивні вимірювання, критичні для оцінки поточного стану здоров'я та прогнозування метаболічного ризику:

- антропометричні вимірювання (DS1): використовуються для базової оцінки стану здоров'я та моніторингу ефективності дієтичних впливів.

- життєві показники (DS6): дозволяють відслідковувати динамічні фізіологічні зміни.⁴

- ключові біомаркери (DS4): лабораторні дані, які є основою для розуміння метаболічної функції. Визначальними чинниками є результати аналізів рівнів тригліцеридів (в середньому 106 ± 46 мг/дл), глюкози (82 ± 8 мг/дл), глікованого гемоглобіну HbA1c ($5,63 \pm 0,34\%$), інсуліну та LDL-холестеролу. Ці біомаркери є критично важливими предикторами метаболічної відповіді на дієту та ризику розвитку метаболічного синдрому (MetS).

- оміксні дані (DS5): аналіз профілів мікробіому є фундаментальним, оскільки мікробіота кишечника відіграє вирішальну роль у засвоєнні поживних речовин та індивідуальній метаболічній реакції

2. Дані щодо поведінки та спосіб життя – необхідна інформація про щоденну поведінку особи, постійний моніторинг біологічних даних про:

- спосіб життя (DS2) та харчування (DS3): дані про дієтичні звички та загальний стан здоров'я.
- динамічні поведінкові дані (DS7, DS8, DS9): включають дані щодо фізичної активності, режиму сну та емоційного стану. Такі дані зазвичай збираються за допомогою носимих цифрових пристроїв – смарт-годинників, кілець, фітнес-трекерів, що забезпечують інформування в режимі реального часу.



Рисунок. 2. Дані бази AI4FoodDB для нутриційного дослідження:

антропометричні вимірювання (DS1), спосіб життя та здоров'я (DS2), харчування (DS3), біомаркери (DS4), кишковий мікробіом (DS5), життєві показники (DS6), фізична активність (DS7), активність сну (DS8), емоційний стан (DS9) та додаткова інформація (DS10).

Методи збору даних позначені різнокольоровими прямокутниками та іконками: **ручний** (зображений у вигляді блокнота), **клінічний** (мікроскоп) або **цифровий** (смарт-годинник)

Джерело: Адаптовано на основі досліджень Romero-Tapiador et al. (2023)

Потреба у всебічному збиранні даних виникає з того факту, що жоден окремий тип даних не може повністю пояснити складну індивідуальну реакцію організму на рекомендоване харчування.

Процес збирання різноманітних даних (DS1–DS10) є важливим кроком, але найбільша перешкода для широкого впровадження штучного інтелекту в клінічну практику полягає не в обчислювальних потужностях, а в критичній відсутності стандартизації та якості даних.

Існуючі бази даних споживання харчових продуктів стикаються з труднощами в упорядкованому фіксуванні складних харчових патернів та точному оціненні енергетичної та нутритивної складових вмісту умовної тарілки. Різниця в методах збирання та описах харчових продуктів, а також варіації у генерації їхнього хімічного складу (наприклад, залежно від того, чи зібрано дані в лабораторії, пацієнтом особисто чи медичним закладом узагальнено) створюють суттєві розбіжності.

Для вирішення цих проблем необхідно створити обчислювальну інфраструктуру для персоналізованої нутриціології, яка повинна забезпечити стандартизовані формати даних, спільну термінологію та онтологію, а також можливість обміну даними між різними дослідженнями, лікарнями та лікарями.

Ключовим аспектом такої інфраструктури має бути те, що вона повинна бути сумірною за обсягом та якістю з існуючими базами даних складових харчових продуктів, такими як європейська EuroFIR або американська USDA's FoodData Central. Стандартизація даних відповідно до глобальних баз даних є критично важливою для забезпечення надійності клінічних даних та можливості обміну інформацією між різними закладами. Відсутність стандартних електронних медичних карток та єдиної онтології призводить до важливого розриву між «великими даними» та «валідними даними» для навчання моделей штучного інтелекту.

Концепція створення справді індивідуальних дієтичних рекомендацій наразі базується на принципі «N-of-1 trial», тобто принцип зосередження досліджень на одному індивіді протягом тривалого періоду. У традиційних групових дослідженнях дані зазвичай усереднюються, що ускладнює їх застосування для конкретного пацієнта. Методологія N-of-1 дослідження передбачають регулярне збирання детальних даних про одну особу щодня або з певними перервами впродовж місяців або років. Цей підхід дозволяє виявити унікальні закономірності та специфічні фактори ризику, які не помітні при обробці групових даних.

Новітні високотехнологічні апарати, такі як носимі пристрої, значно спрощують збирання даних в режимі реального часу. Проте важливо дотримуватись суворих наукових протоколів під час використання методології N-of-1, щоб уникнути суб'єктивних упереджень. Збирання таких динамічних даних в стандартизованій інфраструктурі відкриває нові можливості для адаптації алгоритмів до індивідуальних потреб пацієнтів. Мультимодальний підхід до комплексного збирання даних проілюстровано в табл. 1.

Таблиця 1. Класифікація мультимодальних джерел даних у персоніфікованій нутриціології

Тип даних (DS)	Види вимірювань/ біомаркери	Метод збирання даних	Значення для моделювання ПН
DS1: Антропометричні	ІМТ, Вага, Зріст	Ручний/ Клінічний	Базове оцінення стану здоров'я та ефективності дієтичних заходів

DS4: Біомаркери	Глюкоза, HbA1c, Тригліцериди (106 ± 46 мг/дл), Інсулін	Клінічний (лабораторний аналіз)	Предиктори метаболічної відповіді та ризику MetS
DS5: Мікробіом	Таксономічний профіль, Функціональність	Клінічний	Індивідуальна реакція на макро/мікронутрієнти
DS7-DS9: Спосіб Життя	Фізична активність, Режим сну, Емоційний стан	Цифровий (Smartwatch, Опитування)	Контекстуалізація та адаптація рекомендацій у реальному часі

Джерело: узагальнено на основі моделі AI4FoodDB авторів Romero-Tapiador et al. (2023)

РЕЗУЛЬТАТИ ТА ОБГОВОРЕННЯ. Машинне навчання допомагає перетворювати великі та складні обсяги даних у моделі, здатні прогнозувати, як саме людина реагуватиме на різні дієтичні зміни. В роботі Gavai and van Hillegersberg, (2025) показано значну клінічну цінність ML-моделей, особливо коли мова йде про виявлення людей, які знаходяться в групі високого ризику розвитку Метаболічного Синдрому (MetS) на ранніх стадіях. Для цього використовуються різноманітні дані, включаючи демографічні, генетичні та клінічні.

Наприклад, особливу ефективність показали такі сучасні і потужні ML-моделі класу ансамблевих методів, як Stacking і XGBoost. Вони здатні об'єднати декілька алгоритмів для отримання значно точнішого передбачення, ніж це може зробити будь-яка окрема модель. Дослідження Romero-Tapiador et al. (2023) продемонстрували, що такі підходи, добре прогнозують втрату ваги та поліпшення показників MetS у людей, які дотримуються середземноморської дієти. Серед ключових факторів, що впливають на ці моделі, виділяють вік, маркери інсулінорезистентності та запальні біомаркери. Важливість інсулінорезистентності, як основного предиктора, підкреслює необхідність постійного моніторингу, оскільки цей показник тісно пов'язаний із харчуванням та способом життя.

У дослідженні Wang et al. (2020) показано, що прогностичну ефективність підвищують такі параметри, як показники глюкози натще, наявність жирової дистрофії печінки, індекси червоних кров'яних клітин та фактори способу життя, наприклад, вживання енергетичних напоїв і час, проведений за телевизором. Висока точність цих ансамблевих моделей підтверджує синергію між динамічними клінічними біомаркерами та поведінковими даними. Така інтеграція дозволяє створити механізм зворотного зв'язку, необхідний для постійного вдосконалення дієтичних рекомендацій, на відміну від статичних генетичних прогнозів (Gavai and van Hillegersberg, 2025).

Одним з найбільш складних завдань у клінічній нутриціології вважається оцінювання фактичного споживання їжі. З 2015 року традиційні алгоритми поступово замінюються моделями глибокого навчання, такими як нейронні мережі CNN (Convolutional Neural Networks) і генеративні мережі GAN (Generative Adversarial Networks). Новаторський підхід демонструє оцінка раціону харчування за допомогою зображень (Image-Assisted Dietary Assessment – IADA), що використовує алгоритми комп'ютерного зору для імітації людського сприйняття дієтичної інформації, зокрема для розпізнавання їжі та оцінки обсягу порцій на основі зображень (Chotwanvirat et al., 2024; Liu et al., 2025). Методології глибокого навчання для розпізнавання їжі наразі поєднують:

1. Навчання з перенесенням – цей підхід зменшує потребу в великих маркованих наборах даних про їжу. Моделі спочатку навчаються на великих загальних датасетах (наприклад, ImageNet), а потім тонко налаштовуються для конкретних завдань розпізнавання їжі.

2. Самостійне навчання – використовується для підвищення здатності моделі до узагальнення, у тому числі шляхом прогнозування прихованого вмісту на частинах зображення.

Цікавим фактом є те, що чисто візуальні дані можуть мати культурні упередження. Щоб підвищити точність і практичну цінність моделей, використовують метод злиття мультимодальних даних. Поєднання візуальної інформації з додатковими даними, такими як традиційні рецепти місцевої кухні та геолокація, може компенсувати культурні та регіональні відмінності. Дослідження Liu et al. (2025) показали, що врахування географічного розташування може підвищити продуктивність розпізнавання їжі приблизно на 30%.

Аналіз результатів прогностичної продуктивності алгоритмів штучного інтелекту підсумовано у табл. 2.

Таблиця 2. Продуктивність алгоритмів ML/DL у персоніфікованій нутриціології

Завдання	Алгоритм	Ключові предиктори/вхідні дані	Точність	Результат
Прогнозування MetS/Діабету	XGBoost (Ensemble)	Глюкоза натще, Жирова дистрофія печінки, Індeksi еритроцитів	Accuracy: 96.07%, AUC: 99.29% (Rafie et al., 2025)	Висока ефективність у доклінічній ідентифікації MetS (Li et al., 2025)
Покращення MetS на дієті	Stacking/ XGBoost	Вік, Маркери інсулінорезистентності, Запальні біомаркери	Висока прогностична ефективність (Li et al., 2025)	Оптимізація індивідуалізованих дієтичних втручань
Оцінка раціону (IADA)	Deep Learning CNN/GAN	Зображення їжі + Геолокація/Текст рецепту	Підвищення точності до 30% (Wang et al., 2020)	Підвищення практичної цінності платформ відстеження дієти (Rafie et al., 2025)

Отже, інтеграція Big Data у практику персоніфікованої нутриціології відбувається завдяки комбінації різних класів алгоритмів:

1. Предиктивне моделювання – використовує ансамблеві ML-моделі (XGBoost, Stacking) для прогнозування індивідуальної реакції (наприклад, метаболічної відповіді на глюкозу) та ризику розвитку хронічних захворювань (MetS, діабет).

2. Глибоке Навчання (Deep Learning) – застосовується переважно у Image-Assisted Dietary Assessment (IADA), з використанням CNN/ GAN-моделей для розпізнавання їжі, оцінки порцій та розрахунку калорійності за зображенням.

3. Рекомендаційні системи – працюють на основі ML та Генеративного AI, пропонують персоналізовані продукти, рецепти та дієтичні плани, враховуючи генетику, метаболічні потреби

та смакові вподобання. Таким чином, новітні технології дозволяють створювати більш індивідуалізовані підходи у харчуванні, що враховують особисті потреби кожного організму.

Практичне застосування алгоритмів штучного інтелекту в персоніфікованій нутриціології – це інтелектуальні програми для управління здоров'ям та різноманітні програмні застосунки, які використовують попередньо навчені ML/DL моделі для ідентифікації їжі та розрахунку її поживної цінності.

Алгоритми машинного навчання також наразі активно використовуються для аналізу ринкових трендів та уподобань споживачів, що значно прискорює процес створення нових товарів (Verma et al., 2018). Наприклад, такі компанії, як Coca-Cola, використовують AI для розробки нових напоїв, а Impossible Foods вдосконалює рослинні продукти, які мають імітувати традиційні м'ясні вироби.

Однією з ключових сфер інновацій є використання AI для вивчення того, як споживачі сприймають смак і текстуру продуктів в контексті поживних потреб. Аналізуючи індивідуальні реакції на різні смаки, AI може допомогти створити більш смачні та поживні продукти, орієнтуючись на конкретні групи населення, наприклад, літніх людей або людей із зниженою смаковою чутливістю. Це свідчить про стратегічний перехід до так званої поведінкової нутриціології, коли рекомендації є не лише корисними для здоров'я, але й задовольняють смакові уподобання, що є важливим для формування стійкої звички до здорового харчування.

Як вже було зазначено вище, штучний інтелект має величезний потенціал для зміни підходів до управління хронічними захворюваннями, такими як ожиріння та діабет 2 типу. Завдяки своїй спроможності створювати масштабовані та науково обґрунтовані рішення, AI може допомогти пацієнтам краще дотримуватись дієтичних планів і підвищити їх рівень обізнаності про здоров'я.

Прототипи систем, які надають персоналізовані дієтичні рекомендації для пацієнтів з ожирінням та діабетом, показали обнадійливі результати, особливо в контрольованих умовах. Наприклад, у дослідженнях Rafie et al. (2025) показано, що система досягла 80,1% дотримання цільових показників здоров'я, включаючи норми щодо калорійності, волокон та жирів. Вона також продемонструвала високу відповідність екологічним критеріям, досягнувши 92% дотримання вимог щодо використання сезонних та місцевих інгредієнтів. Ці результати свідчать про те, що AI може забезпечувати точні мікро-втручання. Проте основним викликом залишається довести ефективність таких систем у реальному житті з більшою варіативністю умов. Створення зручного зв'язку між ідеями AI та процесами клінічного управління стане визначальним етапом для подальшого розвитку.

Незважаючи на обнадійливі перспективи, клінічна ефективність та вплив AI-систем у реальному житті ще не цілком зрозумілі. Основними перешкодами для їх ширшого впровадження можуть бути значні відмінності в алгоритмах AI та розмірі вибірок, що ускладнює аналіз та узагальнення результатів, та необхідність адаптації до різних груп населення.

Для безпечного та справедливого впровадження AI в медичну практику майбутні дослідження повинні дотримуватись кількох важливих принципів:

1. потрібні систематичні, довгострокові клінічні випробування, щоб оцінити постійну прихильність пацієнтів і стабільність клінічних результатів;
2. дослідження мають зосереджуватись на тестуванні в умовах реального життя, а не лише в лабораторіях;
3. імплементувати AI-рекомендації в офіційні клінічні настанови, адаптуючи їх під клінічні процеси, платформи телемедицини та публічні ініціативи.

Системи AI повинні переходити від простого прогнозування до реальних дій та інтеграції, тобто має бути вирішено питання впровадження результатів у медичну практику, забезпечуючи постійну адаптацію та практичну значущість для лікарів.

Зважаючи на те, наскільки активну роль бере на себе AI у прийнятті рішень щодо здоров'я, першочерговою стає потреба у прозорості, справедливості та відповідальності щодо цих рішень. Про це акцентовано у новітніх дослідженнях, зокрема Fernandes et al. (2023), Yao et al. (2024), Abbas et al. (2025), Andrade-Calle et al. (2025). Наразі виклики щодо впровадження AI можна поділити дві основні групи:

I. **технічні**: нестандартизовані формати даних електронних карток пацієнтів; проблема «пропущених» або «загублених» даних; відсутність загальноприйнятої референтної бази даних щодо характеристик харчових продуктів (таких як EuroFIR або FoodData Central); вимоги стандартизації для клінічної надійності.

II. **етичні/правові** – включають питання захисту особистих даних (конфіденційності); алгоритмічну прозорість; захист прав пацієнтів; лікарську відповідальність за наслідки рішень AI та право пацієнта на роз'яснення автоматизованого рішення.

Щоб встановити довіру до системи штучного інтелекту, потрібно зрозуміти, як вона приймає рішення та формує рекомендації. Якщо цього немає, персоналізація стає малозрозумілою, а лікарі та пацієнти не можуть впевнено покладатися на AI-рекомендації. Тому важливим елементом, який допомагає усвідомити логіку моделі, наразі є так званий Пояснюваний AI (Explainable AI – XAI), що має на меті підвищити рівень довіри у медичних спеціалістів і пацієнтів, роблячи різноманітні нутриціологічні втручання більш зрозумілими та прийнятними.

Пояснюваність системи – це не просто технічний бонус, а ключова вимога для дотримання юридичних і етичних норм. Наприклад, Загальний регламент про захист даних ЄС (GDPR) говорить про право кожної особи на пояснення автоматизованих рішень (SAP Global AI Ethics Policy, 2025). Крім того, важливими етичними питаннями є прозорість алгоритмів, захист приватності та запобігання дискримінації.

Для досягнення прозорості в системах AI застосовуються різноманітні методи XAI:

- **Пост-фактум пояснення**: аналізують внесок окремих факторів після прийняття рішення. Прикладами є адитивні пояснення Шеплі (Shapley Additive Explanations – SHAP) та локальні інтерпретовані пояснення, незалежні від моделі (Local Interpretable Model-agnostic Explanations – LIME). SHAP може давати як локальні пояснення (чому саме цей пацієнт отримав цю рекомендацію?), так і глобальні (які фактори найбільше впливають на модель в цілому?).

- **Інтерпретовані моделі**: наприклад, метод «Chain of Thought» («ланцюг роздумів») розробляє моделі, які природно пояснюють свої дії, поділяючи їх на логічні етапи.

- **Розширені методи**: пропонують фактичні пояснення і виявлення причинно-наслідкових зв'язків, а не тільки простих кореляцій. Ці підходи нагадують клінічне мислення.

Впровадження систем підтримки клінічних рішень, які використовують XAI, є важливим для індивідуалізованої медицини. У нутриціології XAI виступає не тільки як інструмент пояснення, але й як критично важливий механізм для підвищення прихильності та довіри пацієнтів. Наприклад, у догляді за хронічними захворюваннями, такими як діабет, XAI може аналізувати дані з носимих пристроїв і електронних медичних записів у реальному часі (Wang et al., 2020; Rafie et al., 2025). З використанням SHAP система може пояснити пацієнту чи лікарю, що підвищення рівня глюкози сталося не через дієту, а через недосип або стрес. Це не тільки підвищує довіру до системи, але й навчає користувачів розуміти, які фактори впливають на їхнє здоров'я, що веде до кращих результатів лікування.

В роботі Gavaì and van Hillegersberg, (2025) в прототипі системи рекомендацій XAI описано використання метода генерації з доповненням пошуком (Retrieval-Augmented Generation – RAG) з метою для покращення залучення користувачів, надаючи зрозумілі пояснення переваг різних інгредієнтів та інтерактивні можливості. Це дозволяє перетворити складні нутриціологічні рекомендації на прості та зрозумілі інструкції, підвищуючи обізнаність користувачів про своє здоров'я.

На рівні державного регулювання, в тому числі в системі охорони здоров'я, наразі впроваджують вищий рівень в системі етичних і юридичних стандартів – Відповідальний AI (Responsible AI – RAI). Це комплексна стратегічно-регуляторна методологія, яка гарантує, що розробка та впровадження алгоритмів штучного інтелекту є безпечними, прозорими, справедливими, захищають приватність персональних і медичних даних та чітко визначають межі юридичної відповідальності фахівців. На відміну від Пояснювального AI, тобто технології, яка пояснює дії алгоритму (наприклад, «модель рекомендує цю дієту, бо у пацієнта підвищений HbA1c»), Відповідальний AI – це система правил та принципів, яка гарантує, що вся система працює етично: наприклад, персональні дані пацієнта надійно захищені, алгоритм тестувався на різних групах населення, а остаточне рішення та відповідальність лежать на лікаріві.

Ефективне та етичне впровадження RAI вимагає створення прозорих політичних рамок і регуляторних структур. Важливо, щоб різні сектори працювали разом для стандартизації практик використання AI, що може посилити довіру суспільства до цифрових медичних рішень. Концепція Відповідального AI підкреслює, що етика, відповідальність і довіра стосуються не лише технологій, а й людей, які їх розробляють, впроваджують і використовують. Тому політика повинна враховувати питання алгоритмічної справедливості, прозорості та клінічної перевірки інструментів штучного інтелекту. Урядові органи повинні грати важливу роль у фінансуванні та підтримці міждисциплінарних досліджень, аби забезпечити ефективні стандарти і уникнути неконтрольованого або упередженого впровадження технологій (Chudyk, 2024).

Перспективи персоналізованої нутриціології в значній мірі залежать від подальшого розвитку мультимодальних моделей та генеративного AI штучного інтелекту (Brankovic and Hendrie, 2025; Panayotova, 2025; Wang et al., 2025). Генеративний AI, як показав прототип на основі моделі Large Language Model Meta AI 3 (LLaMA3) (Yao et al., 2024), може динамічно створювати й удосконалювати рецепти та плани харчування, адаптуючи їх під особисті потреби користувачів. Застосування методу генерації з доповненням пошуком (Retrieval-Augmented Generation, RAG) дозволяє надавати рекомендації на основі перевірених джерел, наприклад, USDA FoodData Central, що підтримує високі стандарти доказової нутриціології.

У майбутніх дослідженнях основна увага має бути зосереджена на створенні ще більш потужних мультимодальних моделей, які зможуть об'єднувати геномні, дієтичні, метаболічні дані та інформацію про спосіб життя в одному комплексному форматі. Це вдосконалення дозволить AI формувати більш точні, персоналізовані та корисні дієтичні рекомендації.

ВИСНОВКИ. Основні підходи, результати та рекомендації щодо впровадження персоналізованої нутриціології на основі новітніх технологій AI можна сформулювати наступним чином.

У моделі Персоналізованої нутриціології індивідуалізовані підходи до дієти базуються на детальному аналізі генетичних, фенотипічних та поведінкових даних конкретного індивіда, що дозволяє створювати більш ефективні та релевантні рекомендації. Використання штучного інтелекту та Big Data дає змогу професіоналам у сфері харчування аналізувати велику кількість даних у реальному часі, адаптуючи дієтичні рекомендації відповідно до змін у здоров'ї та поведінці пацієнтів.

Аналіз технічних можливостей і регуляторних викликів вказує на необхідність стратегічних дій для успішного, безпечного і справедливого впровадження AI в галузі персоналізованої нутриціології, а саме:

1. Наразі потрібно розробити і впровадити уніфіковані стандарти даних, які забезпечать сумісність між електронними медичними записами, науковими установами та розробниками AI.

Створення відповідної обчислювальної інфраструктури є критично важливим для забезпечення доступу до надійних даних.

2. Регуляторні наглядові органи повинні вимагати проведення клінічних випробувань інструментів AI в реальних умовах, щоб підтвердити їхню ефективність у довгостроковій перспективі.

3. Розробники повинні використовувати методи Пояснювального AI не лише для відповідності вимогам прозорості, але й для підвищення обізнаності користувачів у сфері здоров'я, що в свою чергу допоможе підвищити рівень їхньої довіри до дієтичних рекомендацій.

4. Необхідно встановити чіткі регуляторні рамки для управління етичними питаннями, такими як конфіденційність, упередженість алгоритмів і відповідальність за рішення, прийняті AI, в межах концепції Відповідального AI.

Зміна фокусу від простого прогнозування до плавної інтеграції AI в клінічні процеси є ключем до зменшення відсотку складних хронічних захворювань і трансформації індивідуальної дієтичної підтримки.

Подяки. Немає.

Конфлікт інтересів. Немає.

References

Abbas, Q., Jeong, W., & Lee, S. W. (2025). Explainable AI in Clinical Decision Support Systems: A Meta-Analysis of Methods, Applications, and Usability Challenges. *Healthcare*, 13(17), 2154. <https://doi.org/10.3390/healthcare13172154>

Agrawal, K., Goktas, P., Kumar, N., & Leung, M.-F. (2025). Artificial intelligence in personalized nutrition and food manufacturing: A comprehensive review of methods, applications, and future directions. *Frontiers in Nutrition*, 12, Article 1636980. <https://doi.org/10.3389/fnut.2025.1636980>

Andrade-Calle, R., de la Torre-Díez, I., & de Luis-Román, D. (2025). Predictive Modeling of Weight Loss and Metabolic Health Outcomes: A Retrospective Predictive Modeling Study. *Health Science Reports*, 8(10), e71236. <https://doi.org/10.1002/hsr2.71236>

Brankovic, A., & Hendrie, G. A. (2025). Perspectives, challenges and future of artificial intelligence in personalised nutrition research. *Proceedings of the Nutrition Society*, 84(4), 1–9. <https://doi.org/10.1017/S0029665125100657>

Chotwanvirat, P., Prachansuwan, A., Sridonpai, P., & Kriengsinyos, W. (2024). Advancements in Using AI for Dietary Assessment Based on Food Images: Scoping Review. *Journal of Medical Internet Research*, 26, e51432. <https://doi.org/10.2196/51432>

Chudyk, N. (2024). Ethical and legal aspects of artificial intelligence systems implementation: Balancing technological progress and fundamental human rights in the context of society's digital transformation. *Actual Problems of Law*, 3, 42–47. <https://doi.org/10.35774/app2024.03.042>

Detopoulou, P., Voulgaridou, G., Moschos, P., & Papadopoulou, S. K. (2023). Artificial intelligence, nutrition, and ethical issues: A mini-review. *Clinical Nutrition Open Science*, 50, Article 100570. <https://doi.org/10.1016/j.nutos.2023.07.001>

EuroFIR. (n.d.). Retrieved November 11, 2025, from <https://www.eurofir.org/>

Fernandes, G. J., Choi, A., Schauer, J. M., Pfammatter, A. F., Spring, B. J., Darwiche, A., & Alshurafa, N. I. (2023). An Explainable Artificial Intelligence Software Tool for Weight Management Experts (PRIMO): Mixed Methods Study. *Journal of Medical Internet Research*, 25, e42047. <https://doi.org/10.2196/42047>

Fonseca, D. C., Fernandes, G. da R., & Waitzberg, D. L. (2025). Artificial intelligence and human microbiome: A brief narrative review. *Clinical Nutrition Open Science*, 59, 134–142. <https://doi.org/10.1016/j.nutos.2024.12.009>

FoodData Central. USDA's comprehensive source of food composition data with multiple distinct data types. (n.d.) Retrieved November 11, 2025, from <https://fdc.nal.usda.gov/>

Gaiduchek, D., Kryvoplias-Volodina, L., Kostin, V., Burova, Z., & Zaporozhets, O. (2025). Synthesis of an analytical system prototype using MQTT and AWS in the Industry 4.0 context. *CEUR Workshop Proceedings*, 4146, 487–497. <https://www.scopus.com/pages/publications/105037230065?origin=resultslist>

Gavai, A. K., & van Hillegersberg, J. (2025). AI-driven personalized nutrition: RAG-based digital health solution for obesity and type 2 diabetes. *PLOS Digital Health*, 4(5), e0000758. <https://doi.org/10.1371/journal.pdig.0000758>

Li, Z., Wu, W., & Kang, H. (2024). Machine Learning-Driven Metabolic Syndrome Prediction: An International Cohort Validation Study. *Healthcare*, 12(24), 2527. <https://doi.org/10.3390/healthcare12242527>

Liu, D., Zuo, E., Wang, D., He, L., Dong, L., & Lu, X. (2025). Deep Learning in Food Image Recognition: A Comprehensive Review. *Applied Sciences*, 15(14), 7626. <https://doi.org/10.3390/app15147626>

Mansouri, M., Benabdellah Chaouni, S., Jai Andaloussi, S., & El Aachak, O. (2023). Deep Learning for Food Image Recognition and Nutrition Analysis Towards Chronic Diseases Monitoring: A Systematic Review. *SN Computer Science*, 4(513). <https://doi.org/10.1007/s42979-023-01972-1>

Martynchuk, O., Bal-Prylypko, L., Shvets, O., & Altanova, A. (2025). Potential applications of artificial intelligence in nutrition science. *Human and Nation's Health*, 3(1), 100–125. <https://doi.org/10.31548/humanhealth.1.2025.100>

Panayotova, G. G. (2025). Artificial Intelligence in Nutrition and Dietetics: A Comprehensive Review of Current Research. *Healthcare*, 13(20), 2579. <https://doi.org/10.3390/healthcare13202579>

Rafie, Z., Talab, M. S., Koor, B. E. Z., Garavand, A., Salehnasab, C., & Ghaderzadeh, M. (2025). Leveraging XGBoost and explainable AI for accurate prediction of type 2 diabetes. *BMC Public Health*, 25(1), Article 3688. <https://doi.org/10.1186/s12889-025-24953-w>

Romero-Tapiador, S., Lacruz-Pleguezuelos, B., Tolosana, R., Freixer, G., et al. (2023). AI4FoodDB: A database for personalized e-Health nutrition and lifestyle through wearable devices and artificial intelligence. *Database: The Journal of Biological Databases and Curation*, 2023, baad049. <https://doi.org/10.1093/database/baad049>

SAP. (n.d.). How to implement responsible AI practices. Retrieved November 11, 2025, from <https://www.sap.com/ukraine/products/artificial-intelligence/ai-ethics.html>

Verma, M., Hontecillas, R., Tubau-Juni, N., Abedi, V., & Bassaganya-Riera, J. (2018). Challenges in Personalized Nutrition and Health. *Frontiers in Nutrition*, 5, Article 117. <https://doi.org/10.3389/fnut.2018.00117>

Wang, L., Wang, X., Chen, A., Jin, X., & Che, H. (2020). Prediction of Type 2 Diabetes Risk and Its Effect Evaluation Based on the XGBoost Model. *Healthcare*, 8(3), 247. <https://doi.org/10.3390/healthcare8030247>

Wang, X., Sun, Z., Xue, H., & An, R. (2025). Artificial Intelligence Applications to Personalized Dietary Recommendations: A Systematic Review. *Healthcare*, 13(12), 1417. <https://doi.org/10.3390/healthcare13121417>

Wu, X., Oniani, D., Shao, Z., Arciero, P., Sivarajkumar, S., Hilsman, J., Mohr, A. E., Ibe, S., Moharir, M., Li-Jia Li, Jain, R., Chen, J., & Wang, Y. (2025). A Scoping Review of Artificial Intelligence

for Precision Nutrition. *Advances in Nutrition*, 16(4), 100398.
<https://doi.org/10.1016/j.advnut.2025.100398>

Yang, C. C. (2022). Explainable Artificial Intelligence for Predictive Modeling in Healthcare. *Journal of Healthcare Informatics Research*, 6, 228–239. <https://doi.org/10.1007/s41666-022-00114-1>

Yao, Y., Duan, J., Xu, K., Cai, Y., Sun, Z., & Zhang, Y. (2024). A survey on large language model (LLM) security and privacy: The good, the bad, and the ugly. *High-Confidence Computing*, 4(2), 100211. <https://doi.org/10.1016/j.hcc.2024.100211>

Zale, A., & Mathioudakis, N. (2022). Machine Learning Models for Inpatient Glucose Prediction. *Current Diabetes Reports*, 22, 353–364. <https://doi.org/10.1007/s11892-022-01477-w>