UNIVERSIDADE FEDERAL DE JUIZ DE FORA
CAMPUS GOVERNADOR VALADARES
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS APLICADAS À SAÚDE

Ranyelle Goulart Amorim

Efeitos de Intervenções Nutricionais Guiadas por IA no Peso Corporal: Uma Revisão Sistemática e Meta-análise

Governador Valadares
2026

Ranyelle Goulart Amorim

Efeitos de Intervenções Nutricionais Guiadas por IA no Peso Corporal: Uma Revisão Sistemática e Meta-análise

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Aplicadas à Saúde, da Universidade Federal de Juiz de Fora, Campus Governador Valadares, como requisito parcial à obtenção do título de Mestre em Ciências Aplicadas à Saúde, área de concentração Biociências.

Orientador(a): Prof(a). Dr(a). Leandro de Morais Cardoso

Governador Valadares

2026

Ficha catalográfica elaborada através do programa de geração
automática da Biblioteca Universitária da UFJF,
com os dados fornecidos pelo(a) autor(a)

Amorim, Ranyelle Goulart.
Efeitos de intervenções nutricionais guiadas por IA no peso corporal : Uma revisão sistemática e meta-análise / Ranyelle Goulart Amorim. -- 2026.
69 f.

Orientador: Leandro de Morais Cardoso
Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Campus Avançado de Governador Valadares, Instituto de Ciências da Vida - ICV. Programa de Pós-Graduação em Ciências Aplicadas à Saúde, 2026.

1. Inteligência Artificial. 2. Inteligência Artificial Generativa. 3. Manejo do Peso. 4. Revisão Sistemática. 5. Metanálise. I. Cardoso, Leandro de Morais , orient. II. Título.

Ranyelle Goulart Amorim

Efeitos de Intervenções Nutricionais Guiadas por IA no Peso Corporal: Uma Revisão Sistemática e Meta-análise

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Aplicadas à Saúde da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Ciências Aplicadas à Saúde. Área de concentração: Biociências.

Aprovada em 04 de setembro de 2026.

BANCA EXAMINADORA

Prof. Dr. Leandro de Morais Cardoso - Orientador
Universidade Federal de Juiz de Fora

Prof. Dr. Fábio Alessandro Pieri
Universidade Federal de Juiz de Fora

Prof. Dr. Cristian Ferreira de Souza
Fundação Oswaldo Cruz - FIOCRUZ

Juiz de Fora, 11/08/2026.

Documento assinado eletronicamente por **Leandro de Morais Cardoso**, **Servidor(a)**, em 04/09/2026, às 16:04, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do Decreto nº 10.543, de 13 de novembro de 2020.

Documento assinado eletronicamente por **CRISTIAN FERREIRA DE SOUZA**, **Usuário Externo**, em 04/09/2026, às 17:14, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do Decreto nº 10.543, de 13 de novembro de 2020.

Documento assinado eletronicamente por **Fabio Alessandro Pieri**, **Servidor(a)**, em 22/09/2026, às 16:58, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do Decreto nº 10.543, de 13 de novembro de 2020.

A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **3136340** e o código CRC **947C61DC**.

AGRADECIMENTOS

Agradeço a Deus por me conceder saúde, força, sabedoria e serenidade para percorrer este longo caminho, sustentando-me diante de cada desafio e renovando minha esperança nos momentos em que ela parecia faltar.

À minha mãe, Maria Aparecida, dedico minha eterna gratidão. Você é meu porto seguro, meu maior exemplo de força e a pessoa que nunca deixou que eu desistisse dos meus sonhos, mesmo quando eles pareciam distantes. Obrigado por cada incentivo, por cada palavra de apoio e por acreditar em mim até nos momentos em que eu mesmo duvidei. Esta conquista também é sua.

Ao meu orientador, Prof. Dr. Leandro de Morais Cardoso, expresso meu sincero agradecimento por todo o conhecimento compartilhado, pela confiança depositada em meu trabalho, pela paciência em cada orientação e pelo incentivo constante ao longo desta jornada acadêmica. Sua dedicação foi essencial para o desenvolvimento desta pesquisa e para minha formação como pesquisador e profissional.

Por fim, um agradecimento mais que especial — e, reconheço, um tanto inusitado — às verdadeiras "coautoras" desta dissertação: Taylor Swift e Ana Castela. Entre canções sobre amores, desamores, o universo e refrões que insistiam em permanecer na cabeça, suas músicas embalaram incontáveis horas de leitura, escrita e análise de dados. Em muitos momentos, foram elas que transformaram madrugadas cansativas em horas mais leves, renovando minha disposição quando o cansaço insistia em vencer. Se esta dissertação chegou ao fim, foi também porque, entre uma tabela, um gráfico e uma página em branco, sempre havia uma boa música para lembrar que persistir também pode ter trilha sonora.

“A verdadeira questão não é se as máquinas pensam, mas se os homens o fazem” (SKINNER,1969 p. 288)

RESUMO

A inteligência artificial (IA) evolui rapidamente; no entanto, revisões sistemáticas anteriores avaliaram ferramentas computacionais obsoletas, tornando necessária uma análise atualizada sobre IA generativa moderna e chatbots na nutrição. O objetivo deste estudo foi avaliar a aplicabilidade e a eficácia de modelos de IA no planejamento, monitoramento, adesão alimentar e redução do peso corporal. Seguindo as diretrizes do Cochrane e do PRISMA (registrado no OSF: osf.io/d952s), bases de dados eletrônicas (PubMed, Cochrane Library, IEEE Xplore, Web of Science, Google Scholar, OATD) foram consultadas até abril de 2026 em busca de ensaios intervencionais randomizados e não randomizados que avaliassem ferramentas de IA versus controles em humanos de 19 a 60 anos. Dois revisores independentes realizaram a seleção dos estudos e a avaliação do risco de viés utilizando as ferramentas RoB 2 e ROBINS-I. A metanálise quantitativa de efeitos aleatórios foi executada no software Jamovi. Treze estudos (k=13, n=2.535) preencheram todos os critérios de inclusão. O agrupamento geral demonstrou uma redução de peso estatisticamente significativa a favor das intervenções com IA (μ = -0,35; IC 95%: -0,54 a -0,16; p < 0,001), traduzindo-se em uma redução média adicional de 2,39 kg, embora a heterogeneidade tenha sido alta (I^2 = 77,87%). Estudos não randomizados (k=6) favoreceram consistentemente as intervenções (μ = -0,37; p < 0,001), mantendo a significância após a remoção de *outliers* na análise de sensibilidade (μ = -0,25; p < 0,001; I^2 = 0%). Nos ensaios clínicos randomizados (k=7), o efeito agrupado inicial (μ = -0,35; p = 0,04) alterou-se após a remoção de um *outlier* influente, assumindo um caráter estatístico limítrofe (μ = -0,21; IC 95%: -0,44 a 0,02; p = 0,071; I^2 = 60,89%). O risco de viés variou de baixo a moderado na maioria dos ensaios. As limitações incluem um número modesto de estudos incluídos, variabilidade nas intervenções tecnológicas e curtos períodos de seguimento (mediana: 12 semanas). Os modelos de IA demonstram um potencial clínico promissor para o manejo do peso, mas exigem supervisão profissional dentro de uma estrutura *Human-in-the-Loop* para garantir a segurança nutricional. Não houve financiamento para este projeto.

Palavras-chave: Inteligência Artificial; Chatbots; Inteligência Artificial Generativa; Manejo do Peso; Revisão Sistemática; Metanálise

ABSTRACT

Artificial intelligence (AI) evolves rapidly, yet previous systematic reviews evaluated obsolete computational tools, necessitating an updated analysis of modern generative AI and chatbots in nutrition. The objective of this study was to evaluate the applicability and effectiveness of AI models in dietary planning, monitoring, adherence, and body weight reduction. Following Cochrane and PRISMA guidelines (registered on OSF: osf.io/d952s), electronic databases (PubMed, Cochrane Library, IEEE Xplore, Web of Science, Google Scholar, OATD) were searched up to April 2026 for randomized and non-randomized interventional trials evaluating AI tools versus controls in humans aged 19 to 60 years. Two independent reviewers performed study selection and risk of bias assessment using RoB 2 and ROBINS-I. Quantitative random-effects meta-analysis was executed using Jamovi software. Thirteen studies (k=13, n=2,535) met all inclusion criteria. Overall pooling demonstrated a statistically significant weight reduction favoring AI interventions (μ = -0.35; 95% CI: -0.54 to -0.16; $p < 0.001$), translating to a mean additional reduction of 2.39 kg, though heterogeneity was high (I^2 = 77.87%). Non-randomized studies (k=6) consistently favored interventions (μ = -0.37; $p < 0.001$), retaining significance after sensitivity outlier removal (μ = -0.25; $p < 0.001$; I^2 = 0%). In randomized controlled trials (k=7), the initial pooled effect (μ = -0.35; p = 0.04) shifted upon removing an influential outlier, assuming a borderline statistical character (μ = -0.21; 95% CI: -0.44 to 0.02; p = 0.071; I^2 = 60.89%). Risk of bias ranged from low to moderate across most trials. Limitations include a modest number of included studies, technological intervention variability, and short follow-up durations (median: 12 weeks). AI models demonstrate promising clinical potential for weight management, but require professional oversight within a Human-in-the-Loop framework to ensure nutritional safety. There wasn't any funding for this project.

Keywords: Artificial Intelligence; Chatbots; Generative AI; Weight Management; Systematic Review; Meta-Analysis

SUMÁRIO

1	**INTRODUÇÃO**	**08**
1.2	Usos possíveis de IA na Nutrição	09
1.2.1	Avaliação Dietética	10
1.2.2	Intervenções nutricionais	10
1.2.3	Manejo da obesidade	10
1.2.4	Estimativa alimentar	10
1.2.5	Determinantes em Nutrição	11
1.3	Potenciais de Aplicação de IA em áreas distintas	11
1.4	Aspectos éticos em IA	12
1.5	Avanço rápido das tecnologias de IA	13
2	**ARTIGO CIENTÍFICO**	**19**
3	**CONCLUSÃO**	**51**
4	**REFERÊNCIAS**	**52**
	APÊNDICE A – Estratégia de Busca	**60**
	APÊNDICE B – Figura 1 (PRISMA Flow Diagram)	**64**
	APÊNDICE C – ROBINS-I Results	**65**
	APÊNDICE D – RoB2 e RoB2 Crossover Results	**66**
	APÊNDICE E – GRADE ASSESSMENT	**67**

1 INTRODUÇÃO

Inteligência artificial (IA) é classificada como processo de intelecto demonstrado por máquinas, como forma de mimetizar o pensamento humano. Há três definições de IA disponíveis atualmente, sendo elas: a IA estreita (Artificial Narrow Intelligence – ANI), IA Geral (Artificial General Intelligence – AGI) e uma forma hipotética conhecida por Superinteligência Artificial (Artificial Super Intelligence). Nesse sentido, uma ANI é limitada e depende de comandos humanos para operar, sendo exemplificadas pelos modelos Google Gemini®, Amazon Alexa®, OpenAI ChatGPT® e Microsoft Copilot®. Em contraponto, IAs de AGI ou ASI teriam, respectivamente, a capacidade racional humana ou poder de raciocínio superiores, atuando sem a necessidade de intervenção de um usuário (Delipetrev et al., 2020; Saghiri et al., 2022).

Uma AGI, definida como uma versão igualmente ou levemente superior à capacidade humana, pode resolver diferentes e desafiadoras tarefas sem a necessidade de um prompt explicativo como acontece com a ANI, variando de operações matemáticas a áreas específicas, como medicina, direito, psicologia e outras. O desenvolvimento de uma AGI pode marcar uma nova fase no mundo empresarial envolvido em IA (Harvard, 2023). Já uma ASI é uma visão futurística da IA, mais capaz que um ser humano de forma absoluta e capaz de romper a barreira do que atualmente é definido como algo exclusivamente humano, como emoções, sentimentos, compreensões artísticas e relacionamentos emocionais. O desenvolvimento de tais ferramentas é um objetivo, apesar de não existirem ferramentas próximas desse estágio (Fourtané, 2019).

Para compreender a função de inteligência das ferramentas de IA, é necessário explorar algumas definições, que servem de embasamento ao desenvolvimento das tecnologias. Nesse escopo, há o Machine Learning (ML), processo de treinamento computacional da ferramenta, podendo ser supervisionado ou não supervisionado (Delipetrev et al., 2020). Outra forma de treinamento é o Deep Learning (DL), nos quais sistemas de redes neurais artificiais (Artificial Neural Network – ANN) simulam a estrutura cerebral humana, emulando aprendizado, memória e generalização de ações (Cheng et al., 2024). Esses processos permitem o desenvolvimento de ferramentas generativas de IA (Gen-AI), que são capazes de criar produtos por meio de comandos e processos de ML e DL, aliados ou não a

acesso à rede mundial de computadores (Internet), como o OpenAI ChatGPT® (Mokhtari et al., 2024).

Como ferramentas baseadas nesses princípios, os *chatbots* enquadram-se na categoria de ANI, apresentando múltiplos potenciais e capacidades de aplicação que dependem da formulação de *prompts*. Para a execução de funcionalidades mais específicas, tais *chatbots* podem submeter-se ao processo de *fine-tuning* (ajuste fino) — etapa de treinamento supervisionado conduzida por especialistas com o intuito de mitigar comportamentos tóxicos, resguardar a privacidade do usuário e aprimorar a precisão e a originalidade das respostas geradas a partir dos parâmetros da rede neural (Hua et al., 2024).

O avanço dessas ferramentas também intensificou os debates sobre as implicações éticas de seu uso, sobretudo no que tange à necessidade de salvaguardar a privacidade dos dados coletados, mitigar impactos adversos e promover uma conduta responsável no desenvolvimento de *chatbots*. Entre os preceitos éticos fundamentais destacam-se a equidade, a não maleficência (não causar danos aos usuários), a preservação da autonomia — incluindo o direito de recusar o uso das plataformas — e a proteção à vida. Ademais, a segurança dos usuários pode ser fortalecida por meio da transparência nos protocolos de tratamento de dados, ainda que a propriedade intelectual e o código-fonte permaneçam protegidos por patentes (Heo et al., 2021).

O uso de Tecnologias da Informação e Comunicação (TICs) é uma realidade consolidada, na qual as ferramentas de Inteligência Artificial (IA) desempenham um papel cada vez mais relevante. Em síntese com a Internet das Coisas (*Internet of Things* – IoT), a IA impulsionou uma transformação digital denominada "Indústria 4.0". Nas diferentes áreas da saúde, expandem-se as investigações sobre a viabilidade, eficácia e desenvolvimento de sistemas de IA voltados à assistência, ao diagnóstico, ao acompanhamento de pacientes, à análise de exames laboratoriais e à prospecção de novos fármacos (Kooli et al., 2022; Popov et al., 2022; Schneider et al., 2021).

Nesse cenário, a adoção de *chatbots* — uma das principais aplicações de IA Generativa — tornou-se amplamente disseminada, sendo utilizada pela população geral tanto para a educação nutricional quanto para a adaptação informal de prescrições dietéticas, como na substituição de alimentos. Contudo, por se tratarem de ANIs, essas ferramentas podem fornecer recomendações imprecisas ou

incompletas a depender do *prompt* utilizado, sem que haja confirmação prévia sobre a validade científica de suas respostas. Paralelamente, os *chatbots* vêm sendo descritos como recursos promissores no combate ao sedentardismo, fornecendo orientações direcionadas a modificar comportamentos dos usuários (Stokel-Walker, 2024). Ademais, embora não esteja presente em todas as aplicações de realidade virtual, a IA integra sistemas interativos por voz populares entre crianças e adolescentes, incitando discussões sobre a extensão dessas intervenções e seus impactos no estilo de vida dessa população (Gilson et al., 2023).

Por se tratarem de ANIs, cabe destacar que tanto os *chatbots* quanto outras aplicações de IA Generativa dependem diretamente da clareza e da precisão dos *prompts* fornecidos pelos usuários. Por estarem sujeitas a erros de interpretação contextual e ao fenômeno das alucinações de dados, essas ferramentas apresentam uma dualidade: por um lado, aceleram o processamento de grandes volumes de informação; por outro, introduzem o risco de geração e disseminação de conteúdos imprecisos ou incorretos (Gilson et al., 2023; Kakun; Tytenko, 2023).

Nesse sentido, uma revisão sistemática focada na aplicação de *chatbots* identificou lacunas importantes na interface entre a nutrição e o manejo de doenças crônicas, como o diabetes mellitus, evidenciando que, a despeito dos avanços tecnológicos, há ainda um vasto campo a ser investigado (Linhares, 2023). Em contrapartida, outra revisão sistemática destacou a viabilidade dos sistemas conversacionais de IA no acompanhamento nutricional e no suporte à tomada de decisão clínica, apontando seu potencial promissor como ferramenta complementar ao cuidado em saúde (Queiroz, 2023).

1.2 Usos possíveis de IA na Nutrição

Uma das áreas potencialmente beneficiadas pelas ferramentas de IA é a nutrição, na qual diversos estudos detalham o emprego de tais tecnologias na avaliação dietética, na intervenção no estilo de vida, no manejo da obesidade, na análise da ingestão alimentar, na epidemiologia nutricional e na predição de fatores de risco para a má nutrição. Nesse cenário, a IA atua como um recurso facilitador ao lidar com a elevada complexidade e o grande volume de variáveis inerentes aos processos de avaliação e intervenção, viabilizando o processamento massivo de dados necessário para a personalização do cuidado. Outras aplicações abrangem a segurança alimentar e a otimização da produção de alimentos, destacando-se o

aprimoramento e a adaptação de fórmulas nutricionais (An et al., 2024; UC Davis, 2024; Sosa-Holwerda et al., 2021).

Com o avanço dessas ferramentas, criam-se oportunidades expressivas para o aperfeiçoamento das recomendações dietéticas e para a análise integrada de fatores ambientais e comportamentais. Essa evolução, contudo, é acompanhada de desafios complexos, como a heterogeneidade nos padrões de aplicação, a indefinição quanto às diretrizes clínicas e a limitação na generalização das respostas fornecidas por *chatbots* (Verma et al., 2018).

Cabe destacar que a nutrição passa por um processo contínuo de adaptação às novas tecnologias, exigindo dos profissionais um domínio crescente de ferramentas digitais — como aplicativos, assistentes virtuais e, mais recentemente, *chatbots* —, o que transforma a atuação tradicionalmente centrada no atendimento presencial (Kelly et al., 2021). A incorporação dessas inovações tem o potencial não apenas de redefinir a prática clínica, mas também de ampliar o acesso e a adesão às orientações nutricionais, estabelecendo um novo paradigma no planejamento dietético (Vandeputte et al., 2023).

Diante dessa expansão, tornam-se indispensáveis investigações focadas nos aspectos éticos, na capacitação profissional e no monitoramento da eficácia dos modelos de IA. Afinal, para utilizar essas ferramentas com segurança e eficácia, é fundamental que o profissional saiba interpretar e aplicar criticamente as informações geradas, o que exige competências cada vez mais voltadas à ciência de dados e à ética digital (Kelly et al., 2021; Kirk et al., 2022).

1.2.1 Avaliação Dietética

A avaliação dietética é um procedimento sistemático de coleta e análise de dados sobre o consumo alimentar, empregado primariamente para estimar a ingestão de nutrientes e energia de indivíduos ou populações. Metodologicamente, utilizam-se questionários de frequência alimentar (QFA) para investigar períodos longitudinais, assumindo-se o risco de viés de memória. Outro método tradicional é o diário ou registro alimentar, que demanda alta adesão e cooperação do participante para o preenchimento em tempo real. Adicionalmente, empregam-se entrevistas para o recordatório alimentar de 24 horas (R24h), aplicadas de forma presencial ou remota por profissionais (Eldridge et al., 2019; Klurfeld et al., 2018). O R24h, embora seja de rápida aplicação e baixo custo, também apresenta vulnerabilidade ao viés de

memória, dependência da habilidade do entrevistador e o risco de registrar padrões alimentares atípicos pontuais (Fisberg et al., 2009).

Em relação ao QFA, apesar de sua utilidade em estudos epidemiológicos, sua aplicação exige tempo considerável e depende diretamente da capacidade cognitiva e da memória remota do avaliado. Tais instrumentos são aplicados com o intuito de fundamentar intervenções nutricionais personalizadas, exigindo uma etapa rigorosa de análise e interpretação dos dados à luz de diretrizes e recomendações nutricionais vigentes (Cade et al., 2017; Cambridge University Press, 2024; Klurfeld et al., 2018).

Nesse panorama, ferramentas de ML e Gen-AI têm demonstrado progressos significativos no reconhecimento de imagens, estimativa do tamanho de porções e cálculo automatizado de macronutrientes e densidade energética, otimizando etapas operacionais da avaliação dietética (Chotwanvirat et al., 2024). A incorporação dessas tecnologias pode reduzir o tempo dispendido na coleta de dados e aumentar a adesão do usuário ao processo (Zhu et al., 2024). Cabe ressaltar, contudo, que a IA não substitui a conduta técnica do nutricionista, atuando de forma complementar no gerenciamento de grandes volumes de dados e na identificação de inconsistências para otimizar o tempo do profissional (Cade et al., 2017; Miyazawa et al., 2022).

1.2.2 Intervenções nutricionais

No que tange às intervenções em estilo de vida voltadas à nutrição, existe uma ampla gama de estratégias cujo objetivo principal é o aprimoramento dos padrões alimentares em protocolos de promoção da saúde. Essas ações incluem a prescrição de diretrizes nutricionais, o incentivo à prática de atividade física e a modificação de comportamentos de risco. Tais abordagens são amplamente empregadas no manejo de pacientes acometidos por Doenças Crônicas Não Transmissíveis (DCNTs), com destaque para o diabetes mellitus e a hipertensão arterial sistêmica (Cross et al., 2024; Karvela et al., 2024).

Nesse domínio, a IA atua no auxílio à predição de necessidades nutricionais individuais e no delineamento de perfis fenotípicos e comportamentais mais detalhados a partir da integração de múltiplos dados (Miyazawa et al., 2022). Essas soluções podem ser desenvolvidas com base em modelos preditivos ou generativos, integradas ou não a aplicativos móveis para otimizar a interatividade com os usuários (Albracht-Schulte, 2024; An et al., 2023). Contudo, a despeito do potencial dessas

ferramentas para aumentar a adesão aos tratamentos, persistem gargalos importantes, tais como a necessidade de aprimorar a precisão dos algoritmos e a superação de entraves éticos no gerenciamento e na privacidade dos dados de saúde (Bond et al., 2023; Goh et al., 2022).

1.2.3 Manejo da obesidade

Outra condição de relevância no campo da nutrição é o manejo da obesidade — contemplando sua detecção, prevenção e tratamento —, o qual se associa diretamente às intervenções no estilo de vida. São exemplos dessas abordagens os programas de reeducação alimentar, o gerenciamento de macronutrientes e o monitoramento contínuo de dados antropométricos (Cross et al., 2024). Cabe ressaltar a necessidade de individualizar tais condutas, sobretudo quando direcionadas a populações vulneráveis, como crianças e idosos (Yi et al., 2024).

A aplicação da IA no manejo nutricional de indivíduos com obesidade encontra-se em franca expansão, com o emprego de ferramentas voltadas ao monitoramento e à terapêutica baseadas predominantemente em algoritmos de ML e DL. Tais tecnologias também fundamentam o desenvolvimento de aplicativos móveis direcionados ao controle comportamental associado à condição (Ryan et al., 2022). Outrossim, na etapa de intervenção, esses modelos auxiliam no processamento e na análise de grandes volumes de informações, otimizando a tomada de decisão clínica frente a cenários com múltiplas variáveis (Mendoza et al., 2023; Yi et al., 2024).

1.2.4 Estimativa alimentar

Outro domínio relevante na área da nutrição é a estimativa alimentar (*food estimation*), processo direcionado a determinar a quantidade e o volume de alimentos consumidos por um indivíduo. Tais dados são tradicionalmente obtidos por meio de inquéritos e da interação direta com o usuário, utilizando-se recursos visuais como imagens e atlas fotográficos de porções alimentares para a identificação e quantificação dos itens. No âmbito científico e tecnológico, esse campo abrange desde a avaliação do tamanho de porções na indústria de alimentos até a estimativa automatizada do peso e da composição nutricional de produtos (Baranowski et al., 2003; Cade et al., 2017; Sosa-Holwerda et al., 2021; Wong et al., 2020).

Nesse contexto, ferramentas de IA são empregadas tanto no setor industrial, para o desenvolvimento e formulação de produtos, quanto na prática clínica por nutricionistas, visando a estimativa automatizada da densidade calórica com base

em variações de volume e massa dos alimentos. Adicionalmente, investigações recentes exploram o desenvolvimento de sistemas de IA voltados à quantificação precisa do consumo e do risco nutricional de pacientes em ambiente hospitalar (Ghosh et al., 2024; Lu et al., 2024).

1.2.5 Determinantes em Nutrição

No que se refere à análise de determinantes em nutrição, a epidemiologia constitui o campo responsável por investigar a distribuição e os condicionantes dos agravos à saúde em diferentes grupos populacionais, destacando-se os quadros de má nutrição e deficiências de micronutrientes (Kac et al., 2007; Yi et al., 2024).

Cabe destacar ainda que essa área lida com múltiplos determinantes e elevado número de variáveis, abrangendo interfaces com disciplinas correlatas e condicionantes macroestruturais, tais como a organização do sistema de saúde, os níveis de escolaridade, a insegurança alimentar e o saneamento básico (Ruel et al., 2013).

Nesse contexto, as ferramentas de IA podem ser aplicadas no desenvolvimento de modelos preditivos e na análise de grandes bancos de dados por meio de ML e DL, destacando-se como diferencial a utilização de arquiteturas de redes neurais complexas para o mapeamento de padrões populacionais (Mendoza et al., 2023; Sosa-Holwerda et al., 2021).

1.3 Potenciais de Aplicação de IA em áreas distintas

A aplicação de sistemas com suporte de IA em diferentes áreas da saúde vem se tornando cada vez mais frequente. Seja no diagnóstico, manejo, monitoramento ou na pesquisa, algoritmos são desenvolvidos para preencher lacunas e enfrentar desafios históricos na assistência. Exemplo disso é a enfermagem, área na qual diversas IAs têm sido projetadas com o intuito de monitorar sinais vitais, sinalizar intervenções precoces e otimizar a elaboração de relatórios e evoluções de enfermagem (Alcântara et al., 2024).

Na medicina, algoritmos sofisticados são empregados para evidenciar alterações em exames de imagem, predizer o declínio de funções fisiológicas e fundamentar ações de saúde coletiva. Essas ferramentas atuam como suporte ao raciocínio clínico dos médicos, reduzindo significativamente o tempo dispendido na execução de tarefas rotineiras (Oliveira et al., 2024). Ademais, a IA demonstra grande potencial na personalização do cuidado, adaptando planos terapêuticos e

esquemas de acompanhamento às especificidades de cada paciente (Pereira et al., 2024).

Por outro lado, um ponto de ambiguidade reside no emprego da IA em pesquisas acadêmicas e na redação de artigos científicos. Embora essas ferramentas atuem como um fator determinante para a otimização do tempo em etapas minuciosas — como a gestão de referências e a adequação do texto às normas de diferentes periódicos —, seu uso indiscriminado tem sido associado ao aumento de casos de plágio e à geração de conteúdo sem a devida fundamentação científica (Pereira et al., 2024).

Acompanhando essa dualidade, outros gargalos requerem discussão, como a complexidade em capturar especificidades individuais e a lida com grandes volumes de dados heterogêneos, fatores que podem comprometer a eficiência de arquiteturas de DL. Além disso, as ferramentas atuais ainda carecem de estratégias consolidadas para lidar com a transmissão de dados incompletos ou ruidosos e para se adequarem com precisão à rotina prática dos profissionais (Manne, 2021).

Uma revisão da literatura apontou que os rápidos avanços em ML apresentam relevante ambiguidade no campo da saúde, revelando tanto incrementos expressivos quanto limitações ainda pouco investigadas. O estudo evidenciou diversas áreas beneficiadas por sistemas de IA, assim como domínios que exigem maiores investigações sobre a funcionalidade e a confiabilidade dos dados frente à heterogeneidade social e clínica. Cabe destacar que os aspectos éticos impõem restrições críticas ao desenvolvimento e à aplicação da IA, destacando-se a proteção de dados, a privacidade dos pacientes e as limitações decorrentes da escassez de dados para o treinamento dos modelos (Manne, 2021; Wiens et al., 2017).

1.4 Aspectos éticos em IA

Uma das preocupações centrais no uso da IA na saúde reside na opacidade dos sistemas e no risco de viés algorítmico, decorrentes do desconhecimento sobre o processamento interno dos dados de *prompt* pelas ANNs — uma vez que tais arquiteturas permanecem protegidas por patentes, *trademarks* e segredos industriais por razões comerciais. Somado a isso, o manuseio e a retenção de dados sensíveis pelos operadores trazem questionamentos relevantes quanto à confidencialidade das informações (Almeida Filho et al., 2024).

Outro ponto crítico é a limitação na explicabilidade das decisões tomadas por algoritmos de ML. A complexidade das variáveis torna esses modelos pouco

transparentes até mesmo para seus desenvolvedores, gerando incertezas ainda maiores para profissionais e usuários leigos em tecnologia da informação (Pasquale, 2015).

Sob a ótica da bioética e do princípio da autonomia, a falta de clareza sobre o funcionamento e as margens de erro da IA pode induzir o usuário ao erro ao confiar acriticamente nas respostas do sistema, o que traz riscos à sua saúde e integridade física. Tais dilemas exigem um debate amplo para o aprimoramento dessas ferramentas, assegurando que atuem estritamente como suporte técnico, e não em substituição aos profissionais de saúde capacitados (Rêgo et al., 2024).

No âmbito da produção científica e acadêmica (como em teses, dissertações e artigos), a IA Generativa tem sido empregada para acelerar a estruturação textual e a adequação bibliográfica. Contudo, observa-se o aumento do uso inadequado dessas ferramentas, manifestado na prática de plágio, na superficialidade do texto e na inclusão de citações descontextualizadas. Evidencia-se, assim, que, embora vantajosa, a IA exige um uso rigorosamente ético e metodologicamente fundamentado (Santos-D'Amorim, 2025).

Considerada uma das tecnologias mais disruptivas na atualidade, a IA assume papel determinante nas decisões clínicas e na gestão em saúde. Entretanto, a evolução regulatória e ética não tem acompanhado a velocidade do desenvolvimento tecnológico, deixando sistemas sujeitos a vieses sem a devida fiscalização. Para além dos benefícios, torna-se urgente a implementação de políticas públicas que promovam uma governança de IA justa, transparente e inclusiva (Bartholomeu et al., 2023).

Em 2019, a Organização Mundial da Saúde (OMS) publicou uma diretriz sobre intervenções digitais em saúde, destacando o potencial das tecnologias para integrar serviços essenciais e ampliar o acesso da população. A OMS enfatizou, todavia, que essas ferramentas possuem caráter auxiliar e não substitutivo, devendo atuar como uma extensão da assistência, e não como elemento de exclusão do atendimento presencial (OMS, 2019).

No cenário internacional, o pioneirismo na governança da IA partiu do Parlamento Europeu com a aprovação do *Artificial Intelligence Act*, que categorizou os riscos da tecnologia em níveis que variam de mínimo a inaceitável. A legislação europeia estabeleceu critérios de transparência e rastreabilidade para modelos de

IA Generativa, exigindo a identificação de conteúdo gerados por IA e incentivando o desenvolvimento de ferramentas abertas e inclusivas (União Europeia, 2023).

No contexto brasileiro, o arcabouço normativo pautou-se inicialmente por diretrizes gerais do Marco Civil da Internet. Todavia, os avanços na regulamentação convergem para o Projeto de Lei nº 2338/2023, que visa estabelecer o marco legal da Inteligência Artificial no país, garantindo a transparência no treinamento dos algoritmos, a avaliação sistemática de impacto e a proteção de direitos em setores fundamentais como saúde, educação e pesquisa (Brasil, 2024).

1.5 Avanço rápido das tecnologias de IA

Diante desse cenário e da crescente aplicação da IA nas diversas vertentes nutricionais, uma revisão sistemática publicada em 2021 buscou compreender a eficácia e a aplicabilidade de *chatbots* de IA na modulação de comportamentos relacionados à saúde, tais como atividade física, dieta e perda de peso (Oh et al., 2021). O referido artigo encerrou sua coleta de dados em novembro de 2020 e não obteve resultados categóricos sobre a eficácia dessas ferramentas, recomendando a realização de novos estudos com critérios mais rigorosos para avaliar a implementação e a efetividade dos *chatbots* (Oh et al., 2021).

As ferramentas de IA encontram-se em evolução acelerada e, alinhadas a esse processo, as publicações sobre o tema mantêm uma trajetória ascendente, somando aproximadamente 240.000 estudos publicados em 2022 — dos quais 232.000 em periódicos —, o que representou um aumento de 4,5% nas publicações em relação ao ano anterior (Maslej et al., 2024). Considerando o recorte temporal do estudo de Oh et al. (2021), a literatura selecionada abrangeu tecnologias que se tornaram obsoletas, a exemplo da evolução da família *ChatGPT*. Dados divulgados pela OpenAI indicam que a versão GPT-2, lançada em 2019, possuía 1,5 bilhão de parâmetros — cerca de 116 vezes menos que a versão GPT-3, lançada em 2020 (Chang, 2023; Maslej et al., 2024; Oh et al., 2021; OpenAI, 2019, 2020, 2023). Por sua vez, a versão GPT-4, lançada em março de 2023, possui uma escala estimada em 1 trilhão de parâmetros — aproximadamente seis vezes maior que a versão anterior. Em 2026 houve a liberação ainda da versão GPT-5.1, ainda com parâmetros sem divulgação pela OpenAI o que evidencia a rápida expansão dessas ferramentas e justifica a atualização da revisão de Oh et al. (Chang, 2023; OpenAI, 2023).

Para preencher tais lacunas, esta revisão sistemática e metanálise avaliou a eficácia clínica de intervenções dietéticas e nutricionais guiadas por IA — incluindo

aplicativos móveis, *chatbots* conversacionais, algoritmos preditivos de ML e plataformas de IA generativa — em estudos de intervenção randomizados e não randomizados. Testou-se a hipótese nula de que as ferramentas de IA focadas na modulação dietética não exercem efeito clinicamente relevante sobre o peso corporal em comparação aos grupos controle ou aos valores basais.

2 ARTIGO CIENTÍFICO

Efeitos de Intervenções Nutricionais Guiadas por IA no Peso Corporal: Uma Revisão Sistemática e Meta-análise

Ranyelle Goulart Amorim [1], Adão Mauricio Gonçalves Pereira Junior [2,3] and Leandro de Morais Cardoso[3],*

[1] Univerisdade Federal de Juiz de Fora
[2] Univerisdade Federal de Juiz de Fora
[3] Univerisdade Federal de Juiz de Fora

***** Correspondence: Leandro Cardoso leandro.cardoso@ufjf.br

Abstract (300 words maximum)

Artificial intelligence (AI) evolves rapidly, yet previous systematic reviews evaluated obsolete computational tools, necessitating an updated analysis of modern generative AI and chatbots in nutrition. The objective of this study was to evaluate the applicability and effectiveness of AI models in dietary planning, monitoring, adherence, and body weight reduction. Following Cochrane and PRISMA guidelines (registered on OSF: osf.io/d952s), electronic databases (PubMed, Cochrane Library, IEEE Xplore, Web of Science, Google Scholar, OATD) were searched up to April 2026 for randomized and non-randomized interventional trials evaluating AI tools versus controls in humans aged 19 to 60 years. Two independent reviewers performed study selection and risk of bias assessment using RoB 2 and ROBINS-I. Quantitative random-effects meta-analysis was executed using Jamovi software. Thirteen studies (k=13, n=2,535) met all inclusion criteria. Overall pooling demonstrated a statistically significant weight reduction favoring AI interventions (μ = -0.35; 95% CI: -0.54 to -0.16; $p < 0.001$), translating to a mean additional reduction of 2.39 kg, though heterogeneity was high (I^2 = 77.87%). Non-randomized studies (k=6) consistently favored interventions (μ = -0.37; $p < 0.001$), retaining significance after sensitivity outlier removal (μ = -0.25; $p < 0.001$; I^2 = 0%). In randomized

controlled trials (k=7), the initial pooled effect (μ = -0.35; p = 0.04) shifted upon removing an influential outlier, assuming a borderline statistical character (μ = -0.21; 95% CI: -0.44 to 0.02; p = 0.071; I^2 = 60.89%). Risk of bias ranged from low to moderate across most trials. Limitations include a modest number of included studies, technological intervention variability, and short follow-up durations (median: 12 weeks). AI models demonstrate promising clinical potential for weight management, but require professional oversight within a Human-in-the-Loop framework to ensure nutritional safety. There wasn't any funding for this project.

Background: Artificial intelligence (AI) evolves rapidly through generative and conversational models, yielding a growing volume of scientific literature. However, previous systematic reviews evaluated obsolete computational tools, necessitating an update on the current landscape of AI applied to nutrition.

Objective: The objective of this study was to evaluate, through a systematic review and meta-analysis, the applicability and effectiveness of AI models in the planning, monitoring, and adherence to healthy diets, as well as in their effects on body weight reduction when applied to nutritional interventions.

Methods: A systematic review and meta-analysis was conducted based on the Cochrane handbook and PRISMA guidelines, evaluating the use of chatbots and Generative AI in humans against control groups or baseline data. The quantitative random-effects analysis and risk of bias assessment (RoB 2 and ROBINS-I) were performed by two independent reviewers.

Results: Report the most important findings, including results of statistical analyses.

Conclusions: Eighteen articles were included, totaling 2,578 participants and revealing a global weight reduction (μ= -0.3477; p = 0.0003) with high heterogeneity (I^2 = 77.87%). However, when strictly isolating randomized controlled trials and removing potential outliers, the mean outcome lost conventional statistical significance, assuming a borderline character (μ = -0.2100; p = 0.0734).

Abbreviations: Please define all nonstandard abbreviations and group designations (e.g. CON, HP) used at first mention in the abstract and text. Alphabetically list and define them.

AGI: (Artificial General Intelligence)

AI: (Artificial Intelligence)

ANI: (Artificial Narrow Intelligence)

ANN: (Artificial Neural Network)

ASI: (Artificial Super Intelligence)

DL: (Deep Learning)

DQI-I: (Diet Quality Index International)

GEN-Al: (Generative Artificial Intelligence)

BMI: (Body Mass Index

LLM: (Large Language Model)

ML: (Machine Learning)

ICTs: Information and Communication Technologies

Registry and registry number for systematic reviews or meta-analyses. osf.io/d952s/

Statement of Significance: This study is the first to systematically review and meta-analyze the effectiveness of modern generative and conversational artificial intelligence architectures in dietary planning and weight management. The results demonstrate that while AI models show a promising clinical trend toward weight reduction, their mathematical efficacy remains borderline in randomized controlled trials, highlighting critical nutritional imbalances and the indispensable need for a supervised Human-in-the-loop framework.

Keywords: Artificial Intelligence; Chatbots; Generative AI; Weight Management; Systematic Review; Meta-Analysis

Introduction

Mitigating the global burden of obesity and diet-related cardiometabolic diseases represents a critical public health imperative (1,2), largely constrained by limited long-term patient adherence to conventional lifestyle and dietary interventions (3,4)**.** In response to these

operational barriers, artificial intelligence (AI) modalities—encompassing machine learning (ML), deep learning (DL), reinforcement learning (RL), and generative AI (Gen-AI)—have emerged as scalable mechanisms for continuous behavioral monitoring and personalized nutritional guidance (5-7). Although these digital solutions are deployed across heterogeneous user interfaces, including standalone mobile applications, wearable-integrated platforms, and conversational chatbots (e.g., OpenAI ChatGPT® and Google Gemini®), they operate via a shared algorithmic framework designed to synthesize patient metrics, deliver automated real-time feedback, and dynamically adapt lifestyle recommendations. Within this architecture, RL algorithms play a pivotal role by continually optimizing behavioral intervention policies based on real-time user engagement and feedback loops, thereby personalizing intervention intensity to improve long-term adherence (5).

In clinical nutrition and metabolic health, AI-driven digital health frameworks are increasingly integrated to evaluate multi-factorial datasets for automated dietary modeling, energy intake estimation, behavioral self-regulation, and clinical risk stratification (8, 9). Concurrently, public adoption of automated algorithmic tools for daily dietary adaptation continues to expand (10), while ML and DL predictive models facilitate the analysis of behavioral compliance trajectories and clinical determinants of weight fluctuation (11, 12). Furthermore, predictive neural networks have demonstrated high analytical accuracy (>93%) in forecasting patient adherence within clinical workflows (13) Nevertheless, despite widespread consumer and clinical uptake, empirical validation regarding the therapeutic efficacy, analytical precision, and safety profiles of machine-generated dietary prescriptions remains limited (14). Simultaneously, in silico and qualitative data indicate that unmonitored generative AI models frequently introduce caloric underestimations and macronutrient imbalances (15, 16), demonstrating that user engagement must be evaluated alongside clinical safety and data privacy protocols (14).

Crucially, existing synthesized evidence remains methodologically outdated. A landmark systematic review by Oh, Zhang, Fang and Fukuoka (17) evaluated early evidence on AI conversational agents; however, its literature search cutoff in November 2020 restricted its synthesis to legacy software architectures preceding recent technological advances (17). Over the subsequent period, primary literature has expanded substantially (11, 18), driven by the evolution of Large Language Models (LLMs). Early iterations, such as GPT-2 (parameterized at approximately 1.5 billion parameters) (19), were superseded by GPT-3 (175 billion parameters) (11,19) and multimodal architectures like GPT-4, estimated to exceed 1 trillion parameters (18, 20). Consequently, previous meta-analytic estimates do not reflect contemporary software capabilities, therapeutic potency, or safety profiles (21, 22).

However, translating advanced AI architectures into measurable clinical outcomes presents distinct methodological challenges. Primary digital health studies exhibit substantial technical heterogeneity—ranging from rule-based systems to complex multimodal LLMs—and frequently utilize non-randomized designs susceptible to selection and attrition biases (14). Additionally, usability evaluations report interface fatigue and engagement attrition (up to 8.4%) in real-world settings (23). Most importantly, empirical consensus is lacking regarding whether these diverse AI delivery mechanisms consistently produce statistically and clinically significant reductions in body weight and body mass index (BMI) relative to active controls, standard care, or non-AI baseline values.

To address these gaps, this systematic review and meta-analysis evaluated the clinical efficacy of AI-guided dietary and nutritional interventions —including mobile applications, conversational chatbots, predictive ML algorithms, and generative AI platforms— across randomized and non-randomized interventional studies. We tested the explicit null hypothesis that AI tools focused on dietary modulation exert no clinically relevant effect on body weight relative to control conditions or baseline values.

Methods

Protocol and Registration

This review was conducted according to guidelines outlined in the Cochrane Handbook for Systematic Reviews of Interventions and reported in compliance with the "Preferred Reporting Items for Systematic Reviews and Meta-Analyses" (PRISMA) guidelines (24). The detailed research protocol was previously registered on the Open Science Framework (OSF) platform under the identifier osf.io/d952s.

Eligibility criteria

To evaluate the clinical efficacy of **AI-driven nutritional interventions** in promoting weight loss, a systematic review and meta-analysis was conducted. Study eligibility criteria were strictly defined using the PICOS (Population, Intervention, Comparison, Outcomes, Study Design) framework.

The primary research question guiding study selection was: "Are AI-guided dietary and nutritional interventions, including conversational chatbots, machine learning algorithms, and generative AI frameworks, more effective in achieving body weight and BMI reduction compared to active or inactive control groups or pre-intervention baseline values?" The detailed operational definitions for each component of the PICOS framework are summarized in Table 1.

Table 1. Eligibility criteria based on the PICOS framework for the quantitative meta-analysis

Component	Inclusion Criteria	Exclusion Criteria
Population (P)	**Human individuals (aged 19 to 60 years) enrolled in weight management, obesity treatment, or digital lifestyle modification programs.**	**Non-human models (in vivo or in vitro); populations with severe clinical comorbidities requiring specialized Medical Nutrition**

		Therapy; cohorts outside the 19–60 age range.
Intervention (I)	**Digital AI tools (chatbots, predictive algorithms, generative AI, apps) focused on dietary and nutritional modulation, guidance, or tracking.**	**Static digital tools lacking adaptive AI automation (e.g., manual logging apps, non-automated SMS reminders, or static online PDF guidelines); physical robotic hardware.** **Interventions focusing exclusively on physical exercise, motor activity, or lacking an AI-driven dietary modulation component.**
Comparator (C)	**Active digital controls (non-AI applications or unoptimized platforms), standard care/waitlist inactive controls, or pre-intervention baseline values (in single-arm trials).**	**Studies lacking a defined control group or lacking baseline-to-endpoint comparative numerical data.**
Outcomes (O)	**Quantitative clinical endpoints: complete numerical data (means, standard deviations, or sample sizes) for changes in body weight.**	Studies **that did not report quantitative body weight data—such as those evaluating glycemia only, dietary adherence, purely qualitative outcomes,** or system usability without convertible anthropometric data—were excluded.
Study Design (S)	**Primary quantitative clinical trials: Randomized Controlled Trials (RCTs) and Non-Randomized Interventional Studies (Non-RCTs, pre-post field trials).**	**Secondary literature (systematic reviews, scoping reviews, narrative reviews, editorials, commentaries); purely observational studies without an active interventional component.**

Fonte: Dados da pesquisa (2026)

Primary interventional clinical trials evaluating AI frameworks for weight management that provided complete quantitative data (means, standard deviations, or convertible effect sizes). Strict exclusion criteria were enforced to eliminate: In silico, animal, or laboratory simulation models without direct clinical human application; Software development and computer science architecture papers lacking end-user clinical outcomes; Secondary literature, protocol papers, and descriptive editorials; and Studies lacking standardized, extractable numerical weight loss

metrics.No restrictions were applied regarding publication date. Full-text articles published in English were required for inclusion.

Search Strategies and Selection Process

A systematic search was conducted across electronic databases, including PubMed, Cochrane Library, IEEE Xplore, Web of Science, Google Scholar, as well as Open Access Theses and Dissertations (OATD) retrieving articles published up to April 2026**.** The detailed search strategy for each database, including the specific combination of MeSH terms and keywords, is provided in Supplementary File S1.

All retrieved records were imported into the Rayyan® reference management platform to eliminate duplicates and manage the selection process. Title and abstract screening were conducted independently by two reviewers (R.G.A. and A.M.G.P.J.), followed by an independent full-text evaluation of the remaining studies. Disagreements and conflicts at any stage were resolved by consensus through the mediation of a third reviewer (L.M.C.). Additionally, a manual search of the reference lists of all eligible articles was performed to identify potentially relevant studies not retrieved by the primary electronic search strategy.

Data Extraction and Certainty Assessment

Data extraction was performed by one reviewer (R.G.A.) using a standardized electronic form and independently verified by a second reviewer (A.M.G.P.J.), with discrepancies resolved through consensus (L.M.C.). Extracted variables comprised study characteristics (primary author, publication year, study design, and country), population demographics (sample size per arm, target clinical condition or weight status, and mean age), intervention and technology details (AI delivery interface, underlying AI architecture, intervention description, control conditions, and follow-up duration), and primary clinical outcomes (quantitative metrics for body weight reduction and main endpoint findings).

The methodological quality of Randomized Controlled Trials (RCTs) was evaluated using the Cochrane Risk of Bias 2 (RoB 2) tool (25), which assesses five domains: bias arising from the randomization process, deviations from intended interventions, missing outcome data, measurement of the outcome, and selection of the reported result. The overall risk of bias for RCTs was categorized as "low," "some concerns," or "high." Non-randomized interventional studies were assessed using the Risk of Bias In Non-randomized Studies - of Interventions (ROBINS-I) tool (26), which evaluates seven distinct bias domains across pre-intervention, at-intervention, and post-intervention stages. The overall risk of bias for these studies was classified as "low," "moderate," "serious," or "critical."
The overall certainty of evidence for the primary outcome (body weight reduction) was evaluated using the Grading of Recommendations Assessment, Development and Evaluation (GRADE) approach (27). Evidence was classified into four levels of certainty: high, moderate, low, or very low, considering domain assessments including risk of bias, inconsistency, indirectness, imprecision, and publication bias. The detailed GRADE evidence profile and summary of findings table are provided in Supplementary File S2.

Data Synthesis

Quantitative synthesis was conducted using a random-effects model executed via Jamovi software (version 2.6.24) supported by the MAJOR module (28-30) under the Windows 11® operating system. Continuous weight change outcomes were expressed as Standardized Mean Differences (SMD, Hedges' g) with corresponding 95% Confidence Intervals (95% CI). The between-study variance (τ^2) was estimated using the Restricted Maximum Likelihood (REML) method, and statistical heterogeneity was evaluated via the Cochrane Q test and quantified by the I^2 statistic. Statistical significance was defined as $p < 0.05$.

Subgroup and sensitivity analyses were pre-specified to evaluate model stability and explore sources of heterogeneity. Studies were stratified by experimental design into randomized controlled trials (RCTs) and non-randomized studies. Sensitivity analyses were executed by iteratively re-estimating models after excluding influential outliers identified through Cook's distances and extreme studentized residuals (> ±2)—specifically study A9 (31) in the RCT subgroup and study A13 (32) in the non-randomized subgroup. Finally, publication bias and funnel plot asymmetry were formally tested using the Begg and Mazumdar rank correlation test (Kendall's τ coefficient), Egger's linear regression test, and Rosenthal's Fail-Safe *N* calculation. Duval and Tweedie's non-parametric Trim and Fill method was also applied to estimate and impute theoretical studies omitted due to publication bias. All native statistical files in ".omv" format and analytical decision logs were publicly deposited in the Open Science Framework (OSF) repository to ensure full methodological replication.

Results

Study selection

The electronic database search identified a total of 239 records, distributed as follows: PubMed/MEDLINE (n = 138), Embase (n = 42), Web of Science (n = 28), Scopus (n = 19), and IEEE Xplore (n = 12). No additional records were identified via grey literature or manual screening.

After removing 55 duplicate entries, 184 unique articles underwent title and abstract screening. A total of 142 studies were excluded for failing to meet the eligibility criteria. The remaining 42 articles proceeded to full-text assessment and were all successfully retrieved. Following full-text evaluation, 29 studies were excluded due to incompatible study design, population, lack of extractable weight loss outcomes, or publication type. Ultimately, 13 primary interventional studies met all eligibility criteria and were included in the quantitative meta-analysis (7

randomized controlled trials and 6 non-randomized intervention studies). Details of the study selection process are presented in the PRISMA flow diagram (Figure 1).

Characteristics of Included Studies

A total of 13 primary interventional studies (k = 13) met all inclusion criteria, comprising 7 randomized controlled trials (including 1 crossover design) and 6 non-randomized interventional designs published between 2013 and 2025. Geographically, the literature was predominantly concentrated in North America (n = 5, all in the United States) and Asia (n = 6; Japan [n=2], India [n=1], Taiwan [n=1], South Korea [n=1], Malaysia [n=1]), with additional representation from Europe (n = 2; Spain [n=1], Russia [n=1]). The target populations focused primarily on adults with overweight or obesity (n = 8) and metabolic comorbidities, including type 2 diabetes, prediabetes, or metabolic risk factors (n = 5), with follow-up durations ranging from 8 weeks to 12 months (median: 12 weeks).

Regarding technical integration, interventions were mostly delivered via mobile applications and digital platforms (n = 7), conversational chatbots (n = 4), or wearable integration / automated communication systems (n = 2). Algorithmically, studies relied on Artificial Neural Networks (ANN, n = 5), rule-based expert systems (n = 3), reinforcement learning engines (n = 2), interactive voice/NLP systems (n = 1), and emerging generative AI/LLMs (n = 1). Across all trials, AI-driven solutions consistently drove significant body weight reduction or demonstrated non-inferiority to standard human-led clinical counseling, with higher engagement levels directly correlating with superior weight loss outcomes (Table 2).

Table 2 - Characteristics of Studies Included in the Meta-Analysis (n = 13)

Study	Design	Country	[Population M-F] / Health Condition	Sample (N)(Int / Cont)	Follow-up Time	Mean Age (Intervention / Control)	AI Tool and Architecture	Main Intervention vs. Control / Baseline	Primary Outcome
Nakata et al. (2022)	Non RCT	Japan	[74%-26%] Overweight / Obesity	71/69	12 wks	42 / 44	Mobile Application (ANN)	Mobile App with AI vs. No intervention	Greater body weight reduction in the AI intervention group.
Okaniwa & Yoshida (2022)	Non RCT	Japan	[32%-68%] Overweight / Obesity	21/24	8 wks	36 / 40	Chatbot (Rule-Based AI)	AI Messages vs. AI Messages + Human Video vs. Control	Lower dropout rate and greater body fat reduction in the combined intervention.
Graham et al. (2022)	Interventional Observational	USA	[34%-66%] Pre-diabetes / Obesity	191/223	52 wks	55 / 51	Chatbot / App (Lark DPP / Rule-Based AI)	AI prevention program in CDC qualifiers vs. Non-qualifiers	Greater weight loss maintenance in participants who met engagement goals.
Shamanna et al. (2020)	Pre-Post Retrospective	India	[70%-30%] Type 2 Diabetes / Obesity	64/64	12 wks	52 / 52	Digital Platform (ANN / TPN Nutrition)	AI/CGM-guided precision nutrition vs. Standard professional care	Significant reduction in body weight, HbA1c, and reduction/elimination of antidiabetics.

Rahmanti et al. (2022)	**Pre-Post (Single Arm)**	**Taiwan**	**[0%-100%] Overweight / Young Adults**	**16/16**	**8 wks**	**30 / 30**	**Chatbot / App (SlimMe / Empathic AI)**	**Chatbot with artificial empathy via messaging app vs. Conventional follow-up**	**High acceptance; aided in calorie monitoring, engagement, and behavioral change.**
Khokhar et al. (2024)	**Pre-Post Field Trial**	**USA**	**[42%-58%] Metabolic Syndrome / Obesity**	**391/391**	**16 wks**	**47 / 47**	**Digital Platform (Expert System)**	**AI-driven digital lifestyle platform (Pre vs. Post Evaluation)**	**Body weight loss in all participants, with generalized achievement of reduction goals.**
Lee et al. (2023)	**RCT**	**South Korea**	**[66%-34%] Type 2 Diabetes / Obesity**	**91/92**	**24 wks**	**56 / 56**	**Digital Platform (ANN)**	**Isolated AI platform vs. Platform + Medical Feedback/CGM vs. Routine care**	**Greater reduction in HbA1c and greater weight loss in groups using the digital platform.**
Mathioudakis et al. (2025)	**RCT**	**USA**	**[29%-71%] Pre-diabetes / Elderly**	**183/185**	**52 wks**	**60 / 57**	**Digital Platform (Reinforcement Learning)**	**100% automated AI prevention program vs. Follow-up by human coaches**	**Automated AI demonstrated non-inferiority to human follow-up in weight loss.**
Forman et al. (2019)	**RCT**	**USA**	**[33%-67%] Overweight / Obesity**	**20/12**	**52 wks**	**54 / 54**	**Mobile System (Reinforcement Learning)**	**AI-optimized remote coaching vs. Non-optimized remote coaching**	**Equivalent weight loss between groups, with expressive reduction in human coaching time and cost.**

Lacruz-Pleguezuelos et al. (2025)	**Crossover RCT**	**Spain**	**[31%-69%] Metabolic Risk / Obesity**	**93/93**	**12 wks**	**50 / 50**	**Wearable Devices / App (ANN)**	**Automated monitoring with wearables + AI vs. Manual logging (Questionnaires)**	**Significant reduction in weight, visceral fat, and improvement in lipid and inflammatory profile.**
Pokushalov et al. (2025)	**RCT**	**Russia**	**[32%-78%] Obesity / Overweight**	**30/30**	**12 wks**	**45 / 46**	**Digital Tool (ANN)**	**AI-guided supplement prescription vs. Doctor-guided prescription**	**Greater reduction in body weight, improved body composition, and appetite suppression in the AI group.**
Mohd Dan et al. (2025)	**RCT**	**Malaysia**	**[NR] Overweight / Obesity**	**81/79**	**8 wks**	**NR / NR**	**Chatbot (Generative AI / LLM / ChatGPT)**	**Personalized prompt generator (NExGEN) vs. Standard manual prompts in ChatGPT**	**Superior weight reduction and improved body composition in the personalized AI group.**
Wright et al. (2013)	**RCT**	**USA**	**[4%-96%] Overweight / Obesity**	**21/22**	**16 wks**	**40 / 40**	**Chatbot / Telephone (IVR / TTS / HEAT System)**	**Automated conversational system via phone vs. Waitlist**	**Viable system; greater engagement resulted in reduction of weight, BMI, and z-score in children.**

Legend and Abbreviations: ANN: Artificial Neural Networks; CDC: U.S. Centers for Disease Control and Prevention; CGM: Continuous Glucose Monitoring; Cont: Control Group; RCT: Randomized Controlled Trial; NRCT: Non-Randomized Clinical Trial; USA: United States of America; AI: Artificial Intelligence; Int: Intervention Group; IVR: Interactive Voice Response; LLM: Large Language Models; NR: Not Reported; N: Sample Size; seg.: Follow-up; wks: weeks; TTS: Text-To-Speech.

Fonte: Dados da pesquisa (2026)

Meta-Analysis

Pooling all 13 included studies (k = 13) within a random-effects framework demonstrated that AI-driven interventions yielded a statistically significant reduction in body weight (μ = -0.35; 95% CI: -0.54 to -0.16; z = -3.58; $p < 0.001$), with 92% of individual effect estimates favoring the intervention. Beyond the standardized metric, converting this effect size using the weighted mean baseline standard deviation of the study population (SD = 6.88 kg), following standard Cochrane Collaboration re-expression guidelines, translates to a mean additional body weight reduction of 2.39 kg in the AI intervention group compared to controls.

However, substantial between-study heterogeneity was observed (Q = 64.76, $p < 0.001$; τ^2 = 0.08; I^2 = 77.87%), yielding a 95% prediction interval ranging from -0.94 to 0.24. Formal testing for publication bias and small-study effects revealed no statistically significant funnel plot asymmetry via Egger's linear regression test (p = 0.960) or Begg and Mazumdar's rank correlation test (p = 0.770). Nevertheless, application of Duval and Tweedie's non-parametric trim-and-fill method imputed three theoretical studies to adjust for minor conservative asymmetry, resulting in a slightly attenuated yet consistent adjusted overall effect size of μ = -0.29 (95% CI: -0.48 to -0.09). Table 3 provides a comprehensive summary of the global meta-analytic metrics, heterogeneity parameters, and publication bias diagnostics.

Table 3. Global Random-Effects Model, Heterogeneity Metrics, and Publication Bias Diagnostics.

Category	***Parameter / Statistical Test***	***Value / Estimate***	***95% Confidence Interval***	***p-value***
Primary Effect	*Overall Standardized Effect (μ)*	*-0.35*	*[-0.54; -0.16]*	*< 0.01*
Heterogeneity	*Between-Study Variance (τ²)*	*0.082 (SE = 0.049)*	—	—

	Consistency Metric (I^2)	*77.87%*	*Cochrane Q(12) = 64.76*	*< 0.01*
	95% Prediction Interval	*[-0.94; 0.24]*	—	—
Publication Bias	*Rosenthal Fail-Safe N*	*278.00*	—	*< 0.01*
	Begg & Mazumdar Rank Correlation (τ)	*-0.08*	—	*0.77*
	Egger's Linear Regression (t)	*0.06*	—	*0.96*
	Trim & Fill Imputed Studies	*3 studies*	*Adjusted Effect: -0.29*	—

Fonte: Dados da pesquisa (2026)

Stratifying the primary synthesis by study design revealed distinct methodological patterns in heterogeneity and treatment effect stability across randomized and non-randomized evidence (Table 2). Initial pooling of randomized controlled trials (k = 7) demonstrated a statistically significant weight reduction favoring AI interventions (μ = -0.35; 95% CI: -0.68 to -0.02; p = 0.040), alongside substantial inter-study heterogeneity (I^2 = 82.42%). However, sensitivity analysis via residual diagnostics identified Study A9 (31) as an influential outlier. Following its removal (k = 6), the point estimate shifted to μ = -0.21 (95% CI: -0.44 to 0.02), causing the treatment effect to lose statistical significance (z = -1.79; p = 0.071). Although 83% of the remaining study arms continued to favor the intervention, residual heterogeneity remained moderate (I^2 = 60.89%; $Q(5)$ = 13.09, p = 0.022), yielding a 95% prediction interval of -0.69 to 0.27.

In contrast to the randomized subgroup, non-randomized studies (k = 6) consistently favored the intervention across all arms (100%), yielding a significant pooled effect (μ = -0.37; 95% CI: -0.60 to -0.14; $p < 0.001$) with moderate heterogeneity (I^2 = 71.83%). Influence diagnostics using Cook's distance identified Study A13 (32) as a primary source of variance. Its removal

(k = 5) reduced inter-study heterogeneity to zero (I^2 = 0.00%; $Q(4)$ = 2.61, p = 0.625), while confirming a statistically significant effect size (μ = -0.25; 95% CI: -0.39 to -0.10; $p < 0.001$). Neither subgroup model showed evidence of funnel plot asymmetry on rank correlation or regression testing ($p > 0.050$). Table 4 details the comparative subgroup metrics and sensitivity adjustments across all experimental frameworks.

Table 4. Subgroup Analysis by Study Design and Sensitivity Testing (Outlier Removal).

Subgroup / Model	*Studies (k)*	*Average Effect (μ)*	*95% CI*	*p-value*	*Heterogeneity (I^2)*	*Heterogeneity Test (Q)*
1. Global Model (Random-Effects)	***13***	***-0.35***	***[-0.54; -0.16]***	***< 0.01***	***77.87%***	***Q(12) = 64.76; p < 0.01***
2. RCT Subgroup						
Full Subgroup Model	*7*	*-0.35*	*[-0.69; -0.02]*	*0.04*	*82.42%*	*Q(6) = 29.15; p < 0.01*
Sensitivity (Excluding Study A9)	*6*	*-0.21*	*[-0.440; 0.02]*	*0.07 (NS)*	*60.89%*	*Q(5) = 13.09; p = 0.02*
3. Non-Randomized Subgroup						
Full Subgroup Model	*6*	*-0.37*	*[-0.60; -0.14]*	*<0.01*	*71.83%*	*Q(5) = 17.75; p <0.01*
Sensitivity (Excluding Study A13)	*5*	*-0.25*	*[-0.39; -0.10]*	*< 0.01*	*0.00%*	*Q(4) = 2.61; p = 0.63*

(NS = Not Statistically Significant at α = 0.05 level).

Fonte: Dados da pesquisa (2026)

Risk of bias and Certainty of Evidence

Methodological quality and risk of bias were evaluated across all 13 included studies using framework-specific tools (Figure 2, 3 and Supplementary File S2).

Among non-randomized designs evaluated via ROBINS-I (n = 6), overall risk of bias was judged as low in two studies (34, 35) and moderate in three studies (36 - 38). A single study (32) presented a critical overall risk of bias, driven by severe deviations from intended interventions in Domain 4 (Figure 2).

For randomized controlled trials assessed using the RoB 2 tool (n = 7, including 1 crossover design assessed with the appropriate tool), two studies [A1 and A9] (38, 31) demonstrated an overall low risk of bias. Four trials [A2, A4, A7, and A8] (39-42) were classified as having some concerns, predominantly due to randomization processes (Domain 1) or carryover effects in crossover design. Only one trial [Study A12] (43) exhibited a high overall risk of bias, resulting from critical deviations from intended interventions (Domain 2) and missing outcome data (Domain 3; Figure 3). All randomized trials showed low risk of bias regarding measurement of outcomes and selective reporting domains.

According to the GRADE assessment (Supplementary File S2), the certainty of evidence for body weight reduction was rated as low for randomized controlled trials (k=7) and very low for non-randomized studies (k=6). For randomized trials, certainty was downgraded due to risk of bias concerns across primary domains and substantial statistical heterogeneity (I^2 = 82.42%). Similarly, non-randomized studies were downgraded for moderate-to-high risk of bias under ROBINS-I assessments and high between-study heterogeneity (I^2 = 71.8%). Despite these ratings, body weight reduction was categorized as a critical outcome across both study designs.

Discussion

Statistical analysis of the pooled literature revealed a complex landscape marked by both promising clinical trends and methodological nuances regarding the efficacy of AI-driven nutritional interventions for body weight reduction. Overall, initial pooling across all included designs demonstrated a statistically significant treatment effect favoring AI interventions (μ = -0.35; 95% CI: -0.54 to -0.16; $p < 0.001$). However, this summary estimate was accompanied by substantial between-study heterogeneity (I^2 = 77.87%), as underscored by a wide 95% prediction interval (-0.94 to 0.24) crossing the null threshold, which indicates that the intervention effect may vary or even invert depending on specific clinical settings (44).

This substantial heterogeneity can be attributed to marked clinical and technological variability across the primary literature, including heterogeneous AI architectures (ranging from rule-based chatbots and artificial neural networks to generative LLMs) and follow-up durations (spanning 8 weeks to 12 months) (45). Furthermore, secondary outcome reporting introduced variance, as body weight reduction was measured as an exploratory secondary endpoint rather than a primary target in several included trials (46) This heterogeneity persisted even within stratified analyses, where randomized controlled trials (RCTs) initially exhibited high variance ($I^2 = 82.42\%$).

A critical finding of this synthesis emerged during subgroup isolation and sensitivity testing. When analyzing RCTs alone ($k = 7$; $\mu = -0.35$; $p = 0.040$), the removal of an influential outlier—Study A9 (31)—moderated overall heterogeneity ($I^2 = 60.89\%$) but attenuated the summary effect ($\mu = -0.21$; 95% CI: -0.44 to 0.02), causing the primary estimate to reach borderline statistical significance ($p = 0.071$). This sensitivity shift illustrates how pooled effects in digital health meta-analyses can be heavily leveraged by individual trials conducted under idealized conditions (47).

Study A9 (31) exemplifies the dichotomy between efficacy in highly controlled experimental environments and real-world pragmatic effectiveness. Featuring an open-label design with intensive 6-month continuous glucose and feedback monitoring, Study A9 generated substantial participant engagement and performance bias (*Hawthorne effect*) (48) While methodologically robust within its trial boundary, such hyper-monitored conditions rarely translate to routine clinical practice (49). Conversely, the non-randomized subgroup demonstrated a robust and highly stable treatment effect ($\mu = -0.37$; $p < 0.001$), which retained statistical significance even after excluding its primary outlier, Study A13 (32), while completely eliminating inter-study variance ($\mu = -0.25$; $p < 0.001$; $I^2 = 0.00\%$). Although non-randomized evidence occupies a lower rung in the traditional hierarchy of evidence and remains susceptible to selection and

confounding biases (50) these designs often capture pragmatic behavioral interactions closer to real-world clinical delivery (51).

Methodological quality assessments further contextualize these quantitative findings. While most RCTs demonstrated low risk of bias or minor concerns under RoB 2.0 (with Study A9 (31) exhibiting an overall low risk of bias, confirming that its outlier status was driven by intervention intensity rather than methodological flaws), non-randomized evidence displayed greater vulnerability. Notably, Study A13 (32) was judged as critical risk under ROBINS-I due to deviations from intended protocols. The fact that the non-randomized effect remained robust ($\mu = -0.25$) even after excluding Study A13 (32) highlights that the observed efficacy trend is not merely an artifact of methodologically compromised literature (24).

These divergent findings demand nuanced interpretation at the intersection of statistical significance and clinical relevance. Rather than viewing the shift to a borderline *p*-value ($p = 0.071$) in the conservative RCT model as a total invalidation of AI efficacy, it reflects a reduction in statistical power inherent to small subgroup sample sizes ($k = 6$). Rigid adherence to binary significance thresholds ($p < 0.05$) has been broadly criticized in contemporary biostatistics (52-54), as dichotomous interpretations risk discarding clinically meaningful effect trends (mean re-expressed additional weight loss of 2.39 kg). Clinical research must evaluate treatment estimates holistically, balancing mathematical *p*-values against practical utility (55).

Beyond quantitative weight metrics, qualitative and *in silico* evidence integrated into this synthesis provides vital insights regarding nutritional safety, user engagement, and clinical execution. While quantitative models confirmed a significant average weight reduction, simulated meal-planning studies evaluating unguided generative AI models and LLMs revealed critical vulnerabilities, including systematic caloric underestimations, lipid imbalances, and

micronutrient deficits (15, 16). This indicates that weight reduction achieved through unmonitored AI tools may not guarantee metabolic or nutritional health (56)

Furthermore, implementation evidence underscores key behavioral mechanisms and adoption barriers. Mobile chatbots, gamified computer vision frameworks, and continuous tracking systems effectively enhanced impulse self-regulation, reduced opportunistic snacking, and improved cardiorespiratory markers (23, 16). However, real-world usability trials highlighted non-negligible user attrition (up to 8.4%), primarily driven by interface overload and fatigue, particularly among older demographics (23). In contrast, predictive artificial neural network models analyzing clinical records achieved high accuracy (>93%) in forecasting dietary adherence (13)**.** Together, these qualitative insights demonstrate that AI platforms perform best not as autonomous prescriptive surrogates, but as predictive, behavioral-support tools operating under human professional guidance (57).

From a translational perspective, AI tools should not be viewed as autonomous replacements for professional care (58)**.** These qualitative nuances align with joint recommendations from the Academy of Nutrition and Dietetics and the American Society for Nutrition (59), which advocate for patient safety and professional competency in exploring AI tools ethically. Cross-sectional surveys among dietitians (60; 61) echo this balance: while professional skepticism persists regarding unguided consumer use, practitioners report optimism regarding AI's capacity to streamline administrative workflows, optimize data tracking, and reduce workload burdens.

Furthermore, integrating AI into academic curricula remains a critical paradigm. As highlighted in recent systematic review (62), transition from punitive institutional postures toward instructive AI literacy will empower future healthcare professionals to deploy these technologies effectively and ethically.

Limitations

Limitations must be acknowledged when interpreting these results. First, the total number of eligible studies remain modest (k = 13), with limited sample sizes across individual trials, constraining subgroup power. Second, substantial heterogeneity in AI intervention modalities—ranging from passive rule-based text systems to adaptive neural networks—precludes establishing a single 'active ingredient' or optimal algorithmic architecture. Third, follow-up durations were predominantly short to medium term (median: 12 weeks), limiting inferences regarding long-term weight maintenance beyond one year. Finally, language restrictions and indexation limits across primary electronic databases may introduce subtle selection biases. Despite these constraints, this review adhered to a pre-registered protocol (OSF), PRISMA reporting guidelines, and Cochrane methodological standards to ensure maximal rigor, transparency, and reproducibility.

Conclusions

The findings of this systematic review and meta-analysis indicate that the integration of artificial intelligence within nutritional care and body weight management exerts promising clinical potential. Although the primary outcome demonstrated borderline statistical significance in conservative models, the observed effect size and its overall clinical relevance suggest that statistical thresholds alone are insufficient to dismiss the therapeutic efficacy of these interventions. Consequently, these findings must be interpreted with caution, emphasizing the need for future trials with adequate statistical power and larger sample sizes.

Furthermore, our synthesis corroborates contemporary literature by underscoring that AI tools should not function as autonomous surrogates for nutritional prescription or behavioral counseling. Rather, their primary clinical utility lies in optimizing systematized workflows within a Human-in-the-Loop framework, wherein professional oversight remains essential to

preserve critical appraisal, clinical judgment, ethical responsibility, and individualized care. Therefore, AI must be conceptualized as a sophisticated decision-support tool rather than a replacement for human clinical practice.

Finally, the long-term consolidation of AI in nutrition depends on the execution of prospective studies with extended follow-up durations, representative populations, and standardized methodologies. Concurrently, integrating AI literacy into healthcare curricula is imperative to empower future practitioners to deploy these technologies safely, ethically, and critically, thereby mitigating automation bias in routine clinical decision-making.

Acknowledgements

RGA and LMC designed research; RGA and AMGPJ conducted research; RGA and AMGPJ analyzed data; RGA and LMC wrote the paper. LMC had primary responsibility for final content. All authors read and approved the final manuscript.

Data Availability:

1) Data described in the manuscript, code book, and analytic code will be made publicly and freely available without restriction at osf.io/d952s/

Funding: NONE

Author Disclosures: The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Declaration of Generative AI and AI-assisted technologies in the writing process: During the preparation of this work the author(s) used Google Gemini in order to correct English grammar. After using this tool/service, the author(s) reviewed and edited the content as needed and take(s) full responsibility for the content of the publication.

References

1. GBD 2021 Adult BMI Collaborators. Global, regional, and national prevalence of adult overweight and obesity, 1990–2021, with forecasts to 2050: a forecasting study for the Global Burden of Disease Study 2021. *Lancet*. 2025; 405(10481):813–838. doi:10.1016/S0140-6736(25)00355-1 [Cited 22 July, 2026].

2.World Health Organization. Obesity and overweight. Available from: https://www.who.int/news-room/fact-sheets/detail/obesity-and-overweight [Cited 22 July, 2026].

3. Wang D, Benito PJ, Rubio-Arias JÁ, Ramos-Campo DJ, Rojo-Tirado MA. Exploring factors of adherence to weight loss interventions in population with overweight/obesity: an umbrella review. *Obesity Rev*. 2024; 25(9):e13783. doi:10.1111/obr.13783. [Cited 22 July, 2026].

4. Slim M, van Breukelen G, van Dongen MC, Kremers SP, Jansen MW, Kremers S. Barriers and facilitators to diet, physical activity and lifestyle behavior intervention adherence: a qualitative systematic review of the literature. *Int J Behav Nutr Phys Act*. 2023; 20:66. doi:10.1186/s12966-023-01464-y [Cited 22 July, 2026].

5. Mokhtari M, Jameel S, Kheir N. Reinforcement learning for generative AI: state of the art, opportunities and open research challenges. *J Artif Intell Res*. 2024; 70:1–25. Available from: https://www.jair.org/index.php/jair/article/view/12692 [Cited 20 July, 2026].

6. Delipetrev B, Tsinaraki C, Kostić U. Historical Evolution of Artificial Intelligence. Publications Office of the European Union: Luxembourg, Luxembourg, 2020. Available from: https://op.europa.eu/en/publication-detail/-/publication/6264ac29-2d3a-11eb-b27b-01aa75ed71a1/language-en [Cited 18 July, 2026].

7. Cheng Y, Li Y, Liu X. A primer on generative artificial intelligence. *Appl Sci*. 2024. Available from: https://www.mdpi.com/2076-3417/12/8/4054 [Cited 19 July, 2026].

8. Sosa-Holwerda A, Park OH, Albracht-Schulte K, Niraula S, Thompson L, Oldewage-Theron W. The role of artificial intelligence in nutrition research: a scoping review. *Nutrients*. 2021; 13(8):2356. Available from: https://www.mdpi.com/2072-6643/13/8/2356 [Cited 21 July, 2026].

9. An R, Wang X. Artificial intelligence applications to public health nutrition. *Nutrients*. 2023; 15(19):4285. Available from: https://doi.org/10.3390/nu15194285 [Cited 22 July, 2026].

10. Stokel-Walker C. How patients are using AI. *BMJ*. 2024; 387:q2393. Available from: https://doi.org/10.1136/bmj.q2393 [Cited 17 July, 2026].

11. Yi X, Wang L, Xu Y, Zhang Y, Liu J, Zhao C, et al. A review of the application of deep learning in obesity: from early prediction aid to advanced management assistance. *Diabetes Metab Syndr*. 2024; 18(4):103000. Available from: https://doi.org/10.1016/j.dsx.2024.103000 [Cited 23 July, 2026].

12. Mendoza M, Silva R, Oliveira L, Santos A, Ferreira C, Costa M, et al. Artificial intelligence-based approaches for obesity management. *Int J Obes*. 2023; 46:292–302. Available from: https://www.nature.com/articles/s41366-023-01387-9 [Cited 24 July, 2026].

13. Mousavi H, Karandish M, Jamshidnezhad A, Hadianfard AM. Determining the effective factors in predicting diet adherence using an intelligent model. *Sci Rep*. 2022; 12:12340. Available from: https://doi.org/10.1038/s41598-022-16680-8 [Cited 25 July, 2026].

14. Heo JH. Ethical review in the age of artificial intelligence. *AI Ethics J*. 2021;2(2):1–19 Available from: https://www.aiethicsjournal.org/10-47289-aiej20210716-4 [Cited 26 July, 2026].

15. Bilen AB, Kalkan GE, Önal HY. Artificial intelligence diet plans underestimate nutrient intake compared to dietitians in adolescents. *Front Nutr*. 2026; 13:1765598. Available from: https://doi.org/10.3389/fnut.2026.1765598 [Cited 27 July, 2026].

16. Kaya Kaçar H, Kaçar ÖF, Avery A. Diet quality and caloric accuracy in AI-generated diet plans: a comparative study across chatbots. *Nutrients*. 2025; 17(2):296. Available from: https://doi.org/10.3390/nu17020206 [Cited 27 July, 2026].

17. Oh YJ, Zhang J, Fang ML, Fukuoka Y. A systematic review of artificial intelligence chatbots for promoting physical activity, healthy diet, and weight loss. *Int J Behav Nutr Phys Act*. 2021; 18(1):160. Available from: https://doi.org/10.1186/s12966-021-01224-6 [Cited 27 July, 2026].

18. OpenAI. GPT-4 technical report. *arXiv preprint arXiv:2303.08774*. 2023. Available from: https://arxiv.org/abs/2303.08774 [Cited 27 July, 2026].

19. Radford A, Wu J, Child R, Luan D, Amodei D, Sutskever I. Language models are unsupervised multitask learners. *OpenAI Blog*. 2019; 1(8):9. Available from: https://openai.com/research/language-unsupervised [Cited 27 July, 2026].

20. Maslej N, Fattorini L, Perrault R, Parli V, Reuel A, Brynjolfsson E, et al. The AI index 2024 annual report. *Stanford University, Institute for Human-Centered AI*. 2024. Available from: https://aiindex.stanford.edu/wp-content/uploads/2024/05/HAI_AI-Index-Report-2024.pdf [Cited 27 July, 2026].

21. Lopez-Alcalde J, et al. Methodological challenges in systematic reviews of mHealth interventions: survey and consensus-based recommendations. *Int J Med Inform*. 2024; 184:105345. Available from: https://doi.org/10.1016/j.ijmedinf.2024.105345 [Cited 27 July, 2026].

22. Gityamwi N, et al. Methodological approaches and author-reported limitations in evaluation studies of digital health technologies (DHT): a scoping review of DHT interventions for cancer, diabetes mellitus, and cardiovascular diseases. *PLOS Digit Health*. 2025; 4(4):e0000806. Available from: https://doi.org/10.1371/journal.pdig.0000806 [Cited 27 July, 2026].

23. Chew HSJ, Chew NWS, Loong SSE, Lim SL, Tam WSW, Chin YH, et al. Effectiveness of an artificial intelligence-assisted app for improving eating behaviors: mixed methods evaluation. *J Med Internet Res*. 2023; 25:e45600. Available from: https://www.jmir.org/2023/1/e45600 [Cited 27 July, 2026].

24. Higgins JPT, Thomas J, Chandler J, Cumpston M, Li T, Page MJ, et al., editors. Cochrane Handbook for Systematic Reviews of Interventions version 6.5 (updated August 2024) [Internet]. Cochrane; 2024. Available from: www.cochrane.org/handbook [Cited 27 July, 2026]

25. Sterne JAC, Savović J, Page MJ, Elbers RG, Blencowe NS, Boutron I, et al. RoB 2: a revised tool for assessing risk of bias in randomised trials. *BMJ*. 2019; 366:l4898. Available from: https://www.bmj.com/content/366/bmj.l4898 [Cited 27 July, 2026].

26. Sterne JA, Hernán MA, Reeves BC, Savović J, Berkman ND, Viswanathan M, et al. ROBINS-I: a tool for assessing risk of bias in non-randomised studies of interventions. *BMJ*. 2016; 355:i4919. Available from: https://www.bmj.com/content/355/bmj.i4919 [Cited 27 July, 2026].

27. Guyatt GH, Oxman AD, Vist GE, Kunz R, Falck-Ytter Y, Alonso-Coello P, et al. GRADE: an emerging consensus on rating quality of evidence and strength of recommendations. *BMJ*. 2008; 336(7650):924-926. Available from: https://www.bmj.com/content/336/7650/924 [Cited 27 July, 2026].

28. The jamovi project. jamovi (Version 2.6) [Computer Software]. 2024. Available from: https://www.jamovi.org [Cited 27 July, 2026].

29.R Core Team. R: A language and environment for statistical computing (Version 4.4) [Computer Software]. Vienna, Austria: R Foundation for Statistical Computing; 2024. Available from: https://cran.r-project.org [Cited 27 July, 2026].

30. Viechtbauer W. Conducting meta-analyses in R with the metafor package. *J Stat Softw*. 2010; 36(3):1-48. Available from: https://www.jstatsoft.org/v36/i03/ [Cited 27 July, 2026].

31. Pokushalov E, Garcia C, Ponomarenko A, Samoilova I, Smith J, Johnson M, et al. Optimizing weight loss with artificial intelligence: A randomized controlled trial of dietary-supplement prescriptions in adults with overweight and obesity. *Clin Nutr ESPEN*. 2024. [Cited 27 July, 2026].

32. Khokhar S, Holden J, Toomer C, Del Parigi A. Weight loss with an AI-powered digital platform for lifestyle intervention. *Obes Surg*. 2024; 34(5):1810-1818. Available from: https://doi.org/10.1007/s11695-024-07209-1 [Cited 27 July, 2026].

33. Nakata Y, Sasai H, Gosho M, Kobayashi H, Shi Y, Ohigashi T, et al. A smartphone healthcare application, CALO mama Plus, to promote weight loss: A randomized controlled trial. *Nutrients*. 2022; 14(21):4608. Available from: https://doi.org/10.3390/nu14214608 [Cited 27 July, 2026].

34. Shamanna P, Saboo B, Damodharan S, Mohammed J, Mohamed M, Poon T, et al. Reducing HbA1c in type 2 diabetes using digital twin technology-enabled precision nutrition: A retrospective analysis. *Diabetes Ther*. 2020; 11(11):2703-2714. Available from: https://doi.org/10.1007/s13300-020-00931-w [Cited 27 July, 2026].

35. Okaniwa F, Yoshida H. Evaluation of dietary management using artificial intelligence and human interventions: Nonrandomized controlled trial. *JMIR Form Res*. 2024; 8:e50693. Available from: https://doi.org/10.2196/50693 [Cited 27 July, 2026].

36. Graham SA, Pitter V, Hori JH, Stein N, Branch OH. Weight loss in a digital app-based diabetes prevention program powered by artificial intelligence. *Digit Health*. 2022; 8:1-12. Available from: https://doi.org/10.1177/20552076221130619 [Cited 27 July, 2026].

37. Rahmanti AR, Yang HC, Bintoro BS, Nursetyo AA, Muhtar MS, Syed-Abdul S, et al. SlimMe, a chatbot with artificial empathy for personal weight management: System design

and finding. *Front Nutr*. 2022; 9:870775. Available from: https://doi.org/10.3389/fnut.2022.870775 [Cited 27 July, 2026].

38. Lee YB, Kim G, Jun JE, Park H, Lee WJ, Hwang YC, et al. An integrated digital health care platform for diabetes management with AI-based dietary management: 48-week results from a randomized controlled trial. *Diabetes Care*. 2023; 46(5):959–966. Available from: https://doi.org/10.2337/dc22-1929 [Cited 27 July, 2026].

39. Mathioudakis N, Lalani B, Abusamaan MS, Alderfer M, Alver D, et al. An AI-powered lifestyle intervention vs human coaching in the Diabetes Prevention Program: A randomized clinical trial. *JAMA*. 2025; 334(23):2079–2089. Available from: https://doi.org/10.1001/jama.2025.19563 [Cited 27 July, 2026].

40. Forman EM, Kerrigan SG, Butryn ML, Juarascio AS, Manasse SM, Ontañón S, et al. Can the artificial intelligence technique of reinforcement learning use continuously-monitored digital data to optimize treatment for weight loss? *J Behav Med*. 2019; 42(2):276–290. Available from: https://doi.org/10.1007/s10865-018-9964-1 [Cited 27 July, 2026].

41. Lacruz-Pleguezuelos B, Bazan GX, Romero-Tapiador S, Freixer G, Tolosana R, Daza R, et al. AI4Food, a feasibility study for the implementation of automated devices in the nutritional advice and follow up within a weight loss intervention. *Clin Nutr*. 2025;44(5):105–114 Available from: https://doi.org/10.1016/j.clnu.2025.03.003 [Cited 27 July, 2026].

42. Wright JA, Phillips BD, Watson BL, Newby PK, Norman GJ, Adams WG. Randomized trial of a family-based, automated, conversational obesity treatment program for underserved populations. *Obesity (Silver Spring)*. 2013; 21(9):E369–E378. Available from: https://doi.org/10.1002/oby.20388 [Cited 27 July, 2026].

43. Moh Dan AS, Linoby A, Kasim SS, et al. Personalized AI prompt generator and ChatGPT for weight loss: Randomized controlled trial in adults with overweight and obesity. *J Technol*

Behav Sci. 202611(1):45–56 Available from: https://doi.org/10.1007/s41347-026-00618-2 [Cited 27 July, 2026].

44.Higgins JPT, Thompson SG, Spiegelhalter DJ. A re-evaluation of random-effects meta-analysis. *J R Stat Soc Ser A Stat Soc*. 2009;172(1):137–159. Available from: https://doi.org/10.1111/j.1467-985X.2008.00552.x [Cited 27 July, 2026].

45. Hua Y, Siddals S, Ma Z, Galatzer-Levy I, Xia W, Hau C, et al. Charting the evolution of artificial intelligence mental health chatbots from rule-based systems to large language models: A systematic review. *World Psychiatry*. 2025; 24(3):383–394. Available from: https://doi.org/10.1002/wps.21352 [Cited 27 July, 2026].

46.Pocock SJ, Rossello X, Owen R, Collier TJ, Stone GW, Rockhold FW. Primary and secondary outcome reporting in randomized trials: JACC State-of-the-Art Review. *J Am Coll Cardiol*. 2021; 78(8):827–839. Available from: https://doi.org/10.1016/j.jacc.2021.06.024 [Cited 27 July, 2026].

47.Viechtbauer W, Cheung MWL. Outlier and influence diagnostics for meta-analysis. *Res Synth Methods*. 2010; 1(2):112–125. Available from: https://doi.org/10.1002/jrsm.11 [Cited 27 July, 2026].

48. Berkhout C, Berbra C, Favre J, Collins C, Calafiore M, Peremans L, et al. Defining and evaluating the Hawthorne effect in primary care: A systematic review and meta-analysis. *Front Med (Lausanne)*. 2022; 9:1033486. Available from: https://doi.org/10.3389/fmed.2022.1033486 [Cited 27 July, 2026].

49. Schaid DJ, Lucchinetti CF. Clinical trials overview: From explanatory to pragmatic clinical trials. *Mayo Clin Proc*. 2023; 98(8):1158–1170. Available from: https://doi.org/10.1016/j.mayocp.2023.04.013 [Cited 27 July, 2026].

50. Sterne JAC, Hernán MA, Reeves BC, Savović J, Berkman ND, Viswanathan M, et al. ROBINS-I: A tool for assessing risk of bias in non-randomised studies of interventions. *BMJ*. 2016; 355:i4919. Available from: https://doi.org/10.1136/bmj.i4919 [Cited 27 July, 2026].

51. Bui E, et al. Research objectives and general considerations for pragmatic clinical trials of pain treatments: IMMPACT statement. *Pain*. 2023; 164(Suppl 1):S3–S17. Available from: https://pmc.ncbi.nlm.nih.gov/articles/PMC10281023/ [Cited 27 July, 2026].

52. Wasserstein RL, Schirm AL, Lazar NA. Moving to a world beyond "p < 0.05". *Am Stat*. 2019; 73(Suppl 1):1–19. Available from: https://doi.org/10.1080/00031305.2019.1583913 [Cited 27 July, 2026].

53. Webb R. The significance of 'non-significant'. *J Wound Care*. 2019; 28(4):193. Available from: https://doi.org/10.12968/jowc.2019.28.4.193 [Cited 27 July, 2026].

54. Bordoni Jd, Tonet L. A incerteza do processo científico. *Rev Pesq Educ Jurid*. 2016; 2(1). Available from: https://doi.org/10.26668/IndexLawJournals/2525-9636/2016.v2i1.174 [Cited 27 July, 2026].

55. Ahmed ES, Butt NM. The misunderstood p-value: why statistical significance is not enough in clinical practice. *Br J Anaesth*. 2025; 134(4):909–913. Available from: https://doi.org/10.1016/j.bja.2025.01.008 [Cited 27 July, 2026].

56. Schulze MB, Stefan N. Metabolically healthy obesity: from epidemiology and mechanisms to clinical implications. *Nat Rev Endocrinol*. 2024; 20:633–646. Available from: https://doi.org/10.1038/s41574-024-01008-5 [Cited 27 July, 2026].

57. Martínez-Pérez BN, de la Torre-Díez I, López-Coronado M. Mobile health applications for the most prevalent conditions by the World Health Organization: review and analysis. *J Med Internet Res*. 2013; 15(6):e120. Available from: https://doi.org/10.2196/jmir.2600 [Cited 27 July, 2026].

58. World Health Organization. Ethics and governance of artificial intelligence for health: WHO guidance. Geneva: World Health Organization; 2021. Available from: https://www.who.int/publications/i/item/9789240029200 [Cited 27 July, 2026].

59. Murofushi K, et al. Artificial Intelligence and Machine Learning Resource Guide: The Academy of Nutrition and Dietetics and the American Society for Nutrition Joint Taskforce for Artificial Intelligence. *Am J Clin Nutr*. 2026;123(2):410–418. Available from: https://doi.org/10.1016/j.ajcnut.2026.101240 [Cited 27 July, 2026].

60. Johnson D, et al. Perceptions of Registered Dietitian Nutritionists (RDNs) on the Use of Artificial Intelligence (AI) in Clinical Nutrition Care: A Cross-Sectional Survey Within a Large U.S. Healthcare System *Nutrients* 2026;18(6):1806. Available from: https://doi.org/10.3390/nu18060934 [Cited 27 July, 2026].

61. Alhazmi A, Ibrahem M, Dawria A. Knowledge, attitude and practice of artificial intelligence among dietitians in Saudi Arabia: a cross-sectional study. *BMJ Open*. 2025; 15(9):e104230. Available from: https://doi.org/10.1136/bmjopen-2025-104230 [Cited 27 July, 2026].

62. Almalki M, et al. Integrating artificial intelligence into medical education: a narrative systematic review of current applications, challenges, and future directions. *BMC Med Educ*. 2025; 25:1187. Available from: https://doi.org/10.1186/s12909-025-05871-x [Cited 27 July, 2026].

3 CONCLUSÃO

A condução de pesquisas acerca do uso de ferramentas de IA é fundamental para avaliar seus impactos, benefícios, riscos e aspectos éticos, mesmo quando os resultados não se mostram categoricamente positivos. O debate científico sustentado pelos dados disponíveis aponta perspectivas promissoras mesmo em cenários de incerteza, viabilizando desdobramentos relevantes ao fundamentar a necessidade de revisitar temas não pacificados e mapear o estado da arte. Ademais, a IA não deve ser analisada sob óticas simplistas ou julgamentos binários, mas sim a partir de uma perspectiva responsável, pragmática e baseada em evidências, evitando-se abordagens pautadas em vieses ou no senso comum.

Evidencia-se que a aplicação da inteligência artificial no contexto nutricional e na prática profissional voltada ao manejo do peso corporal apresenta uma tendência consistente de benefício. Embora o desfecho primário tenha se situado no limite da significância estatística, a análise integrada do tamanho do efeito e da relevância clínica indica que rejeitar a utilidade da intervenção com base estrita em limiares p-valorados binários pode configurar um erro de Tipo II (falso-negativo). Os valores encontrados refletem o potencial dessas tecnologias, cuja força estatística plena poderá ser confirmada futuramente com a publicação de ensaios mais robustos e com maiores amostras.

Os achados corroboram o consenso da literatura internacional contemporânea de que as ferramentas de IA não devem atuar de forma isolada ou autônoma na prescrição e no aconselhamento dietético. Os dados apontam para ganhos substanciais de eficiência em operações sistematizadas sob o modelo *Human-in-the-Loop* — isto é, com supervisão humana direta. A automação de tarefas repetitivas, a triagem e a redução da carga administrativa proporcionadas pela IA não constituem justificativa para a exclusão do profissional de saúde, indispensável para o julgamento clínico, a empatia e a responsabilidade ética.

O sucesso da transição tecnológica depende da ampliação de estudos com maiores tempos de seguimento e em populações heterogêneas que retratem a realidade clínica. Complementarmente, faz-se urgente a reformulação das matrizes curriculares, incorporando o letramento em IA nos cursos de graduação e pós-graduação. Essas recomendações podem contribuir diretamente para a mitigação do

viés de automação e para o fortalecimento de uma prática digital fundamentada em evidências.

REFERÊNCIAS

AHMED, E. S. BUTT, N. M. O valor p mal compreendido: por que a significância estatística não é suficiente na prática clínica. **British Journal of Anaesthesia**, v. 134, n. 4, p. 909-913, abr. 2025. DOI: 10.1016/j.bja.2025.01.008. Disponível em: https://doi.org/10.1016/j.bja.2025.01.008. Acesso em: 19 jun. 2026.

ALBRACHT-SCHULTE, K. The role of artificial intelligence in nutrition research: a scoping review. **Nutrients,** v. 13, n. 8, p. 2356, 2021. Disponível em: https://aithor.com/paper-summary/the-role-of-artificial-intelligence-in-nutrition-research-a-scoping-review. Acesso em: 3 dez. 2024.

ALCÂNTARA, Hellen Souza de; ALMEIDA, Diego Monteiro de; PINTO, Emanuel Vieira. Inteligência artificial no cuidado de enfermagem: um estudo acerca do futuro da profissão. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 10, n. 12, p. 1290–1305, 2024. DOI: 10.51891/rease.v10i12.17352. Disponível em: https://periodicorease.pro.br/rease/article/view/17352. Acesso em: 28 mar. 2025.

ALHAZMI, A.; IBRAHEM, M.; DAWRIA, A. Knowledge, attitude and practice of artificial intelligence among dietitians in Saudi Arabia: a cross-sectional study. **BMJ Open**, v. 15, n. 9, p. e104230, set. 2025. DOI: 10.1136/bmjopen-2025-104230. Disponível em: https://doi.org/10.1136/bmjopen-2025-104230. Acesso em: 19 jun. 2026.

ALMEIDA FILHO, Carlito Lins de *et al*. Desafios éticos para o uso de inteligência artificial na educação e na pesquisa. **Políticas Públicas, Meio Ambiente e Desenvolvimento no Século XXI**, v. 6, n. 3, 2024. DOI: 10.33448/rsd-v13i3.45210. Acesso em: 22 mar. 2024.

AN, Ruopeng; WANG, Xiaoxin. Artificial intelligence applications to public health nutrition. **Nutrients**, v. 15, n. 19, p. 4285, 8 out. 2023. DOI: 10.3390/nu15194285. Disponível em: https://doi.org/10.3390/nu15194285. Acesso em: 3 dez. 2024.

BARANOWSKI, Tom *et al*. Are current health behavioral change models helpful in guiding prevention of weight gain efforts?. **Obesity Research**, v. 11, Suppl. S10, p. 23S-43S, out. 2003. DOI: 10.1038/oby.2003.222. Disponível em: https://doi.org/10.1038/oby.2003.222. Acesso em: 3 dez. 2024.

BARTHOLOMEU, A. B. A revolução da inteligência artificial na saúde: impacto, oportunidades e desafios pelo mundo. **Revista Qualidade HC**, n. 3, p. 26–30, 2023. Disponível em: https://hcrp.usp.br/revistaqualidadehc/uploads/Artigos/509/509.pdf. Acesso em: 23 maio 2025.

BOND, Ashley; MCCAY, Kevin; LAL, Simon. Artificial intelligence & clinical nutrition: What the future might have in store. **Clinical Nutrition ESPEN**, v. 57, p. 734, 2023. DOI: 10.1016/j.clnesp.2023.07.082. Disponível em: https://doi.org/10.1016/j.clnesp.2023.07.082. Acesso em: 3 dez. 2024.

BORDONI, J. d'A.; TONET, L. A incerteza do processo científico. **Revista de Pesquisa e Educação Jurídica**, 2016. DOI: 10.26668/IndexLawJournals/2525-9636/2016.v2i1.174. Disponível em: https://doi.org/10.26668/IndexLawJournals/2525-9636/2016.v2i1.174 Acesso em: 19 jun. 2026.

BRASIL. Ministério da Cultura. **Senado Federal aprova marco regulatório da inteligência artificial**. Brasília, DF: Ministério da Cultura, 10 dez. 2024. Disponível em: https://www.gov.br/cultura/pt-br/assuntos/noticias/senado-federal-aprova-marco-regulatorio-da-inteligencia-artificial. Acesso em: 23 maio 2025.

CADE, Janet E. *et al*. DIET@NET: Best Practice Guidelines for dietary assessment in health research. **BMC Medicine**, v. 15, p. 202, 2017. DOI: 10.1186/s12916-017-0962-x. Disponível em: https://doi.org/10.1186/s12916-017-0962-x. Acesso em: 3 dez. 2024.

CHANG, Edward Y. **Examining GPT-4's Capabilities and Enhancement with SocraSynth**. Preprint. ResearchGate, 2023. Disponível em: https://www.researchgate.net/publication/374753069_Examining_GPT-4%27s_Capabilities_and_Enhancement_with_SocraSynth. Acesso em: 2 dez. 2024.

CHENG, Y.; LI, Y.; LIU, X. A primer on generative artificial intelligence. **Applied Sciences**, v. 12, n. 8, p. 4054, 2024. Disponível em: https://www.mdpi.com/2076-3417/12/8/4054. Acesso em: 2 dez. 2024.

CHOTWANVIRAT, Phawinpon *et al*. Advancements in using AI for dietary assessment based on food images: scoping review. **JMIR Human Factors**, v. 11, p. e51432, 2024. Disponível em: https://www.jmir.org/2024/1/e51432/. Acesso em: 3 dez. 2024.

CROSS, Victoria *et al*. Do personalized nutrition interventions improve dietary intake and risk factors in adults with elevated cardiovascular disease risk factors? A systematic review and meta-analysis of randomized controlled trials. **Nutrition Reviews**, v. 83, n. 4, p. 512–528, 2024. DOI: 10.1093/nutrit/nuae149. Disponível em: https://doi.org/10.1093/nutrit/nuae149. Acesso em: 3 dez. 2024.

DELIPETREV, Blagoj; TSINARAKI, Chrisa; KOSTIĆ, Uroš. **Historical evolution of artificial intelligence**. EUR 30221 EN. Luxembourg: Publications Office of the European Union, 2020. DOI: 10.2760/801580. Disponível em: https://op.europa.eu/en/publication-detail/-/publication/6264ac29-2d3a-11eb-b27b-01aa75ed71a1/language-en. Acesso em: 2 dez. 2024.

ELDRIDGE, Alison L. *et al*. Evaluation of new technology-based tools for dietary intake assessment—An ILSI Europe dietary intake and exposure task force evaluation. **Nutrients**, v. 11, n. 1, p. 55, 2019. DOI: 10.3390/nu11010055. Disponível em: https://doi.org/10.3390/nu11010055. Acesso em: 3 dez. 2024.

FISBERG, Regina Mara; MARCHIONI, Dirce Maria Lobo; COLUCCI, Ana Carolina Almada. Avaliação do consumo alimentar e da ingestão de nutrientes na prática clínica. **Arquivos Brasileiros de Endocrinologia & Metabologia**, São Paulo, v. 53,

n. 5, p. 653-660, jul. 2009. DOI: 10.1590/S0004-27302009000500014. Acesso em: 20 mar. 2024.

FOURTANÉ, Susan. **What is AI?** The three types of artificial intelligence. Westcliff University. Disponível em: https://ir.westcliff.edu/. Acesso em: 8 dez. 2024.
GHOSH, S.; RAJKUMAR, R. R. Food image recognition and calorie prediction using Faster R-CNN and Mask R-CNN. *In*: **IEEE Xplore**, 2024. Disponível em: https://ieeexplore.ieee.org/document/10335053. Acesso em: 3 dez. 2024.

GILSON, A. et al. How well does ChatGPT pass the Medical Licensing Exams? The implications of Large Language Models in medical education and clinical practice. **JMIR Medical Education**, v. 9, e45312, 2023. DOI: 10.2196/45312. Acesso em: 3 dez. 2024.

GOH, Yong Shian *et al*. Machine learning in health promotion and behavioral change: scoping review. **Journal of Medical Internet Research**, v. 24, n. 6, p. e35831, 2 jun. 2022. DOI: 10.2196/35831. Disponível em: https://doi.org/10.2196/35831. Acesso em: 3 dez. 2024.

HARVARD INTERNATIONAL REVIEW. **A race to extinction**: how great power competition is making artificial intelligence existentially dangerous. Disponível em: https://hir.harvard.edu/a-race-to-extinction/. Acesso em: 8 dez. 2024.

HEO, Jung Hwan. Ethical review in the age of artificial intelligence. **AI Ethics Journal**, v. 2, n. 2, p. 4, 16 jul. 2021. Disponível em: https://www.aiethicsjournal.org/10-47289-aiej20210716-4. Acesso em: 4 dez. 2024.

HUA, Shangying; JIN, Shuangci; JIANG, Shengyi. The limitations and ethical considerations of ChatGPT. **Data Intelligence**, v. 6, n. 1, p. 201–239, 2024. DOI: 10.1162/dint_a_00243. Disponível em: https://doi.org/10.1162/dint_a_00243. Acesso em: 8 dez. 2024.

JOHNSON, D. *et al*. Perceptions of Registered Dietitian Nutritionists (RDNs) on the Use of Artificial Intelligence (AI) in Clinical Nutrition Care: A Cross-Sectional Survey Within a Large U.S. Healthcare System. **Nutrients**, v. 18, n. 6, 2026. DOI: 10.3390/nu18060934. Disponível em: https://doi.org/10.3390/nu18060934. Acesso em: 19 jun. 2026.

KAC, Gilberto; SICHIERY, Rosely; GIGANTE, Denise Petrucci (org.). **Epidemiologia nutricional**. Rio de Janeiro/São Paulo: Editora Fiocruz/Atheneu, 2007. E-book. DOI: 10.7476/9788575413203. Acesso em: 3 dez. 2024.

KAKUN, Artem; TYTENKO, Sergiy. Generative AI and prompt engineering in education. **Modern Engineering and Innovative Technologies**, v. 29, n. 1, p. 117, 2023. DOI: 10.30890/2567-5273.2023-29-01-052. Disponível em: http://www.moderntechno.de/index.php/meit/article/view/meit29-01-052. Acesso em: 31 jul. 2026.

KARVELA, Maria *et al*. Assessment of the impact of a personalised nutrition intervention in impaired glucose regulation over 26 weeks: a randomised controlled

trial. **Scientific Reports**, v. 14, p. 10119, 2024. DOI: 10.1038/s41598-024-55105-6. Disponível em: https://www.nature.com/articles/s41598-024-55105-6. Acesso em: 3 dez. 2024.

KELLY, Jaimon T. *et al*. Digital disruption of dietetics: are we ready? **Journal of Human Nutrition and Dietetics**, v. 34, n. 1, p. 134-146, 2021. DOI: 10.1111/jhn.12819. Disponível em: https://doi.org/10.1111/jhn.12819 Acesso em: 23 maio 2025.

KIRK, Daniel *et al*. Aprendizado de máquina na pesquisa nutricional. **Avanços em Nutrição**, v. 13, n. 6, p. 2573-2589, 2022. Disponível em: https://www.sciencedirect.com/science/article/pii/S2161831323000923. Acesso em: 23 maio 2025.

KLURFELD, David M. *et al*. Technology innovations in dietary intake and physical activity assessment: challenges and recommendations for future directions. **American Journal of Preventive Medicine**, v. 55, n. 4, p. e117-e122, out. 2018. Disponível em: https://www.sciencedirect.com/science/article/pii/S0749379718320233. Acesso em: 3 dez. 2024.

KOOLI, Chokri; MUFTAH, Hend Al. Artificial intelligence in healthcare: a comprehensive review of its ethical concerns. **Technological Sustainability**, mar. 2022. DOI: 10.1108/TECHS-12-2021-0029. Disponível em: https://doi.org/10.1108/TECHS-12-2021-0029. Acesso em: 3 dez. 2024.

LINHARES, J. L. **Plataforma inteligente para a comunicação com hipertensos**: revisão sistemática. 2023. 83 f. Dissertação (Mestrado em Saúde da Família) – Programa de Pós-Graduação em Saúde da Família, Universidade Federal do Ceará, Sobral, 2023. Disponível em: https://repositorio.ufc.br/bitstream/riufc/73517/5/2022_dis_jlplinhares.pdf. Acesso em: 23 maio 2025.

LU, Y. et al. Artificial intelligence in food calorie and nutrient estimation: a systematic review and practical implications. **Trends in Food Science & Technology**, v. 145, p. 104380, 2024. Disponível em: https://doi.org/10.1016/j.tifs.2024.104380.Acesso em: 1 dez. 2024.

MANNE, Ravi; KANTHETI, Sneha C. Artificial Intelligence in Healthcare: chances and challenges. **Current Journal of Applied Science and Technology**, v. 40, n. 6, p. 78–89, 2021. Artigo nº CJAST.67947. DOI: 10.9734/cjast/2021/v40i631320. Disponível em: https://doi.org/10.9734/cjast/2021/v40i631320. Acesso em: 23 maio 2025.

MASLEJ, Nestor *et al*. **The AI Index 2024 Annual Report**. AI Index Steering Committee, Institute for Human-Centered AI, Stanford University, Stanford, CA, abr. 2024. Disponível em: https://aiindex.stanford.edu/wp-content/uploads/2024/05/HAI_AI-Index-Report-2024.pdf. Acesso em: 1 dez. 2024.

MENDOZA, M. *et al*. Artificial Intelligence-Based Approaches for Obesity Management. **International Journal of Obesity**, v. 47, n. 4, p. 292-302, 2023. Disponível em: https://doi.org/10.1038/s41366-023-01387-9. Acesso em: 3 dez. 2024.

MIYAZAWA, Taiki *et al*. Artificial intelligence in food science and nutrition: a narrative review. **Nutrition Reviews**, v. 80, n. 12, p. 2288–2300, dez. 2022. DOI: 10.1093/nutrit/nuac033. Disponível em: https://doi.org/10.1093/nutrit/nuac033. Acesso em: 3 dez. 2024.

MOKHTARI, M.; JAMEEL, S.; KHEIR, N. Reinforcement learning for generative AI: state of the art, opportunities and open research challenges. **Journal of Artificial Intelligence Research**, v. 70, p. 1-25, 2024. Disponível em: https://www.jair.org/index.php/jair/article/view/12692. Acesso em: 2 dez. 2024.

MUROFUSHI, K. *et al*. Artificial Intelligence and Machine Learning Resource Guide: The Academy of Nutrition and Dietetics and the American Society for Nutrition Joint Taskforce for Artificial Intelligence. **The American Journal of Clinical Nutrition**, v. 123, n. 2, p. 410–418, 2026. DOI: 10.1016/j.ajcnut.2026.101240. Disponível em: https://doi.org/10.1016/j.ajcnut.2026.101240. Acesso em: 19 jun. 2026.

OH, Yoo Jung *et al*. A systematic review of artificial intelligence chatbots for promoting physical activity, healthy diet, and weight loss. **International Journal of Behavioral Nutrition and Physical Activity**, v. 18, n. 1, p. 160, 2021. DOI: 10.1186/s12966-021-01224-6. Disponível em: https://doi.org/10.1186/s12966-021-01224-6. Acesso em: 1 dez. 2024.

OLIVEIRA, F. E. de *et al*. O uso da inteligência artificial na identificação do paciente psiquiátrico com tendência suicida. **Revista Contemporânea**, v. 4, n. 10, p. e6253, 2024. DOI: 10.56083/RCV4N10-152. Disponível em: https://ojs.revistacontemporanea.com/ojs/index.php/home/article/view/6253. Acesso em: 28 mar. 2025.

OPENAI. **Better Language Models are Secretly Few-Shot Learners**. 2020. Disponível em: https://openai.com/index/better-language-models/. Acesso em: 2 dez. 2024.

OPENAI. **GPT-4 Technical Report**. 2023. Disponível em: https://arxiv.org/pdf/2303.08774. Acesso em: 2 dez. 2024.

OPENAI. **Language Models are Unsupervised Multitask Learners**. 2019. Disponível em: https://openai.com/research/language-unsupervised. Acesso em: 2 dez. 2024.

ORGANIZAÇÃO MUNDIAL DA SAÚDE. **OMS divulga primeira diretriz sobre intervenções de saúde digital**. Organização Pan-Americana da Saúde, 17 abr. 2019. Disponível em: https://www.paho.org/pt/noticias/17-4-2019-oms-divulga-primeira-diretriz-sobre-intervencoes-saude-digital. Acesso em: 23 maio 2025.

PASQUALE, Frank. The black box society: the secret algorithms that control money and information. **Cambridge**: Harvard University Press, 2015. Disponível em: https://raley.english.ucsb.edu/wp-content/Engl800/Pasquale-blackbox.pdf. Acesso em: 31 jul. 2026.

PEREIRA, I. Leite dos R. *et al*. Desafios e avanços na personalização diagnóstica e terapêutica na era da inteligência artificial na saúde. **Brazilian Journal of Implantology and Health Sciences**, v. 6, n. 1, p. 1282–1290, 2024. DOI: 10.36557/2674-8169.2024v6n1p1282-1290. Disponível em: https://bjihs.emnuvens.com.br/bjihs/article/view/1259. Acesso em: 28 mar. 2025.

POPOV, Vladimir V. *et al*. Industry 4.0 and digitalisation in healthcare. **Sensors**, v. 21, n. 6, p. 1-19, 2021. Disponível em: https://pmc.ncbi.nlm.nih.gov/articles/PMC8953130. Acesso em: 2 dez. 2024.

QUEIROZ, C. A. **O uso de agente conversacional para autocuidado em pessoas com Diabetes Mellitus**: revisão sistemática. 2023. 81 f. Dissertação (Mestrado em Saúde da Família) – Programa de Pós-Graduação em Saúde da Família, Universidade Federal do Ceará, Sobral, 2023. Disponível em: https://repositorio.ufc.br/bitstream/riufc/73890/1/Dis_2023_cadequeiroz.pdf. Acesso em: 23 maio 2025.

RÊGO, Ana Regina. A ética nos usos de “inteligência” artificial: interações, mercado e sociedade. **Organicom**, v. 21, n. 44, p. 109–120, 2024. DOI: 10.11606/issn.2238-2593.organicom.2024.221333. Disponível em: https://www.revistas.usp.br/organicom/article/view/221333. Acesso em: 20 mar. 2025.

RUEL, Marie T.; ALDERMAN, Harold. Nutrition-sensitive interventions and programmes: how can they help to accelerate progress in improving maternal and child nutrition?. **The Lancet**, London, v. 382, n. 9891, p. 536-551, 10–16 ago. 2013. DOI: 10.1016/S0140-6736(13)60843-0. Acesso em: 20 mar. 2025.

RYAN, R. et al. Machine learning and digital health interventions for obesity management and behavioral change: a systematic review. **Obesity Reviews**, v. 23, n. 6, e13420, 2022. DOI: 10.1111/obr.13420. Acesso em: 2 dez. 2024.

SAGHIRI, Ali Mohammad *et al*. A survey of artificial intelligence challenges: analyzing the definitions, relationships, and evolutions. **Applied Sciences**, v. 12, n. 8, p. 4054, 2022. DOI: 10.3390/app12084054. Disponível em: https://www.mdpi.com/2076-3417/12/8/4054. Acesso em: 2 dez. 2024.

SANTOS-D’AMORIM, Karen. Artigos retratados, o uso indiscriminado da Inteligência Artificial na pesquisa/escrita científica e outros “fantasmas”. **Divulga-CI**, v. 3, n. 2, fev. 2025. Acesso em: 15 mar. 2025.

SCHNEIDER, Theresa; YATES, Richard. The role of artificial intelligence in healthcare and the evolution of diagnostic tools. **The Lancet Digital Health**, v. 3, n. 2, p. 79-89, 2021. DOI: 10.1016/S2589-7500(20)30315-3. Disponível em: https://doi.org/10.1016/S2589-7500(20)30315-3. Acesso em: 2 dez. 2024.

SOSA-HOLWERDA, A. *et al*. The role of artificial intelligence in nutrition research: a scoping review. **Nutrients**, v. 13, n. 8, p. 2356, 2021. Disponível em: https://www.mdpi.com/2072-6643/13/8/2356. Acesso em: 3 dez. 2024.

STOKEL-WALKER, Chris. How patients are using AI. **BMJ**, v. 387, 19 nov. 2024. DOI: 10.1136/bmj.q2393. Disponível em: https://doi.org/10.1136/bmj.q2393. Acesso em: 12 dez. 2024.

SUMMERBELL, C. et al Personalised nutrition: the role of new dietary assessment methods. **Proceedings of the Nutrition Society**, Cambridge University Press v. 83, n. 2, p. 145-152, 2024. Disponível em: https://www.cambridge.org/core/journals/proceedings-of-the-nutrition-society/article/personalised-nutrition-the-role-of-new-dietary-assessment-methods/C7242953F909C3AB93F3A60B65386C5C. Acesso em: 3 dez. 2024.

TAWFIK, Gehad Mohamed *et al*. A step by step guide for conducting a systematic review and meta-analysis with simulation data. **Tropical Medicine and Health**, v. 47, n. 46, 2019. Disponível em: https://tropmedhealth.biomedcentral.com/articles/10.1186/s41182-019-0165-6. Acesso em: 3 dez. 2024.

UNIÃO EUROPEIA. **Lei da UE sobre IA**: primeira regulamentação de inteligência artificial. Parlamento Europeu, 12 jun. 2023. Atualizado em 20 fev. 2025. Disponível em: https://www.europarl.europa.eu/topics/pt/article/20230601STO93804/lei-da-ue-sobre-ia-primeira-regulamentacao-de-inteligencia-artificial. Acesso em: 23 maio 2025.

VANDEPUTTE, Jules *et al*. Principles and validations of an artificial intelligence-based recommender system suggesting acceptable food changes. **The Journal of Nutrition**, v. 153, n. 2, p. 598-604, 2023. Disponível em: https://doi.org/10.1016/j.tjnut.2022.12.015. Acesso em: 23 maio 2025.

VERMA, Meghna *et al*. Challenges in personalized nutrition and health. **Frontiers in Nutrition**, v. 5, p. 117, 2018. Disponível em: https://www.frontiersin.org/articles/10.3389/fnut.2018.00117/full. Acesso em: 23 maio 2025.

WASSERSTEIN, R. L.; SCHIRM, A. L.; LAZAR, N. A. Moving to a world beyond “p < 0.05”. **The American Statistician**, v. 73, n. S1, p. 1-19, 2019. DOI: 10.1080/00031305.2019.1583913. Disponível em: https://doi.org/10.1080/00031305.2019.1583913. Acesso em: 19 jun. 2026.

WEBB, R. The significance of ‘non-significant’. **Journal of Wound Care**, v. 28, n. 4, p. 193, abr. 2019. Disponível em: https://doi.org/10.12968/jowc.2019.28.4.193. Acesso em: 19 jun. 2026.

WIENS, J.; SHENOY, E. S. Machine learning for healthcare: on the verge of a major shift in healthcare epidemiology. **Clinical Infectious Diseases**, Oxford, v. 66, n. 1, p. 149–153, 1 jan. 2018. Disponível em: https://doi.org/10.1093/cid/cix731. Acesso em: 23 maio 2025.

WONG, A.; LIU, Y. A systematic review of sensor-based methodologies for food portion size estimation. **IEEE Access**, v. 8, p. 10090–10101, 2020. Disponível em: https://ieeexplore.ieee.org/document/9272773. Acesso em: 3 dez. 2024.

YI, Xinghao *et al*. A review of the application of deep learning in obesity: From early prediction aid to advanced management assistance. **Diabetes & Metabolic Syndrome: Clinical Research & Reviews**, v. 18, n. 4, p. 103000, abr. 2024. DOI: 10.1016/j.dsx.2024.103000. Disponível em: https://doi.org/10.1016/j.dsx.2024.103000. Acesso em: 20 jul. 2026.

APENDICE A – Estratégia de Busca

Search Completion Date: April 2026

Core Concepts Intersected (Boolean AND):

Concept 1 (Artificial Intelligence & Conversational Agents) AND Concept 2 (Diet & Nutritional Quality) AND Concept 3 (Body Weight & Obesity Outcomes)

Pairwise Combination A (2-Way): Concept 1 AND Concept 2 *(Focus on AI + Nutrition/Dietary Adherence)*

Pairwise Combination B (2-Way): Concept 1 AND Concept 3 *(Focus on AI + Body Weight/Obesity)*

Search Strategy Overview

To ensure total reproducibility, the detailed search syntax for each interface and electronic database searched up to April 2026 is reported below. All terms were derived from Medical Subject Headings (MeSH), Health Sciences Descriptors (DeCS), and free-text titles/abstracts terms, filtered according to the pre-established scope.

Concept 1: AI & Conversational Agents	Concept 2: Diet & Nutrition	Concept 3: Weight & Body Outcomes
Artificial Intelligence	Diet	Obesity
Chatbot	Dietetics	Overweight
Conversational Agent	Nutritional Sciences	Body Weight
Generative AI	Food Intake	Weight Loss
Large Language Models (LLM)	Dietary Adherence	Body Mass Index (BMI)
Generative Artificial Intelligence	Nutritional Quality	Body Weight Changes
Interactive Voice Response	Healthy Diet	Weight Control

Concept 1: AI & Conversational Agents	Concept 2: Diet & Nutrition	Concept 3: Weight & Body Outcomes
Natural Language Processing	Caloric Intake	Weight Reduction

Detailed Search Strategies by Database:

1. **PubMed / MEDLINE**

Interface: PubMed (NLM) / Fields Searched: MeSH Terms, Title/Abstract

(((("Artificial Intelligence"[MeSH] OR "Chatbot"[MeSH] OR "Conversational Agent" OR "Generative AI" OR "Large Language Models" OR "LLM" OR "Generative Artificial Intelligence" OR "Interactive Voice Response") AND ("Diet"[MeSH] OR "Dietetics"[MeSH] OR "Nutritional Sciences"[MeSH] OR "Food Intake"[MeSH] OR "Dietary Adherence" OR "Nutritional Quality" OR "Healthy Diet" OR "Caloric Intake")) AND ("Obesity"[MeSH] OR "Overweight"[MeSH] OR "Body Weight"[MeSH] OR "Weight Loss"[MeSH] OR "Body Mass Index"[MeSH] OR "Body Weight Changes" OR "BMI"))

2. **Cochrane Library**

Interface: Wiley Online Library / Fields Searched: Title, Abstract, Keyword (via Trials and Reviews)

(("Artificial Intelligence" OR "Chatbot" OR "Conversational Agent" OR "Generative AI" OR "Large Language Model" OR "LLM") AND ("Diet" OR "Dietetics" OR "Nutritional Science" OR "Food Intake" OR "Dietary Adherence" OR "Nutritional Quality" OR "Healthy Diet") AND ("Obesity" OR "Overweight" OR "Body Weight" OR "Weight Loss" OR "Body Mass Index" OR "BMI"))

3. **IEEE Xplore**

Interface: IEEE Xplore Digital Library / Fields Searched: Document Title and Abstract

((("Document Title":"Artificial Intelligence" OR "Document Title":"Chatbot" OR "Document Title":"Generative AI" OR "Abstract":"Conversational Agent" OR "Abstract":"Large Language Models") AND ("Abstract":"Diet" OR "Abstract":"Nutrition" OR "Abstract":"Dietary Adherence" OR "Abstract":"Nutritional Quality") AND ("Abstract":"Weight Loss" OR "Abstract":"Obesity" OR "Abstract":"Body Weight" OR "Abstract":"BMI")))

4. **Web of Science**

Interface: Clarivate Analytics (via CAPES Periodicals Portal) /Fields Searched: Topic

TS=(("Artificial Intelligence" OR "Chatbot" OR "Conversational Agent" OR "Generative AI" OR "Large Language Models" OR "LLM") AND ("Diet" OR "Dietetics" OR "Nutritional Science" OR "Food Intake" OR "Dietary Adherence" OR "Nutritional Quality") AND ("Obesity" OR "Overweight" OR "Body Weight" OR "Weight Loss" OR "Body Mass Index" OR "BMI"))

5. **Google Scholar**

Interface: Web Browser Interface (Scholar) / Strategy: Simplified Boolean query

("Artificial Intelligence" OR "Chatbot" OR "Generative AI") AND ("Diet" OR "Nutritional Quality" OR "Dietary Adherence") AND ("Weight Loss" OR "Obesity" OR "Body Weight")

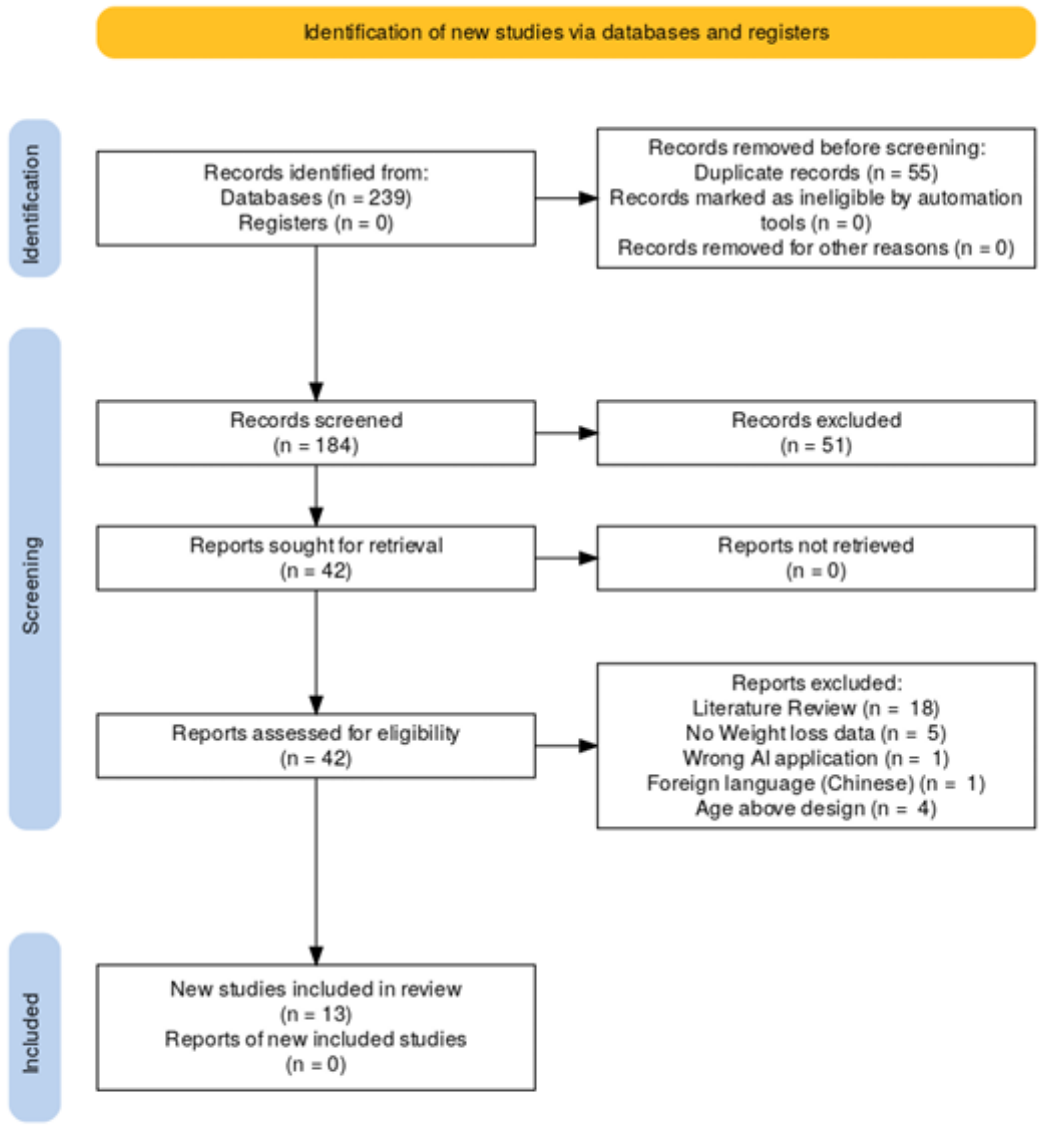
6. Open Access Theses and Dissertations (OATD)

Interface: oatd.org / Fields Searched: Title, Abstract, and Keywords

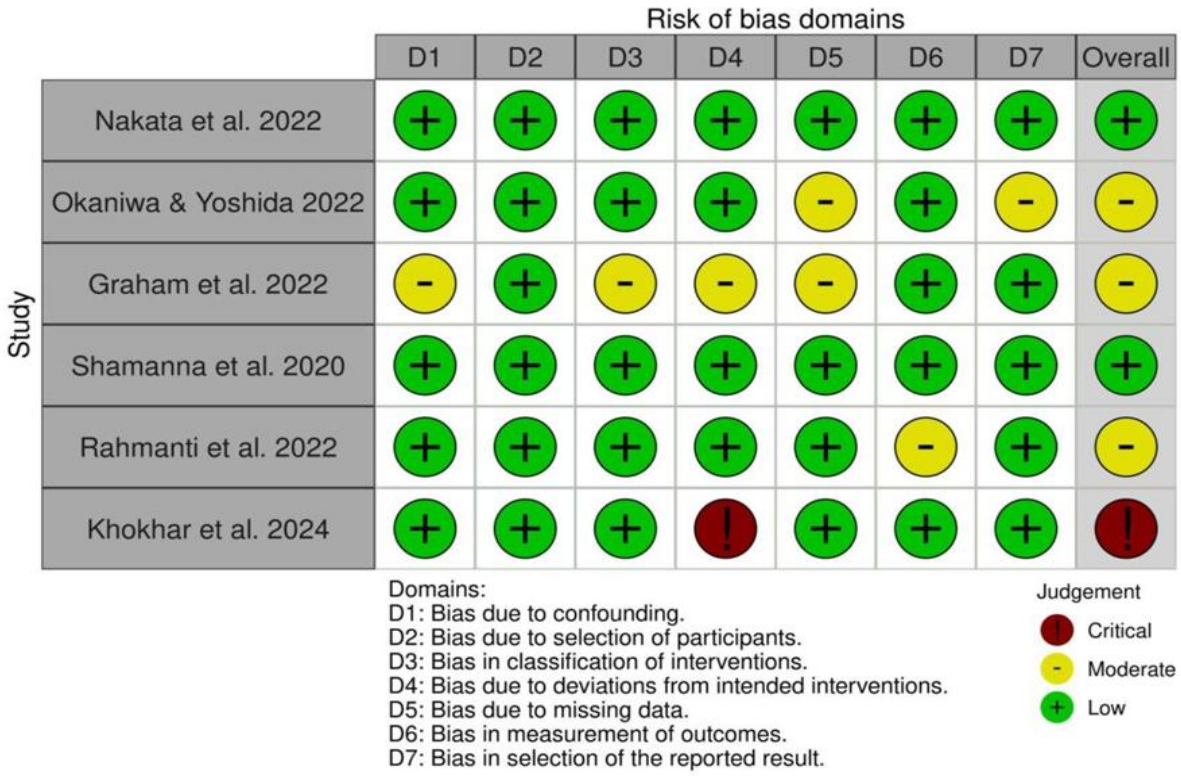
("Artificial Intelligence" OR "Chatbot" OR "Generative AI") AND ("Diet" OR "Nutrition" OR "Dietary") AND ("Weight Loss" OR "Obesity" OR "Body Weight")

APENDICE B – Figura 1 (PRISMA Flow Diagram)

Figure 1- PRISMA Flow Diagram

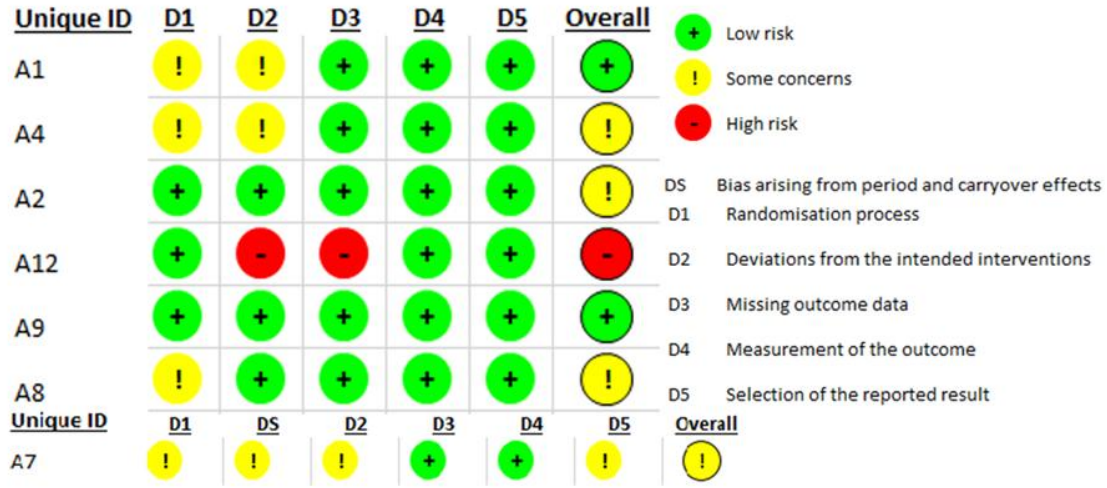


APENDICE C – ROBINS-I Results



APENDICE D – RoB2 e RoB2 Crossover Results

Study Risk of Bias by RoB2 and RoB2 Crossover



Study ID and correspondent references: A1 (38), A2 (39), A4(40), A7[Crossover](41), A8(42), A9(31), A12(43).

APENDICE E – GRADE ASSESSMENT

Autor(es): Ranyelle Goulart Amorim, Adão Mauricio Gonçalves Pereira Junior and Leandro de Morais Cardoso

Pergunta: AI-guided dietary and nutritional interventions (chatbots, apps, generative AI) compared to active digital controls, standard care, inactive controls, or baseline values to body weight reduction

Contexto: Effects of AI-Guided Nutritional Interventions on Body Weight: A Systematic Review and Meta-Analysis

Certainty assessment							Number of patients		Effects		Certainty	Importance
Number of Studies	Study design	Risk of Bias	Inconsistences	Indirect Evidences	Imprecisions	Other considerations	AI-guided dietary and nutritional interventions (chatbots, apps, generative AI)	Active digital controls, standard care, inactive controls, or baseline values	Relative (95% IC)	Absoluto (95% IC)		
Body Weight Reduction (kg)												
7	RCT's	Serious[a]	Serious[b]	Not Serious	Not serious	none	500	494	-	MD **0.21 kg minor** (0.35 minor to 0.07 minor)	⨁⨁◯◯ Low[a,b]	CRITICAL
Body Weight Reduction (kg)												
6	Observational Studies	Serious[c]	Serious[b]	Not Serious	Not Serious	none	773	811	-	MD **0.37 kg minor** (0.6 minor to 0.14 minor)[d]	⨁◯◯◯ Very Low[b,c]	CRITICAL

CI: Confidence interval; **MD:** Mean difference

Explanations

a. "Most studies presented some concerns or high risk of bias in specific domains."

b. High statistical heterogeneity was observed across studies, indicating substantial variation in effect sizes among interventions.

c. "The studies presented moderate risk of bias overall according to ROBINS-I, with concerns in domain measurements and missing data."

d. "The analysis of 6 studies showed an effect size of -0.37 (95% CI: -0.60 to -0.14; I^2 = 71.8%). After removing 1 outlier (study A13), heterogeneity dropped to I^2 = 0% and the adjusted effect was -0.25 (95% CI: -0.39 to -0.10)."