

Uso da inteligência artificial para estimativa dietética com base em imagens de alimentos

Use of artificial intelligence for dietary estimation based on food images

Título abreviado: Inteligência artificial e consumo alimentar

Júlia Pinheiro da Cunha

Acadêmica do curso de Nutrição, Escola de Ciências Sociais e da Saúde, Pontifícia Universidade Católica de Goiás. Goiânia, Goiás, Brasil.

Daniela Canuto Fernandes Almeida

Docente do curso de Nutrição, Escola de Ciências Sociais e da Saúde, Pontifícia Universidade Católica de Goiás. Goiânia, Goiás, Brasil. Email: daniela.enf@pucgoias.edu.br. *Autor correspondente.

RESUMO

Introdução: a inteligência artificial tem se destacado como ferramenta promissora na área da nutrição, sobretudo em estudos que investigam a aplicação na avaliação do consumo alimentar por meio de imagens. **Objetivo:** avaliar a correlação e a concordância entre a análise da composição de nutrientes de imagens de alimentos, no ChatGPT e em softwares de nutrição. **Material e métodos:** a pesquisa foi conduzida utilizando-se imagens de alguns alimentos pertencentes aos grupos de cereais e tubérculos, leguminosas, carnes, legumes e hortaliças disponíveis em atlas fotográficos. Comparou-se as estimativas oriundas da análise das imagens pelo ChatGPT e a avaliação por softwares. **Resultados:** o ChatGPT identificou corretamente a maioria dos alimentos, entretanto, apresentou uma tendência para superestimar o peso e o VET de porções médias e grandes dos alimentos, especialmente aquelas com maior densidade energética, e de superestimar teores de carboidratos e proteínas de alimentos de baixa densidade energética. A concordância entre os métodos variou, em geral, de pobre a moderada. A apresentação das medidas caseiras nas imagens dos alimentos (colheres, conchas e escumadeiras) acarretaram menores desvios-padrão, resultando em maior consistência nas estimativas. **Conclusão:** o ChatGPT apresenta potencial relevante como ferramenta complementar para a avaliação dietética baseada em imagens, principalmente para triagens rápidas e análises preliminares. Entretanto, faz-se necessária a padronização de imagens e o aprimoramento de modelos para alimentos regionais, assim como a aplicação de questões éticas e de privacidade. Desse modo, estudos futuros com amostras ampliadas são necessários para consolidar a aplicabilidade na prática do nutricionista.

Palavras-chave: inteligência artificial; estimativa dietética; imagens de alimentos; ChatGPT.

ABSTRACT

Introduction: Artificial intelligence has stood out as a promising tool in the field of nutrition, especially in studies investigating its application in assessing food consumption through images. **Objective:** To evaluate the correlation and agreement between the analysis of the nutrient composition of food images in ChatGPT and nutrition software. **Materials and methods:** The research was conducted using images of some foods belonging to the groups of cereals and tubers, pulses, meats, vegetables, and greens available in photographic atlas. Estimates from the analysis of images by ChatGPT were compared with the evaluation by software. **Results:** ChatGPT correctly identified most foods, but tended to overestimate the weight and total energetic value of medium and large portions of foods, especially those with higher energy density, and to overestimate the carbohydrate and protein content of foods with low energy density. Agreement between the methods generally ranged from poor to moderate. The presentation of household measures in food images (spoons, ladles, and skimmers) resulted in lower standard deviations, leading to greater consistency in estimates. **Conclusion:** ChatGPT has significant potential as a complementary tool for image-based dietary assessment, especially for rapid screening and preliminary analysis. However, image standardization and model improvement for regional foods are necessary, as well as the application of ethical and privacy issues. Thus, future studies with larger samples are needed to consolidate its applicability in nutritionist practice.

Keywords: artificial intelligence; dietary estimation; food images; ChatGPT.

INTRODUÇÃO

A avaliação da ingestão alimentar é uma etapa essencial para a compreensão do estado nutricional de indivíduos, e representa um importante recurso para intervenções em saúde pública e práticas clínicas (Fisberg; Marchioni; Colucci, 2009). Tradicionalmente, essa estimativa é realizada por meio de autorrelatos e entrevistas conduzidas por nutricionistas, utilizando ferramentas como o recordatório alimentar de 24 horas (R24h), registros alimentares (RA), questionários de frequência alimentar (QFA) e diários alimentares (Silva; Souza, 2021).

Há que se ponderar, no entanto, que a estimativa precisa do tamanho das porções representa um dos maiores obstáculos enfrentados na análise da ingestão alimentar, uma vez que, tais métodos dependem fortemente da memória do indivíduo, além de estarem sujeitos a vieses. Outro aspecto a ser discutido é que essa estimativa, muitas vezes, demanda tempo e profissionais capacitados para a coleta e análise dos dados (Silva; Souza, 2021). Deste modo, a depender do tipo de erro envolvido, a estimativa da ingestão alimentar pode resultar em valores inferiores ou superiores ao consumo real do indivíduo (Fisberg; Marchioni; Colucci, 2009).

Nessa perspectiva, com o avanço das tecnologias digitais, a inteligência artificial (IA), parece constituir uma estratégia para tornar esse processo mais automatizado e preciso. Uma das alternativas interessantes à prática do profissional Nutricionista propõe o uso de imagens de alimentos para a análise do consumo alimentar, permitindo a identificação, estimativa do volume e do valor nutricional dos registros enviados pelo próprio cliente/paciente (Tahir; Loo, 2021). Dentre os avanços mais recentes, destaca-se a utilização do modelo ChatGPT, que tem sido investigado como uma ferramenta no reconhecimento de alimentos e na análise de informações nutricionais. Lo et al. (2024) avaliaram a precisão do modelo ChatGPT na identificação de alimentos e na estimativa de nutrientes com base em imagens, observando desempenho satisfatório na comparação com avaliações visuais de nutricionistas e por softwares. Esses achados denotam o potencial da IA no suporte à avaliação dietética, principalmente em contextos com restrição de tempo ou de recursos humanos (Lo et al., 2024). Não foram encontrados estudos publicados no Brasil que tenham avaliado a utilização do ChatGPT para essa finalidade, tampouco pesquisas que façam uso de imagens provenientes de registros fotográficos nacionais, como os disponibilizados em manuais de porções brasileiras.

Diante desse cenário, torna-se relevante investigar o potencial da inteligência artificial, como ferramenta complementar na avaliação do consumo alimentar a partir de imagens de alimentos. Assim, esta pesquisa teve o objetivo de avaliar a correlação e a concordância entre a análise do tamanho da porção e da composição de nutrientes de alimentos, no ChatGPT e em softwares de nutrição, visando a avaliação dessa tecnologia de inteligência artificial como ferramenta na estimativa da ingestão alimentar.

MATERIAL E MÉTODOS

Padronização das imagens de alimentos

A análise da composição em nutrientes de alguns alimentos foi realizada por meio do uso de imagens disponíveis em atlas alimentares digitais, que oferecem fotografias padronizadas com porções conhecidas e identificadas. Esses atlas são amplamente utilizados em estudos nutricionais e possibilitam estimativas mais precisas de volume e de porção, além de padronizar a visualização dos alimentos (Crispim et al., 2017; Ministério da Saúde, 2014). A partir da análise dos atlas fotográficos, foram escolhidos os seguintes alimentos em cada grupo alimentar: carnes (bife e peito de frango), leguminosas (feijão), cereais e tubérculos (arroz e batata frita), verduras e legumes (alface, tomate e cenoura). Os alimentos foram escolhidos considerando-se os seguintes critérios: (1) disponibilidade das imagens nos atlas; (2) disponibilidade do peso das porções; (3) representatividade para o grupo alimentar; e (4) qualidade visual da imagem para identificação do alimento. Preparações alimentares foram excluídas após seleção prévia, em razão do fato de que a quantidade e os tipos de ingredientes usados na receita não foram detalhados nos atlas fotográficos, o que inviabilizaria os cálculos para comparação no software nutricional.

Para cada alimento, foram avaliadas imagens retiradas dos dois atlas fotográficos selecionados e disponíveis para consulta. No Manual Fotográfico de Quantificação Alimentar, para cada alimento, são disponibilizadas de cinco a seis imagens (Crispim et al., 2017). Deste modo, para padronização e análise no estudo, foram selecionadas três imagens por alimento que representassem as diferentes

porções. A porção denominada P, foi considerada selecionando-se uma imagem que caracterizasse uma porção pequena normalmente consumida pela população. No caso das porções denominadas M e G, estas representaram tamanhos de porções médias e grandes, respectivamente. O segundo atlas selecionado para análise apresentava as imagens dos alimentos associado a presença de uma medida caseira (CS – colher de sopa, CA – colher de arroz; ES – escumadeira, PG – pegador de macarrão) (Ministério da Saúde, 2014). Estas imagens também foram analisadas para verificação da influência da medida caseira na estimativa da porção e da composição de nutrientes na análise da foto pelo ChatGPT.

Porção e composição em nutrientes: comparação entre software e inteligência artificial

Após a seleção das imagens dos atlas fotográficos digitais, o peso da porção identificada no atlas foi registrado em uma planilha do Excel®. Inicialmente, foi realizada a avaliação da composição em nutrientes da porção, utilizando-se a descrição do alimento no atlas e a análise por meio de softwares de nutrição (Web diet® e Dietbox®), que utilizam como banco de dados as tabelas de composição nutricional, TACO e da *U.S. Department of Agriculture* (USDA). Essa etapa serviu como linha de base para avaliar a composição em nutrientes obtidos de forma tradicional, sem o uso de qualquer ferramenta de inteligência artificial.

Em seguida, procedeu-se à análise do tamanho da porção, composição em nutrientes e valor energético de cada alimento selecionado no ChatGPT. O procedimento de análise contemplou o envio ao ChatGPT da imagem do alimento, retirada dos atlas fotográficos, com o seguinte prompt de linguagem: *“Tenho algumas fotos para as quais quero que você me forneça uma estimativa do conteúdo nutricional. Especificamente, quero que você me dê uma estimativa de energia, proteína, carboidrato total, gordura total, fibra alimentar, açúcar total, gordura saturada, gordura poliinsaturada, gordura monoinsaturada, na porção total, de acordo com a TACO e a USDA. Forneça também uma lista dos alimentos na foto com uma estimativa do peso físico de cada alimento em gramas. Forneça sua melhor estimativa pontual e não forneça um intervalo. Ao estimar o peso, forneça uma estimativa de peso para cada ingrediente individual que você identificar na imagem, em vez dos pesos combinados de vários ingredientes.”*

O prompt associado à imagem do alimento foi enviada ao ChatGPT para análise, sem qualquer tipo de treinamento prévio da inteligência artificial, com o objetivo de identificar o desempenho bruto do sistema ao lidar com imagens desconhecidas. Esse procedimento foi realizado duas vezes, em um intervalo médio de 15 dias entre uma análise e outra, com a mesma imagem e prompt, para avaliar a consistência da avaliação realizada.

Análise estatística

Os dados foram tabulados em planilha do Excel e as análises foram realizadas no software R (versão 4.1.3). A normalidade da distribuição dos dados foi avaliada pelo teste de Shapiro-Wilk. A correlação foi avaliada pelos coeficientes de Pearson ou Spearman, de acordo com o teste de normalidade. A força de correlação foi considerada conforme a seguir: 0,00 – 0,19 (bem fraca); 0,20 a 0,39 (fraca); 0,40 a 0,69 (moderada); 0,7 a 0,89 (forte); 0,90 a 1,0 (muito forte) (Barbetta, 2006). A concordância entre as estimativas feitas pelos softwares nutricionais (Dietbox/WebDiet) e pelo ChatGPT foi avaliada pelo coeficiente de Lin para avaliar a variabilidade dos métodos, a magnitude das diferenças e se a avaliação feita pelo ChatGPT superestimou ou subestimou a ingestão alimentar. A concordância foi classificada em concordância: quase perfeita (>0.90), substancial ($0.8 - 0.9$), moderada ($0.65 - 0.8$) e pobre (<0.65) (Barbetta, 2006). Para todas as análises, foi considerado um nível de significância de 5%.

RESULTADOS

O peso da porção e a composição nutricional analisada pelo software e estimada pelo ChatGPT estão mostrados nas Tabelas 1, 2 e 3. Na análise da capacidade do ChatGPT de estimar os pesos das porções, é interessante destacar que para as porções maiores de arroz e feijão observou-se coeficiente de variação (CV) maior do que 20% entre as estimativas realizadas pelo ChatGPT, indicando alta variabilidade na análise realizada (Tabela 1). No caso da batata, a estimativa do peso pelo ChatGPT para as porções média e grande foi bastante variável, com CV de 23,5%. Observou-se ainda que as estimativas de peso realizadas pelo ChatGPT variaram sobremaneira intra análise (repetições no próprio ChatGPT), resultando em

desvios-padrão elevados para alguns alimentos (Tabela 1). Quanto à correlação entre o peso real e o peso estimado, observou-se que esta foi positiva e forte para o tomate, arroz e feijão (Tabela 4). Por outro lado, na análise de concordância entre métodos (análise vs estimativa), observou-se concordância pobre na estimativa do peso das porções de frango, batata e tomate (Tabela 2), indicando que a estimativa pelo ChatGPT não apresenta comparabilidade com o peso real indicado nos atlas fotográficos. Ao analisar a porção de frango, a diferença entre pesos reais e estimados variou de – 38 g a 18 g (Tabela 4). Para esse alimento, a correlação observada foi muito forte (0,98), contudo, a concordância entre os métodos foi classificada como substancial (0,86), conforme Tabela 4. Isso indica que, embora o ChatGPT geralmente acerte a direção da mudança de peso, há um erro de estimativa de até 38 g para menos ou 18 g para mais na porção. Em síntese, os resultados indicam que, a magnitude dos desvios e os elevados coeficientes de variação em determinados grupos sugerem que a acurácia das estimativas pelo ChatGPT, sem treinamentos prévios ou modelos matemáticos específicos, ainda é limitada, especialmente em alimentos com maior densidade energética e porções de maior volume.

Observou-se nas Tabelas 1, 2 e 3 que os valores de desvio-padrão das estimativas do ChatGPT apresentaram, em alguns casos, padrões idênticos entre diferentes alimentos e porções (por exemplo, 7,07; 14,14; 42,43). Esse comportamento decorre do número reduzido de repetições ($n = 2$) realizado para cada imagem, o que faz com que o desvio-padrão dependa diretamente da diferença entre as duas estimativas obtidas. Assim, quando essa diferença é constante, o resultado gera valores idênticos. Tal padrão evidencia que o ChatGPT produz respostas probabilísticas, com pequenas variações entre análises repetidas, característica inerente aos modelos de linguagem generativa. Portanto, a repetição dos mesmos valores de desvio-padrão não representa erro estatístico, mas sim a consistência do grau de variação interna do modelo de IA frente à mesma entrada visual.

Tabela 1. Peso, valor energético total (VET) e teores de macronutrientes de alimentos dos grupos de cereais, tubérculos e leguminosas, calculado por software e estimado pelo Chat GPT

Grupo/ Alimento	Peso real	Peso estimado	Carboidrato calculado	Carboidrato estimado	Proteína calculada	Proteína estimada	Lipídio calculado	Lipídio estimado	VET calculado	VET estimado
Cereais										
Arroz P ¹	60,0	85,0 ± 7,1	15,29 ± 0,01	24,19 ± 2,42	1,40 ± 0,01	2,20 ± 0,28	0,70 ± 0,0	0,23 ± 0,09	74,91 ± 0,13	110,60 ± 11,60
Arroz M ¹	112,0	147,5 ± 17,7	28,52 ± 0,02	41,9 ± 4,3	2,6 ± 0,0	3,8 ± 0,3	1,3 ± 0,0	0,41 ± 0,13	139,83 ± 0,25	191,50 ± 18,81
Arroz G ¹	318,0	210,0 ± 42,43	85,20 ± 5,95	59,62 ± 11,06	7,69 ± 0,44	0,71 ± 0,01	2,18 ± 2,23	0,54 ± 0,08	401,76 ± 7,42	272,40 ± 49,21
Arroz CS P ²	31,0	37,50 ± 17,68	7,90 ± 0,0	10,63 ± 4,84	1,18 ± 0,03	2,15 ± 0,49	0,39 ± 0,02	0,10 ± 0,0	38,83 ± 0,25	48,50 ± 21,92
Arroz CS M ²	50,0	87,50 ± 17,68	12,72 ± 0,03	24,80 ± 4,67	2,48 ± 0,03	3,68 ± 0,11	0,60 ± 0,01	0,20 ± 0,0	62,18 ± 0,25	113,50 ± 20,51
Arroz Escumadeira G ²	106,0	145,0 ± 7,07	27,0 ± 0,0	41,18 ± 1,38	2,34 ± 0,20	1,45 ± 0,35	1,28 ± 0,04	0,40 ± 0,14	132,08 ± 0,12	188,40 ± 5,09
Tubérculos										
Batata Frita P ¹	62,0	60 ± 14,40	21,50 ± 0,85	19,25 ± 2,19	2,94 ± 0,20	2,05 ± 0,49	8,02 ± 0,16	9,23 ± 3,78	161,0 ± 5,4	163 ± 41,72
Batata Frita M ¹	143,0	120 ± 28,28	49,59 ± 1,96	38,50 ± 4,38	6,75 ± 0,49	4,10 ± 0,99	18,53 ± 0,32	18,45 ± 7,57	373,52 ± 12,05	373,52 ± 12,05
Batata Frita G ¹	265,0	180 ± 42,43	91,88 ± 3,64	57,75 ± 6,58	12,48 ± 0,96	6,15 ± 1,48	34,32 ± 0,59	27,68 ± 11,35	691,99 ± 22,61	326,00 ± 83,44
Batata Frita CAP ²	50,0	42,50 ± 10,60	17,36 ± 0,65	13,75 ± 5,59	2,34 ± 0,20	1,45 ± 0,35	6,48 ± 0,11	7,28 ± 1,03	130,29 ± 4,65	123,65 ± 13,93
Batata Frita Escumadeira G ²	100,0	95 ± 7,07	34,67 ± 1,37	30,35 ± 7,14	4,73 ± 0,33	3,25 ± 0,21	12,96 ± 0,22	16,80 ± 0,0	261,08 ± 8,60	279,75 ± 18,03
Leguminosas										
Feijão preto P	61,0	65,0 ± 21,21	8,52 ± 0,03	10,20 ± 4,81	2,72 ± 0,02	4,0 ± 2,26	0,32 ± 0,02	0,33 ± 0,11	42,0 ± 7,06	64,20 ± 37,05
Feijão preto M	105,0	110,0 ± 14,14	14,7 ± 0,0	17,0 ± 4,8	4,7 ± 0,0	6,6 ± 2,5	0,6 ± 0,0	0,6 ± 0,1	72,4 ± 11,9	105,8 ± 42,1
Feijão preto G	174,0	175,0 ± 35,36	24,38 ± 0,02	27,20 ± 9,62	7,80 ± 0,01	10,60 ± 4,81	0,92 ± 0,02	0,88 ± 0,18	120,02 ± 19,82	170,0 ± 79,20
Feijão preto Concha	140,0	112,50 ± 24,75	20,22 ± 1,68	16,74 ± 1,33	6,70 ± 0,01	6,22 ± 0,03	0,78 ± 0,03	0,63 ± 0,04	102,50 ± 6,36	103,0 ± 5,94

¹Atlas fotográfico Crispim et al. (2017). A porção denominada P representa a imagem de uma porção pequena; M indica a porção média, e G a porção grande (representando as imagens selecionadas no atlas).

²Atlas fotográfico Ministério da Saúde, 2014; ³ O peso considerado real indica o peso referido para a porção do alimento registrada no atlas fotográfico, utilizado como base para a pesquisa (valor absoluto).

Tabela 2. Peso, valor energético total (VET) e teores de macronutrientes de alimentos do grupo de carnes, calculado por software e estimado pelo Chat GPT

Grupo/ Alimento	Peso real	Peso estimado	Proteína calculada	Proteína estimada	Lipídio calculado	Lipídio estimado	VET calculado	VET estimado
Peito de frango P ¹	22	35,0 ± 0,07	6,9 ± 0,14	10,85 ± 2,19	0,74 ± 0,35	1,26 ± 0,25	35,53 ± 3,58	57,45 ± 12,09
Peito de frango M ¹	76	70,0 ± 14,14	23,89 ± 0,57	21,7 ± 4,38	2,66 ± 1,08	2,52 ± 0,51	122,74 ± 12,36	114,9 ± 24,18
Peito de frango G ¹	158	120,0 ± 0,00	49,72 ± 1,24	37,2 ± 0,00	5,51 ± 2,28	4,32 ± 0,00	255,17 ± 25,70	196,8 ± 1,70
Bife bovino P ²	55	57,5 ± 3,54	16,71 ± 0,01	15,05 ± 0,78	3,98 ± 0,02	8,65 ± 2,19	107,12 ± 0,18	134,4 ± 22,06
Bife bovino M ²	153	105,0 ± 7,07	46,50 ± 0,01	27,5 ± 2,12	11,01 ± 0,02	15,59 ± 1,99	298,17 ± 0,25	243,8 ± 8,77
Bife bovino G ²	310	172,5 ± 10,60	94,22 ± 0,02	40 ± 5,09	22,37 ± 0,03	22,54 ± 0,14	604,75 ± 0,35	353,2 ± 4,52

¹Atlas fotográfico Crispim et al. (2017). A porção denominada P representa a imagem de uma porção pequena; M indica a porção média, e G a porção grande (representando as imagens selecionadas no atlas).

²Atlas fotográfico Ministério da Saúde, 2014;

³ O peso considerado real indica o peso referido para a porção do alimento registrada no atlas fotográfico, utilizado como base para a pesquisa (valor absoluto).

Tabela 3. Peso, valor energético total (VET) e teores de macronutrientes de alimentos do grupo de frutas, verduras e legumes, calculado por software e estimado pelo Chat GPT

Grupo/ Alimento	Peso real ³	Peso estimado	Carboidrato calculado	Carboidrato estimado	Proteína calculada	Proteína estimada	Lipídio calculado	Lipídio estimado	VET calculado	VET estimado
<i>Verduras e Legumes</i>										
Alface crespa	20,0	25 ± 7,07	0,37 ± 0,04	0,66 ± 0,08	0,24 ± 0,05	0,30 ± 0,13	0,02 ± 0,02	0,08 ± 0,03	2,57 ± 0,61	3,15 ± 0,21
Tomate fatiado P ¹	9,0	50 ± 0,00	0,34 ± 0,08	2,13 ± 0,32	0,10 ± 0,00	0,43 ± 0,04	0,01 ± 0,01	0,10 ± 0,00	1,69 ± 0,44	9,50 ± 0,71
Tomate fatiado M ¹	23,0	100 ± 0,00	0,91 ± 0,27	4,30 ± 0,57	0,23 ± 0,04	0,90 ± 0,00	0,07 ± 0,04	0,20 ± 0,00	4,27 ± 1,04	19,00 ± 1,41
Tomate fatiado G ¹	103,0	150 ± 0,00	4,02 ± 1,11	6,43 ± 0,88	1,02 ± 0,16	1,33 ± 0,04	0,24 ± 0,08	0,30 ± 0,00	18,90 ± 4,38	28,50 ± 2,12
Cenoura cozida P ¹	20,0	40,00 ± 0,00	1,72 ± 0,54	3,14 ± 0,08	0,19 ± 0,02	0,41 ± 0,16	0,02 ± 0,03	0,09 ± 0,01	7,48 ± 2,14	13,80 ± 0,28
Cenoura cozida M ¹	50,0	80,00 ± 0,00	4,32 ± 1,39	6,28 ± 0,17	0,51 ± 0,13	0,82 ± 0,31	0,11 ± 0,01	0,18 ± 0,03	18,97 ± 5,71	27,60 ± 0,57
Cenoura cozida G ¹	126,0	120,00 ± 0,00	10,71 ± 3,52	9,42 ± 0,25	1,22 ± 0,25	1,23 ± 0,47	0,24 ± 0,05	0,27 ± 0,04	46,86 ± 14,33	41,40 ± 0,85
Tomate P ²	70,0	62,50 ± 3,54	2,75 ± 0,78	2,73 ± 0,47	0,69 ± 0,12	0,54 ± 0,06	0,38 ± 0,17	0,28 ± 0,03	12,87 ± 3,02	12,00 ± 1,41
Tomate M ²	100,0	100 ± 0,00	3,92 ± 1,10	4,30 ± 0,57	1,00 ± 0,14	0,90 ± 0,00	0,24 ± 0,09	0,20 ± 0,00	18,17 ± 4,00	19,00 ± 1,41
Tomate G ²	150	130 ± 0,00	5,86 ± 1,62	5,56 ± 0,78	1,48 ± 0,25	1,14 ± 0,05	0,16 ± 0,06	0,12 ± 0,02	27,50 ± 6,36	24,50 ± 2,12

¹Atlas fotográfico Crispim et al. (2017). A porção denominada P representa a imagem de uma porção pequena; M indica a porção média, e G a porção grande (representando as imagens selecionadas no atlas).

²Atlas fotográfico Ministério da Saúde, 2014.

³ O peso considerado real indica o peso referido para a porção do alimento registrada no atlas fotográfico, utilizado como base para a pesquisa (valor absoluto).

Tabela 4 - Análise da correlação e da concordância entre os pesos reais e estimados pelo chat GPT

Alimento	Correlação ¹		Concordância Lin		Diferença entre pesos real e estimado (g) ^b
	p	r	r	IC (95%)	
Frango	0,0002	0,98	0,86	0,63 - 0,95	- 38 a 18
Carne	0,0001	0,99	0,61	- 0,22 - 0,93	- 130 a 5
Feijão	0,005	0,86	0,86	0,45 - 0,97	- 45 a 26
Arroz	0,002	0,87	0,81	0,42 - 0,95	- 78 a 50
Batata frita	0,0001	0,93	0,64	0,19 - 0,87	-12 a - 115
Tomate	0,010	0,70	0,58	0,16 - 0,82	- 20 a 77
Cenoura	0,0013	0,97	0,86	0,55 - 0,96	- 6 a 40

¹Correlação de Pearson. Valores de p<0,05 indicam diferença significativa.

No que tange à análise dos nutrientes presentes nas porções dos alimentos avaliados, observou-se que as estimativas de carboidratos pelo ChatGPT indicaram diferenças expressivas entre os métodos, resultando em desvios-padrão elevados para alguns alimentos (Tabelas 1, 2 e 3). No caso do arroz, verificou-se que as porções pequenas e médias foram superestimadas pelo ChatGPT, enquanto uma das porções grandes apresentou subestimação relevante, com CV acima de 18%, indicando elevada variabilidade nas estimativas (Tabela 1). Para o feijão, as estimativas também oscilaram em torno dos valores calculados, sendo observada tendência de superestimação em todas as porções cujos registros fotográficos não apresentavam as medidas caseiras, especialmente na porção grande, na qual o CV foi de 20,6% (Tabela 1). Já para a batata frita, constatou-se que as porções médias e grandes apresentaram subestimação do teor de carboidratos pelo ChatGPT (Tabela 3). Quanto aos vegetais, verificou-se que o tomate fatiado apresentou superestimação em todas as porções analisadas (Tabela 3). No caso da cenoura, observou-se padrão semelhante, com valores superestimados de carboidratos nas porções pequena e média e discreta subestimação na porção grande. De modo geral, verificou-se correlação forte entre os métodos para o arroz, feijão, tomate e cenoura, e correlação muito forte para a batata frita (Tabela 5). Quanto à concordância entre os métodos, identificou-se concordância moderada entre os teores de carboidratos para arroz, feijão, batata frita e cenoura, porém pobre para o tomate. Para a batata frita, a concordância é pobre (0,64), e as diferenças são significativas (- 12 g a -115g), sugerindo uma subestimação consistente (Tabela 5).

Tabela 5 - Análise da correlação e da concordância entre os teores de carboidratos calculado pelo software e estimado pelo chat GPT

Alimento	Correlação ¹		Concordância Lin		Diferença entre os teores de carboidrato calculado e estimado (g) ^b
	p	r	r	IC (95%)	
Feijão	0,035	0,74	0,72	0,15 – 0,93	-3,97 a 9,6
Arroz	0,0004	0,85	0,75	0,47 – 0,89	-37,6 a 16,4
Batata frita	0,02589	0,95	0,74	0,48 – 0,88	-41,35 a -0,1
Tomate	0,0076	0,72	0,56	0,15 – 0,80	- 0,30 a 3,16
Cenoura	0,0214	0,88	0,77	0,32 – 0,93	- 0,89 a 2,84

¹Correlação de Pearson. Valores de p<0,05 indicam diferença significativa.

* Os dados da carne e do frango não foram analisados por não serem fontes desse nutriente.

Os teores de proteínas dos alimentos calculados pelos softwares nutricionais e estimados pelo ChatGPT encontram-se nas Tabelas de 1 a 3. Observou-se que, para o arroz, houve superestimação nas porções pequenas e médias, enquanto a porção grande foi subestimada, com coeficiente de variação (CV) superior a 15%, indicando elevada variabilidade nas estimativas (Tabela 1). Em relação ao feijão, verificou-se tendência de superestimação do teor de proteínas em todas as porções analisadas, com destaque para a porção grande (Tabela 1). Para a batata frita, o ChatGPT subestimou as proteínas em todas as porções (Tabela 3). Já nos vegetais, como tomate e cenoura, identificou-se superestimação nas porções pequenas e médias (Tabela 6). Observou-se concordância pobre entre os métodos para a maioria dos alimentos analisados, conforme Tabela 6.

Tabela 6 - Análise da correlação e da concordância entre os teores de proteína calculado pelo software e estimado pelo chat GPT

Alimento	Correlação ¹		Concordância Lin		Diferença entre os teores de proteína calculado e estimado (g) ^b
	p	r	r	IC (95%)	
Frango	0,0005	0,98	0,86	0,65 – 0,94	-13,4 a 5,6
Carnes	0,001	0,97	0,37	0,04 – 0,63	-57,4 a -1,1
Feijão	0,08	0,65	0,51	-0,04 – 0,82	-0,59 a 3,7
Arroz	0,002	0,86	0,77	0,51 – 0,90	-3,2 a 1,34
Batata frita	0,0005	0,89	0,51	0,20 – 0,73	-8,06 a -1,0
Tomate	0,0200	0,66	0,57	0,14 – 0,82	-0,34 a 0,37
Cenoura	0,0101	0,92	0,84	0,34 – 0,97	0,01 a 0,27

¹Correlação de Pearson. Valores de $p < 0,05$ indicam diferença significativa.

Observa-se que as estimativas de lipídios variaram de forma considerável entre os grupos alimentares, especialmente em alimentos fritos e de origem animal. Para a batata frita, o ChatGPT apresentou valores de lipídios superiores aos calculados, indicando uma tendência de superestimação da gordura total, principalmente nas porções média e grande, nas quais o desvio-padrão foi mais elevado. Entretanto, quando a análise da porção de batata do registro fotográfico foi feita com a imagem que continha a medida caseira, a análise foi exata (Tabela 1). De modo semelhante, o frango e as carnes apresentaram discrepâncias positivas entre os valores calculados e estimados, o que pode estar relacionado à dificuldade do modelo (ChatGPT) em diferenciar visualmente métodos de cocção (grelhado, frito, cozido), que impactam diretamente no teor de gordura. Por outro lado, alimentos com menor teor lipídico,

como tomate, cenoura e feijão, apresentaram valores próximos entre as duas estimativas, com desvios-padrão reduzidos, evidenciando maior precisão do modelo para alimentos com baixo conteúdo de gordura (Tabelas 1, 2 e 3). Os resultados observados nas análises de correlação e de concordância entre os métodos (Tabela 7) reforçam esses achados, demonstrando correlações fortes a muito fortes entre os valores de lipídios calculados e estimados das carnes e de frituras como a batata, indicando associação linear positiva entre os métodos. As diferenças médias entre os teores de lipídios calculado e o estimado variaram de -15,1 g (batata frita) a +5,9 g (carne), demonstrando que, de forma geral, o ChatGPT superestimou os valores lipídicos, especialmente em alimentos com alto teor de gordura ou cocção em óleo (Tabela 7). Esses resultados indicam que, embora o modelo apresente boa capacidade de reconhecer tendências gerais, sua precisão quantitativa ainda é limitada para nutrientes altamente variáveis, como os lipídios.

Tabela 7 - Análise da correlação e da concordância entre os teores de lipídios totais calculado pelo software e estimado pelo chat GPT

Alimento	Correlação ¹		Concordância Lin		Diferença entre os teores de lipídios calculado e estimado (g) ^b
	p	r	r	IC (95%)	
Frango	0,013	0,90	0,77	0,41 – 0,92	-2,81 a 0,45
Carnes	0,002	0,96	0,84	0,46 – 0,96	-1,11 a 5,97
Feijão	0,003	0,88	0,86	0,47 - 0,97	-0,18 a 0,1
Arroz	0,099	0,50	0,10	-0,03 – 0,23	-3,27
Batata frita	0,005	0,80	0,79	0,38 - 0,94	-15,1 a 4,0
Tomate	0,0294	0,63	0,52	0,10 – 0,78	- 0,04 a 0,06
Cenoura	0,0003	0,98	0,77	0,37 – 0,93	0,02 a 0,20

¹Correlação de Pearson. Valores de $p < 0,05$ indicam diferença significativa.

Em relação ao valor energético total (VET) estimado pelo ChatGPT, observou-se que as estimativas obtidas pela IA variaram consideravelmente em relação aos valores calculados pelo software, com diferenças mais expressivas em alimentos de maior densidade energética, como as porções grandes de batata frita, que apresentaram médias elevadas e desvios-padrão amplos, sugerindo maior variabilidade entre as estimativas (Tabelas 1, 2 e 3). Em contraste, alimentos com menor teor calórico, como alface e tomate, apresentaram menor dispersão dos valores, demonstrando maior consistência nas estimativas do ChatGPT, exceto para

o feijão (Tabelas 1 e 3). De modo geral, o ChatGPT tendeu a superestimar o VET em relação ao valor de referência obtido pelo software, comportamento coerente com o padrão observado nas demais análises, o que pode estar associado à sensibilidade do modelo à aparência visual de alimentos mais calóricos. Na Tabela 8, verifica-se que a correlação entre o VET real e o estimado foi forte e positiva para a maioria dos alimentos ($> 0,7$), especialmente para frango e carne (0,98), evidenciando consistência linear entre os métodos, porém o feijão apresentou uma correlação pobre (0,44). No entanto, a concordância de Lin, variou entre moderada e a fraca, sendo moderada para frango (0,88) e batata frita (0,81), e fraca para feijão (0,33) e tomate (0,57), de acordo com a Tabela 8. Esses resultados indicam que, embora o ChatGPT apresente boa correlação com os valores calculados, sua capacidade de estimar o VET de forma equivalente ao método de referência ainda é limitada para alguns alimentos, especialmente aqueles com composição mais complexa.

Tabela 8 - Análise da correlação e da concordância entre o VET calculado pelo software e estimado pelo chat GPT

Alimento	Correlação ¹		Concordância Lin		Diferença entre VET real e estimado (kcal) ^b
	p	r	r	IC (95%)	
Frango	0,0003	0,98	0,88	0,72 – 0,95	-75,34 a 27,94
Carne	0,0003	0,98	0,62	0,28 – 0,82	- 254,5 a 42,75
Feijão	0,2713	0,44	0,33	-0,24 – 0,73	-20 a 71,6
Arroz	0,0002	0,87	0,76	0,52 – 0,89	-169,4 a 65,65
Batata frita	0,0004	0,90	0,81	0,52 – 0,93	-0,08 a 307,5
Tomate	0,009	0,71	0,57	0,15 – 0,81	- 3 a 14
Cenoura	0,0164	0,89	0,79	0,36 - 0,94	- 5,84 a 13,56

¹Correlação de Pearson. Valores de $p < 0,05$ indicam diferença significativa.

Ao analisar a influência da presença das medidas caseiras nas imagens do atlas fotográfico, foi observado que, de forma geral, as estimativas das porções cujas fotos continham medidas caseiras associadas à imagem do alimento, apresentaram menores desvios-padrão em comparação às imagens sem referência dimensional (Tabelas 1, 2 e 3). Observou-se esse comportamento para os pesos estimados do arroz e da batata frita (ambos com a imagem da escumadeira; DP= $\pm 7,1$ g), cujos valores foram substancialmente inferiores aos desvios observados em porções equivalentes, mas sem medidas visuais, como a batata frita M1 ($\pm 28,28$ g) e o arroz M1 ($\pm 17,7$ g).

DISCUSSÃO

A investigação da aplicabilidade do modelo ChatGPT na avaliação do consumo alimentar ainda possui muitas lacunas, sendo que poucos estudos foram publicados sobre o assunto (Amoutzopoulos et al., 2025; Belkhouribchia et al., 2025; Lo et al., 2024; Lu et al., 2020; Papathanail et al., 2021; Shonkoff et al., 2023; Tahir; Loo, 2021). Os resultados obtidos neste estudo sugerem que o ChatGPT possui desempenho promissor na estimativa do conteúdo nutricional a partir de imagens de alimentos, embora ainda existam limitações importantes em termos de acurácia e consistência (Tabelas 1-8). De forma geral, as correlações entre os valores calculados por softwares nutricionais e as estimativas fornecidas pela IA foram classificadas entre fortes e muito fortes para a maioria dos nutrientes analisados (Tabelas 1-8). No entanto, as análises de concordância entre os métodos evidenciaram variabilidade significativa entre os métodos, indicando que a similaridade dos valores absolutos ainda não é suficiente para a substituição completa das ferramentas convencionais. Comparando os achados com a literatura, observa-se que a precisão identificada neste estudo é semelhante à relatada por Lo et al. (2024), que verificaram correlações fortes entre as estimativas de IA e as medições humanas, contudo, reportaram baixa concordância entre os métodos.

Em relação à estimativa do peso das porções, foi observado que o ChatGPT apresentou maiores discrepâncias para alimentos com maior densidade energética e variações volumétricas. Essa dificuldade pode estar associada à ausência de calibração visual específica para diferentes tamanhos de porções e à falta de sensibilidade do modelo para reconhecer características de alimentos típicos de determinadas regiões e culturas. Sistemas de IA baseados em visão computacional ainda enfrentam desafios na estimativa volumétrica precisa dos alimentos, especialmente quando há variação de perspectiva ou de iluminação mostrando que para alimentos isolados ou de composição simples, há maior facilidade de identificação e classificação pela IA, enquanto pratos complexos apresentam desafios devido à sobreposição de alimentos e limites pouco claros entre os componentes da refeição (Lo et al., 2024; Lu et al., 2020; Shonkoff et al., 2023). No estudo de Lo et al. (2024), os autores analisaram a correlação entre as estimativas de peso avaliadas pelo modelo ChatGPT e o peso real, tendo sido observado boa concordância (0,78) entre as estimativas da IA e os dados de referência. Nesse caso, o desempenho do

modelo ChatGPT foi comparável ao de observadores humanos na estimativa do tamanho das porções, cuja concordância foi de 0,81. Na análise de viés, os autores reportaram que o ChatGPT apresentou uma superestimação média de 23,5 g em relação ao peso real, com limites de concordância de -93,1 a 140,1 g. Por outro lado, a avaliação por observadores humanos apresentou viés médio menor (6,9 g), porém com limites de concordância mais amplos (-132,4 a 146,3 g). Entretanto, cabe ressaltar que estes autores avaliaram imagens de alimentos isolados e o estudo indicou que, embora o ChatGPT tenda a superestimar ligeiramente o peso das porções, suas estimativas são mais consistentes e menos variáveis do que a análise feita por humanos, o que denota um maior potencial para análises mais confiáveis (Lo et al., 2024).

Ao analisar 114 fotografias de refeições obtidas a partir de dados de uma pesquisa nacional de ingestão alimentar, Amoutzopoulos et al. (2025) relataram que o modelo ChatGPT apresentou boa precisão na identificação dos alimentos presentes nas imagens, contudo, foram observadas limitações na estimativa do tamanho das porções, sendo mais preciso nas refeições menores e subestimando o peso das porções médias e grandes. Interessante acrescentar que Papathanail et al. (2021) observaram menor precisão para categorias de acompanhamentos devido ao grande número de tipos de alimentos possíveis, dificultando a identificação. Outrossim, em outro estudo, o desempenho da IA variou conforme o tipo de alimento, tendo sido observado os menores erros para carne/peixe (6,56%) e salada/vegetais (7,46%), e erros um pouco maiores para acompanhamentos (9,50%) e sobremesa (10,74%) (Lu et al., 2020). Esses achados evidenciam que a complexidade visual na análise de refeições completas impõe um maior desafio à IA, ao passo que imagens de alimentos isolados favorecem uma interpretação mais precisa e estável das estimativas, como observado também no presente estudo.

Quanto à análise dos macronutrientes, os resultados indicaram que o ChatGPT tendeu a superestimar os teores de carboidratos e proteínas em alimentos de baixa densidade energética, como vegetais e leguminosas, e subestimar os valores em alimentos ricos em gordura, como batata frita e carnes. Essas variações podem refletir tanto limitações na interpretação visual quanto as diferenças nas bases de dados nutricionais utilizadas pelo modelo (Lo et al., 2024; Lu et al., 2020; Tahir; Loo, 2021). Discute-se que a precisão das estimativas nutricionais por IA depende fortemente do treinamento do modelo com imagens representativas e de alta qualidade, além da

adequação da base de dados utilizada para comparação (Lu et al., 2020; Tahir; Loo, 2021). No caso dos lipídios, observou-se que o ChatGPT apresentou tendência à superestimação, principalmente em alimentos de preparo frito ou com maior teor de gordura visível. Esse comportamento pode estar relacionado à dificuldade do modelo em distinguir visualmente métodos de cocção, uma vez que a coloração e a textura do alimento frito podem induzir a interpretações equivocadas de teor lipídico. De maneira semelhante, estudo conduzido por Tahir; Loo, (2021), também observaram maior erro relativo em nutrientes sensíveis ao método de preparo, reforçando a necessidade de calibragem específica para diferentes técnicas culinárias (Tahir; Loo, 2021).

Em relação ao valor energético total (VET), embora o ChatGPT consiga captar a direção das variações energéticas, observou-se erro considerável nas estimativas absolutas. Isso pode estar relacionado à ausência de padronização da escala nas imagens analisadas e à falta de reconhecimento preciso do tamanho da porção, fatores essenciais para o cálculo do VET. Além disso, a variabilidade observada entre as repetições na análise das imagens indica que o desempenho do ChatGPT ainda depende de fatores externos, como o enquadramento da foto e a iluminação, o que reforça a necessidade de protocolos padronizados de captura de imagem para uso dessa ferramenta na prática nutricional (Amoutzopoulos et al., 2025). Em estudo com a análise de refeições completas, foi observada uma subestimação do conteúdo da maioria dos nutrientes avaliados, embora os resultados de correlação e a análise de quartis indicassem que o ChatGPT possuía consistência na classificação das refeições de acordo com o conteúdo nutricional (Lo et al., 2024). De modo semelhante, nas análises do presente estudo, observou-se que o ChatGPT apresentou tendência à subestimação das porções médias e grandes, especialmente em alimentos de maior densidade energética, como arroz, batata frita e frango (Tabelas 1-8), reforçando o padrão também identificado por Lo et al. (2024), e destacando a importância de calibrar o modelo para análise de porções volumosas e/ou refeições completas.

No presente estudo, também foi observado que imagens dos alimentos que apresentavam medidas caseiras apresentaram um desvio-padrão menor. Esse comportamento evidencia que a presença de um objeto de referência padronizado fornece ao modelo de inteligência artificial um parâmetro visual adicional que facilita a inferência do volume e da porção do alimento (Lo et al., 2024; Tahir; Loo, 2021). Nesse caso, vale discutir que as medidas caseiras funcionam como marcadores espaciais,

permitindo que o ChatGPT utilize proporções dimensionais mais realistas, resultando em estimativas mais consistentes. Dessa forma, a padronização das imagens com utensílios de medida mostrou-se uma estratégia eficaz para minimizar as limitações observadas quanto à precisão e reprodutibilidade das análises realizadas no ChatGPT. Isto também foi reportado no estudo de Tahir; Loo, (2021), que destacaram que a utilização de objetos de referência nas fotos ao lado do alimento ou prato, como talheres, moedas ou até mesmo o próprio polegar pode facilitar o cálculo preciso do volume dos alimentos.

Apesar da facilidade e potencial para uso na prática do nutricionista, é preciso considerar que a avaliação dietética por meio do Chat GPT ainda apresenta questões éticas e de confiabilidade, que precisam ser cuidadosamente consideradas. Há riscos potenciais relacionados à privacidade e segurança dos dados, bem como a ocorrência de vieses algorítmicos que podem comprometer a análise do consumo alimentar. Além disso, a falta de referências padronizadas na análise realizada por esses modelos reforça a necessidade de estratégias que assegurem a integridade, a confidencialidade e a veracidade das informações processadas (Belkhouribchia et al., 2025).

É importante ressaltar que a maioria dos estudos que avaliam o uso da inteligência artificial na estimativa dietética não apresenta as análises por grupo de alimento, concentrando-se, na precisão do modelo de forma geral ou em categorias amplas, como refeições completas (Amoutzopoulos et al., 2025; Lo et al., 2024; Shonkoff et al., 2023; Tahir; Loo, 2021). Assim, além da quantidade limitada de estudos, a ausência de análises em relação à estimativa de macronutrientes, dificulta a comparabilidade entre métodos, uma vez que as variações de volume e composição dos alimentos influenciam diretamente a precisão das estimativas. A análise individualizada por grupo alimentar permite identificar diferentes padrões de erro e consistência nas estimativas feitas pelo ChatGPT (Shonkoff et al., 2023).

O presente estudo apresenta limitações, como o número reduzido de alimentos analisados e de repetições das análises, o que impediu a aplicação de testes estatísticos mais robustos. O fato de cada imagem ter sido analisada apenas duas vezes limitou a variabilidade dos dados, reduzindo a capacidade de generalização dos resultados para todos os alimentos pertencentes a cada grupo alimentar. Todavia, a pesquisa contribui com a investigação inicial e discussão da aplicabilidade dessa ferramenta de IA na prática do profissional nutricionista. Diante disso, embora o

ChatGPT represente um avanço expressivo na interpretação visual de alimentos, sua aplicação prática em contextos clínicos e de pesquisa requer protocolos padronizados, controle de qualidade das imagens e medidas de proteção de dados.

Por fim, destaca-se que apesar das limitações, os resultados demonstram que o modelo possui capacidade de identificar tendências e relações proporcionais entre os nutrientes e o tamanho das porções, evidenciando potencial de aplicabilidade prática após o aprimoramento do modelo. Recomenda-se, portanto, o desenvolvimento de estudos futuros com amostras de alimentos consumidos no Brasil e por região, além do uso de fotografias padronizadas de preparações típicas brasileiras e uso de modelos de IA específicos e treinados, a fim de consolidar a viabilidade da tecnologia para uso clínico e educacional. Por fim, este estudo reforça que a inteligência artificial não substitui o olhar crítico e humanizado do nutricionista, mas amplia suas possibilidades, podendo contribuir para a padronização e melhor estimativa do consumo alimentar. Outrossim, a compreensão mais aprofundada da aplicação na avaliação nutricional é válida e importante e deve considerar as questões éticas, sendo um passo essencial para o fortalecimento da profissão.

CONCLUSÃO

O ChatGPT apresenta limitações quanto à precisão quantitativa, especialmente na estimativa do peso das porções médias e grandes e de nutrientes com alta variabilidade, como lipídios e valor energético total. As correlações obtidas entre o ChatGPT e a análise por software indicam que, mesmo sem treinamento prévio ou calibração específica, a ferramenta é capaz de identificar tendências e relações proporcionais entre o tamanho das porções e a composição nutricional. No entanto, em relação à concordância entre métodos, observou-se que esta foi, em geral, de pobre a moderada. A presença de medidas caseiras nas imagens, como colheres, conchas e escumadeiras, contribuiu para reduzir a variação nas estimativas. Isso demonstra que o uso de referências visuais padronizadas pode melhorar a capacidade do modelo de aferir volumes e proporções, sendo importante para futuras aplicações da IA na avaliação dietética.

Dessa forma, o ChatGPT pode ser utilizado como ferramenta complementar na prática clínica e em pesquisas nutricionais, especialmente para análises preliminares,

triagens rápidas ou apoio educacional, desde que sejam adotados protocolos padronizados de captura de imagem e calibração dos modelos. Recomenda-se que futuras investigações explorem bases de dados nacionais, com objetivo de aprimorar a confiabilidade, a reprodutibilidade e a aplicabilidade prática dessa tecnologia na estimativa dietética assistida por inteligência artificial.

REFERÊNCIAS

AMOUTZOPOULOS, Birdem et al. Portion size estimation in dietary assessment: a systematic review of existing tools, their strengths and limitations. **Nutrition Reviews**, v. 78, n. 11, p. 885-900, 1 nov. 2020. DOI:10.1093/nutrit/nuz107. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/31999347/>. Acesso em: 28 maio 2025.

BARBETTA, Pedro Alberto. **Estatística aplicada às ciências sociais**. 6. ed. Florianópolis: Ed. da UFSC, 2006. Disponível em: https://www.ispsn.org/sites/default/files/documentos-virtuais/pdf/estatisca_aplicada_edicao_0.pdf. Acesso em: 12 nov. 2025

BELKHOURIBCHIA, J. et al. Large language models in clinical nutrition: an overview of its opportunities and challenges. **Frontiers in Nutrition**, 2025. Disponível em: <https://www.frontiersin.org/journals/nutrition/articles/10.3389/fnut.2025.1635682/full>.1635682/full. Acesso em: 01 nov. 2025

CRISPIM, Sandra Patricia et al. **Manual de quantificação alimentar**: álbum fotográfico. São Paulo: Faculdade de Saúde Pública – USP, Núcleo de Pesquisas Epidemiológicas em Nutrição e Saúde, 2019. Disponível em: https://nutritotal.com.br/pro/wp-content/uploads/2019/02/manual_quantificacao_alimentar-compactado-1.pdf. Acesso em: 15 abr. 2025.

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. 617-624, jul. 2009. Disponível em: <https://www.scielo.br/j/abem/a/y96PnbFww5kJDSfdYfpDsqi/>. Acesso em: 28 maio 2025.

LO, Frank P-W et al. Dietary assessment with multimodal ChatGPT: a systematic analysis. **IEEE Journal of Biomedical and Health Informatics**, v. 28, n. 12, p. 7577–7587, dez. 2024. DOI: 10.1109/JBHI.2024.3417280. Disponível em: <https://ieeexplore.ieee.org/document/10565946>. Acesso em: 01 nov. 2025

LU, Y. GoFOOD™: an artificial intelligence system for dietary assessment. **Sensors**, v. 20, n. 15, p. 4283, 2020. DOI: 10.3390/s20154283. Disponível em: <https://www.mdpi.com/1424-8220/20/15/4283>. Acesso em: 13 nov. 2025

MINISTÉRIO DA SAÚDE. INSTITUTO NACIONAL DE ALIMENTAÇÃO E NUTRIÇÃO. SECRETARIA DE PROGRAMAS ESPECIAIS. **Manual fotográfico**: utensílios e porções alimentares – ISACamp-Nutri 2014. Campinas: UNICAMP, 2014. Disponível em: <https://pt.scribd.com/document/853514579/Medidas-caseiras-manual-fotografico>. Acesso em: 30 abr. 2025.

PAPATHANAIL, Ioannis et al. Evaluation of a novel artificial intelligence system to monitor and assess energy and macronutrient intake in hospitalised older patients. **Nutrients**, v. 13, n. 12, p. 4539, 17 dez. 2021. Disponível em: <https://doi.org/10.3390/nu13124539>. Acesso em: 13 nov. 2025

SILVA, T. F.; SOUZA, A. M. Validação de um questionário de frequência alimentar para adultos. **Revista de Nutrição**, v. 34, e190045, 2021. Disponível em: <https://www.scielo.br/j/rn/a/gbMCtkzHTF5J48RJVNbB87J>. Acesso em: 28 maio 2025.

SHONKOFF, Eleanor et al. AI-based digital image dietary assessment methods compared to humans and ground truth: a systematic review. **Annals of Medicine**, v. 55, n. 2, 2023. DOI: 10.1080/07853890.2023.2273497. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10836267/>. Acesso em: 18 nov. 2025

TAHIR, Ghalib Ahmed; LOO, Chu Kiong. A comprehensive survey of image-based food recognition and volume estimation methods for dietary assessment. **Healthcare**, v. 9, n. 12, p. 1676, 2021. DOI: 10.3390/healthcare9121676. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/34946400/>. Acesso em: 25 nov. 2025