



UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ - UNIOESTE

CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS - CCET

Programa de Pós-Graduação em Ciência da Computação - PPGComp

Um Sistema de Recomendação para Nutrição Oncológica baseado em Decisão Multicritério

Dissertação (Mestrado)

Lucas Soares da Silva



PPGComp

Cascavel-PR

2025

UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ - UNIOESTE
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS - CCET
Programa de Pós-Graduação em Ciência da Computação - PPGComp

Lucas Soares da Silva

**Um Sistema de Recomendação para Nutrição Oncológica
baseado em Decisão Multicritério**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre em Ciência da Computação, do Programa de Pós-Graduação em Ciência da Computação da Universidade Estadual do Oeste do Paraná - Campus de Cascavel.

Orientador(a): Dr. Fabio Alexandre Spanhol
Coorientador(a): Dr. Thiago Henrique Pereira Silva

Cascavel-PR

2025

Ficha de identificação da obra elaborada através do Formulário de Geração Automática do Sistema de Bibliotecas da Unioeste.

Silva, Lucas Soares da
: Um Sistema de Recomendação para Nutrição Oncológica baseado em Decisão Multicritério / Lucas Soares da Silva; orientador Fabio Alexandre Spanhol; coorientador Thiago Henrique Pereira Silva. -- Cascavel, 2025.
112 p.

Dissertação (Mestrado Acadêmico Campus de Cascavel) -- Universidade Estadual do Oeste do Paraná, Centro de Ciências Exatas e Tecnológicas, Programa de Pós-Graduação em Ciências da Computação, 2025.

1. Recomendações nutricionais. 2. Sistemas de recomendação. 3. otimização combinatória. 4. multicritério. I. Spanhol, Fabio Alexandre, orient. II. Silva, Thiago Henrique Pereira, coorient. III. Título.

LUCAS SOARES DA SILVA

**UM SISTEMA DE RECOMENDAÇÃO PARA NUTRIÇÃO ONCOLÓGICA
BASEADO EM DECISÃO MULTICRITÉRIO**

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre pelo Programa de Pós-Graduação em Ciência da Computação (PPGComp) da Universidade Estadual do Oeste do Paraná – Unioeste, campus de Cascavel, aprovada pela Comissão formada pelos professores:

Prof. Dr. Fabio Alexandre Spanhol (Orientador)
Colegiado de Programa de Pós-Graduação em
Ciência da Computação, UNIOESTE

Prof. Dr. Thiago Henrique Pereira Silva
(Coorientador)
Universidade Federal de Uberlândia

Prof. Dr. André Luiz Brun
Colegiado de Programa de Pós-Graduação em
Ciência da Computação, UNIOESTE

Prof. Dr. Sidgley Camargo de Andrade
Colegiado de Programa de Pós-Graduação em
Ciência da Computação, UNIOESTE

Cascavel, 21 de março de 2025

Este trabalho é dedicado aos heróis de suas próprias histórias.

Agradecimentos

Agradeço aos meus pais Gilso e Sirlei que sempre me apoiaram nos momentos importantes.

Agradeço a minha esposa Kalen que acredita mais em mim do que eu mesmo.

Agradeço aos meus orientadores Dr. Fabio e Dr. Thiago pelo conhecimento compartilhado.

Agradeço também a todos os professores do PPGComp que fizeram parte dessa jornada.

Agradeço a todos os amigos, familiares e colegas de trabalho que de uma forma ou de outra me fizeram continuar.

*Ainda não comi frutos suficientes da Árvore do Conhecimento,
embora na minha profissão eu seja obrigado a comê-los regularmente.*
(Albert Einstein)

Resumo

SILVA, Lucas Soares da. **Um Sistema de Recomendação para Nutrição Oncológica baseado em Decisão Multicritério**. Orientador: Dr. Fabio Alexandre Spanhol. 2025. 112f. Dissertação (Mestrado em Ciência da Computação) – Universidade Estadual do Oeste do Paraná, Cascavel – Paraná, 2025.

Pacientes oncológicos enfrentam desafios metabólicos, imunológicos e bioquímicos que frequentemente resultam em desnutrição, comprometendo tanto a eficácia do tratamento quanto a qualidade de vida. Nesse contexto, uma abordagem personalizada e multidisciplinar, como o uso de sistemas de recomendação, se apresenta como uma ferramenta valiosa para auxiliar profissionais de nutrição na elaboração de planos alimentares adaptados às necessidades específicas de cada paciente. Nesse sentido, este trabalho aplica um sistema de recomendação multicritério voltado para pacientes oncológicos, utilizando dados nutricionais de alimentos e a geração de dados sintéticos para criar perfis personalizados. Os modelos computacionais desenvolvidos, utilizando as abordagens TOPSIS e NSGA-II, foram capazes de gerar recomendações alimentares que atendem a metas nutricionais individuais, respeitando todas as restrições necessárias. Além disso, foi implementado um método para geração de dados sintéticos, permitindo a criação de perfis personalizados de pacientes oncológicos. Em complemento ao trabalho dos profissionais da área de nutrição, as abordagens propostas podem contribuir para a recomendação de dietas para pacientes oncológicos.

Palavras-chave: Câncer; Recomendações nutricionais; Sistemas de recomendação multicritério; TOPSIS; NSGA-II

Abstract

SILVA, Lucas Soares da. **A Recommendation System for Oncological Nutrition Based on Multicriteria Decision.** Orientador: Dr. Fabio Alexandre Spanhol. 2025. 112f. Dissertação (Mestrado em Ciência da Computação) – Universidade Estadual do Oeste do Paraná, Cascavel – Paraná, 2025.

Oncological patients face metabolic, immunological, and biochemical challenges that often lead to malnutrition, compromising both treatment effectiveness and quality of life. In this context, a personalized and multidisciplinary approach, such as the use of recommendation systems, emerges as a valuable tool to assist nutrition professionals in developing dietary plans tailored to each patient's specific needs. This study applies a multi-criteria recommendation system for oncological patients, utilizing nutritional data from foods and synthetic data generation to create personalized profiles. The computational models developed, using the TOPSIS and NSGA-II approaches, successfully generated dietary recommendations that meet individual nutritional goals while adhering to all necessary restrictions. Additionally, a method for synthetic data generation was implemented, enabling the creation of personalized oncological patient profiles. Complementing the work of nutrition professionals, the proposed approaches can contribute to dietary recommendations for oncological patients.

Keywords: *Cancer; Nutritional recommendations; Multicriteria decision-making recommendation systems; TOPSIS; NSGA-II*

Lista de figuras

Figura 1 – Pirâmide dos alimentos	24
Figura 2 – Estimativas para o ano de 2023 das taxas brutas e ajustadas de incidência por 100 mil habitantes e do número de casos novos de câncer, segundo sexo e localização primária	26
Figura 3 – Distribuição proporcional dos dez tipos de câncer mais incidentes estimados para 2023 por sexo, exceto pele não melanoma	27
Figura 4 – Tipos de sistemas de recomendação	31
Figura 5 – Processo lógico dos sistemas de recomendação	33
Figura 6 – Modelo do Processo em 3 estágios	34
Figura 7 – A arquitetura geral para recomendação de alimentos.	43
Figura 8 – A arquitetura geral para recomendação de alimentos.	46
Figura 9 – Fluxo de Trabalho do Simulador de Pacientes Oncológicos.	56
Figura 10 – As 10 maiores ocorrências de alimentos no método TOPSIS	90
Figura 11 – Média de proteínas por paciente	90
Figura 12 – Média de carboidratos por paciente	91
Figura 13 – Média de lipídios por paciente	91
Figura 14 – Distribuição das medianas Nutricionais por paciente	93
Figura 15 – Comparação entre macronutrientes para todos os pacientes	94
Figura 16 – As 10 maiores ocorrências de alimentos no método NSGA-II	95
Figura 17 – Média de proteínas por paciente	95
Figura 18 – Média de carboidratos por paciente	96
Figura 19 – Média de lipídios por paciente	96
Figura 20 – Distribuição das medianas Nutricionais por paciente	97
Figura 21 – Comparação entre macronutrientes para todos os pacientes	98

Lista de quadros

Quadro 1 – Formulário Diagnóstico	52
---	----

Lista de tabelas

Tabela 1 – Geração de pacientes através de dados sintéticos	50
Tabela 2 – Estatísticas da Altura (cm) e Coeficiente de Variação (%) por Faixa Etária e Sexo (IBGE, 2019)	53
Tabela 3 – Simulador de Pacientes Oncológicos: Tipos de Dados e Métodos de Geração	54
Tabela 4 – Exemplo de Paciente Oncológico gerado por simulador	58
Tabela 5 – Grupos Alimentares Brasileiros	59
Tabela 6 – Recomendações nutricionais baseadas em medicamentos oncológicos.	65
Tabela 7 – Exemplo de Resultado com Informações de Alimentos	66
Tabela 8 – Paciente 1	72
Tabela 9 – Experimento 1 (TOPSIS): Segunda-feira	73
Tabela 10 – Experimento 1 (TOPSIS): Terça-feira	73
Tabela 11 – Experimento 1 (TOPSIS): Quarta-feira	73
Tabela 12 – Experimento 1 (TOPSIS): Quinta-feira	74
Tabela 13 – Experimento 1 (TOPSIS): Sexta-feira	74
Tabela 14 – Experimento 1 (NSGA-II): Segunda-feira	75
Tabela 15 – Experimento 1 (NSGA-II): Terça-feira	75
Tabela 16 – Experimento 1 (NSGA-II): Quarta-feira	76
Tabela 17 – Experimento 1 (NSGA-II): Quinta-feira	76
Tabela 18 – Experimento 1 (NSGA-II): Sexta-feira	77
Tabela 19 – Paciente 2	78
Tabela 20 – Experimento 2 (TOPSIS): Segunda-feira	79
Tabela 21 – Experimento 2 (TOPSIS): Terça-feira	79
Tabela 22 – Experimento 2 (TOPSIS): Quarta-feira	79
Tabela 23 – Experimento 2 (TOPSIS): Quinta-feira	80
Tabela 24 – Experimento 2 (TOPSIS): Sexta-feira	80
Tabela 25 – Experimento 2 (NSGA-II): Segunda-feira	81
Tabela 26 – Experimento 2 (NSGA-II): Terça-feira	81
Tabela 27 – Experimento 2 (NSGA-II): Quarta-feira	82
Tabela 28 – Experimento 2 (NSGA-II): Quinta-feira	82
Tabela 29 – Experimento 2 (NSGA-II): Sexta-feira	83
Tabela 30 – Paciente 3	84
Tabela 31 – Experimento 3 (TOPSIS): Segunda-feira	85
Tabela 32 – Experimento 3 (TOPSIS): Terça-feira	85
Tabela 33 – Experimento 3 (TOPSIS): Quarta-feira	85
Tabela 34 – Experimento 3 (TOPSIS): Quinta-feira	86
Tabela 35 – Experimento 3 (TOPSIS): Sexta-feira	86

Tabela 36 – Experimento 3 (NSGA-II): Segunda-feira	87
Tabela 37 – Experimento 3 (NSGA-II): Terça-feira	87
Tabela 38 – Experimento 3 (NSGA-II): Quarta-feira	87
Tabela 39 – Experimento 3 (NSGA-II): Quinta-feira	88
Tabela 40 – Experimento 3 (NSGA-II): Sexta-feira	88
Tabela 41 – Shapiro–Wilk nas diferenças “real – target”	100
Tabela 42 – Comparação entre os Métodos NSGA-II e TOPSIS	102

Lista de abreviaturas e siglas

AHP *Analytic Hierarchy Process*. 42

BWM *Best Worst Method*. 42

CSV *Comma Separated Valued*. 71

DCNT Doença Crônica Não Transmissível. 19, 25

DEMATEL *Decision-Making Trial and Evaluation Laboratory*. 42

DNTs Doenças Não Transmissíveis. 25

EML Lista Modelo de Medicamentos Essenciais. 64

FAO *Food and Agriculture Administration*. 59

GAN *Generative Adversarial Network*. 50

HRS Sistema de Recomendação Híbrido. 44

HTFRS Sistema de Recomendação de Alimentos Saudáveis e Sensível ao Tempo. 44–46

IA Inteligência Artificial. 104

IBGE Instituto Brasileiro de Geografia e Estatística. 54

IDH Índice de Desenvolvimento Humano. 25

IL-6 Interleucina-6. 28

IMC Índice de Massa Corporal. 57, 60

INCA Instituto Nacional do Câncer José de Alencar. 21, 25, 27, 53, 54

INFOODS International Network of Food Data Systems. 58

IR-HD Recomendador Inteligente para Dieta Saudável. 44

IRQ Intervalo Interquartilico. 92, 97

KCAL *quilocalorias*. 23, 59

LLM *Large Language Model*. 50, 104

MCDA *Multi-Criteria Decision Analysis*. 42

MCDM *Multi-criteria Decision Making*. 20, 21, 42

MS Ministério da Saúde. 25

NERVE *Ambiente Virtual de Ensaio de Exame Neurológico*. 50

NLP Processamento de Linguagem Natural. 44

NSGA-II *Non-dominated Sorting Genetic Algorithm II*. 17, 21, 35, 38, 40, 51, 67–70, 77, 80, 83, 86, 88, 89, 94–98, 101–103

OMS Organização Mundial da Saúde. 19, 25, 64

PIF Fator Indutor de Proteólise. 28

PLN Processamento de Linguagem Natural. 104

PROMETHEE *Preference Ranking Organization Method for Enrichment of Evaluations*. 42

RENAME Relação Nacional de Medicamentos Essenciais. 64

SBX *Simulated Binary Crossover* . 69

SIDNIE *Entrevistas Estruturadas Desenvolvidas por Enfermeiras na Educação*. 50

SR Sistema de Recomendação. 30, 32, 33, 47, 69

SRS Sistemas de Recomendação de Saúde. 33

TACO Tabela Brasileira de Composição de Alimentos. 58

TBCA Tabela Brasileira de Composição de Alimentos. 21, 34, 58, 59, 69, 71

TMB Taxa Metabólica Basal. 24, 56, 57, 66, 68, 69, 98

TNE Terapia Nutricional Enteral. 29

TNF- α Fator de Necrose Tumoral Alfa. 28

TNO Terapia Nutricional Oral. 29

TNP Terapia Nutricional Parental. 29

TOPSIS *Technique for Order Preference by Similarity to Ideal Solution*. 17, 21, 35–38, 42, 51, 66–68, 70, 72, 74, 78, 80, 84, 86, 88–93, 98–103

UNU *United Nations University*. 59

USP Universidade de São Paulo. 58

Sumário

1	Introdução	19
1.1	Objetivos	21
1.1.1	Objetivos específicos	21
1.2	Estrutura do Trabalho	22
2	Fundamentação	23
2.1	Pirâmide Alimentar	23
2.2	Câncer	25
2.2.1	Incidência do Câncer no Brasil	25
2.2.2	Câncer e Nutrição	27
2.3	Nutrição Oncológica	28
2.4	O “Problema da Dieta” na Computação	29
2.5	Sistemas de Recomendação	30
2.5.1	Sistemas de Recomendação Não Personalizados	31
2.5.2	Sistemas de Recomendação Personalizados	32
2.5.3	Sistemas de Recomendação Multicritério	33
2.5.4	Métodos de Tomada de Decisão Multicritério	35
2.5.4.1	TOPSIS	35
2.5.4.2	NSGA-II	37
3	Trabalhos Relacionados	41
3.1	Recomendação de Dietas Personalizadas	41
3.2	Geração de Dados Artificiais de Pacientes	49
3.2.1	Procedimento	49
3.2.1.1	Crítérios de Inclusão e Exclusão	49
3.2.1.2	Bases de Dados Utilizadas	49
3.2.1.3	Estratégia de Busca	49
3.2.2	Compilação dos Resultados	50
4	Abordagens para Recomendação e Geração de Dados	51
4.1	Ambiente e Ferramentas	51
4.2	Simulação de Dados de Pacientes Oncológicos	52
4.2.1	Fluxo de Geração	56
4.2.2	Geração de Dados Sintéticos	57
4.2.2.1	Exemplo de Perfil Sintético Gerado	58
4.3	Tratamento e Composição dos Dados de Alimentos	58

4.3.1	Calculadora de Necessidades Nutricionais	59
4.3.1.1	Pseudocódigo da Calculadora de Macronutrientes	62
4.3.2	Verificar Alergias, Intolerâncias e Incompatibilidades	63
4.3.2.1	Filtro de Alergias	63
4.3.2.2	Filtro de Alimentos Indigestos	64
4.3.2.3	Filtro de Intolerâncias	64
4.3.2.4	Filtro de Incompatibilidades Oncológicas	64
4.3.2.5	Restrições devido a medicação	64
4.4	Gerador de Dietas para Pacientes Oncológicos	65
4.4.1	Função Objetivo	65
4.4.2	Principais Soluções	67
4.4.2.1	Solução Multicritério	67
4.4.2.2	Solução Multiobjetivo	68
5	Resultados e Discussão	70
5.1	Experimentos	70
5.1.1	Experimento 1	71
5.1.1.1	Resultados do Método TOPSIS	72
5.1.1.2	Resultados do Método NSGA-II	74
5.1.2	Experimento 2	77
5.1.2.1	Resultados do Método TOPSIS	78
5.1.2.2	Resultados do Método NSGA-II	80
5.1.3	Experimento 3	83
5.1.3.1	Resultados do Método TOPSIS	84
5.1.3.2	Resultados do Método NSGA-II	86
5.2	Avaliação	88
5.2.1	Informações geradas a partir do método TOPSIS	89
5.2.2	Informações geradas a partir do método NSGA-II	94
5.3	Análise dos Resultados	98
5.3.1	Análise Estatística das Diferenças em Relação às Recomendações Nutri- cionais	99
5.3.1.1	Resultados do Teste de Normalidade (Shapiro–Wilk)	100
5.3.1.2	Comparação das Médias: Teste <i>t</i> de Uma Amostra e <i>Wilcoxon</i>	100
5.3.1.3	Interpretação dos Resultados	101
5.3.2	Comparação entre os Métodos <i>Technique for Order Preference by Si- milarity to Ideal Solution (TOPSIS)</i> e <i>Non-dominated Sorting Genetic Algorithm II (NSGA-II)</i>	101
5.4	Limitações do Estudo	102
6	Considerações Finais	103

6.1	Conclusões	103
6.2	Trabalhos Futuros	104
	Referências	106

1

Introdução

De acordo com a [Organização Mundial da Saúde \(OMS\)](#), o uso de tabaco, a falta de atividade física regular, o consumo de álcool em excesso e a adoção de dietas pobres em nutrientes e ricas em alimentos processados são fatores que têm sido associados a um aumento significativo no risco de morte por [Doenças Crônicas Não Transmissíveis \(DCNTs\)](#) ([OMS, 2020](#)). Essas doenças, como as condições cardíacas, o câncer, o diabetes e as doenças respiratórias crônicas, representam uma parcela substancial da carga global de doenças e são responsáveis por um número significativo de mortes anualmente. De acordo com [NILSON et al. \(2020\)](#), na América Latina, incluindo o Brasil, as dietas inadequadas - caracterizadas pelo baixo consumo de cereais, frutas e hortaliças, além do excesso de nutrientes críticos - estão entre os principais fatores de risco para [DCNTs](#). Esses fatores dietéticos estão diretamente associados ao crescimento do consumo de ultraprocessados: de 2000 a 2013, o volume comercializado de ultraprocessados cresceu 43,7% em todo o mundo e 48% na América Latina ([FOOD, 2015](#); [NILSON et al., 2020](#)).

Além dos efeitos diretos da doença, muitas condições também acarretam consequências secundárias significativas. Em particular, pacientes oncológicos enfrentam um alto risco de desnutrição ([AUGUST et al., 2009](#)). Destaca-se a importância crucial do acompanhamento nutricional, além de outros cuidados paliativos. No Brasil, a Lei nº 8.234/1991 estabelece que a prescrição de dietas é uma atribuição exclusiva dos profissionais de nutrição, ressaltando a necessidade de intervenções especializadas para garantir a adequada alimentação e nutrição desses pacientes ([BRASIL, 1991](#)).

Entre os diversos desafios enfrentados por pacientes com doenças graves, a nutrição desempenha um papel vital no cuidado abrangente de pacientes oncológicos, tanto durante o tratamento ativo quanto nos estágios avançados da doença ([ARENDS et al., 2017](#)). Uma alimentação adequada pode contribuir significativamente para a qualidade de vida e o bem-estar desses indivíduos, fornecendo suporte nutricional essencial para enfrentar os desafios físicos e emocionais associados ao câncer. Para os pacientes em tratamento oncológico, uma nutrição

balanceada é essencial para ajudar a manter a força física, a energia e a imunidade necessárias para enfrentar os desafios associados à terapia, como quimioterapia, radioterapia e cirurgias. Durante esse período, é comum ocorrerem efeitos colaterais que podem afetar o apetite, a digestão e a absorção de nutrientes, como náuseas, vômitos, mucosite e perda de peso (PRADO et al., 2009). Nesses casos, estratégias nutricionais específicas, como a adaptação da consistência dos alimentos, a escolha de alimentos ricos em nutrientes e a suplementação nutricional, podem ajudar a manter o estado nutricional adequado e a minimizar complicações (PEREIRA, 2024).

Nesse contexto, enquanto uma abordagem de dieta generalizada pode falhar, a nutrição personalizada pode beneficiar consumidores a aderirem a uma alimentação saudável e prazerosa, pois a dieta está intimamente associada a parâmetros individuais como as características físicas e psicológicas, incluindo estado de saúde, fenótipo e genótipo, necessidades e preferências, comportamento, estilo de vida, bem como orçamento (TOLEDO; ALZHRANI; MARTINEZ, 2019).

Considerando a diversidade de fatores que influenciam a nutrição personalizada, soluções computacionais aplicadas à saúde podem auxiliar profissionais capacitados a atender às demandas de cada paciente. Ao longo dos anos, diversas soluções computacionais foram propostas para a construção de sistemas de recomendação de alimentação saudável, como pode ser visto em (ESPÍN; HURTADO; NOGUERA, 2016; RIBEIRO et al., 2017; YANG et al., 2017; AGAPITO et al., 2018). A maioria dos estudos não é focada nas preferências do usuário e a incorporação de conceitos e princípios nutricionais nos modelos computacionais não é suficientemente profunda, tendo como a principal causa o combate à obesidade (TOLEDO; ALZHRANI; MARTINEZ, 2019).

Os sistemas de recomendação multicritério surgem como alternativas promissoras para cenários de pesquisa complexos, onde diversas variáveis estão envolvidas, pois visam identificar itens que maximizem a utilidade de cada usuário, oferecendo uma abordagem mais precisa e personalizada na recomendação de conteúdos (ADOMAVICIUS; KWON, 2007).

De acordo com Tzeng e Huang (2011), os métodos de *Multi-criteria Decision Making* (MCDM) são ferramentas eficazes para a análise de decisões complexas envolvendo múltiplos critérios. Mais especificamente, se mostraram como opções viáveis para integrar dados alimentares com restrições dos pacientes, permitindo avaliar aspectos como adequação nutricional e preferências individuais para oferecer prescrições mais personalizadas.

Segundo Fu, Xue e Chang (2022), os métodos MCDM são definidos pela *International MCDM Society MCDM* (2022) como o estudo de técnicas e procedimentos voltados para a tomada de decisão em contextos onde há múltiplos critérios, muitas vezes conflitantes, que podem ser formalmente incorporados ao processo de planejamento e gestão (KOU; PENG, 2009). O objetivo do MCDM é escolher a melhor alternativa de um conjunto de candidatos ou ordenar alternativas em uma pré-ordem de preferência por avaliar um conjunto finito de alternativas com base em dois ou mais critérios (FU; XUE; CHANG, 2022). Desta forma, é possível resumir o

objetivo das decisões multicritério como sendo selecionar a melhor opção entre várias alternativas ou classificá-las em uma ordem de preferência pré-determinada. Como resultado, avalia-se um conjunto finito de alternativas com base em dois ou mais critérios.

Considerando as características dos [MCDM](#), assume-se que seja possível aplicar as técnicas no contexto de sistemas de recomendação nutricionais, pois são sistemas que poderiam gerar dietas de acordo com as restrições do paciente a partir de um conjunto pré-definido de grupos alimentares.

1.1 Objetivos

Esta pesquisa buscou responder à seguinte questão: **Um modelo computacional pode auxiliar profissionais da área de nutrição oncológica a elaborar dietas personalizadas de acordo com as necessidades e restrições dos pacientes?**

Assim, o objetivo principal deste trabalho foi construir e avaliar um modelo computacional de sistema de recomendação personalizado, baseado em métodos de decisão multicritério, aplicado à área de Nutrição Oncológica, com a finalidade de agilizar o processo de cuidados paliativos. Esse sistema poderá auxiliar profissionais de nutrição oncológica na definição de uma dieta que atenda aos objetivos do tratamento e ofereça menores riscos aos pacientes, evitando possíveis violações de restrições.

Neste trabalho, optou-se por utilizar exclusivamente a [Tabela Brasileira de Composição de Alimentos \(TBCA\)](#), pois ela reúne alimentos amplamente disponíveis em diversas regiões do país e fornece, de forma simplificada e gratuita, todas as informações necessárias para a pesquisa. Além disso, um simulador foi desenvolvido considerando os tipos de câncer mais incidentes no Brasil, como os cânceres de próstata, mama, cólon e reto, conforme levantamento do [Instituto Nacional do Câncer José de Alencar \(INCA\)](#) (INCA, 2022).

Como sistema de recomendação, o modelo computacional aplicado à nutrição oncológica foi desenvolvido com duas abordagens distintas: [TOPSIS](#), um método de análise multicritério que identifica a alternativa mais próxima da solução ideal, e [NSGA-II](#), um algoritmo genético que otimiza simultaneamente múltiplos objetivos por meio da consideração de soluções não dominadas. Notadamente, ambas soluções geraram resultados que atendem de forma criteriosa às necessidades nutricionais dos pacientes, respeitando suas restrições alimentares.

1.1.1 Objetivos específicos

Os objetivos específicos deste trabalho foram definidos da seguinte forma:

- Desenvolver e validar um simulador para a geração de dados representativos de pacientes oncológicos.

- Projetar e implementar um modelo computacional capaz de recomendar dietas personalizadas para pacientes oncológicos, considerando restrições alimentares e necessidades nutricionais específicas.
- Avaliar a eficácia do modelo como uma ferramenta de apoio à nutrição oncológica.

1.2 Estrutura do Trabalho

O restante do texto está organizado da seguinte forma. O Capítulo 2 apresenta os principais conceitos básicos para o entendimento do presente trabalho. A seguir, o Capítulo 3 discute os principais trabalhos relacionados. Em seguida, o Capítulo 4 descreve abordagens para recomendação e geração de dados sintéticos adotadas. Já o Capítulo 5 apresenta e discute os resultados. E, finalmente, o Capítulo 6 traz as considerações finais deste trabalho.

2

Fundamentação

Este capítulo apresenta os principais conceitos e dados atualizados acerca do câncer, explorando suas implicações epidemiológicas, nutricionais e tecnológicas. Inicialmente, aborda-se os aspectos clínicos e estatísticos da doença, destacando sua elevada incidência mundial e os desafios específicos do cenário brasileiro, com ênfase nas variações regionais e nas estratégias de prevenção e tratamento. Em seguida, discute-se a nutrição oncológica, evidenciando a importância de abordagens personalizadas para o suporte nutricional dos pacientes durante o tratamento. Por fim, apresenta-se os sistemas de recomendação, destacando como a integração de conhecimentos das áreas de saúde, alimentação e computação pode gerar soluções inovadoras para otimizar a assistência nutricional.

2.1 Pirâmide Alimentar

A pirâmide alimentar é uma representação gráfica que orienta a distribuição equilibrada dos grupos alimentares na dieta diária. No Brasil, ela foi adaptada para refletir os hábitos e a cultura alimentar da população, estruturando oito grupos alimentares – como cereais e tubérculos, leguminosas e verduras, frutas, leite e derivados, carnes e ovos, feijões e oleaginosas, óleos e gorduras, açúcares e doces – e estabelecendo a quantidade recomendada de porções para cada um (PHILIPPI, 2008). Além disso, os alimentos foram organizados em medidas usuais, com seus respectivos pesos em gramas, facilitando a compreensão e aplicação das recomendações nutricionais.

Philippi (2013) destaca que os nomes dos grupos de alimentos na pirâmide brasileira foram definidos com base na identidade da população em relação aos alimentos presentes em cada grupo, considerando tanto os hábitos alimentares quanto o valor nutritivo. Além disso, os valores das porções foram apresentados em gramas, *quilocalorias (KCAL)* e medidas usuais, facilitando o entendimento da população e a transmissão das orientações nutricionais.

Nota-se que esse modelo organiza os grupos alimentares e suas respectivas porções em camadas. As camadas mais próximas à base correspondem a porções mais generosas (e.g., seis porções para o grupo de cereais e tubérculos, que inclui alimentos como arroz, pão e batata), enquanto o topo da pirâmide indica os alimentos que devem ser consumidos com parcimônia, como aqueles do grupo de óleos e gorduras, além de açúcares e doces. Assim, a pirâmide facilita a compreensão de uma alimentação equilibrada, considerando os hábitos alimentares e a disponibilidade de alimentos para atender às necessidades nutricionais da população brasileira.

A Figura 1 ilustra um modelo de pirâmide de alimentos adaptada por [Philippi \(2013\)](#) e voltada para uma dieta de 2.000 calorias.

Figura 1 – Pirâmide dos alimentos



Fonte: Adaptado de ([PHILIPPI, 2013](#))

Além da organização dos grupos alimentares e das porções recomendadas, a compreensão das necessidades energéticas do organismo é de interesse para orientar uma alimentação equilibrada. Conforme apontado por [Wahrlich e Anjos \(2001\)](#), um dos conceitos principais é a **Taxa Metabólica Basal (TMB)**, que corresponde à quantidade de energia necessária para a manutenção das funções vitais do organismo. Sua medição é realizada em condições padronizadas de jejum, repouso físico e mental, em um ambiente tranquilo, com controle de temperatura, iluminação e ausência de ruídos ([HARRIS; BENEDICT, 1918](#); [BURSZTEIN et al., 1989](#)).

2.2 Câncer

O termo “câncer” abrange uma vasta gama de mais de cem tipos distintos de doenças, todas elas compartilhando a característica fundamental de um crescimento celular descontrolado (neoplasia). Tais células proliferam rapidamente, sendo agressivas e incontroláveis, levando à formação de tumores que podem invadir tecidos vizinhos ou órgãos mais distantes, podendo-se espalhar para outras partes do corpo (INCA, 2022). Homens frequentemente enfrentam câncer de pulmão, próstata, colorretal, estômago e fígado, enquanto mulheres têm maior incidência de câncer de mama, colorretal, pulmão, cervical e tireoide (OMS, 2020).

O câncer enquadra-se no grupo das **Doenças Não Transmissíveis (DNTs)**, também conhecida como **DCNT**, tendem a ser de longa duração e são o resultado de uma combinação de fatores genéticos, fisiológicos, ambientais e comportamentais (OMS, 2020). Mais precisamente, a **OMS** define como **DCNT** as doenças cardiovasculares (cerebrovasculares, isquêmicas), as neoplasias, as doenças respiratórias crônicas e diabetes *mellitus*, são doenças não transmissíveis de pessoa para pessoa (BRASIL et al., 2008).

Dados recentes da **OMS** indicam que o câncer é a segunda principal causa de morte em todo o mundo, sendo responsável por aproximadamente 9,6 milhões de óbitos, representando um em cada seis óbitos em 2018. Em países com alto **Índice de Desenvolvimento Humano (IDH)**, as taxas de sobrevivência de muitos tipos de câncer estão melhorando graças à detecção precoce acessível, tratamento de qualidade e cuidados pós-tratamento. As últimas atualizações incluem tendências globais, regionais e por país de 2000 a 2019. A próxima atualização dessas estimativas incluirá uma avaliação do impacto direto e indireto da pandemia de COVID-19 na mortalidade e morbidade (OMS, 2020).

No Brasil, o câncer também é um problema de saúde preocupante. Estimativas do **Ministério da Saúde (MS)** e do **INCA** apontam para 704 mil novos casos de câncer diagnosticados para o triênio 2023-2025 (INCA, 2022).

2.2.1 Incidência do Câncer no Brasil

Esta seção apresenta uma síntese das estimativas de incidência para cada ano do triênio 2023-2025 no Brasil, acompanhada de breves comentários sobre os diferentes tipos de câncer considerados nesta projeção (INCA, 2022).

A Figura 2 apresenta as estimativas de incidência de câncer no Brasil para o ano de 2023, destacando os tipos mais frequentes entre homens e mulheres, excluindo câncer de pele. Entre os homens, o câncer de próstata apresenta a maior incidência, com uma estimativa de 71.730 casos, seguido pelo câncer de cólon e reto (21.970 casos), traqueia, brônquio e pulmão (18.020 casos) e estômago (13.340 casos). Já entre as mulheres, o câncer de mama é o mais prevalente, com 73.610 casos previstos, seguido pelo câncer de cólon e reto (23.660 casos), colo do útero (17.010 casos) e traqueia, brônquio e pulmão (14.540 casos).

Figura 2 – Estimativas para o ano de 2023 das taxas brutas e ajustadas de incidência por 100 mil habitantes e do número de casos novos de câncer, segundo sexo e localização primária

LOCALIZAÇÃO PRIMÁRIA NEOPLASIA MALIGNA	ESTIMATIVA DOS CASOS NOVOS								
	Homens			Mulheres			Total		
	Casos	Taxa bruta	Taxa ajustada	Casos	Taxa bruta	Taxa ajustada	Casos	Taxa bruta	Taxa ajustada
Mama feminina	-	-	-	73.610	66,54	41,89	73.610	66,54	41,89
Próstata	71.730	67,86	55,49	-	-	-	71.730	67,86	55,49
Cólon e reto	21.970	20,78	12,43	23.660	21,41	11,06	45.630	21,10	11,43
Traqueia, brônquio e pulmão	18.020	17,06	12,73	14.540	13,15	9,26	32.560	15,06	10,52
Estômago	13.340	12,63	9,51	8.140	7,36	4,92	21.480	9,94	7,08
Colo do útero	-	-	-	17.010	15,38	13,25	17.010	15,38	13,25
Glândula tireoide	2.500	2,33	1,84	14.160	12,79	6,68	16.660	7,68	4,83
Cavidade oral	10.900	10,30	7,64	4.200	3,83	2,61	15.100	6,99	4,95
Linfoma não Hodgkin	6.420	6,08	4,55	5.620	5,08	3,00	12.040	5,57	3,79
Leucemias	6.250	5,90	4,75	5.290	4,78	3,95	11.540	5,33	4,43
Sistema nervoso central	6.110	5,80	4,56	5.380	4,85	3,80	11.490	5,31	4,33
Bexiga	7.870	7,45	3,96	3.500	3,14	1,58	11.370	5,25	2,75
Esôfago	8.200	7,76	5,46	2.790	2,49	1,43	10.990	5,07	3,38
Pâncreas	5.290	5,00	3,74	5.690	5,15	3,22	10.980	5,07	3,31
Fígado	6.390	6,06	5,18	4.310	3,89	3,14	10.700	4,95	4,29
Pele melanoma	4.640	4,37	2,24	4.340	3,90	1,56	8.980	4,13	1,88
Corpo do útero	-	-	-	7.840	7,08	4,13	7.840	7,08	4,13
Laringe	6.570	6,21	5,07	1.220	1,09	0,72	7.790	3,59	2,68
Ovário	-	-	-	7.310	6,62	5,01	7.310	6,62	5,01
Linfoma de Hodgkin	1.500	1,40	0,84	1.580	1,41	0,78	3.080	1,41	0,75
Outras localizações	41.730	39,49	26,17	33.970	30,69	19,70	75.700	34,99	21,96
Todas as neoplasias, exceto pele não melanoma	239.430	226,56	185,61	244.160	220,75	154,08	483.590	223,59	169,63
Pele não melanoma	101.920	96,44	-	118.570	107,21	-	220.490	101,95	-
Todas as neoplasias	341.350	323,00	-	362.730	327,96	-	704.080	325,53	-

*População-padrão mundial (1960). / *Números arredondados para múltiplos de 10.

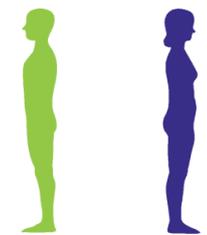
Fonte: (INCA, 2022)

No que diz respeito às questões geográficas, segundo o relatório do INCA (2022), os números compilados evidenciam variações regionais e padrões de risco, com destaque para a maior concentração de casos nas regiões Sudeste e Sul, tradicionalmente associadas a fatores como maior urbanização e acesso ao diagnóstico. A taxa ajustada por 100 mil habitantes reflete a gravidade de tipos específicos, como o câncer de mama em mulheres (41,89) e próstata em homens (55,49). No total, todas as neoplasias somam 704.080 casos estimados no país, reforçando a necessidade de estratégias de prevenção e controle para mitigar o impacto da doença.

Para enfatizar os tipos de câncer mais comuns entre homens e mulheres, a Figura 3 apresenta a proporção dos dez tipos de câncer mais incidentes no Brasil, excluindo o câncer de pele não melanoma. Observa-se que o câncer de próstata corresponde a 30% de todos os casos em homens, enquanto o câncer de mama tem uma proporção semelhante entre as mulheres, atingindo 30,1%. Além disso, o câncer de cólon e reto, assim como o de traqueia, brônquio e pulmão, são frequentes em ambos os gêneros. Destacam-se também tipos específicos além dos

mais prevalentes (próstata e mama), como o câncer de cavidade oral entre os homens e os de colo do útero e ovário entre as mulheres.

Figura 3 – Distribuição proporcional dos dez tipos de câncer mais incidentes estimados para 2023 por sexo, exceto pele não melanoma

Localização Primária	Casos	%			Localização Primária	Casos	%
Próstata	71.730	30,0%	Homens	Mulheres	Mama feminina	73.610	30,1%
Cólon e reto	21.970	9,2%			Cólon e reto	23.660	9,7%
Traqueia, brônquio e pulmão	18.020	7,5%			Colo do útero	17.010	7,0%
Estômago	13.340	5,6%			Traqueia, brônquio e pulmão	14.540	6,0%
Cavidade oral	10.900	4,6%			Glândula tireoide	14.160	5,8%
Esôfago	8.200	3,4%			Estômago	8.140	3,3%
Bexiga	7.870	3,3%			Corpo do útero	7.840	3,2%
Laringe	6.570	2,7%			Ovário	7.310	3,0%
Linfoma não Hodgkin	6.420	2,7%			Pâncreas	5.690	2,3%
Fígado	6.390	2,7%			Linfoma não Hodgkin	5.620	2,3%

*Números arredondados para múltiplos de 10.

Fonte: INCA (2022)

2.2.2 Câncer e Nutrição

De acordo com [Garófalo \(2012\)](#), há um consenso na comunidade científica de que a maioria dos cânceres em adultos está ligada a fatores ambientais, sugerindo a possibilidade de prevenção. Além disso, há reconhecimento de que o comportamento alimentar e a atividade física podem desempenhar papéis cruciais como fatores de proteção contra essa doença.

Evidências indicam que a alimentação desempenha um papel crucial na transformação de células normais em células cancerígenas, juntamente com outros fatores determinantes, como o tabagismo e o sedentarismo. De fato, a dieta e o tabaco são os principais contribuintes para as mortes por câncer atribuídas a fatores ambientais, seguidos por elementos como ocupação, consumo de álcool, poluição e aditivos alimentares. Acredita-se que uma dieta apropriada possa prevenir até 4 milhões de novos casos de câncer anualmente, reforçando a importância da alimentação como fator de proteção contra a doença ([GARÓFOLO, 2012](#))

Apesar do papel preventivo da alimentação, a desnutrição continua sendo um problema recorrente entre pacientes oncológicos. Um estudo realizado pelo Serviço de Nutrição do INCA em 2013 ([INCA, 2022](#)) demonstrou a alta prevalência de desnutrição no momento da internação em Unidades Hospitalares no Brasil ([SBNO, 2021](#)). Ademais, a desnutrição promove alterações morfológicas e funcionais. No pulmão, podem surgir atelectasias e pneumonias decorrentes da redução da massa muscular diafragmática e da redução dos níveis de concentração de lecitina nos alvéolos pulmonares em pacientes desnutridos ([SBNO, 2021](#)).

Considerando um cenário ainda mais desafiador, a desnutrição não apenas compromete o estado nutricional dos pacientes oncológicos, mas também pode aumentar o risco de complicações

no período pós-operatório. Como consequência, essa condição prolonga o tempo de internação, impacta negativamente a qualidade de vida e eleva os custos do tratamento (SBNO, 2021)

Diante dessas condições clínicas e nutricionais, torna-se essencial o desenvolvimento de protocolos criteriosos de assistência nutricional para pacientes com câncer, considerando as diferentes fases da doença e do tratamento. Esse aprimoramento visa otimizar os recursos disponíveis e melhorar a qualidade da atenção prestada a esses pacientes (SBNO, 2021).

2.3 Nutrição Oncológica

A nutrição oncológica é uma área especializada da nutrição que se concentra nas necessidades nutricionais específicas de pessoas que estão passando pelo tratamento do câncer. O objetivo principal da nutrição oncológica é garantir que os pacientes recebam a quantidade adequada de nutrientes para ajudar a apoiar o seu sistema imunológico, manter a força física e lidar com os efeitos colaterais comuns do tratamento, como perda de apetite, náuseas, vômitos, diarreia, constipação e perda de peso.

A desnutrição associada ao câncer é um problema global de saúde pública e está relacionada com a redução da qualidade de vida, da tolerância ao tratamento e da eficácia terapêutica. Além disso, a desnutrição aumenta o risco de complicações e os custos hospitalares, constituindo um importante fator de risco para a progressão da doença e da mortalidade (BAUER; CAPRA; FERGUSON, 2002; GUERRA et al., 2016).

O câncer desencadeia uma série de alterações metabólicas, incluindo modificações no metabolismo de carboidratos, intolerância à glicose, resistência periférica à insulina e mudanças no metabolismo de ácidos graxos e proteínas. Citocinas têm um papel significativo, induzindo aumento na lipólise e redução na síntese de ácidos graxos, resultando em elevação dos níveis de lipídios circulantes. Além disso, pacientes com câncer frequentemente experimentam perda massiva de músculo esquelético, impulsionada por citocinas como o **Fator de Necrose Tumoral Alfa (TNF- α)**, interleucina-1 beta, **Interleucina-6 (IL-6)**, interferon gama e **Fator Indutor de Proteólise (PIF)** (SBNO, 2021).

A desnutrição associada ao câncer não se limita ao aspecto metabólico, impactando diversos órgãos. No pulmão, por exemplo, pode levar a atelectasias e pneumonias devido à redução da massa muscular diafragmática e aos baixos níveis de lecitina nos alvéolos pulmonares. No fígado, a desnutrição provoca alterações como edema, atrofia dos hepatócitos, esteatose hepática e comprometimento funcional, limitando a capacidade de depuração de fármacos e síntese de albumina. O sistema gastrointestinal também é afetado, aumentando o risco de síndrome de má absorção, translocação intestinal de micro-organismos, hipocloridria e atrofia das mucosas gástrica e intestinal (SBNO, 2021).

Além das implicações metabólicas e nos órgãos, a desnutrição em pacientes com câncer

compromete o sistema imunológico. Diminui a produção de imunoglobulinas, reduz a atividade do sistema complemento e diminui o número de linfócitos T e CD4, enfraquecendo a capacidade bactericida dos neutrófilos. Essa diminuição na resistência imunológica aumenta a vulnerabilidade a infecções de feridas, sepse abdominal e pneumonia pós-operatória. Consequentemente, a desnutrição pode contribuir para complicações no período pós-operatório, prolongando a internação, prejudicando a qualidade de vida e aumentando os custos do tratamento. Diante desses desafios, é essencial desenvolver protocolos criteriosos de assistência nutricional em todas as fases da doença e do tratamento, visando otimizar recursos e aprimorar a qualidade do cuidado oferecido aos pacientes com câncer (SBNO, 2021).

No Brasil, foi publicado em 2021 o “I Consenso Brasileiro de Nutrições Oncológica” SBNO (2021), elaborado pela Sociedade Brasileira de Nutrição Oncológica, onde são definidas diretrizes para atuação clínica dos profissionais da área. A terapia nutricional no paciente adulto oncológico cirúrgico tem como principal objetivo a melhora clínica e nutricional com prevenção de complicações infecciosas e não infecciosas (SBNO, 2021). A assistência nutricional ao paciente oncológico deve ser individualizada, o que compreende a avaliação nutricional, o cálculo das necessidades nutricionais, a *Terapia Nutricional Oral (TNO)*, *Terapia Nutricional Enteral (TNE)* ou *Terapia Nutricional Parental (TNP)*, a alta e o seguimento ambulatorial (SBNO, 2021).

Do ponto de vista jurídico, a maioria dos estados considera a nutrição artificial e a hidratação como não diferentes de qualquer outro tratamento médico e, como tal, geralmente são consideradas cuidados extraordinários. As crenças culturais ou religiosas do paciente podem desempenhar um papel crucial no processo de tomada de decisão, pois alguns sistemas de fé colocam qualquer extensão de sobrevivência acima da qualidade de vida, enquanto grande parte da medicina ocidental agora enfatiza mais a qualidade de vida (MOYNIHAN; KELLY; FISCH, 2005).

2.4 O “Problema da Dieta” na Computação

O “problema da dieta”, proposto por Stigler (1945), refere-se a uma questão de otimização computacional que busca determinar a composição de uma dieta que atenda às necessidades nutricionais de uma pessoa, enquanto minimiza o custo associado à compra dos alimentos.

Formalmente, o problema da dieta é equivalente ao problema da mochila multidimensional 0/1, visando gerar um cardápio com o menor custo. A solução proposta envolve a associação de preços e qualidade nutricional dos alimentos, buscando criar um cardápio ideal que atenda às restrições diárias de requisitos nutricionais. Durante o processamento, a inclusão (valor lógico verdadeiro, i.e., 1) ou exclusão (valor lógico falso, i.e., 0) de produtos no cardápio ocorre até alcançar as quantidades desejadas de nutrientes essenciais (e.g., energia, proteína, cálcio). O objetivo é obter um cardápio que satisfaça as restrições nutricionais com o menor custo total possível, sujeito à limites definidos para requisitos nutricionais diários (por exemplo, e.g., energia,

proteína, cálcio, ferro, vitamina A, etc.) (KALDIRIM; KOSE, 2006).

Embora estudado há mais de 50 anos, o problema da dieta segue sendo um tema de pesquisa ativo, com foco na personalização dos *frameworks* de geração de cardápios (TOLEDO; ALZHRANI; MARTINEZ, 2019).

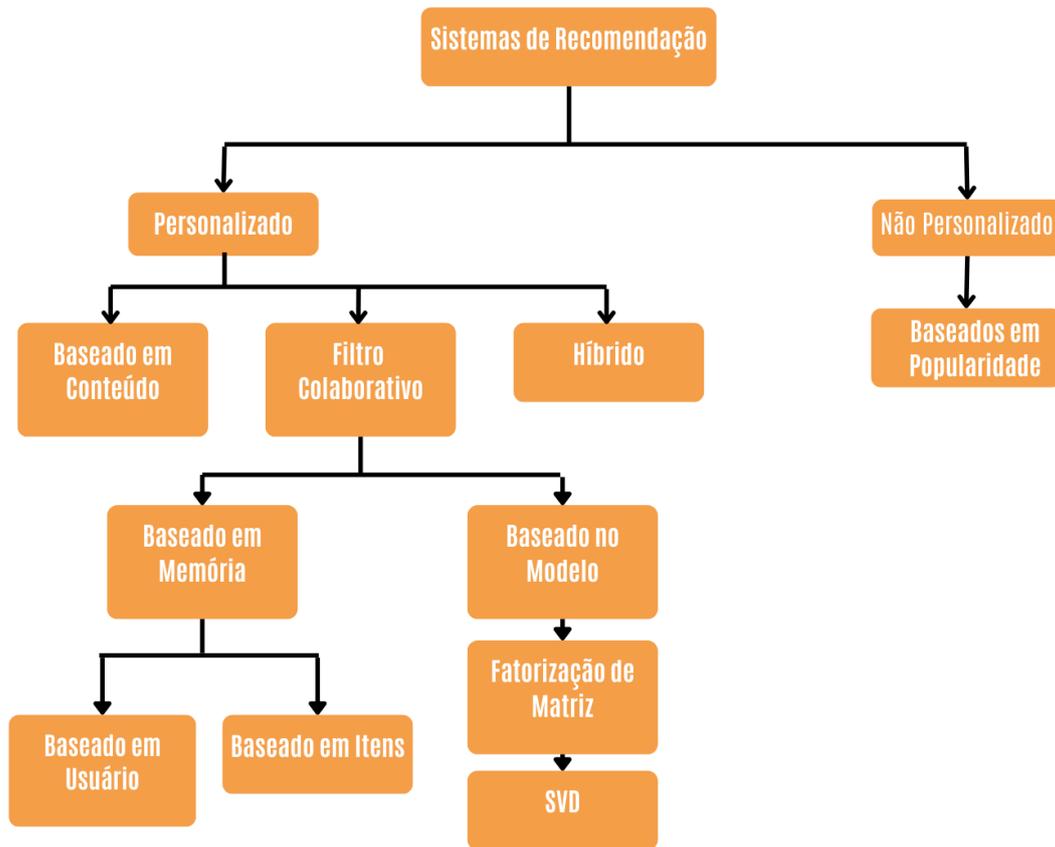
2.5 Sistemas de Recomendação

Quando um usuário na Internet recebe uma sugestão de filme ou livro em algum determinado *site*, pode-se dizer que esse *site* faz uso de um Sistema de Recomendação (SR). Segundo COSLEY et al. (2003), a capacidade dos humanos de localizar as informações que desejam cresce mais lentamente do que a velocidade com que novas informações se tornam acessíveis. Os sistemas de recomendação são uma ferramenta para ajudar a conectar essa lacuna. Esses sistemas usam as opiniões das pessoas sobre itens em um domínio de informação para ajudar as pessoas a tomarem decisões sobre quais outros itens consumir.

O objetivo de um SR é gerar recomendações significativas para uma coleção de usuários para itens ou produtos que possam interessá-los. Sugestões para livros na *Amazon* ou filmes na *Netflix* são exemplos do mundo real da operação de sistemas de recomendação de força do setor. A implementação de tais mecanismos de recomendação depende do domínio e das características particulares dos dados disponíveis (MELVILLE et al., 2010).

Geralmente, existem dois tipos principais de sistemas de recomendação, personalizados e não personalizados, conforme ilustrado na Figura 4 (THINSOLVER, 2022), que são definidos a seguir.

Figura 4 – Tipos de sistemas de recomendação



Fonte: Adaptado de (THINSOLVER, 2022)

2.5.1 Sistemas de Recomendação Não Personalizados

Os sistemas de recomendação não personalizados são o tipo mais simples de sistemas de recomendação. Como sugere o nome, este tipo de sistema de recomendação não leva em consideração as preferências pessoais dos usuários, ou seja, as recomendações produzidas por estes sistemas são idênticas para cada cliente (PORIYA et al., 2014).

Os sistemas de recomendação não personalizados, como os recomendadores baseados em popularidade, operam sugerindo itens de acordo com sua alta aceitação geral. Por exemplo, podem indicar os 10 filmes mais populares, os livros mais vendidos ou os produtos mais frequentemente adquiridos pelos usuários (THINSOLVER, 2022).

Para tornar mais claro o conceito, considere que estamos navegando em um *site*, como a *Amazon* ou o Mercado Livre, como usuários anônimos, somos apresentados a itens que estão sendo visualizados por outros membros no momento. Esses sistemas operam recomendando produtos aos consumidores com base nas opiniões ou classificações médias de outros usuários. Em outras palavras, essas recomendações são simplesmente sugestões ou listagens de itens que podem interessar ao usuário, independentemente de suas preferências individuais.

Os sistemas de recomendação não personalizados geralmente empregam dois tipos principais de algoritmos: recomendação agregada de opinião, que envolve a consolidação das avaliações dos usuários sobre os produtos para sugerir novos itens; e recomendação básica de associação de produtos, que sugere itens relacionados com base em compras anteriores ou nas preferências do usuário (PORIYA et al., 2014).

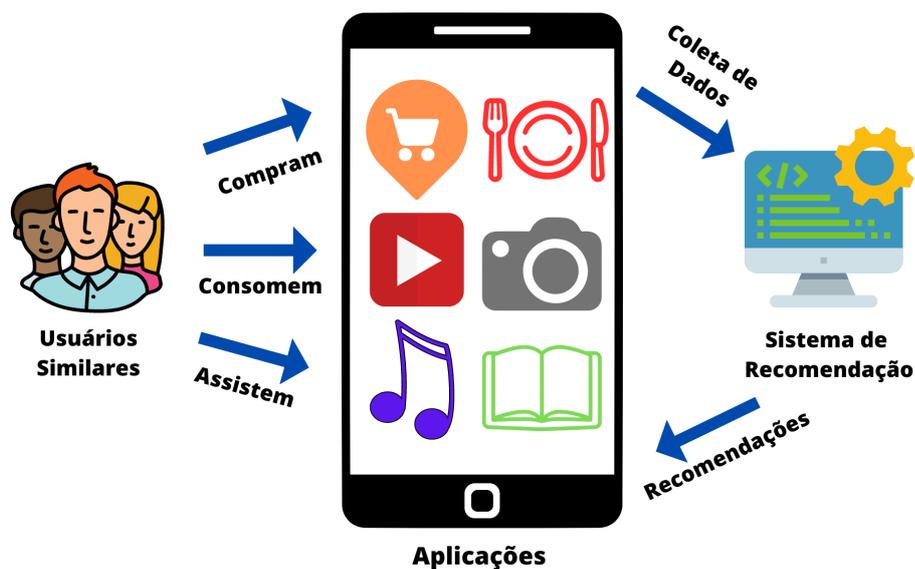
2.5.2 Sistemas de Recomendação Personalizados

Por outro lado, atualmente há uma necessidade constante em todas as empresas em saber mais sobre as preferências dos clientes para lhes proporcionar um serviço mais eficiente. Este fato deu uma grande importância para o campo de sistemas de recomendação que prospera ao fornecer aos usuários recomendações precisas que correspondem às suas preferências (CHAAYA et al., 2018).

Recomendações personalizadas são oferecidas como listas de itens classificados. Ao realizar esse ranqueamento, os SR tentam prever quais são os produtos ou serviços mais adequados, com base nas preferências e restrições do usuário. A fim de cumprir tal tarefa computacional, os SR coletam as preferências dos usuários, explicitamente expressas, como, por exemplo, classificações para produtos, ou são inferidas pela interpretação das ações do usuário. Por exemplo, um SR pode considerar a navegação para uma determinada página de um produto como um sinal implícito de preferência pelos itens mostrados nessa página (RICCI; ROKACH; SHAPIRA, 2011).

A Figura 5 ilustra o funcionamento simplificado de um sistema de recomendação. O usuário interage com diversos tipos de itens, como filmes, músicas, livros, produtos ou qualquer outro conteúdo relevante ao contexto do sistema. Essa interação pode incluir a visualização, a avaliação, a compra ou o consumo de tais itens. O comportamento do usuário é coletado pelo sistema de recomendação, que analisa esses dados e utiliza algoritmos para entender as preferências e interesses do usuário. Com base nessa análise, o sistema de recomendação gera uma lista de recomendações personalizadas para o usuário. Essas recomendações são selecionadas de acordo com o perfil daquele usuário, levando em consideração seus gostos, histórico de interações anteriores, avaliações, preferências declaradas ou qualquer outra informação relevante disponível. Como resultado, o objetivo é fornecer ao usuário sugestões de itens que sejam mais propensos a serem de seu interesse.

Figura 5 – Processo lógico dos sistemas de recomendação



Fonte: Adaptado de (FERREIRA et al., 2020)

Estudos demonstraram que os SR já vêm sendo empregados em serviços de saúde, como os **Sistemas de Recomendação de Saúde (SRS)**, para fins educativos, dietéticos e de assistência a atividades (KIM et al., 2009; RICCI; ROKACH; SHAPIRA, 2011; SEZGIN; ÖZKAN, 2013).

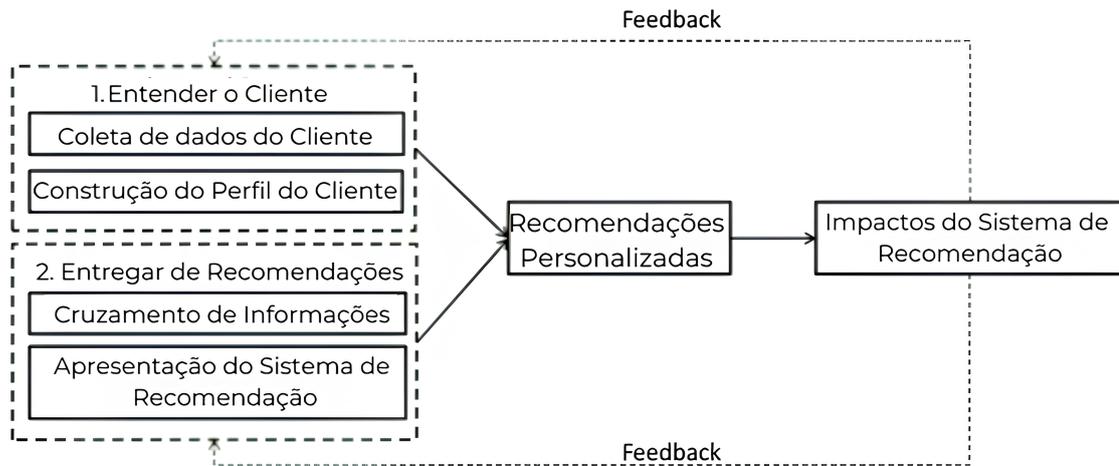
2.5.3 Sistemas de Recomendação Multicritério

A maioria dos sistemas de recomendação atuais lida com avaliações de único critério, como avaliações de filmes e livros. No entanto, em algumas aplicações, como recomendadores de restaurantes, é crucial incorporar avaliações de múltiplos critérios aos métodos de recomendação. Por exemplo, muitos guias de restaurantes, como o Guia Zagat, fornecem três critérios para avaliações de restaurantes: comida, decoração e serviço (ADOMAVICIUS; TUZHILIN, 2005b).

Sistemas de recomendação multicritério têm como objetivo encontrar itens mais úteis para cada usuário, assim como fazem os sistemas de recomendação de avaliação única. Portanto, o sistema deve ser capaz de prever a avaliação geral de cada item para cada usuário, a fim de comparar os itens com base em suas avaliações gerais e recomendar os melhores itens aos usuários (ADOMAVICIUS; KWON, 2007).

A personalização constitui um processo iterativo que pode ser definido pelos três estágios do ciclo compreender-entregar-medir (ADOMAVICIUS; TUZHILIN, 2005a). De acordo com LI e KARAHANNA (2015), O modelo de processo (Figura 6), de forma iterativa, (1) tenta entender o cliente, coletando informações sobre ele para construir seu perfil; (2) entrega as recomendações ao usuário a partir do cruzamento das informações e da apresentação do sistema de recomendação (SR); e, por fim, (3) realiza a medição das recomendações personalizadas (i.e., o *feedback* do

Figura 6 – Modelo do Processo em 3 estágios



Fonte: Adaptado de (LI; KARAHANNA, 2015)

usuário), bem como os impactos do SR. Nota-se que, após avaliar os impactos, um novo ciclo é iniciado.

Baseado nesse modelo de processo, a proposta é adaptá-lo para, de forma iterativa, (1) conhecer o paciente, (2) criar seu perfil, (3) fazer recomendações adequadas e (4) avaliar os impactos. Idealmente, o funcionamento pode ser ilustrado com os seguintes estágios:

1. Coleta de dados de pacientes.
2. Construção dos perfis dos pacientes
3. Cruzar informações dos pacientes com uma base de dados alimentares obtidos através da [TBCA \(USP, 2023\)](#).
4. Recomendar alimentos para inclusão na dieta do paciente.
5. Avaliar se a dieta alcançou os resultados esperados.

Idealmente, os dados coletados no estágio 1 deveriam ser provenientes de pessoas reais, especialmente aquelas que representem de forma adequada a diversidade de casos nutricionais na população oncológica. No entanto, devido a limitações de tempo e dificuldades em estabelecer parcerias para a obtenção de dados médicos, a solução adotada é criar um simulador de pacientes, considerando as características demográficas e nutricionais da população brasileira. Consequentemente, o estágio 2 de construção de perfis também é simulado, gerando variações de casos fictícios baseados em dados estatísticos.

Outro ponto fraco do modelo de processo adaptado é o último estágio de *feedback*, que requer a participação de um profissional da área, o que, sem sua colaboração, impede uma avaliação com rigor científico para verificar se a dieta alcançou os resultados esperados. Para

superar esse desafio, a solução é avaliada com base no cumprimento dos critérios estabelecidos para cada paciente simulado, conforme informado na entrada do modelo.

Em conclusão, mesmo com algumas limitações, esse processo iterativo e contínuo do Sistema de Recomendação visa melhorar a precisão e a relevância das sugestões ao longo do tempo, adaptando-se às mudanças de preferências e necessidades do usuário. Assim, o objetivo principal é fornecer uma experiência personalizada e satisfatória, facilitando a descoberta de produtos que sejam do interesse do consumidor.

2.5.4 Métodos de Tomada de Decisão Multicritério

Na literatura, diversos algoritmos foram identificados como potenciais candidatos para resolver o problema de cruzamento de informações em contextos de tomada de decisão multicritério. Entre eles, destacam-se dois métodos amplamente utilizados e validados: o **TOPSIS** (*Technique for Order Preference by Similarity to Ideal Solution*), proposto por [Hwang et al. \(1981\)](#), e o **NSGA-II**, desenvolvido por [Deb et al. \(2000\)](#).

2.5.4.1 TOPSIS

Os métodos multicritério permitem a consideração de múltiplos critérios simultaneamente na tomada de decisão. Eles avaliam e classificam diferentes alternativas com base em um conjunto de critérios estabelecidos, permitindo a identificação da melhor opção de acordo com os objetivos definidos. O algoritmo **TOPSIS** avalia uma matriz de decisão que contém m alternativas associadas a n atributos (ou critérios).

Sejam

$$A = \{A_1, A_2, \dots, A_m\} \quad (\text{conjunto de alternativas}),$$

$$C = \{x_1, x_2, \dots, x_n\} \quad (\text{conjunto de critérios}).$$

A matriz de decisão $D = (x_{ij}) \in \mathbb{R}^{m \times n}$ é dada por:

$$D = \begin{matrix} & x_1 & x_2 & \cdots & x_j & \cdots & x_n \\ \begin{matrix} A_1 \\ A_2 \\ \vdots \\ A_i \\ \vdots \\ A_m \end{matrix} & \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1j} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2j} & \cdots & x_{2n} \\ \vdots & \vdots & & \vdots & & \vdots \\ x_{i1} & x_{i2} & \cdots & x_{ij} & \cdots & x_{in} \\ \vdots & \vdots & & \vdots & & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mj} & \cdots & x_{mn} \end{pmatrix} \end{matrix}$$

onde x_{ij} é o valor da alternativa A_i segundo o critério x_j .

O método **TOPSIS** foi escolhido devido à sua capacidade de gerar um ranqueamento das soluções, o que é particularmente útil em contextos onde a melhor opção não é necessaria-

mente a única possível. Esse aspecto é especialmente relevante em problemas do mundo real, onde diferentes alternativas podem ser igualmente viáveis, dependendo das preferências e das necessidades dos usuários.

Segundo [Hwang et al. \(1981\)](#), o algoritmo **TOPSIS** foi originalmente desenvolvido para selecionar a melhor alternativa entre um conjunto finito de opções, o que demonstra sua capacidade de simplificar e estruturar o processo de decisão. Logo, o método foi escolhido devido a sua aceitação por pesquisadores e profissionais ([BEHZADIAN et al., 2012](#)).

Os passos do algoritmo **TOPSIS** descritos no Algoritmo 1 são:

1. **Normalização da Matriz de Decisão:** A primeira etapa envolve normalizar a matriz de decisão, que é a matriz que contém os valores de cada critério para cada alternativa. A normalização é feita para garantir que todos os critérios tenham o mesmo peso na análise.
2. **Atribuição de Pesos:** Cada critério é ponderado com base na importância relativa. Os pesos são atribuídos para refletir a relevância de cada critério na tomada de decisão. Os pesos geralmente são fornecidos pelos tomadores de decisão ou calculados com métodos específicos.
3. **Matriz Normalizada Ponderada:** Multiplica-se a matriz normalizada pelos pesos atribuídos a cada critério. Isso resulta na matriz normalizada ponderada.
4. **Identificação das Soluções Ideais:** Para cada critério, é determinado se a alternativa é a melhor (maximização) ou a pior (minimização). Isso é feito calculando os valores máximo e mínimo em cada coluna da matriz normalizada ponderada.
5. **Cálculo da Distância Euclidiana:** Calcula-se a distância Euclidiana entre a alternativa e a solução ideal para cada critério. Isso é feito para as soluções ideais de maximização e minimização.
6. **Cálculo da Proximidade à Solução Ideal Positiva e Negativa:** Calcula-se a proximidade relativa da alternativa à solução ideal positiva (para critérios de maximização) e à solução ideal negativa (para critérios de minimização). Isso é feito usando as distâncias Euclidianas calculadas.
7. **Índice TOPSIS:** Calcula-se o índice **TOPSIS** para cada alternativa, que é a razão entre a proximidade à solução ideal negativa e a soma da proximidade à solução ideal positiva e negativa.
8. **Classificação das Alternativas:** As alternativas são classificadas com base nos índices **TOPSIS**, em ordem decrescente. A alternativa com o índice mais alto é considerada a melhor escolha.

Algoritmo 1: Método TOPSIS

Input: Matriz de decisão original X , Pesos dos atributos W , Tipo de atributo (benefício/custo) T

Output: Classificação de alternativas

- 1 // Construção da matriz de decisão normalizada R :
- 2 **for** $i \leftarrow 1$ **to** n **do**
- 3 **for** $j \leftarrow 1$ **to** m **do**
- 4 $R_{ij} \leftarrow \frac{X_{ij}}{\sqrt{\sum_{i=1}^n X_{ij}^2}}$;
- 5 // Construção da matriz de decisão normalizada ponderada V :
- 6 **for** $i \leftarrow 1$ **to** n **do**
- 7 **for** $j \leftarrow 1$ **to** m **do**
- 8 $V_{ij} \leftarrow R_{ij} \times W_j$;
- 9 // Determinar as soluções ideais pA_q e $pA_{\bar{q}}$:
- 10 **for** $j \leftarrow 1$ **to** m **do**
- 11 **if** T_j é benefício **then**
- 12 $pA_q[j] \leftarrow \max(V_{.j})$;
- 13 $pA_{\bar{q}}[j] \leftarrow \min(V_{.j})$;
- 14 **else**
- 15 $pA_q[j] \leftarrow \min(V_{.j})$;
- 16 $pA_{\bar{q}}[j] \leftarrow \max(V_{.j})$;
- 17 // Calcular a medida de separação S :
- 18 **for** $i \leftarrow 1$ **to** n **do**
- 19 $S_i \leftarrow \sqrt{\sum_{j=1}^m (V_{ij} - pA_q[j])^2}$;
- 20 $S_{\bar{i}} \leftarrow \sqrt{\sum_{j=1}^m (V_{ij} - pA_{\bar{q}}[j])^2}$;
- 21 // Calcular a proximidade relativa D (Índice TOPSIS):
- 22 **for** $i \leftarrow 1$ **to** n **do**
- 23 $D_i \leftarrow \frac{S_{\bar{i}}}{S_i + S_{\bar{i}}}$;
- 24 //Índice TOPSIS:
- 25 //Calcula-se o índice TOPSIS para cada alternativa, que é a razão entre a proximidade à solução ideal negativa e a soma da proximidade à solução ideal positiva e negativa.
- 26 //Classificação das Alternativas:
- 27 //As alternativas são classificadas com base nos índices TOPSIS, em ordem decrescente. A alternativa com o índice mais alto é considerada a melhor escolha.

2.5.4.2 NSGA-II

Esse algoritmo possibilita a geração de recomendações alimentares personalizadas, considerando não apenas as preferências individuais dos pacientes, mas também aspectos

nutricionais cruciais para o contexto oncológico. A fase subsequente engloba a avaliação crítica dessas recomendações por um profissional especializado na área de nutrição oncológica, notadamente um nutricionista oncológico. A parceria entre o sistema e o profissional, utilizando uma metodologia qualitativa, permite uma análise refinada das sugestões, contribuindo para a confiabilidade e eficácia do modelo proposto. Essa abordagem integrada visa não apenas aprimorar as estratégias nutricionais, mas também fortalecer a colaboração entre a tecnologia e a expertise clínica na promoção da saúde de pacientes em tratamento oncológico.

O método multiobjetivo **NSGA-II** (*Non-dominated Sorting Genetic Algorithm II*), proposto por [Deb et al. \(2000\)](#) é uma abordagem que lida com problemas que envolvem múltiplos objetivos conflitantes, de forma similar ao que ocorre com o **TOPSIS**. Ele busca encontrar soluções que sejam ótimas em termos de diferentes critérios simultaneamente, levando em consideração a ideia de Pareto-ótimo, ou seja, soluções que não podem ser melhoradas em um critério sem piorar em outro.

Devido aos conflitos e à incomensurabilidade entre as funções-objetivo, não é possível encontrar uma única solução ótima para todas elas simultaneamente. Por isso, no espaço de objetivos não há ordenação total: embora se possa afirmar que $(1, 1)^\top$ é “menor” que $(3, 3)^\top$, não existe critério para comparar $(1, 3)^\top$ com $(3, 1)^\top$. Assim, concentra-se a atenção nos vetores de objetivos cujos componentes não podem ser melhorados sem que pelo menos um outro componente piore. Essa definição foi apresentada por Edgeworth em 1881 e ficou conhecida como optimalidade de Pareto após Vilfredo Pareto refiná-la em 1896 ([MIETTINEN, 1999](#)).

Definição 2.5.1 (Pareto-ótimo) *Seja*

$$f: S \subseteq \mathbb{R}^n \rightarrow \mathbb{R}^k, \quad f(x) = (f_1(x), \dots, f_k(x)).$$

Um vetor de decisão $x^ \in S$ é Pareto-ótimo se não existir outro $x \in S$ tal que*

$$f_i(x) \leq f_i(x^*) \quad \forall i = 1, \dots, k \quad e \quad f_j(x) < f_j(x^*) \quad \text{para algum } j.$$

De forma equivalente, o vetor de objetivos $z^ = f(x^*) \in Z$ é Pareto-ótimo se não existir $z \in Z$ que satisfaça as mesmas desigualdades ([MIETTINEN, 1999](#)).*

O método **NSGA-II** foi escolhido para abordar o problema devido à sua eficácia em resolver problemas que podem ser modelados como variações do problema da mochila, como é o caso do problema da dieta ([STIGLER, 1945](#)). O **NSGA-II**, de acordo com [Vargas \(2018\)](#), é o algoritmo evolutivo para se resolver problemas de otimização multiobjetivo mais popular na literatura, tornando-o uma escolha viável para essa aplicação.

Os passos do Algoritmo **NSGA-II** estão expostos em [2](#).

1. **Inicialização da População:** Gere uma população inicial de soluções candidatas de maneira aleatória ou usando estratégias específicas.

2. **Avaliação de *Fitness*:** Avalie o desempenho de cada solução da população em relação aos objetivos definidos.
3. **Ordenação Não Dominada:** Classifique as soluções com base na relação de não dominação, criando frentes de Pareto.
4. **Atribuição de *Rank* e *Crowding Distance*:** Atribua um *rank* a cada solução com base nas frentes de Pareto e na distância de multidão para preservar a diversidade.
5. **Seleção de Pais:** Selecione soluções para reprodução, favorecendo soluções com *ranks* mais baixos e maior distância de multidão.
6. **Recombinação e Mutação:** Aplique operadores genéticos, como recombinação e mutação, para gerar uma nova população de descendentes.
7. **Avaliação de *Fitness* dos Descendentes:** Avalie o desempenho dos descendentes em relação aos objetivos.
8. **Combinação de Populações:** Combine a população atual e os descendentes para formar uma nova população.
9. **Redução da População:** Se necessário, reduza a população para o tamanho desejado, favorecendo soluções de *ranks* mais baixos e maior distância de multidão.
10. **Critério de Convergência:** Verifique se um critério de convergência é atendido, como o número de gerações ou a melhoria na frente de Pareto.

Algoritmo 2: Método NSGA-II

Input: Número de gerações gen_{max} , Tamanho da população N , Probabilidade de crossover p_c , Probabilidade de mutação p_m

Output: População final Pareto-ótima

```

1 //Inicialização da população
2  $P_0 \leftarrow$  GerarPopulaçãoInicial( $N$ );
3 AvaliarObjetivos( $P_0$ );
4  $F \leftarrow$  OrdenacaoPorDominancia( $P_0$ );
5  $t \leftarrow 0$ ;
6 while  $t < gen_{max}$  do
7   //Geração da população filha  $Q_t \leftarrow \emptyset$ ;
8   for  $i \leftarrow 1$  to  $N$  do
9      $pais \leftarrow$  SeleçãoPorTorneio( $P_t$ );
10     $filho \leftarrow$  AplicarCrossover( $pais, p_c$ );
11     $filho \leftarrow$  AplicarMutação( $filho, p_m$ );
12     $Q_t \leftarrow Q_t \cup \{filho\}$ ;
13  //Combinação e avaliação das populações
14   $R_t \leftarrow P_t \cup Q_t$ ;
15  AvaliarObjetivos( $R_t$ );
16   $F \leftarrow$  OrdenacaoPorDominancia( $R_t$ );
17  //Seleção da próxima geração
18   $P_{t+1} \leftarrow \emptyset$ ;
19   $i \leftarrow 1$ ;
20  while  $|P_{t+1}| + |F_i| \leq N$  do
21    CalcularCrowdingDistance( $F_i$ );
22     $P_{t+1} \leftarrow P_{t+1} \cup F_i$ ;
23     $i \leftarrow i + 1$ ;
24  //Preenchimento usando crowding distance
25  OrdenarPorCrowdingDistance( $F_i$ );
26   $P_{t+1} \leftarrow P_{t+1} \cup$  PrimeirosIndivíduos( $F_i, N - |P_{t+1}|$ );
27   $t \leftarrow t + 1$ ;

```

3

Trabalhos Relacionados

Por meio da análise de diversos artigos e estudos de caso, este capítulo busca evidenciar as tendências, os desafios e as inovações que têm contribuído para o desenvolvimento de sistemas de recomendação e para o aprimoramento das metodologias de geração de dados sintéticos, estabelecendo um panorama abrangente do estado da arte nessas áreas. Inicialmente, são discutidos estudos clássicos e modernos que abordam o problema da dieta, desde as primeiras abordagens que visavam otimizar o custo e o equilíbrio nutricional, até os avanços que integraram múltiplos critérios e aspectos comportamentais à recomendação de alimentos. Em seguida, são exploradas as estratégias utilizadas para a criação de pacientes artificiais, fundamentais para a simulação clínica e a validação de intervenções terapêuticas, especialmente diante das dificuldades de se obter dados reais de pacientes oncológicos.

3.1 Recomendação de Dietas Personalizadas

Estudos sobre computação aplicados a dietas têm sido estudados há algumas décadas (STIGLER, 1945; SMITH, 1963; LOCKS, 1980; LANCASTER; TAJ, 1994). Um dos primeiros trabalhos nesse contexto é o de Stigler (1945), que propôs o que ficou conhecido como o problema clássico da dieta. Esse estudo foi desenvolvido a partir de uma preocupação econômica do governo norte-americano com seus soldados. O objetivo era determinar uma dieta ótima baseada na quantidade de nutrientes recomendada pelo Conselho Nacional de Pesquisa Norte-americano e que tivesse o menor custo possível.

Anos mais tarde, Smith (1963) abordou o uso de computadores para o planejamento de dietas humanas, uma inovação tecnológica significativa na época. O artigo discute como modelos matemáticos e programação linear podem ser aplicados ao cálculo de dietas nutricionalmente balanceadas, levando em consideração as necessidades dietéticas de indivíduos e grupos. Como resultado, definiu-se o que é conhecido como ‘*gap de Stigler*’, que refere-se à diferença entre

sua solução aproximada e a solução exata obtida posteriormente com o uso de técnicas de programação linear.

Já [Locks \(1980\)](#) comparou dois modelos de dieta, sendo um modelo de custo mínimo e outro de alimentos mais palatáveis, a diferença de custos é o ‘*gap de Stigler*’. O estudo comprovou que a dieta de custo mínimo tem escassez calórica em relação com o outro modelo. O autor também comprova que as técnicas de Programação Linear podem ser utilizadas para solucionar o problema da dieta clássico, que tem poucos parâmetros em relação aos padrões atuais.

Combinando um objetivo econômico com o equilíbrio nutricional, [Lancaster e Taj \(1994\)](#) observaram que esse modelo resulta em um padrão único de consumo alimentar avaliado como dieta de menor custo, porém a variedade de alimentos é limitada pelo número de restrições nutricionais e contém apenas alguns alimentos em quantidades pouco apetitosas. Em contraste, os padrões de consumo prevalentes contêm uma grande variedade de alimentos, que custam mais do que dieta de menor custo e criam o chamado ‘*gap de Stigler*’. Além da nutrição e da economia, o consumo alimentar é impulsionado pela preferência e pelo comportamento de busca de variedade.

Na literatura há trabalhos mais recentes que associam as dietas personalizadas a sistemas de recomendação multicritério. Mais especificamente, [Toledo, Alzahrani e Martinez \(2019\)](#) levantaram e avaliaram trabalhos. O resultado desses estudos concluíram que os mesmos não estão focados especificamente na nutrição, mas em saúde e bem-estar a nutrição como um componente superficial. Como conclusão, tal estudo direciona os esforços nas seguintes direções:

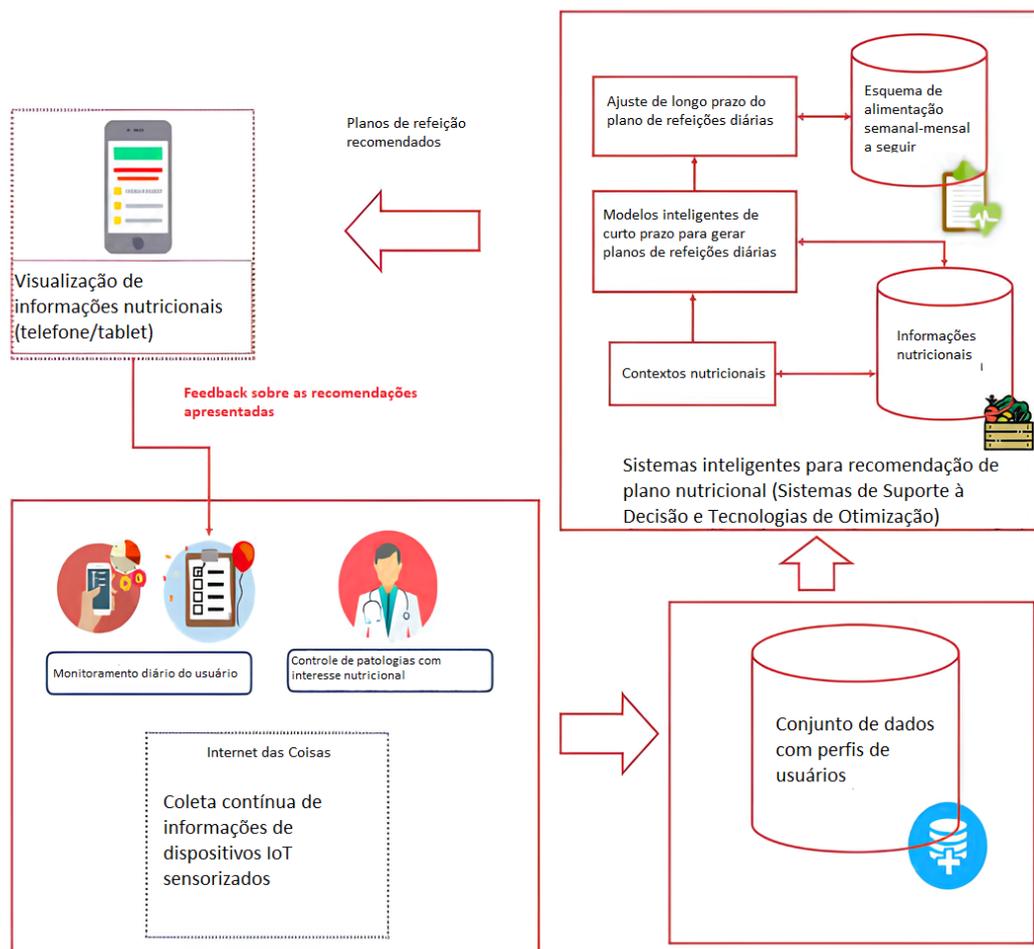
- A integração do processamento de classificação [MCDM](#) juntamente com a conscientização sobre informações nutricionais dentro do domínio da recomendação de alimentos.
- O uso de métodos de perfilagem de usuários baseados em *feedback* no domínio da recomendação de alimentos.

Ainda segundo [Toledo, Alzahrani e Martinez \(2019\)](#), a *Multi-Criteria Decision Analysis (MCDA)* é uma área focada em ajudar na tomada de decisões entre múltiplas alternativas que são avaliadas por vários critérios conflitantes. Diferentes tipos de problemas de decisão podem ser formulados dentro do contexto da [MCDA](#); desde problemas de escolha, ordenação, classificação e descrição, até problemas de eliminação e design. A maioria dos problemas estudados na literatura se concentra em problemas de escolha e classificação, assim, muitas abordagens como *Analytic Hierarchy Process (AHP)* ([SAATY, 1990](#)), *TOPSIS* ([HWANG et al., 1981](#)), *Preference Ranking Organization Method for Enrichment of Evaluations (PROMETHEE)* ([BRANS; MARESCHAL, 1990](#)), *Decision-Making Trial and Evaluation Laboratory (DEMATEL)* ([GABUS; FONTELA, 1972](#)), *VIKOR* ([OPRICOVIC; TZENG, 2004](#)) ou, mais recentemente, *Best Worst Method (BWM)* ([REZAEI, 2015](#)) e assim por diante, foram desenvolvidas e aplicadas em problemas do mundo real.

A Figura 7 apresenta uma arquitetura estruturada em 4 camadas para o sistema de recomendação de dietas proposto por Toledo, Alzahrani e Martinez (2019). Resumidamente, essa arquitetura pode ser descrita como:

1. Camada de Coleta de Informações: Focada em capturar todas as informações relevantes relacionadas à nutrição do usuário.
2. Camada de Construção do Perfil do Usuário: Armazena as informações que caracterizam os usuários, servindo como entrada para a abordagem de recomendação nutricional.
3. Camada de Sistemas Inteligentes: Recebe as informações do perfil do usuário e retorna um plano de refeições recomendado.
4. Camada de aplicação para Usuário Final: Apresenta os planos de refeições recomendados e informações nutricionais adicionais.

Figura 7 – A arquitetura geral para recomendação de alimentos.



Fonte: Adaptado de Toledo, Alzahrani e Martinez (2019).

Ao explorar análises de *Big Data*, Lambay e Mohideen (2022) propuseram um *framework* conhecido como **Sistema de Recomendação Híbrido (HRS)** que faz uso de **Processamento de Linguagem Natural (NLP)** para gerar recomendações de dietas. Além disso, foi proposto um algoritmo híbrido chamado **Recomendador Inteligente para Dieta Saudável (IR-HD)** para a realização da estrutura **HRS**.

Em relação às limitações dos sistemas de recomendação de dietas presentes na literatura, Rostami et al. (2023) destacam:

- **Recomendações Saudáveis:** Muitos sistemas de recomendação de alimentos existentes não priorizam fatores nutricionais ou de saúde, focando apenas nas preferências dos usuários.
- **Consciência dos Ingredientes:** Modelos tradicionais frequentemente ignoram os ingredientes específicos dos alimentos, o que leva a recomendações que podem não corresponder às preferências ou restrições dietéticas dos usuários.
- **Fator Tempo:** Sistemas anteriores assumem preferências alimentares estáticas, desconsiderando mudanças nos gostos dos usuários ao longo do tempo.
- **Problema de Esparsidade de Dados:** Usuários que avaliaram apenas alguns alimentos fornecem dados insuficientes, dificultando a recomendação precisa, especialmente para alimentos “de início frio” (aqueles que ainda não receberam avaliações suficientes).
- **Agrupamento de Alimentos:** Agrupar alimentos semelhantes para melhorar as recomendações é problemático devido a limitações inerentes dos algoritmos de agrupamento, como a dificuldade em determinar o número ideal de grupos.
- **Controlabilidade:** A maioria dos sistemas não permite que os usuários influenciem o processo de recomendação ajustando as entradas ou preferências.

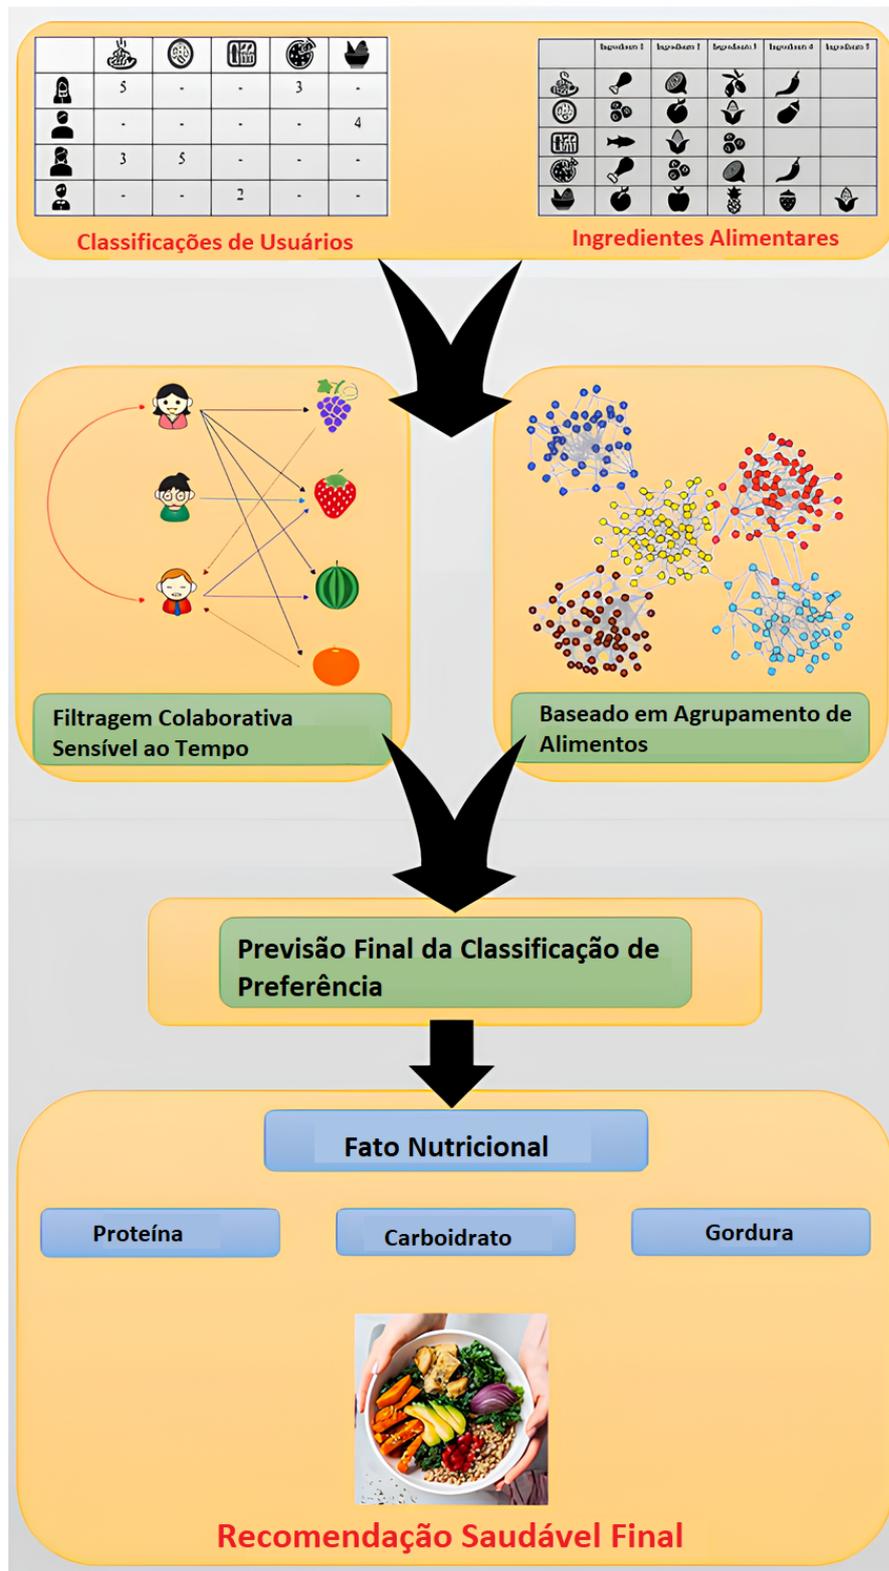
Para enfrentar esses desafios, os autores propõem o **Sistema de Recomendação de Alimentos Saudáveis e Sensível ao Tempo (HTFRS)** que sugere alimentos desejáveis e saudáveis para o usuário ativo. Este sistema apresenta várias características inovadoras, tais como:

- **Recomendações Saudáveis:** O modelo **HTFRS** incorpora fatores de saúde e nutrição para guiar os usuários em direção a escolhas alimentares mais saudáveis.
- **Consciência dos Ingredientes:** Combina as avaliações dos usuários com os dados dos ingredientes dos alimentos, aumentando a precisão das recomendações ao considerar as preferências de ingredientes dos usuários.
- **Sensível ao Tempo:** O sistema inclui uma função de similaridade sensível ao tempo para refletir as mudanças nas preferências alimentares dos usuários ao longo do tempo, atribuindo mais peso às avaliações recentes.

- **Recomendações Baseadas na Similaridade dos Alimentos:** O [HTFRS](#) utiliza um gráfico atribuído para representar as informações das receitas, o que resolve o problema de início frio e permite melhor previsão de alimentos não avaliados.
- **Consciência de Grupos de Alimentos:** O sistema considera explicitamente as categorias de alimentos, otimizando o agrupamento de alimentos ao utilizar semelhanças baseadas em ingredientes.
- **Recomendação Controlável:** O sistema introduz um mecanismo controlável pelo usuário, permitindo que ele equilibre suas preferências alimentares com fatores de saúde.

Além disso, [Rostami et al. \(2023\)](#) apresentaram uma visão geral do modelo, conforme destacado na Figura 8.

Figura 8 – A arquitetura geral para recomendação de alimentos.



Fonte: Adaptado de Rostami et al. (2023)

O sistema HTFRS possui duas fases principais: (1) filtragem colaborativa sensível ao tempo e (2) a previsão de classificação baseada nos ingredientes dos alimentos. Na primeira fase,

a matriz de similaridade entre usuários é calculada levando em consideração a data e hora da classificação. Em seguida, considerando as semelhanças entre os usuários e suas classificações históricas, as classificações dos usuários são previstas usando o modelo baseado na filtragem colaborativa. Na segunda fase, os alimentos são inicialmente considerados como nós em uma rede social com atributos, onde os ingredientes de cada alimento são indicados pelos atributos dos nós. Por fim, com base nessa representação de rede social com atributos, a matriz de similaridade entre os alimentos é calculada.

Observando a necessidade de fornecer recomendações de alimentos que ofereçam conselhos nutricionais de alta qualidade tanto para usuários saudáveis quanto para aqueles com doenças crônicas relacionadas à dieta, [Agapito et al. \(2018\)](#) propuseram um SR baseado na web, chamado DIETOS (Sistema Organizador de Dietas), cuja versão inicial foi principalmente dedicada a perfilar turistas visitando a Calábria e, assim, recomendar-lhes alimentos regionais compatíveis com seu estado de saúde. DIETOS destaca-se por oferecer recomendações nutricionais personalizadas, baseadas em questionários médicos e medições clínicas (como creatinina, glicose e pressão arterial), que permitem um perfil de saúde de alta qualidade. O sistema avalia tanto usuários saudáveis quanto pacientes com doenças crônicas (calculando a taxa de filtração glomerular para os estágios da doença) e conta com um catálogo exclusivo de alimentos típicos da Calábria, com informações sobre propriedades benéficas e efeitos colaterais.

Apesar de identificarem diversas abordagens para recomendação de alimentos e geração automática de menus, considerando aspectos como preferências pessoais e culturais, restrições de saúde e religião, composição dos menus e coocorrência de receitas, [Bianchini et al. \(2017\)](#), identificaram que integrar essas recomendações com os melhores hábitos alimentares continua sendo um desafio não resolvido. Para contornar essa situação, propuseram um método de recomendação orientado para educação nutricional, balanceando preferências dos usuários com hábitos alimentares saudáveis.

Os trabalhos desenvolvidos por [Espín, Hurtado e Noguera \(2016\)](#), [Ribeiro et al. \(2017\)](#), [YANG et al. \(2017\)](#), [Mckensy-Sambola et al. \(2021\)](#) propõem o uso de estratégias computacionais avançadas para a recomendação de dietas personalizadas. Esses estudos enfatizam a necessidade de adaptar as recomendações alimentares às características individuais dos usuários, considerando suas preferências, necessidades nutricionais e condições de saúde específicas. A motivação predominante é o combate à obesidade, um dos maiores desafios de saúde pública atualmente, pois a abordagem personalizada pode contribuir para a adoção de hábitos alimentares mais saudáveis e a promoção de mudanças comportamentais sustentáveis.

O estudo de [Kim et al. \(2009\)](#) propõe um design de sistema de recomendação focado em dietas voltadas para a prevenção e o tratamento de doenças cardiovasculares. Além de desenvolver uma estrutura robusta para a personalização das recomendações alimentares, o estudo aborda a integração de tecnologias de monitoramento, sugerindo a instalação de sensores de sinais vitais nas residências dos usuários. Essa estratégia permite a coleta contínua de dados clínicos

relevantes, possibilitando uma análise dinâmica do estado de saúde dos indivíduos e a adaptação das recomendações conforme as condições fisiológicas observadas.

O trabalho de [Hong e Jung \(2021\)](#) explora sistemas de recomendação multicritério aplicados ao setor do turismo, especificamente na recomendação de restaurantes para grupos culturais. Ao adotar essa abordagem, o estudo diferencia-se por focar em variáveis contextuais e culturais, em vez de questões diretamente relacionadas à saúde. Essa metodologia ressalta a flexibilidade das técnicas de recomendação multicritério, que podem ser adaptadas para lidar com desafios variados, desde a diversidade gastronômica até as particularidades dos grupos de usuários, proporcionando sugestões que levam em conta tanto preferências culturais quanto aspectos logísticos.

Mais recentemente, o trabalho de [Pochmann \(2022\)](#) apresenta um sistema de recomendação multiobjetivo para dietas alimentares, demonstrando avanços significativos na integração de múltiplas metas na formulação das recomendações. Este estudo vai além da simples personalização baseada em preferências, incorporando fatores adicionais como sustentabilidade, impacto ambiental e diversidade nutricional. Ao equilibrar diferentes objetivos, o sistema se mostra capaz de oferecer soluções alimentares mais abrangentes, que atendem simultaneamente a diversas demandas e restrições, contribuindo para a promoção de uma alimentação equilibrada e consciente.

O trabalho de [Chaves \(2022\)](#), que utiliza como referência o estudo de [Delinski et al. \(2019\)](#), investiga a aplicação de métodos multiobjetivos na geração de cardápios para restaurantes universitários. Essa linha de pesquisa demonstra como técnicas de otimização podem ser empregadas para equilibrar múltiplos critérios, como diversidade de pratos, custos, restrições nutricionais e preferências dos usuários. A abordagem adotada nesses estudos evidencia o potencial dos métodos multiobjetivos para melhorar a tomada de decisão em ambientes complexos, onde é necessário harmonizar aspectos econômicos, nutricionais e de satisfação do consumidor.

Por fim, o trabalho de [Spak et al. \(2017\)](#) apresenta uma motivação semelhante à dos estudos anteriores, voltada para a otimização de sistemas de recomendação alimentar. Contudo, destaca-se pela adoção do método de Programação Linear como ferramenta computacional para a resolução do problema. Essa técnica permite uma modelagem matemática rigorosa, facilitando a resolução de desafios complexos relacionados à alocação de recursos e ao balanceamento de múltiplos critérios. Ao optar pela Programação Linear, o estudo oferece uma abordagem alternativa que enfatiza a precisão e a eficiência na geração de recomendações, demonstrando a importância da escolha adequada dos métodos de otimização na construção de sistemas robustos e adaptáveis.

3.2 Geração de Dados Artificiais de Pacientes

Devido a limitações da disponibilidade de dados públicos de pacientes oncológicos, foi necessário adotar uma estratégia de geração de dados sintéticos com base em uma revisão da literatura sobre o tema. O objetivo desta revisão foi identificar e avaliar as técnicas utilizadas na geração de pacientes artificiais, com ênfase em simulação clínica, modelagem de dados médicos e aprendizado de máquina para validação de intervenções terapêuticas.

Pacientes sintéticos podem ser gerados por meio de modelos de progressão da doença e seus respectivos padrões de cuidado, permitindo a criação de prontuários de saúde sintéticos realistas, seguros e em larga escala (WALONOSKI et al., 2018).

3.2.1 Procedimento

Na condução desta revisão, as buscas foram realizadas manualmente, seguindo diretrizes básicas comumente adotadas em revisões sistemáticas (SAMPAIO; MANCINI, 2007).

3.2.1.1 Critérios de Inclusão e Exclusão

- **Critérios de Inclusão:** Estudos publicados entre 2015 e 2024 que envolvem abordagens computacionais para geração de pacientes artificiais ou dados sintéticos, modelagem de dados clínicos, simulação de tratamentos e evolução de doenças. Incluem-se estudos que utilizam aprendizado de máquina, redes neurais ou outras técnicas de inteligência artificial.
- **Critérios de Exclusão:** Estudos que não envolvem a geração de pacientes artificiais, que não possuem aplicação prática ou que não utilizam dados médicos. Estudos puramente teóricos, sem validação de intervenções clínicas, também foram excluídos.

3.2.1.2 Bases de Dados Utilizadas

As bases de dados consultadas foram: *PubMed*, *dblp*, *IEEE Xplore* e *Google Scholar*. A pesquisa foi realizada utilizando as palavras-chave “*generation patients*”, “*synthetic patients*” e “*virtual patients*”.

3.2.1.3 Estratégia de Busca

A busca foi realizada utilizando os seguintes termos:

- **População:** “*Artificial patients*”OR “*Virtual patients*”
- **Intervenção:** “*Patient generation*”OR “*Synthetic data generation*”OR “*Simulation of clinical data*”
- **Comparação:** “*Real patient data*”OR “*Clinical trial data*”

- **Desfecho:** "Validation of clinical interventions", "Simulation of disease progression", "Personalized medicine"

A *string* de busca foi ajustada para cada base de dados, e a última pesquisa foi realizada em 20/08/2024.

3.2.2 Compilação dos Resultados

Os estudos foram triados de forma independente. Primeiramente, foram analisados os títulos e resumos, seguidos da leitura completa dos artigos considerados relevantes. Ao término, foram encontrados 19 trabalhos sobre geração de pacientes artificiais, listados na Tabela 1.

Tabela 1 – Geração de pacientes através de dados sintéticos

Ano	Referência	Técnica
2015	(HEINRICHS; DEV; DAVIES, 2015)	Modelos matemáticos que simulam a fisiologia humana.
2015	(KLEINSMITH et al., 2015)	O sistema NERVE para estudantes de medicina.
2016	(DAS et al., 2016)	Dados estáticos calibrados com Algoritmos Genéticos.
2016	(PENCE; DUKES; HODGES, 2016)	O sistema SIDNIE para estudantes de enfermagem.
2016	(BABICHENKO et al., 2016)	Modelo baseado em redes <i>Bayesianas</i> com dados reais.
2017	(ZHOU et al., 2017)	Modelagem matemática.
2017	(SOBOCAN; KLEMENC-KETIS, 2017)	Estudo qualitativo em etapas para mensurar pacientes.
2017	(JOHANSSON; SKANTZE; JÖNSSON, 2017)	A plataforma Robô Furhat.
2018	(WALONOSKI et al., 2018)	Modelos de progressão baseados em dados estatísticos.
2018	(TAVARNESI et al., 2018)	Clipes pré-gravados por atores para fornecer realismo.
2019	(PEZOULAS; TACHOS; FOTIADIS, 2019)	Distribuição Log-normal Multivariada; Conjuntos de Árvores Supervisionadas; e Conjuntos de Árvores Não Supervisionadas
2020	(REDJDAL et al., 2020)	Árvores de decisão estruturadas.
2020	(JUÁREZ et al., 2020)	Distribuição multivariada Gaussiana
2020	(SINISI et al., 2020)	Busca no espaço de parâmetros com verificação estatística:
2021	(ZHOU et al., 2021)	Dados clínicos reais combinados com o simulador ODIN
2021	(TAKAHASHI et al., 2021)	GAN e Node2Vec que reproduzem a distribuição estatística dos dados reais.
2022	(ZHANG; YAN; MALIN, 2022)	<i>Framework</i> LS-EHR que aprimora a simulação por meio de <i>fuzzing</i> condicional e regularização, rejeição de amostragem e incorporação de conhecimento prévio.
2024	(CHU; GOODELL, 2024)	Treinamento de <i>chatbots</i> através de LLM .
2024	(BORG; PARODIS; SKANTZE, 2024)	A plataforma Robô Furhat combinada com LLM .

4

Abordagens para Recomendação e Geração de Dados

Este capítulo descreve em detalhes a abordagem metodológica adotada para o desenvolvimento do sistema de recomendação de dietas personalizadas para pacientes oncológicos. Inicialmente, são apresentadas as bases conceituais que fundamentam as decisões metodológicas, inspiradas em estudos prévios, e os critérios que direcionaram a escolha de uma abordagem aplicada, dedutiva, descritiva e interpretativa. Em seguida, o capítulo expõe os procedimentos e técnicas utilizadas na coleta, pré-processamento e integração dos dados dos alimentos e dos pacientes. Como resultado, destaca-se a implementação de um simulador de pacientes oncológicos que gera perfis sintéticos para superar as limitações impostas pela indisponibilidade de dados reais.

Adicionalmente, são detalhados os algoritmos empregados para a recomendação alimentar, incluindo métodos multicritério [TOPSIS](#) e a abordagem multiobjetivo [NSGA-II](#), que, em conjunto, possibilitam a otimização e personalização das dietas.

4.1 Ambiente e Ferramentas

Para a implementação do modelo, optou-se pela linguagem de programação *Python* e pela plataforma *Google Colab*. Essa escolha se deve a diversos fatores, como a facilidade de compartilhamento de código, a ampla disponibilidade de recursos computacionais e bibliotecas especializadas pré-instaladas, além da possibilidade de execução em ambiente *online* através do navegador *Web*.

Os códigos-fonte desenvolvidos estão disponibilizados em um repositório público no [GitHub](#)¹.

¹ <<https://github.com/lucssouares7/Mestrado/blob/main/sronconutri.py>>

4.2 Simulação de Dados de Pacientes Oncológicos

O simulador desenvolvido gera pacientes sintéticos com perfis baseados em parâmetros definidos a partir de um formulário elaborado por um profissional especializado em nutrição oncológica, conforme Quadro 1. Esses parâmetros seguem diretrizes da área, garantindo a compatibilidade dos perfis gerados com a prática clínica e as necessidades nutricionais de indivíduos com câncer.

Quadro 1 – Formulário Diagnóstico

Avaliação Clínica
Antecedentes pessoais:
Patologias atuais:
Histórico familiar de patologias:
Medicamentos em uso:
Fitoterápicos, chás e vitaminas em uso:
Cirurgias já realizadas:
Fase do tratamento oncológico:
Avaliação do Estado Nutricional / Funcionalidade
Peso atual:
Peso há um mês:
Peso há 3 meses:
Peso no diagnóstico (data):
Altura:
Alterações na capacidade funcional:
Atividade física:
Hábitos Sociais
Tabagismo:
Etilismo:
Chimarrão:
Hábito / Ingestão Alimentar
Alterações na ingestão alimentar:
Consistência alimentar aceita:
Alergia ou intolerâncias:
Recusas ou alimentos indigestos:
Alimentos preferidos:
Consumo de suplementos alimentares:
Hábito intestinal:
Hábito urinário:
Hidratação:
Sintomas e Principais Queixas
Efeitos colaterais do tratamento:
Recordatório 24 Horas
Conduta Nutricional Inicial

Fonte: Desenvolvido pela nutricionista oncológica Ana Galeski, CRN-8/7972

Este modelo representa um artefato parcial desenvolvido em *Python*, que implementa um simulador para gerar dados sintéticos de pacientes oncológicos. O simulador visa compensar a falta de dados de pacientes reais por meio da geração de perfis aleatórios que seguem parâmetros médicos e demográficos consistentes.

A definição do tipo de câncer seguiu a prevalência de incidência observada na população, conforme os dados fornecidos pelo [INCA \(INCA, 2022\)](#). Para a estatura do paciente foi determinada uma faixa que contempla os últimos dados antropométricos médios disponíveis da população brasileira feitos pelo [IBGE \(2020\)](#). A Tabela 2 detalha melhor a modelagem desses dados. Na Tabela 2, as colunas P5, P50 e P95 são percentis, que representam pontos específicos na distribuição dos dados de altura por faixa etária e sexo, sendo:

- **P5 (Percentil 5):** Indica o valor abaixo do qual estão os 5% menores valores da distribuição. Ou seja, 5% da população tem altura inferior a esse valor.
- **P50 (Percentil 50 ou Mediana):** Representa o valor central da distribuição, dividindo os dados em duas partes iguais. Isso significa que 50% das pessoas têm altura abaixo desse valor e 50% têm altura acima dele.
- **P95 (Percentil 95):** Indica o valor abaixo do qual estão 95% dos dados. Ou seja, apenas 5% da população tem altura superior a esse valor.

Para definir os níveis de atividade física recomendados para pacientes oncológicos, baseou-se nas diretrizes apresentadas pelo guia da [Sociedade Brasileira de Oncologia Clínica \(SBOC\) \(2023\)](#), o qual incentiva e promove a prática regular de exercícios.

Tabela 2 – Estatísticas da Altura (cm) e Coeficiente de Variação (%) por Faixa Etária e Sexo (IBGE, 2019)

Faixa Etária	Altura (cm)			Coef. de Variação (%)		
	P5	P50	P95	P5	P50	P95
Homens						
18 a 24 anos	161,2	173,9	184,2	5,5	0,6	0,7
25 a 39 anos	161,0	173,4	185,0	0,5	0,2	0,6
40 a 59 anos	158,1	171,5	184,2	0,7	0,4	0,7
60 anos ou mais	155,7	168,0	179,0	0,7	0,3	1,2
Mulheres						
18 a 24 anos	151,2	160,0	169,9	0,5	0,7	1,0
25 a 39 anos	150,9	161,0	171,6	0,5	0,3	0,4
40 a 59 anos	146,7	158,5	170,0	0,5	0,3	0,4
60 anos ou mais	142,9	154,1	166,6	0,8	0,3	0,6

Fonte: Adaptado de ([IBGE, 2020](#))

Tabela 3 – Simulador de Pacientes Oncológicos: Tipos de Dados e Métodos de Geração

Atributo	Tipo de Dado	Descrição
nome	str	Nome completo do paciente
data_nascimento	datetime.date	Data de nascimento do paciente
idade	int	Idade do paciente
peso_atual	float	Peso atual do paciente em kg
sexo	str	Sexo do paciente ('M' ou 'F')
altura	float	Estatura do paciente em metros
atividadeFisica	str	Nível de atividade física
tmb	float	Taxa Metabólica Basal em kcal/dia
Kcal	float	Necessidade calórica diária
alergias	list[str]	Lista de alergias do paciente
intolerancias	list[str]	Lista de intolerâncias alimentares
suplementos_alimentares	list[str]	Lista de suplementos dietéticos
calorias_refeicao	list[float]	Calorias por refeição
data_diagnostico	datetime.date	
peso_diagnostico	float	Peso na época do diagnóstico em kg
peso_mes_passado	float	Peso de um mês atrás em kg
peso_3_meses_passados	float	Peso de três meses atrás em kg
patologias_atuais	str	Tipo de câncer atual
medicamentos	list[str]	Lista de medicamentos atuais
fitoterapico_em_uso	str	Tratamento fitoterápico atual
cirurgias	str	Tipo de cirurgia realizada
fase_tratamento	str	Fase atual do tratamento do câncer
tabagismo	str	Status de tabagismo
etilism	str	Status de uso de álcool
chimarrao	str	Status de consumo de chimarrão
consistencia_alimentar_aceita	int	Número de refeições por dia
alimentos_preferidos	list[str]	Lista de alimentos preferidos
alimentos_indigestos	list[str]	Lista de alimentos problemáticos

Fonte: Autoria própria (2025)

Baseada nas informações anteriores fornecidas pelo [INCA](#) e pelo [Instituto Brasileiro de Geografia e Estatística \(IBGE\)](#), a Tabela 3 detalha os tipos de dados gerados. Resumidamente, são apresentados os atributos, tipos de dados, descrições e métodos de geração.

Em termos de implementação, a classe *Paciente* modela um paciente individual, encapsulando atributos como dados pessoais, informações antropométricas, dados socioculturais, histórico patológico e parâmetros nutricionais. Além disso, a classe oferece métodos que permitem definir e recuperar essas informações, bem como calcular as necessidades nutricionais com base nos dados armazenados.

A Classe GeradorDePessoas gera um número especificado de perfis sintéticos de pacientes. Utiliza a biblioteca *Faker* para criar dados pessoais realistas. Atribui valores aleatórios a vários atributos do paciente com base em listas e probabilidades pré-definidas.

As características do mundo real foram consideradas nesse modelo por meio das seguintes variáveis, utilizadas para mapear elementos específicos da implementação:

- *tipos_cancer_medicamentos*: Dicionário que mapeia tipos de câncer aos medicamentos associados.
- *fitoterapicos*: Lista de tratamentos fitoterápicos, obtidos através da colaboração de nutricionistas oncológico do estudo feito por [Monteiro et al. \(2020\)](#).
- *tipos_cirurgia*: Lista de tipos de cirurgia.
- *fases_tratamento*: Lista de fases do tratamento.
- *tipos_atividade_fisica*: Lista de níveis de atividade física.
- *tipos_alergias*: Lista de alergias comuns.
- *tipos_intolerancias*: Lista de intolerâncias comuns.
- *tipos_suplementos_alimentares*: Lista de suplementos alimentares.

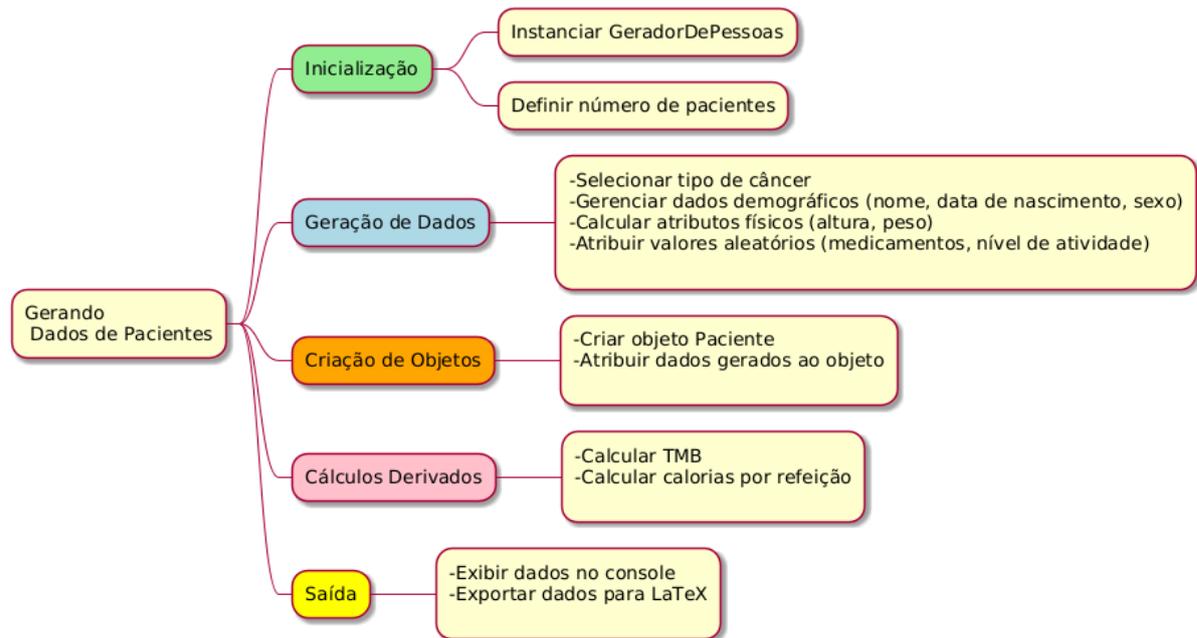
Também foram implementadas funções auxiliares para calcular alguns atributos. Tais funções, em geral, calculam dados de forma pseudo-aleatória, pois utilizam estimativas do mundo real:

- *calcular_idade*: Calcula a idade com base na data de nascimento.
- *calcularPeso*: Determina o peso de um paciente com base no sexo, data de nascimento, altura e conforme o tipo de câncer.
- *definirSexo*: Atribui o sexo mais provável com base no tipo de câncer. Por exemplo, um paciente com câncer de mama tem maior probabilidade de ser do sexo feminino, enquanto o câncer de próstata ocorre exclusivamente em indivíduos do sexo masculino.
- *definirNome*: Gera um nome através da biblioteca Faker com o parâmetro brasileiro e com base no sexo definido anteriormente.

4.2.1 Fluxo de Geração

A Figura 9 apresenta um diagrama que sintetiza o fluxo de trabalho do simulador para a geração de pacientes oncológicos sintéticos.

Figura 9 – Fluxo de Trabalho do Simulador de Pacientes Oncológicos.



Fonte: Autoria própria (2025)

A classe `GeradorDePessoas` é instanciada com o número desejado de pacientes a serem gerados. Em seguida, o método `gerar_pessoas_aleatorias` é chamado, executando as seguintes ações:

- Seleciona aleatoriamente um tipo de câncer de uma lista predefinida pelo dados do [INCA \(2022\)](#), conforme Figura 2.
- Gera os dados demográficos do paciente, como nome, data de nascimento e sexo;
- Calcula os atributos físicos, incluindo altura e peso;
- Atribui valores aleatórios para outros atributos, como medicamentos e nível de atividade física.

Para cada pessoa gerada, um objeto *Paciente* é instanciado. Os dados gerados são atribuídos aos atributos do objeto e, em seguida, os seguintes valores derivados são calculados:

- **TMB**;

- Calorias por refeição;
- Exibição no console para validação e revisão;
- Geração de uma representação em *LaTeX*, permitindo a criação de relatórios.

4.2.2 Geração de Dados Sintéticos

O simulador utiliza listas predefinidas para vários atributos (por exemplo, tipos de câncer, medicamentos, suplementos). Os dados demográficos são gerados utilizando a biblioteca *Faker*, que fornece informações realistas e específicas por região. Desse modo, as principais etapas do processo de geração de dados são:

1. **Cálculo de Peso:** O peso inicial é determinado com base em categorias de [Índice de Massa Corporal \(IMC\)](#), com probabilidades ajustadas por idade e sexo. Mudanças de peso ao longo do tempo são simuladas com base no tipo de câncer, utilizando mudanças percentuais predefinidas.
2. **Cálculo da TMB:** Utiliza a equação de [Harris e Benedict \(1918\)](#), ajustada por um fator de atividade.

$$TMB = \begin{cases} 66,4730 + 13,7516 W + 5,0033 H - 6,7550 A, & \text{homens,} \\ 655,0955 + 9,5634 W + 1,8496 H - 4,6756 A, & \text{mulheres.} \end{cases}$$

Onde:

W : peso (kg),

H : altura (cm),

A : idade (anos).

3. **Preferências Alimentares e Intolerâncias:** Seleciona aleatoriamente alimentos de uma lista predefinida, garantindo que não haja sobreposição, na medida do possível, entre alimentos preferidos e problemáticos.

Limitações e Suposições: O simulador assume certas probabilidades e relações entre variáveis que podem não refletir perfeitamente as distribuições do mundo real. As mudanças de peso são simplificadas e podem não capturar a complexidade completa das dinâmicas de peso em pacientes com câncer. A gama de tipos de câncer, tratamentos e outros fatores médicos é limitada aos predefinidos no código.

Potenciais Melhorias: Incorporar relações mais complexas entre variáveis (por exemplo, probabilidades relacionadas à idade para certos tipos de câncer). Expandir a gama de condições médicas, tratamentos e atributos de pacientes. Implementar algoritmos mais sofisticados de mudança de peso com base nas fases do tratamento e na progressão do câncer.

4.2.2.1 Exemplo de Perfil Sintético Gerado

Nesta seção, apresenta-se um exemplo ilustrativo dos dados sintéticos gerados pelo simulador de pacientes oncológicos. A Tabela 4 lista os principais atributos gerados, tais como dados demográficos, histórico de peso, informações clínicas, além de dados comportamentais e de restrições alimentares.

Tabela 4 – Exemplo de Paciente Oncológico gerado por simulador

Dados do Paciente	
Nome	Yuri Nogueira
Data de Nascimento	1979-05-18 00:00:00
Peso Atual(kg)	62.08
Data do Diagnóstico	2023-12-04 00:00:00
Peso na Data do Diagnóstico (kg)	77.12
Peso há 1 mês (kg)	57.28
Peso há 3 meses (kg)	52.88
Altura (m)	1.56
Sexo	M
Atividade Física	Moderadamente Ativo
Patologias Atuais	Leucemia Promielocítica Aguda
Medicamentos em Uso	[Ácido Retinóico, Daunorubicin]
Fitoterapicos	Alcachofra (Cynara scolymus L.)
Cirurgias	Cirurgia de Estadiamento
Fase do Tratamento Oncológico	Aplicação do Tratamento
Tabagismo	Não
Etilismo	Não
Chimarrao	Sim
Consistência Alimentar aceita	5
Taxa de Metabolismo Basal	2166
Média de calorias por refeição	433.2
Alimentos Preferidos	CARNE FRALDINHA FRITA
Alimentos Indigestos	CARNE PORCO BISTECA FRITA
Alergias	mariscos
Intolerâncias	glúten
Suplementos Alimentares	spirulina

Fonte: Autoria própria (2025)

4.3 Tratamento e Composição dos Dados de Alimentos

Para a obtenção de dados sobre alimentos, já existem estudos que classificam os grupos alimentares no Brasil. Essas informações podem ser encontradas na literatura, incluindo a [TBCA](#), desenvolvida pela [Universidade de São Paulo \(USP\)](#), além de outras fontes nacionais como a [Tabela Brasileira de Composição de Alimentos \(TACO\)](#) desenvolvida pela [Unicamp \(2004\)](#) e também internacionais como a [International Network of Food Data Systems \(INFOODS\)](#) que

é ligada à *United Nations University (UNU)* e ao *Food and Agriculture Administration (FAO)*, que propôs diretrizes e criou ferramentas que implicaram em grande avanço nas tabelas de composição (GIUNTINI; LAJOLO; MENEZES, 2006).

Quanto aos dados de alimentos, a *TBCA* apresenta as porções padronizadas em 100 gramas. Entretanto, constatou-se que as bases de dados disponíveis online frequentemente são excessivamente extensas ou incompletas, o que implica que muitos dados acabam sendo descartados por inviabilidade de serem incluídos em uma dieta adequada. Dessa forma, os alimentos selecionados foram mapeados de maneira similar ao modelo da pirâmide de alimentos proposto por *Philippi (2013)* e organizados em grupos, conforme ilustrado na Tabela 5. Para cada grupo, foram definidos valores energéticos em função da dieta e das quantidades dos alimentos, permitindo estabelecer os equivalentes em energia (*KCAL*).

Tabela 5 – Grupos Alimentares Brasileiros

Grupo	Exemplos
Grupo 1: Óleos e Gorduras	Azeite, manteiga, óleo vegetal, abacate
Grupo 2: Açúcares e Doces	Açúcar, mel, chocolate, sorvete
Grupo 3: Carnes e Ovos	Carne, peixe, ovos, frango
Grupo 4: Leite, Queijo, Iogurte	Leite, queijo, iogurte, coalhada
Grupo 5: Feijões e Oleaginosas	Feijão, lentilhas, grão-de-bico, amêndoas
Grupo 6: Verduras e Legumes	Alface, cenoura, brócolis, abobrinha
Grupo 7: Frutas	Maçã, banana, laranja, morango
Grupo 8: Arroz, Pão, Massa, Batata, Mandioca	Arroz, pão, massa, batata, mandioca, milho

Fonte: Adaptado de (PHILIPPI, 2013)

A credibilidade e precisão da *TBCA* são amplamente reconhecidas pela comunidade científica, o que fortalece a confiabilidade dos modelos matemáticos e consequentemente, as recomendações dietéticas geradas estão fundamentadas em dados nutricionais sólidos (SOARES et al., 2024).

Nesta pesquisa, além do agrupamento tradicional dos alimentos, tornou-se necessário identificar e classificar separadamente as bebidas, com o objetivo de excluí-las do plano alimentar.

4.3.1 Calculadora de Necessidades Nutricionais

A calculadora de macronutrientes, baseada no Consenso Nacional e na fórmula de *Harris e Benedict (1918)*, foi desenvolvida para auxiliar profissionais de saúde e nutricionistas no cálculo das necessidades nutricionais específicas de pacientes oncológicos em diferentes fases do tratamento. Essa ferramenta permite estimar com precisão os requerimentos de macronutrientes — como calorias, proteínas, carboidratos e gorduras —, bem como de micronutrientes essenciais, contribuindo para otimizar a resposta terapêutica e melhorar a qualidade de vida dos pacientes, conforme as orientações do Consenso Nacional de Nutrição Oncológica (INCA, 2015).

A calculadora define o grupo etário do paciente - pediátrico, adulto ou idoso - com base na idade, o que permite ajustar as recomendações nutricionais de acordo com as diferentes necessidades ao longo da vida. As necessidades calóricas e de macronutrientes são calculadas considerando o peso, o IMC, a fase do tratamento e o nível de atividade física do paciente. As fases do tratamento oncológico incluem o tratamento ativo, a recuperação, a manutenção da saúde e a doença avançada, e cada uma delas requer adaptações nutricionais específicas. Durante o tratamento ativo, o foco é fornecer suporte calórico adequado para enfrentar o estresse metabólico; na recuperação, as necessidades são ajustadas para restaurar o estado nutricional; na manutenção da saúde, a dieta é balanceada para prevenir recorrências e preservar a saúde; na doença avançada, o foco está no conforto do paciente, priorizando alimentos de fácil digestão e com alta densidade calórica.

Para utilizar a calculadora, é necessário fornecer dados demográficos, como nome, idade e sexo, além de informações antropométricas, incluindo peso atual e altura, que permitem o cálculo automático do IMC. A fase do tratamento e as patologias atuais também são consideradas, pois influenciam as necessidades nutricionais do paciente. O nível de atividade física, classificado de sedentário a extremamente ativo, também é levado em conta para ajustar o gasto energético. A calculadora também permite incluir informações sobre alergias, intolerâncias e preferências alimentares, possibilitando a personalização das refeições de acordo com as necessidades e limitações do paciente.

O IMC é definido pela [Organization \(2000\)](#) um índice simples de peso-altura, comumente usado para classificar baixo peso, sobrepeso e obesidade em adultos. Ele é definido como o peso em quilogramas dividido pelo quadrado da altura em metros (kg/m^2). O cálculo do IMC é dado pela Equação 1.

$$\text{IMC} = \frac{\text{Peso}}{\text{Altura}^2} \quad (1)$$

Por exemplo, um adulto que pesa 70 kg e tem altura de 1,75 m terá um IMC de 22,9 pois

$$\text{IMC} = \frac{70 \text{ kg}}{(1,75 \text{ m})^2} = 22,9$$

Conforme o [SBNO \(2021\)](#), esse valor é utilizado para ajustar as necessidades de proteínas e calorias com base no estado nutricional do paciente. As necessidades calóricas são ajustadas conforme a fase do tratamento e o grupo etário do paciente. Por exemplo, para um adulto em tratamento ativo, recomenda-se cerca de 25 kcal por quilograma de peso corporal, enquanto na fase de recuperação a necessidade cai para 22 kcal/kg. Na fase de manutenção da saúde, a recomendação é entre 18 e 22 kcal/kg, e, na fase de doença avançada, 20 kcal/kg é a quantidade recomendada para manter o conforto e evitar perda de peso indesejada. As necessidades proteicas também variam conforme o IMC: para pacientes com IMC abaixo de 30, a necessidade é de 1,5 g/kg de peso; entre 30 e 40, recomenda-se 2 g/kg; e acima de 40, 2,5 g/kg, considerando que a proteína é essencial para a preservação da massa muscular e a recuperação do paciente.

Algoritmo 3: Algoritmo para Determinar o Grupo Etário

```
Input: idade  
Output: grupo etário  
1 if idade ≤ 18 then  
2 | grupo ← pediátrico;  
3 end  
4 else if idade ≥ 60 then  
5 | grupo ← idoso;  
6 end  
7 else  
8 | grupo ← adulto;  
9 end  
10 return grupo;
```

Como exemplo, para um paciente adulto com 60 kg, IMC de 22, em fase de recuperação e com atividade física leve, a calculadora indicaria uma necessidade diária de 1320 kcal (60 kg x 22 kcal/kg) e 90 g de proteínas (60 kg x 1,5 g/kg), com os carboidratos e gorduras distribuídos conforme uma proporção balanceada de macronutrientes, a fim de garantir o suporte nutricional adequado.

A calculadora de macronutrientes, baseada no Consenso Nacional de Nutrição Oncológica [SBNO \(2021\)](#), é uma ferramenta fundamental para a elaboração de planos alimentares individualizados para pacientes oncológicos, proporcionando um suporte nutricional eficaz que visa atender às necessidades de cada paciente conforme a fase do tratamento, melhorando a qualidade de vida e promovendo um acompanhamento nutricional completo.

4.3.1.1 Pseudocódigo da Calculadora de Macronutrientes

Algoritmo 4: Calcular Calorias e Proteínas

Input: peso, IMC, fase_tratamento
Output: calorias, proteinas

```
1 if fase_tratamento = tratamento_ativo then
2   | calorias  $\leftarrow$  25  $\times$  peso;
3   | if IMC < 30 then
4   |   | proteinas  $\leftarrow$  1.5  $\times$  peso;
5   |   | else
6   |   |   | if IMC < 40 then
7   |   |   |   | proteinas  $\leftarrow$  2.0  $\times$  peso;
8   |   |   |   | else
9   |   |   |   |   | proteinas  $\leftarrow$  2.5  $\times$  peso;
10  |   |   |   |   | end
11  |   |   |   | end
12  |   | end
13  | else if fase_tratamento = recuperacao then
14  |   | calorias  $\leftarrow$  25  $\times$  peso;
15  |   | if IMC < 30 then
16  |   |   | proteinas  $\leftarrow$  1.2  $\times$  peso;
17  |   |   | else
18  |   |   |   | proteinas  $\leftarrow$  1.5  $\times$  peso;
19  |   |   |   | end
20  |   | end
21  | else if fase_tratamento = manutencao_saude then
22  |   | calorias  $\leftarrow$  22  $\times$  peso;
23  |   | proteinas  $\leftarrow$  1.0  $\times$  peso;
24  |   | end
25  | else if fase_tratamento = doenca_avancada then
26  |   | calorias  $\leftarrow$  20  $\times$  peso;
27  |   | proteinas  $\leftarrow$  0.8  $\times$  peso;
28  |   | end
29  | else
30  |   | calorias  $\leftarrow$  0;
31  |   | proteinas  $\leftarrow$  0;
32  |   | end
33 return calorias, proteinas;
```

Algoritmo 5: Calculadora de Necessidades Nutricionais

Input: idade, peso, altura, fase_tratamento, consistencia_alimentar
Output: macronutrientes, recomendações, micronutrientes

- 1 grupo ← DeterminarGrupoEtario(idade);
- 2 IMC ← peso / (altura)²;
- 3 (calorias, proteínas) ← CalcularEnergetica(peso, IMC, fase_tratamento);
- 4 //Definir gordura, carboidratos e hidratação com base em grupo e peso;
- 5 **if** consistencia_alimentar definida **then**
- 6 | refeicoes ← consistencia_alimentar;
- 7 **end**
- 8 **else**
- 9 | refeicoes ← 5;
- 10 **end**
- 11 calorias_refeicao ← calorias / refeições;
- 12 //Definir recomendações padrões (ex.: consumo de frutas, legumes, carnes, sal, álcool);
- 13 macronutrientes ← { calorias, proteínas, gordura, carboidratos, hidratação, refeições, calorias_refeicao };
- 14 **return** macronutrientes, recomendações, micronutrientes;

A calculadora também pode ser capaz de definir micronutrientes e suplementos para o paciente, tais como vitaminas e minerais que podem ser encontrados em alimentos ou obtidos por meio de suplementação. E também poderia gerar recomendações instrutivas, pois, além das quantidades de alimentos, o cuidado ao consumir também é relevante na nutrição oncológica.

4.3.2 Verificar Alergias, Intolerâncias e Incompatibilidades

A partir do simulador de pacientes oncológicos, foram desenvolvidos métodos para incluir possíveis restrições alimentares específicas de cada paciente. Essas restrições foram configuradas com base em condições comuns observadas no Brasil e atribuídas de maneira aleatória no contexto do simulador.

Após a geração dos dados dos pacientes e a criação das bases de alimentos, foram aplicados filtros específicos para mapear e excluir alimentos que poderiam ser prejudiciais ou incompatíveis com as condições individuais dos pacientes.

Esses filtros foram organizados em quatro etapas complementares, descritas a seguir.

4.3.2.1 Filtro de Alergias

O objetivo deste filtro é identificar e remover alimentos ou ingredientes associados a alergias previamente indicadas pelo paciente. Para isso, foi utilizado um mapeamento que

relaciona alergias conhecidas (como trigo, leite e amendoim) com categorias alimentares. Por exemplo, um paciente alérgico ao trigo terá automaticamente excluídos da lista alimentos categorizados como cereais, pães e massas.

4.3.2.2 Filtro de Alimentos Indigestos

Este filtro identifica e exclui alimentos que o paciente considera indigestos, independentemente de fatores médicos. Essa etapa é importante para personalizar a dieta com base nas preferências e no conforto do paciente. Por exemplo, alimentos como carne ou leite podem ser considerados indigestos por determinados pacientes e, por isso, são excluídos.

4.3.2.3 Filtro de Intolerâncias

O filtro de intolerâncias aborda alimentos que podem causar reações adversas devido à incapacidade do paciente de digerir determinados nutrientes, como lactose ou glúten. Através de um mapeamento de intolerâncias para categorias alimentares, os alimentos são analisados e excluídos caso estejam relacionados às intolerâncias do paciente.

4.3.2.4 Filtro de Incompatibilidades Oncológicas

Este filtro aplica uma abordagem mais abrangente, considerando alimentos, ingredientes e formas de preparo que geralmente são desaconselhados para pacientes oncológicos, conforme o [SBNO \(2021\)](#). Alimentos embutidos, crus, ultraprocessados e com baixo valor nutricional são identificados e removidos da lista, garantindo que as recomendações finais atendam às necessidades de uma dieta oncológica equilibrada e segura.

4.3.2.5 Restrições devido a medicação

Desde a década de 1970, a [OMS](#) implementa políticas para ampliar o acesso a medicamentos, recomendando listas nacionais baseadas em sua [Lista Modelo de Medicamentos Essenciais \(EML\)](#). No Brasil, esse processo iniciou-se em 1964, com o Decreto nº 53.612, e foi formalizado em 1975 como [Relação Nacional de Medicamentos Essenciais \(RENAME\)](#) ([Ministério da Saúde, 2022](#)). A [EML](#) inclui medicamentos destinados a pacientes oncológicos.

Foram mapeados alguns desses medicamentos conforme os tipos de câncer mais incidentes no país. Os dados utilizados foram extraídos das bulas disponíveis no [Bulário Eletrônico da ANVISA \(2024\)](#) e do [Einstein \(2017\)](#); além disso, foi elaborado um arquivo de dados estruturado contendo informações detalhadas sobre medicamentos comumente utilizados no tratamento oncológico, conforme apresentado na Tabela 6. Esse arquivo serve de base para que o modelo possa gerar respostas precisas e contextualizadas sobre restrições alimentares, contribuindo para a personalização do atendimento nutricional dos pacientes oncológicos.

Tabela 6 – Recomendações nutricionais baseadas em medicamentos oncológicos.

Medicamento	Aspecto Nutricional	Recomendações nutricionais
Capecitabina	Diarreia	Evitar alimentos ricos em fibras; atenção à hidratação.
Cisplatina	Náuseas e Vômitos	Evitar consumir líquidos durante as refeições; preferir alimentos fáceis de digerir; manter hidratação adequada.
Cisplatina	Neutropenia	Redobrar atenção à higienização de alimentos; evitar alimentos crus ou mal cozidos.
Tamoxifeno	Anemia	Consumir alimentos ricos em ferro e vitamina C; evitar chá, café e alimentos ricos em cálcio.
Paclitaxel	Neutropenia	Evitar alimentos crus ou não pasteurizados devido ao risco de infecção.
Fluoruracila	Diarreia	Evitar alimentos ricos em fibras insolúveis; manter hidratação rigorosa.
Docetaxel	Náuseas e Vômitos	Evitar alimentos irritantes; manter refeições leves e hidratação.
Doxorrubicina	Mucosite	Evitar alimentos ácidos, crocantes ou que possam machucar a mucosa.
Carboplatina	Náuseas e Vômitos	Preferir alimentos gelados ou em temperatura ambiente e de fácil digestão; manter hidratação adequada.
Carboplatina	Neutropenia	Higienizar bem frutas e hortaliças; evitar alimentos crus ou mal cozidos.
Oxaliplatina	Sensibilidade ao Frio	Evitar consumo de alimentos e bebidas geladas para reduzir desconforto.
Trastuzumabe	Reação Sistêmica	Evitar alimentos que possam causar desconforto gástrico em casos de efeitos colaterais sistêmicos.
Gefitinibe	Diarréia	Evitar alimentos gordurosos ou ricos em fibras insolúveis; manter hidratação.

Fonte: Adaptado de (EINSTEIN, 2017; ANVISA, 2024)

4.4 Gerador de Dietas para Pacientes Oncológicos

Após a aplicação dos filtros, é gerada uma lista refinada contendo apenas os alimentos apropriados para a dieta de um paciente específico, levando em consideração suas restrições alimentares individuais.

4.4.1 Função Objetivo

O principal objetivo da dieta para o paciente oncológico é garantir uma nutrição adequada que minimize a perda de massa magra durante o tratamento. Para isso, modelamos uma função objetivo que busca maximizar a ingestão de proteínas, minimizar o consumo de gorduras e

carboidratos, e manter a ingestão calórica dentro dos limites da **TMB**, evitando assim um superávit calórico.

A função objetivo para a dieta do paciente oncológico pode ser formulada como um problema de otimização multiobjetivo, onde se busca maximizar a ingestão de proteínas, enquanto se minimiza o consumo de gorduras e carboidratos. Assim, o modelo é definido por:

$$\begin{aligned} \max \quad & P, \\ \min \quad & (G + C), \end{aligned}$$

sujeito à restrição calórica:

$$\sum_{i=1}^n \text{Calorias}_i \leq \text{TMB}. \quad (2)$$

Onde:

- P representa a quantidade total de proteínas na dieta;
- G representa a quantidade total de gorduras;
- C representa a quantidade total de carboidratos;
- $\sum_{i=1}^n \text{Calorias}_i$ é a soma das calorias dos alimentos selecionados;
- **TMB** é a taxa de metabolismo basal do paciente.

Logo nos resultados preliminares do método **TOPSIS**, observou-se que a melhor escolha de alimento era sempre a mesma. Como pode ser visto na Tabela 7. Dessa forma, tornou-se necessário ajustar o método e seus parâmetros para permitir a obtenção de uma dieta personalizada.

Para evitar a repetição de alimentos ao longo do dia, foram realizadas verificações que garantem a inclusão de um conjunto de dados sem repetições, assegurando maior variedade na dieta e reduzindo a recomendação de alimentos similares. Mas não foi possível garantir que alimentos semelhantes fossem incluídos na mesma dieta e também é possível ocorrer a repetição de alimentos em dias diferentes.

Tabela 7 – Exemplo de Resultado com Informações de Alimentos

Paciente	Alimentos	Quantidade de Porções
Paciente 1	MACARRÃO INTEGRAL C/ MOLHO PESTO	100
	– Proteínas: 97,8	
	– Carboidratos: 18,9	
	– Gorduras: 60,6	
	– Fibras: 24,7	

Fonte: Autoria própria (2025)

É possível perceber que na Tabela 7 o mesmo alimento foi sugerido cem vezes, logo, foi necessária adaptação do código para contornar esses casos.

O refinamento dos parâmetros do método **TOPSIS** resultou em recomendações mais alinhadas com as necessidades nutricionais reais dos pacientes. Um aspecto crucial considerado neste ajuste foi a tendência à desnutrição e perda de massa muscular frequentemente observada em pacientes oncológicos, conforme evidenciado pela literatura científica (REIS; LIMA; LIMA, 2023; COLLING; DUVAL; SILVEIRA, 2012). Em resposta a essa condição específica, os métodos de geração de recomendações dietéticas foram calibrados para priorizar alimentos com alto teor proteico, reduzindo a ênfase em alimentos ricos em gorduras e carboidratos. Esta abordagem é fundamentada no papel essencial das proteínas na preservação e regeneração do tecido muscular, aspectos particularmente relevantes no contexto do tratamento oncológico. Os dados resultantes, tanto dos alimentos selecionados quanto das características do paciente, são utilizados como entradas para dois algoritmos distintos, responsáveis por otimizar e personalizar as recomendações alimentares.

4.4.2 Principais Soluções

Para a implementação do algoritmo multicritério **TOPSIS** (HWANG et al., 1981), foram utilizadas bibliotecas como a *TOPSISpy*, pois essa versão estava disponível na linguagem *python*. Enquanto para a implementação do algoritmo multiobjetivo **NSGA-II** foi utilizado o *framework PyMOO* - Otimização Multiobjetivo em *Python* na sua versão 3. É uma biblioteca em *Python* focada na resolução de problemas de otimização multiobjetivo. Ela fornece implementações eficientes de algoritmos evolucionários usados para encontrar soluções em problemas onde há múltiplos critérios conflitantes a serem considerados.

4.4.2.1 Solução Multicritério

Para aplicar o algoritmo **TOPSIS**, precisamos organizar os alimentos em refeições. Isso ocorre porque o **TOPSIS** é um método de tomada de decisão. Assim, a cada refeição, o método precisa determinar quais alimentos devem ser incluídos ou excluídos da dieta sugerida.

Foram gerados pacientes pelo simulador; o sistema de geração não tem limitações além dos recursos do sistema e da linguagem, portanto, foram gerados pacientes de características diferentes para que os resultados pudessem ser comparados em diferentes contextos.

Antes da aplicação do método **TOPSIS** para recomendação alimentar, realiza-se um pré-processamento dos dados, onde são adicionadas colunas de *score* e *rank* ao *dataframe* para identificar os alimentos que melhor atendem às necessidades nutricionais estabelecidas.

Os seguintes parâmetros foram aplicados ao Método **TOPSIS**:

- **Matriz de Decisão:** Consiste na seleção dos critérios que representam os aspectos

nutricionais dos alimentos (nesse caso, ENERGIA KCAL, PROTEÍNA, CARBOIDRATO TOTAL, LIPÍDIOS e FIBRA ALIMENTAR).

- **Pesos:** Vetor que atribui a importância relativa de cada critério. No caso, utilizamos o vetor $[0.1, 0.1, 0.1, 0.1, 0.1]$ para não priorizar nenhum critério em detrimento dos demais.
- **Direções (ou Impactos):** Vetor que define se os critérios devem ser maximizados ou minimizados. Por exemplo, o vetor $[0, 1, 0, 0, 0]$ indica que o critério PROTEÍNA deve ser maximizado enquanto os demais devem ser minimizados.

Após essa etapa, foi realizada a aplicação do método efetivamente. Como se trata de um método de escolhas baseadas em multicritérios, foram mapeadas estruturas de dados que representam as refeições dos pacientes. Nesse caso, optou-se por realizar as refeições da semana, respeitando a consistência alimentar definida anteriormente.

O sistema classifica as refeições em dois tipos principais: Café da manhã/Lanche e Almoço/Jantar. Esta classificação foi adotada considerando que determinados alimentos podem ser adequados para ambos os tipos de refeição.

Para cada refeição, o método **TOPSIS** é aplicado para determinar a melhor combinação de alimentos dentre as opções viáveis. O sistema seleciona os alimentos conforme os parâmetros estabelecidos, respeitando as restrições de macronutrientes, o que permite que as recomendações geradas possam ser posteriormente adaptadas por um nutricionista oncológico na elaboração do plano alimentar personalizado para o paciente.

4.4.2.2 Solução Multiobjetivo

Assim, tanto o método **TOPSIS** quanto o método **NSGA-II** operam sobre conjuntos idênticos de dados para definir os parâmetros da dieta. As condições de aplicação também foram mantidas constantes, incluindo a consistência alimentar, a organização em refeições diárias e a quantidade aleatória de alimentos por refeição, que varia entre 2 e 5 itens.

Esta padronização das entradas e condições permite uma avaliação mais precisa de cada método, eliminando possíveis variações decorrentes de diferentes conjuntos de dados ou parâmetros e buscando garantir uma comparação consistente entre os métodos.

O algoritmo **NSGA-II** (DEB et al., 2000) utiliza o conceito da Fronteira de Pareto, o que significa que não há uma única solução ótima, mas sim um conjunto de soluções equilibradas entre os critérios definidos (DEB et al., 2000).

Um dos aspectos observados nas dietas geradas por esse algoritmo é que a quantidade de calorias recomendada tende a ficar abaixo da **TMB** do paciente, ou seja, o consumo calórico sugerido é inferior ao necessário para a manutenção do peso atual.

Sob uma perspectiva computacional, essa abordagem pode parecer ineficiente, pois a solução gerada não atinge diretamente os requisitos calóricos ideais. No entanto, dentro do contexto de um **SR**, essa característica oferece flexibilidade para que um nutricionista oncológico possa ajustar a dieta, seja adicionando novos alimentos ou aumentando as quantidades dos já recomendados, garantindo uma abordagem personalizada e adaptada às necessidades individuais do paciente.

Para aplicar o método **NSGA-II** neste problema, utilizou-se população de tamanho $\mu = 200$, número de gerações igual a 200, DataFrame contendo os alimentos extraídos da **TBCA**, cinco dias de dieta semanal, número de refeições por dia definido conforme a consistência alimentar do paciente e número de alimentos por refeição sorteado aleatoriamente entre 2 e 5. A meta calórica diária foi fixada na **TMB** do paciente, com peso de 10,0 atribuído ao desvio energético na função objetivo e razão mínima de energia exigida de 90% da meta. Usou-se seed igual a 1, amostragem inicial inteira aleatória, operador de *crossover* discreto (**DiscreteCrossover**) com probabilidade $p_c = 0,9$, operador de mutação **PolynomialMutation** com probabilidade

$$p_m = \frac{1}{\text{total_foods}}$$

e seleção por torneio binário (**TournamentSelection**) com pressão igual a 2. Adotou-se ainda o esquema $\mu + \lambda$ com $\mu = \lambda = 200$, ou seja, sem elitismo adicional.

A taxa de *crossover* $p_c = 0,9$ significa que em 90% dos pares de pais aplica-se o **Simulated Binary Crossover (SBX)**, gerando dois filhos então arredondados para índices inteiros válidos. A mutação emprega o **PolynomialMutation** de forma que cada gene, com probabilidade $1/\text{total_foods}$, sofre uma perturbação segundo distribuição polinomial (parâmetro η) e depois é projetado no intervalo de índices do DataFrame. Como alternativa, o *crossover* discreto gera uma máscara binária aleatória e, em cada posição, escolhe-se o gene de um ou de outro pai sem interpolar valores. A seleção de pais utiliza torneio binário: em cada disputa escolhem-se dois indivíduos aleatoriamente e avança como vencedor aquele com melhor *rank* de Pareto (ou, em caso de empate, maior distância de *crowding*). Finalmente, violações de meta calórica ou duplicação excessiva aparecem como restrições positivas em

$$G_{\text{upper}} = \text{energia_dia} - \text{meta_calórica}, \quad G_{\text{dup}} = \#\text{itens} - \#\text{itens únicos},$$

e o **NSGA-II** aplica dominação por restrição – soluções factíveis dominam as violadas, e entre estas são preferidas as de menor soma de violações.

5

Resultados e Discussão

Neste capítulo, são apresentados e analisados os resultados obtidos na geração de recomendações dietéticas para pacientes em tratamento oncológico. Seguindo a abordagem de [Soares et al. \(2024\)](#), serão apresentados dados hipotéticos de pacientes gerados pelo simulador implementado, seguidos pelas recomendações obtidas a partir de dois métodos distintos: [TOPSIS](#) e [NSGA-II](#).

Os resultados são apresentados em tabelas organizadas por dias da semana, onde cada tabela contém as recomendações alimentares específicas para as refeições estabelecidas. Uma característica relevante do método [TOPSIS](#) é a possibilidade de incluir um mesmo alimento múltiplas vezes na dieta, desde que sejam respeitadas as restrições calóricas.

Analisando as tabelas de resultados, observa-se que as dietas recomendadas mantêm-se consistentemente próximas à taxa de metabolismo basal do paciente, evidenciando a capacidade do método [TOPSIS](#) em convergir para soluções próximas ao ideal estabelecido.

5.1 Experimentos

Entre os resultados esperados, destacava-se o desenvolvimento de um artefato de *software*: um sistema de recomendação para nutrição oncológica baseado em decisão multicritério. Esse sistema deveria utilizar dados de pacientes reais para sugerir alimentos a serem incluídos nos planos alimentares. Devido à indisponibilidade de dados públicos de pacientes reais, optou-se pelo desenvolvimento de um sistema para gerar dados sintéticos, simulando perfis de pacientes oncológicos. Esse sistema abrange informações pessoais, histórico médico, estado nutricional (peso, medidas, patologias etc.), hábitos sociais e alimentares, além de alergias, intolerâncias alimentares e alimentos de difícil digestão.

Conforme o levantamento realizado pelo [INCA \(2022\)](#), os tipos de câncer com maior incidência no Brasil foram selecionados e organizados em uma estrutura de dicionário de dados.

Para cada paciente gerado no simulador, foi atribuído um tipo de câncer, que serviu como base para a definição de outras características, iniciando pelos medicamentos prescritos e seguindo com os dados pessoais. Ainda de acordo com as estatísticas apresentadas pelo INCA (2022), as probabilidades de ocorrência dos diferentes tipos de câncer foram definidas com base no sexo biológico do paciente, considerando que alguns tipos são mais prevalentes em homens ou mulheres. Após a atribuição do sexo, o nome do paciente foi gerado utilizando a biblioteca *Faker*¹, e ajustado para nomes brasileiros. O nome do paciente não influencia aspectos nutricionais, sendo incluído apenas para conferir realismo à simulação dos dados. Por outro lado, o sexo biológico impacta o cálculo da taxa de metabolismo basal, tornando sua consideração essencial para o ajuste adequado das necessidades nutricionais.

Além disso, em determinados casos, foi necessário considerar relações de dependência entre os dados. Por exemplo, ao selecionar ‘Câncer de Próstata’ como a patologia do paciente hipotético, os medicamentos atribuídos foram aqueles indicados na literatura para esse tipo de câncer. Da mesma forma, levando em conta que essa doença ocorre exclusivamente em pacientes do sexo masculino, o método que definiu o sexo do paciente influenciou diretamente a escolha do nome, garantindo coerência nos dados gerados.

Após a geração dos dados de um determinado número de pacientes oncológicos pelo simulador, o sistema deve cruzar suas preferências e restrições com um banco de alimentos previamente modelado, fornecendo recomendações para compor dietas personalizadas.

Para cada paciente, foram selecionados dados alimentares da TBCA USP (2023), organizados em um arquivo *Comma Separated Valued (CSV)* com mais de 5000 alimentos extraídos de diversas regiões do país. Esses dados foram processados para identificar alimentos com ingredientes potencialmente problemáticos, como aqueles aos quais o paciente apresentava alergia, intolerância, dificuldade de digestão ou incompatibilidade com o tratamento oncológico.

Finalmente, no contexto dos objetivos computacionais, buscou-se minimizar a ingestão calórica e maximizar a oferta de proteínas, conforme apresentado no Capítulo 4.

Seguindo a abordagem de PAULINO (2017) e, posteriormente, de Soares et al. (2024), foram conduzidos três experimentos com pacientes de perfis distintos para gerar resultados e avaliar os modelos, cujos detalhes serão apresentados nas seções seguintes.

Os alimentos destinados a esses pacientes foram filtrados para excluir aqueles aos quais o paciente apresenta alergia, intolerância ou que, por preferência pessoal, não consome.

5.1.1 Experimento 1

Para o experimento 1 foi gerado um paciente feminino, com Câncer de Mama e nível de atividade física considerado Levemente Ativo, conforme a Tabela 8.

¹ <<https://pypi.org/project/Faker/>>

Tabela 8 – Paciente 1

Atributo	Valor
Nome	Laura Peixoto
Data de Nascimento	1982-10-09
Data do Diagnóstico	2024-11-25
Peso na Data do Diagnóstico (kg)	91.080000
Peso há 3 meses (kg)	91.440000
Peso há 1 mês (kg)	91.810000
Peso Atual (kg)	92.180000
Altura (m)	1.560000
Sexo	F
Atividade Física	Levemente Ativo
Patologias Atuais	Câncer de Mama
Medicamentos em Uso	Trastuzumab, Tamoxifeno, Paclitaxel, Capecitabina, Docetaxel
Fitoterapicos	Cáscara-sagrada (<i>Rhamnus purshiana</i> D.C.)
Cirurgias	Cirurgia Debulking (Cirurgia Citorredutora)
Fase do Tratamento Oncológico	Doença Avançada
Tabagismo	Sim
Etilismo	Não
Chimarrao	Sim
Consistência Alimentar aceita	5
Taxa de Metabolismo Basal	1843.55 Kcals/dia
Média de calorias por refeição	368.71 Kcals/refeição
Alimentos Preferidos	PAPA DE CARNE BOVINA (MÚSCULO), FEIJÃO PRETO, BATATA BAROA (MANDIOQUINHA, SALSA) E ABÓBORA CABOTIAN (JAPONESA), C/ CALDO DE FRANGO, C/ CEBOLA, S/ ÓLEO, S/ SAL,
Alimentos Indigestos	SUFLÊ, CENOURA, C/ MOLHO BRANCO, C/ QUEIJO PARMESÃO, C/ SAL, (CENOURA, OVO DE GALINHA, FARINHA DE ROSCA, SALSA, QUEIJO PARMESÃO, C/ MOLHO BRANCO (FARINHA DE TRIGO, MANTEIGA E LEITE), C/ ÓLEO, CEBOLA E ALHO, C/ SAL),
Alergias	CHOCOLATE
Intolerâncias	AMENDOIM
Suplementos Alimentares	malato de citrulina

Fonte: Autoria própria (2025)

5.1.1.1 Resultados do Método TOPSIS

As recomendações de alimentos a serem adicionados na dieta para 5 dias da semana para o Paciente 1 são mostradas nas Tabelas 9 à 13, que representam as dietas geradas através do método TOPSIS.

Tabela 9 – Experimento 1 (TOPSIS): Segunda-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CEREAL	1	335,00	13,10	74,20	4,90
COENTRO	1	294,00	20,90	48,00	10,40
FRAMBOESA	5	225,00	6,00	59,50	3,25
SALADA DE FRUTAS	5	140,00	2,95	44,10	1,00
TOMILHO	3	321,00	16,68	73,50	5,04
OMELETE VEGANO	2	310,00	15,22	58,40	5,10
Total do Dia		1625,00	74,85	357,70	29,69

Fonte: Autoria própria (2025)

Tabela 10 – Experimento 1 (TOPSIS): Terça-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
FRUTA PÃO	5	320,00	5,40	86,00	0,95
SOPA	1	293,00	83,10	69,00	6,63
QUIBE VEGETARIANO COM CENOURA	2	246,00	27,20	36,00	1,16
FEIJÃO PRETO	5	315,00	17,90	60,50	7,50
QUIBE VEGETARIANO COM TOMATE E PIMENTÃO	2	248,00	27,20	36,20	1,16
CREME DE GOIABA	1	53,00	2,12	9,96	1,29
Total do Dia		1475,00	162,92	297,66	18,69

Fonte: Autoria própria (2025)

Tabela 11 – Experimento 1 (TOPSIS): Quarta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
ABACATE	4	304,00	4,60	23,36	24,84
MEXERICA	1	36,00	0,65	9,34	0,13
VAGEM MANTEIGA	1	20,00	1,35	4,43	0,14
FEIJÃO CARIOCA	4	368,00	20,60	71,20	6,28
PERA	5	265,00	2,85	70,00	0,55
LARANJA	1	52,00	0,83	12,80	0,36
CAJÁ-MANGA	1	46,00	1,28	11,40	0,00
CALDO DE FEIJÃO	5	230,00	13,90	44,20	5,25
FEIJOADA VEGETARIANA	2	100,00	4,96	19,30	2,36
KIWI	5	295,00	6,25	63,50	5,00
CREME DE ABACATE	1	70,00	2,01	5,52	5,07
Total do Dia		1786,00	59,28	335,05	49,98

Fonte: Autoria própria (2025)

Tabela 12 – Experimento 1 (TOPSIS): Quinta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
QUIBEBE	4	312,00	34,24	26,40	10,68
CAJU	1	43,00	0,77	10,10	0,49
SALADA	5	200,00	14,20	24,85	9,45
ALMEIRÃO	1	86,00	1,68	6,15	7,20
MOLHO	1	71,00	5,04	14,60	0,14
MORANGO	5	150,00	4,10	32,70	2,00
MAÇÃ	4	192,00	1,20	52,00	0,00
CARNE	2	254,00	50,80	1,70	5,34
PEIXE	1	88,00	30,80	0,04	2,29
SANDUÍCHE	2	268,00	11,74	52,60	2,72
PÊSSEGO	2	84,00	1,76	20,20	0,36
Total do Dia		1748,00	156,33	241,34	40,67

Fonte: Autoria própria (2025)

Tabela 13 – Experimento 1 (TOPSIS): Sexta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CAJÁ	5	135,00	2,95	31,85	0,85
PÃO	1	232,00	10,70	45,90	1,79
TOMATE	5	225,00	8,05	45,05	5,30
VAGEM	2	98,00	5,36	15,94	2,92
MANGA	5	260,00	4,30	64,00	1,10
CREME DE KIWI	2	98,00	4,46	15,36	2,78
SUSHI	2	270,00	16,10	44,00	5,42
PRATO DE COMIDA BRASILEIRO REGIÃO SUDESTE	1	96,00	5,70	14,20	2,66
PERU	1	186,00	24,90	0,54	9,31
CREME DE MANGA	3	153,00	6,03	25,98	3,57
Total do Dia		1753,00	88,55	302,82	35,70

Fonte: Autoria própria (2025)

Analisando os dados do experimento 1 para o método **TOPSIS**, é possível perceber que não houve violação das restrições calóricas conforme o proposto, a quantidade de proteínas sempre esteve superior a lipídios.

5.1.1.2 Resultados do Método NSGA-II

O método NSGA-II gerou as recomendações de produtos a serem adicionados à dieta do Paciente 1 para cinco dias da semana, conforme apresentado nas Tabelas 14 à 18.

Tabela 14 – Experimento 1 (NSGA-II): Segunda-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
ESTROGONOFFE DE FRANGO	1	152,00	17,50	2,58	7,93
QUEIJO MINAS TIPO	1	448,00	31,90	2,48	35,00
SOPA MILHO FUBÁ	1	69,00	1,93	13,40	1,16
FRANGO AO MOLHO	1	149,00	20,30	1,47	6,99
BATATA INGLESA COZIDA	1	57,00	1,41	11,10	1,09
GOIABA BRANCA INTEIRA	1	45,00	0,79	12,30	0,51
OVO GALINHA INTEIRO	1	125,00	10,40	1,38	8,70
INHAME S/ CASCA	1	92,00	2,38	21,20	0,15
BISCOITO DOCE	1	452,00	7,85	75,10	14,10
CARNE BOI QUARTO	1	223,00	31,90	0,49	10,30
Total do Dia		1812,00	126,36	141,50	85,93

Fonte: Autoria própria (2025)

Tabela 15 – Experimento 1 (NSGA-II): Terça-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CARNE BOI PATINHO	1	212,00	34,20	0,79	8,00
CHURRASQUINHO ESPETINHO CARNE	1	200,00	22,80	4,08	10,40
SANDUÍCHE PEITO	1	237,00	17,30	27,40	6,87
PEIXE ÁGUA SALGADA	1	108,00	17,70	0,98	3,79
CAPELETI C/ CARNE	1	149,00	6,96	24,20	3,07
COUVE-FLOR À MILANESA	1	127,00	3,48	10,40	8,40
BIFE À CAVALO	1	285,00	23,70	0,00	21,10
GELATINA CEREJA EM	1	369,00	48,50	42,50	0,60
QUIABO C/ CASCA	1	32,00	1,39	4,99	1,35
ARROZ COM COUVE	1	102,00	2,55	17,90	2,76
Total do Dia		1821,00	178,58	133,24	66,34

Fonte: Autoria própria (2025)

Tabela 16 – Experimento 1 (NSGA-II): Quarta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
SUFLÊ FRANGO	1	162,00	15,40	7,66	7,77
ESCAROLA REFOGADA	1	33,00	1,92	3,90	1,55
AÇAFRÃO PISTILO IN	1	352,00	11,40	65,40	5,85
PURÊ INHAME	1	121,00	2,26	18,00	4,74
SOPA CARNE	1	364,00	11,80	64,00	7,40
MACARRÃO TRIGO	1	159,00	3,45	25,50	4,96
REPOLHO BRANCO COZIDO	1	57,00	2,33	6,53	2,61
PANQUECA C/ RECHEIO	1	243,00	17,10	16,60	12,10
BANANA OURO IN	1	116,00	1,35	28,80	0,10
CARNE COELHO COZIDA	1	169,00	29,30	0,00	5,70
Total do Dia		1776,00	96,31	236,39	52,78

Fonte: Autoria própria (2025)

Tabela 17 – Experimento 1 (NSGA-II): Quinta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CALDO CARNE TABLETE	1	242,00	8,11	17,90	15,50
PEIXE ÁGUA SALGADA	1	230,00	20,80	2,37	15,30
LASANHA PRONTA INDUSTRIALIZADA	1	99,00	6,81	13,50	2,23
FERMENTO BIOLÓGICO LEVEDURA	1	104,00	17,00	7,70	1,52
CARNE PORCO LOMBO	1	198,00	29,50	3,26	7,41
TAPIOCA C/ QUEIJO	1	298,00	7,38	51,50	6,90
IOGURTE NATURAL DESNATADO	1	55,00	4,24	8,30	0,52
BISCOITO DOCE MAISENA	1	437,00	8,07	75,20	12,00
SOPA MILHO FUBÁ	1	59,00	2,06	10,90	1,16
MOSTARDA COZIDA DRENADA	1	48,00	2,17	4,53	2,91
Total do Dia		1770,00	106,14	195,16	65,45

Fonte: Autoria própria (2025)

Tabela 18 – Experimento 1 (NSGA-II): Sexta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CANELONE C/ CARNE	1	170,00	14,80	11,50	7,43
QUEIJO RICOTA	1	139,00	12,60	3,79	8,11
MISSOSHIRO MISSÔ CALDO	1	32,00	2,40	2,90	1,27
MACARRÃO TRIGO	1	137,00	13,00	13,80	3,46
CAMAFEU LEITE CON- DENSADO	1	375,00	5,33	60,30	12,70
PICLES PEPINO AZEDO	1	10,00	0,33	2,26	0,20
MELADO CANA	1	306,00	0,00	76,60	0,00
PEIXE ÁGUA SALGADA	1	114,00	16,00	0,03	5,48
SOPA PEITO	1	293,00	83,10	69,00	6,63
ARROZ COM JAMBU	1	125,00	2,56	24,00	2,45
Total do Dia		1701,00	150,12	264,18	47,73

Fonte: Autoria própria (2025)

Analisando os dados do experimento 1 para o método **NSGA-II**, é possível perceber que não houve violação das restrições calóricas conforme o proposto, porém a recomendação proteica nem sempre foi priorizada.

5.1.2 Experimento 2

Para este experimento, foi gerado um paciente masculino com câncer de próstata e nível de atividade física considerado sedentário, conforme a Tabela 19.

Tabela 19 – Paciente 2

Atributo	Valor
Nome	Pedro Henrique Cirino
Data de Nascimento	1976-02-16
Data do Diagnóstico	2023-06-17
Peso na Data do Diagnóstico (kg)	88.270000
Peso há 3 meses (kg)	84.450000
Peso há 1 mês (kg)	80.790000
Peso Atual (kg)	77.300000
Altura (m)	1.720000
Sexo	M
Atividade Física	Sedentario
Patologias Atuais	Câncer de Próstata
Medicamentos em Uso	Bicalutamida, Leuprorelina, Enzalutamida, Docetaxel
Fitoterapicos	Espinheira-santa (Maytenus officinalis Mabb.)
Cirurgias	Cirurgia Diagnóstica (Biópsia)
Fase do Tratamento Oncológico	Recuperação
Tabagismo	Sim
Etilismo	Não
Chimarrao	Não
Consistência Alimentar aceita	5
Taxa de Metabolismo Basal	1932.44 Kcals/dia
Média de calorias por refeição	386.49 Kcals/refeição
Alimentos Preferidos	PINHA, IN NATURA, ANNONA SQUAMOSA L.,
Alimentos Indigestos	CHOCOLATE, AO LEITE, COM CASTANHA DO BRA- SIL,
Alergias	AMENDOIM
Intolerâncias	FRUTAS CÍTRICAS
Suplementos Alimentares	óleo de colza

Fonte: Autoria própria (2025)

5.1.2.1 Resultados do Método TOPSIS

As recomendações de alimentos a serem adicionados na dieta para 5 dias da semana para o Paciente 2 são exibidas nas Tabelas 20 à 24, que representam as dietas geradas através do método TOPSIS.

Tabela 20 – Experimento 2 (TOPSIS): Segunda-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CEREAL	1	335,00	13,10	74,20	4,90
SALADA DE FRUTAS	1	28,00	0,59	8,82	0,20
COENTRO	1	294,00	20,90	48,00	10,40
OMELETE VEGANO	2	310,00	15,22	58,40	5,10
FRUTA PÃO	1	64,00	1,08	17,20	0,19
MISSÔSHIRU	1	287,00	26,40	21,40	10,70
ERVILHA	1	89,00	7,45	17,20	0,58
HAMBÚRGUER DE GRÃO DE BICO	2	308,00	14,36	48,00	9,32
VAGEM MANTEIGA	1	20,00	1,35	4,43	0,14
Total do Dia		1735,00	100,45	297,65	41,53

Fonte: Autoria própria (2025)

Tabela 21 – Experimento 2 (TOPSIS): Terça-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
QUIBE VEGETARIANO COM TOMATE E PIMENTÃO	3	372,00	40,80	54,30	1,74
PASTA DE FEIJÃO VERMELHO	3	345,00	25,26	61,20	4,77
SANDUÍCHE	2	268,00	11,74	52,60	2,72
FEIJÃO CARIOCA	4	368,00	20,60	71,20	6,28
PEIXE	2	300,00	32,40	3,92	17,32
LEITE	1	37,00	3,12	5,14	0,40
Total do Dia		1690,00	133,92	248,36	33,23

Fonte: Autoria própria (2025)

Tabela 22 – Experimento 2 (TOPSIS): Quarta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
COBERTURA DE CHOCOLATE	1	348,00	5,65	64,70	9,42
FEIJOADA VEGETARIANA	5	250,00	12,40	48,25	5,90
SALADA	1	40,00	2,84	4,97	1,89
ALMEIRÃO	1	86,00	1,68	6,15	7,20
HAMBÚRGUER	2	362,00	21,80	20,80	22,00
MOLHO	5	355,00	25,20	73,00	0,70
PIRÃO DE LEITE	1	122,00	2,58	14,20	6,21
OVOS BENEDICT	1	227,00	13,40	13,20	13,70
Total do Dia		1790,00	85,55	245,27	67,02

Fonte: Autoria própria (2025)

Tabela 23 – Experimento 2 (TOPSIS): Quinta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
ALGA	1	336,00	6,21	80,90	0,30
SUSHI CALIFORNIA	2	280,00	15,14	47,60	5,54
JARDINEIRA DE CARNE DE SOJA	1	97,00	10,10	13,00	1,18
CREAM CHEESE	1	195,00	8,50	4,37	16,00
COCO	1	177,00	1,01	2,19	18,40
SUSHI	2	270,00	16,10	44,00	5,42
PRATO DE COMIDA BRASILEIRO REGIÃO SUDESTE	1	96,00	5,70	14,20	2,66
ESPETO DE QUEIJO COALHO	1	311,00	21,40	3,35	23,50
Total do Dia		1762,00	84,16	209,61	73,00

Fonte: Autoria própria (2025)

Tabela 24 – Experimento 2 (TOPSIS): Sexta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
BANANA	1	241,00	2,85	29,80	12,70
LASANHA	3	297,00	23,10	15,72	18,00
LEGUMES	1	46,00	3,11	9,33	0,28
SALADA DE LEGUMES	1	29,00	2,00	4,56	0,31
PUDIM DE LEITE	1	201,00	5,69	33,00	5,12
PRATO DE COMIDA BRASILEIRO REGIÃO NORDESTE	3	354,00	17,88	57,00	8,34
PUDIM DE PÃO	1	207,00	5,02	37,80	4,01
Total do Dia		1375,00	59,65	187,21	48,76

Fonte: Autoria própria (2025)

Analisando os dados do experimento 2 para o método **TOPSIS**, é possível perceber que não houve violação das restrições calóricas conforme o proposto, a quantidade de proteínas sempre esteve superior a lipídios.

5.1.2.2 Resultados do Método NSGA-II

As recomendações de produtos a serem adicionados na dieta para 5 dias da semana para o Paciente 2 são exibidas nas Tabelas 25 à 29, que representam as dietas geradas através do método **NSGA-II**.

Tabela 25 – Experimento 2 (NSGA-II): Segunda-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CARNE BOVINA PATINHO	1	165,00	27,90	0,75	5,61
BOLINROSA LATA MOÇA	1	323,00	7,30	54,80	8,30
PORCO ORELHA COZIDO	1	161,00	15,90	0,20	10,80
MACARRÃO TRIGO	1	140,00	3,98	24,70	2,89
BIFE À PARMEGIANA	1	341,00	17,20	10,00	20,30
PEIXE ÁGUA DOCE	1	143,00	18,40	3,29	6,26
TORRADA TRIGO TRADICIONAL	1	337,00	9,93	50,00	11,00
SALADA AGRIÃO	1	46,00	2,48	3,51	2,85
SOPA FEIJÃO PRETO	1	59,00	2,67	11,40	1,13
CREME CHOCOLATE DANETE	1	156,00	5,20	23,10	4,70
Total do Dia		1871,00	110,96	181,75	73,84

Fonte: Autoria própria (2025)

Tabela 26 – Experimento 2 (NSGA-II): Terça-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
LEITE VACA CONDENSADO	1	319,00	7,67	57,00	6,74
MACARRÃO TRIGO	1	137,00	13,00	13,80	3,46
CARNE BOI PATINHO	1	265,00	33,00	0,00	14,70
PURÊ CENOURA	1	56,00	0,77	4,25	4,39
PEIXE ÁGUA SALGADA	1	114,00	16,00	0,03	5,48
SANDUÍCHE PÃO FORMA	1	183,00	13,70	16,30	7,40
PÃO DE QUEIJO	1	421,00	3,65	70,00	14,00
ARROZ SELVAGEM COZIDO	1	101,00	3,99	21,30	0,34
SALADA FOLHAS E	1	174,00	2,14	9,96	14,50
SOPA DE ENTULHO	1	40,00	1,95	7,14	0,90
Total do Dia		1810,00	95,87	199,78	71,91

Fonte: Autoria própria (2025)

Tabela 27 – Experimento 2 (NSGA-II): Quarta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
BOLO TRIGO E	1	403,00	6,83	56,10	17,00
IOGURTE FRUTAS DIET	1	107,00	4,86	18,60	1,41
SANDUÍCHE HAMBÚR- GUER BOVINO	1	216,00	10,80	23,40	9,16
ARROZ COM FRANGO	1	139,00	7,20	19,60	3,84
ESTROGONOFE DE CARNE	1	169,00	15,00	2,98	10,80
ALMÔNDEGA DE SOJA	1	189,00	22,80	25,00	0,77
CARNE BOI FILÉ	1	207,00	27,30	3,32	9,40
SOJA GRÃO ORGÂNICA	1	94,00	7,89	7,72	4,19
CANELONE C/ PEITO	1	144,00	16,90	11,50	3,60
OMELETE C/ OVO	1	215,00	13,40	2,19	17,00
Total do Dia		1883,00	132,98	170,41	77,17

Fonte: Autoria própria (2025)

Tabela 28 – Experimento 2 (NSGA-II): Quinta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CARNE BOI CONTRA- FILÉ	1	187,00	35,90	0,82	4,49
BOLO COCO MISTURA	1	369,00	6,40	84,60	0,90
OVO CODORNA INTEIRO	1	157,00	13,10	1,16	11,10
OSSOBUCO CHAMBARI COZIDO	1	193,00	26,50	2,88	8,42
SALADA ALFACE LISA	1	13,00	1,69	2,43	0,12
FIAMBRE FRANGO CO- ZIDO	1	120,00	22,70	0,00	3,30
SANDUÍCHE HAMBÚR- GUER BOVINO	1	216,00	10,80	23,40	9,16
BIFE À PARMEGIANA	1	341,00	17,20	10,00	20,30
PIMENTÃO AMARELO COZIDO	1	30,00	1,39	6,47	0,35
PÃO ITALIANO	1	261,00	8,80	50,10	3,50
Total do Dia		1887,00	144,48	181,86	61,64

Fonte: Autoria própria (2025)

Tabela 29 – Experimento 2 (NSGA-II): Sexta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CEBOLA BRANCA REFOGADA	1	254,00	2,01	10,50	23,10
PAVÊ MORANGO BISCOITO	1	231,00	4,89	31,70	9,51
MACARRÃO TRIGO SECO	1	126,00	3,56	27,00	0,57
CARNE BOI CHARQUE	1	254,00	34,70	0,75	12,50
PUDIM DE PÃO	1	207,00	5,02	37,80	4,01
SALADA ALFACE CRESPA	1	41,00	1,34	2,00	3,51
SEQUILHO AMIDO	1	465,00	1,29	62,90	23,20
CHUCHU S/ CASCA	1	37,00	1,26	5,94	1,27
FAROFA COUVE	1	259,00	1,77	50,20	6,78
GELATINA LIMÃO EM	1	12,00	1,58	1,10	0,10
Total do Dia		1886,00	57,42	229,89	84,55

Fonte: Autoria própria (2025)

Analisando os dados do experimento 2 para o método [NSGA-II](#), é possível perceber que não houve violação das restrições calóricas conforme o proposto, porém a recomendação proteica nem sempre foi priorizada.

5.1.3 Experimento 3

Para o Experimento 3, foi gerado um paciente masculino, com câncer de pulmão e nível de atividade física considerado sedentário, conforme a Tabela [30](#).

Tabela 30 – Paciente 3

Atributo	Valor
Nome	Sr. Asafe Siqueira
Data de Nascimento	1937-06-22
Data do Diagnóstico	2023-06-18
Peso na Data do Diagnóstico (kg)	81.510000
Peso há 3 meses (kg)	73.930000
Peso há 1 mês (kg)	67.050000
Peso Atual (kg)	60.820000
Altura (m)	1.710000
Sexo	M
Atividade Física	Sedentario
Patologias Atuais	Câncer de Pulmão
Medicamentos em Uso	Cisplatina, Carboplatina, Paclitaxel, Vinorelbina, Pembrolizumabe
Fitoterapicos	Alcachofra (<i>Cynara scolymus</i> L.)
Cirurgias	Cirurgia Diagnóstica (Biópsia)
Fase do Tratamento Oncológico	Manutenção da Saúde
Tabagismo	Sim
Etilismo	Não
Chimarrao	Sim
Consistência Alimentar aceita	3
Taxa de Metabolismo Basal	1338.0 Kcals/dia
Média de calorias por refeição	446.0 Kcals/refeição
Alimentos Preferidos	SALADA DE LEGUMES, COZIDOS NO VAPOR, S/ SAL, (COUVE-FLOR, CENOURA, BRÓCOLIS, BATATA, VAGEM, S/ SAL),
Alimentos Indigestos	PAPA DE CARNE BOVINA MOÍDA (ACÉM), CENOURA E BATATA BAROA (MANDIOQUINHA, BATATA SALSA), C/ CALDO DE CARNE, C/ CEBOLA, S/ ÓLEO, S/ SAL,
Alergias	SOJA
Intolerâncias	CAFÉ
Suplementos Alimentares	óleo de palma

Fonte: Autoria própria (2025)

5.1.3.1 Resultados do Método TOPSIS

As recomendações de alimentos a serem adicionados na dieta para 5 dias da semana para o Paciente 3 são exibidas nas Tabelas 31 à 35, que representam as dietas geradas através do método TOPSIS.

Tabela 31 – Experimento 3 (TOPSIS): Segunda-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CEREAL	1	335,00	13,10	74,20	4,90
FRAMBOESA	1	45,00	1,20	11,90	0,65
COENTRO	1	294,00	20,90	48,00	10,40
TOMILHO	1	107,00	5,56	24,50	1,68
SALADA DE FRUTAS	5	140,00	2,95	44,10	1,00
OMELETE VEGANO	1	155,00	7,61	29,20	2,55
GOIABA	3	135,00	2,37	36,90	1,53
Total do Dia		1211,00	53,69	268,80	22,71

Fonte: Autoria própria (2025)

Tabela 32 – Experimento 3 (TOPSIS): Terça-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
AÇAI	5	340,00	4,50	38,30	25,05
FRUTA PÃO	1	64,00	1,08	17,20	0,19
MISSÔSHIRU	1	287,00	26,40	21,40	10,70
ERVILHA	1	89,00	7,45	17,20	0,58
DOCE DE LEITE	2	394,00	41,80	54,60	2,74
MEXERICA	1	36,00	0,65	9,34	0,13
Total do Dia		1210,00	81,88	158,04	39,39

Fonte: Autoria própria (2025)

Tabela 33 – Experimento 3 (TOPSIS): Quarta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
VAGEM MANTEIGA	5	100,00	6,75	22,15	0,70
PERA	5	265,00	2,85	70,00	0,55
LARANJA	1	52,00	0,83	12,80	0,36
FEIJÃO PRETO	5	315,00	17,90	60,50	7,50
LENTILHA	1	99,00	7,30	19,60	0,46
QUEIJO	5	405,00	84,50	16,00	0,50
Total do Dia		1236,00	120,13	201,05	10,07

Fonte: Autoria própria (2025)

Tabela 34 – Experimento 3 (TOPSIS): Quinta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CAJU	5	215,00	3,85	50,50	2,45
ACEROLA	1	30,00	0,71	6,89	0,38
MAÇÃ	1	48,00	0,30	13,00	0,00
CALDO DE FEIJÃO	5	230,00	13,90	44,20	5,25
FEIJOADA VEGETARIANA	4	200,00	9,92	38,60	4,72
MORANGO	5	150,00	4,10	32,70	2,00
SANDUÍCHE	2	268,00	11,74	52,60	2,72
Total do Dia		1141,00	44,52	238,49	17,52

Fonte: Aatoria própria (2025)

Tabela 35 – Experimento 3 (TOPSIS): Sexta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CREME DE FRUTAS VERMELHAS	5	240,00	11,15	39,30	6,25
CAJÁ	5	135,00	2,95	31,85	0,85
MANGA	1	52,00	0,86	12,80	0,22
PEIXE	5	440,00	154,00	0,20	11,45
CREME DE KIWI	5	245,00	11,15	38,40	6,95
PERU	1	186,00	24,90	0,54	9,31
Total do Dia		1298,00	205,01	123,09	35,03

Fonte: Aatoria própria (2025)

Analisando os dados do Experimento 3 para o método **TOPSIS**, é possível perceber que não houve violação das restrições calóricas conforme o proposto, a quantidade de proteínas sempre esteve superior a lipídios.

5.1.3.2 Resultados do Método NSGA-II

As recomendações de produtos a serem adicionados na dieta para 5 dias da semana para o Paciente 3 são exibidas nas Tabelas 36 à 40, que representam as dietas geradas por meio do método **NSGA-II**.

Tabela 36 – Experimento 3 (NSGA-II): Segunda-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
MASSA PIZZA GRÃO	1	234,00	8,80	31,40	9,51
SUCO NATURAL ABA-CAXI	1	64,00	0,56	15,70	0,14
MANJERICÃO IN NATURA	1	19,00	1,99	3,64	0,39
CREME ABÓBORA CABOTIAN	1	86,00	6,41	6,50	4,05
RONDELE RICOTA E QUEIJO REQUEIJÃO MÉDIA	1	102,00	5,15	13,20	3,58
CHUCHU S/ CASCA	1	24,00	0,78	5,84	0,27
PEIXE ÁGUA DOCE	1	104,00	22,40	0,00	1,58
Total do Dia		914,00	56,00	79,31	45,02

Fonte: Autoria própria (2025)

Tabela 37 – Experimento 3 (NSGA-II): Terça-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CEBOLA BRANCA COZIDA	1	40,00	1,79	9,16	0,26
CARNE BOI PALETA	1	149,00	19,50	4,79	5,90
GELATINA LIMÃO EM ESPETO DE QUEIJO	1	12,00	1,58	1,10	0,10
VAGEM MACARRÃO COZIDA	1	311,00	21,40	3,35	23,50
MACARRÃO C/ MOLHO	1	30,00	1,49	6,82	0,09
BOLO DE MANDIOCA	1	115,00	4,93	21,70	0,89
BERINJELA RECHEADADA	1	166,00	10,00	16,30	6,97
	1	86,00	4,21	7,14	5,11
Total do Dia		909,00	64,90	70,36	42,82

Fonte: Autoria própria (2025)

Tabela 38 – Experimento 3 (NSGA-II): Quarta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
TOMATE MADURO COZIDO	1	19,00	0,95	4,00	0,11
OVO GALINHA INTEIRO	1	125,00	10,30	1,38	8,66
SOPA CANJA	1	70,00	7,48	6,16	1,86
MOLHO PARA CARNE	1	171,00	1,56	8,78	12,70
PEIXE ÁGUA SALGADA	1	82,00	16,70	1,31	1,23
ARROZ COM ESPINAFRE	1	103,00	2,26	18,50	2,71
PURÊ BATATA BAROA	1	107,00	1,04	16,70	4,36
CARNE BOI FILÉ	1	266,00	30,20	0,00	16,10
Total do Dia		943,00	70,49	56,83	47,73

Fonte: Autoria própria (2025)

Tabela 39 – Experimento 3 (NSGA-II): Quinta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
BATATA BAROA MANDI-OQUINHA	1	111,00	0,82	17,80	4,46
CREME ABÓBORA CABOTIAN	1	79,00	2,49	8,77	4,01
PERA C/ CASCA	1	54,00	0,40	14,00	0,23
PEIXE ÁGUA DOCE	1	177,00	18,90	0,00	11,30
PIMENTÃO VERMELHO ASSADO	1	25,00	1,08	5,69	0,15
CHARUTO DE REPOLHO	1	86,00	8,75	9,52	1,66
CARNE BOI MAMINHA	1	233,00	29,30	0,64	12,30
SAGU MORANGO MISTURA	1	122,00	0,00	30,40	0,00
Total do Dia		887,00	61,74	86,82	34,11

Fonte: Autoria própria (2025)

Tabela 40 – Experimento 3 (NSGA-II): Sexta-feira

Alimento	Quantidade	Calorias (kcal)	Proteína (g)	Carboidrato (g)	Lipídios (g)
CARNE BOI MAMINHA	1	233,00	30,70	0,17	11,90
ACELGA COZIDA DRENADA	1	22,00	1,47	4,39	0,11
PIMENTÃO VERMELHO ASSADO	1	25,00	1,08	5,67	0,15
SUCO NATURAL JABUTICABA	1	21,00	0,12	5,04	0,15
IOGURTE FRUTAS DIET	1	107,00	4,86	18,60	1,41
PEIXE ÁGUA DOCE	1	88,00	30,80	0,04	2,29
SOPA PEITO	1	65,00	7,53	5,59	1,58
MOLHO PARA SALADA	1	313,00	1,26	4,57	32,40
Total do Dia		874,00	77,82	44,07	49,99

Fonte: Autoria própria (2025)

Analisando os dados do Experimento 3 para o método **NSGA-II**, é possível perceber que não houve violação das restrições calóricas conforme o proposto, a quantidade de proteínas sempre esteve superior a lipídios.

5.2 Avaliação

Para uma análise mais aprofundada, foram geradas 100 amostras contendo informações detalhadas sobre pacientes e suas respectivas dietas, que serviram de base para a aplicação dos métodos **TOPSIS** e **NSGA-II**. Gráficos estatísticos — incluindo diagramas de dispersão, boxplots e gráficos de barras — foram elaborados para comparar os resultados obtidos e destacar padrões e tendências nos dados. Durante a validação, um nutricionista oncológico colaborou ativamente,

refinando os parâmetros e ajustando as recomendações para assegurar que o planejamento nutricional estivesse adequado às necessidades específicas de cada paciente.

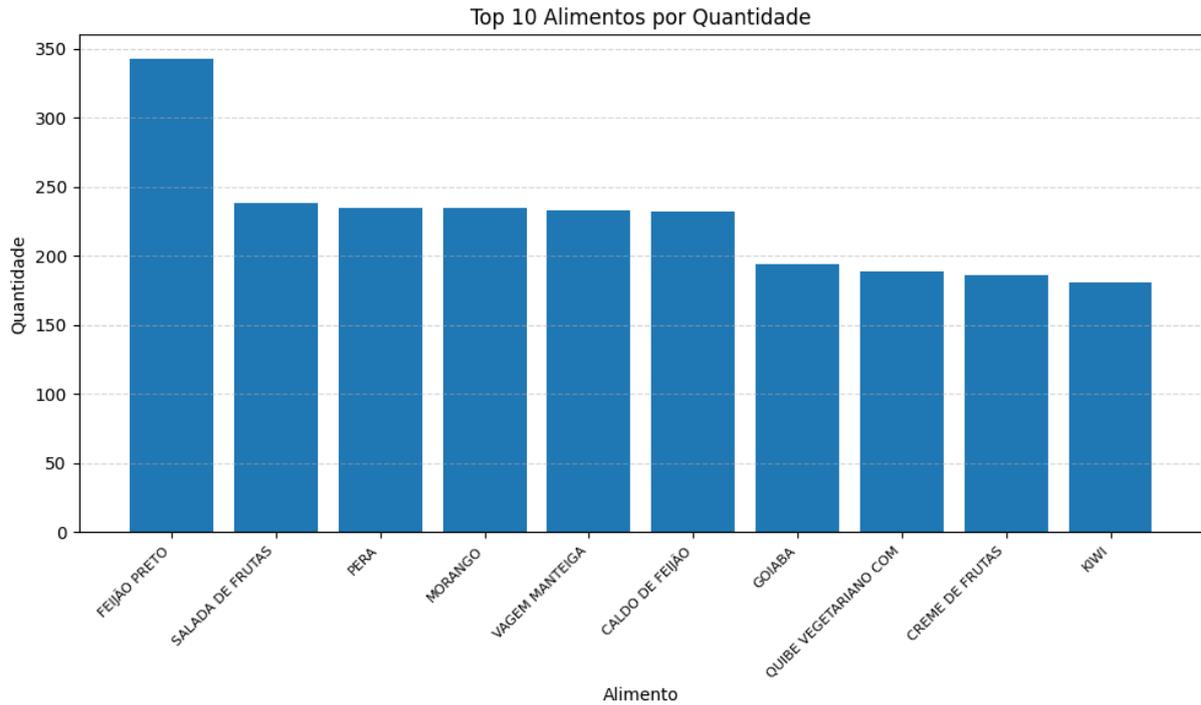
A partir das visualizações, observou-se que o **NSGA-II** produz dietas cujos macronutrientes se concentram em torno de valores médios predefinidos (em média, 175–180g/dia de carboidratos, 70g/dia de proteínas e 50g/dia de lipídios), apresentando baixa variabilidade entre pacientes. Em contraste, o **TOPSIS** resultou em uma distribuição mais ampla: alguns pacientes alcançaram de 300 a 400g/dia de carboidratos ou 120 a 140g/dia de proteínas, enquanto outros permaneceram abaixo de 120g/dia de carboidratos ou 40g/dia de proteínas; a ingestão de lipídios também oscilou de aproximadamente 20 a 80g/dia. Esses achados indicam que, quando o objetivo é manter a ingestão nutricional dentro de um intervalo restrito e homogêneo, o **NSGA-II** apresenta melhor desempenho; por outro lado, se há necessidade de acomodar preferências ou restrições individuais com amplitudes extremas, o **TOPSIS** demonstra maior flexibilidade na definição das quantidades de macronutrientes.

5.2.1 Informações geradas a partir do método TOPSIS

A Figura 10 apresenta os 10 alimentos mais frequentemente recomendados nas dietas geradas pelo método **TOPSIS**. Esses alimentos foram selecionados por atenderem de forma mais adequada às restrições nutricionais dos pacientes, minimizando violações e garantindo um equilíbrio nutricional alinhado aos objetivos da dieta. A alta frequência desses itens nas soluções geradas pelo **TOPSIS** indica que eles possuem uma composição nutricional favorável dentro dos critérios estabelecidos, contribuindo para a adequação das dietas propostas.

Entre os itens destacados, observa-se uma forte ênfase em fontes proteicas (como *Carne* e *Peixe*) e preparações de baixo teor calórico (como *Salada*, *Sopa* e *Suco Natural*), o que favorece o aporte de aminoácidos essenciais, vitaminas e fibras para manutenção da saciedade e controle glicêmico. No entanto, a presença recorrente de alimentos mais processados e ricos em carboidratos simples (como *Sanduíche*, *Biscoito* e *Pão*) sugere que, apesar de satisfatórios para atender às metas energéticas, esses itens podem elevar rapidamente a carga glicêmica se não forem moderados. Por fim, a ocorrência moderada de *Feijão* e *Macarrão* evidencia que legumes e carboidratos complexos estão presentes, mas em menor proporção.

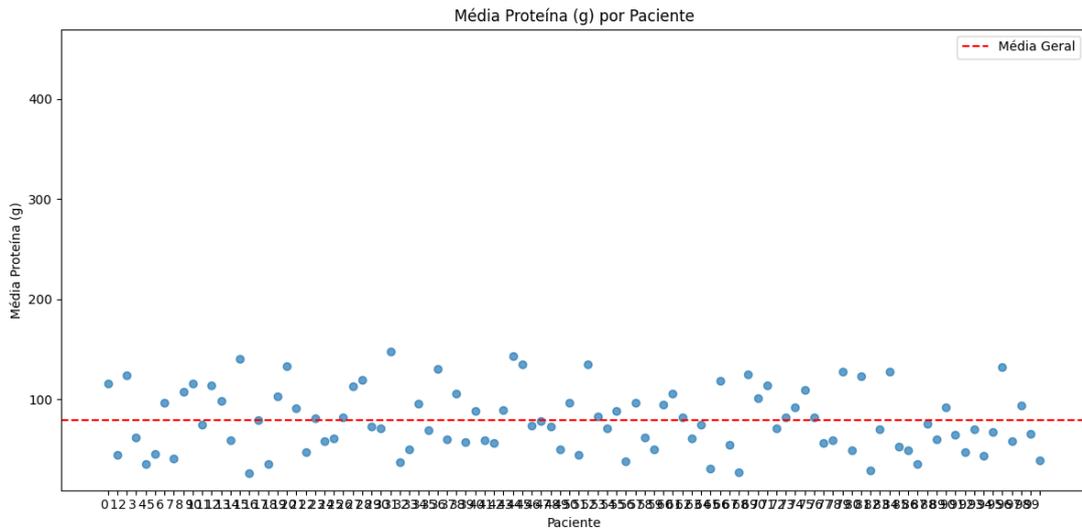
Figura 10 – As 10 maiores ocorrências de alimentos no método TOPSIS



Fonte: Autoria própria (2025)

A Figura 11 apresenta a média de proteína dos pacientes das 100 amostras geradas pelo método TOPSIS.

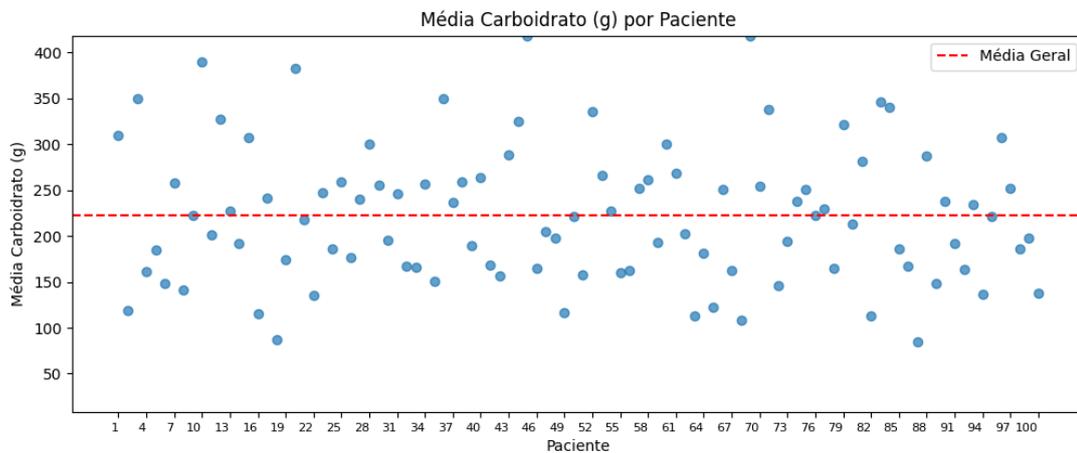
Figura 11 – Média de proteínas por paciente



Fonte: Autoria própria (2025)

A Figura 12 apresenta a média de carboidratos dos pacientes das 100 amostras geradas pelo método TOPSIS.

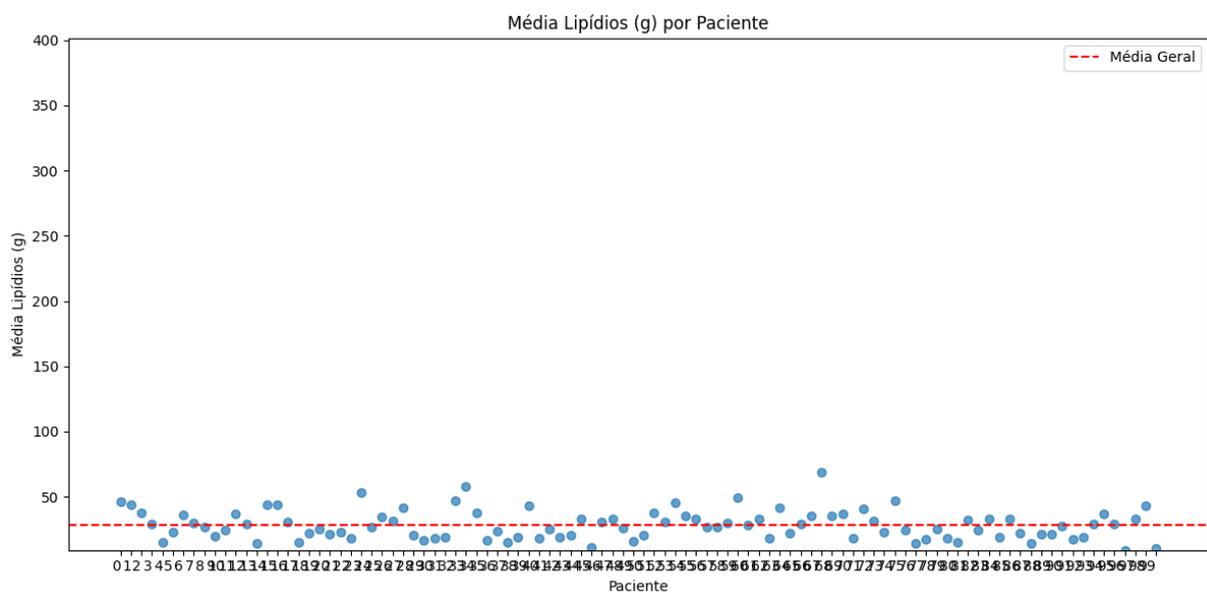
Figura 12 – Média de carboidratos por paciente



Fonte: Autoria própria (2025)

A Figura 13 apresenta a média de lipídios dos pacientes das 100 amostras geradas pelo método TOPSIS. Nota-se que a escala do gráfico de lipídios é menor em relação aos dados de proteínas e carboidratos, o que demonstra que as dietas geradas apresentam quantidades menores desse macronutriente.

Figura 13 – Média de lipídios por paciente



Fonte: Autoria própria (2025)

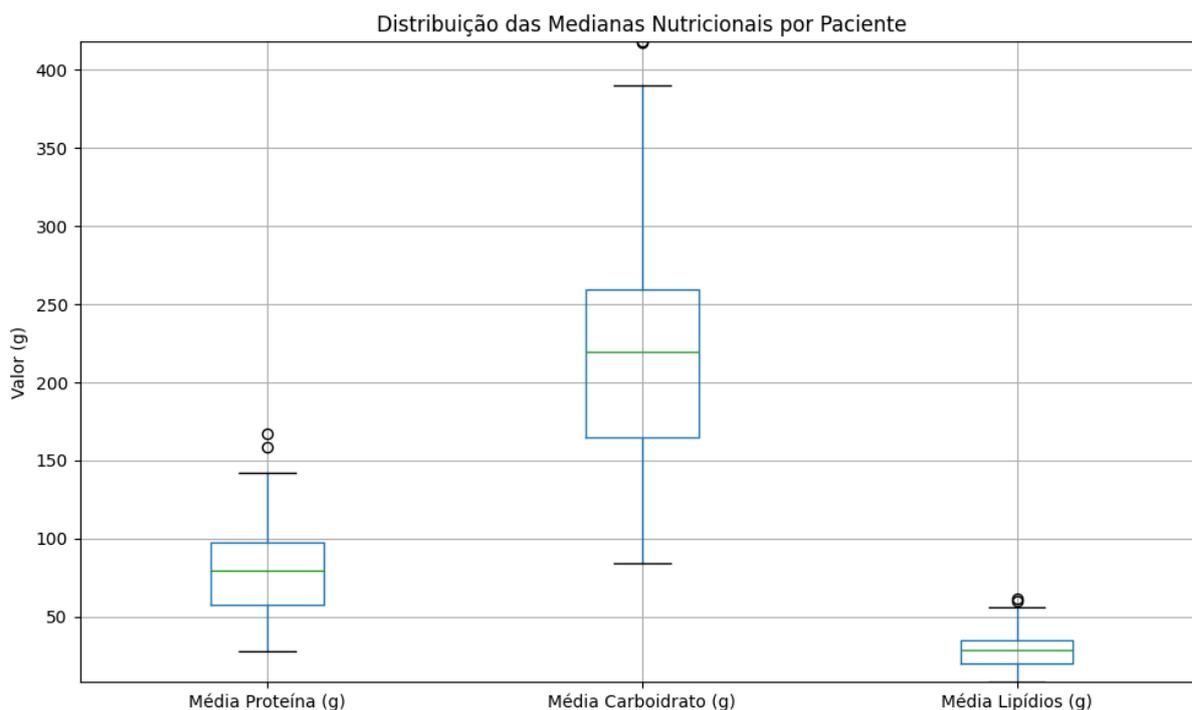
A Figura 14 ilustra a distribuição das medianas diárias de proteína, carboidrato e lipídio nos planos alimentares gerados para cada paciente a partir de 100 amostras avaliadas pelo método TOPSIS. Verifica-se que a mediana do aporte proteico situa-se em aproximadamente 70g, com

o primeiro quartil (Q_1) em torno de 55g e o terceiro quartil (Q_3) próximo de 95g, resultando em um **Intervalo Interquartil (IRQ)** de aproximadamente 40g. Essa dispersão relativamente estreita indica que o algoritmo produz soluções consistentes quanto à distribuição proteica para diferentes perfis de pacientes. No caso dos carboidratos, a mediana das medianas está em cerca de 220g, sendo Q_1 em torno de 165g e Q_3 em torno de 270g, originando um **IRQ** de aproximadamente 105g. A amplitude desse **IRQ** evidencia a capacidade do método **TOPSIS** de adaptar o aporte energético às necessidades individuais, de modo que algumas dietas alcançam valores próximos de 400g, enquanto outras permanecem próximas a 90g. Já para os lipídios, a mediana das medianas aproxima-se de 25g, com Q_1 em torno de 20g e Q_3 por volta de 35g, resultando em um **IRQ** de 15g. Esse reduzido **IRQ** lipídico reflete a estratégia do algoritmo em atenuar a variabilidade de gordura nas dietas, atendendo às recomendações nutricionais para pacientes oncológicos, que demandam ingestão lipídica moderada.

Adicionalmente, observa-se que os “bigodes” se estendem de aproximadamente 30g até valores superiores a 145g para a proteína, indicando algumas soluções com aporte proteico excepcional, possivelmente direcionadas a pacientes com maiores necessidades anabólicas ou em fases específicas do tratamento. Para carboidratos, os limites inferior e superior variam de cerca de 90g a quase 400g, corroborando a inclusão de dietas hipercalóricas quando necessário. No que concerne aos lipídios, estão presentes *outliers* acima de 60g, sugerindo que, apesar da ênfase em contestar o consumo de gorduras, determinadas combinações podem superar esse patamar em casos específicos, possivelmente para atender a perfis que toleram maior ingestão lipídica sem comprometer o tratamento.

Em suma, a análise da Figura 14 evidencia que o método **TOPSIS**, ao ponderar critérios de otimização, é capaz de gerar planos alimentares com aporte proteico e glicídico elevado e homogêneo, ao mesmo tempo em que restringe a ingestão lipídica a faixas controladas. Tal comportamento corrobora a eficiência do algoritmo em formular dietas nutricionalmente equilibradas, alinhadas às diretrizes clínicas de pacientes oncológicos, garantindo consistência no fornecimento de macronutrientes e flexibilidade para ajustes conforme as necessidades individuais.

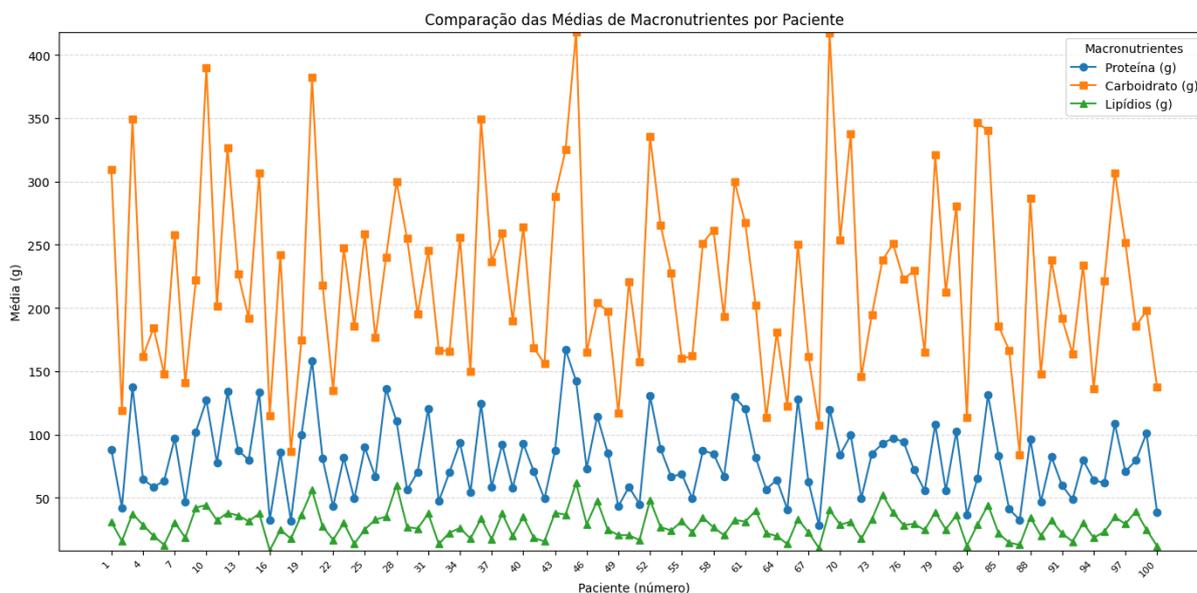
Figura 14 – Distribuição das medianas Nutricionais por paciente



Fonte: Autoria própria (2025)

A Figura 15 apresenta a comparação das médias diárias de macronutrientes (proteínas, carboidratos e lipídios) para cada um dos 100 pacientes, calculadas por meio do método TOPSIS. Observa-se que a curva de carboidratos exibe ampla variabilidade: há pacientes cujo valor médio supera 380–400g/dia, enquanto outros estão abaixo de 120g/dia, o que demonstra que o TOPSIS tende a gerar dietas com ingestões de carboidratos bastante dispersas em relação à média geral. Em contrapartida, as médias proteicas permanecem majoritariamente no intervalo de 40g a 120g/dia, apresentando oscilações menos extremas, e poucos indivíduos ultrapassam pontuais valores de cerca de 140g/dia. Já para lipídios, a distribuição é ainda mais concentrada: a grande maioria dos pacientes consome entre 15g e 50g/dia, e raramente ultrapassa 70g/dia. A linha pontilhada horizontal em cada série representa a média geral do nutriente, e fica evidente que muitos indivíduos se encontram acima ou abaixo desse ponto de referência na curva de carboidratos, ao passo que as variações nas curvas de proteínas e lipídios permanecem mais próximas da média global. Portanto, a Figura 15 evidencia que o TOPSIS produz soluções nutricionais com variação substancial em carboidratos, enquanto mantém ingestões de proteínas e lipídios relativamente mais uniformes para toda a amostra.

Figura 15 – Comparação entre macronutrientes para todos os pacientes



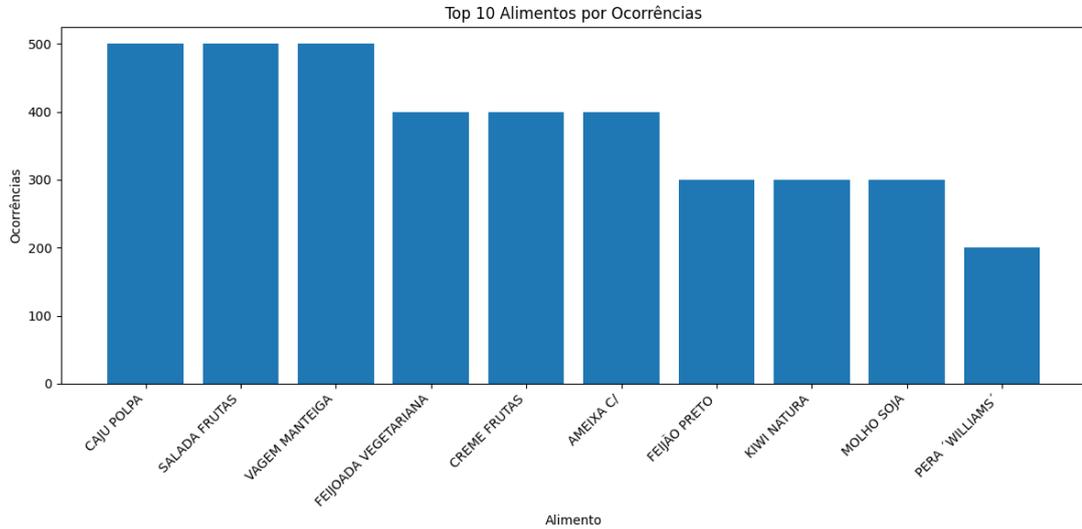
Fonte: Autoria própria (2025)

5.2.2 Informações geradas a partir do método NSGA-II

A Figura 16 exibe as 10 maiores ocorrências de alimentos selecionados pelo método NSGA-II ao longo das 100 amostras analisadas. Esses alimentos representam aqueles que menos violam as restrições nutricionais estabelecidas para os pacientes, sendo, portanto, mais frequentemente incluídos nas dietas geradas pelo algoritmo. Observa-se que “Carne” lidera a frequência (cerca de 93 ocorrências), seguida de “Salada” (cerca de 78) e “Peixe” (cerca de 55), indicando forte tendência a priorizar proteínas de alto valor biológico em combinação com preparações de baixo teor calórico. Em seguida aparecem “Sopa” (cerca de 42) e “Suco Natural” (cerca de 40), itens que fornecem hidratação e micronutrientes sem elevar excessivamente a densidade energética, favorecendo saciedade e controle glicêmico. Já “Macarrão” (cerca de 34) e “Sanduíche” (cerca de 34) refletem a necessidade de carboidratos de liberação moderada a rápida para manter níveis adequados de energia, mas, em contrapartida, podem elevar o pico glicêmico caso consumidos em excesso ou sem acompanhamento proteico. Itens como “Gelatina” (cerca de 20) e “Queijo” (cerca de 19) aparecem com menor frequência, porém cumprem papel de volumizar dietas hipocalóricas e fornecer proteína láctea, respectivamente, o que pode ser útil em fases de recuperação clínica ou para incrementar valor protéico em pequenas porções. Por fim, “Batata” (cerca de 18) demonstra a preferência por carboidrato complexo acessível e versátil, mas deve ser consumida de forma equilibrada para não superar as metas de carboidratos diárias. De maneira geral, a elevada presença de proteínas animais e preparações leves no topo das ocorrências sugere que o NSGA-II tende a formar dietas nutricionalmente densas e balanceadas em macronutrientes, embora seja recomendável atentar para a variação de fontes

vegetais (leguminosas, tubérculos integrais e hortaliças folhosas) a fim de ampliar a diversidade de fibras, micronutrientes e compostos bioativos nas dietas propostas.

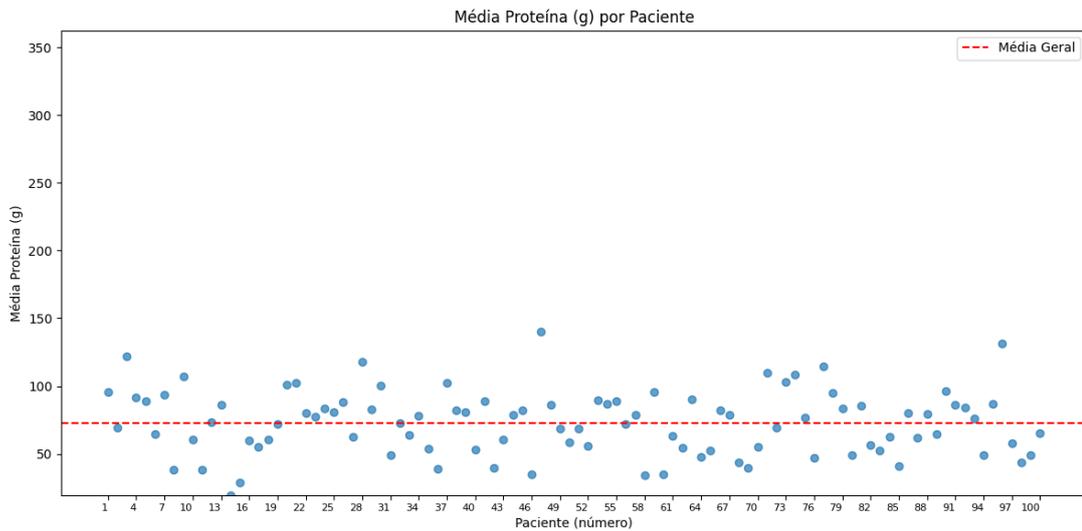
Figura 16 – As 10 maiores ocorrências de alimentos no método NSGA-II



Fonte: Autoria própria (2025)

A Figura 17 apresenta a média de proteína dos pacientes das 100 amostras geradas pelo método NSGA-II.

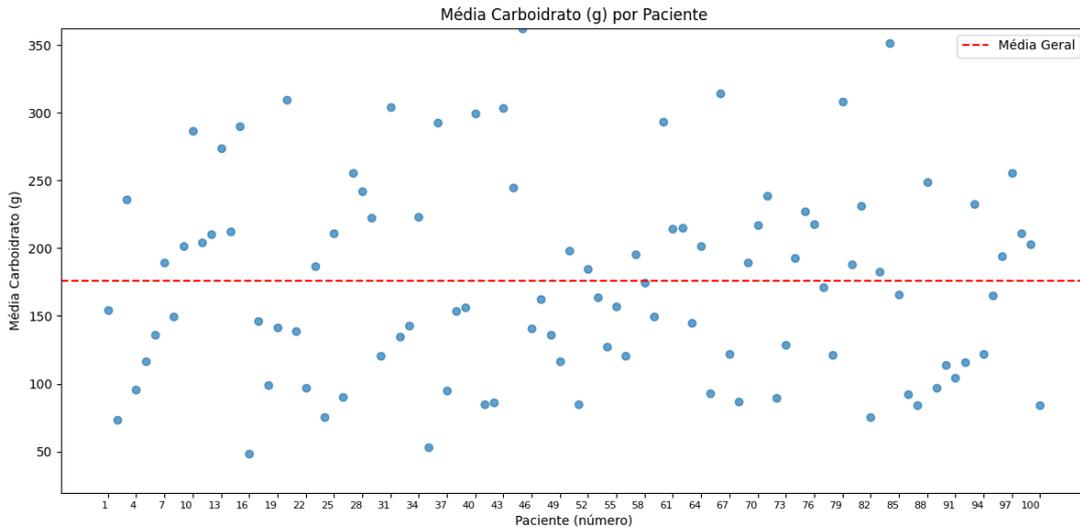
Figura 17 – Média de proteínas por paciente



Fonte: Autoria própria (2025)

A Figura 18 apresenta a média de carboidratos dos pacientes das 100 amostras geradas pelo método NSGA-II.

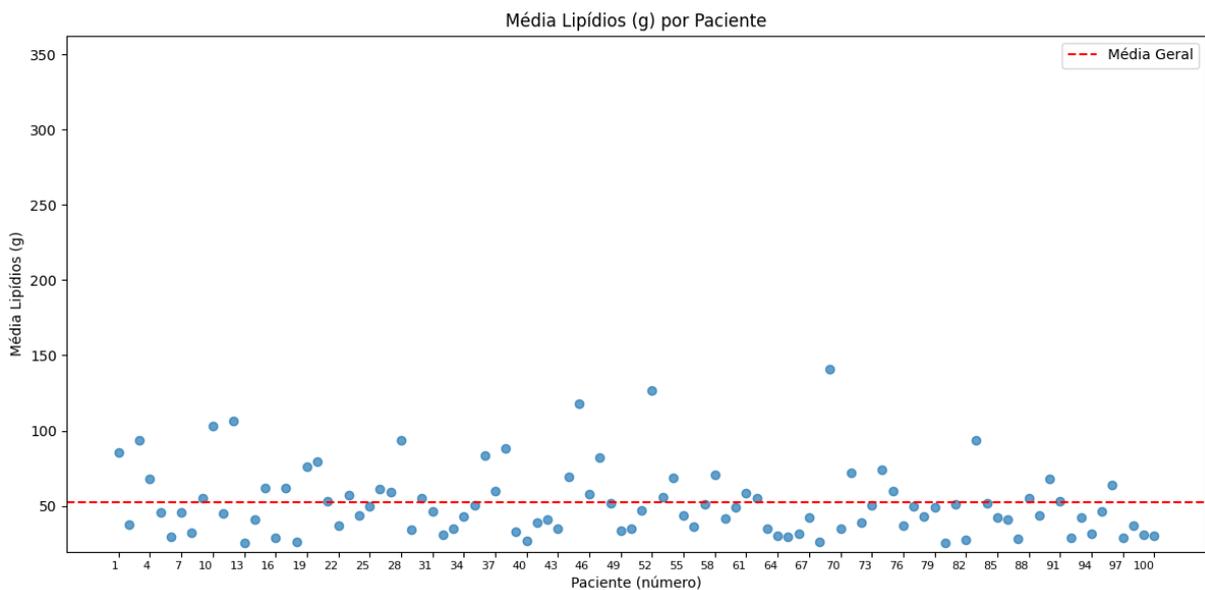
Figura 18 – Média de carboidratos por paciente



Fonte: Aatoria própria (2025)

A Figura 19 apresenta a média da ingestão de lipídios nos planos alimentares dos pacientes com base nas 100 amostras geradas pelo método **NSGA-II**. Ao analisar a distribuição dos valores, percebe-se que, embora a escala do gráfico de lipídios seja inferior à dos carboidratos, ela se mantém próxima à escala do gráfico de proteínas. Esse comportamento indica que as dietas geradas pelo **NSGA-II** não priorizaram a minimização da ingestão de lipídios, resultando em um equilíbrio entre proteínas e lipídios que pode não ser ideal para o contexto da nutrição oncológica.

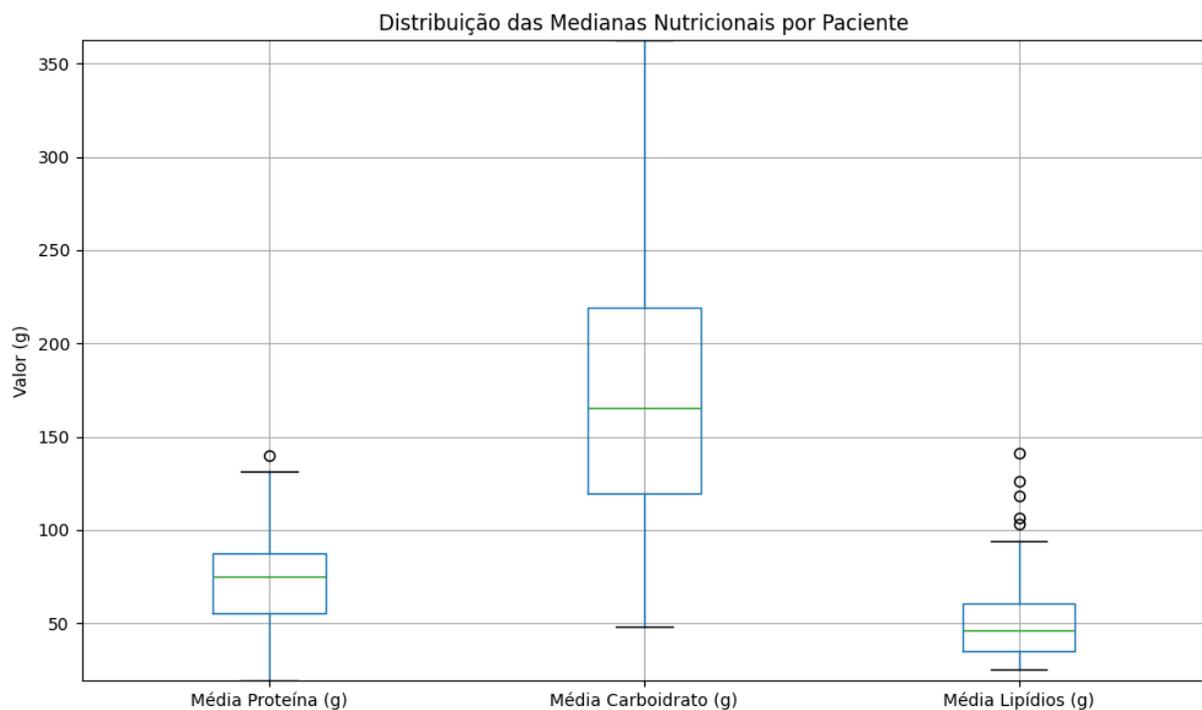
Figura 19 – Média de lipídios por paciente



Fonte: Aatoria própria (2025)

A Figura 20 apresenta a distribuição das medianas diárias de proteína, carboidrato e lipídios geradas pelo método **NSGA-II** em 100 amostras para cada paciente. Observa-se que a mediana da ingestão protéica situa-se em torno de 75g, com o primeiro quartil (Q_1) próximo a 55g e o terceiro quartil (Q_3) em torno de 90g, resultando em um **IRQ** de cerca de 35g. Esse **IQR** relativamente moderado revela consistência no aporte de proteínas entre os planos, embora existam *outliers* acima de 120g, indicando soluções com aportes excepcionais voltadas a perfis que requerem maior suporte anabólico. No caso dos carboidratos, a mediana das medianas situa-se em aproximadamente 160g, com Q_1 em torno de 115g e Q_3 em cerca de 220g, gerando um **IRQ** de aproximadamente 105g. Essa amplitude mais ampla reflete a necessidade de acomodar diferentes demandas energéticas; os bigodes estendem-se de cerca de 60g a 320g, com *outliers* acima de 330g, evidenciando dietas hipercalóricas em alguns casos. Por fim, a mediana lipídica gira em torno de 45g, com Q_1 por volta de 30g e Q_3 em torno de 60g, resultando em um **IRQ** de cerca de 30g; os valores extremos alcançam aproximadamente 130g, indicando que, embora o algoritmo tenda a moderar a ingestão de gordura, há planos específicos que contemplam teores lipídicos mais elevados. Em suma, o **NSGA-II** demonstra capacidade de produzir dietas com aporte protéico relativamente estável, variabilidade moderada em carboidratos para atender demandas energéticas distintas e controle lipídico que se estende a perfis especiais, resultando em soluções nutricionalmente ajustadas às necessidades dos pacientes.

Figura 20 – Distribuição das medianas Nutricionais por paciente

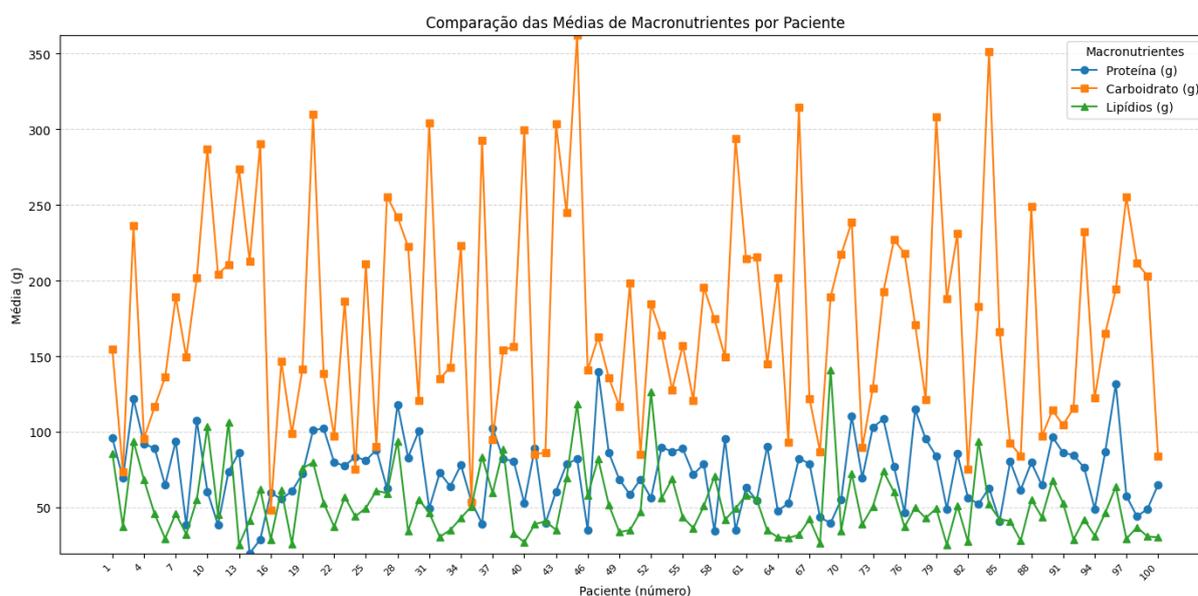


Fonte: Autoria própria (2025)

A Figura 21 apresenta a comparação das médias diárias de macronutrientes (proteínas,

carboidratos e lipídios) para cada um dos 100 pacientes, calculadas por meio do método **NSGA-II**. Observa-se que a curva de carboidratos é consideravelmente mais homogênea em torno da média geral: a maioria dos pacientes situa-se entre aproximadamente 150g e 250g/dia, e poucos valores ultrapassam 300g ou caem abaixo de 100g. Isso demonstra que o **NSGA-II** gera dietas cujas ingestões de carboidratos permanecem próximas de um intervalo restrito, com baixa dispersão em relação à linha pontilhada que indica a média global. Em relação às proteínas, a faixa também é moderada: a maior parte das médias proteicas fica entre 40g e 100g/dia, com poucos *outliers* acima de 110g/dia, configurando oscilações menos acentuadas do que as observadas pelo **TOPSIS**. Por fim, a curva de lipídios (triângulos verdes) revela distribuição ainda mais concentrada, com a praticamente totalidade dos pacientes consumindo entre 20g e 60g/dia, sem picos extremos acima de 80g. A linha pontilhada horizontal em cada série representa a média geral de cada nutriente, e fica evidente que, no **NSGA-II**, as variações de carboidratos, proteínas e lipídios ocorrem em estreita proximidade a essa média global. Dessa forma, a Figura 21 evidencia que o **NSGA-II** produz soluções nutricionais com ingestões macronutrientes muito mais uniformes e centralizadas em torno dos valores-alvo, em comparação ao **TOPSIS**.

Figura 21 – Comparação entre macronutrientes para todos os pacientes



Fonte: Autoria própria (2025)

5.3 Análise dos Resultados

Os resultados apresentam recomendações de dietas que levam em conta as restrições alimentares dos pacientes, evitando alimentos incompatíveis com a dieta oncológica e considerando a **TMB** de cada um, o que garante um planejamento nutricional adequado. Esses achados indicam que os modelos desenvolvidos têm potencial para aplicação em dietas personalizadas,

desde que ajustes e validações sejam realizados pelo profissional de nutrição oncológica em conjunto com o paciente. Contudo, devido à base de dados utilizada, o sistema pode, em alguns casos, recomendar alimentos de outras regiões, financeiramente inacessíveis ou fora de época, entre outras limitações.

5.3.1 Análise Estatística das Diferenças em Relação às Recomendações Nutricionais

Para complementar a análise, foram realizados testes estatísticos e os resultados obtidos ao comparar as médias diárias de macronutrientes geradas pelo método TOPSIS com os valores definidos para cada paciente. O objetivo é avaliar se as dietas calculadas se alinham, em média, às recomendações individuais de proteínas, carboidratos e lipídios. Para tanto, adotou-se o seguinte protocolo:

1. Para cada paciente e cada nutriente, calculou-se a diferença $\Delta_i = (\text{real obtido})_i - (\text{target})_i$.
2. Aplicou-se o teste de Shapiro–Wilk ao vetor de diferenças $\{\Delta_i\}$ para verificar o pressuposto de normalidade.
 - **Shapiro–Wilk:** teste de normalidade que avalia se um conjunto de dados provém de uma distribuição normal. A estatística W aproxima-se de 1 quando há normalidade, e um p -valor inferior a 0,05 indica violação do pressuposto de normalidade.
3. Caso a distribuição das diferenças fosse compatível com normalidade ($p > 0,05$), procedeu-se ao teste t de uma amostra (*one-sample t-test*), cuja hipótese nula H_0 é: $\mu_{\Delta} = 0$.
 - **One-sample t-test:** verifica se a média de uma amostra difere de um valor conhecido (neste caso, zero). Considera o desvio-padrão da amostra e o número de observações para construir a estatística t .
4. Se o vetor de diferenças não atendesse ao critério de normalidade ($p \leq 0,05$), utilizou-se o teste não paramétrico de Wilcoxon Signed-Rank, cuja hipótese nula H_0 é: “a mediana de Δ é zero”.
 - **Wilcoxon Signed-Rank:** teste não paramétrico que compara medianas de duas amostras pareadas ou, neste caso, testa se a mediana de diferenças em uma única amostra difere de zero. É apropriado quando a suposição de normalidade não é satisfeita.
5. Em todos os casos, adotou-se nível de significância $\alpha = 0,05$.

5.3.1.1 Resultados do Teste de Normalidade (Shapiro–Wilk)

A Tabela 41 resume os resultados do teste de *Shapiro–Wilk* aplicado às diferenças Δ_i para cada nutriente.

Tabela 41 – Shapiro–Wilk nas diferenças “real – target”

Diferença	W	p-valor	Observação
Δ Proteína (g)	0,9808	0,1531	distribu. normal
Δ Carboidrato (g)	0,9821	0,1921	distribu. normal
Δ Lipídios (g)	0,9674	0,0140	sem normalidade

Para proteínas e carboidratos, a estatística de *Shapiro–Wilk* ($p > 0,05$) não rejeita a hipótese de normalidade. Em relação a lipídios, o p -valor $p = 0,0140$ evidencia que as diferenças não se distribuem normalmente, exigindo a aplicação de um teste não paramétrico.

5.3.1.2 Comparação das Médias: Teste t de Uma Amostra e *Wilcoxon*

- **Proteína (g)** Como as diferenças Δ seguem distribuição normal ($p = 0,1531$), aplicou-se o *one-sample t-test* para testar $H_0 : \mu_{\Delta} = 0$.
 - Estatística $t = 0,2806$
 - $p = 0,7796$
 - Média das diferenças $\bar{\Delta} = +0,6323$ g

O valor $p > 0,05$ aponta que não há diferença estatisticamente significativa entre a média de proteína real e a recomendação. Em termos práticos, as dietas de proteínas geradas pelo **TOPSIS** atendem adequadamente aos valores estabelecidos.

- **Carboidrato (g)** Como as diferenças Δ também são normais ($p = 0,1921$), aplicou-se o *one-sample t-test*, resultando em:
 - Estatística $t = -29,1305$
 - $p < 0,0001$
 - Média das diferenças $\bar{\Delta} = -170,2647$ g

O p extremamente baixo indica que rejeitamos H_0 e, portanto, a média dos carboidratos difere significativamente de zero. Em média, as dietas ficaram 170g/dia abaixo da recomendação, o que revela uma subestimação sistemática no componente de carboidrato.

- **Lipídios (g)** Neste caso, a normalidade foi rejeitada ($p = 0,0140$), o que levou ao uso do teste não paramétrico de *Wilcoxon Signed-Rank*:
 - Estatística $W = 0$

- $p < 0,0001$
- Média das diferenças $\bar{\Delta} = -88,8508$ g

O p muito baixo indica que rejeitamos H_0 de “mediana igual a zero”. Em outras palavras, há diferença significativa entre a ingestão de lipídios real, o objetivo e a média das diferenças mostra que as dietas ficaram, em média, cerca de 89 g/dia **abaixo** da recomendação.

5.3.1.3 Interpretação dos Resultados

Os testes estatísticos demonstram que, embora o método **TOPSIS** atinja satisfatoriamente os valores recomendados de proteína (sem diferença significativa), ele subestima de forma expressiva a quantidade de carboidratos e lipídios em relação ao objetivo nutricional. Em síntese:

- Proteína: sem diferença significativa ($p = 0,7796$).
- Carboidrato: diferença altamente significativa ($p < 0,0001$), com média $-170,2647$ g/dia, indicando subestimação.
- Lipídios: diferença significativa ($p < 0,0001$) segundo Wilcoxon, com média $-88,8508$ g/dia, também subestimado.

Do ponto de vista da prática clínica, essa disparidade sugere que, apesar de o algoritmo **TOPSIS** ser capaz de alinhar a proteína ao objetivo, ajustes adicionais são necessários para corrigir sistematicamente as recomendações de carboidratos e lipídios.

Em síntese, o conjunto de testes estatísticos empregados (*Shapiro–Wilk*, *one-sample t-test* e *Wilcoxon Signed-Rank*) oferece um arcabouço rigoroso para validar se as dietas geradas satisfazem ou não as necessidades individualizadas de cada macronutriente, permitindo ajustes finos para que o planejamento nutricional atenda integralmente aos parâmetros clínicos estabelecidos.

5.3.2 Comparação entre os Métodos **TOPSIS** e **NSGA-II**

Ao analisar os resultados obtidos, observa-se que, na implementação realizada, o método **TOPSIS** apresenta um desempenho mais alinhado à função objetivo em comparação ao **NSGA-II**. Essa diferença ocorre porque o **TOPSIS** otimiza a solução ao maximizar a ingestão de proteínas e minimizar a de lipídios, critérios essenciais no contexto da nutrição oncológica. Por outro lado, o **NSGA-II** gera soluções em que os valores de proteínas e lipídios são muito próximos entre si, o que pode comprometer a adequação nutricional para pacientes oncológicos, uma vez que uma ingestão excessiva de lipídios pode ser prejudicial. Essa limitação evidencia a necessidade de ajustes na modelagem do **NSGA-II** para garantir que os resultados reflitam melhor os objetivos nutricionais desejados.

Outro aspecto fundamental a ser considerado é o desempenho computacional dos dois métodos, especialmente em termos de tempo de execução. A Tabela 42 apresenta uma comparação do tempo de processamento para um conjunto de 100 amostras. Os resultados desse experimento empírico evidenciam uma diferença significativa entre os métodos avaliados: enquanto o **TOPSIS** concluiu a análise em pouco mais de meio minuto, o **NSGA-II** demandou mais de 2 horas para ser finalizado. A complexidade computacional do **TOPSIS** é linear em relação ao número de alternativas e critérios, visto que é um método baseado em álgebra linear e cálculos mais simples. Já o **NSGA-II** é um algoritmo evolutivo baseado em otimização multiobjetivo e busca estocástica, sendo ordens de magnitude mais custoso comparado ao **TOPSIS**.

Tabela 42 – Comparação entre os Métodos NSGA-II e TOPSIS

Método	Entradas	Tempo (minutos)
NSGA-II	100	124,0
TOPSIS	100	0,5

Fonte: Autoria própria (2025)

5.4 Limitações do Estudo

Por se tratar de um tema multidisciplinar e que envolve tópicos sensíveis, foram encontradas limitações que impediram que a pesquisa alcançasse resultados mais precisos. Embora os dados sintéticos atendam às exigências nutricionais e possibilitem a aplicação dos métodos **TOPSIS** e **NSGA-II**, a principal limitação foi a impossibilidade de validar o estudo com casos reais.

- **Ausência de dados clínicos:** Além disso, uma das principais limitações desta pesquisa foi a ausência de dados clínicos. Não foi possível formalizar o compartilhamento de dados de pacientes reais com instituições parceiras, estudos similares ou hospitais. Para contornar essa dificuldade, implementou-se a geração sintética de dados, garantindo que os mesmos estivessem dentro de limites aceitáveis e próximos da realidade.
- **Ausência de validação por especialista:** Ademais, a proposta inicial também previa a validação dos resultados por uma nutricionista oncológica. Contudo, devido a restrições de agenda, a especialista não foi capaz de avaliar os resultados dentro do prazo estabelecido. Não obstante, destaca-se que as dietas recomendadas pelo modelo não violam as restrições nutricionais e são compostas por alimentos comumente presentes no cotidiano da população.

Tais limitações devem ser levadas em consideração em trabalhos futuros, pois apresentam oportunidades para aprimorar tanto a precisão quanto a aplicabilidade dos métodos propostos.

6

Considerações Finais

Neste capítulo, são apresentadas as principais conclusões obtidas ao longo do desenvolvimento deste trabalho, destacando os resultados alcançados e suas implicações. Além disso, são discutidas as limitações identificadas e sugestões para trabalhos futuros, com o objetivo de aprofundar a pesquisa e explorar novas possibilidades dentro da área de automação da recomendação de nutrição oncológica.

6.1 Conclusões

Neste trabalho foi proposto e avaliado um modelo de Sistema de Recomendação Multi-critério aplicado à nutrição oncológica, cujo objetivo era responder à questão de pesquisa:

Um modelo computacional pode auxiliar profissionais da área de nutrição oncológica a elaborar dietas personalizadas de acordo com as necessidades e restrições dos pacientes?

Para responder a essa questão, foi necessário cumprir os seguintes objetivos:

- Construir e validar um Simulador de Dados de Pacientes Oncológicos.
- Definir e implementar o modelo do Sistema de Recomendação.
- Avaliar o modelo.

O estudo teve como objetivo principal desenvolver um sistema de recomendação capaz de auxiliar profissionais da área de nutrição a prescrever dietas personalizadas para pacientes oncológicos, considerando aspectos como preferências alimentares, restrições médicas e necessidades nutricionais específicas. Para isso, foram utilizadas abordagens baseadas em métodos de decisão multicritério ([TOPSIS](#)) e multiobjetivo ([NSGA-II](#)), os quais possibilitaram uma modelagem mais precisa das recomendações alimentares.

Para lidar com a indisponibilidade de dados públicos de pacientes oncológicos, foi necessária a criação de um simulador de pacientes baseado em técnicas de geração de dados sintéticos. Esse simulador permitiu a validação dos modelos propostos sem a necessidade de coleta de dados reais, garantindo a viabilidade e a robustez das análises realizadas.

Os resultados obtidos ao longo dos experimentos sugerem que a abordagem adotada pode contribuir para a elaboração de planos alimentares otimizados, favorecendo a melhoria do estado nutricional dos pacientes e, potencialmente, impactando sua qualidade de vida. A validação do modelo, realizada por meio da análise de casos simulados e comparações com diretrizes nutricionais existentes, demonstrou que o sistema é capaz de gerar recomendações coerentes e alinhadas com as melhores práticas na área de nutrição oncológica.

Por outro lado, alguns desafios ainda se apresentam. Especificamente, a aplicação da proposta em ambientes reais ainda não foi realizada devido à ausência de dados nutricionais e clínicos disponíveis. Ademais, a integração do sistema com prontuários eletrônicos e bancos de dados médicos podem proporcionar maior precisão e personalização das recomendações, permitindo um acompanhamento mais efetivo dos pacientes.

Assim, conclui-se que a pesquisa desenvolvida contribui para a interseção entre computação e nutrição oncológica, demonstrando que sistemas de recomendação baseados em decisão multicritério podem ser ferramentas valiosas no suporte à tomada de decisão em contextos clínicos. Espera-se que os resultados deste estudo possam incentivar novas pesquisas na área e contribuir para o desenvolvimento de soluções cada vez mais eficazes e acessíveis para o cuidado nutricional de pacientes oncológicos.

6.2 Trabalhos Futuros

Este trabalho abre caminho para possibilidades de pesquisas futuras, incluindo aplicações em outras áreas da nutrição. Entre essas possibilidades, destacam-se estudos voltados para nutrição personalizada, dietas específicas para pacientes com diabetes e estratégias nutricionais voltadas para a saúde cardiovascular. Sob outra perspectiva, a inclusão de técnicas de aprendizado de máquina e inteligência artificial poderia aprimorar os modelos propostos, permitindo que se tornem cada vez mais adaptativos. Com um fluxo contínuo de *feedback* do paciente, o sistema poderia gerar recomendações de dietas cada vez mais otimizadas.

Uma abordagem promissora para a identificação automática das restrições alimentares associadas aos medicamentos envolve a extração sistemática de informações diretamente das bulas disponibilizadas em portais farmacêuticos especializados. Esse processo pode ser aprimorado por meio da aplicação de técnicas avançadas de [Processamento de Linguagem Natural \(PLN\)](#) e [Inteligência Artificial \(IA\)](#), permitindo a organização e interpretação eficiente desses dados. A integração de um [LLM](#) ajustado especificamente para esse propósito pode representar uma solução mais robusta, sobretudo com capacidade de lidar com diferentes cenários. Com o

treinamento adequado, esse sistema poderia identificar padrões complexos, reconhecer variações nas recomendações nutricionais e oferecer *insights* personalizados, contribuindo para a segurança e a adesão ao tratamento medicamentoso.

Um outro trabalho interessante seria construir um artefato de *software* (*web* ou *mobile*) para que usuários finais pudessem inserir seus dados voluntariamente para receber recomendações de dieta baseada no perfil cadastrado. Isso permitiria um uso mais amplo e acessível da tecnologia, beneficiando não apenas profissionais de nutrição, mas também pacientes que buscam um suporte nutricional mais adaptado às suas necessidades.

Finalmente, a utilização de dados reais de pacientes possibilitaria um estudo comparativo entre as recomendações do modelo computacional e as orientações de um profissional de nutrição, avaliando a eficácia e precisão do sistema. Uma abordagem que se mostrou desafiante neste trabalho, mas que pode ser explorada em pesquisas futuras, é o treinamento de um modelo de inteligência artificial especificamente para a definição de restrições alimentares, permitindo uma personalização mais aprofundada e significativa para cada paciente.

Referências

- ADOMAVICIUS, G.; KWON, Y. New recommendation techniques for multicriteria rating systems. *IEEE Intelligent Systems*, IEEE, v. 22, n. 3, p. 48–55, 2007. Citado 2 vezes nas páginas 20 e 33.
- ADOMAVICIUS, G.; TUZHILIN, A. Personalization technologies: a process-oriented perspective. *Communications of the ACM*, ACM New York, NY, USA, v. 48, n. 10, p. 83–90, 2005. Citado na página 33.
- ADOMAVICIUS, G.; TUZHILIN, A. Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE transactions on knowledge and data engineering*, IEEE, v. 17, n. 6, p. 734–749, 2005. Citado na página 33.
- AGAPITO, G. et al. Dietos: A dietary recommender system for chronic diseases monitoring and management. *Computer methods and programs in biomedicine*, Elsevier, v. 153, p. 93–104, 2018. Citado 2 vezes nas páginas 20 e 47.
- ANVISA. *Bulário Eletrônico da ANVISA*. 2024. [Acessado em: 20 nov. 2024]. Disponível em: <<https://consultas.anvisa.gov.br/#/bulario/>>. Citado 2 vezes nas páginas 64 e 65.
- ARENDS, J. et al. Espen expert group recommendations for action against cancer-related malnutrition. *Clinical nutrition*, Elsevier, v. 36, n. 5, p. 1187–1196, 2017. Citado na página 19.
- AUGUST, D. A. et al. Aspen clinical guidelines: nutrition support therapy during adult anticancer treatment and in hematopoietic cell transplantation. *JPEN. Journal of parenteral and enteral nutrition*, v. 33, n. 5, p. 472–500, 2009. Citado na página 19.
- BABICHENKO, D. et al. Designing the model patient: Data-driven virtual patients in medical education. In: IEEE. *2016 IEEE International Conference on Serious Games and Applications for Health (SeGAH)*. [S.l.], 2016. p. 1–8. Citado na página 50.
- BAUER, J.; CAPRA, S.; FERGUSON, M. Use of the scored patient-generated subjective global assessment (pg-sga) as a nutrition assessment tool in patients with cancer. *European journal of clinical nutrition*, Nature Publishing Group, v. 56, n. 8, p. 779–785, 2002. Citado na página 28.
- BEHZADIAN, M. et al. A state-of-the-art survey of topsis applications. *Expert Systems with applications*, Elsevier, v. 39, n. 17, p. 13051–13069, 2012. Citado na página 36.
- BIANCHINI, D. et al. Prefer: A prescription-based food recommender system. *Computer Standards & Interfaces*, Elsevier, v. 54, p. 64–75, 2017. Citado na página 47.
- BORG, A.; PARODIS, I.; SKANTZE, G. Creating virtual patients using robots and large language models: A preliminary study with medical students. In: *Companion of the 2024 ACM/IEEE International Conference on Human-Robot Interaction*. [S.l.: s.n.], 2024. p. 273–277. Citado na página 50.
- BRANS, J. P.; MARESCHAL, B. The promethee methods for mcdm; the promcalc, gaia and bankadviser software. In: *Readings in multiple criteria decision aid*. [S.l.]: Springer, 1990. p. 216–252. Citado na página 42.

BRASIL. *Lei nº 8234, de 17 de setembro de 1991*. 1991. <https://www.planalto.gov.br/ccivil_03/leis/1989_1994/l8234.htm>. Acesso em: 14 fev. 2024. Citado na página 19.

BRASIL et al. *Diretrizes e recomendações para o cuidado integral de doenças crônicas não-transmissíveis*. [S.l.]: Secretaria de Vigilância em Saúde/Secretaria de Atenção à Saúde Brasília, 2008. Citado na página 25.

BURSZTEIN, S. et al. A mathematical analysis of indirect calorimetry measurements in acutely ill patients. *The American journal of clinical nutrition*, Elsevier, v. 50, n. 2, p. 227–230, 1989. Citado na página 24.

CHAYYA, G. et al. An improved non-personalized combined-heuristic strategy for collaborative filtering recommender systems. In: IEEE. *2018 IEEE Middle East and North Africa Communications Conference (MENACOMM)*. [S.l.], 2018. p. 1–6. Citado na página 32.

CHAVES, R. G. Comparação do nsga-ii e do ε -restrito para o planejamento de cardápios do restaurante universitário da universidade federal de ouro preto. 2022. Citado na página 48.

CHU, S. N.; GOODELL, A. J. Synthetic patients: Simulating difficult conversations with multimodal generative ai for medical education. *arXiv preprint arXiv:2405.19941*, 2024. Citado na página 50.

COLLING, C.; DUVAL, P. A.; SILVEIRA, D. H. Pacientes submetidos à quimioterapia: avaliação nutricional prévia. *Revista brasileira de cancerologia*, v. 58, n. 4, p. 611–617, 2012. Citado na página 67.

COSLEY, D. et al. Is seeing believing? how recommender system interfaces affect users' opinions. In: *Proceedings of the SIGCHI conference on Human factors in computing systems*. [S.l.: s.n.], 2003. p. 585–592. Citado na página 30.

DAS, A. et al. Creating virtual ards patients. In: IEEE. *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.], 2016. p. 2729–2732. Citado na página 50.

DEB, K. et al. A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: Nsga-ii. In: SPRINGER. *Parallel Problem Solving from Nature PPSN VI: 6th International Conference Paris, France, September 18–20, 2000 Proceedings 6*. [S.l.], 2000. p. 849–858. Citado 3 vezes nas páginas 35, 38 e 68.

DELINSKI, L. M. M. et al. *Utilização da modelagem matemática multiobjetivo na geração de dieta para um restaurante universitário*. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2019. Citado na página 48.

EINSTEIN, H. I. A. *Manual Farmacêutico [Internet]*. São Paulo, 2017. [Capturado em novembro de 2024]. Disponível em: <<https://aplicacoes.einstein.br/manualfarmaceutico/Paginas/Home.aspx>>. Citado 2 vezes nas páginas 64 e 65.

ESPÍN, V.; HURTADO, M. V.; NOGUERA, M. Nutrition for elder care: a nutritional semantic recommender system for the elderly. *Expert Systems*, Wiley Online Library, v. 33, n. 2, p. 201–210, 2016. Citado 2 vezes nas páginas 20 e 47.

FERREIRA, D. et al. Recommendation system using autoencoders. *Applied Sciences*, MDPI, v. 10, n. 16, p. 5510, 2020. Citado na página 33.

- FOOD, U.-P. Drink products in latin america: Trends. *Impact on Obesity, Policy Implications*, 2015. Citado na página 19.
- FU, C.; XUE, M.; CHANG, W. Multiple criteria decision making with reliability of assessment. *Annals of Operations Research*, Springer, p. 1–37, 2022. Citado na página 20.
- GABUS, A.; FONTELA, E. World problems, an invitation to further thought within the framework of dematel. *Battelle Geneva Research Center, Geneva, Switzerland*, v. 1, n. 8, p. 12–14, 1972. Citado na página 42.
- GARÓFOLO, A. *Nutrição clínica, funcional e preventiva aplicada à oncologia: teoria e pratica professional*. [S.l.]: Editora Rubio, 2012. Citado na página 27.
- GIUNTINI, E. B.; LAJOLO, F. M.; MENEZES, E. Wenzel de. Composição de alimentos: um pouco de história. *Archivos latinoamericanos de nutricion*, Archivos Latinoamericanos de Nutrición, v. 56, n. 3, p. 295–303, 2006. Citado na página 59.
- GUERRA, R. et al. Análise comparativa do rastreamento de desnutrição e ferramentas diagnósticas como preditores de custos de internação. *J Hum Nutr Diet*, v. 29, n. 2, p. 165–173, 2016. Citado na página 28.
- HARRIS, J. A.; BENEDICT, F. G. A biometric study of human basal metabolism. *Proceedings of the National Academy of Sciences*, v. 4, n. 12, p. 370–373, 1918. Citado 3 vezes nas páginas 24, 57 e 59.
- HEINRICHS, L.; DEV, P.; DAVIES, D. Authoring, deploying, and managing dynamic virtual patients in virtual clinical environments. *Bio-Algorithms and Med-Systems*, De Gruyter, v. 11, n. 2, p. 79–88, 2015. Citado na página 50.
- HONG, M.; JUNG, J. J. Multi-criteria tensor model for tourism recommender systems. *Expert Systems with Applications*, Elsevier, v. 170, p. 114537, 2021. Citado na página 48.
- HWANG, C.-L. et al. Methods for multiple attribute decision making. *Multiple attribute decision making: methods and applications a state-of-the-art survey*, Springer, p. 58–191, 1981. Citado 4 vezes nas páginas 35, 36, 42 e 67.
- IBGE, C. d. T. e. R. *Pesquisa Nacional de Saúde: 2019: Atenção Primária à Saúde e Informações Antropométricas: Brasil*. Rio de Janeiro: IBGE, 2020. 66 p. ISBN 978-65-87201-25-2. Citado na página 53.
- INCA, I. N. D. C. J. A. G. D. S. *ESTIMATIVA 2023: INCIDÊNCIA DE CÂNCER NO BRASIL*. RIO DE JANEIRO, BRASIL, 2022. Disponível em: <<https://www.inca.gov.br/sites/ufu.sti.inca.local/files/media/document/estimativa-2023.pdf>>. Citado 8 vezes nas páginas 21, 25, 26, 27, 53, 56, 70 e 71.
- JOHANSSON, R.; SKANTZE, G.; JÖNSSON, A. A psychotherapy training environment with virtual patients implemented using the furhat robot platform. In: SPRINGER. *Intelligent Virtual Agents: 17th International Conference, IVA 2017, Stockholm, Sweden, August 27-30, 2017, Proceedings 17*. [S.l.], 2017. p. 184–187. Citado na página 50.
- JUÁREZ, M. A. et al. Generation of digital patients for the simulation of tuberculosis with uiss-tb. *BMC bioinformatics*, Springer, v. 21, p. 1–8, 2020. Citado na página 50.

- KALDIRIM, E.; KOSE, Z. Application of a multi-objective genetic algorithm to the modified diet problem. In: *Genetic and Evolutionary Computation Conference (GECCO)*. [S.l.: s.n.], 2006. v. 6. Citado na página 30.
- KIM, J.-H. et al. Design of diet recommendation system for healthcare service based on user information. In: IEEE. *2009 Fourth International Conference on Computer Sciences and Convergence Information Technology*. [S.l.], 2009. p. 516–518. Citado 2 vezes nas páginas 33 e 47.
- KLEINSMITH, A. et al. Understanding empathy training with virtual patients. *Computers in human behavior*, Elsevier, v. 52, p. 151–158, 2015. Citado na página 50.
- KOU, G.; PENG, Y. A bibliography analysis of multi-criteria decision making in computer science (1989-2009). In: SPRINGER. *International Conference on Multiple Criteria Decision Making*. [S.l.], 2009. p. 68–71. Citado na página 20.
- LAMBAY, M. A.; MOHIDEEN, S. P. A hybrid approach based diet recommendation system using ml and big data analytics. 2022. Citado na página 44.
- LANCASTER, L. M.; TAJ, S. The cost of decent subsistence in perspective. *Socio-Economic Planning Sciences*, Elsevier, v. 28, n. 2, p. 121–131, 1994. Citado 2 vezes nas páginas 41 e 42.
- LI, S. S.; KARAHANNA, E. Online recommendation systems in a b2c e-commerce context: A review and future directions. *JOURNAL OF THE ASSOCIATION FOR INFORMATION SYSTEMS*, v. 16, n. 2, p. 2, 2015. Citado 2 vezes nas páginas 33 e 34.
- LOCKS, M. O. The “stinger gap”: the difference between the “cost of subsistence” and that of a minimum-cost noninstitutional diet with palatability. *Computers & Industrial Engineering*, Elsevier, v. 4, n. 1, p. 19–29, 1980. Citado 2 vezes nas páginas 41 e 42.
- MCDM, I. S. 2022. [Urlhttp://www.mcdmsociety.org/](http://www.mcdmsociety.org/). Citado na página 20.
- MCKENSY-SAMBOLA, D. et al. Ontology-based nutritional recommender system. *Applied Sciences*, MDPI, v. 12, n. 1, p. 143, 2021. Citado na página 47.
- MELVILLE, P. et al. *Encyclopedia of machine learning*. [S.l.]: Springer-Verlag, chapter Recommender systems, 2010. Citado na página 30.
- MIETTINEN, K. *Nonlinear multiobjective optimization*. [S.l.]: Springer Science & Business Media, 1999. v. 12. Citado na página 38.
- Ministério da Saúde. *Relação Nacional de Medicamentos Essenciais Rename 2022 [recurso eletrônico]*. Brasília: Ministério da Saúde, 2022. Citado na página 64.
- MONTEIRO, C. R. de A. et al. Uso de fitoterápicos em pacientes com câncer na região do grande abc. *Clinical Oncology Letters*, Centro de Estudos e Pesquisa de Hematologia e Oncologia (CEPHO), n. AheadOfPrint, p. 0–0, 2020. Citado na página 55.
- MOYNIHAN, T.; KELLY, D. G.; FISCH, M. J. To feed or not to feed: is that the right question? *Journal of clinical oncology*, American Society of Clinical Oncology, v. 23, n. 25, p. 6256–6259, 2005. Citado na página 29.
- NILSON, E. A. F. et al. Custos atribuíveis a obesidade, hipertensão e diabetes no sistema Único de saúde, brasil, 2018. *Revista Panamericana de Salud Pública*, SciELO Public Health, v. 44, p. e32, 2020. Citado na página 19.

- OMS, O. M. d. S. *Organização Mundial da Saúde*. Geneva, Switzerland: OMS, 2020. Citado 2 vezes nas páginas 19 e 25.
- OPRICOVIC, S.; TZENG, G.-H. Compromise solution by mcdm methods: A comparative analysis of vikor and topsis. *European journal of operational research*, Elsevier, v. 156, n. 2, p. 445–455, 2004. Citado na página 42.
- ORGANIZATION, W. H. Obesity: preventing and managing the global epidemic: report of a who consultation. World Health Organization, 2000. Citado na página 60.
- PAULINO, J. C. P. L. Modelagem matemática para otimização de dietas de portadores de diabetes mellitus. UNIVERSIDADE FEDERAL DE ALOAS, 2017. Citado na página 71.
- PENCE, T. B.; DUKES, L. C.; HODGES, L. F. Animation validation of obese virtual pediatric patients using a flacc pain scale. In: SPRINGER. *Virtual, Augmented and Mixed Reality: 8th International Conference, VAMR 2016, Held as Part of HCI International 2016, Toronto, Canada, July 17-22, 2016. Proceedings 8*. [S.l.], 2016. p. 552–564. Citado na página 50.
- PEREIRA, L. F. S. Aspectos nutricionais dos pacientes em tratamento oncológico: Uma revisão sistemática. *Revista Contemporânea*, v. 4, n. 5, p. e3405–e3405, 2024. Citado na página 20.
- PEZOULAS, V.; TACHOS, N.; FOTIADIS, D. Generation of virtual patients for in silico cardiomyopathies drug development. In: IEEE. *2019 IEEE 19th International Conference on Bioinformatics and Bioengineering (BIBE)*. [S.l.], 2019. p. 671–674. Citado na página 50.
- PHILIPPI, S. T. *PIRÂMIDE DOS ALIMENTOS: FUNDAMENTOS BÁSICOS DA NUTRIÇÃO*. [S.l.]: EDITORA MANOLE, 2008. Citado na página 23.
- PHILIPPI, S. T. Redesenho da pirâmide alimentar brasileira para uma alimentação saudável. SÃO PAULO, 2013. Citado 3 vezes nas páginas 23, 24 e 59.
- POCHMANN, V. d. O. Sistema de recomendação multiobjetivo para dietas alimentares. 2022. Citado na página 48.
- PORIYA, A. et al. Non-personalized recommender systems and user-based collaborative recommender systems. *Int. J. Appl. Inf. Syst*, v. 6, n. 9, p. 22–27, 2014. Citado 2 vezes nas páginas 31 e 32.
- PRADO, C. M. et al. Sarcopenia as a determinant of chemotherapy toxicity and time to tumor progression in metastatic breast cancer patients receiving capecitabine treatment. *Clinical cancer research*, American Association for Cancer Research, v. 15, n. 8, p. 2920–2926, 2009. Citado na página 20.
- REDJDAL, A. et al. Creating synthetic patients to address interoperability issues: a case study with the management of breast cancer patients. In: *Integrated Citizen Centered Digital Health and Social Care*. [S.l.]: IOS Press, 2020. p. 177–181. Citado na página 50.
- REIS, M. I. G. dos; LIMA, M. B. de; LIMA, F. C. Aspectos nutricionais de pacientes com câncer gástrico e suas implicações no desfecho clínico. *Revista JRG de Estudos Acadêmicos*, v. 6, n. 12, jan. 2023. Disponível em: <<https://doi.org/10.5281/zenodo.7570468>>. Citado na página 67.
- REZAEI, J. Bwm: Best worst method. *Delft University of Technology*. <https://bestworstmethod.com/wp-content/uploads/2020/01/Best-Worst-Method-BWM-2019.pdf>, 2015. Citado na página 42.

- RIBEIRO, D. et al. Souschef: mobile meal recommender system for older adults. In: SCITEPRESS. *International Conference on Information and Communication Technologies for Ageing Well and e-Health*. [S.l.], 2017. v. 2, p. 36–45. Citado 2 vezes nas páginas 20 e 47.
- RICCI, F.; ROKACH, L.; SHAPIRA, B. Introduction to recommender systems handbook. In: *Recommender systems handbook*. [S.l.]: Springer, 2011. p. 1–35. Citado 2 vezes nas páginas 32 e 33.
- ROSTAMI, M. et al. A novel healthy and time-aware food recommender system using attributed community detection. *Expert Systems with Applications*, Elsevier, v. 221, p. 119719, 2023. Citado 3 vezes nas páginas 44, 45 e 46.
- SAATY, T. L. How to make a decision: the analytic hierarchy process. *European journal of operational research*, Elsevier, v. 48, n. 1, p. 9–26, 1990. Citado na página 42.
- SAMPAIO, R. F.; MANCINI, M. C. Estudos de revisão sistemática: um guia para síntese criteriosa da evidência científica. *Brazilian journal of physical therapy*, SciELO Brasil, v. 11, p. 83–89, 2007. Citado na página 49.
- SBNO. *I Consenso brasileiro de nutrição oncológica da SBNO*. Rio de Janeiro: Edite, 2021. Citado 6 vezes nas páginas 27, 28, 29, 60, 61 e 64.
- SEZGIN, E.; ÖZKAN, S. A systematic literature review on health recommender systems. In: IEEE. *2013 E-Health and Bioengineering Conference (EHB)*. [S.l.], 2013. p. 1–4. Citado na página 33.
- SINISI, S. et al. Complete populations of virtual patients for in silico clinical trials. *Bioinformatics*, Oxford University Press, v. 36, n. 22-23, p. 5465–5472, 2020. Citado na página 50.
- SMITH, V. E. *Supplement to Electronic Computation of Human Diets*. [S.l.]: Bureau of Business and Economic Research, Graduate School of Business . . . , 1963. Citado na página 41.
- SOARES, T. F. et al. Otimização multiobjetivo aplicada ao planejamento de dietas para portadores de diabetes. Universidade Federal de Uberlândia, 2024. Citado 3 vezes nas páginas 59, 70 e 71.
- SOBOCAN, M.; KLEMENC-KETIS, Z. Medical students' attitudes towards the use of virtual patients. *Journal of Computer Assisted Learning*, Wiley Online Library, v. 33, n. 4, p. 393–402, 2017. Citado na página 50.
- Sociedade Brasileira de Oncologia Clínica (SBOC). *Recomendações de atividade física durante e após tratamento oncológico*. São Paulo: Sociedade Brasileira de Oncologia Clínica; Instituto Nacional de Câncer; Sociedade Brasileira de Atividade Física e Saúde, 2023. 33f.: il. Citado na página 53.
- SPAK, M. D. S. et al. Aplicação da modelagem matemática para o planejamento de cardápios para restaurantes universitários. Universidade Tecnológica Federal do Paraná, 2017. Citado na página 48.
- STIGLER, G. J. The cost of subsistence. *Journal of farm economics*, JSTOR, v. 27, n. 2, p. 303–314, 1945. Citado 3 vezes nas páginas 29, 38 e 41.

- TAKAHASHI, Y. et al. Decentralized learning with virtual patients for medical diagnosis of diabetes. *SN Computer Science*, Springer, v. 2, p. 1–10, 2021. Citado na página 50.
- TAVARNESI, G. et al. Learning with virtual patients in medical education. In: *EC-TEL (Practitioner Proceedings)*. [S.l.: s.n.], 2018. Citado na página 50.
- THINGSOLVER. *Introduction to recommender systems*. 2022. Url<https://thingsolver.com/introduction-to-recommender-systems/>. Citado 2 vezes nas páginas 30 e 31.
- TOLEDO, R. Y.; ALZHRANI, A. A.; MARTINEZ, L. A food recommender system considering nutritional information and user preferences. *IEEE Access*, IEEE, v. 7, p. 96695–96711, 2019. Citado 4 vezes nas páginas 20, 30, 42 e 43.
- TZENG, G.-H.; HUANG, J.-J. *Multiple attribute decision making: methods and applications*. [S.l.]: CRC press, 2011. Citado na página 20.
- UNICAMP, T. . N. *Tabela Brasileira de Composição de Alimentos (TACO)*. [S.l.]: Nepa-Unicamp, Campinas, 2004. Online. [out 2004]. 42 p. Disponível em: <<http://www.unicamp.br/nepa/taco>>. Citado na página 58.
- USP. *Tabela Brasileira de Composição de Alimentos*. 2023. Url<http://www.tbca.net.br/>. Citado 2 vezes nas páginas 34 e 71.
- VARGAS, D. E. Um estudo dos parâmetros do algoritmo nsga-ii com o operador sbx em problemas de otimização estrutural multiobjetivo. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, v. 6, n. 2, 2018. Citado na página 38.
- WAHRLICH, V.; ANJOS, L. A. d. Aspectos históricos e metodológicos da medição e estimativa da taxa metabólica basal: uma revisão da literatura. *Cadernos de Saúde Pública*, SciELO Brasil, v. 17, p. 801–817, 2001. Citado na página 24.
- WALONOSKI, J. et al. Synthea: An approach, method, and software mechanism for generating synthetic patients and the synthetic electronic health care record. *Journal of the American Medical Informatics Association*, Oxford University Press, v. 25, n. 3, p. 230–238, 2018. Citado 2 vezes nas páginas 49 e 50.
- YANG, L. et al. Yum-me: A personalized nutrient-based meal recommender system. *ACM TRANSACTIONS ON INFORMATION SYSTEMS (TOIS)*, ACM NEW YORK, NY, USA, v. 36, n. 1, p. 1–31, 2017. Citado 2 vezes nas páginas 20 e 47.
- ZHANG, Z.; YAN, C.; MALIN, B. A. Keeping synthetic patients on track: feedback mechanisms to mitigate performance drift in longitudinal health data simulation. *Journal of the American Medical Informatics Association*, Oxford University Press, v. 29, n. 11, p. 1890–1898, 2022. Citado na página 50.
- ZHOU, C. et al. Virtual patients for mechanical ventilation in the intensive care unit. *Computer Methods and Programs in Biomedicine*, Elsevier, v. 199, p. 105912, 2021. Citado na página 50.
- ZHOU, Y. et al. A framework for the generation of realistic synthetic cardiac ultrasound and magnetic resonance imaging sequences from the same virtual patients. *IEEE transactions on medical imaging*, IEEE, v. 37, n. 3, p. 741–754, 2017. Citado na página 50.