

UNIVERSIDADE FEDERAL DE OURO PRETO  
INSTITUTO DE CIÊNCIAS EXATAS E BIOLÓGICAS  
DEPARTAMENTO DE COMPUTAÇÃO

GUSTAVO VIEIRA NASCIMENTO  
Orientador: Prof. Dr. Gladston Juliano Prates Moreira

**ALGORITMO EVOLUTIVO MULTI OBJETIVO COM MEDIDA DE  
UNIFORMIDADE NO ESPAÇO DE DECISÃO APLICADO NO  
PROBLEMA DA DIETA**

Ouro Preto, MG  
2025

UNIVERSIDADE FEDERAL DE OURO PRETO  
INSTITUTO DE CIÊNCIAS EXATAS E BIOLÓGICAS  
DEPARTAMENTO DE COMPUTAÇÃO

GUSTAVO VIEIRA NASCIMENTO

**ALGORITMO EVOLUTIVO MULTI OBJETIVO COM MEDIDA DE UNIFORMIDADE  
NO ESPAÇO DE DECISÃO APLICADO NO PROBLEMA DA DIETA**

Monografia apresentada ao Curso de Ciência da Computação da Universidade Federal de Ouro Preto como parte dos requisitos necessários para a obtenção do grau de Bacharel em Ciência da Computação.

**Orientador:** Prof. Dr. Gladston Juliano Prates Moreira

Ouro Preto, MG  
2025



## FOLHA DE APROVAÇÃO

**Gustavo Vieira Nascimento**

### **Algoritmo Evolutivo Multiobjetivo com Medida de Uniformidade no Espaço de Decisão Aplicado no Problema da Dieta**

Monografia apresentada ao Curso de Ciência da Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Ciência da Computação

Aprovada em 09 de Abril de 2025.

#### Membros da banca

Gladston Juliano Prates Moreira (Orientador) - Doutor - Universidade Federal de Ouro Preto  
Fernando Henrique de Oliveira Duarte (Examinador) - Mestre - Programa de Pós Graduação em Ciência da Computação (UFOP)  
Marcus Daniel de Almeida (Examinador) - Mestre - Programa de Pós Graduação em Ciência da Computação (UFOP)

Gladston Juliano Prates Moreira, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 09/04/2025



Documento assinado eletronicamente por **Gladston Juliano Prates Moreira, PROFESSOR DE MAGISTERIO SUPERIOR**, em 09/04/2025, às 19:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0893627** e o código CRC **70FB0188**.

*Dedico este trabalho aos meus pais, avós, e todos os meus primos e tios, por estarem sempre ao meu lado, seja nos momentos de tristeza ou de alegria*

# Agradecimentos

Quero agradecer inicialmente aos meus pais, Vanderlan e Tânia, que com muito amor e carinho nutriram minha sede por conhecimento, me incentivando na vida acadêmica e me fornecendo todo o suporte necessário para chegar até aqui. Mais que isso, gostaria de agradecer todos os meus parentes, que mesmo distantes, me apoiaram por essa jornada.

Agradeço também ao meu orientador, Prof. Dr. Gladston , pela orientação diligente e ensino de excelência, assim como todos os professores do Departamento de Computação da Universidade Federal de Ouro Preto, pelo compromisso com o trabalho, didática, e incentivo aos estudantes.

Por fim, agradeço à Universidade Federal de Ouro Preto, por me fornecer a oportunidade de expandir o meu conhecimento e me tornar um indivíduo mais apto.

O homem é lobo do homem. (HOBBS, 1651)

# Resumo

Este trabalho aborda o problema da dieta, que fundamentalmente envolve a criação de uma seleção de alimentos ótima para um certo período de tempo, dadas certas restrições e um ou mais objetivos a serem otimizados. Em variações multiobjetivo do problema, as abordagens atuais focam em melhorar a uniformidade das soluções apenas no espaço dos objetivos, não considerando a igualmente crucial uniformidade no espaço de decisão. Esse trabalho propõe a criação de um modelo de otimização multiobjetivo para o problema da dieta que incorpora uma medida de uniformidade para gerar uma melhor distribuição de soluções no espaço de decisão. Esse modelo busca (1) minimizar custo, (2) maximizar proteínas totais e (3) minimizar penalidades de variedade da dieta, enquanto satisfaz restrições diárias alimentares. A partir dos experimentos, foi possível mostrar que a abordagem proposta consegue gerar dietas que aproximam a fronteira Pareto do problema e que, quando comparadas ao NSGA-II, têm melhor desempenho em métricas de uniformidade no espaço de decisão e com hipervolume semelhante. Os resultados evidenciam a aplicabilidade prática da abordagem em planejamentos alimentares personalizados, oferecendo ampla escolha para um possível tomador de decisões.

**Palavras-chave:** Problema da dieta. Espaço de Decisão. Medida de Uniformidade.

# Abstract

This work addresses the diet problem, which fundamentally involves selecting an optimal combination of foods over a specified period while satisfying given constraints and optimizing one or more objectives. In multiobjective variations of the problem, current approaches focus solely on improving solution uniformity in the objective space, neglecting the equally crucial uniformity in the decision space. We propose a novel multiobjective optimization model for the diet problem that incorporates a uniformity metric to generate better-distributed solutions in the decision space. Our model simultaneously: (1) minimizes cost, (2) maximizes protein content, and (3) reduces dietary variety penalties, while satisfying daily nutritional constraints. Experimental results demonstrate that our approach was able to generate solutions that approximate the real Pareto front, outperforming NSGA-II in decision-space uniformity metrics while maintaining comparable hypervolume. These findings highlight the model's effectiveness for personalized meal planning applications, offering ample choice for possible decision takers.

**Keywords:** Diet Problem, Decision Space, Uniformity Measure.

# Lista de Ilustrações

Figura 2.1 – Exemplo de Fronteira Pareto . . . . .	5
Figura 2.2 – Etapas do processo Evolutivo . . . . .	7
Figura 5.1 – Fronteira Pareto do exemplo de uma execução das duas abordagens; NSGA-II à esquerda e WDH à direita . . . . .	17
Figura 5.2 – Histogramas das simulações de Monte-Carlo para a medida de HiperVolume, com 30, 100 e 300 gerações . . . . .	18
Figura 5.3 – Histogramas das simulações de Monte-Carlo para a medida de $d_{min}$ , com 30, 100 e 300 gerações . . . . .	19
Figura 5.4 – Histogramas das simulações de Monte-Carlo para a medida de $d_{med}$ , com 30, 100 e 300 gerações . . . . .	19

# Lista de Tabelas

Tabela 4.1 – Tabela de Categorias de Alimentos . . . . .	11
Tabela 4.2 – Tabela de penalidades . . . . .	12
Tabela 5.1 – Tabela de comparações entre os algoritmos WDH e NSGA-II . . . . .	17

# Lista de Algoritmos

4.1	Heurística WDH .....	15
-----	----------------------	----

# Lista de Abreviaturas e Siglas

ABNT	Associação Brasileira de Normas Técnicas
DECOM	Departamento de Computação
UFOP	Universidade Federal de Ouro Preto
VDR	Valores Diários Recomendados
MOEA	MultiObjective Evolutionary Algorithm (Algoritmo Multiobjetivo Evolutivo)

# Lista de Símbolos

$\in$	Pertence
$\forall$	Para todo
$\prec$	Domina
$\exists$	Existe
$\nexists$	Não existe
$\cup$	União de conjuntos

# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Justificativa	2
1.2	Objetivos	2
1.3	Objetivos Específicos	3
1.4	Organização do Trabalho	3
1.4.1	Estrutura da Monografia	3
<b>2</b>	<b>Fundamentação Teórica</b>	<b>4</b>
2.1	Problema da Dieta	4
2.2	Problema de Otimização Multiobjetivo	4
2.3	Uniformidade no Espaço de Decisão baseado em Dominância	6
2.4	Algoritmos Evolutivos Multiobjetivo (MOEAs)	6
2.4.1	NSGA-II	8
<b>3</b>	<b>Revisão Bibliográfica</b>	<b>9</b>
3.1	Trabalhos Relacionados	9
<b>4</b>	<b>Desenvolvimento</b>	<b>11</b>
4.1	Conjunto de Dados	11
4.2	Definição do modelo	11
4.3	Medida de Uniformidade no Espaço de Decisão	13
4.4	Penalidade	14
4.5	Algoritmo Genético	14
4.6	Experimentação Prática	16
<b>5</b>	<b>Resultados</b>	<b>17</b>
<b>6</b>	<b>Considerações Finais</b>	<b>20</b>
6.1	Conclusão	20
6.2	Trabalhos Futuros	20
	<b>Referências</b>	<b>21</b>

# 1 Introdução

Segundo (International Food Information Council Foundation, 2023) e (GlobalData, 2020), a busca por um estilo de vida mais saudável é uma tendência global, e valores nutricionais, assim como sabor e preço, são as características mais levadas em conta na hora da compra, ideia corroborada por (DUARTE; TEIXEIRA; SILVA, 2021). Tudo isso indica uma busca pelo consumidor por uma alimentação melhor, por meio de dietas que sejam saudáveis e pouco onerosas.

Pensando na dificuldade de se criar uma dieta de baixo preço, (STIGLER, 1945) propôs o que é conhecido como problema da dieta, que consiste em identificar uma combinação de alimentos que satisfaça as necessidades nutricionais de um indivíduo com o menor custo possível. Entretanto, situações reais de planejamento de dietas geralmente envolvem mais do que apenas minimizar o custo, e em decorrência disto, surgem variações do problema original com dois ou mais objetivos conflitantes, tornando-se um problema multiobjetivo.

Além da minimização do custo, alguns exemplos de objetivos utilizados na versão multiobjetivo do problema são minimizar gorduras trans e saturadas (AMIN; MULLIGAN-GOW; ZHANG, 2019), maximizar variedade (MARRERO et al., 2020) (RAMOS-PÉREZ et al., 2021), maximizar quantidade de proteínas (SILVA et al., 2017), ou minimizar uma métrica agregada de peso (POCHMANN; ZUBEN, 2022). Esses objetivos são conflitantes entre si, o que significa que a melhora de um objetivo implica na piora dos outros. Esse tipo de problema geralmente não possui uma solução única, mas várias soluções que fazem o equilíbrio entre os diversos objetivos, e o conjunto dessas soluções constitui a chamada fronteira Pareto.

Entretanto, encontrar uma aproximação da fronteira Pareto de um problema não é uma tarefa simples; a natureza combinatória do problema implica em um espaço de busca imenso, e o uso de métodos heurísticos se torna essencial para se encontrar soluções em tempo viável. Um desses métodos é o de um algoritmo evolutivo, descrito por (HOLLAND, 1975), que utiliza as ideias de evolução de Charles Darwin para a criação de uma população de soluções que a cada geração se torna mais apta a resolver o problema.

O uso da heurística de algoritmo evolutivo se tornou comum para resolver problemas multiobjetivo, culminando no que são chamados MOEAs (MultiObjective Evolutionary Algorithms), algoritmos evolutivos multiobjetivo. Dois dos MOEAs mais comuns são o SPEA2 (Strength Pareto Evolutionary Algorithm 2) (ZITZLER; LAUMANN; THIELE, 2001) e o NSGA-II (Non-dominated Sorting Genetic Algorithm II) (DEB et al., 2002), que se exaltam na sua capacidade de gerar soluções diversas e de rápida convergência. No problema da dieta multiobjetivo, o uso do NSGA-II tem sido comum, como em (KALDIRIM; KOSE, 2006), (SELJAK, 2006) e (POCHMANN; ZUBEN, 2022), que realçam sua flexibilidade para diferentes restrições do

problema.

Além disso, no contexto de otimização multiobjetivo, é interessante também que se tenha variedade no Espaço de Decisão, onde as escolhas dos valores das variáveis a serem aplicadas nas funções objetivo são feitas. Um Espaço de decisão mais variado ou uniforme permite que a entidade responsável pela escolha da solução, chamada de Tomador de Decisões, tenha um leque de soluções distintas para escolher como preferir. Em (MOREIRA; PAQUETE, 2019), uma métrica de uniformidade ponderada pela dominância é usada para manter a uniformidade no espaço de decisão sem ter perdas significativas na convergência no espaço dos objetivos.

Neste trabalho, utilizaremos uma medida de uniformidade no espaço de decisão em um algoritmo genético multiobjetivo para resolver o Problema da Dieta, visando gerar diversas dietas diferentes entre si, que são nutritivas, variadas e de baixo custo.

## 1.1 Justificativa

O problema da dieta pode ser modelado como um problema multiobjetivo, pois envolve a minimização e maximização de vários objetivos. Utilizando recomendações mínimas e máximas para macronutrientes e micronutrientes, é possível estabelecer as restrições necessárias.

(SELJAK, 2006) descreve o Problema da Dieta multiobjetivo como um problema da mochila multidimensional e um problema de decisão NP-completo, e, portanto, o uso de heurísticas como algoritmos evolutivos se torna essencial para se encontrar soluções próximas da fronteira Pareto em tempo factível.

Os algoritmos genéticos possibilitam a busca de soluções viáveis em um domínio com um número extremamente alto de combinações, e a capacidade de evolução e mutação das soluções provê uma aproximação com soluções variadas e próximas da fronteira Pareto real. Por causa disso, o uso de MOEAs como o NSGA-II se torna comum para a resolução desse problema, sendo utilizado em (KALDIRIM; KOSE, 2006), (SUN; WANG, 2024), (MOREIRA et al., 2017) e obtendo resultados satisfatórios.

## 1.2 Objetivos

Desenvolver um algoritmo evolutivo que utiliza uma métrica de uniformidade no espaço de decisão que seja capaz de gerar uma gama de dietas distintas entre si que satisfaçam as necessidades nutricionais diárias recomendadas, minimizando custo e maximizando variedade em um intervalo de tempo de 7 dias. Serão então feitos testes e comparações com o desempenho do algoritmo NSGA-II.

## 1.3 Objetivos Específicos

Os objetivos específicos do trabalho são:

- Criação de um modelo para o problema da dieta que envolva minimizar o custo, maximizar variedade através da minimização de uma medida de penalidade, e maximizar a quantidade total de proteína.
- Implementação de uma ferramenta para geração de dietas neste modelo que utilize de uma medida de uniformidade para melhor distribuição de soluções no espaço de decisão
- Realizar comparações de uniformidade e hipervolume entre a ferramenta implementada e o algoritmo NSGA-II

## 1.4 Organização do Trabalho

Esse trabalho é dividido em 6 capítulos, que remetem à estrutura do Trabalho de Conclusão de Curso. Nos capítulos 2 e 3, será feita uma breve contextualização dos algoritmos e conhecimentos básicos para o entendimento e desenvolvimento do trabalho, além de uma exposição e discussão de trabalhos relacionados ao tema. O capítulo 4 descreverá a metodologia do trabalho, o que foi produzido no trabalho e como foi feito; já os capítulos 5 e 6 abordam os resultados dos testes experimentais e discussão acerca do que foi obtido.

### 1.4.1 Estrutura da Monografia

**Capítulo 1:** Introdução.

**Capítulo 2:** Fundamentação Teórica

**Capítulo 3:** Revisão Bibliográfica

**Capítulo 4:** Metodologia.

**Capítulo 5:** Resultados e Discussões.

**Capítulo 6:** Considerações Finais

## 2 Fundamentação Teórica

### 2.1 Problema da Dieta

O problema da dieta é caracterizado como um problema da mochila multidimensional (SELJAK, 2006), descrito pela primeira vez em (STIGLER, 1945), tratando da busca em minimizar o custo monetário de uma dieta que satisfaça todas as necessidades calóricas e nutritivas de um indivíduo. Considerando  $A$  como o conjunto de alimentos a ser avaliado e  $N$  o conjunto de componentes essenciais na dieta (Calorias, Macronutrientes, Vitaminas, Sais minerais, etc.), chamados de elementos, tal problema pode ser definido em termos de programação linear como:

$$\min \sum_i c_i x_i, \quad i \in A \quad (1)$$

$$s.a. \sum_i n_{ij} x_i \geq R_j, \quad i \in A, j \in N \quad (2)$$

$$x_i \geq 0$$

Em (1),  $c_i$  corresponde ao custo do alimento  $i$  por porção, e  $x_i$  corresponde à variável de decisão que determina a quantidade de porções que o alimento  $i$  tem na dieta. Em (2),  $n_{ij}$  é a quantidade do elemento  $j$  que está presente no alimento  $i$ , e  $R_j$  é a quantidade mínima do elemento  $j$  que deve estar presente na dieta.

A dieta pode ser feita para períodos de tempo diferentes, como para um dia, uma semana ou até um mês. Também pode ter objetivos diferentes do de minimizar custo, como maximizar calorias ou proteínas, e também pode envolver mais de um objetivo simultaneamente, levando em consideração também fatores como preferências pessoais, variedade, restrições calóricas, entre outros.

### 2.2 Problema de Otimização Multiobjetivo

Um problema de otimização multiobjetivo (EHRGOTT, 2005) é um problema que envolve minimizar simultaneamente dois ou mais objetivos conflitantes, em que a melhora de um objetivo implica na piora de outro(s). Dado um conjunto de  $m$  objetivos e um vetor de variáveis de decisão  $x$ , o problema pode ser descrito como

$$\min f(x) = (f_1(x), f_2(x), f_3(x), \dots, f_m(x)), x \in X$$

Em que  $X$  é o conjunto de valores factíveis para o vetor de variáveis de decisão  $x$  no que é chamado espaço de decisão. A imagem do vetor de variáveis de decisão  $x$ ,  $f(x)$ , corresponde

ao espaço objetivo, e o objetivo se torna então minimizar a função objetivo  $f(x)$  no contexto da otimalidade Pareto. Para isso, primeiro é necessário definir a relação de dominância.

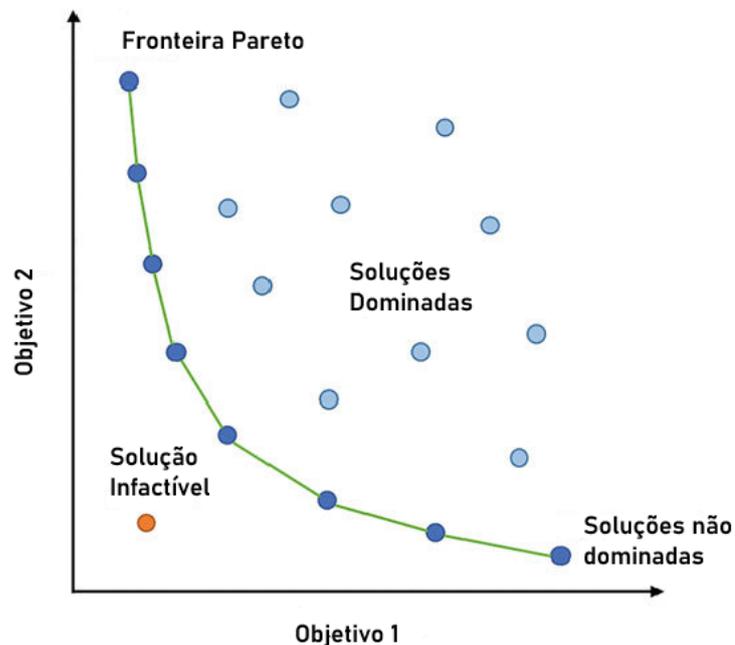
Seja  $x_1, x_2 \in X$ , a relação de dominância,  $\prec$ , é definida como

$$f(x_1) \prec f(x_2) \iff f(x_1) \leq f(x_2), f(x_1) \neq f(x_2)$$

em que  $f(x_1) \leq f(x_2)$  se, e somente se,  $f_i(x_1) \leq f_i(x_2) \forall i = 1, \dots, m$  e  $f(x_1) \neq f(x_2)$  se, e somente se  $\exists i \in \{1, \dots, m\}$  tal que  $f_i(x_1) < f_i(x_2)$ . Dessa maneira, uma solução  $x_1$  domina  $x_2$  se ela obter um resultado melhor em ao menos uma das funções objetivo. A relação de dominância é reflexiva e transitiva, o que significa que se  $x_1 \prec x_2$ , então  $x_2 \succ x_1$ , e que se  $x_1 \prec x_2 \prec x_3$ , então  $x_1 \prec x_3$

Uma solução  $f(x')$  é uma solução Pareto-ótima se  $\nexists x \in X$  tal que  $f(x) \prec f(x')$ , ou seja, não existe outra solução que a domine. O conjunto de todas as soluções Pareto-ótimas é chamado de conjunto Pareto, denotado como  $X_E$ , e o conjunto  $Y_N$  denota o conjunto imagem de  $X_E$ , e representa o conjunto de pontos não dominados, chamado também de fronteira Pareto, e ilustrado na Figura 2.1.

Figura 2.1 – Exemplo de Fronteira Pareto



Fonte: Adaptado pelo autor de (LIU; IJZERMAN; WESTEN, 2021)

A fronteira Pareto real pode não ser alcançável, requerendo muitas vezes uma aproximação que seja o mais fiel e representativa da real possível. As soluções que estão abaixo da fronteira são infactíveis, e não podem ser alcançadas por qualquer combinação de variáveis de decisão do problema. Como não existe uma solução ótima única, e sim um conjunto de soluções, cabe a uma entidade chamada de tomador de decisão realizar a escolha da solução a ser aplicada. O tomador de decisão pode ser um humano que escolhe entre a solução que mais lhe agrada ou

uma estratégia computacional que faz a escolha baseada em alguma métrica. Portanto, ter várias soluções diferentes entre si é desejável.

## 2.3 Uniformidade no Espaço de Decisão baseado em Dominação

Em problemas multiobjetivo, além da importância de se haver uma boa distribuição das soluções no espaço das soluções, também é importante que se tenha uma boa distribuição no espaço de decisão, para que seja possível o tomador de decisão ter liberdade de escolher não só os resultados das funções, mas também valores diferentes para as variáveis.

Para isso, (MOREIRA; PAQUETE, 2019) propõe uma função de uniformidade ponderada pela dominância, assim como a utilização dessa função ponderada no processo de seleção de um algoritmo genético, como forma de aumentar a distribuição e uniformidade no espaço de decisão. Dado um par de pontos  $x, x'$  pertencentes a uma população  $P$ , essa função de uniformidade é dada por

$$w_d(x, x') = \frac{\|x - x'\|}{|d(x) - d(x')| + 1}$$

em que  $\|x - x'\|$  é a distância euclidiana entre  $x$  e  $x'$ , e  $d(x)$  é uma função utilizada na etapa de seleção do algoritmo SPEA-2, definida como:

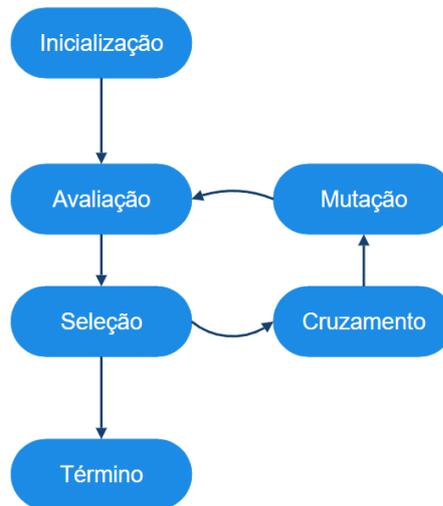
$$d(x) = \sum_{\substack{x' \in P \\ f(x') \prec f(x)}} s(x')$$

A função  $s(x')$  diz respeito à quantidade de pontos que o ponto  $x'$  domina.

## 2.4 Algoritmos Evolutivos Multiobjetivo (MOEAs)

Algoritmos evolutivos, descritos inicialmente em (HOLLAND, 1975), são uma classe de algoritmos que usam princípios da seleção natural e da sobrevivência do mais forte para gerar aproximações ou soluções para problemas de busca ou otimização. Exemplos de algoritmos evolutivos são algoritmos genéticos, voltados para a realização de cruzamentos e codificação de soluções por meio de cadeias de informação chamadas de gene. Cada solução que consegue resolver o problema em questão é chamada de indivíduo ou cromossomo, e um conjunto de indivíduos é uma população.

Figura 2.2 – Etapas do processo Evolutivo



Fonte: Adaptação de:

<https://towardsdatascience.com/introduction-to-evolutionary-algorithms-a8594b484ac>. Acesso em 31 de agosto de 2024

A Figura 2.2 descreve as principais etapas de um algoritmo evolutivo genético, sendo elas:

- **Inicialização:** É a etapa inicial do algoritmo. Um número predeterminado de indivíduos são gerados de forma aleatória para constituir uma população inicial para o problema.
- **Avaliação:** Os indivíduos são avaliados quanto a uma métrica de aptidão (do inglês *Fitness*). Essa métrica de aptidão diz respeito ao valor que o indivíduo obtém na função objetivo do problema, e é um indicativo de sua qualidade em resolvê-la.
- **Seleção:** Feita a avaliação, os indivíduos que tiveram maior aptidão são escolhidos para a formação de pares para a etapa de cruzamento.
- **Cruzamento:** Os pares de indivíduos são combinados para gerar novos indivíduos, nos quais componentes diferentes de cada elemento do par são selecionados para formar um novo indivíduo que herda características de ambos.
- **Mutação:** Após a criação dos novos indivíduos, há uma chance, chamada taxa de mutação, de ocorrer uma pequena variação em alguma característica do indivíduo, ampliando a diversidade da população.

Após a etapa de mutação, a nova população se junta à anterior e um novo processo de avaliação, seleção, cruzamento e mutação é feito até que se alcance um número predefinido de iterações, onde o processo termina e a população final de soluções é obtida.

Em (SCHAFFER, 1985), a estratégia de algoritmos evolutivos é expandida para a aplicação em problemas multiobjetivos, onde a aptidão (*Fitness*) é um vetor, e não algo escalar, visando indivíduos próximos à fronteira Pareto. Desde então, ocorreram diversos avanços nessa categoria de algoritmos evolutivos, que passaram a ser conhecidos como Algoritmos Evolutivos Multiobjetivo (*MultiObjective Evolutionary Algorithms*), ou MOEAs. São algoritmos voltados para a resolução de problemas multiobjetivo, e os mais utilizados são o NSGA-II (DEB et al., 2002) e o SPEA2 (ZITZLER; LAUMANN; THIELE, 2001).

### 2.4.1 NSGA-II

O Algoritmo NSGA-II (*Non-dominated Sorting Genetic Algorithm II*) é um MOEA cuja principal característica é o uso de uma métrica chamada de *Crowding Distance*, que mede a proximidade de uma solução em relação às demais.

Na etapa de seleção, a aptidão da solução é primeiramente determinada pela métrica que é chamada de *Non-dominated Sorting*, descrita em (BAKER, 1985). No *Non-dominated Sorting*, as soluções são classificadas pelo que é chamado de *rank*: as soluções não-dominadas iniciais de uma população  $P$  possuem *rank* 1 e são denotadas por  $F_1$ . Um conjunto de soluções de *rank*  $k$ ,  $F_k$ , é obtido a partir das soluções não dominadas do conjunto  $P / \bigcup_{i=1}^{k-1} F_i$ .

Soluções de mesmo *rank* são então escolhidas pela sua *Crowding distance*. A *Crowding distance* é uma métrica que visa medir quão diversa uma solução é, através da sua distância às demais soluções. Para obtê-la, é calculada a diferença normalizada entre os vizinhos da solução para cada um dos objetivos, e as diferenças são agregadas, conforme a seguinte fórmula:

$$crowdingDistance(i) = \sum_f \frac{f(i+1) - f(i-1)}{max_f - min_f}$$

em que  $f$  é a função objetivo,  $i$  é a solução, e  $max_f$  e  $min_f$  são os valores máximo e mínimo do objetivo  $f$ , respectivamente. As soluções com maior e menor valor em cada função objetivo são atribuídas um valor infinito para a *Crowding distance*.

Após a etapa de seleção, as etapas de cruzamento e mutação são realizadas e uma nova seleção é feita. O processo se repete até que se ultrapasse algum limiar de convergência ou um número máximo de iterações seja alcançado. Ao utilizar da *Crowding distance*, o NSGA-II garante uma boa diversidade de soluções, oferecendo ampla variedade de escolha para o tomador de decisão.

## 3 Revisão Bibliográfica

### 3.1 Trabalhos Relacionados

Um dos primeiros trabalhos voltados ao uso de MOEAs para a resolução do problema da dieta multiobjetivo foi (KALDIRIM; KOSE, 2006), que faz uso de avaliações, idade e gênero do usuário para criar uma dieta mais personalizada, que corresponde a diferentes necessidades nutricionais de cada pessoa. Com o uso do NSGA-II para geração de soluções e com um modelo que permite até 3 repetições de um alimento, foi desenvolvido um programa com interface gráfica para interação do usuário.

Em (AMIN; MULLIGAN-GOW; ZHANG, 2019), é proposto um modelo com muitos objetivos que visa minimizar custo, gorduras trans e saturadas, açúcares, e maximizar fibras. Nele, as restrições ajudam a criar uma dieta variada ao limitar o número máximo de um grupo de alimentos em um período de um mês e utilizando métodos escalares para geração de um conjunto de soluções. Além disso, incorpora uma medida de incerteza para pequenas variações no preço ou quantidade de consumo de um alimento, tornando o modelo mais robusto.

Para a geração apenas de cardápios para almoço, (MARRERO et al., 2020) faz uso de um MOEA baseado em decomposição para criar uma dieta balanceada, através de um modelo que tenta maximizar uma métrica agregada de variedade. A abordagem proposta foi capaz de criar cardápios variados com baixo aumento no preço quando comparado a um algoritmo focado em otimizar um só objetivo.

Utilizando do modelo proposto por (MARRERO et al., 2020), em (RAMOS-PÉREZ et al., 2021) são feitos testes comparativos dos MOEAs mais comuns, incluindo um operador de reparo para tornar soluções não-factíveis em soluções factíveis, variando taxa de mutação, taxa de crossover e tamanho da população. Com resultado, foi constatado que o algoritmo NSGA-II foi capaz de obter uma melhor métrica de hipervolume em um planejamento breve de 5-10 dias, enquanto SPEA2 foi o que se mostrou melhor em planejamentos mais longos, de 20-40 dias.

Ainda no âmbito de geração de cardápios para almoços, (MOREIRA et al., 2017) utiliza uma versão do algoritmo NSGA-II com um operador de crossover próprio e utiliza-o para criar cardápios voltados a crianças brasileiras, levando em conta limite de custo e as necessidades nutricionais infantis. Quando comparado ao mesmo modelo utilizando métricas escalares, foi possível gerar um conjunto Pareto com 30 vezes mais soluções, e com uma métrica de hipervolume superior.

Levando em conta as múltiplas camadas de otimização possíveis no problema, (SELJAK, 2006) propõe uma abordagem ao problema em 3 níveis de otimização: global, diário e por refeição. Soluções de nível mais baixo são otimizadas e combinadas em soluções de um nível

superior, que reforçam esse processo a um nível global. Utilizando dessa estratégia, do algoritmo NSGA-II para determinação da fronteira pareto e de dois operadores de reparo, foi possível criar uma dieta com um bom custo e que leva em conta atributos como sazonalidade, cor, temperatura, e consistência.

De forma similar a (SELJAK, 2006), em (POCHMANN; ZUBEN, 2022), os autores aproveitam a natureza do problema da dieta para propor um modelo que é resolvido em dois níveis. Um alto nível, em que residem os múltiplos objetivos, em que é usado o algoritmo NSGA-II para definir a melhor combinação de alimentos para as refeições, e um baixo nível, onde há um problema de otimização linear que define a quantidade em gramas dos alimentos da camada superior com o intuito de maximizar o ganho energético. A partir dessa estratégia, foi possível gerar uma fronteira Pareto que se aproxima da ótima e que possui uma boa dispersão entre as soluções no espaço dos objetivos.

Em relação à elaboração de dietas mais personalizadas, (SUN; WANG, 2024) propõe um modelo voltado a pessoas diabéticas, levando em conta necessidades específicas de cada usuário para a elaboração de uma dieta. Utilizando o NSGA-II, foi possível criar dietas personalizadas para cada usuário que levam em conta o controle do açúcar no sangue, requisitos nutricionais e preferências pessoais.

Para pessoas que precisam emagrecer, (SILVA et al., 2017) propõe um modelo baseado em evolução diferencial que visa manter o consumo diário de calorias perto de 1200 Kcal ao mesmo tempo que tenta maximizar a quantidade de proteínas da dieta, como forma de deixar o usuário saciado. A estratégia faz uso de 17 grupos de alimentos pré-definidos para as refeições, e como resultado foi possível obter dietas que transitam bem entre os dois objetivos, permitindo que nutricionistas escolham opções mais em conta para cada pessoa.

Já em (TÜRKMENOGLU; UYAR; KIRAZ, 2022), utiliza-se de inferência fuzzy para transformar termos vagos do tomador de decisões em uma notação matemática, que por sua vez compõe uma das funções objetivo a serem otimizadas, levando em consideração custo, tempo de preparo e preferência do alimento. Como resultado, as preferências pessoais do tomador de decisão, traduzidas em termos de inferência fuzzy, foram capazes de guiar o modelo, obtendo fronteiras Pareto mais dispersas. Esse trabalho enaltece a importância de se considerar as preferências pessoais do usuário na construção de um modelo.

A partir dos trabalhos citados, é possível perceber que o uso de MOEAs e do NSGA-II se destacam, sendo utilizados em modelos e estratégias bem diferentes entre si. Em relação aos modelos, os principais objetivos abordados foram minimizar custo e maximizar variedade, e alguns modelos optam por utilizar refeições ou pratos pré-definidos.

## 4 Desenvolvimento

### 4.1 Conjunto de Dados

Para o conjunto de dados de alimentos, foi utilizado os dados da tabela TACO (CAMPI-NAS, 2011), que dispõe informações nutricionais de 597 alimentos separados em 14 categorias por porção de 100 gramas. Alimentos com quantidade traço de algum componente (descrita como "Tr") ou cujo componente não se aplica (descrito como "NA") tiveram seus respectivos valores para tal componente zerados. Alimentos com componentes que estão sendo reavaliados (marcados com \*) foram removidos. A Tabela 4.1 dispõe das categorias e a quantidade de alimentos presentes em cada uma delas.

Tabela 4.1 – Tabela de Categorias de Alimentos

Categoria	Quantidade de Alimentos
Cereais	63
Verduras	99
Frutas	96
Gorduras	14
Frutos do Mar	50
Carnes	123
Leite	24
Bebidas	14
Ovos	7
Açucarados	20
Miscelânea	9
Industrializados	5
Preparados	32
Leguminosas	30
Nozes	11

Como o conjunto de dados não possui dados referentes ao custo monetário das porções dos alimentos, foram atribuídos custos aleatórios entre R\$1.00 e R\$10.00 para cada um dos alimentos listados.

### 4.2 Definição do modelo

Foram definidas três funções objetivos para o problema: Minimizar custo, minimizar penalidades de repetição e maximizar as proteínas de uma dieta de sete dias. Considerando  $A$  como o conjunto de alimentos,  $c_i$  como o custo do alimento  $i$  e  $x_{ij}$  a quantidade de porções do alimento  $i$  no dia  $j$ , a primeira função objetivo, minimizar custos, é descrita como:

$$f_1 = \sum_{j=1}^7 \sum_i c_i x_{ij}, \quad i \in A \quad (3)$$

Para a segunda função objetivo, foi utilizada a definição de grau de repetitividade descrita por (RAMOS-PÉREZ et al., 2021). No artigo, são feitas 3 refeições por dia por 5 dias, e são aplicadas penalidades sobre a repetição de refeições, a repetição de categorias de alimentos em refeições do mesmo dia e a repetição de categorias de alimentos em dias diferentes. Nesse trabalho, os dias não são separados em refeições e, portanto, a função objetiva foi adequada de forma a incluir somente a última penalidade, a de repetição de categorias de alimentos em dias diferentes. A tabela 4.2 descreve as penalidades e seus valores foram os mesmos utilizados no artigo, com exceção de categorias não presentes no conjunto de dados, que foram omitidas, e a adição de uma nova penalidade para a repetição com seis dias. Categorias de alimentos presentes no conjunto de dados e não presentes na tabela estão incluídas na categoria "Outros".

Tabela 4.2 – Tabela de penalidades

Penalidade	Descrição	Valor
$p_1$	Penalidade por repetir a categoria Outros	0.1
$p_2$	Penalidade por repetir a categoria Carnes	3
$p_3$	Penalidade por repetir a categoria Cereais	0.3
$p_4$	Penalidade por repetir a categoria Frutas	0.1
$p_5$	Penalidade por repetir a categoria Leites	0.3
$p_6$	Penalidade por repetir a categoria Leguminosas	0.3
$p_7$	Penalidade por repetir a categoria Peixes	0.5
$p_8$	Penalidade por repetir a categoria Vegetais	0.1
$p_9$	Penalidade por repetir a mesma categoria um dia antes	3
$p_{10}$	Penalidade por repetir a mesma categoria dois dias antes	2.5
$p_{11}$	Penalidade por repetir a mesma categoria três dias antes	1.8
$p_{12}$	Penalidade por repetir a mesma categoria quatro dias antes	1
$p_{13}$	Penalidade por repetir a mesma categoria cinco dias antes	0.2
$p_{14}$	Penalidade por repetir a mesma categoria seis dias antes	0.1

O valor  $v_{FG_j}$  é dado pela Equação 4, onde dado um dia  $j$ ,  $y_{g_d} = 1$  significa que a categoria  $g$  foi repetida no dia  $j - d$ , e  $y_{g_d} = 0$  significa que não foi.  $z_d = 1$  significa que alguma categoria foi repetida  $d$  dias antes de  $j$ , e  $z_d = 0$  significa que nenhuma categoria foi repetida  $d$  dias antes de  $j$ .  $|G|$  diz respeito à quantidade de categorias e  $p_{|G|+d}$  e  $p_g$  diz respeito aos valores das penalidades presentes na Tabela 4.2.

$$v_{FG_j} = \sum_{d=1}^{j-1} \left( \sum_{g=1}^{|G|} y_{g_d} \cdot p_g \right) + (z_d \cdot p_{|G|+d}) \quad (4)$$

Dessa maneira, a segunda função objetivo, cujo objetivo é aumentar a variedade da dieta através da minimização das penalidades de repetição, é dada pela equação 5.

$$f_2 = \sum_{j=1}^7 v_{FG_j} \quad (5)$$

Finalmente, a terceira função objetivo, que é maximizar a quantidade de proteína da dieta, é dada pela equação 6, onde  $u_i$  é a quantidade de proteína fornecida pelo alimento  $c$ .

$$f_3 = \sum_{j=1}^7 \sum_i u_i x_{ij}, \quad i \in A \quad (6)$$

Como restrições do problema foram definidos valores mínimos para cada um dos elementos, a partir da tabela de Valores Diários Recomendados (VDR) fornecidos pela Anvisa ([Agência Nacional de Vigilância Sanitária \(ANVISA\), 2020](#)). Para a satisfação das restrições, cada um dos componentes em cada um dos sete dias deve ter um valor igual ou maior que o da tabela VDR. Dessa forma, o modelo completo do problema é descrito como:

$$\min F(x) = [f_1(x), f_2(x)], \quad (7)$$

$$\max f_3(x), \quad (8)$$

Sujeito a:

$$\sum_i n_{ik} x_{ij} \geq R_k, \quad i \in A, k \in N, \forall j \in \{1, 2, \dots, 7\} \quad (9)$$

$$x_{ij} \geq 0 \quad (10)$$

onde  $A$  é o conjunto de alimentos,  $N$  é o conjunto de elementos da dieta,  $n_{ij}$  é a quantidade do elemento  $k$  presente no alimento  $i$ ,  $x_{ij}$  é a quantidade de porções do alimento  $i$  no dia  $j$ , e  $R_k$  a quantidade recomendada do elemento  $k$ . Por fim, a equação 10 descreve a não negatividade das soluções.

### 4.3 Medida de Uniformidade no Espaço de Decisão

Baseado na medida de uniformidade ponderada pela dominância ( $w_d$  proposta por [MOREIRA; PAQUETE, 2019](#)) e utilizada na etapa de seleção de um algoritmo genético, foi criada uma nova medida,  $w_{dh}$ , que calcula a diferença entre duas soluções baseada na distância de Hamming ([HAMMING, 1950](#)) delas. Um vetor binário de  $n$  elementos é atribuído a cada dieta, cujos elementos representam a presença de um dado alimento na dieta, e utilizando-se desse vetor, a distância de Hamming entre duas dietas é calculada por

$$d_h(x_h, x'_h) = \sum_{i=1}^n |x_{hi} - x'_{hi}| \quad (11)$$

em que  $x_h, x'_h$  são os vetores binários das dietas  $x, x'$ , respectivamente, pertencentes a um conjunto de dietas  $D$ , e  $n$  é o número de alimentos no conjunto de dados. Utilizando-se dessa definição, a medida de uniformidade  $w_{dh}$  é definida por

$$w_{dh}(x, x') = \frac{d_h(x_h, x'_h)}{|d(x) - d(x')| + 1} \quad (12)$$

Além disso, para medir a uniformidade dos algoritmos, serão utilizadas duas medidas baseadas na distância de Hamming no espaço de decisão. Essas medidas são

$$d_{hmin} = \min(d_h(x_h, x'_h)), \forall x, x' \in D, x \neq x' \quad (13)$$

$$d_{hmed} = \frac{\sum_{x' \in D} \sum_{x \in D} d_h(x_h, x'_h)}{|D|^2} \quad (14)$$

A métrica da equação 13 descreve a menor distância entre quaisquer par de dietas na fronteira Pareto, e a equação 14 descreve a média aritmética de todas as distâncias entre as dietas.

## 4.4 Penalidade

Algumas soluções geradas para o modelo podem não satisfazer as restrições nutricionais do problema. Para resolver isso, na realização dos torneios binários no algoritmo genético, soluções factíveis sempre vão ter preferência sobre soluções infactíveis. Caso ambas as soluções comparadas sejam infactíveis, a solução que tiver a menor penalidade será escolhida. Essa penalidade,  $pen$  é a soma das diferenças entre o VDR e o total da dieta para cada dia e elemento, e é dada por:

$$pen = \sum_j^7 \sum_i^{|N|} (R_i - V_{ij}), \forall V_{ij} < R_i$$

onde  $N$  é o conjunto de elementos,  $R_i$  é o valor mínimo recomendado para o elemento  $i$ , e  $V_{ij}$  é a quantidade total do elemento  $i$  no dia  $j$ .

## 4.5 Algoritmo Genético

Assim como descrito em (MOREIRA; PAQUETE, 2019), a métrica  $w_{dh}$  pode ser utilizada em um algoritmo MinMax para realizar a seleção de um algoritmo genético, como demonstrado em 4.1

**Algoritmo 4.1:** Heurística WDH

---

**Entrada:** População  $P$ , escalar  $k$   
**Saída:**  $R$

```

1 início
2   Seja  $N_P$  o conjunto de dietas não dominadas de  $P$ ;
3   Seja  $x_i, x_j$  as dietas em  $N_P$  com  $w_{dh}(x_i, x_j)$  máximo;
4    $R \leftarrow x_i, x_j$ ;
5   enquanto ( $|R| < k$ ) faça
6     Encontrar  $x' \in \{P - R\}$  tal que  $\min_{r \in R} w_{dh}(x', r)$  é máximo;
7      $R \leftarrow R \cup \{x'\}$ ;
8   fim
9   Retorne  $R$ ;
10 fim

```

---

Uma dieta é representada por uma matriz de 580 linhas e 7 colunas, que correspondem à quantidade de alimentos no conjunto de dados e à quantidade de dias da dieta, respectivamente. Um elemento  $x_{ij}$  nessa matriz corresponde a quantas porções de 100g do alimento  $i$  fazem parte da dieta no dia  $j$ . Usando dessa representação, o algoritmo genético para se chegar a uma aproximação da fronteira Pareto após  $max$  gerações é descrito pelos seguintes passos:

- Criar uma população inicial  $P_0$  de  $k$  indivíduos gerados aleatoriamente, cada um representando uma dieta. Cada indivíduo então é sujeito ao operador de reparo para satisfação das restrições.
- Inicializar  $t \leftarrow 0$
- Enquanto  $t \leq max$ :
  1. Calcular a aptidão de cada indivíduo da população  $P_t$  utilizando a métrica de *Non-Dominated Sorting* do NSGA-II
  2. Realizar  $k$  torneios binários aleatórios entre os indivíduos de  $P_t$  e definir  $k/2$  pares de indivíduos para a etapa de Crossover.
  3. Para cada par de indivíduos selecionado, realizar o Crossover Multiponto por colunas dos indivíduos e gerar um novo par de indivíduos.
  4. Aplicar um operador de mutação de troca de bit sobre os  $k$  indivíduos gerados, gerando uma população  $Q_t$
  5. Executar a heurística WDH com escalar  $k$  sobre a população  $P_t \cup Q_t$  para se obter a população  $P_{t+1}$
  6.  $t \leftarrow t + 1$
- Aplicar o operador de reparo sobre os indivíduos da população final  $P_{max}$
- Retornar as soluções não dominadas da população final  $P_{max}$

## 4.6 Experimentação Prática

Nessa seção, foram feitos experimentos comparativos entre o método proposto utilizando a heurística WDH e o método NSGA-II. A performance no espaço dos objetivos foi medida em termos de Hipervolume, descrita em (ZITZLER; THIELE, 1999), e a uniformidade no espaço de decisão foi medida utilizando as métricas  $d_{hmin}$  e  $d_{hmed}$ . O ponto de referência para o cálculo do hipervolume é baseado no maior valor obtido para cada função objetivo em um dos algoritmos, e esse valor é utilizado para normalizar os resultados antes do cálculo do hipervolume.

Os experimentos foram realizados em um computador com processador Ryzen 5 2600, 16GB de memória RAM DDR4 3000MHz, usando o sistema operacional Windows 11.

Os parâmetros para os algoritmos genéticos foram:

- População inicial de tamanho 30.
- Os valores da quantidade de cada alimento em cada dia são inicializados aleatoriamente de forma ponderada, com 94% de chance de valor 0, 4% de chance de valor 1 e 1% de chance de valor 2.
- Número máximo de gerações de tamanho = 30, 100, 300.
- Crossover Multiponto por coluna com 20 pontos.
- Mutação de virada de bit com chance de 5% caso o valor seja 1 e 0.16% para caso o valor seja 0.

Para cada número máximo de gerações, cada abordagem foi executada 30 vezes e foi feita a média dos resultados obtidos.

## 5 Resultados

Os resultados dos experimentos são descritos na tabela 5. A princípio, com 30 gerações, com o algoritmo proposto (WDH), a menor diferença entre dois pares de dietas foi uma distância de cerca de 100 elementos; em contrapartida, para o NSGA-II, esse número é apenas cerca de 39. A média da distância entre os pares da abordagem proposta também é maior, ressaltando que ela é capaz de gerar dietas mais distintas entre si sem muita diferença na área coberta pelos pontos, uma vez que o hipervolume é semelhante.

Tabela 5.1 – Tabela de comparações entre os algoritmos WDH e NSGA-II

	WDH			NSGA-II		
	Hipervolume	$d_{hmin}$	$d_{hmed}$	Hipervolume	$d_{hmin}$	$d_{hmed}$
30 Gerações	0.397	99.56	187.61	0.411	38.93	160.33
100 Gerações	0.417	92.10	160.81	0.394	35.46	122.72
300 Gerações	0.412	91.76	155.28	0.404	36.10	108.55

Para 100 e 300 gerações, as discrepâncias se mantêm, com uma leve diminuição na distância média em decorrência da convergência do algoritmo. A figura 5 mostra o resultado da fronteira Pareto de uma instância da abordagem WDH e uma instância da abordagem NSGA-II após 100 iterações. É possível perceber uma falta de soluções com pouca penalidade, mas alto custo, uma vez que o custo da dieta está atrelado à quantidade de alimentos, e com mais alimentos de diferentes categorias, mais penalidades são aplicadas.

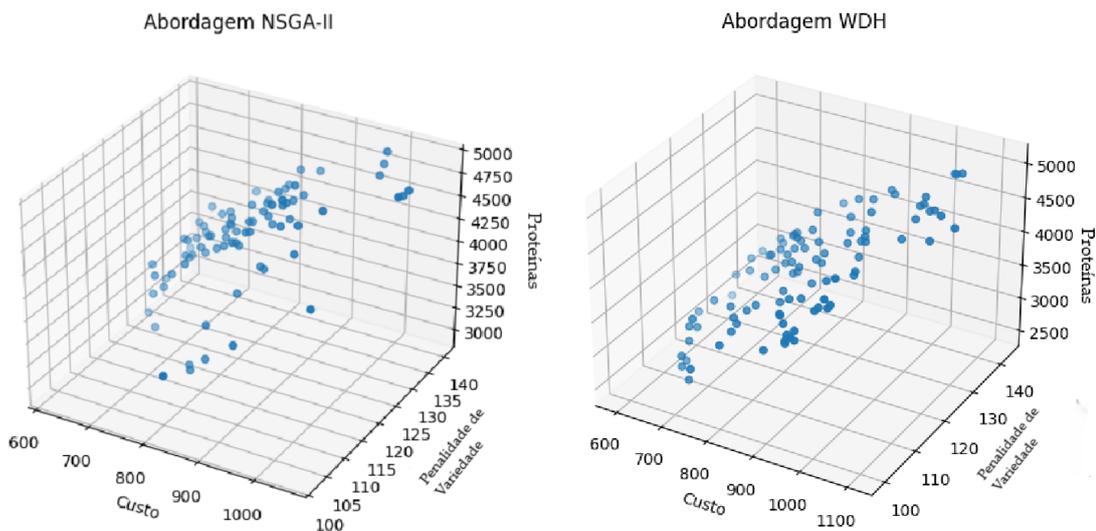


Figura 5.1 – Fronteira Pareto do exemplo de uma execução das duas abordagens; NSGA-II à esquerda e WDH à direita

Para comparar o desempenho das abordagens, foi feita uma simulação de Monte Carlo,

usando os resultados das médias de 30 instâncias de cada abordagem como amostras. Assim, a hipótese nula e a hipótese alternativa são descritas como:

$$\begin{cases} H_0 : \text{Não existe evidência que uma abordagem é melhor que a outra} \\ H_1 : \text{Existe evidência que uma abordagem é melhor que a outra} \end{cases}$$

Caso as amostras sejam significativamente diferentes, a diferença entre as amostras será um ponto incomum em uma distribuição de resultados separados aleatoriamente. Para realizar esse teste, foram feitos os seguintes passos:

1. Calcular a média da diferença entre os valores das amostras, o que será chamado de resultado observado.
2. Realocar metade do total de amostras para uma abordagem e metade para a outra, calcular novamente a média das diferenças.
3. Repetir o passo anterior 5000 vezes e criar a distribuição dos valores calculados.
4. Se o resultado observado não for mais extremo que a fração da distribuição que representa 0.01 de significância, considerar a hipótese nula. Caso contrário, rejeitá-la.

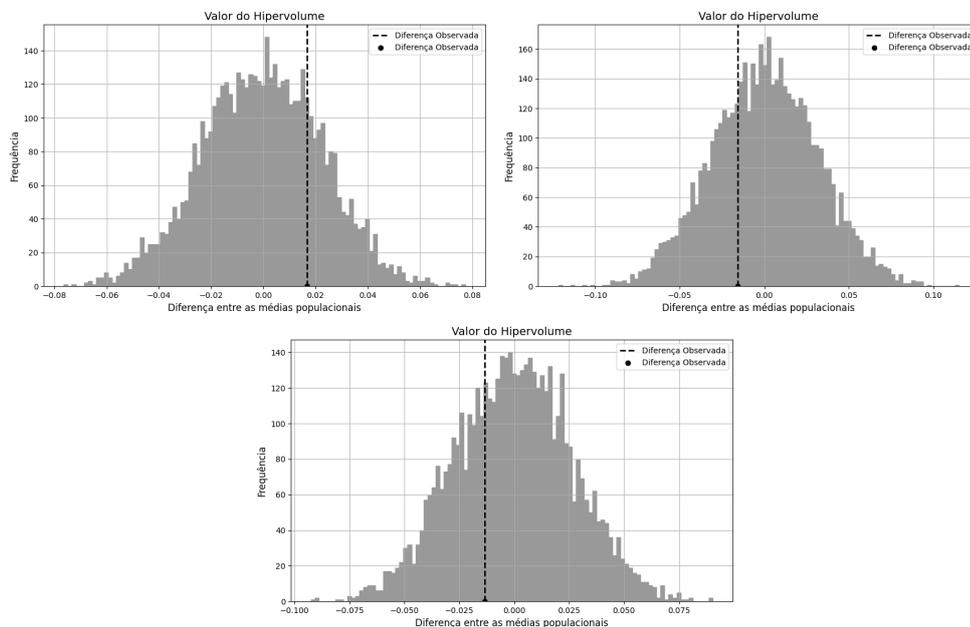


Figura 5.2 – Histogramas das simulações de Monte-Carlo para a medida de HyperVolume, com 30, 100 e 300 gerações

A partir das distribuições, foram criados histogramas, denotados em cinza em 5.2, 5.3 e 5.4. O resultado observado é representado por um ponto escuro e uma linha tracejada. Para a medida de hipervolume, nos resultados observados de 30, 100 e 300 gerações, a hipótese nula

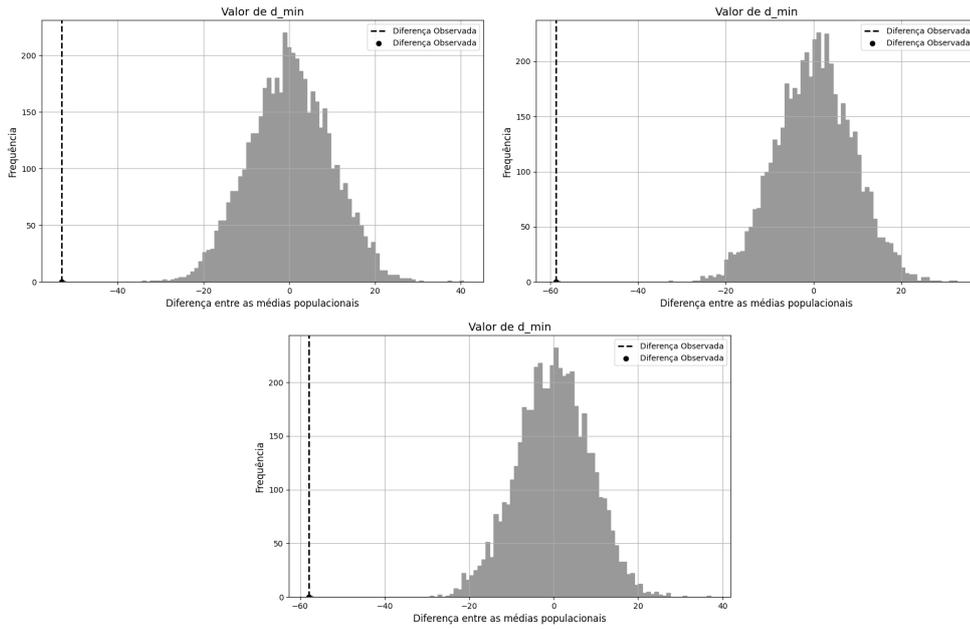


Figura 5.3 – Histogramas das simulações de Monte-Carlo para a medida de  $d_{min}$ , com 30, 100 e 300 gerações

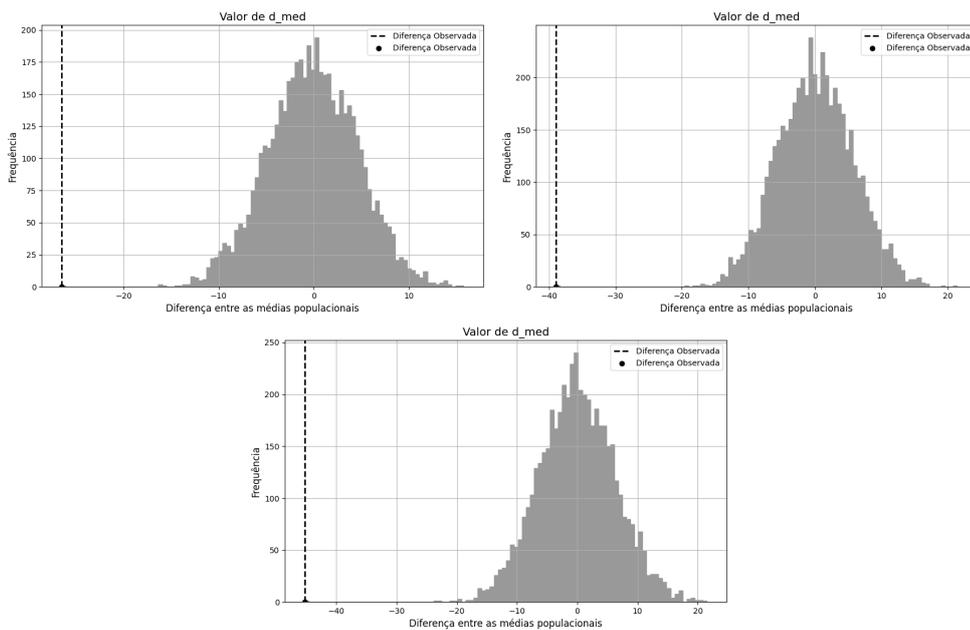


Figura 5.4 – Histogramas das simulações de Monte-Carlo para a medida de  $d_{med}$ , com 30, 100 e 300 gerações

não é rejeitada. Já para as métricas de  $d_{min}$  e  $d_{med}$ , em 30, 100 e 300 gerações, a hipótese nula é rejeitada, e a abordagem WDH é favorecida.

## 6 Considerações Finais

### 6.1 Conclusão

A partir do que foi desenvolvido, foi possível propor um modelo para o problema da dieta que minimize custo, maximize proteína e maximize a variedade através da minimização de penalidades por repetição. Desse modelo, foi utilizada uma medida de uniformidade no processo de seleção de um algoritmo evolutivo para gerar soluções que aproximam a fronteira Pareto real do problema, são mais bem distribuídas no espaço de decisão que o NSGA-II e que não têm perdas mensuráveis na medida de Hipervolume.

Com isso, a abordagem permite que tomadores de decisão tenham mais liberdade na escolha das dietas, podendo aderir melhor a preferências pessoais e mantendo uma boa eficiência da dieta através de um conjunto de soluções mais variado. Além disso, a abordagem pode ser utilizada dentro do contexto de outros problemas multiobjetivo que simulam um problema da mochila multidimensional, como um problema de agendamento de salas ou vôos, ou até mesmo integrado em problemas com variáveis não discretas.

### 6.2 Trabalhos Futuros

Como trabalhos futuros, é possível explorar a abordagem em um conjunto de dados mais completo, com mais alimentos, informações de preço ou menos dados faltantes. Pode-se avaliar a abordagem sobre outros objetivos, como minimizar sódio, gorduras saturadas ou maximizar fibras, em outros problemas multiobjetivo parecidos, como problemas de agendamento, ou avaliar sua eficácia em problemas com menos variáveis.

# Referências

Agência Nacional de Vigilância Sanitária (ANVISA). *Instrução Normativa nº 75, de 8 de outubro de 2020*. 2020. Diário Oficial da União. Dispõe sobre os procedimentos para regularização de produtos.

AMIN, S. H.; MULLIGAN-GOW, S.; ZHANG, G. Selection of food items for diet problem using a multi-objective approach under uncertainty. In: MÁRQUEZ, F. P. G. (Ed.). *Application of Decision Science in Business and Management*. Rijeka: IntechOpen, 2019. cap. 11. Disponível em: <<https://doi.org/10.5772/intechopen.88691>>.

BAKER, J. E. Adaptive selection methods for genetic algorithms. In: *Proceedings of the 1st International Conference on Genetic Algorithms*. USA: L. Erlbaum Associates Inc., 1985. p. 101–111. ISBN 0805804269.

CAMPINAS, N. d. E. e. P. e. A. Universidade Estadual de. *Tabela Brasileira de Composição de Alimentos (TACO)*. Campinas, Brasil, 2011. Versão 4.0.

CARVALHO, M. de. *Construindo o saber: técnicas de metodologia científica*. [S.l.]: Papirus Editora, 1989. ISBN 9788530800710.

DEB, K.; PRATAP, A.; AGARWAL, S.; MEYARIVAN, T. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE Transactions on Evolutionary Computation*, v. 6, n. 2, p. 182–197, 2002.

DUARTE, P.; TEIXEIRA, M.; SILVA, S. Healthy eating as a trend: Consumers' perceptions towards products with nutrition and health claims. *Review of Business Management*, v. 23, p. 405–421, 09 2021.

EHRGOTT, M. *Multicriteria Optimization*. Berlin, Heidelberg: Springer-Verlag, 2005. ISBN 3540213988.

GlobalData. *Consumer Attitudes towards Health and Wellness*. 2020. Disponível em: <<https://www.globaldata.com/store/report/consumer-attitudes-health-wellness-trend-analysis/>>.

HAMMING, R. W. Error detecting and error correcting codes. *Bell System Technical Journal*, Wiley Online Library, v. 29, n. 2, p. 147–160, 1950.

HOBBS, T. *Leviatã*. [S.l.]: Oxford University Press, 1651. “O homem é lobo do homem.”.

HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. Ann Arbor, MI: University of Michigan Press, 1975. ISBN 9780262581110.

International Food Information Council Foundation. *2023 Food & Health Survey*. 2023. Disponível em: <<https://foodinsight.org/2023-food-and-health-survey/>>.

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.

- LIU, X.; IJZERMAN, A. P.; WESTEN, G. J. P. van. Computational approaches for de novo drug design: Past, present, and future. In: \_\_\_\_\_. *Artificial Neural Networks*. New York, NY: Springer US, 2021. p. 139–165. ISBN 978-1-0716-0826-5. Disponível em: <[https://doi.org/10.1007/978-1-0716-0826-5\\_6](https://doi.org/10.1007/978-1-0716-0826-5_6)>.
- MARRERO, A.; SEGREDO, E.; LEON, C.; SEGURA, C. A memetic decomposition-based multi-objective evolutionary algorithm applied to a constrained menu planning problem. *Mathematics*, v. 8, p. 1960, 11 2020.
- MOREIRA, G.; PAQUETE, L. Guiding under uniformity measure in the decision space. In: *2019 IEEE Latin American Conference on Computational Intelligence (LA-CCI)*. [S.l.: s.n.], 2019. p. 1–6.
- MOREIRA, R. P. C.; WANNER, E. F.; MARTINS, F. V. C.; SARUBBI, J. F. M. The menu planning problem: a multiobjective approach for brazilian schools context. *Proceedings of the Genetic and Evolutionary Computation Conference Companion*, 2017. Disponível em: <<https://api.semanticscholar.org/CorpusID:22147468>>.
- POCHMANN, V. O.; ZUBEN, F. J. V. Multi-objective bilevel recommender system for food diets. In: *2022 IEEE Congress on Evolutionary Computation (CEC)*. [S.l.: s.n.], 2022. p. 1–8.
- RAMOS-PÉREZ, J.-M.; MIRANDA, G.; SEGREDO, E.; LEÓN, C.; RODRÍGUEZ-LEÓN, C. Application of multi-objective evolutionary algorithms for planning healthy and balanced school lunches. *Mathematics*, v. 9, n. 1, 2021. ISSN 2227-7390. Disponível em: <<https://www.mdpi.com/2227-7390/9/1/80>>.
- RAMPAZZO, L. *Metodologia científica*. [S.l.]: Edições Loyola, 2005. ISBN 9788515024988.
- SCHAFFER, J. D. Multiple objective optimization with vector evaluated genetic algorithms. In: *Proceedings of the 1st International Conference on Genetic Algorithms*. USA: L. Erlbaum Associates Inc., 1985. p. 93–100. ISBN 0805804269.
- SELJAK, B. Dietary menu planning using an evolutionary method. In: *2006 International Conference on Intelligent Engineering Systems*. [S.l.: s.n.], 2006. p. 108–113.
- SILVA, J. G. R.; BERNARDINO, H. S.; BARBOSA, H. J. C.; CARVALHO, I. A. de; VIEIRA, V. da F.; LOUREIRO, M. M. S.; XAVIER, C. R. Solving a multiobjective caloric-restricted diet problem using differential evolution. In: *2017 IEEE Congress on Evolutionary Computation (CEC)*. [S.l.: s.n.], 2017. p. 2062–2069.
- STIGLER, G. J. The cost of subsistence. *Journal of Farm Economics*, [Oxford University Press, Agricultural & Applied Economics Association], v. 27, n. 2, p. 303–314, 1945. ISSN 10711031. Disponível em: <<http://www.jstor.org/stable/1231810>>.
- SUN, J.; WANG, G. The application of multi-objective optimization algorithm in diabetic nutrition meal planning. *Journal of Intelligence and Knowledge Engineering*, v. 2, p. 156–None, 03 2024.
- TÜRKMENOĞLU, C.; UYAR, A. Şima; KIRAZ, B. Fuzzy inference based a posterior decision-making for multi-objective diet optimization problem. *European Journal of Science and Technology*, 2022. Disponível em: <<https://api.semanticscholar.org/CorpusID:255116355>>.

ZITZLER, E.; LAUMANN, M.; THIELE, L. SPEA2: Improving the strength pareto evolutionary algorithm. In: *Evolutionary Methods for Design, Optimisation and Control with Applications to Industrial Problems (EUROGEN 2001)*. Athens, Greece: International Center for Numerical Methods in Engineering (CIMNE), 2001. p. 95–100.

ZITZLER, E.; THIELE, L. Multiobjective evolutionary algorithms: a comparative case study and the strength pareto approach. *IEEE Transactions on Evolutionary Computation*, v. 3, n. 4, p. 257–271, 1999.