



# OTIMIZAÇÃO MULTIOBJETIVO: TEORIA E APLICAÇÕES

**Palavras-chave:** Otimização multiobjetivo, Soma ponderada ,  $\varepsilon$ -restrito

Matheus Queiroz Mota, IMECC - UNICAMP  
Kelly Cristina Poldi, IMECC - UNICAMP

---

## Introdução:

A otimização multiobjetivo envolve a otimização simultânea de várias funções, sujeitas a um conjunto de restrições formadas por equações e/ou inequações matemáticas. Devido aos conflitos entre essas funções (ou seja, otimizar uma função pode prejudicar o desempenho das outras), a solução "ótima" depende de qual objetivo é priorizado, pois, na maior parte das vezes, a solução que otimiza uma função específica não otimiza as demais. Portanto, existe um conjunto de soluções conhecido como soluções de Pareto [2].

Deste modo, o presente projeto visa estudar os conceitos de otimização multiobjetivo e alguns métodos exatos para obtenção de soluções para problemas de otimização multiobjetivo, implementando computacionalmente os métodos estudados; que são: o método da Soma Ponderada e o método  $\varepsilon$ -restrito. Para suas respectivas implementações foi utilizada a biblioteca PuLP, do Python [6]. Além disso, testamos essas implementações em aplicações específicas, como o Problema da Dieta, onde o objetivo é minimizar o custo e maximizar a proteína, e o Problema da Produção, onde buscamos maximizar o lucro e minimizar a emissão de CO<sub>2</sub>. Tais modelagens e soluções irão constar no relatório final.

## Metodologia:

**Problema de Otimização Multiobjetivo:** De maneira geral, um Problema de Otimização Multiobjetivo (POM) é caracterizado por possuir mais de uma função objetivo, digamos  $p$  funções ( $p > 1$ ) que devem ser maximizadas, sujeitas a um conjunto de restrições matemáticas  $\mathcal{X} \subseteq \mathbb{R}^n$ :  $\mathcal{X} \neq \emptyset$ . Assim, o problema pode ser formulado da seguinte forma:

$$\begin{aligned} \max \quad & \mathbf{z} = (f_1(\mathbf{x}), \dots, f_p(\mathbf{x})) \\ \text{sujeito a} \quad & x \in \mathcal{X} \end{aligned}$$

---

em que:

- $x = (x_1, x_2, \dots, x_n)^T \in \mathbb{R}^n$  é vetor das variáveis de decisão;
- $z_i = f_i(\mathbf{x})$  é a  $i$ -ésima função objetivo a ser maximizada,  $i = 1, \dots, p$ .

Assim, um Problema de Otimização Multiobjetivo (POM) busca otimizar (maximizar e/ou minimizar) várias funções objetivas dentro de determinadas restrições. Isso implica que não há uma solução única e perfeita, mas um conjunto de soluções ótimas chamadas soluções de Pareto [1]. Conseqüentemente, utilizamos métodos específicos para abordar problemas multiobjetivos. Os principais métodos explorados são a Soma Ponderada e o método  $\varepsilon$ -restrito, ambos denominados métodos de escalarização.

**Método da Soma Ponderada:** Esse método consiste em transformar um problema multi-objetivo em um problema mono-objetivo, através da formulação de uma função objetivo que é a soma ponderada das  $p$  funções originais. Para cada função  $f_k$ , é atribuído um peso  $\lambda_k \geq 0$ , de modo que, para ao menos um  $i$ , tenhamos  $\lambda_i > 0$ . Sendo assim, a formulação do problema pode ser descrita da seguinte forma:

$$\begin{aligned} \max z &= \sum_{k=1}^p \lambda_k f_k(x) \\ \text{s.a } &\left\{ x \in \mathcal{X} \right. \end{aligned} \quad (1)$$

**Método do  $\varepsilon$ -restrito:** em um POM com  $p$  funções objetivas  $(f_1(x), f_2(x), \dots, f_p(x))$ , selecionamos uma dessas funções (digamos  $f_i(x)$ ) para otimização. As outras funções,  $f_j(x)$  com  $(j \neq i)$ , são consideradas restrições no novo problema mono-objetivo, onde para cada  $j$ , tem-se  $f_j(x) \geq \varepsilon_j$ , de modo que cada  $\varepsilon_j$  é determinado pelo tomador de decisões do problema. Deste modo, tal problema pode ser modelado como:

$$\begin{aligned} \max & f_i(x) \\ \text{s.a } &\left\{ \begin{array}{l} x \in X \\ f_k(x) \geq \varepsilon_k, \quad k = 1, \dots, i-1, i+1, \dots, p \end{array} \right. \end{aligned} \quad (2)$$

Vale ressaltar que ambos os métodos retornam soluções fracamente eficientes, e, sob certas condições, podem retornar soluções eficientes do problema original. Para mais detalhes, consulte as referências [3] e [4].

**Implementação Computacional:** Durante a pesquisa, desenvolvemos seis algoritmos computacionais. Estes incluem os algoritmos para o método da soma ponderada e o  $\varepsilon$ -restrito, além de duas variantes desses métodos que permitem ajustar e variar os parâmetros. Adicionalmente,

---

criamos dois algoritmos, um para cada método exato, que suportam a leitura de arquivos .csv, facilitando a aplicação em problemas de grande escala.

Para a implementação, utilizamos a biblioteca PuLP [6], que nos ajudou a modelar os métodos e utilizar um solver para obter soluções factíveis. Além disso, utilizamos a biblioteca pandas [5] para ler os dados dos arquivos .csv. Todos os códigos estão disponíveis no (**GitHub**).

**Página Web:** Visando divulgar a parte teórica de forma mais leve e dinâmica, fizemos, por meio da biblioteca *streamlit* [7] do Python, uma página web que contém explicações sintetizadas dos principais conceitos da otimização multiobjetivo, os métodos exatos, bem como figuras e gráficos interativos. Para acessar página web, (**Clique Aqui**), caso a página esteja inativa, basta clicar na opção "Yes, get this app back up!".

## Aplicações

Vamos apresentar neste texto um exemplo prático da otimização multiobjetivo, escolhemos um exemplo de problema de transporte, que é apenas um dos vários casos que exploramos durante a Iniciação Científica. Outros exemplos, que abordam temas como dieta, produção e outros aspectos relevantes, são reportados no relatório final.

Considere dois armazéns (Armazéns 1 e 2) responsáveis por armazenar produtos alimentícios destinados a três mercados (Mercados A, B e C) de uma determinada empresa. Um dos objetivos da empresa é minimizar os custos de transporte de itens dos armazéns até os mercados. No entanto, visando emitir a quantidade mínima de CO<sub>2</sub> por toda sua frota, a empresa estimou a produção de CO<sub>2</sub>, em média por valor unitário de produto transportado, de cada armazém para cada mercado.

### Variáveis de decisão:

$x_{mn}$  : quantidade de mercadorias transportadas do Armazém  $m$  para o Mercado  $n$ .

**Funções-objetivo:** neste problema, a função custo é representada por  $z_1(x)$  e a função que representa a quantidade de CO<sub>2</sub> é  $z_2(x)$ . Os coeficientes correspondentes são dados por:

$$\min z_1(x) = 2x_{1A} + 4x_{1B} + 5x_{1C} + 3x_{2A} + 1x_{2B} + 2x_{2C} \quad (\text{Custo de transporte em R\$})$$

$$\min z_2(x) = 9x_{1A} + 4x_{1B} + x_{1C} + 2x_{2A} + 5x_{2B} + 8x_{2C} \quad (\text{Emissão de CO}_2)$$

## Restrições:

- Capacidade de armazenamento: cada armazém possui uma capacidade máxima de produtos que podem ser estocados, ou seja, a quantidade de mercadorias que vai do armazém para todas as cidades não deve exceder a capacidade do armazém. Os respectivos valores de capacidade são dados a seguir:

$$x_{1A} + x_{1B} + x_{1C} \leq 100 \quad (\text{Capacidade do Armazém 1})$$

$$x_{2A} + x_{2B} + x_{2C} \leq 150 \quad (\text{Capacidade do Armazém 2})$$

- Demanda: cada mercado possui uma demanda mínima de produtos que deve ser respeitada, ou seja, a produção de cada armazém para a cidade deve ser maior ou igual a essa demanda mínima. Vale ressaltar que, nas restrições de demanda, estamos trabalhando com desigualdades do tipo " $\geq$ ", pois restrições do tipo " $=$ " podem ocasionar infactibilidade. As restrições são dadas a seguir:

$$x_{1A} + x_{2A} \geq 80 \quad (\text{Demanda do Mercado A})$$

$$x_{1B} + x_{2B} \geq 70 \quad (\text{Demanda do Mercado B})$$

$$x_{1C} + x_{2C} \geq 100 \quad (\text{Demanda do Mercado C})$$

**Solução:** Por meio dos algoritmos desenvolvidos e disponíveis para consulta no (**GitHub**), obtivemos a curva apresentada na Figura [1] representando o conflito das duas funções objetivos:

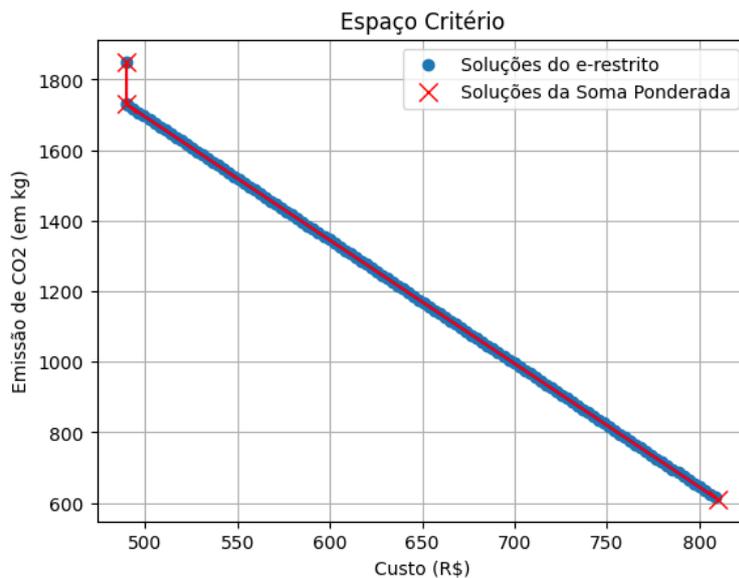


Figura 1: Gráfico da fronteira de Pareto do exemplo do transporte, para os métodos exatos.

---

Pode-se notar, na Figura [1], que ao diminuir o custo de transporte, aumentamos a quantidade de CO2 emitida.

## Conclusão:

Em conclusão, este trabalho abordou tanto os aspectos teóricos quanto práticos da Otimização Multiobjetivo, explorando desde os fundamentos conceituais até a implementação computacional de métodos exatos.

Espera-se que as ferramentas desenvolvidas nesta pesquisa, incluindo os códigos, e a página web, possam não apenas auxiliar aqueles que estudam a área de otimização multiobjetivo, mas também despertar o interesse daqueles que desejam aprofundar-se neste campo da matemática.

## Agradecimento

Os autores agradecem o apoio financeiro PIBIC/CNPq UNICAMP, cota 2023-2024.

## Referências

- [1] C. H. Antunes, M. J. Alves e J. N. Clímaco. *Multiobjective linear and integer programming*. Switzerland: Springer, 2016.
- [2] V. Chankong e Y. Y. Haimes. *Multiobjective decision making: Theory and methodology*. New York: Elsevier Science Publishing Co, 1983.
- [3] K. Deb. *Multiobjective optimization using evolutionary algorithms*. John Wiley & Sons, 2005.
- [4] M. Ehrgott. *Multicriteria optimization*. Lecture Notes in Economics and Mathematical Systems. Springer-Verlag, 2005.
- [5] *Pandas Documentation*. URL: <https://pandas.pydata.org/pandas-docs/stable/> (acesso em 22/07/2024).
- [6] Python Optimization Tools (PyOpt). *PuLP: LP Modelling in Python*. URL: <https://github.com/coin-or/pulp> (acesso em 19/07/2024).
- [7] *Streamlit Documentation*. URL: <https://docs.streamlit.io/library/api-reference> (acesso em 19/07/2024).