



## UM ESTUDO COMPARATIVO ENTRE UM ALGORITMO GENÉTICO E UM ALGORITMO DE EVOLUÇÃO DIFERENCIAL PARA O PROBLEMA DA DIETA RESTRITA EM CALORIAS

**João Gabriel Rocha Silva**

Universidade Federal de Juiz de Fora  
Juiz de Fora, Minas Gerais  
joaogabriel.comp@gmail.com

**Hélio José Corrêa Barbosa**

Universidade Federal de Juiz de Fora  
Juiz de Fora, Minas Gerais  
hcbm@lncc.br

**Iago Augusto Carvalho**

Universidade Federal de Minas Gerais  
Belo Horizonte, Minas Gerais  
iagoac@dcc.ufmg.br

**Vinícius da Fonseca Vieira**

Universidade Federal de São João del Rei  
São João del Rei, Minas Gerais  
vfvieira@gmail.com

**Carolina Ribeiro Xavier**

Universidade Federal de São João del Rei  
São João del Rei, Minas Gerais  
carolrx@gmail.com

### RESUMO

Uma alimentação rica e balanceada, junto a prática de exercícios físicos, são a forma mais comum e eficaz de obter uma boa forma física e um corpo saudável. Desde o clássico problema da dieta, proposto por Stigler, vários outros trabalhos tiveram como objetivo formular dietas seguindo certo número de restrições. Este trabalho aborda uma variação do problema clássico de Stigler, o Problema da Dieta Restrita em Calorias (PDRC). O objetivo do PDRC é encontrar dieta de reduzido valor calórico que respeite todas as necessidades nutricionais do indivíduo, de forma a possibilitar a perda de peso sem comprometimento da saúde. É apresentada uma formulação por Programação Quadrática Inteira Mista para o PDRC, além de um Algoritmo Genético que resolve a formulação proposta. Resultados de diferentes dietas são apresentados. O algoritmo desenvolvido é comparado ao melhor algoritmo da literatura para o PDRC. É demonstrado que o Algoritmo Genético é mais eficiente para resolver o PDRC, obtendo dietas com menor valor calórico.

**PALAVRAS CHAVE.** Algoritmo Genético, Evolução Diferencial, Problema da Dieta.

**Outras aplicações em PO, Metaheurísticas, Otimização Combinatória**



### **ABSTRACT**

A rich and balanced diet, along with physical exercises, are the most common and efficient approaches to achieve a good physical form and a healthy body. Since the classical Diet Problem, proposed by Stigler, several works had the objective to formulate diets that follow a certain number of constraints. This work focus on a variation of the classical Stigler's problem, the Caloric-Restricted Diet Problem (CRDP). The CRDP objective is to find a diet with reduced calorie count that respects all nutritional needs of an individual, thus making possible weight loss without compromising health. A Mixed Quadratic-Integer Linear Programming formulation for CRDP is presented, along a Genetic Algorithm that solves the proposed formulation. Different diets are presented. The developed algorithm is compared with the best algorithm in the literature for the CRDP. It is shown that the Genetic Algorithm is more efficient to solve CRDP, achieving diets with a smaller calorie count.

**KEYWORDS.** Genetic Algorithms, Differential Evolution, Diet Problem.

**Other applications in OR, Metaheuristics, Combinatorial Optimization**



## 1. Introdução

Algoritmos Evolutivos (AE) são metaheurísticas que baseiam-se em princípios de evolução natural proposto por Darwin, que podem ser aplicados a problemas de diversas áreas do conhecimento. AE's se baseiam num conjunto de soluções, denominados população, onde cada solução da população é dito ser um indivíduo. O processo de otimização da AE consiste em transições probabilísticas entre dois ou mais indivíduos de uma população, o que difere da regra determinista de algoritmos de otimização clássicos.

Para a resolução de problemas lineares ou não lineares, AE recomendados são por exemplo: Algoritmo Genético (AG) e Algoritmo de Evolução Diferencial (ED). Nestes algoritmos, como em outros AE, o processo evolutivo se inicia a partir de uma população inicial gerada aleatoriamente. Em cada geração os indivíduos passam por processos de mutação e recombinação. Em seguida, os indivíduos mais aptos são selecionados para a próxima geração. O conceito de população, mutação e recombinação transforma estes algoritmos em algoritmos rápidos, robustos e estáveis, que podem facilmente escapar de ótimos locais e alcançar boas soluções com um tempo computacional razoável.

Os algoritmos AG e ED podem ser facilmente adaptados a um grande número de problemas de otimização. Um dos problemas mais clássicos é o Problema da Dieta (PD), introduzido em [Stigler, 1945], que visa a construção de uma dieta para um homem de 70 Kg que respeite a quantidade mínima de nutrientes recomendados pelo Conselho Nacional de Pesquisa Norte-americano em 1943, e tem o custo financeiro mínimo.

Diferente da formulação clássica onde a função objetivo minimiza o custo financeiro da dieta, a proposta apresentada em [Silva et al., 2016], denominada Problema da Dieta Restrita em Calorias (PDRC), tem objetivo de formular uma dieta que minimize o número de calorias ingeridas, e que respeite a quantidade mínima de nutrientes. Além disso, ele visa desenvolver uma dieta saborosa que pode ser facilmente adotado por um grande número de indivíduos.

Com base nesta proposta e nos conceitos dos algoritmos genéticos, é apresentado neste trabalho um AG para o PDRC, onde por sua vez são desenvolvidas cada operação, critério de seleção e parada. Em seguida, seus resultados são comparado aos alcançados pelo ED proposto por [Silva et al., 2016]. Experimentos computacionais demonstraram que o AG desenvolvido é mais eficiente que o algoritmo da literatura para PDRC, sendo possível computar dietas com um menor número calórico com um mesmo número de avaliações.

## 2. O problema da dieta restrita em calorias

Uma dieta com uma grande quantidade de calorias está diretamente ligada a um ganho de peso [Bistrrian, 2011]. Mais do que apenas o peso corporal, dietas com altos índices calóricos podem afetar a saúde de um indivíduo, sendo responsável por um grande número de doenças crônicas, como por exemplo: doenças cardíacas [Dalen e Devries, 2014], diabetes [Ley et al., 2014] e doenças de rim [Heerspink et al., 2012].

Visto ser difícil desenvolver dietas com restrição calórica que forneça todos os nutrientes necessários, tais como: proteínas, zinco e ferro, entre outros, a primeira tentativa de desenvolver um algoritmo para obter uma dieta saudável foi apresentada em [Stigler, 1945]. No entanto, ele busca apenas uma dieta de custo mínimo, não se preocupando com a aplicação desta dieta em uma base diária. Além disso, a dieta calculada em [Stigler, 1945] não apresenta uma variedade de alimentos nem de palatabilidade, o que faz com que essa prática torna-se difícil de seguir.

Devido um número crescente de indivíduos obesos [Yang e Colditz, 2015], é interessante o desenvolvimento de métodos computacionais para gerar dietas ao mesmo tempo saudáveis e saborosas. Alguns trabalhos tentaram resolver este problema desenvolvendo versões modificadas do problema da dieta apresentado em [Stigler, 1945], como exemplo: [Mamat et al., 2011], uma variante multiobjetivo [Gallenti, 1997], e uma abordagem de otimização robusta [Bas, 2014].

O foco deste trabalho é o Problema da Dieta Restrita em Calorias. É um problema de otimização introduzido em [Silva et al., 2016] que tem como objetivo obter dietas com restrição



calórica que são saudáveis e saborosas ao mesmo tempo. A dieta é modelada como seis refeições diferentes e cada refeição é representada por um conjunto de diferentes alimentos. Seja  $T$  e  $N$  o conjunto de alimentos disponíveis e o conjunto de nutrientes considerados no problema, respectivamente. A formulação matemática do PDRC é definida com as variáveis de decisão binária  $y$  tal que  $y_i = 1$  se o alimento  $i \in T$  for incluído na dieta e  $y_i = 0$  caso contrário. Além disso, as variáveis auxiliares  $p_i \in \mathbb{R}_+$  representam a quantidade de alimento  $i \in T$  a ser consumida. Além disso  $m_{ij}$  representa a quantidade de nutriente  $j \in N$  que está contida no alimento  $i \in T$ , e  $b_j$  seja a exigência mínima do nutriente  $j \in N$ . Por fim,  $kcal_i$  representa a contagem de calorias de uma porção de alimento  $i \in T$ . O PDRC pode ser descrito pelas Equações 1 - 4. Pode-se notar que se trata de um problema de Programação Quadrática Inteira Mista. Então, é um problema de  $NP$ -Difícil [Garey e Johnson, 2002].

$$\min \left| 1200 - \sum_i kcal_i p_i y_i \right|, \quad \forall i \in T \quad (1)$$

$$\sum_i \sum_j m_{ij} p_i y_i \geq b_j, \quad \forall i \in T, j \in N \quad (2)$$

$$y_i \in \{0, 1\}, \quad \forall i \in T \quad (3)$$

$$p_i \in [0.5, 3], \quad \forall i \in T \quad (4)$$

A função objetivo (1) tem como intuito desenvolver uma dieta com 1200 kcal. Este número foi fixado porque uma dieta com 1200 kcal é a mais indicada para redução de peso [Crampes et al., 1988], de modo que uma maior quantidade de calorias não contribui e uma forma significativa para este objetivo. Por outro lado, uma dieta com uma menor quantidade de calorias pode representar um risco para a saúde de um indivíduo. As desigualdades (2) mantêm todos os nutrientes necessários a um nível recomendado. As equações (3) e (4) definem o domínio das variáveis  $y$  e  $p$ , respectivamente. Este modelo considera que uma porção contém 100 g de um alimento ou 100 ml de uma bebida. O valor de  $p_i$  é limitado dentro do intervalo  $[0.5, 3]$  para que nem uma grande quantidade de algum alimento seja prescrita, assim dominando a dieta, ou uma pequena porção de algum alimento a ser incluído. Evita uma situação real impraticável (imagine cozinhar apenas 10 g de peixe no jantar, por exemplo).

Além do número de calorias da dieta, o PDRC leva em consideração outros nove nutrientes: fibras dietéticas ( $Df$ ), carboidratos ( $C$ ), proteínas ( $Pt$ ), cálcio ( $Ca$ ), manganês ( $Mn$ ), ferro ( $Fe$ ), magnésio ( $Mg$ ), fósforo ( $P$ ) e zinco ( $Zn$ ). A Tabela 1 apresenta a recomendação de ingestão diária de nutrientes [de Vigilância Sanitária, 2003]. Essas recomendações mínimas são garantidas pelas desigualdades 2.

exigência	nutricional (g)	exigência	nutricional (mg)
$Df$	$\geq 25$	$Ca$	$\geq 1000$
$C$	$\geq 300$	$Mn$	$\geq 2.3$
$Pt$	$\geq 75$	$Fe$	$\geq 14$
		$Mg$	$\geq 260$
		$P$	$\geq 700$
		$Zn$	$\geq 7$

Tabela 1: Recomendação de ingestão diária dos nutrientes [de Vigilância Sanitária, 2003]



## 2.1. Base de dados utilizada

Os nutrientes de cada alimento utilizados neste trabalho foram obtidos a partir da Tabela Brasileira de Composição de Alimentos (TACO) [Lima et al., 2011], elaborada por pesquisadores da Universidade de Campinas. Ela contém dados de um grande número de alimentos e bebidas, com uma descrição quantitativa de cerca de 25 de seus nutrientes. Cada dado representa uma porção de 100 g (ou 100 mL, quando apropriado) de um produto.

A TACO apresenta informações sobre alimentos em uma variedade de estados. Por exemplo, apresenta carne crua, carne crua com sal e carne cozida. Assim, apenas um subconjunto dos alimentos da TACO (que pode ser servido em uma refeição) são selecionados para serem incluídos em  $T$ . Além disso, este trabalho só considera os nutrientes mais importantes, considerando assim 9 dos 25 nutrientes de TACO no problema. Os nutrientes selecionados são exibidos nas colunas ímpares da Tabela 1.

O subconjunto selecionado de alimentos foi classificado em 9 categorias, de acordo com suas características. Este procedimento foi realizado por um especialista da área. As categorias são exibidas na Tabela 2. A primeira coluna exibe o nome da categoria. A segunda coluna mostra o símbolo associado a cada categoria. A terceira coluna indica o número de alimentos em cada categoria. A última coluna mostra o intervalo de números associados a cada categoria. Este intervalo será usado para representar uma solução para os algoritmos evolutivos utilizados.

produto	símbolo	#	intervalo
bebidas	$B$	21	1–21
sucos	$S$	11	22–32
frutas	$F$	62	33–94
lacteos	$L$	19	95–113
carboidratos 1	$C1$	21	114–134
carboidratos 2	$C2$	12	135–146
grãos	$G$	12	147–158
vegetais	$V$	41	159–199
proteínas	$P$	95	200–294

Tabela 2: Classificação de diferentes produtos da TACO [Lima et al., 2011]

Bebidas, exceto sucos naturais e bebidas alcoólicas, são simbolizadas como  $B$ . Sucos de frutas naturais são representados pelo símbolo  $S$ . As frutas, em geral, são a terceira categoria. Eles são representados como  $F$ . Os produtos derivados do leite têm o símbolo  $L$ . Os carboidratos são separados em dois grupos diferentes, simbolizados por  $C1$  e  $C2$ . O primeiro contém petiscos, como pão, biscoitos e biscoitos. Este último é composto por carboidratos de farinha principal, como arroz, batata e mandioca. Grãos e leguminosas, como lentilhas e feijão, são representados como  $G$  e os vegetais são simbolizados como  $V$ . A última categoria contém alimentos ricos em proteínas, como carne, frango e ovos, sendo representado pelo símbolo  $P$ .

## 3. Algoritmo Genético para o PDCR

Nesta seção é apresentado um Algoritmo Genético (AG) [Davis, 1991] para a resolução do PDCR. Este algoritmo genético é baseado no modelo evolutivo para o PDCR apresentado em [Silva et al., 2016]. Posteriormente, o AG proposto é comparado com o algoritmo de Evolução Diferencial, proposto em Silva et al. [2016], na Sessão 4.

Algoritmos Genéticos [Davis, 1991] são os algoritmos evolucionistas mais clássicos. Eles foram propostos nas décadas de 1950 e 1960, quando vários cientistas de computadores estudaram de forma independente os sistemas evolutivos tentando imitá-lo em uma ferramenta de otimização genérica para problemas de engenharia [Mitchell, 1998].

Um AG considera três aspectos básicos da teoria da evolução natural de Darwin: (i) cruzamento; (ii) mutação; e (iii) seleção do mais apto. Esses aspectos são modelados como operadores



e aplicados iterativamente em uma população inicial até que um critério de parada seja atingido e cada iteração seja considerada uma *geração*. Um AG tem dois parâmetros: a Taxa de cruzamento  $Tc \in [0, 1]$  e a taxa de mutação  $Tm \in [0, 1]$ . As taxas de cruzamento e mutação controlam a probabilidade de uma solução ser cruzada ou mantida, respectivamente. Estes operadores são explicados abaixo.

### 3.1. Representação da população

Denotaremos uma população como  $X = x_1, x_2, \dots, x_{pop}$ , onde  $x_i$  é o  $i$ -ésimo indivíduo de  $X$ . Seja  $X^g$  denota a população  $X$  na geração  $g$ . A população inicial é dito estar na primeira geração. No final da iteração de um operador, a população resultante  $X^{g+1}$  é dita estar na geração  $g + 1$ . Além disso, todos os algoritmos têm algumas características comuns, tais como inicialização da população, representação e avaliação da solução. Primeiro, será descrito as características comuns. Em seguida, apresentado cada algoritmo separadamente.

Uma solução do PDRC pode ser representada por um conjunto de diferentes refeições. Assim, uma solução é modelada como uma combinação dos tipos mais comuns de produtos consumidos em cada refeição. Uma vez que os alimentos são divididos em 9 categorias (ver Tabela 2), é possível construir uma dieta com uma grande variedade de produtos [Silva et al., 2016].




Figura 1: Modelo de uma solução. Existem 6 refeições diferentes, formadas por 17 produtos alimentares distintos [Silva et al., 2016]

A Figura 1 mostra a modelagem dessa solução. Considera que um indivíduo come 6 refeições diferentes em um determinado dia, sendo elas: (i) café da manhã; (ii) dois lanches; (iii) almoço; (iv) jantar; e (v) ceia.

0.6	2.1	2.9	1.2	1	0.8	2	2.7	1.9	1.1	0.6	1	1.6	1.1	1.7	2	0.5
13	52	16	17	19	7	33	12	84	10	18	6	16	11	31	9	41

Figura 2: Representação de um indivíduo no PDCR [Silva et al., 2016]

Da Figura 1, é possível representar a solução de um CRDP como na Figura 2. Uma solução consiste em dois vetores de 17 variáveis cada, representando as 6 refeições exibidas na Figura 1. O primeiro vetor, chamado *vetor de porções*, representa as porções  $p_i$  do produto alimentar selecionado. O segundo vetor, denotado *vetor ID*, contém números inteiros no intervalo  $[1, 294]$ . Uma função bijetiva  $f : \mathbb{N} \mapsto T$  que mapeia cada número como um alimento diferente é aplicada a cada gene do *vetor ID*. Para um dado indivíduo  $x_i \in X$ , denotamos como  $x_i^j$  o par de variáveis  $j$ , denotando um alimento e tamanho de porção. Além disso, denotamos como  $x_i^{p_j}$  e  $x_i^{ID_j}$  a  $j$ -ésima posição de *vetor de porções* e *vetor ID*, respectivamente. Vale a pena mencionar que cada gene deste vetor é apenas permitido assumir os números que mapeiam produtos de sua própria categoria, como mostrado na quarta coluna da Tabela 2.

### 3.2. Inicialização da população

Uma população inicial  $X = \{x_1, x_2, \dots, x_{pop}\}$  é gerada aleatoriamente com  $|X| = Pop$  indivíduos. Primeiro, um número real aleatório é gerado no intervalo  $[0.5, 3]$  para cada posição do *vetor de porções*. Em seguida, é gerado um número inteiro aleatório para cada posição do *vetor ID*. Este número inteiro está dentro do intervalo de sua classe, como mencionado acima.



### 3.3. Avaliação de uma solução

Quando nenhuma restrição é violada, a PDRC emprega a Equação (1) como função de aptidão. No entanto, quando alguma restrição é violada, um mecanismo para tratar essas violações deve ser adotado. Assim, a função de aptidão se torna a função objetivo mais um termo de penalização [Barbosa et al., 2015]. Este termo é definido de acordo com a Equação (5).

$$\min |Kcal - 1200| + \sum_j \left( \frac{|\sum_{i \in F} (m_{ij} p_i y_i) - b_j|}{b_j} \right) \cdot M, \quad \forall j \in N \quad (5)$$

onde  $m_{ij}$  representa a quantidade de nutriente  $j \in N$  no produto  $i \in F$ ,  $M$  é um número grande constante, usado como taxa de penalização para restrições violadas. Tanto  $p_i$ ,  $y_i$ , quanto  $b_j$  são os mesmos indicados na Equação (1). É notório que não há penalidade para o valor de  $y_i$ . Os limites de  $y_i$  são manipulados pelos algoritmos evolutivos, de forma que um valor menor que 0.5 ou maior que 3 é arredondado para pertencer a este intervalo.

### 3.4. Cruzamento

O cruzamento é o primeiro operador aplicado em cada geração. Este operador gera  $pop$  pares de novas soluções, combinando duas soluções selecionadas aleatoriamente da população atual. Cada par é composto por soluções  $p_1$  e  $p_2$ . Eles são gerados pela combinação de duas soluções aleatórias  $x_i, x_j$  de  $X$  com uma probabilidade  $Tc$ .

Inicialmente,  $p_1 \leftarrow x_i$  e  $p_2 \leftarrow x_j$ . Como uma solução é representada por 6 refeições diferentes, é escolhido aleatoriamente um delas para ser trocado entre os  $p_1$  e  $p_2$ . Portanto, é gerado um número aleatório  $r_1$  no intervalo  $\{1 - 6\}$ . Então, outro número aleatório  $r_2 \in [0, 1]$  é gerado. Se  $r_2 \leq Tc$ , então  $p_1$  troca refeição  $r_1$  com  $p_2$ . Se  $r_2 > Tc$ , nada acontece. Em seguida, o operador de mutação é aplicado em ambas as soluções resultantes.

### 3.5. Mutação

Como uma solução é composta por dois vetores, um com números inteiros e outro com variáveis de valor real, define-se operadores de mutação diferentes. O primeiro operador é aplicado no vetor *porções*. Ele gera um novo valor para cada posição de  $p_1$  e  $p_2$  com probabilidade  $Tm$ . Este novo valor é gerado usando uma distribuição normal  $(\mu, \sigma)$ , onde  $\mu$  é o valor da porção anterior e  $\sigma = 0.2$ . Se resultar em um valor menor que 0.5 ou maior que 3, então ele é arredondado para pertencer a esse intervalo. Dessa forma, não viola o domínio das variáveis definidas na Equação (4).

O segundo operador é aplicado no *vetor ID*. Para cada posição do vetor *ID*, é gerado outro número inteiro aleatório no mesmo intervalo que o alimento original pertence.

Ambos os operadores são aplicados com uma probabilidade  $Tm$ . Para cada par de alimento e porção, um número aleatório  $r \in [0, 1]$  é gerado. Se  $r \leq Tm$ , então ambos os operadores de mutação são aplicados. Se  $r > Tm$ , então a solução não é modificada.

### 3.6. Seleção

Este operador seleciona as soluções que serão submetidas à próxima geração. Ele compara o  $i$ -ésimo par de soluções geradas pelos operadores de cruzamento e mutação com a  $i$ -ésima solução da população atual. Porém, a solução com a melhor aptidão é selecionada para compor a próxima geração e as outras são descartadas.

## 4. Experimentos Computacionais

Experimentos computacionais foram realizados em uma computador com um processador Intel Core i5 CPU 5200U com 2,2 GHz e 4 GB de memória RAM, executado em sistema operacional Linux. Os códigos foram implementados em C e compilados com a versão GNU GCC 4.7.3.



Os experimentos computacionais visam comparar o AG proposto com o DE apresentado em Silva et al. [2016]. O primeiro experimento descrito tem o objetivo de realizar a calibração dos parâmetros, tanto do AG como do ED. Para isto, dois experimentos fatoriais completos foram realizados, utilizando valores pertencentes ao domínio dos parâmetros em cada um dos algoritmos. Como se tratam de algoritmos estocásticos, é necessário a execução de cada experimento repetidamente. Assim, é possível minimizar o erro estatístico devido a estocasticidade. Assim, cada experiência foi repetida 30 vezes. Foi adotado o número de 2500 avaliações da função de aptidão como critério de parada.

Os resultados deste experimento são apresentados nas Tabelas 3 e 4. Cada linha destas tabelas representa uma combinação de parâmetros possível, sendo que o melhor conjunto de parâmetros para cada algoritmo é destacado em negrito. Ao analisar a Tabela 3, pode-se perceber que o AG é muito influenciado pelo tamanho de sua população, conseguindo melhores resultados com o incremento no tamanho da população. O inverso acontece com o ED, que quanto maior o número de gerações (intensificação), menor é o valor calórico encontrado pela dieta (Tabela 4).

Tabela 3: Experimento fatorial completo para as combinações de parâmetros no AG

parâmetros				função de aptidão			
tamanho da população	gerações	$Tc$	$Tm$	média	melhor	pior	desvio padrão
25	100	0.4	0.1	1700.87	1521.29	1901.60	101.59
25	100	0.4	0.2	1687.86	1523.81	1924.72	88.60
25	100	0.4	0.4	1633.05	1499.16	1766.22	78.22
25	100	0.6	0.1	1733.08	1589.98	1944.90	90.73
25	100	0.6	0.2	1692.86	1542.77	2021.99	105.56
25	100	0.6	0.4	1689.71	1577.80	1906.35	89.46
25	100	0.8	0.1	1810.93	1649.92	2118.26	113.46
25	100	0.8	0.2	1800.41	1642.96	2177.98	134.43
25	100	0.8	0.4	1673.61	1523.31	1844.99	79.76
50	50	0.4	0.1	1625.12	1493.95	1730.74	59.85
50	50	0.4	0.2	1613.22	1510.87	1745.90	70.85
50	50	0.4	0.4	1573.24	1502.42	1670.32	45.69
50	50	0.6	0.1	1653.93	1512.32	1884.84	91.96
50	50	0.6	0.2	1585.31	1490.97	1759.37	56.37
50	50	0.6	0.4	1559.18	1455.63	1719.59	50.21
50	50	0.8	0.1	1701.09	1556.31	2014.89	97.56
50	50	0.8	0.2	1638.59	1491.00	1745.03	61.45
50	50	0.8	0.4	1575.94	1489.88	1671.66	47.49
100	25	0.4	0.1	1570.93	1478.75	1712.36	53.55
100	25	0.4	0.2	1545.23	1480.75	1637.88	40.96
<b>100</b>	<b>25</b>	<b>0.4</b>	<b>0.4</b>	<b>1521.24</b>	<b>1458.25</b>	<b>1604.91</b>	<b>36.76</b>
100	25	0.6	0.1	1564.83	1475.97	1704.33	51.84
100	25	0.6	0.2	1541.84	1446.20	1674.73	42.90
100	25	0.6	0.4	1528.26	1472.25	1614.64	38.01
100	25	0.8	0.1	1583.18	1500.58	1756.36	57.93
100	25	0.8	0.2	1562.61	1461.35	1658.88	45.34
100	25	0.8	0.4	1524.66	1469.55	1619.58	40.51

A Figura 3 apresenta a curva de convergência de cada um dos algoritmos utilizando a melhor combinação de parâmetros encontrada, como destacado em negrito nas tabelas 3 e 4. Cada ponto da curva foi computado como a média das 30 execuções realizadas com o mesmo conjunto de parâmetros. É possível observar que o AG proposto consegue obter dietas com um menor índice calórico, sendo mais efetivo que o ED para o PDCR. Isto se deve ao balanço entre diversificação e intensificação proposto nos operadores do algoritmo.

A Tabela 5 mostra dois exemplos de dietas, uma computada pelo AG e outra pelo ED.





Tabela 4: Experimento fatorial completo para as combinações de parâmetros no ED

parâmetros				função de aptidão			
tamanho da população	gerações	$Tc$	$F$	média	melhor	pior	desvio padrão
25	100	0.4	0.4	1559.49	1492.69	1640.43	38.81
25	100	0.4	0.8	1564.57	1488.76	1641.96	32.91
25	100	0.4	1.2	1562.27	1476.90	1690.78	47.72
25	100	0.6	0.4	1554.76	1471.39	1701.61	47.25
25	100	0.6	0.8	1570.44	1471.94	1682.61	53.53
<b>25</b>	<b>100</b>	<b>0.6</b>	<b>1.2</b>	<b>1548.97</b>	<b>1492.91</b>	<b>1680.71</b>	<b>44.98</b>
25	100	0.8	0.4	1604.06	1518.45	1742.35	47.80
25	100	0.8	0.8	1599.47	1481.25	1709.59	58.63
25	100	0.8	1.2	1597.91	1517.09	1692.01	51.22
50	50	0.4	0.4	1579.90	1523.32	1647.25	32.28
50	50	0.4	0.8	1606.07	1515.40	1741.35	43.34
50	50	0.4	1.2	1609.78	1524.99	1718.01	49.69
50	50	0.6	0.4	1562.68	1498.45	1648.84	40.33
50	50	0.6	0.8	1593.86	1496.89	1757.35	52.47
50	50	0.6	1.2	1597.46	1536.47	1661.36	36.27
50	50	0.8	0.4	1581.52	1506.01	1697.11	49.56
50	50	0.8	0.8	1586.55	1524.73	1684.92	44.14
50	50	0.8	1.2	1608.19	1534.66	1724.25	46.74
100	25	0.4	0.4	1676.21	1539.05	1808.00	60.94
100	25	0.4	0.8	1688.20	1574.21	1776.86	40.48
100	25	0.4	1.2	1692.99	1592.84	1780.80	45.14
100	25	0.6	0.4	1626.50	1546.67	1734.94	50.82
100	25	0.6	0.8	1637.55	1558.30	1710.99	38.24
100	25	0.6	1.2	1679.40	1600.84	1832.27	54.33
100	25	0.8	0.4	1596.31	1521.55	1699.80	45.30
100	25	0.8	0.8	1634.79	1523.48	1762.32	51.54
100	25	0.8	1.2	1654.88	1568.34	1758.60	52.18

Nela pode-se notar a diversidade de alimentos, que contribui para que o indivíduo possa fazer a dieta de uma forma mais fácil e prazerosa.

## 5. Conclusão e trabalhos futuros

Neste trabalho é proposta a comparação entre dois algoritmos evolutivos para o Problema de Dieta Restrita a Calorias (PDCR). O algoritmo genético proposto foi avaliado e comparado com um algoritmo de Evolução Diferencial proposto em Silva et al. [2016]. Foi desenvolvida uma análise de convergência. Experimentos computacionais mostraram que o algoritmo genético proposto supera o algoritmo de [Silva et al., 2016].

Trabalhos futuros sobre este problema devem investigar um PDCR multiobjetivo. Apesar de minimizar a contagem de calorias de uma dieta, pode-se também maximizar a quantidade de proteínas ou fibras ingeridas. Desta forma, seria possível desenvolver uma dieta restrita em calorias que fornece um maior nível de saciedade para um indivíduo.

## Agradecimentos

Este trabalho foi parcialmente financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Fundação de Apoio à Pesquisa do Estado de Minas Gerais, Brasil (FAPEMIG) e Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Brasil (CAPES).

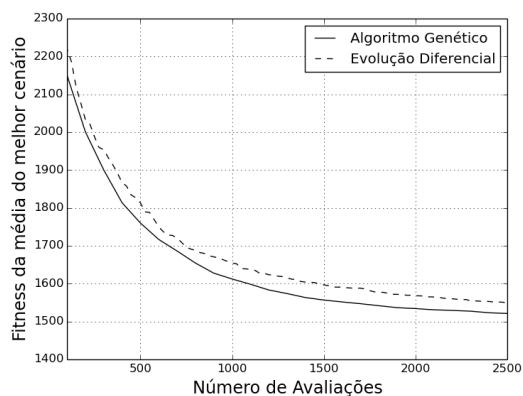


Figura 3: Evolução média do melhor cenário para o AG e o ED

Tabela 5: Exemplo de duas possíveis dietas

Dieta 1 - Gerada pelo AG <b>1604.91 Kcal</b>		Dieta 2 - Gerada pelo ED <b>1554.23 Kcal</b>	
Café da manhã			
Iogurte natural desnatado	75 ml	Café infusão	10 50 ml
Manga crua	200 g	Pêsseco aurora cru	245 g
Curau de milho verde	110 g	Pão de forma integral	50 g
Lanche da manhã			
Nêspera crua	280 g	Banana nanica crua	300 g
Almoço			
Batata baroa cozida	125 g	Arroz tipo dois cozido	50 g
Feijão rosinha cozido	90 g	Feijão fradinho cozido	250 g
Mostarda em folhas	195 g	Alfavaca crua	235 g
Almeirão cru	300 g	Brócolis cozido	300 g
Filé de abadejo	50 g	Coxa de frango sem pele	50 g
Suco de limão cravo	190 ml	Suco de limão galero	50 ml
Lanche da tarde			
Suco de limão cravo	225 ml	Água tônica	250 ml
Cereal de milho	60 g	Pão de soja	50 g
Jantar			
Batata baroa cozida	200 g	Batata inglesa souté	50 g
Ervilha em vagem	200 g	Feijão rajado cozido	140 g
Aipo cru	275 g	Beterraba cozida	145 g
Sardinha crua	50 g	Quibe assado	50 g
Ceia			
Banana figo crua	80 g	Fatia de queijo suíço	50 g

## Referências

- Barbosa, H. J., Lemonge, A. C., e Bernardino, H. S. (2015). A critical review of adaptive penalty techniques in evolutionary computation. In *Evolutionary Constrained Optimization*, volume 1 of *Infosys Science Foundation Series*, p. 1–27. Springer.
- Bas, E. (2014). A robust optimization approach to diet problem with overall glycemic load as objective function. *Applied Mathematical Modelling*, 38(19):4926–4940.



- Bistrrian, B. R. (2011). Diet, lifestyle, and long-term weight gain. *The New England Journal of Medicine*, 365(11):1058–1059.
- Crampes, F., Marceron, M., Beauville, M., Riviere, D., Garrigues, M., Berlan, M., e Lafontan, M. (1988). Platelet alpha 2-adrenoceptors and adrenergic adipose tissue responsiveness after moderate hypocaloric diet in obese subjects. *International journal of obesity*, 13(1):99–110.
- Dalen, J. E. e Devries, S. (2014). Diets to prevent coronary heart disease 1957-2013: what have we learned? *The American journal of medicine*, 127(5):364–369.
- Davis, L. (1991). Handbook of genetic algorithms. p. 385.
- de Vigilância Sanitária, A. N. (2003). Resolution rdc number 360. Diário Oficial da União. URL <https://goo.gl/wbZxgw>. Accessed: 2016-03-16.
- Gallenti, G. (1997). The use of computer for the analysis of input demand in farm management: A multicriteria approach to the diet problem. In *First European conference for information technology in agriculture*.
- Garey, M. R. e Johnson, D. S. (2002). *Computers and intractability*, volume 29. W. H. Freeman.
- Heerspink, H. J. L., Holtkamp, F. A., Parving, H.-H., Navis, G. J., Lewis, J. B., Ritz, E., De Graeff, P. A., e De Zeeuw, D. (2012). Moderation of dietary sodium potentiates the renal and cardiovascular protective effects of angiotensin receptor blockers. *Kidney international*, 82(3):330–337.
- Ley, S. H., Hamdy, O., Mohan, V., e Hu, F. B. (2014). Prevention and management of type 2 diabetes: dietary components and nutritional strategies. *The Lancet*, 383(9933):1999–2007.
- Lima, D. M., Padovani, R. M., Rodriguez-Amaya, D. B., Farfán, J. A., Nonato, C. T., Lima, M. T. d., Salay, E., Colugnati, F. A. B., e Galeazzi, M. A. M. (2011). Tabela brasileira de composição de alimentos – taco. URL <http://www.unicamp.br/nepa/taco/tabela.php?ativo=tabela>. Accessed: 2016-03-16.
- Mamat, M., Rokhayati, Y., Mohamad, N., e Mohd, I. (2011). Optimizing human diet problem with fuzzy price using fuzzy linear programming approach. *Pakistan Journal of Nutrition*, 10(6): 594–598.
- Mitchell, M. (1998). *An introduction to genetic algorithms*. MIT press.
- Silva, J. G. R., Carvalho, I. A., Loureiro, M. M. S., da Fonseca Vieira, V., e Xavier, C. R. (2016). Developing tasty calorie restricted diets using a differential evolution algorithm. In *Computational Science and Its Applications - ICCSA 2016 - 16th International Conference, Beijing, China, July 4-7, 2016, Proceedings, Part V*, p. 171–186.
- Stigler, G. J. (1945). The cost of subsistence. *Journal of farm economics*, 27(2):303–314.
- Yang, L. e Colditz, G. A. (2015). Prevalence of overweight and obesity in the united states, 2007-2012. *JAMA internal medicine*.