

# Método $q$ -GC: uma generalização do método dos gradientes conjugados

**Érica J. C. Gouvêa,**      **Marluce Scarabello,**

Programa de Doutorado em Computação Aplicada, CAP, INPE,  
12227-010, São José dos Campos, SP

E-mail: ericagouvea@gmail.com,    marluce.scarabello@inpe.br,

**Aline C. Soterroni,**      **Fernando Manuel Ramos,**

Laboratório Associado de Computação e Matemática Aplicada, LAC, INPE,  
12227-010, São José dos Campos, SP

E-mail: alinecsoterroni@gmail.com,    fernando.ramos@inpe.br,

**Roberto L. Galski**

Centro de Rastreo e Controle de Satélites, CRC, INPE

12210-080, São José dos Campos, SP

E-mail: galski@ccs.inpe.br .

**Resumo:** *Recentemente, baseado na derivada de Jackson, foi proposta uma generalização do método da máxima descida, denominada método do  $q$ -gradiente ( $q$ -G), para problemas de otimização global contínua. Dentro desse contexto, este trabalho apresenta uma generalização do método dos gradientes conjugados ( $q$ -GC) com base no conceito do vetor  $q$ -gradiente. Para avaliar o desempenho do método  $q$ -GC foram considerados os resultados obtidos pelo método  $q$ -G e por três Algoritmos Genéticos (AGs) para um conjunto de seis funções teste de 20 variáveis e mesmo critério de parada. No geral, os resultados mostram que o  $q$ -GC é um método promissor para solução de problemas de otimização multimodais.*

**Palavras-chave:**  $q$ -gradiente,  $q$ -derivada, método  $q$ -G, método  $q$ -GC

## 1 Introdução

Recentemente, uma generalização do método da máxima descida, denominada método  $q$ -G, foi desenvolvida por [10] para problemas de otimização global contínua. Esse método utiliza como direção de busca, a direção contrária à direção do vetor  $q$ -gradiente, definido a partir da derivada clássica com o auxílio do parâmetro  $q$ . Dentro desse contexto, esse trabalho apresenta uma generalização do método dos gradientes conjugados, denominada método dos  $q$ -Gradientes Conjugados ( $q$ -GC), onde a primeira direção de busca é a direção contrária à direção do vetor  $q$ -gradiente e as outras direções são combinações lineares da direção contrária à direção do vetor  $q$ -gradiente do ponto atual com as direções anteriores. Tanto no método  $q$ -G quanto no método  $q$ -GC,  $q$  é um parâmetro chave e, à medida que  $q$  tende a 1, as  $q$ -versões retomam suas respectivas versões clássicas.

Para testar essa nova abordagem, o método  $q$ -GC foi aplicado em seis funções teste (três unimodais e três multimodais) comumente utilizadas na área de otimização contínua. Os resultados são comparados com os obtidos pelo método  $q$ -G, além dos Algoritmos Genéticos (AGs) G3-PCX (veja [2]), SPC-vSBX e SPC-PNX (veja [1]). Embora preliminares, os resultados mostram a capacidade do método de escapar de mínimos locais em problemas multimodais. Já para

os problemas unimodais, o  $q$ -GC permite encontrar o mínimo da função em menos iterações ou com uma precisão melhor que o método  $q$ -G.

## 2 O método $q$ -GC

A derivada de Jackson, ou  $q$ -derivada, de uma função  $f(x)$  de uma única variável é dada por (veja [6])

$$D_q f(x) = \frac{f(qx) - f(x)}{qx - x}, \quad (1)$$

onde  $q$  é um número real diferente de 1 e  $x$  diferente de 0. No limite, quando  $q \rightarrow 1$  (ou  $x \rightarrow 0$ ), a  $q$ -derivada retorna à derivada clássica. Para funções diferenciáveis de  $n$  variáveis,  $f(\mathbf{x})$ , o  $q$ -gradiente é o vetor das  $n$   $q$ -derivadas parciais de primeira ordem de  $f$  dado por (veja [10])

$$D_{q_i, x_i} f(\mathbf{x}) = \begin{cases} \frac{f(x_1, \dots, q_i x_i, \dots, x_n) - f(x_1, \dots, x_i, \dots, x_n)}{q_i x_i - x_i}, & x_i \neq 0 \text{ e } q_i \neq 1 \\ \frac{\partial f(\mathbf{x})}{\partial x_i}, & x_i = 0 \text{ ou } q_i = 1 \end{cases}, \quad (2)$$

onde o parâmetro  $q$  é um vetor  $\mathbf{q} = (q_1, \dots, q_i, \dots, q_n)$  com  $q_i \neq 1, \forall i$ . Note que, se  $x_i = 0$  ou  $q_i = 1$ , a  $q$ -derivada parcial de primeira ordem retorna à derivada parcial clássica. A equação anterior define o vetor  $q$ -gradiente de  $f$  como [10]

$$\nabla_{\mathbf{q}} f(\mathbf{x})^T = [D_{q_1, x_1} f(\mathbf{x}) \dots D_{q_i, x_i} f(\mathbf{x}) \dots D_{q_n, x_n} f(\mathbf{x})], \quad (3)$$

em que no limite,  $q_i \rightarrow 1 (\forall i = 1, \dots, n)$ , o vetor  $q$ -gradiente retorna ao vetor gradiente clássico.

Em geral, os métodos de otimização utilizam o procedimento iterativo  $\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha^k \mathbf{d}^k$ , em que  $\mathbf{d}^k$  é a direção de busca e  $\alpha^k$  é o tamanho do passo dado nesta direção na iteração  $k$ . Os métodos de otimização baseados em gradiente diferem entre si na forma em que a direção e o tamanho do passo são calculados. O método da máxima descida, por exemplo, utiliza  $\mathbf{d}^k = -\nabla f(\mathbf{x}^k)$  como direção de busca e o tamanho do passo  $\alpha^k$  é, em geral, determinado por uma técnica de busca linear que minimiza a função objetivo ao longo de  $\mathbf{d}^k$ . No método  $q$ -G, a direção de busca é a direção contrária à direção do vetor  $q$ -gradiente da função objetivo no ponto  $x^k$ ,  $-\nabla_{\mathbf{q}} f(\mathbf{x}^k)$ , como definida na Equação (3). De forma similar, o método  $q$ -GC é uma generalização do método dos gradientes conjugados de Fletcher e Reeves [4] no qual a primeira direção de busca é a direção contrária à direção do vetor  $q$ -gradiente e as outras direções são combinações lineares da direção contrária à direção do vetor  $q$ -gradiente do ponto atual com as direções anteriores.

O parâmetro  $q$  utilizado no cálculo da  $q$ -derivada pode ser qualquer número real diferente de 1. Assim como em [10], os valores de  $q_i^k x_i^k, i = 1, \dots, n$ , foram sorteados segundo uma distribuição gaussiana com média no ponto  $x_i^k$  e desvio padrão  $\sigma^k$ . O desvio padrão é inicialmente diferente de zero e tende a zero ao longo do procedimento iterativo por meio da expressão  $\sigma^{k+1} = \beta \sigma^k$  em que  $\beta \in [0, 1]$  é o fator de redução.

Geralmente, os métodos baseados em gradiente realizam busca linear a cada iteração para determinar o comprimento do passo a ser dado em uma direção que é de descida (veja [3]). Uma vez que a direção de busca do método  $q$ -GC pode ser tanto de descida quanto de subida, dependendo do valor do parâmetro  $\mathbf{q}$ , o cálculo para o comprimento do passo na iteração  $k$  é dado por  $\alpha^{k+1} = \beta \alpha^k$ . Por simplicidade,  $\beta$  é o mesmo fator de redução usado no cálculo do  $\sigma^k$  (veja [10]).

As principais etapas do algoritmo do método  $q$ -GC são descritas a seguir.

---

**Algoritmo do Método  $q$ -GC**

---

**Dados**  $f(\mathbf{x})$  contínua e diferenciável, ponto inicial  $\mathbf{x}^0$  e os parâmetros livres  $\sigma^0 > 0$ ,  $\alpha^0 > 0$  e  $0 < \beta < 1$

- 1: **Faça**  $k = 0$
  - 2: **Faça**  $\mathbf{x}_{\text{melhor}} = \mathbf{x}^k$
  - 3: Gere  $q_i^k (i = 1, \dots, n)$  com distribuição gaussiana para  $\sigma^k$  e  $\mu^k = \mathbf{x}^k$
  - 4: Calcule  $\nabla_{\mathbf{q}} f(\mathbf{x}^k)$
  - 5:  $\mathbf{d}^k = -\nabla_{\mathbf{q}} f(\mathbf{x}^k)$
  - 6:  $\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha^k \mathbf{d}^k$
  - 7:  $k = k + 1$
  - 8: **Enquanto o critério de parada não for satisfeito, faça:**
  - 9:     Gere  $q_i^k (i = 1, \dots, n)$  com distribuição gaussiana para  $\sigma^k$  e  $\mu^k = \mathbf{x}^k$
  - 10:     Calcule  $\nabla_{\mathbf{q}} f(\mathbf{x}^k)$
  - 11:      $\delta^{k-1} = \nabla_{\mathbf{q}} f(\mathbf{x}^k)^T \nabla_{\mathbf{q}} f(\mathbf{x}^k) / \nabla_{\mathbf{q}} f(\mathbf{x}^{k-1})^T \nabla_{\mathbf{q}} f(\mathbf{x}^{k-1})$
  - 12:      $\mathbf{d}^k = -\nabla_{\mathbf{q}} f(\mathbf{x}^k) + \delta^{k-1} \mathbf{d}^{k-1}$
  - 13:      $m = \nabla_{\mathbf{q}} f(\mathbf{x}^k)^T \mathbf{d}^k$
  - 14:     **Se**  $m \geq 0$  e  $\mathbf{q} = \mathbf{1}$ , **então**  $\mathbf{d}^k = -\nabla_{\mathbf{q}} f(\mathbf{x}^{k-1})$
  - 15:      $\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha^k \mathbf{d}^k$
  - 16:     **Se**  $f(\mathbf{x}^{k+1}) < f(\mathbf{x}_{\text{melhor}})$  **então**  $\mathbf{x}_{\text{melhor}} = \mathbf{x}^{k+1}$
  - 17:      $\sigma^{k+1} = \beta \sigma^k$
  - 18:      $\alpha^{k+1} = \beta \alpha^k$
  - 19:      $k = k + 1$
  - 20: **Retorna**  $\mathbf{x}_{\text{melhor}}$
- 

O algoritmo termina quando um critério de parada apropriado é satisfeito. Em aplicações do mundo real, onde o mínimo global não é conhecido, o critério de parada poderá ser um número máximo de avaliações da função objetivo ou o valor do gradiente da função no ponto atual  $\|\nabla f(\mathbf{x}^k)\|$ , desde que o método  $q$ -GC retome sua versão clássica no final da busca. O algoritmo retorna o melhor ponto visitado durante o procedimento iterativo como mostra o passo 20 do algoritmo. Note que as direções são reinicializadas apenas se a direção for de subida e o parâmetro  $\mathbf{q}$  for igual a  $\mathbf{1}$  (passo 14). O método  $q$ -GC utiliza apenas três parâmetros de ajuste:  $\sigma^0$ ,  $\alpha^0$  e  $\beta$ . Embora uma má escolha desses parâmetros causem uma deteriorização em seu desempenho, simulações mostraram que o algoritmo do método  $q$ -GC é suficientemente robusto sendo capaz de atingir a bacia de atração do mínimo global<sup>1</sup>. A seguir, o método  $q$ -GC é comparado com o método  $q$ -G e com AGs considerados eficientes na resolução de problemas de otimização global.

### 3 Experimentos Computacionais

O desempenho do método  $q$ -GC é avaliado em seis funções teste de 20 variáveis. As funções unimodais são: *Ellipsoidal*, Schwefel e Rosenbrock; e as funções multimodais são: Ackley, Rastrigin e Rastrigin Rotacionada. A descrição completa dessas funções pode ser encontrada em [10]. Todas as funções possuem mínimo global em  $f(\mathbf{x}^*) = 0$  com  $\mathbf{x}^* = \mathbf{0}$ , com exceção da função Rosenbrock onde  $\mathbf{x}^* = \mathbf{1}$ . Os critérios de parada são: máximo de  $10^6$  avaliações da função objetivo ou  $f(\mathbf{x}) < 10^{-20}$ , os mesmos adotados em [1], [2] e [10]. A Tabela 1 exhibe os valores dos parâmetros de ajuste  $\sigma^0$ ,  $\alpha^0$  e  $\beta$ , usados em cada função pelo método  $q$ -GC. Os valores de  $\sigma^0$  e  $\alpha^0$  foram normalizados pelo maior comprimento linear do espaço de busca,  $L = \sqrt{\sum_{i=1}^n (\mathbf{x}_{\text{max}_i} - \mathbf{x}_{\text{min}_i})^2}$ , com  $\mathbf{x}_{\text{max}_i}$ ,  $\mathbf{x}_{\text{min}_i}$  definidos como em [1].

Os resultados são apresentados nas Tabelas 2 e 3. As colunas “Melhor”, “Mediano” e “Pior”

---

<sup>1</sup>Bacia de atração do mínimo global  $\mathbf{x}^*$ ,  $\mathbf{x}^* \in \mathbb{R}^n$ , de uma função  $f(\mathbf{x})$  é a região  $B$ ,  $B \subset \mathbb{R}^n$ , que contém o ponto  $\mathbf{x}^*$  e, para todo  $\mathbf{x} \in B$ , uma trajetória de descida da  $f(\mathbf{x})$  converge para o ponto  $\mathbf{x}^*$  (veja [5]).

Funções	$\sigma^0/L$	$\alpha^0/L$	$\beta$
<i>Ellipsoidal</i>	0,0012	0,0750	0,9000
Schwefel	0,0025	0,0025	0,9900
Rosenbrock	0,0001	0,3052	0,9995
Ackley	0,0092	0,0083	0,9000
Rastrigin	0,1953	0,0004	0,9995
Rastrigin Rotacionada	0,1074	0,0005	0,9995

 Tabela 1: Parâmetros usados pelo método  $q$ -GC para o conjunto de funções teste.

referem-se, respectivamente, ao menor, ao mediano e ao maior número de avaliações da função objetivo necessárias para atingir a precisão desejada de  $10^{-20}$ . A coluna “ $f(\mathbf{x}_{\text{melhor}})$ ” exibe o melhor valor da função objetivo encontrado durante o procedimento iterativo. Note que, quando a precisão desejada não é atingida, o melhor valor encontrado pelo método é exibido. A coluna “Sucesso” exibe o número de execuções independentes que atingiram a precisão desejada (para as funções unimodais) ou que alcançaram a bacia de atração do mínimo global (para as funções multimodais). Os melhores valores estão em negrito.

Função	Algoritmos	Melhor	Mediano	Pior	$f(\mathbf{x}_{\text{melhor}})$	Sucesso
<i>Ellipsoidal</i>	<b>G3-PCX</b>	<b>5.826</b>	<b>6.800</b>	<b>7.728</b>	<b><math>10^{-20}</math></b>	<b>10/10</b>
	SPC-vSBX	49.084	50.952	57.479	$10^{-20}$	10/10
	SPC-PNX	36.360	39.360	40.905	$10^{-20}$	10/10
	<b><math>q</math>-gradiente</b>	<b>5.905</b>	<b>7.053</b>	<b>7.381</b>	<b><math>10^{-20}</math></b>	<b>50/50</b>
	$q$ -GC	8.914	9.260	9.486	$10^{-20}$	50/50
Schwefel	<b>G3-PCX</b>	<b>13.988</b>	<b>15.602</b>	<b>17.188</b>	<b><math>10^{-20}</math></b>	<b>10/10</b>
	SPC-vSBX	260.442	294.231	334.743	$10^{-20}$	10/10
	SPC-PNX	236.342	283.321	299.301	$10^{-20}$	10/10
	$q$ -gradiente	289.174	296.103	299.178	$10^{-20}$	50/50
	$q$ -GC	81.913	83.117	84.311	$10^{-20}$	50/50
Rosenbrock	<b>G3-PCX</b>	<b>16.508</b>	<b>21.452</b>	<b>25.520</b>	<b><math>10^{-20}</math></b>	<b>36/50</b>
	SPC-vSBX	$10^6$	-	-	$10^{-4}$	48/50
	SPC-PNX	$10^6$	-	-	$10^{-10}$	38/50
	$q$ -gradiente	$10^6$	-	-	$10^{-10}$	50/50
	$q$ -GC	$10^6$	-	-	$10^{-10}$	50/50

Tabela 2: Comparação entre os algoritmos sobre o conjunto de funções teste unimodais.

Para as funções unimodais (Tabela 2), o método  $q$ -GC apresenta um desempenho superior ao método  $q$ -G e dos AGs SPC-vSBX e SPC-PNX, mas é superado pelo AG G3-PCX. Note que o método  $q$ -GC atinge a precisão desejada em todas as 50 execuções. Para as funções multimodais (Tabela 3), tanto o método  $q$ -GC quanto o método  $q$ -G são claramente superiores aos AGs. Porém, o método  $q$ -GC é melhor que o método  $q$ -G pois atinge a precisão desejada com um maior número de sucessos ou um menor número de avaliações da função objetivo. Para a função Rastrigin Rotacionada, por exemplo, enquanto os três AGs foram incapazes de encontrar a bacia do mínimo global, o método  $q$ -GC conseguiu atingir essa bacia em 84% das execuções, contra

Função	Algoritmos	Melhor	Mediano	Pior	$f(\mathbf{x}_{\text{melhor}})$	Sucesso
Ackley	G3-PCX	$10^6$	-	-	3.959	0
	SPC-vSBX	57.463	63.899	65.902	$10^{-10}$	10/10
	SPC-PNX	45.736	48.095	49.392	$10^{-10}$	10/10
	$q$ -gradiente	11.850	12.465	13.039	$10^{-15}$	50/50
	<b><math>q</math>-GC</b>	<b>11.295</b>	<b>11.424</b>	<b>11.522</b>	<b><math>10^{-15}</math></b>	<b>50/50</b>
Rastrigin	G3-PCX	$10^6$	-	-	15.936	0
	SPC-vSBX	260.685	306.819	418.482	$10^{-20}$	6/10
	SPC-PNX	$10^6$	-	-	4.975	0
	$q$ -gradiente	676.050	692.450	705.037	$10^{-20}$	48/50
	<b><math>q</math>-GC</b>	<b>778.824</b>	<b>796.662</b>	<b>814.698</b>	<b><math>10^{-20}</math></b>	<b>50/50</b>
Rotacionada	G3-PCX	$10^6$	-	-	309.429	0
	SPC-vSBX	$10^6$	-	-	8.955	0
	SPC-PNX	$10^6$	-	-	3.980	0
	$q$ -gradiente	541.857	545.957	549.114	$10^{-20}$	20/50
	<b><math>q</math>-GC</b>	<b>803.485</b>	<b>824.482</b>	<b>857.909</b>	<b><math>10^{-20}</math></b>	<b>42/50</b>

Tabela 3: Comparação entre os algoritmos sobre o conjunto de funções teste multimodais.

apenas 40% apresentado pelo  $q$ -G.

## 4 Conclusões

Este trabalho apresenta uma  $q$ -versão do método dos gradientes conjugados, denominada método  $q$ -GC, baseado no conceito do vetor  $q$ -gradiente desenvolvido em [10]. A principal ideia por trás do método é a transição entre busca global, no início, e busca local, no final, do procedimento iterativo, com a presença de mecanismos que permitem que o método escape de mínimos locais e caminhe cada vez mais na direção do mínimo global. O método  $q$ -GC foi comparado com o método  $q$ -G (veja [10]) e com três AGs (veja [1, 2]), para seis funções teste da literatura. Embora preliminares, o desempenho do método  $q$ -GC é promissor, especialmente quando aplicado em funções multimodais.

## Referências

- [1] P. J. Ballester e J. N. Carter, An effective real-parameter genetic algorithm with parent centric normal crossover for multimodal optimisation, em “Genetic and Evolutionary Computation Conference - GECCO 2004” (K. Deb, ed.) pp. 901-913, Springer-Verlag, Seattle, WA, 2004.
- [2] K. Deb, A. Anand e D. Joshi, A computationally efficient evolutionary algorithm for real-parameter optimization, *Evolutionary Computation*, 10 (2002) 345-369.
- [3] G. Di Pillo e L. Palagi, Nonlinear programming: Introduction, em “Handbook of applied optimization” (P. M. Pardalos e M. G. C. Resende) pp. 263-268, Oxford University Press, New York, 2002.

- [4] R. Fletcher e C. M. Reeves, Function minimization by conjugate gradients, *Computer Journal*, 07 (1964) 149-154.
- [5] H. Huang, Global Optimization: Filled Function Methods, em “Encyclopedia of Optimization, Second Edition” (C. A. Floudas e P. M. Pardalos, eds.) pp. 1316-1323, Springer, New York, 2009.
- [6] F. H. Jackson, On  $q$ -functions and a certain difference operator, *Trans. Roy Soc. Edin.*, 46 (1908) 253-281.
- [7] F. H. Jackson, On  $q$ -definite integrals, *Quart. J. Pure and Appl. Math.*, 41 (1910) 193-203.
- [8] F. H. Jackson,  $q$ -Difference Equations, *American Journal of Mathematics*, 32, (1910) 307-314.
- [9] J. Nocedal e S. J. Wright, “Numerical Optimization”, Springer-Verlag, New York, 1999.
- [10] A. C. Soterroni, R. L. Galski e F. M. Ramos, The  $q$ -gradient method for global optimization, *arXiv:1209.2084*, math.OA (2012).
- [11] G. N. Vanderplaats, “Numerical optimization techniques for engineering design”, McGraw-Hill, New York, 1984.