

## Métodos de Gradiente Conjugado com Busca Linear Inexata<sup>1</sup>

B.P.B. SILVA, C.H. dos SANTOS, J.J. ROSSETTO, M. CARDIA, N.M.P. VOLPI,  
Y. JIAHONG, Departamento de Matemática, UFPR, 81531-990 Curitiba, PR,  
Brasil.

**Este trabalho é dedicado à memória da Professora Beatriz P. de Barros e Silva falecida em 3 de abril de 2000.**

**Resumo.** Neste trabalho apresentamos uma família de métodos de gradiente conjugado. Definimos uma direção de busca que depende de dois parâmetros e nem sempre satisfaz o critério das direções conjugadas, mas que, de certa forma, é uma aproximação da direção de Newton. Com uma escolha conveniente dos parâmetros, obtemos alguns dos métodos conhecidos na literatura. Testes computacionais foram realizados para comparar os novos métodos obtidos.

### 1. Introdução

Os métodos de gradiente conjugado têm despertado muito interesse para a resolução de problemas de minimização sem restrições de grande porte, devido a sua grande vantagem de não precisar guardar qualquer matriz, obtendo com isso um baixo custo computacional. Recentemente, vários autores têm considerado direções de busca que não satisfazem o critério das direções conjugadas, optando por aproximá-las, de alguma forma, da direção de Newton e em seguida fazendo uma busca linear inexata. Uma vasta literatura pode ser encontrada a respeito desse assunto, muitas das quais serão mencionadas no decorrer deste trabalho.

Seja o problema

$$\underset{x \in \mathbb{R}^n}{\text{minimizar}} f(x), \quad (1.1)$$

onde  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  é uma função com derivadas parciais contínuas.

Os métodos considerados neste trabalho geram os iterados

$$x_{k+1} = x_k + \alpha_k d_k, \quad (1.2)$$

$$d_{k+1} = -\theta_k g_{k+1} + \beta_k d_k, \quad (1.3)$$

---

<sup>1</sup>Apoio financeiro da FUNPAR

onde  $g_k$  denota  $g(x_k) = \nabla f(x_k)$  e

$$\beta_k = \frac{(\theta_k y_k - \frac{1}{s_k} p_k)^t g_{k+1}}{y_k^t d_k} \quad (1.4)$$

com  $y_k = g_{k+1} - g_k$  e  $p_k = x_{k+1} - x_k = \alpha_k d_k$ . Observemos que com uma escolha conveniente dos escalares  $\theta_k$  e  $s_k$  obtemos alguns dos métodos conhecidos na literatura. Seja  $\theta_k = 1$ . Se  $s_k = 1$  então, substituindo (1.4) em (1.3), temos a direção apresentada por Perry em [8]. Se  $s_k \rightarrow \infty$ , temos a direção de Hestenes-Stiefel [7]. Se a busca linear for exata, temos a direção de Polak-Ribière [9] e, se os sucessivos gradientes são ortogonais, temos a direção de Fletcher-Reeves [6]. Agora, se

$$\theta_k = \frac{p_k^t p_k}{p_k^t y_k} \quad (1.5)$$

e se  $s_k = 1$  então, (1.4) é a fórmula de Birgin-Martinez [2], que foi fortemente motivada pelos trabalhos de Barzilai-Borwein [1] e Raydan [10] e deu bons resultados computacionais.

Motivados pelo sucesso de Birgin-Martinez [2], considerando os bons resultados obtidos por Sherali-Ulular [13], que exigem que a direção de Perry [8] satisfaça equação

$$s_k d_{k+1} = -H_{k+1}^{-1} g_{k+1},$$

onde  $H_{k+1}$  é a hessiana de  $f$  em  $x_{k+1}$ , gerando  $\beta_k = (y_k - \frac{1}{s_k} p_k)^t g_{k+1} / y_k^t d_k$  e inspirados no trabalho de Dai-Yuan-Yuan [3] que é uma generalização, sob o ponto de vista de interpolação, dos trabalhos de Barzilai-Borwein [1] e Raydan [10], tomaremos outros valores para  $\theta_k$  e  $s_k$ . Seja  $\theta_k$  dado por (1.5) e consideremos

$$t_k = \theta_k^{-1} = \frac{p_k^t y_k}{p_k^t p_k}. \quad (1.6)$$

O modelo quadrático

$$q_{k+1} = f_{k+1} + \alpha g_{k+1}^t p_k + \frac{1}{2} t_k \alpha^2 \|p_k\|^2, \quad (1.7)$$

onde  $f_{k+1} = f(x_{k+1})$ , é uma aproximação para  $f(x_{k+1} + \alpha p_k)$ . É fácil ver que  $t_k$  dado por (1.6) satisfaz a condição de interpolação

$$\nabla q_{k+1}(-1) = g_k^t p_k. \quad (1.8)$$

Portanto,  $\theta_k$  dado por (1.5) é uma aproximação para a inversa da derivada direcional segunda de  $f$  em  $x_{k+1}$  ao longo de  $p_k$ .

Para qualquer  $t_k \in \mathbb{R}$ , o modelo quadrático (1.7) satisfaz as condições de interpolação

$$q_{k+1}(0) = f_{k+1} \quad (1.9)$$

e

$$\nabla q_{k+1}(0) = g_{k+1}^t p_k, \quad (1.10)$$

Se (1.8) é substituída por uma outra condição de interpolação

$$q_{k+1}(-1) = f_k, \quad (1.11)$$

então podemos obter de (1.7) que

$$t_k = \frac{2(f_k - f_{k+1} + g_{k+1}^t p_k)}{\|p_k\|^2} \quad (1.12)$$

donde

$$\theta_k = \frac{p_k^t p_k}{2(f_k - f_{k+1} + g_{k+1}^t p_k)}. \quad (1.13)$$

Além disso, podemos também construir um modelo cúbico

$$c_{k+1}(\alpha) = f_{k+1} + \alpha g_{k+1}^t p_k + \frac{1}{2} t_k \alpha^2 \|p_k\|^2 + \xi_k \alpha^3$$

tal que as condições (1.8)-(1.11) são todas satisfeitas, donde segue que

$$t_k = \frac{6(f_k - f_{k+1}) + 4g_{k+1}^t p_k + 2g_k^t p_k}{p_k^t p_k} \quad (1.14)$$

e, portanto,

$$\theta_k = \frac{p_k^t p_k}{6(f_k - f_{k+1}) + 4g_{k+1}^t p_k + 2g_k^t p_k}. \quad (1.15)$$

É fácil ver que as fórmulas (1.13) e (1.15) são idênticas a (1.5) se  $f$  é quadrática no segmento de reta  $x_k$  e  $x_{k+1}$ . Isto indica que se a função objetivo é quadrática (1.13) e (1.15) são exatamente os mesmos que (1.5). Então para uma função qualquer, como estamos usando as informações do valor da função e do valor do gradiente em  $x_k$  e  $x_{k+1}$  para derivar (1.13) e (1.15), é razoável esperar que estas duas fórmulas sejam melhores que (1.5).

Portanto, (1.3) e (1.4) nos dão uma estrutura unificada produzindo uma família de métodos de gradiente conjugado.

Observamos que as direções de Sherali-Ulular e de Birgin-Martinez serão paralelas se tomarmos o mesmo valor para os respectivos parâmetros  $s_k$  e  $\theta_k$ .

## 2. O Algoritmo

Nesta seção descreveremos um método que é uma combinação das idéias dos algoritmos de gradiente conjugado escalado de Birgin-Martinez [2] e Sherali-Ulular [13].

**Algoritmo 2.1:** Dados  $x_o \in \mathbb{R}^n$ ,  $c = 10^{-4}$ ,  $r = 0.9$  e  $\epsilon > 0$

### Inicialização

Faça

$$k = 0$$

$$d_0 = -g_0$$

**Repita**

$$\alpha_k = 1 \text{ ou } \left( \alpha_k = \begin{cases} 1, & \text{se } k = 0 \\ \alpha_{k-1} \frac{\|d_{k-1}\|}{\|d_k\|}, & \text{se } k \neq 0 \end{cases} \right)$$

$$\alpha = \alpha_k$$

Enquanto  $f(x_k + \alpha d_k) > f(x_k) + c\alpha g_k^t d_k$  ou  
 $g(x_k + \alpha d_k)^t d_k < r g_k^t d_k$  escolha  $\sigma \in [0.1, 0.5]$  e  
 faça  $\alpha = \sigma \alpha$ .

Fim

$$\alpha_k = \alpha$$

$$x_{k+1} = x_k + \alpha_k d_k$$

$$\beta_k = \frac{(\theta_k y_k - \frac{1}{s_k} p_k)^t g_{k+1}}{y_k^t d_k}, \text{ com } \theta_k = 1 \text{ (ou dado por (1.5) ou (1.13))}$$

$$\text{ou (1.15)) e } s_k = 1 \text{ (ou } s_k = \alpha_k)$$

$$d = -\theta_k g_{k+1} + \beta_k d_k$$

Se  $d^t g_{k+1} \leq -10^{-3} \|d\| \|g_{k+1}\|$  então  $d_{k+1} = d$ .

Senão,  $d_{k+1} = -\theta_k g_{k+1}$

$$k = k + 1$$

**Até que**  $\|g_k\| < \epsilon$

**Comentários:**

- A direção  $d = -\theta_k g_{k+1} + \beta_k d_k$  não é necessariamente uma direção de descida. E esta é a razão que motivou as várias modificações da fórmula de Perry [8] feitas por Shanno [11].
- Estamos usando como reinicialização o mesmo critério ingênuo de Birgin-Martinez [2]. Com isso estamos garantindo que  $d$  é uma direção de descida.
- Em Dennis-Schnabel [4] e Fletcher [5] é mostrado que um comprimento de passo  $\alpha$  satisfazendo

$$f(x_k + \alpha d_k) \leq f(x_k) + c\alpha g_k^t d_k \quad \text{e} \quad g(x_k + \alpha d_k)^t d_k \geq r g_k^t d_k$$

sempre existe se  $f$  é limitada inferiormente na direção  $d_k$ .

- Nas implementações também realizamos busca linear como em Shanno-Phua [12].

### 3. Resultados Numéricos e Conclusões

Os resultados numéricos foram obtidos usando os problemas testes de Sherali-Ulular [13]. Consideramos oito métodos diferentes com dois critérios para escolha do tamanho de passo inicial na busca linear. Os métodos foram identificados como na Tabela 1 abaixo:

Tabela 1

MÉTODO	$\theta_k$	$s_k$
$M_1$	$p_k^t p_k / p_k^t y_k$	$\alpha_k$
$M_2$	$p_k^t p_k / 2(f_k - f_{k+1} + g_{k+1}^t p_k)$	$\alpha_k$
$M_3$	1	$\alpha_k$
$M_4$	$p_k^t p_k / [6(f_K - f_{k+1}) + 4g_{k+1}^t p_k + 2g_k^t p_k]$	$\alpha_k$
$M_5$	$p_k^t p_k / p_k^t y_k$	1
$M_6$	$p_k^t p_k / 2(f_k - f_{k+1} + g_{k+1}^t p_k)$	1
$M_7$	1	1
$M_8$	$p_k^t p_k / [6(f_K - f_{k+1}) + 4g_{k+1}^t p_k + 2g_k^t p_k]$	1

Os resultados da Tabela 2 correspondem a escolha do passo inicial na busca linear de  $\alpha_k = 1$  e os da Tabela 3 para  $\alpha_k = \begin{cases} 1 & \text{se } k = 0, \\ \alpha_{k-1} \frac{\|d_{k-1}\|}{\|d_k\|} & \text{se } k \neq 0. \end{cases}$

Os valores representados nas colunas das Tabelas 2 e 3 são o número de iterações e o número de chamadas da função, exceto na primeira coluna, onde P é o número do problema e n é o número de variáveis.

Tabela 2

P/n	M1	M2	M3	M4	M5	M6	M7	M8
1/2	4/30	4/30	9/42	5/36	6/40	6/40	14/71	16/79
2/2	28/184	27/202	35/113	24/116	43/237	37/208	33/180	14/102
3/4	130/461	102/366	216/647	118/357	164/643	254/857	53/242	250/836
4/4	100/388	169/630	115/355	116/436	105/485	78/307	52/209	108/420
5/2	30/93	11/44	16/66	9/55	35/102	9/39	12/48	12/71
6/5	126/469	137/470	172/454	203/597	143/556	131/500	153/466	97/374
6/10	356/929	343/885	277/647	271/759	225/702	252/779	347/881	227/713
7/20	22/61	25/64	18/61	25/56	24/56	17/51	35/101	34/87
7/40	34/93	36/92	28/81	38/101	27/66	36/93	64/149	40/108
7/200	87/209	96/255	77/170	110/261	93/246	79/220	96/221	90/235
8/3	51/267	94/333	84/243	56/218	57/231	83/279	80/260	70/275
9/5	304/937	266/874	201/535	209/657	235/684	271/886	368/1024	248/690
10/10	8/60	8/60	7/54	9/62	9/65	8/61	9/87	5/50

Tabela 3

P/n	M1	M2	M3	M4	M5	M6	M7	M8
1/2	7/37	7/37	4/21	11/54	6/16	6/16	7/107	7/20
2/2	23/215	28/190	26/185	22/153	34/209	28/137	28/196	21/124
3/4	150/608	434/1801	160/1181	115/450	111/420	54/198	88/593	234/868
4/4	69/368	97/547	42/224	82/377	179/1043	35/165	105/511	60/251
5/2	17/59	19/57	14/41	16/46	22/70	15/40	15/43	20/51
6/5	299/1343	355/1513	222/1664	112/390	197/711	173/632	67/477	121/390
6/10	437/1845	437/1916	454/3487	440/2938	224/804	255/868	131/958	193/791
7/20	24/52	27/61	158/204	25/57	21/32	24/35	156/222	26/62
7/40	50/124	35/85	184/251	38/104	47/94	35/58	169/270	29/69
7/200	72/240	71/241	130/352	70/206	71/167	66/163	120/360	64/160
8/3	38/145	68/231	44/296	65/215	57/190	59/212	64/418	65/185
9/5	172/640	223/859	158/785	175/296	176/711	156/636	144/733	157/568
10/10	7/25	7/25	6/84	7/25	7/15	7/15	7/76	7/15

Dos resultados numéricos obtidos concluímos que os métodos são competitivos, sendo que seu desempenho varia de acordo com o problema testado, com a escolha de um determinado parâmetro usado na busca linear (nossas tabelas apresentam os

resultados apenas com valor  $1/3$  para tal parâmetro) e com a escolha inicial para o tamanho do passo  $\alpha_k$  na busca linear.

Os autores deste trabalho agradecem ao Prof. Dr. Jin Yun Yuan (UFPR) pelos comentários e sugestões recebidas.

## Referências

- [1] J. Barzilai, J.M. Borwein, Two-point stepsize gradient methods, *IMA J. Num. Anal.*, **8** (1988), 141-148.
- [2] E.G. Birgin, J.M. Martinez, A spectral conjugate gradient method for unconstrained optimization, Technical Report, IMECC, Universidade de Campinas, 1998.
- [3] Y.H. Dai, Y.J. Yuan, Y. Yuan, Modified two-point stepsize gradient methods for unconstrained optimization, Relatório Técnico, Departamento de Matemática, Universidade Federal do Paraná, 1998.
- [4] J.E. Dennis Jr, R.B. Schnabel, "Numerical methods for unconstrained optimization and nonlinear equations", Prentice-Hall, Englewood Cliffs, 1983.
- [5] R. Fletcher, "Practical methods of optimization", John-Wiley and Sons, New York, 1987.
- [6] R. Fletcher, C.M. Reeves, Function minimization by conjugate gradient, *Comput. J.*, **7** (1964), 149-154.
- [7] M.R. Hestenes, E. Stiefel, Methods of conjugate gradients for solving linear systems, *J. Res. Bur. Standards Sec.*, **48** (1952), 429-436.
- [8] A. Perry, A modified conjugate gradient algorithm, *Operations Research*, **26** (1978), 1073-1078.
- [9] E. Polak, G. Ribière, Note sur la convergence de méthodes de directions conjuguées, *Revue Française d'Informatique et de Recherche Opérationnelle*, **16** (1969), 35-43.
- [10] M. Raydan, The Barzilai and Borwein gradient method for the large scale unconstrained minimization problem, *SIAM J. Optim.*, **7** (1997), 26-33.
- [11] D.F. Shanno, Conjugate gradient method with inexact searches, *Mathematics of Operations Research*, **3** (1978), 244-256.
- [12] D.F. Shanno, K.H. Phua, Minimization of unconstrained multivariate functions, *ACM Transactions on Mathematical Software*, **2** (1976), 87-94.
- [13] H.D. Sherali, O. Ulular, Conjugate gradient methods using quasi-Newton updates with inexact line searches, *Journal of Mathematical Analysis and Applications*, **150** (1990), 359-377.