

# Um método de pontos interiores para resolução de problemas lineares discretos mal-postos

Emídio Santos Portilho Júnior<sup>1</sup>  
 CECE/UNIOESTE, Foz do Iguaçu, PR  
 Aurelio Ribeiro Leite de Oliveira<sup>2</sup>  
 IMECC/UNICAMP, Campinas, PR

**Resumo.** Dada a importância e a dificuldade em se obter resultados satisfatórios via métodos diretos para solução de problemas lineares discretos mal-postos oriundos da discretização de problemas inversos lineares. Neste trabalho, nós retomamos o método de pontos interiores do tipo Preditor-Corretor apresentado em [5] que aproxima o problema de regularização de Tikhonov por um problema de programação quadrática através de uma formulação Primal-Dual com barreira logarítmica. Este método Preditor-Corretor nos leva a sistemas de equações normais que são resolvidos pelo método dos gradientes conjugados preconditionado com o preconditionador separador. Neste trabalho, a fim de reduzir o número de iterações de pontos interiores e do método dos gradientes conjugados preconditionado [8], propomos a utilização do preconditionador Fatoração Controlada de Cholesky [1].

**Palavras-chave.** Regularização de Tikhonov, Programação Quadrática, Métodos de Pontos Interiores.

## 1 Introdução

A discretização de um problema inverso comumente fornece um sistema linear de equações

$$Ax = b, \quad A \in \mathbb{R}^{m \times n}, \quad x \in \mathbb{R}^n, \quad b \in \mathbb{R}^m \quad (1)$$

Quando os valores singulares da matriz dos coeficientes deste sistema se acumulam próximos à origem e decaem gradualmente a zero, isso torna a matriz severamente mal-condicionada. Tais sistemas são frequentemente chamados de problemas lineares discretos e mal-postos [6].

O método de regularização de Tikhonov é um dos mais antigos e mais populares métodos de regularização. Este método aproxima o sistema linear (1) pelo sistema regularizado

$$(A^T A + \alpha^2 I)x = A^T b, \quad (2)$$

onde  $\alpha \geq 0$  é o parâmetro de regularização que determina a quantidade de regularização e  $I$  é o operador identidade.

Em muitos problemas, a matriz  $A$  tem muitos valores singulares pequenos, o que acaba acarretando um mal condicionamento da matriz  $A$  e conseqüentemente de  $A^T A$ , visto que os autovalores de  $A^T A$  são os valores singulares de  $A$  elevados ao quadrado. Além disso, em geral o vetor  $b$

<sup>1</sup>emidio.portilho@gmail.com.

<sup>2</sup>aurelio@ime.unicamp.br.

está contaminado por erros de medidas (ruídos). Neste trabalho, assumiremos que os erros estão restritos ao lado direito do sistema (1), isto é, dado  $b$  podemos escrever

$$b = \bar{b} + e \quad \bar{b} = A\bar{x},$$

onde  $\bar{b}$  representa os dados exatos não perturbados,  $\bar{x} = A^\dagger \bar{b}$  representa a solução exata e o vetor  $e$  representa os erros nos dados.

A solução  $x$  de um problema mal-posto obtida via métodos diretos está com frequência associada a um valor elevado de  $\|x\|_2$ , veja [7]. Em vista disso o método apresentado por Tikhonov e Arsenin em [7] tem por objetivo obter soluções do sistema de equações lineares  $Ax = b$  com norma pequena, do que é proposto resolver o problema de minimização:

$$\min_x \|x\|_2, \text{ sujeito a } \|b - Ax\|_2 \leq \mathbf{T}_0 \quad (3)$$

onde  $\mathbf{T}_0$  é o valor máximo da norma do resíduo que estamos dispostos a aceitar. Sendo assim, estamos diante de um problema de minimização com restrições de desigualdade.

No trabalho [5], o problema de minimização (3) foi aproximado por um problema de programação quadrática através de uma formulação Primal-Dual que deu origem a um método Preditor-Corretor capaz de obter uma solução para o problema de minimização (3). Este método Preditor-Corretor da origem a sistemas de equações normais que são resolvidos via método dos gradientes conjugados preconditionado com o preconditionador separador. Neste trabalho, a fim de reduzir o número de iterações de pontos interiores e do método dos gradientes conjugados preconditionado [8], propomos a utilização do preconditionador Fatoração Controlada de Cholesky [1].

## 2 Métodos de Pontos Interiores

Em [5], para desenvolver o método de pontos interiores (MPI) para o problema de regularização de Tikhonov, nós aproximamos o problema de minimização (3) pelo problema (4), que procura soluções com propriedades similares as requeridas pelo problema (3):

$$\begin{cases} \min_{x,u,v} & \frac{\tau}{2} \|x\|_2^2 + e^T(u+v) \\ \text{sujeito a} & Ax + u - v = b. \\ & (u, v) \geq 0 \text{ e } x \in \mathbb{R}^n. \end{cases} \quad (4)$$

Trata-se de um problema de programação quadrática com restrições lineares, onde  $A$  é uma matriz de posto completo  $m \times n$ ,  $b$  e  $x$  são vetores colunas de dimensões apropriadas. Além disso,  $e$  é um vetor com todas as entradas iguais a 1 e  $u$  e  $v$  são variáveis não negativas. O valor  $\tau > 0$  representa um parâmetro de penalização para valores grandes de  $\|x\|_2$ .

Associado ao problema primal (4), temos o problema de programação quadrática dual:

$$\begin{cases} \max_{x,y,z,w} & -\frac{\tau}{2} \|x\|^2 + y^T b \\ \text{sujeito a} & \tau x - A^T y = 0 \\ & e - y - z = 0 \\ & e + y - w = 0 \\ & (z, w) \geq 0 \text{ e } y \in \mathbb{R}^m. \end{cases} \quad (5)$$

Aplicando os mesmos passos de [9] aos problemas (4) e (5) obtemos um método de pontos interiores do tipo preditor-corretor cujo a estrutura é dada pelo Algoritmo 1.

---

**Algoritmo 1:** Etapas do PCM

---

**Dados:**  $(x^0, u^0, v^0, y^0, z^0, w^0)$  com  $(u^0, v^0, z^0, w^0) > 0$

**Resultado:** Solução do PCM

**para**  $k = 1, 2, \dots$  **faça**

1.  $\mu^k = \frac{u_k^T z_k + v_k^T w_k}{2n}$ ;
2.  $\dot{q}^k = r_b^k + U^k(e - (Z^k)^{-1}r_z^k) + V^k(-e^k + (W^k)^{-1}r_w^k)$
3.  $(\Theta^k)^{-1} = (Z^k)^{-1}(U^k) + (W^k)^{-1}V^k$
4.  $\Delta x^{af} = (A^T \Theta^k A + \tau I_n)^{-1}(A^T \Theta^k \dot{q}^k + r_y^k)$
5.  $\Delta y^{af} = \Theta^k(\dot{q}^k - A \Delta x^{af})$
6.  $\Delta z^{af} = -r_z^k - \Delta y^{af}$
7.  $\Delta w^{af} = \Delta y^{af} - r_w^k$
8.  $\Delta u^{af} = -U^k e + (Z^k)^{-1}U^k r_z + (Z^k)^{-1}U^k \Delta y^{af}$
9.  $\Delta v^{af} = -V^k e + (W^k)^{-1}V^k r_w - (W^k)^{-1}V^k \Delta y^{af}$
10. Obtenha  $\alpha_u^{af}, \alpha_v^{af}, \alpha_z^{af}$  e  $\alpha_w^{af}$
11.  $\alpha^{af} = \beta^k \min \{ \alpha_u^{af}, \alpha_v^{af}, \alpha_z^{af}, \alpha_w^{af} \}$  onde  $\beta^k \in (0, 1)$
12.  $\mu_{af}^k = \frac{(u^k + \alpha_u^{af} \Delta u^{af})(z^k + \alpha_z^{af} \Delta z^{af}) + (v^k + \alpha_v^{af} \Delta v^{af})(w^k + \alpha_w^{af} \Delta w^{af})}{2n}$
13.  $\sigma_k = \left( \frac{\mu_{af}^k}{\mu^k} \right)^3$
14.  $\ddot{q} = (Z^k)^{-1}(-\sigma_k \mu^k e + \Delta U^{af} \Delta Z^{af} e) + (W^k)^{-1}(\sigma_k \mu^k e - \Delta V^{af} \Delta W^{af} e)$
15.  $(\Theta^k)^{-1} = (Z^k)^{-1}(U^k) + (W^k)^{-1}V^k$
16.  $\Delta x^{cc} = (A^T \Theta^k A + \tau I_n)^{-1}(A^T \Theta^k \ddot{q}^k)$
17.  $\Delta y^{cc} = \Theta^k(\ddot{q}^k - A \Delta x^{cc})$
18.  $\Delta z^{cc} = -\Delta y^{cc}$
19.  $\Delta w^{cc} = \Delta y^{cc}$
20.  $\Delta u^{cc} = (Z^k)^{-1}(\sigma_k \mu^k e - \Delta U^{af} \Delta Z^{af} e + U^k \Delta y^{cc})$
21.  $\Delta v^{cc} = (W^k)^{-1}(\sigma_k \mu^k e - \Delta V^{af} \Delta W^{af} e - V^k \Delta y^{cc})$
22. Obtenha a direção de descida  $d^k = d_k^{af} + d_k^{cc}$
23. Calcule o comprimento de passo  $\alpha^k = \beta^k \min \{ \rho_u, \rho_v, \rho_w, \rho_z \}$  onde:  

$$\beta^k \in (0, 1), \text{ e } \rho_u = \min_i \left\{ -\frac{u_i^k}{\Delta u_i^k} \mid \Delta u_i^k < 0 \right\}, \rho_v = \min_i \left\{ -\frac{v_i^k}{\Delta v_i^k} \mid \Delta v_i^k < 0 \right\},$$

$$\rho_w = \min_i \left\{ -\frac{w_i^k}{\Delta w_i^k} \mid \Delta w_i^k < 0 \right\}, \rho_z = \min_i \left\{ -\frac{z_i^k}{\Delta z_i^k} \mid \Delta z_i^k < 0 \right\};$$
24.  $(\mathbf{x}_{k+1}, \mathbf{y}_{k+1}) = (\mathbf{x}_k, \mathbf{y}_k) + \alpha^k d^k$

**fim**

---

Neste algoritmo valem as seguintes igualdades:  $\alpha_u^{af} = \operatorname{argmax} \{ \alpha \in (0, 1] : u^k + \alpha \Delta u^{af} > 0 \}$ ,  $\alpha_v^{af} = \operatorname{argmax} \{ \alpha \in (0, 1] : v^k + \alpha \Delta v^{af} > 0 \}$ ,  $\alpha_z^{af} = \operatorname{argmax} \{ \alpha \in (0, 1] : z^k + \alpha \Delta z^{af} > 0 \}$ ,  $\alpha_w^{af} = \operatorname{argmax} \{ \alpha \in (0, 1] : w^k + \alpha \Delta w^{af} > 0 \}$ ,  $Z^k = \operatorname{diag}(z_1^k, z_2^k, \dots, z_m^k)$ ,  $U^k = \operatorname{diag}(u_1^k, u_2^k, \dots, u_m^k)$ ,  $W^k = \operatorname{diag}(w_1^k, w_2^k, \dots, w_m^k)$ ,  $V^k = \operatorname{diag}(v_1^k, v_2^k, \dots, v_m^k)$ ,  $r_b^k = b - Ax^k - u^k + v^k$ ,  $r_y^k = A^T y^k - \tau x^k$ ,  $r_z^k = z^k + y^k - e$  e  $r_w^k = w^k - y^k - e$ .

Na etapa 4 do Algoritmo 1 nos deparamos com sistemas de equações normais. Para resolver tais sistemas utilizamos o Método dos Gradientes Conjugados Precondicionado (MGCP) [8].

Nós implementamos duas versões do Algoritmo 1, a primeira versão utilizando o preconditionador separador desenvolvido em [3]. Vamos nos referir a esta combinação como MPCLU. A segunda versão foi implementada utilizando a Fatoração Controlada de Cholesky proposta por [1]. A esta combinação iremos nos referir como MPCFCC.

Mais detalhes sobre as formulações MPCLU e MPCFCC podem ser encontras em [4].

### 3 Resultados Numéricos

Todos os resultados numéricos foram desenvolvidos em MATLAB R2013b com sistema operacional 64-bit Windows 10, processador Intel Core I7-8550U, 1.99 Ghz, 16 GB de memória RAM. Os códigos para calcular a discretização dos exemplos deste trabalho provêm dos pacotes disponibilizados em [2]. Consideramos que o lado direito dos sistemas está contaminado por ruídos, ou seja,  $b = \bar{b} + e$ , em que  $e$  refere-se a um vetor aleatório normalizado escolhido de tal forma que  $\|e\|/\|\bar{b}\| = \epsilon > 0$ . Iremos nos referir ao quociente  $NL = \|e\|/\|\bar{b}\|$  como nível de ruído. Para os testes numéricos assumimos  $\tau = 5 \times 10^{-3}$ .

A fim de comparar a eficiência do MPCFCC e do MPCLU, iremos comparar os resultados obtidos por ambos os métodos na resolução dos problemas de teste Baart, Shaw e Phillips com níveis de ruído  $NL = 10^{-3}$ ,  $NL = 10^{-4}$  e  $NL = 10^{-5}$  respectivamente. Nós testamos ambos os métodos para várias dimensões dos problemas de teste. Apresentamos os resultados nas tabelas a seguir:

Tabela 1: MPCFCC aplicado à matriz de Baart.

Dimensão	It	Itgcp	Erd	Eri	$t_{cpu}$
250	8	148	$1,158 \times 10^{-1}$	$2,403 \times 10^{-4}$	$2,809 \times 10^{-1}$
500	9	129	$1,201 \times 10^{-1}$	$1,635 \times 10^{-4}$	$6,022 \times 10^{-1}$
1000	10	131	$7,760 \times 10^{-2}$	$5,332 \times 10^{-5}$	$2,841 \times 10^{+0}$
2000	10	131	$1,058 \times 10^{-1}$	$4,386 \times 10^{-4}$	$2,312 \times 10^{+1}$
5000	11	147	$1,101 \times 10^{-1}$	$2,134 \times 10^{-5}$	$5,811 \times 10^{+2}$

Tabela 2: MPCLU aplicado à matriz de Baart.

Dimensão	It	Itgcp	Erd	Eri	$t_{cpu}$
250	9	148	$1,145 \times 10^{-1}$	$2,204 \times 10^{-4}$	$4,127 \times 10^{-1}$
500	11	158	$1,300 \times 10^{-1}$	$1,657 \times 10^{-4}$	$5,723 \times 10^{-1}$
1000	10	164	$1,573 \times 10^{-1}$	$6,239 \times 10^{-5}$	$1,742 \times 10^{+0}$
2000	12	201	$7,130 \times 10^{-2}$	$3,557 \times 10^{-5}$	$8,885 \times 10^{+0}$
5000	10	165	$8,060 \times 10^{-2}$	$3,120 \times 10^{-5}$	$5,365 \times 10^{+1}$

Tabela 3: MPCFCC aplicado à matriz de Shaw.

Dimensão	It	Itgcp	Erd	Eri	$t_{cpu}$
250	13	332	$3,250 \times 10^{-2}$	$1,474 \times 10^{-5}$	$3,200 \times 10^{-1}$
500	13	332	$3,360 \times 10^{-2}$	$9,887 \times 10^{-6}$	$7,339 \times 10^{-1}$
1000	14	354	$3,340 \times 10^{-2}$	$8,180 \times 10^{-6}$	$3,478 \times 10^{+0}$
2000	14	343	$3,350 \times 10^{-2}$	$6,793 \times 10^{-6}$	$2,598 \times 10^{+1}$
3000	15	372	$3,310 \times 10^{-2}$	$6,273 \times 10^{-7}$	$8,920 \times 10^{+1}$

Tabela 4: MPCLU aplicado à matriz de Shaw.

Dimensão	It	Itgcp	Erd	Eri	$t_{cpu}$
250	12	344	$3,170 \times 10^{-2}$	$1,283 \times 10^{-5}$	$4,074 \times 10^{-1}$
500	12	337	$3,450 \times 10^{-2}$	$1,144 \times 10^{-5}$	$8,760 \times 10^{-1}$
1000	15	396	$3,230 \times 10^{-2}$	$5,710 \times 10^{-6}$	$4,019 \times 10^{+0}$
2000	14	356	$3,310 \times 10^{-2}$	$7,223 \times 10^{-6}$	$1,500 \times 10^{+1}$
3000	15	382	$3,360 \times 10^{-2}$	$6,546 \times 10^{-6}$	$3,363 \times 10^{+2}$

Tabela 5: MPCFCC aplicado à matriz de Phillips.

Dimensão	It	Itgcp	Erd	Eri	$t_{cpu}$
252	9	285	$1,180 \times 10^{-2}$	$6,052 \times 10^{-4}$	$2,707 \times 10^{-1}$
504	11	377	$1,440 \times 10^{-2}$	$5,890 \times 10^{-4}$	$6,451 \times 10^{-1}$
1024	12	417	$1,480 \times 10^{-2}$	$3,644 \times 10^{-4}$	$3,200 \times 10^{+0}$
2048	13	502	$1,210 \times 10^{-2}$	$4,740 \times 10^{-4}$	$2,557 \times 10^{+1}$
4096	12	458	$1,120 \times 10^{-2}$	$4,235 \times 10^{-4}$	$2,876 \times 10^{+2}$

Tabela 6: MPCLU aplicado à matriz de Phillips.

Dimensão	It	Itgcp	Erd	Eri	$t_{cpu}$
252	10	385	$1,000 \times 10^{-2}$	$3,143 \times 10^{-4}$	$3,817 \times 10^{-1}$
504	11	429	$1,250 \times 10^{-2}$	$3,563 \times 10^{-4}$	$9,546 \times 10^{-1}$
1024	12	458	$9,000 \times 10^{-3}$	$3,182 \times 10^{-4}$	$4,547 \times 10^{+0}$
2048	13	512	$1,170 \times 10^{-2}$	$3,919 \times 10^{-4}$	$2,302 \times 10^{+1}$
4096	12	466	$1,160 \times 10^{-2}$	$5,213 \times 10^{-4}$	$1,038 \times 10^{+2}$

A primeira coluna das tabelas nos informa a dimensão das matrizes, a segunda coluna fornece o número de iterações de métodos de pontos interiores que foram necessárias para resolver o problema, ao passo que a terceira fornece o número de iterações do MGCP necessárias durante toda a execução do método de pontos interiores em questão. Uma vez que a solução exata  $\mathbf{x}$  é conhecida, as colunas Erd e Eri representam respectivamente os erros relativos cometidos:  $Erd = \|\mathbf{x}^k - \mathbf{x}\|_2 / \|\mathbf{x}\|_2$  e  $Eri = \|A\mathbf{x}^k - b\|_2 / \|b\|_2$ . Por fim,  $t_{cpu}$  representa o tempo em segundos demandados pelo método para resolução do problema.

Para o problema de Baart as iterações de MPI e iterações de MGCP do método MPCFCC se mostrou competitivo com o método MPCLU, ele também se mostrou competitivo no quesito tempo computacional, exceto para ordem  $n = 5000$ .

Já para o problema de teste Shaw, o número de iterações de ponto interior e de MGCP dos métodos MPCFCC e MPCLU tiveram resultados bem próximos e podemos dizer o mesmo com relação à precisão dos resultados alcançados pelos mesmos. Na maior parte dos casos, o tempo de processamento do MPCFCC obteve resultados melhores do que o método MPCLU.

Por fim, para o problema de Phillips o número iterações de MPI foram os mesmos em quase todos os casos. Mas, o número de iterações de MGCP foram menores em todos os casos. No entanto, os resultados de tempo de processamento  $t_{cpu}$  do MPCFCC se tornaram maiores do que os do MPCLU a partir da ordem  $n = 2048$ . Isto se deve à necessidade de atualizar o preconditionador Fatoração Controlada de Cholesky quando o mesmo perde eficiência.

## 4 Conclusões

Neste trabalho, o cálculo das direções de busca do método Preditor-Corretor nos levaram a sistemas de equações normais. Estes sistemas de equações normais foram resolvidos pelo Método dos Gradientes Conjugados Precondicionado. Sendo os preconditionadores utilizados o Precondicionador Separador e a Fatoração Controlada de Cholesky.

De modo geral podemos dizer que o MPCLU e o MPCFCC obtiveram ordem de precisão das soluções bastante similares. Também, o número de iterações de MPI de ambos os métodos se mostraram bem próximos para os exemplos utilizados. No entanto, na maior parte dos casos o método MPCFCC obteve êxito em diminuir o número de iterações de MGCP no decorrer das iterações de MPI.

Concluimos que embora sejam necessários mais testes, os resultados obtidos com a implementação dos métodos no software MATLAB, mostram que o MPCFCC pode ser competitivo com o MPCLU.

## Referências

- [1] Campos, F. F. Analysis of conjugate gradient-type methods for solving linear equations, Tese de Doutorado, University of Oxford, 1995.
- [2] Hansen, P. C. Regularization tools version 4.0 for matlab 7.3. *Numer. Algorithms*, volume 46, pages 189–194, 2007. DOI: 10.1007/s11075-007-9136-9.
- [3] Oliveira, A. R. L.; Sorensen, D. A new class of preconditioners for large-scale linear systems from interior point methods for linear programming, *Linear Algebra and its applications*, Elsevier, volume 394, pages 1–24, 2005. DOI: 10.1016/j.laa.2004.08.019.
- [4] Portilho Jr, E. S. Métodos de pontos interiores para resolução de problemas de regularização de Tikhonov de grande porte, Tese de Doutorado, Unicamp, 2020.

- [5] Portilho Jr, E. S.; Oliveira, A. R. L. Métodos de pontos interiores para resolução de problemas de regularização de Tikhonov de grande porte, *Anais do X Encontro Regional de Matemática Aplicada e Computacional do Rio Grande do Sul – ERMAC-RS*, 2020. ISBN: 978-65-5623-103-7
- [6] Rezghi, R. and Hosseini, S. M. A new variant of l-curve for tikhonov regularization, *Journal of Computational and Applied Mathematics*, Elsevier, volume 231, pages 914–924, 2009. DOI: 10.1016/j.cam.2009.05.016.
- [7] Tikhonov, A. N.; Aarsenin, V. Y. *Solution of ill-posed problems*. V.H. Winston & Sons, Washington DC, 1977.
- [8] Trefethen, L. N.; Bau, D. *Numerical Linear Algebra*. Society for Industrial and Applied Mathematics, 1997.
- [9] Zhang, Y. A primal-dual interior point approach for computing  $l_1$  and  $l_\infty$  solutions of over-determined linear systems, *J. Optim. Theory Appl.*, volume 77(2), pages 323–341, 1993. DOI:10.1007/BF00940715.