

矩阵方程 $AXB + CX^T D = E$ 自反最佳逼近解的迭代算法

杨家稳¹, 孙合明²

(1. 滁州职业技术学院基础部, 安徽 滁州 239000)
(2. 河海大学理学院, 江苏 南京 210098)

摘要: 本文研究了 Sylvester 矩阵方程 $AXB + CX^T D = E$ 自反(或反自反)最佳逼近解. 利用所提出的共轭方向法的迭代算法, 获得了一个结果: 不论矩阵方程 $AXB + CX^T D = E$ 是否相容, 对于任给初始自反(或反自反)矩阵 X_1 , 在有限迭代步内, 该算法都能够计算出该矩阵方程的自反(或反自反)最佳逼近解. 最后, 三个数值例子验证了该算法是有效性的.

关键词: Sylvester 矩阵方程; Kronecker 积; 共轭方向法; 最佳逼近解; 自反矩阵

MR(2010) 主题分类号: 15B57 中图分类号: O241.5

文献标识码: A 文章编号: 0255-7797(2015)05-1275-12

1 引言

首先介绍文中的符号: $\Re^{m \times n}$ 表示 $m \times n$ 阶实矩阵的集合, I 表示单位矩阵, A^T 表示矩阵 A 的转置, $A \otimes B$ 表示矩阵 A 与矩阵 B 的 Kronecker 积. $\langle A, B \rangle = \text{trace}(B^T A)$, $\|A\|$ 表示矩阵 A 的 Frobenius 范数, $\|A\|^2 = \langle A, A \rangle$, $\|\alpha\|_2$ 表示向量 α 的 2 - 范数, $\|\alpha\|_2^2 = \langle \alpha, \alpha \rangle$. 若 $P^2 = I$ 且 $P^T = P$, 则称实矩阵 P 是反射矩阵. 若 $A = PAP$ (或 $A = -PAP$), 则称矩阵 A 为关于反射 P 的自反(或反自反)矩阵, 记 $R_r^{n \times n}(P) = \{A \in R^{n \times n} | PAP = A\}$. 若 $\text{vec}(X^T) = Q(m, n)\text{vec}(X)$, 其中 $X \in R^{m \times n}$, 则称 $Q(m, n)$ 为置换矩阵, 且

$$Q(m, n) = Q(n, m)^T = Q(n, m)^{-1}.$$

矩阵 $A = (a_{ij}) \in R^{m \times n}$ 的拉伸算子 $\text{vec}(\cdot)$ 为

$$\text{vec}(A) = [a_{11}, a_{21}, \dots, a_{m1}, a_{12}, a_{22}, \dots, a_{m2}, \dots, a_{1n}, a_{2n}, \dots, a_{mn}]^T,$$

$\nabla f(X)$ 表示 $f(X)$ 关于 X 的梯度算子, 即 $\nabla f(X) = (\frac{\partial f}{\partial x_{11}}, \frac{\partial f}{\partial x_{21}}, \dots, \frac{\partial f}{\partial x_{mn}})^T$, $\nabla^2 f(X)$ 为 Hessian 矩阵, 其中 $X = (x_{ij}) \in R^{m \times n}$.

我们知道关于反射矩阵的自反矩阵或反自反矩阵在系统与控制理论、工程、科学计算和其他领域都有广泛的应用^[1-2]. 近年来, Sylvester 矩阵方程 $AXB + CX^T D = E$ 是计算数学研究的热点之一, 并且取得很多成果. 若矩阵方程相容, 文献[3]利用 Moore-Penrose 广义给出了 $AX + X^T C = B$ 解的表达式, 文献[4-5]用共轭梯度迭代算法给出矩阵方程 $AXB + CX^T D = E$ 极小范数最小二乘解, 2011 年文献[6]给出了 $XA + AX^T = 0$ 的一般解, 2012 年文献[7]给出 $AXB + CX^T D = E$ 的可解性, 文献[8]给出求解方程 $A_1 X_1 B_1 = C$,

*收稿日期: 2013-06-12 接收日期: 2013-07-30

基金项目: 安徽高校省级自然科学基金资助 (KJ2011B119).

作者简介: 杨家稳 (1972-), 男, 安徽滁州, 副教授, 硕士, 主要研究方向: 优化算法.

$A_2X_2B_2 = D$ 的自反 (或反自反) 最佳逼近解. 若矩阵方程不相容, 对于任意给定矩阵, 盛^[9]提出一种算法求得最佳逼近解, 2012 年文献 [10] 提出一种算法求 $AXB + CX^T D = E$ 的自反 (或反自反) 最佳逼近解.

目前还未见研究方程 $AXB + CX^T D = E$ 的自反 (或反自反) 最佳逼近解的文献. 一般来说, 较容易求得该矩阵方程无约束条件的解, 但很难求该矩阵方程的带约束条件的解. 我们利用共轭方向法思想, 先构造一个可行方向, 然后根据这个可行方向再构造相互共轭的下降方向, 所以初始矩阵通过有限次迭代能够收敛于全局最小点.

本文考虑如下问题:

问题 I 给定矩阵 $A, C \in \Re^{m \times l}, B, D \in \Re^{l \times n}, E \in \Re^{m \times n}$, 求 $X \in \Re_r^{l \times l}(P)$, 使得

$$\|E - AXB - CX^T D\| = \min. \quad (1.1)$$

问题 II 设问题 I 的解集合为 S_E , 给定 $X^* \in R_r^{l \times l}(P)$, 求 $\hat{X} \in S_E$ 使得

$$\|\hat{X} - X^*\| = \min_{X \in S_E} \|X - X^*\|. \quad (1.2)$$

对于矩阵方程 $AXB + CX^T D = E$, 若它们是相容的, S_E 是解的集合; 若它们不相容, S_E 就是最小二乘解的集合. 所以无论矩阵方程 $AXB + CX^T D = E$ 是否相容, 都可以认为 S_E 是问题 I 的解集合. 问题 II 是在 S_E 里找一个与矩阵 $X^* \in R_r^{l \times l}(P)$ 最接近的矩阵. 由于数据不完整或者修改数据, 在线性系统的测试和复原过程中, 会提出问题 II, 未知矩阵的估计值 X^* 可以通过实验观测和统计分布的信息获得.

显然问题 I 的最小二乘解等价 (1.3) 式的最小二乘解

$$\|E - AXB - CX^T D\|^2 = \min, \quad (1.3)$$

其中 $X \in \Re_r^{l \times l}(P)$.

本文的结构如下: 第 2 部分给出问题 I 和问题 II 的一个迭代算法并证明所给算法是收敛的; 第 3 部分用三个数值例子来验证该算法的有效性; 第 4 部分给出结论.

2 问题 I 和 II 的迭代算法

下面给出问题 I 和 II 的算法, 算法的具体步骤如下:

步骤 1 输入 $A \in \Re^{m \times l}, B \in \Re^{l \times n}, C \in \Re^{m \times l}, D \in \Re^{l \times n}$ 和 $E \in \Re^{m \times n}$;

步骤 2 任给自反矩阵 $X_1 \in \Re_r^{l \times l}(P)$, 其中 $P \in \Re_r^{l \times l}$ 是任意广义自反矩阵;

步骤 3 计算

$$\begin{aligned} R_1 &= E - AX_1B - CX_1^T D; \\ g_1 &= A^T R_1 B^T + D R_1^T C + P(A^T R_1 B^T + D R_1^T C)P; \\ V_1 &= A^T A g_1 B B^T + A^T C g_1^T D B^T + D B^T g_1^T A^T C + D D^T g_1 C^T C; \\ d_1 &= V_1 + P V_1 P; \\ k &:= 1; \end{aligned}$$

步骤 4 如果 $g_1 = \mathbf{0}$, 则停止迭代; 否则转入步骤 5;

步骤 5 计算 $\text{vec}(X_{k+1}) = \text{vec}(X_k) + \frac{\|g_k\|^2}{\|d_k\|^2} \text{vec}(d_k)$, 即 $X_{k+1} = X_k + \frac{\|g_k\|^2}{\|d_k\|^2} d_k$;

$$\begin{aligned} U_k &= A^T A d_k B B^T + A^T C d_k^T D B^T + D B^T d_k^T A^T C + D D^T d_k C^T C; \\ g_{k+1} &= A^T R_{k+1} B^T + D R_{k+1}^T C + P(A^T R_{k+1} B^T + D R_{k+1}^T C)P \\ &= g_k - \frac{\|g_k\|^2}{\|d_k\|^2} (U_k + P U_k P); \\ V_{k+1} &= A^T A g_{k+1} B B^T + A^T C g_{k+1}^T D B^T + D B^T g_{k+1}^T A^T C + D D^T g_{k+1} C^T C; \\ d_{k+1} &= V_{k+1} + P V_{k+1} P + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} d_k. \end{aligned}$$

步骤 6 如果 $g_{k+1} = \mathbf{0}$, 则停止迭代; 否则 $k := k + 1$, 转入步骤 5.

为了证明该算法的收敛性, 首先给出下面一些定理.

定理 1 设 $F(X) = \|E - AXB - CX^T D\|^2$, $R = E - AXB - CX^T D$, 其中 $X \in \Re_r^{l \times l}(P)$, 则

- (i) 存在 $X^* \in \Re_r^{l \times l}(P)$ 使得 $\nabla F(X^*) = \mathbf{0}$, 且 $\nabla F(X) = -2\text{vec}(A^T RB^T + DR^T C)$.
- (ii) $\nabla^2 F(X)$ 为半正定矩阵.

证 (i) 令 $\text{vec}(X^T) = Q(l, l)\text{vec}(X)$, $A_1 = B^T \otimes A + (D^T \otimes C)Q(l, l)$,

$$\begin{aligned} F(X) &= \|E - AXB - CX^T D\|^2 = \|\text{vec}(E - AXB - CX^T D)\|_2^2 \\ &= \|\text{vec}(E) - \text{vec}(AXB - CX^T D)\|_2^2 \\ &= \|\text{vec}(E) - [B^T \otimes A + (D^T \otimes C)Q(l, l)]\text{vec}(X)\|_2^2 \\ &= \langle \text{vec}(E) - A_1 \text{vec}(X), \text{vec}(E) - A_1 \text{vec}(X) \rangle \\ &= [\text{vec}(E)]^T \text{vec}(E) - 2[\text{vec}(X)]^T A_1^T \text{vec}(E) + [\text{vec}(X)]^T A_1^T A_1 \text{vec}(X), \end{aligned}$$

所以

$$\begin{aligned} \nabla F(X) &= 2A_1^T A_1 \text{vec}(X) - 2A_1^T \text{vec}(E) = 2[A_1^T A_1 \text{vec}(X) - A_1^T \text{vec}(E)] \\ &= -2\text{vec}(A^T RB^T + DR^T C). \end{aligned}$$

显然, 矩阵方程 $A_1^T A_1 \text{vec}(X) - A_1^T \text{vec}(E) = \mathbf{0}$ 是相容的, 则存在 $X^* \in \Re_r^{l \times l}(P)$ 使得 $A_1^T A_1 \text{vec}(X^*) - A_1^T \text{vec}(E) = \mathbf{0}$, 即 $\nabla F(X^*) = \mathbf{0}$.

(ii) 因为 $\nabla F(X) = 2A_1^T A_1 \text{vec}(X) - 2A_1^T \text{vec}(E)$, 所以 $\nabla^2 F(X) = 2A_1^T A_1$. 由于对于任意 $Y \in \Re^{l^2}$ 都有 $\|A_1 Y\|^2 \geq 0 \Rightarrow \langle A_1 Y, A_1 Y \rangle \geq 0 \Rightarrow Y^T A_1^T A_1 Y \geq 0$, 所以 $\nabla^2 F(X)$ 为半正定矩阵.

定理 2^[11] 设 $S \subset \Re^n$ 为凸集, $f : S \subset \Re^n \rightarrow \Re$ 在 S 的内点集 $\text{int } S$ 二次连续可微, 若 $x^* \in \text{int } S$ 为 $f(x)$ 的驻点, 且 $\forall x \in \text{int } S$, $\nabla^2 f(x)$ 半正定, 则 x^* 为 $f(x)$ 在 $\text{int } S$ 上的全局极小点.

定理 3 若 $\{X_i\}$, $\{g_i\}$ 和 $\{d_i\}$ 是算法产生的序列, 则 $g_i, d_i, X_i \in \Re_r^{l \times l}(P)$ ($i = 1, 2, \dots$).

证 下面用数学归纳法来证明 $g_i, d_i, X_i \in \Re_r^{l \times l}(P)$ ($i = 1, 2, \dots$).

当 $i = 1$ 时, 所给的初始矩阵 $X_1 \in \Re_r^{l \times l}(P)$, 显然 $g_1 \in \Re_r^{l \times l}(P)$, $d_1 \in \Re_r^{l \times l}(P)$.

假设当 $i = k$ ($k \geq 2$) 时, $g_k, d_k, X_k \in \Re_r^{l \times l}(P)$ 结论成立. 当 $i = k + 1$ 时,

$$\begin{aligned} Pg_{k+1}P &= P[g_k - \frac{\|g_k\|^2}{\|d_k\|^2}(U_k + PU_kP)]P = Pg_kP - \frac{\|g_k\|^2}{\|d_k\|^2}(PU_kP + U_k) = g_{k+1}, \\ Pd_{k+1}P &= P(V_{k+1} + PV_{k+1}P + \frac{\|g_{k+1}\|^2}{\|g_k\|^2}d_k)P = PV_{k+1}P + V_{k+1} + \frac{\|g_{k+1}\|^2}{\|g_k\|^2}Pd_kP = d_{k+1}, \\ PX_{k+1}P &= P\left(X_k + \frac{\|g_k\|^2}{\|d_k\|^2}d_k\right)P = PX_kP + \frac{\|g_k\|^2}{\|d_k\|^2}Pd_kP = X_k + \frac{\|g_k\|^2}{\|d_k\|^2}d_k = X_{k+1}, \end{aligned}$$

故 $g_i, d_i, X_i \in \Re_r^{l \times l}(P)$ ($i = 1, 2, \dots$).

定理 4 若 $X^* \in \Re_r^{l \times l}(P)$ 是 $\nabla F(X) = \mathbf{0}$ 的解, $\{X_i\}$, $\{g_i\}$ 和 $\{d_i\}$ 是算法产生的序列. 如果 $g_i \neq \mathbf{0}$, 则 $d_i \neq \mathbf{0}$ ($i = 1, 2, \dots, s$).

证 首先利用数学归纳法证明 $\langle d_i, X^* - X_i \rangle = \|g_i\|^2$ ($i = 1, 2, \dots, s$), 当 $i = 1$ 时,

$$\begin{aligned} &\langle d_1, X^* - X_1 \rangle \\ &= \langle V_1 + PV_1P, X^* - X_1 \rangle \\ &= \langle A^T A g_1 B B^T + A^T C g_1^T D B^T + D B^T g_1^T A^T C + D D^T g_1 C^T C, X^* - X_1 \rangle \\ &\quad + \langle A^T A g_1 B B^T + A^T C g_1^T D B^T + D B^T g_1^T A^T C + D D^T g_1 C^T C, P(X^* - X_1)P \rangle \\ &= 2 \langle A^T A g_1 B B^T + A^T C g_1^T D B^T + D B^T g_1^T A^T C + D D^T g_1 C^T C, X^* - X_1 \rangle \\ &= 2 \langle A^T A g_1 B B^T + D D^T g_1 C^T C, X^* - X_1 \rangle + 2 \langle A^T C g_1^T D B^T + D B^T g_1^T A^T C, X^* - X_1 \rangle \\ &= 2 \langle A^T A g_1 B B^T + D D^T g_1 C^T C, X^* - X_1 \rangle + 2 \langle B D^T g_1 C^T A + C^T A g_1 B D^T, (X^* - X_1)^T \rangle \\ &= 2 \langle g_1, A^T A (X^* - X_1) B B^T + D D^T (X^* - X_1) C^T C \rangle \\ &\quad + 2 \langle g_1, D B^T (X^* - X_1)^T A^T C + A^T C (X^* - X_1)^T D B^T \rangle \\ &= 2 \langle g_1, A^T A (X^* - X_1) B B^T + D D^T (X^* - X_1) C^T C + D B^T (X^* - X_1)^T A^T C \\ &\quad + A^T C (X^* - X_1)^T D B^T \rangle \\ &= \langle g_1, 2(A^T R_1 B^T + D R_1^T C) \rangle \\ &= \langle g_1, A^T R_1 B^T + D R_1^T C \rangle + \langle g_1, A^T R_1 B^T + D R_1^T C \rangle \\ &= \langle g_1, A^T R_1 B^T + D R_1^T C \rangle + \langle P g_1 P, A^T R_1 B^T + D R_1^T C \rangle \\ &= \langle g_1, A^T R_1 B^T + D R_1^T C \rangle + \langle g_1, P(A^T R_1 B^T + D R_1^T C)P \rangle \\ &= \langle g_1, A^T R_1 B^T + D R_1^T C + P(A^T R_1 B^T + D R_1^T C)P \rangle \\ &= \|g_1\|^2. \end{aligned}$$

假设当 $i = k$ ($s > k \geq 2$) 时, $\langle d_k, X^* - X_k \rangle = \|g_k\|^2$ 成立. 当 $i = k + 1$ 时,

$$\begin{aligned} \langle d_{k+1}, X^* - X_{k+1} \rangle &= \langle V_{k+1} + PV_{k+1}P + \frac{\|g_{k+1}\|^2}{\|g_k\|^2}d_k, X^* - X_{k+1} \rangle \\ &= \langle V_{k+1}, X^* - X_{k+1} \rangle + \langle V_{k+1}, P(X^* - X_{k+1})P \rangle + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \langle d_k, X^* - X_{k+1} \rangle \\ &= \langle 2(A^T A g_{k+1} B B^T + A^T C g_{k+1}^T D B^T + D B^T g_{k+1}^T A^T C + D D^T g_{k+1} C^T C), X^* - X_{k+1} \rangle \end{aligned}$$

$$\begin{aligned}
& + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \langle d_k, X^* - X_{k+1} \rangle \\
= & \langle g_{k+1}, 2(A^T R_{k+1} B^T + D R_{k+1}^T C) \rangle + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \langle d_k, X^* - X_{k+1} \rangle \\
= & \langle g_{k+1}, A^T R_{k+1} B^T + D R_{k+1}^T C + P(A^T R_{k+1} B^T + D R_{k+1}^T C)P \rangle \\
& + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \langle d_k, X^* - X_{k+1} \rangle \\
= & \|g_{k+1}\|^2 + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \langle d_k, X^* - X_{k+1} \rangle \\
= & \|g_{k+1}\|^2 + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \left\langle d_k, X^* - X_k - \frac{\|g_k\|^2}{\|d_k\|^2} d_k \right\rangle \\
= & \|g_{k+1}\|^2 + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \left[\langle d_k, X^* - X_k \rangle - \frac{\|g_k\|^2}{\|d_k\|^2} \langle d_k, d_k \rangle \right] \\
= & \|g_{k+1}\|^2 + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \left[\|g_k\|^2 - \frac{\|g_k\|^2}{\|d_k\|^2} \|d_k\|^2 \right] = \|g_{k+1}\|^2.
\end{aligned}$$

故 $\langle d_i, X^* - X_i \rangle = \|g_i\|^2$ 成立, 所以当 $g_i \neq \mathbf{0}$ 时, $P_i \neq \mathbf{0}$ ($i = 1, 2, \dots, s$).

定理 5 若 g_1 和 d_1 是算法产生的, $\text{vec}(g_1^T) = Q(l, l)\text{vec}(g_1) = Q\text{vec}(g_1)$. 如果 $g_1 \neq \mathbf{0}$, 则 $\nabla F(X_1)^T \text{vec}(d_1) < 0$.

证

$$\begin{aligned}
& \nabla F(X_1)^T \text{vec}(d_1) = \langle -2\text{vec}(A^T R_1 B^T + D R_1^T C), \text{vec}(d_1) \rangle \\
= & -\langle 2\text{vec}(A^T R_1 B^T + D R_1^T C), \text{vec}(P d_1 P) \rangle \\
= & -\langle 2\text{vec}(A^T R_1 B^T + D R_1^T C), (P \otimes P)\text{vec}(d_1) \rangle \\
= & -\langle \text{vec}[(A^T R_1 B^T + D R_1^T C) + P(A^T R_1 B^T + D R_1^T C)P], \text{vec}(d_1) \rangle \\
= & -\langle \text{vec}(g_1), (I + P \otimes P)\text{vec}(A^T A g_1 B B^T + A^T C g_1^T D B^T + D B^T g_1^T A^T C + D D^T g_1 C^T C) \rangle \\
= & -[\text{vec}(g_1)]^T (I + P \otimes P) [B^T \otimes A + (D^T \otimes C)Q]^T [B^T \otimes A + (D^T \otimes C)Q] \text{vec}(g_1) \\
= & -\{[B^T \otimes A + (D^T \otimes C)Q] (I + P \otimes P) \text{vec}(g_1)\}^T [B^T \otimes A + (D^T \otimes C)Q] \text{vec}(g_1) \\
= & -\{[B^T \otimes A + (D^T \otimes C)Q] 2\text{vec}(g_1)\}^T [B^T \otimes A + (D^T \otimes C)Q] \text{vec}(g_1) \\
= & -2 \|[B^T \otimes A + (D^T \otimes C)Q] \text{vec}(g_1)\|_2^2 \leq 0.
\end{aligned}$$

假设 $\|[B^T \otimes A + (D^T \otimes C)Q] \text{vec}(g_1)\|_2^2 = 0$, 则 $[B^T \otimes A + (D^T \otimes C)Q] \text{vec}(g_1) = \mathbf{0}$, 从而可得

$$\text{vec}(d_1) = (I + P \otimes P) [B^T \otimes A + (D^T \otimes C)Q]^T [B^T \otimes A + (D^T \otimes C)Q] \text{vec}(g_1) = \mathbf{0}.$$

因为 $g_1 \neq \mathbf{0}$, 根据定理 4 可得 $d_1 \neq \mathbf{0}$, 这与 $\text{vec}(d_1) = \mathbf{0}$ 矛盾, 所以

$$-\|[B^T \otimes A + (D^T \otimes C)Q] \text{vec}(g_1)\|_2^2 < 0.$$

即 $\nabla F(X_1)^T \text{vec}(d_1) < 0$.

定理 5 表明了算法中的搜索方向 $\text{vec}(d_1)$ 是一个可行性下降方向. 下面将证明所有的搜索方向相互共轭.

定理 6 $\{g_i\}$ 和 $\{d_i\}$ 是算法产生的序列, 且 $d_i \neq \mathbf{0}$ ($i = 1, 2, \dots, l$), 则

$$\langle g_i, g_j \rangle = 0 ; \quad \langle d_i, d_j \rangle = 0 (i, j = 1, 2, \dots, l, i \neq j). \quad (2.1)$$

证 因为 $\langle A, B \rangle = \langle B, A \rangle$, 其中 $A, B \in \Re^{m \times n}$, 所以只需证明当 $1 \leq i < j$ 时结论成立即可. 用数学归纳法分两步来证明该结论:

第一步 证明 $\langle g_i, g_{i+1} \rangle = 0$ 且 $\langle d_i, d_{i+1} \rangle = 0$ ($i = 1, 2, \dots$). 当 $i = 1$ 时,

$$\begin{aligned} \langle g_1, g_2 \rangle &= \left\langle g_1, g_1 - \frac{\|g_1\|^2}{\|d_1\|^2} (U_1 + PU_1P) \right\rangle = \langle g_1, g_1 \rangle - \frac{\|g_1\|^2}{\|d_1\|^2} \langle g_1, U_1 + PU_1P \rangle \\ &= \|g_1\|^2 - \frac{\|g_1\|^2}{\|d_1\|^2} [\langle g_1, U_1 \rangle + \langle Pg_1P, U_1 \rangle] = \|g_1\|^2 - \frac{\|g_1\|^2}{\|d_1\|^2} \langle g_1, 2U_1 \rangle \\ &= \|g_1\|^2 - \frac{2\|g_1\|^2}{\|d_1\|^2} \langle g_1, A^T Ad_1 BB^T + A^T Cd_1^T DB^T + DB^T d_1^T A^T C + DD^T d_1 C^T C \rangle \\ &= \|g_1\|^2 - \frac{2\|g_1\|^2}{\|d_1\|^2} \langle A^T Ag_1 BB^T + A^T Cg_1^T DB^T + DB^T g_1^T A^T C + DD^T g_1 C^T C, d_1 \rangle \\ &= \|g_1\|^2 - \frac{\|g_1\|^2}{\|d_1\|^2} \langle V_1, d_1 + Pd_1P \rangle = \|g_1\|^2 - \frac{\|g_1\|^2}{\|d_1\|^2} \langle V_1 + PV_1P, d_1 \rangle \\ &= \|g_1\|^2 - \frac{\|g_1\|^2}{\|d_1\|^2} \langle d_1, d_1 \rangle = 0, \\ \langle d_1, d_2 \rangle &= \langle d_1, V_2 + PV_2P + \frac{\|g_2\|^2}{\|g_1\|^2} d_1 \rangle = \langle d_1, 2V_2 \rangle + \frac{\|g_2\|^2}{\|g_1\|^2} \langle d_1, d_1 \rangle \\ &= \langle d_1, 2(A^T Ag_2 BB^T + A^T Cg_2^T DB^T + DB^T g_2^T A^T C + DD^T g_2 C^T C) \rangle + \frac{\|g_2\|^2}{\|g_1\|^2} \langle d_1, d_1 \rangle \\ &= \langle 2(A^T Ad_1 BB^T + A^T Cd_1^T DB^T + DB^T d_1^T A^T C + DD^T d_1 C^T C), g_2 \rangle + \frac{\|g_2\|^2}{\|g_1\|^2} \langle d_1, d_1 \rangle \\ &= \langle 2U_1, g_2 \rangle + \frac{\|g_2\|^2}{\|g_1\|^2} \langle d_1, d_1 \rangle = \langle U_1 + PU_1P, g_2 \rangle + \frac{\|g_2\|^2}{\|g_1\|^2} \langle d_1, d_1 \rangle \\ &= \left\langle \frac{\|d_1\|^2}{\|g_1\|^2} (g_1 - g_2), g_2 \right\rangle + \frac{\|g_2\|^2}{\|g_1\|^2} \|d_1\|^2 \\ &= \frac{\|d_1\|^2}{\|g_1\|^2} \langle g_1 - g_2, g_2 \rangle + \frac{\|g_2\|^2}{\|g_1\|^2} \|d_1\|^2 = 0. \end{aligned}$$

假设当 $i \leq k-1$ ($s > k \geq 2$) 结论成立. 当 $i = k$ 时,

$$\begin{aligned} \langle g_k, g_{k+1} \rangle &= \left\langle g_k, g_k - \frac{\|g_k\|^2}{\|d_k\|^2} (U_k + PU_kP) \right\rangle = \|g_k\|^2 - \frac{\|g_k\|^2}{\|d_k\|^2} \langle g_k, 2U_k \rangle \\ &= \|g_k\|^2 - \frac{\|g_k\|^2}{\|d_k\|^2} \langle A^T Ag_k BB^T + DB^T g_k^T A^T C + A^T Cg_k^T DB^T + DD^T g_k C^T C, 2d_k \rangle \end{aligned}$$

$$\begin{aligned}
&= \|g_k\|^2 - \frac{\|g_k\|^2}{\|d_k\|^2} \langle V_k, 2d_k \rangle = \|g_k\|^2 - \frac{\|g_k\|^2}{\|d_k\|^2} \langle V_k, d_k + Pd_kP \rangle \\
&= \|g_k\|^2 - \frac{\|g_k\|^2}{\|d_k\|^2} \langle V_k + PV_kP, d_k \rangle \\
&= \|g_k\|^2 - \frac{\|g_k\|^2}{\|d_k\|^2} \langle d_k - \frac{\|g_k\|^2}{\|g_{k-1}\|^2} d_{k-1}, d_k \rangle \\
&= \|g_k\|^2 - \frac{\|g_k\|^2}{\|d_k\|^2} (\|d_k\|^2 - \frac{\|g_k\|^2}{\|g_{k-1}\|^2} \langle d_{k-1}, d_k \rangle) = 0, \\
\langle d_k, d_{k+1} \rangle &= \langle d_k, V_{k+1} + PV_{k+1}P + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} d_k \rangle = \langle d_k, 2V_{k+1} \rangle + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \|d_k\|^2 \\
&= \langle d_k, 2(A^T A g_{k+1} B B^T + A^T C g_{k+1}^T D B^T + D B^T g_{k+1}^T A^T C + D D^T g_{k+1} C^T C) \rangle \\
&\quad + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \|d_k\|^2 \\
&= \langle 2(A^T A d_k B B^T + A^T C d_k^T D B^T + D B^T d_k^T A^T C + D D^T d_k C^T C), g_{k+1} \rangle \\
&\quad + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \|d_k\|^2 = \langle 2U_k, g_{k+1} \rangle + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \|d_k\|^2 \\
&= \langle U_k + P U_k P, g_{k+1} \rangle + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \|d_k\|^2 \\
&= \frac{\|d_k\|^2}{\|g_k\|^2} \langle g_k - g_{k+1}, g_{k+1} \rangle + \frac{\|g_{k+1}\|^2}{\|g_k\|^2} \|d_k\|^2 = 0,
\end{aligned}$$

故 $\langle g_i, g_{i+1} \rangle = 0$ 且 $\langle d_i, d_{i+1} \rangle = 0$ ($i = 1, 2, \dots$) 成立.

第二步 根据第一步结论, 假设对于任意 i 和 k 都有 $\langle g_i, g_{i+k} \rangle = 0$ 且 $\langle d_i, d_{i+k} \rangle = 0$ 成立.

下面证明 $\langle g_i, g_{i+k+1} \rangle = 0$ 且 $\langle d_i, d_{i+k+1} \rangle = 0$ 成立.

$$\begin{aligned}
\langle g_i, g_{i+k+1} \rangle &= \langle g_i, g_{i+k} - \frac{\|g_{i+k}\|^2}{\|d_{i+k}\|^2} (U_{i+k} + P U_{i+k} P) \rangle = -\frac{\|g_{i+k}\|^2}{\|d_{i+k}\|^2} \langle g_i, 2U_{i+k} \rangle \\
&= -\frac{2\|g_{i+k}\|^2}{\|d_{i+k}\|^2} \langle g_i, A^T A d_{i+k} B B^T + A^T C d_{i+k}^T D B^T + D B^T d_{i+k}^T A^T C + D D^T d_{i+k} C^T C \rangle \\
&= -\frac{2\|g_{i+k}\|^2}{\|d_{i+k}\|^2} \langle A^T A g_i B B^T + A^T C g_i^T D B^T + D B^T g_i^T A^T C + D D^T g_i C^T C, d_{i+k} \rangle \\
&= -\frac{2\|g_{i+k}\|^2}{\|d_{i+k}\|^2} \langle V_i, d_{i+k} \rangle = -\frac{\|g_{i+k}\|^2}{\|d_{i+k}\|^2} \langle V_i, d_{i+k} + P d_{i+k} P \rangle \\
&= -\frac{\|g_{i+k}\|^2}{\|d_{i+k}\|^2} \langle V_i + P V_i P, d_{i+k} \rangle = -\frac{\|g_{i+k}\|^2}{\|d_{i+k}\|^2} \langle d_i - \frac{\|g_i\|^2}{\|g_{i-1}\|^2} d_{i-1}, d_{i+k} \rangle = 0, \\
\langle d_i, d_{i+k+1} \rangle &= \langle d_i, V_{i+k+1} + P V_{i+k+1} P + \frac{\|g_{i+k+1}\|^2}{\|g_{i+k}\|^2} d_{i+k} \rangle \\
&= \langle d_i, 2V_{i+k+1} \rangle + \frac{\|g_{i+k+1}\|^2}{\|g_{i+k}\|^2} \langle d_i, d_{i+k} \rangle
\end{aligned}$$

$$\begin{aligned}
&= \langle d_i, 2(A^T A g_{i+k+1} B B^T + A^T C g_{i+k+1}^T D B^T + D B^T g_{i+k+1}^T A^T C + D D^T g_{i+k+1} C^T C) \rangle \\
&= \langle 2(A^T A d_i B B^T + A^T C d_i^T D B^T + D B^T d_i^T A^T C + D D^T d_i C^T C), g_{i+k+1} \rangle \\
&= \langle 2U_i, g_{i+k+1} \rangle = \langle U_i + P U_i P, g_{i+k+1} \rangle = \frac{\|d_i\|^2}{\|g_i\|^2} \langle g_i - g_{i+1}, g_{i+k+1} \rangle = 0.
\end{aligned}$$

由第一步和第二步可得 $\langle g_i, g_j \rangle = 0$ 且 $\langle d_i, d_j \rangle = 0$ ($i, j = 1, 2, \dots, i \neq j$) 成立.

定理 7 若 $\forall X_1 \in \Re_r^{l \times l}(P)$, 其中 $P \in \Re_r^{l \times l}$ 是广义自反矩阵, 算法能在有限迭代步内得到问题 I 的自反解.

证 假设 $g_i \neq \mathbf{0}$ ($i = 1, 2, \dots, l^2$), 由定理 4 可知, $d_i \neq \mathbf{0}$ ($i = 1, 2, \dots, l^2$), 因此根据算法能够计算出 X_{l^2+1} 和 g_{l^2+1} . 由定理 6 可得 $\langle g_i, g_{l^2+1} \rangle = 0$ ($i = 1, 2, \dots, l^2$) 和 $\langle g_i, g_j \rangle = 0$ ($i, j = 1, 2, \dots, l^2, i \neq j$). 因为 $\{g_1, g_2, \dots, g_{l^2}\}$ 是矩阵空间 $\Re_r^{l^2}$ 的正交基, 所以 $g_{l^2+1} = \mathbf{0}$, 即可推导出 $\nabla F(X_{l^2+1}) = \mathbf{0}$. 由定理 1–定理 3 可得, X_{l^2+1} 为问题 I 的自反解.

定理 8 [12] 假设最小剩余问题 $\|Mx - b\|_2 = \min$ 有解 $x^* \in R(M^T)$, 则 x^* 是该剩余问题的极小范数最小二乘解.

定理 9 在所给算法中, 如果取初始矩阵 $X_1 = \frac{1}{2}(A^T N B^T + D N^T C) + \frac{1}{2}P(A^T N B^T + D N^T C)P$, 其中 $N \in \Re^{m \times n}$, 特别取 $X_1 = \mathbf{0}$, 算法能够在有限迭代步内获得问题 I 的极小范数最小二乘自反解.

证 如果取初始矩阵 $X_1 = \frac{1}{2}(A^T N B^T + D N^T C) + \frac{1}{2}P(A^T N B^T + D N^T C)P$, 由定理 7 可知, 算法能在有限迭代步内得到问题 I 的自反解 X^* , 且 X^* 能表示成

$$X^* = \frac{1}{2}(A^T \tilde{N} B^T + D \tilde{N}^T C) + \frac{1}{2}P(A^T \tilde{N} B^T + D \tilde{N}^T C)P.$$

记 $\text{vec}(X^T) = Q \text{vec}(X)$, 其中 $X \in \Re^{l \times l}$.

下面将证明 X^* 是问题 I 的极小范数最小二乘自反解:

$$\begin{aligned}
&\min_{X \in \Re_r^{l \times l}(P)} \|E - (AXB + CX^T D)\| \\
&= \min_{X \in \Re_r^{l \times l}(P)} \left\| E - \frac{1}{2}(AXB + CX^T D) - \frac{1}{2}(APXPB + CPX^T PD) \right\| \\
&= \min_{X \in \Re_r^{l \times l}(P)} \left\| \text{vec}(E) - \frac{1}{2} \text{vec}[(AXB + CX^T D) + (APXPB + CPX^T PD)] \right\|_2 \\
&= \min_{X \in \Re_r^{l \times l}(P)} \left\| \text{vec}(E) - \frac{1}{2} \left\{ B^T \otimes A + (D^T \otimes C)Q + (B^T P) \otimes (AP) + [(D^T P) \otimes (CP)]Q \right\} \text{vec}(\tilde{N}) \right\|_2.
\end{aligned}$$

若 $\tilde{N} \in \Re^{m \times n}$, 则

$$\begin{aligned}
\text{vec}(X^*) &= \text{vec}[\frac{1}{2}(A^T \tilde{N} B^T + D \tilde{N}^T C) + \frac{1}{2}P(A^T \tilde{N} B^T + D \tilde{N}^T C)P] \\
&= \frac{1}{2} \left\{ B^T \otimes A + (D^T \otimes C)Q + (B^T P) \otimes (AP) + [(D^T P) \otimes (CP)]Q \right\}^T \text{vec}(\tilde{N}) \\
&\in \Re \left(\frac{1}{2} \left\{ B^T \otimes A + (D^T \otimes C)Q + (B^T P) \otimes (AP) + [(D^T P) \otimes (CP)]Q \right\}^T \right).
\end{aligned}$$

故当取初始矩阵 $X_1 = \frac{1}{2}(A^T NB^T + DN^T C) + \frac{1}{2}P(A^T NB^T + DN^T C)P$ 时, 特别 $X_1 = \mathbf{0}$, 由定理 8 可得, 算法获得的自反解 X^* 就是自反的极小范数最小二乘解.

若问题 I 的解集 S_X 为非空集, \bar{X} 是所给的逼近矩阵, 其中 $\bar{X} \in \Re_r^{l \times l}(P)$, 则

$$\begin{aligned} & \min_{X \in \Re_r^{l \times l}(P)} \|E - AXB - CX^T D\| \\ &= \min_{X \in \Re_r^{l \times l}(P)} \|(E - A\bar{X}B - C\bar{X}^T D) - A(X - \bar{X})B - C(X - \bar{X})^T D\|. \end{aligned}$$

令 $\tilde{X} = X - \bar{X}$ 及 $\tilde{E} = E - A\bar{X}B - C\bar{X}^T D$, 那么最佳逼近问题 II 就等价于先求 (2.2) 式的自反极小范数最小二乘解.

$$\min_{\bar{X} \in \Re_r^{l \times l}(P)} \|\tilde{E} - A\tilde{X}B - C\tilde{X}^T D\|. \quad (2.2)$$

由算法可得 (2.2) 式的自反极小范数最小二乘解 \tilde{X}^* , 从而计算出问题 I 和 II 的自反最佳逼近解 $\hat{X} = \tilde{X}^* + \bar{X}$.

3 数值例子

本节用三个数值例子来验证上述算法的可行性. 第一个例子是当矩阵方程 $AXB + CX^T D = E$ 有自反解且逼近矩阵为零矩阵时, 求该方程的自反最佳逼近解; 第二个例子是当矩阵方程 $AXB + CX^T D = E$ 不相容且逼近矩阵为零矩阵时, 求该方程的自反最佳逼近解; 最后一个例子是当矩阵方程 $AXB + CX^T D = E$ 有自反解且逼近矩阵为非零矩阵时, 求 $AXB + CX^T D = E$ 的自反最佳逼近解. 用 Matlab2007R 进行仿真模拟, 取初始自反矩阵 $X_1 = \mathbf{0}$.

例 1 考虑下面最小剩余问题:

$$\|E - AXB - CX^T D\| = \min, \quad (3.1)$$

其中

$$\begin{aligned} A &= \begin{pmatrix} 2 & 1 & 6 & 3 & -4 \\ 5 & 4 & -3 & 3 & -6 \\ -1 & 4 & 8 & -7 & 2 \\ 5 & -2 & -6 & 9 & 4 \end{pmatrix}, \quad B = \begin{pmatrix} 5 & 2 & -6 & -4 & 5 \\ -7 & 8 & 1 & 3 & -5 \\ 2 & -9 & 8 & -1 & -2 \\ 2 & 4 & -3 & -7 & 11 \\ 4 & 6 & -2 & -12 & -4 \end{pmatrix}, \\ C &= \begin{pmatrix} 4 & -2 & 9 & -7 & 11 \\ -6 & 7 & 5 & 8 & -3 \\ -13 & 2 & 4 & -5 & 1 \\ 8 & -6 & 2 & 6 & -2 \end{pmatrix}, \quad D = \begin{pmatrix} -3 & -2 & 7 & 3 & -1 \\ -6 & 1 & -2 & 5 & -2 \\ 4 & 3 & 1 & -3 & 9 \\ -5 & -3 & 2 & 4 & 6 \\ 2 & 3 & -6 & 11 & -11 \end{pmatrix}, \quad \bar{X} = \begin{pmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{pmatrix}, \end{aligned}$$

$$E = \begin{pmatrix} -2064 & -1543 & 1510 & 838 & -195 \\ 261 & -271 & 227 & -742 & 304 \\ -119 & -524 & 720 & -1683 & 4651 \\ -563 & 1059 & -773 & 796 & -3000 \end{pmatrix}, P = \begin{pmatrix} 0 & 0 & -1 & 0 & 0 \\ 0 & -1 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & -1 \\ 0 & 0 & 0 & -1 & 0 \end{pmatrix}.$$

可以验证下面的 X 就是矩阵方程 $AXB + CX^T D = E$ 有自反解,

$$X = \begin{pmatrix} 1 & 3 & -4 & -8 & -2 \\ 2 & -5 & 2 & 12 & 12 \\ -4 & 3 & 1 & -2 & -8 \\ -6 & 7 & 9 & -3 & 4 \\ 9 & 7 & -6 & 4 & -3 \end{pmatrix}.$$

利用所给的算法, 迭代 29 步得到

$$X_{29} = \begin{pmatrix} 1.0000 & 3.0000 & -4.0000 & -8.0000 & -2.0000 \\ 2.0000 & -5.0000 & 2.0000 & 12.0000 & 12.0000 \\ -4.0000 & 3.0000 & 1.0000 & -2.0000 & -8.0000 \\ -6.0000 & 7.0000 & 9.0000 & -3.0000 & 4.0000 \\ 9.0000 & 7.0000 & -6.0000 & 4.0000 & -3.0000 \end{pmatrix} \in \Re_r^{5 \times 5}(P),$$

相应的余项

$$R_{29} = \|E - AX_{29}B - CX_{29}^T D\| = 4.2299e-012,$$

相对误差

$$\delta_{29} = \|X_{29} - X\| / \|X\| = 7.8262e-015,$$

其中下标是迭代步数.

例 2 仍考虑 (3.1) 式的最小剩余问题, A, B, C, D, P 和 \bar{X} 同例 1,

$$E = \begin{pmatrix} -2060 & -1543 & 1510 & 838 & -195 \\ 261 & -271 & 227 & -742 & 304 \\ -119 & -524 & 720 & -1683 & 4651 \\ -563 & 1059 & -773 & 796 & -3000 \end{pmatrix}.$$

可以验证该方程 $AXB + CX^T D = E$ 不相容, 利用算法得到

$$X_{21} = \begin{pmatrix} 1.0009 & 3.0041 & -3.9952 & -8.0070 & -2.0278 \\ 1.9442 & -5.0596 & 1.9442 & 12.0414 & 12.0414 \\ -3.9952 & 3.0041 & 1.0009 & -2.0278 & -8.0070 \\ -5.9965 & 7.0020 & 9.0038 & -2.9887 & 4.0117 \\ 9.0038 & 7.0020 & -5.9965 & 4.0117 & -2.9887 \end{pmatrix} \in \Re_r^{5 \times 5}(P),$$

相应的余项

$$R_{21} = \|E - AX_{21}B - CX_{21}^T D\| = 2.0560.$$

例 3 仍考虑 (3.1) 式的最小剩余问题, A, B, C, D, E 和 P 同例 1,

$$\bar{X} = \begin{pmatrix} 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 \\ 10 & 10 & 10 & 10 & 10 \end{pmatrix} \in \Re_r^{5 \times 5}(P).$$

利用算法, 迭代 37 步得到

$$\tilde{X}_{37} = \begin{pmatrix} -9.0000 & -7.0000 & -14.0000 & -18.0000 & -12.0000 \\ -8.0000 & -15.0000 & -8.0000 & 2.0000 & 2.0000 \\ -14.0000 & -7.0000 & -9.0000 & -12.0000 & -18.0000 \\ -16.0000 & -3.0000 & -1.0000 & -13.0000 & -6.0000 \\ -1.0000 & -3.0000 & -16.0000 & -6.0000 & -13.0000 \end{pmatrix} \in \Re_r^{5 \times 5}(P),$$

所以自反最佳逼近解为

$$\hat{X}_{37} = \tilde{X}_{37} + \bar{X} = \begin{pmatrix} 1.0000 & 3.0000 & -4.0000 & -8.0000 & -2.0000 \\ 2.0000 & -5.0000 & 2.0000 & 12.0000 & 12.0000 \\ -4.0000 & 3.0000 & 1.0000 & -2.0000 & -8.0000 \\ -6.0000 & 7.0000 & 9.0000 & -3.0000 & 4.0000 \\ 9.0000 & 7.0000 & -6.0000 & 4.0000 & -3.0000 \end{pmatrix} \in \Re_r^{5 \times 5}(P),$$

相应的余项

$$R_{37} = \|E - A\hat{X}_{37}B - C\hat{X}_{37}^T D\| = 3.4050e-012.$$

4 结论

本文利用共轭方向法思想, 提出了求矩阵方程 $AXB + CX^T D = E$ 自反最佳逼近解的一个迭代算法. 无论 $AXB + CX^T D = E$ 是否相容, 任取一个初始自反矩阵 X_1 , 所给的算法都能够在有限迭代步内获得其自反最佳逼近解. 三个数值例子的结果表明该算法是可行性的.

参 考 文 献

- [1] Chen, Hsin-Chu. Generalized reflexive matrices: special properties and applications [J]. SIAM J. Matrix Anal. Appl., 1998, (19) :140–153.
- [2] Chen Hsin-Chu. The SAS domain decomposition method for structural analysis[R]. CSRD Teach., Report 754, Center for Supercomputing Research and Development, Urbana, IL: University of Illinois, 1988.
- [3] Piao Fengxian, Zhang Qingling, Wang Zhefeng. The solution to matrix equation $AX + X^T C = B$ [J]. J. Franklin Institute, 2007, 344: 1056–1062.
- [4] Li Xie, Liu Yanjun, Yang Huizhong. Gradient based and least squares based iterative algorithms for matrix equation $AXB + CX^T D = E$ [J]. Appl. Math. Comput., 2010, 217: 2191–2199.

- [5] Wang Minghui, Cheng Xuehan, Wei Musheng. Iterative algorithms for solving the matrix equation $AXB + CX^T D = E$ [J]. *Appl. Math. Comput.*, 2007, 187(2): 622–629.
- [6] Teran F, Dopico F. The solution of the equation $XA + AX^T = 0$ and its applications to the theory of orbits [J]. *Linear Algebra Appl.*, 2011, 434: 44–67.
- [7] 赵琳琳. 矩阵方程 $AXB + CX^T D = E$ 的可解性 [J]. 山东大学学报 (理学版), 2012, 47(10): 45–48.
- [8] Mehdi Dehghan, Masoud Hajarian. Finite iterative algorithms for the reflexive and anti-reflexive solutions of the matrix equations $A_1 X_1 B_1 = C, A_2 X_2 B_2 = D$ [J]. *Math. Computer Modeling*, 2009, 49: 1937–1959.
- [9] 盛兴平, 苏友峰, 陈果良. 矩阵方程 $A^T XB + B^T X^T A = D$ 的极小范数最小二乘解的迭代算法 [J]. 高等学校计算数学学报, 2008, 30(4): 352–362.
- [10] 孙合明, 李庆芳, 杨家稳. 自反矩阵下矩阵方程 $AXB + CXD = E$ 的最佳逼近解 [J]. 重庆理工大学学报 (自然科学), 2012, 26(4): 109–114.
- [11] 张光澄, 王文娟, 韩会磊等. 非线性最优化计算方法 [M]. 北京: 高等教育出版社, 2006.
- [12] Peng Zhuohua, Hu Xiyan, Zhang Lei. An efficient algorithm for the least-squares reflective solution of the matrix equations $A_1 X B_1 = C_1, A_2 X B_2 = C_2$ [J]. *Appl. Math. Comput.*, 2006, 181: 988–999.

AN ITERATIVE ALGORITHM FOR THE REFLEXIVE OPTIMAL APPROXIMATION SOLUTION OF MATRIX EQUATIONS

$$AXB + CX^T D = E$$

YANG Jia-wen¹ , SUN He-ming²

(1. Department of Basic, Chuzhou Vocational and Technical College, Chuzhou 239000, China)

(2. College of Science, Hohai University, Nanjing 210098, China)

Abstract: In this paper, we study the optimal approximation solution of the Sylvester matrix equations $AXB + CX^T D = E$ over reflexive (anti-reflexive) matrices. By using the proposed conjugate direction method, we get a result that whatever matrix equations $AXB + CX^T D = E$ are consistent or not, for arbitrary initial reflexive (anti-reflexive) matrix X_1 , the reflexive (anti-reflexive) optimal approximation solution can be obtained within finite iteration steps in the absence of round-off errors. The effectiveness of the proposed algorithm is verified by three numerical examples.

Keywords: sylvester matrix equations; Kronecker product; conjugate direction method; optimal approximation solution; reflexive matrix

2000 MR Subject Classification: 15B57