



MAX PLANCK INSTITUTE
FOR DYNAMICS OF COMPLEX
TECHNICAL SYSTEMS
MAGDEBURG



COMPUTATIONAL METHODS IN
SYSTEMS AND CONTROL THEORY

求解线性矩阵方程的 混合精度算法

Xiaobo Liu (刘晓波)

德国马克斯·普朗克复杂技术系统动力学研究所

湘潭大学数韵学术报告

中国湖南·湘潭

2026 年 9 月 16 日

基于以下合作研究

Dmytryshyn, Fasi, Higham, & L. [SIAM J. Sci. Comput., 待刊]

Benner & L. [ArXiv:2510.02126 [math.NA], 2026 年 5 月修订]



1. 混合精度简介
2. Sylvester 矩阵方程
3. 低秩 Lyapunov 矩阵方程
4. 总结



典型的（规格化）浮点格式

s	$E = (e_1 \cdots e_w)_2$	$f_1 \cdots f_{t-1}$
1 位	w 位	$t - 1$ 位

$$x = (-1)^s \cdot (1.f_1 \cdots f_{t-1})_2 \cdot 2^{E - (2^{w-1} - 1)}, \quad 2^{w-1} - 1 \text{ 为指数偏置}$$

表：四种浮点格式的参数。

格式	有效数 位数 (t)	指数 位数 (w)	数值范围	$u = 2^{-t}$
bf16	8	8	$10^{\pm 38}$	3.9×10^{-3}
fp16	11	5	$10^{\pm 5}$	4.9×10^{-4}
fp32	24	8	$10^{\pm 38}$	6.0×10^{-8}
fp64	53	11	$10^{\pm 308}$	1.1×10^{-16}

- 更低精度 $\rightsquigarrow$ 更快的浮点运算、更少的通信和更低的能耗。



典型的（规格化）浮点格式

s	$E = (e_1 \cdots e_w)_2$	$f_1 \cdots f_{t-1}$
1 位	w 位	$t - 1$ 位

$$x = (-1)^s \cdot (1.f_1 \cdots f_{t-1})_2 \cdot 2^{E - (2^{w-1} - 1)}, \quad 2^{w-1} - 1 \text{ 为指数偏置}$$

表：四种浮点格式的参数。

格式	有效数 位数 (t)	指数 位数 (w)	数值范围	$u = 2^{-t}$
bf16	8	8	$10^{\pm 38}$	3.9×10^{-3}
fp16	11	5	$10^{\pm 5}$	4.9×10^{-4}
fp32	24	8	$10^{\pm 38}$	6.0×10^{-8}
fp64	53	11	$10^{\pm 308}$	1.1×10^{-16}

- 更低精度 $\rightsquigarrow$ 更快的浮点运算、更少的通信和更低的能耗。



典型的（规格化）浮点格式

s	$E = (e_1 \cdots e_w)_2$	$f_1 \cdots f_{t-1}$
1 位	w 位	$t - 1$ 位

$$x = (-1)^s \cdot (1.f_1 \cdots f_{t-1})_2 \cdot 2^{E - (2^{w-1} - 1)}, \quad 2^{w-1} - 1 \text{ 为指数偏置}$$

表：四种浮点格式的参数。

格式	有效数 位数 (t)	指数 位数 (w)	数值范围	$u = 2^{-t}$
bf16	8	8	$10^{\pm 38}$	3.9×10^{-3}
fp16	11	5	$10^{\pm 5}$	4.9×10^{-4}
fp32	24	8	$10^{\pm 38}$	6.0×10^{-8}
fp64	53	11	$10^{\pm 308}$	1.1×10^{-16}

- 更低精度 $\rightsquigarrow$ 更快的浮点运算、更少的通信和更低的能耗。



何时使用低精度？

- 只需较低的计算精度
- 与其他来源的误差相平衡：
模型降阶、近似（如低秩近似、离散化）
- 具有自我修正机制（如迭代改进）✓

⇒ 混合精度算法在计算的不同部分选用不同精度，在保证精度与稳定性的同时提高性能。



何时使用低精度？

- 只需较低的计算精度
- 与其他来源的误差相平衡：
模型降阶、近似（如低秩近似、离散化）
- 具有自我修正机制（如迭代改进）✓

⇒ 混合精度算法在计算的不同部分选用不同精度，在保证精度与稳定性的同时提高性能。



何时使用低精度？

- 只需较低的计算精度
- 与其他来源的误差相平衡：
模型降阶、近似（如低秩近似、离散化）
- 具有自我修正机制（如迭代改进）✓

⇒ **混合精度算法**在计算的不同部分选用不同精度，在保证精度与稳定性的同时提高性能。



1. 混合精度简介
2. **Sylvester 矩阵方程**
3. 低秩 Lyapunov 矩阵方程
4. 总结



$$\underbrace{\begin{matrix} \boxed{A} \\ m \times m \end{matrix}}_{m \times m} \begin{matrix} \boxed{X} \\ m \times n \end{matrix} + \begin{matrix} \boxed{X} \\ m \times n \end{matrix} \underbrace{\begin{matrix} \boxed{B} \\ n \times n \end{matrix}}_{n \times n} = \underbrace{\begin{matrix} \boxed{C} \\ m \times n \end{matrix}}_{m \times n}$$

应用：分块对角化 • 矩阵函数扰动理论 • 系统平衡 • 控制 • 模型降阶等。

问题设置：

- 中等规模的稠密系数矩阵 $\rightsquigarrow$ 例如, $\max(m, n) \lesssim 10^4$
- 不要求具有特定结构

$\rightsquigarrow$ 首选方法：Bartels–Stewart 算法 (Bartels & Stewart, '72).

目标：结合两种精度求解 X ：高精度（工作精度）+ 低精度



$$\underbrace{\begin{matrix} \boxed{A} \\ m \times m \end{matrix}}_{m \times m} \begin{matrix} \boxed{X} \\ m \times n \end{matrix} + \begin{matrix} \boxed{X} \\ m \times n \end{matrix} \underbrace{\begin{matrix} \boxed{B} \\ n \times n \end{matrix}}_{n \times n} = \underbrace{\begin{matrix} \boxed{C} \\ m \times n \end{matrix}}_{m \times n}$$

应用：分块对角化 • 矩阵函数扰动理论 • 系统平衡 • 控制 • 模型降阶等。

问题设置：

- 中等规模的稠密系数矩阵 $\rightsquigarrow$ 例如, $\max(m, n) \lesssim 10^4$
- 不要求具有特定结构

$\rightsquigarrow$ 首选方法：Bartels–Stewart 算法 (Bartels & Stewart, '72).

目标：结合两种精度求解 X ：高精度（工作精度）+ 低精度



$$\boxed{A} \boxed{X} + \boxed{X} \boxed{B} = \boxed{C}$$

1. 计算 Schur 分解:

$$\boxed{A} = \boxed{U_A} \begin{array}{|c|} \hline \diagdown \\ T_A \\ \hline \end{array} \boxed{U_A^*}, \quad \boxed{B} = \boxed{U_B} \begin{array}{|c|} \hline \diagdown \\ T_B \\ \hline \end{array} \boxed{U_B^*}$$

2. 通过代入法求解

$$\begin{array}{|c|} \hline \diagdown \\ T_A \\ \hline \end{array} \boxed{Y} + \boxed{Y} \begin{array}{|c|} \hline \diagdown \\ T_B \\ \hline \end{array} = \boxed{\tilde{C}}, \quad \tilde{C} = U_A^* C U_B$$

3. 返回 $X := U_A Y U_B^*$



$$\boxed{A} \boxed{X} + \boxed{X} \boxed{B} = \boxed{C}$$

1. 计算 Schur 分解:

$$\boxed{A} = \boxed{U_A} \boxed{T_A} \boxed{U_A^*}, \quad \boxed{B} = \boxed{U_B} \boxed{T_B} \boxed{U_B^*}$$

2. 通过代入法求解

$$\boxed{T_A} \boxed{Y} + \boxed{Y} \boxed{T_B} = \boxed{\tilde{C}}, \quad \tilde{C} = U_A^* C U_B$$

3. 返回 $X := U_A Y U_B^*$



$$\boxed{A} \boxed{X} + \boxed{X} \boxed{B} = \boxed{C}$$

1. 计算 Schur 分解:

$$\boxed{A} = \boxed{U_A} \begin{array}{|c|} \hline \diagdown \\ T_A \\ \hline \end{array} \boxed{U_A^*}, \quad \boxed{B} = \boxed{U_B} \begin{array}{|c|} \hline \diagdown \\ T_B \\ \hline \end{array} \boxed{U_B^*}$$

2. 通过代入法求解

$$\begin{array}{|c|} \hline \diagdown \\ T_A \\ \hline \end{array} \boxed{Y} + \boxed{Y} \begin{array}{|c|} \hline \diagdown \\ T_B \\ \hline \end{array} = \boxed{\tilde{C}}, \quad \tilde{C} = U_A^* C U_B$$

3. 返回 $X := U_A Y U_B^*$



$$A X + X B = C$$



$$U_A^* U_A T_A U_A^* X U_B + U_A^* X U_B T_B U_B^* U_B = U_A^* C U_B$$

1. 计算 Schur 分解:

$$\boxed{A} = \boxed{U_A} \boxed{T_A} \boxed{U_A^*}, \quad \boxed{B} = \boxed{U_B} \boxed{T_B} \boxed{U_B^*}$$

2. 通过代入法求解

$$\boxed{T_A} \boxed{Y} + \boxed{Y} \boxed{T_B} = \boxed{\tilde{C}}, \quad \tilde{C} = U_A^* C U_B$$

3. 返回 $X := U_A Y U_B^*$



$$A X + X B = C$$



$$U_A^* U_A T_A U_A^* X U_B + U_A^* X U_B T_B U_B^* U_B = U_A^* C U_B$$

1. 计算 Schur 分解:

$$\boxed{A} = \boxed{U_A} \boxed{T_A} \boxed{U_A^*}, \quad \boxed{B} = \boxed{U_B} \boxed{T_B} \boxed{U_B^*}$$

2. 通过代入法求解

$$\boxed{T_A} \boxed{Y} + \boxed{Y} \boxed{T_B} = \boxed{\tilde{C}}, \quad \tilde{C} = U_A^* C U_B$$

3. 返回 $X := U_A Y U_B^*$



$$A X + X B = C$$



$$U_A^* U_A T_A U_A^* X U_B + U_A^* X U_B T_B U_B^* U_B = U_A^* C U_B$$

1. 计算 Schur 分解:

$$A = U_A \begin{array}{|c|} \hline T_A \\ \hline \end{array} U_A^*, \quad B = U_B \begin{array}{|c|} \hline T_B \\ \hline \end{array} U_B^*$$

2. 通过代入法求解

$$\begin{array}{|c|} \hline T_A \\ \hline \end{array} Y + Y \begin{array}{|c|} \hline T_B \\ \hline \end{array} = \tilde{C}, \quad \tilde{C} = U_A^* C U_B$$

3. 返回 $X := U_A Y U_B^*$



$$A X + X B = C$$



$$T_A Y + Y T_B = U_A^* C U_B, \quad Y = U_A^* X U_B$$

1. 计算 Schur 分解:

$$\boxed{A} = \boxed{U_A} \begin{array}{|c|} \hline \diagdown \\ T_A \\ \hline \end{array} \boxed{U_A^*}, \quad \boxed{B} = \boxed{U_B} \begin{array}{|c|} \hline \diagdown \\ T_B \\ \hline \end{array} \boxed{U_B^*}$$

2. 通过代入法求解

$$\begin{array}{|c|} \hline \diagdown \\ T_A \\ \hline \end{array} \boxed{Y} + \boxed{Y} \begin{array}{|c|} \hline \diagdown \\ T_B \\ \hline \end{array} = \boxed{\tilde{C}}, \quad \tilde{C} = U_A^* C U_B$$

3. 返回 $X := U_A Y U_B^*$



1. 计算 Schur 分解 $A =: U_A T_A U_A^*$ $\triangleright 25m^3$
2. 计算 Schur 分解 $B =: U_B T_B U_B^*$ $\triangleright 25n^3$
3. 计算 $\tilde{C} := U_A^* C U_B$ $\triangleright 2mn(m+n)$
4. 求解 $T_A Y + Y T_B = \tilde{C}$, 得到 Y $\triangleright mn(m+n)$
5. 返回 $X := U_A Y U_B^*$ $\triangleright 2mn(m+n)$

观察

- 步骤 1 和 2 采用低精度
- 使用低精度 Schur 因子 $\rightsquigarrow$ 需要修改步骤 3–5

$\rightsquigarrow$ 我们的思路

1. 已有低精度三角因子 $\rightsquigarrow$ 用迭代改进 (IR) 求解与步骤 4 中方程“邻近”的方程: 其系数矩阵为低精度三角因子加上小扰动。
2. 对低精度酉因子重新正交归一化或显式求逆



1. 计算 Schur 分解 $A =: U_A T_A U_A^*$ $\triangleright 25m^3$
2. 计算 Schur 分解 $B =: U_B T_B U_B^*$ $\triangleright 25n^3$
3. 计算 $\tilde{C} := U_A^* C U_B$ $\triangleright 2mn(m+n)$
4. 求解 $T_A Y + Y T_B = \tilde{C}$, 得到 Y $\triangleright mn(m+n)$
5. 返回 $X := U_A Y U_B^*$ $\triangleright 2mn(m+n)$

观察

- 步骤 1 和 2 采用低精度
- 使用低精度 Schur 因子 $\rightsquigarrow$ 需要修改步骤 3–5

$\rightsquigarrow$ 我们的思路

1. 已有低精度三角因子 $\rightsquigarrow$ 用迭代改进 (IR) 求解与步骤 4 中方程“邻近”的方程：其系数矩阵为低精度三角因子加上小扰动。
2. 对低精度酉因子重新正交归一化或显式求逆



1. 计算 Schur 分解 $A =: U_A T_A U_A^*$ $\triangleright 25m^3$
2. 计算 Schur 分解 $B =: U_B T_B U_B^*$ $\triangleright 25n^3$
3. 计算 $\tilde{C} := U_A^* C U_B$ $\triangleright 2mn(m+n)$
4. 求解 $T_A Y + Y T_B = \tilde{C}$, 得到 Y $\triangleright mn(m+n)$
5. 返回 $X := U_A Y U_B^*$ $\triangleright 2mn(m+n)$

观察

- 步骤 1 和 2 采用低精度
- 使用低精度 Schur 因子 $\rightsquigarrow$ 需要修改步骤 3–5

$\rightsquigarrow$ 我们的思路

1. 已有低精度三角因子 $\rightsquigarrow$ 用迭代改进 (IR) 求解与步骤 4 中方程“邻近”的方程：其系数矩阵为低精度三角因子加上小扰动。
2. 对低精度酉因子重新正交归一化或显式求逆



目标: 求解 $\underbrace{(T_A + \Delta_A)}_{T_A \text{ 低精度}} Y + Y \underbrace{(T_B + \Delta_B)}_{T_B \text{ 低精度}} = \underbrace{U_A^* C U_B}_{U_A, U_B \text{ 高精度下保持酉性}} =: D$

1 $k \leftarrow 0$

2 当 $\|\Delta_Y\| > \varepsilon$ 执行

3 $R_k \leftarrow D - (T_A + \Delta_A) Y_k + Y_k (T_B + \Delta_B)$

4 用 Bartels–Stewart 算法求解 $T_A \Delta_Y + \Delta_Y T_B = R_k$, 得到 Δ_Y

5 $Y_{k+1} \leftarrow Y_k + \Delta_Y$

6 $k \leftarrow k + 1$

7 结束

8 返回 Y_k

计算成本: $3kmn(m+n)$ 次浮点运算

• 收敛的充分条件: $\|\Delta_A\|_2 + \|\Delta_B\|_2 < \text{sep}_F(T_A, -T_B)$



目标: 求解 $\underbrace{(T_A + \Delta_A)}_{T_A \text{ 低精度}} Y + Y \underbrace{(T_B + \Delta_B)}_{T_B \text{ 低精度}} = \underbrace{U_A^* C U_B}_{U_A, U_B \text{ 高精度下保持酉性}} =: D$

1 $k \leftarrow 0$

2 **当** $\|\Delta_Y\| > \varepsilon$ **执行**

3 $R_k \leftarrow D - (T_A + \Delta_A) Y_k + Y_k (T_B + \Delta_B)$

4 用 Bartels–Stewart 算法求解 $T_A \Delta_Y + \Delta_Y T_B = R_k$, 得到 Δ_Y

5 $Y_{k+1} \leftarrow Y_k + \Delta_Y$

6 $k \leftarrow k + 1$

7 **结束**

8 **返回** Y_k

计算成本: $3kmn(m+n)$ 次浮点运算

• **收敛的充分条件:** $\|\Delta_A\|_2 + \|\Delta_B\|_2 < \text{sep}_F(T_A, -T_B)$



目标: 求解 $\underbrace{(T_A + \Delta_A)}_{T_A \text{ 低精度}} Y + Y \underbrace{(T_B + \Delta_B)}_{T_B \text{ 低精度}} = \underbrace{U_A^* C U_B}_{U_A, U_B \text{ 高精度下保持酉性}} =: D$

-
- 1 $k \leftarrow 0$
 - 2 **当** $\|\Delta_Y\| > \varepsilon$ **执行**
 - 3 $R_k \leftarrow D - (T_A + \Delta_A) Y_k + Y_k (T_B + \Delta_B)$
 - 4 用 Bartels–Stewart 算法求解 $T_A \Delta_Y + \Delta_Y T_B = R_k$, 得到 Δ_Y
 - 5 $Y_{k+1} \leftarrow Y_k + \Delta_Y$
 - 6 $k \leftarrow k + 1$
 - 7 **结束**
 - 8 **返回** Y_k
-

计算成本: $3kmn(m+n)$ 次浮点运算

- **收敛**的充分条件: $\|\Delta_A\|_2 + \|\Delta_B\|_2 < \text{sep}_F(T_A, -T_B)$



- 1 计算 Schur 分解 $A = U_A T_A U_A^*$ ▷ 采用低精度 u_ℓ
- 2 计算 Schur 分解 $B = U_B T_B U_B^*$
- 3 计算 QR 分解 $U_A = Q_A R_A$, $U_B = Q_B R_B$ ▷ 重新正交归一化
- 4 $\Delta_A \leftarrow Q_A^* A Q_A - T_A$
- 5 $\Delta_B \leftarrow Q_B^* B Q_B - T_B$
- 6 $D \leftarrow Q_A^* C Q_B$
- 7 求解 $T_A Y + Y T_B = D$, 得到 Y
- 8 当 $\|\Delta_Y\| > \varepsilon$ 执行
 - 9 $R \leftarrow D - (T_A + \Delta_A) Y + Y (T_B + \Delta_B)$
 - 10 用 Bartels–Stewart 算法求解 $T_A \Delta_Y + \Delta_Y T_B = R$, 得到 Δ_Y
 - 11 $Y \leftarrow Y + \Delta_Y$
- 12 结束
- 13 $X \leftarrow Q_A Y Q_B^*$



- 1 计算 Schur 分解 $A = U_A T_A U_A^*$ ▷ 采用低精度 u_ℓ
- 2 计算 Schur 分解 $B = U_B T_B U_B^*$
- 3 计算 U_A^* 和 U_B 的 LU 分解
- 4 $\Delta_A \leftarrow U_A^* A U_A^{-*} - T_A$
- 5 $\Delta_B \leftarrow U_B^{-1} B U_B - T_B$
- 6 $D \leftarrow U_A^* C U_B$
- 7 求解 $T_A Y + Y T_B = D$, 得到 Y
- 8 当 $\|\Delta_Y\| > \varepsilon$ 执行
 - 9 $R \leftarrow D - (T_A + \Delta_A) Y + Y (T_B + \Delta_B)$
 - 10 用 Bartels–Stewart 算法求解 $T_A \Delta_Y + \Delta_Y T_B = R$, 得到 Δ_Y
 - 11 $Y \leftarrow Y + \Delta_Y$
- 12 结束
- 13 $X \leftarrow U_A^{-*} Y U_B^{-1}$



混合精度算法的计算成本

- 重新正交归一化
 - $25(m^3 + n^3) + mn(m + n)$ 低精度浮点运算
 - $6(m^3 + n^3) + (4 + 3k)mn(m + n)$ 高精度浮点运算
- 求逆
 - $25(m^3 + n^3) + mn(m + n)$ 低精度浮点运算
 - $4\frac{2}{3}(m^3 + n^3) + (4 + 3k)mn(m + n)$ 高精度浮点运算

Bartels–Stewart 算法的计算成本

- $25(m^3 + n^3) + 5mn(m + n)$ 高精度浮点运算

这些计算成本应如何比较？



混合精度算法的计算成本

- 重新正交归一化
 - $25(m^3 + n^3) + mn(m + n)$ 低精度浮点运算
 - $6(m^3 + n^3) + (4 + 3k)mn(m + n)$ 高精度浮点运算
- 求逆
 - $25(m^3 + n^3) + mn(m + n)$ 低精度浮点运算
 - $4\frac{2}{3}(m^3 + n^3) + (4 + 3k)mn(m + n)$ 高精度浮点运算

Bartels–Stewart 算法的计算成本

- $25(m^3 + n^3) + 5mn(m + n)$ 高精度浮点运算

这些计算成本应如何比较？



计算成本模型

$$\rho = \frac{\text{低精度单次浮点运算平均时间}}{\text{高精度单次浮点运算平均时间}}$$

$\rho = 0$ 低精度浮点运算的成本可忽略

$\rho = 1$ 低、高精度浮点运算的成本相同

$\rho > 1$ 模拟的低精度运算

$0 \leq \rho \ll 1$ 在新型硬件（如 GPU）上成立



计算成本模型

$$\rho = \frac{\text{低精度单次浮点运算平均时间}}{\text{高精度单次浮点运算平均时间}}$$

$\rho = 0$ 低精度浮点运算的成本可忽略

$\rho = 1$ 低、高精度浮点运算的成本相同

$\rho > 1$ 模拟的低精度运算

$0 \leq \rho \ll 1$ 在新型硬件（如 GPU）上成立



计算成本模型

$$\rho = \frac{\text{低精度单次浮点运算平均时间}}{\text{高精度单次浮点运算平均时间}}$$

$\rho = 0$ 低精度浮点运算的成本可忽略

$\rho = 1$ 低、高精度浮点运算的成本相同

$\rho > 1$ 模拟的低精度运算

$0 \leq \rho \ll 1$ 在新型硬件（如 GPU）上成立



归一化计算成本（以高精度运算为单位）

$$C_N = C_h + \rho \cdot C_\ell$$

- C_h : 高精度浮点运算次数
- C_ℓ : 低精度浮点运算次数

C_ℓ 中的每次浮点运算均按 ρ 加权。




最大迭代次数


$$\lfloor \varphi(\rho) \rfloor, \quad \varphi(\rho) = \frac{C_{BS}(m, n) - C_N^{ni}(m, n)}{C_N^{it}(m, n)}$$

其中

- $C_{BS}(m, n)$: **高精度** Bartels–Stewart 算法的成本
- $C_N^{ni}(m, n)$: 新算法**非迭代部分**的归一化成本
- $C_N^{it}(m, n)$: 改进过程**一次迭代**的归一化成本



(a) 基于重新正交归一化。



(b) 基于求逆。

- $\rho = \text{低精度单次浮点运算平均时间} / \text{高精度单次浮点运算平均时间}$



算法

- sylv: MATLAB 内置函数 `sylvester`
- mp_orth: 重新正交归一化算法的 MATLAB 实现
- mp_inv: 求逆算法的 MATLAB 实现


迭代改进容差: $1e-12 \cdot \max(m, n)$

测试集


- 文献中的 19 个 Sylvester 方程, 规模为 31–1,668

精度

- TensorFloat-32: 由 CPFloat 模拟 (Fasi & Mikaitis, '23)
- 自定义 24 位格式: 有效数为 16 位, 数值范围与 TensorFloat-32 相同
- binary64 (高精度)




(c) 相对残差。




(d) 迭代次数。

- 采用 tf32/fp64 且 $\rho \leq 0.2$ 时，多数情况下快于 Bartels–Stewart 算法
- GB200 TC 上 tf32 加速 $31.3\times$ (90 PFLOPS/2880 TFLOPS) (NVIDIA, '25)




(e) 相对残差。




(f) 迭代次数。

- 采用 tf32/fp64 且 $\rho \leq 0.2$ 时，多数情况下快于 Bartels–Stewart 算法
- GB200 TC 上 tf32 加速 $31.3\times$ (90 PFLOPS/2880 TFLOPS) (NVIDIA, '25)




(g) 相对残差。




(h) 迭代次数。

- 新算法在所有测试问题上均收敛
- 采用 24 位格式/fp64 且 $\rho \leq 0.3$ 时，多数情况下快于 Bartels–Stewart 算法



(i) 相对残差。



(j) 迭代次数。

- 新算法在所有测试问题上均收敛
- 采用 24 位格式/fp64 且 $\rho \leq 0.3$ 时，多数情况下快于 Bartels–Stewart 算法



1. 混合精度简介
2. Sylvester 矩阵方程
- 3. 低秩 Lyapunov 矩阵方程**
4. 总结



低秩（代数）Lyapunov 方程

$$\underbrace{\boxed{A}}_{n \times n} \boxed{X} + \boxed{X} \boxed{A^T} = - \underbrace{\boxed{L} \boxed{L^T}}_{W=LL^T} \quad \text{或} \quad - \underbrace{\boxed{L} \boxed{S} \boxed{L^T}}_{W=LSL^T}$$

$$L \in \mathbb{R}^{n \times m}, \quad S = S^T \in \mathbb{R}^{m \times m}, \quad m \ll n.$$

应用于控制理论、系统平衡和模型降阶等。

- $n \sim 10^4$ 或更大
- $\operatorname{Re} \lambda_i(A) < 0$, W 为半正定矩阵
- X 为半正定矩阵, 且具有较小的数值秩:

$$\|X - X_\varepsilon\| \leq u\|X\|, \quad \operatorname{rank}(X_\varepsilon) \ll n$$

$\leadsto$ 寻求 $X = ZZ^T$, 其中因子 $Z \approx$ 低秩矩阵 (Komaroff, '88).



低秩（代数）Lyapunov 方程

$$\underbrace{\boxed{A}}_{n \times n} \boxed{X} + \boxed{X} \boxed{A^T} = - \underbrace{\boxed{L} \boxed{L^T}}_{W=LL^T} \quad \text{或} \quad - \underbrace{\boxed{L} \boxed{S} \boxed{L^T}}_{W=LSL^T}$$

$$L \in \mathbb{R}^{n \times m}, \quad S = S^T \in \mathbb{R}^{m \times m}, \quad m \ll n.$$

应用于控制理论、系统平衡和模型降阶等。

- $n \sim 10^4$ 或更大
- $\operatorname{Re} \lambda_i(A) < 0$, W 为半正定矩阵
- X 为半正定矩阵, 且具有较小的数值秩:

$$\|X - X_\varepsilon\| \leq u\|X\|, \quad \operatorname{rank}(X_\varepsilon) \ll n$$

$\leadsto$ 寻求 $X = ZZ^T$, 其中因子 $Z \approx$ 低秩矩阵 (Komaroff, '88).



对 $Ax = b$, 使用三种精度 $u_r \leq u \leq u_s$: (Carson & Higham, '18)

- u , 工作精度
- u_s , 求解修正方程
- u_r , 残差计算

-
- 1 以精度 u_s 求解 $Ax = b$, 以精度 u 存储 x
 - 2 重复
 - 3 以精度 u_r 计算 $r = b - Ax$, 并将 r 舍入至精度 u_s
 - 4 以精度 u_s 求解 $Ad = r$, 以精度 u 存储 d
 - 5 以精度 u 更新 $x \leftarrow x + d$.
 - 6 直到 收敛
-

- 后向误差可达 $O(u)$, 取决于 $\kappa(A)$



- 已有工作：用两种精度的迭代改进 (IR) 求解 $AX + XA^T + LL^T = 0$ (Benner et al., '11).
 - 在 CPU-GPU 混合平台上的 fp32-fp64 实现
 - $X = ZZ^T$ 的 **Cholesky 型**解因子 Z
 - 未给出舍入误差分析
- 我们的贡献：
 - 推广至 **LDL^T 型**因子形式 $X = ZYZ^T \rightsquigarrow$ 允许解的迭代矩阵为不定矩阵
 - 针对两种形式开展混合精度误差分析



- 已有工作：用两种精度的迭代改进 (IR) 求解 $AX + XA^T + LL^T = 0$ (Benner et al., '11).
 - 在 CPU-GPU 混合平台上的 fp32-fp64 实现
 - $X = ZZ^T$ 的 **Cholesky 型**解因子 Z
 - 未给出舍入误差分析
- 我们的贡献：
 - 推广至 **LDL^T 型**因子形式 $X = ZYZ^T \rightsquigarrow$ 允许解的迭代矩阵为不定矩阵
 - 针对两种形式开展混合精度误差分析



计算 $AX + XA^T + LSL^T = 0$ 的解 $X = ZYZ^T$ 。

-
- 1 以精度 u_s 求解 $AX + XA^T + LSL^T = 0$, 以精度 u 存储 Z 和 Y
 - 2 重复
 - 3 计算 $\mathcal{R}(Z, Y) := AZYZ^T + ZYZ^TA^T + LSL^T = L_\Delta S_\Delta L_\Delta^T$ (采用精度 u_r), 并将 L_Δ 和 S_Δ 舍入至精度 u_s
 - 4 以精度 u_s 求解 $AX_\Delta + X_\Delta A^T + L_\Delta S_\Delta L_\Delta^T = 0$, 并以精度 u 存储 Z_Δ 和 Y_Δ (其中 $X_\Delta = Z_\Delta Y_\Delta Z_\Delta^T$)
 - 5 以精度 u 求与 $X \leftarrow X + X_\Delta$ 最近的半正定矩阵的因子 Z 和 Y 。
► 右端项非半正定; 计算 Y 、 Z 时不显式构造 $n \times n$ 矩阵
 - 6 直到 收敛
-

• 高于 u_s 的精度下仅需 $O(n^2)$ 次浮点运算: 残差计算与解更新。



计算 $AX + XA^T + LSL^T = 0$ 的解 $X = ZYZ^T$ 。

-
- 1 以精度 u_s 求解 $AX + XA^T + LSL^T = 0$, 以精度 u 存储 Z 和 Y
 - 2 重复
 - 3 计算 $\mathcal{R}(Z, Y) := AZYZ^T + ZYZ^TA^T + LSL^T = L_\Delta S_\Delta L_\Delta^T$ (采用精度 u_r), 并将 L_Δ 和 S_Δ 舍入至精度 u_s
 - 4 以精度 u_s 求解 $AX_\Delta + X_\Delta A^T + L_\Delta S_\Delta L_\Delta^T = 0$, 并以精度 u 存储 Z_Δ 和 Y_Δ (其中 $X_\Delta = Z_\Delta Y_\Delta Z_\Delta^T$)
 - 5 以精度 u 求与 $X \leftarrow X + X_\Delta$ 最近的半正定矩阵的因子 Z 和 Y .
▶ 右端项非半正定; 计算 Y 、 Z 时不显式构造 $n \times n$ 矩阵
 - 6 直到 收敛
-

- 高于 u_s 的精度下仅需 $O(n^2)$ 次浮点运算: 残差计算与解更新。



计算 $AX + XA^T + LSL^T = 0$ 的解 $X = ZYZ^T$ 。

-
- 1 以精度 u_s 求解 $AX + XA^T + LSL^T = 0$ ，以精度 u 存储 Z 和 Y
 - 2 重复
 - 3 计算 $\mathcal{R}(Z, Y) := AZYZ^T + ZYZ^TA^T + LSL^T = L_\Delta S_\Delta L_\Delta^T$ (采用精度 u_r)，并将 L_Δ 和 S_Δ 舍入至精度 u_s
 - 4 以精度 u_s 求解 $AX_\Delta + X_\Delta A^T + L_\Delta S_\Delta L_\Delta^T = 0$ ，并以精度 u 存储 Z_Δ 和 Y_Δ (其中 $X_\Delta = Z_\Delta Y_\Delta Z_\Delta^T$)
 - 5 以精度 u 求与 $X \leftarrow X + X_\Delta$ 最近的半正定矩阵的因子 Z 和 Y 。
▶ 右端项非半正定；计算 Y 、 Z 时不显式构造 $n \times n$ 矩阵
 - 6 直到 收敛
-

• 高于 u_s 的精度下仅需 $O(n^2)$ 次浮点运算：残差计算与解更新。



计算 $AX + XA^T + LSL^T = 0$ 的解 $X = ZYZ^T$ 。

-
- 1 以精度 u_s 求解 $AX + XA^T + LSL^T = 0$ ，以精度 u 存储 Z 和 Y
 - 2 重复
 - 3 计算 $\mathcal{R}(Z, Y) := AZYZ^T + ZYZ^TA^T + LSL^T = L_\Delta S_\Delta L_\Delta^T$ (采用精度 u_r)，并将 L_Δ 和 S_Δ 舍入至精度 u_s
 - 4 以精度 u_s 求解 $AX_\Delta + X_\Delta A^T + L_\Delta S_\Delta L_\Delta^T = 0$ ，并以精度 u 存储 Z_Δ 和 Y_Δ (其中 $X_\Delta = Z_\Delta Y_\Delta Z_\Delta^T$)
 - 5 以精度 u 求与 $X \leftarrow X + X_\Delta$ 最近的半正定矩阵的因子 Z 和 Y 。
▶ 右端项非半正定；计算 Y 、 Z 时不显式构造 $n \times n$ 矩阵
 - 6 直到收敛
-

• 高于 u_s 的精度下仅需 $O(n^2)$ 次浮点运算：残差计算与解更新。



1. 将 $\mathcal{R}(Z, Y) = AZYZ^T + ZYZ^T A^T + LSL^T$ 改写为

$$\begin{aligned}\mathcal{R}(Z, Y) &= \begin{bmatrix} Z & AZ & L \end{bmatrix} \begin{bmatrix} 0 & Y & 0 \\ Y & 0 & 0 \\ 0 & 0 & S \end{bmatrix} \begin{bmatrix} Z^T \\ Z^T A^T \\ L^T \end{bmatrix} \\ &=: FNF^T, \quad F \text{ 为高瘦矩阵 } (Z \text{ 和 } L \text{ 亦如此}).\end{aligned}$$

2. 计算薄 QR 分解 $F = UT$, 构造 $H = TNT^T$, 再计算谱分解 $H = Q\Lambda Q^T$ 。

3. 进行特征值截断, 舍去满足 $|\lambda_i| < \eta_r$ 的项:

$$\mathcal{R}(Z, Y) \approx UQ_t\Lambda_tQ_t^T U^T =: L_\Delta S_\Delta L_\Delta^T,$$

其中

$$L_\Delta = UQ_t, \quad S_\Delta = \Lambda_t.$$



1. 将 $\mathcal{R}(Z, Y) = AZYZ^T + ZYZ^T A^T + LSL^T$ 改写为

$$\mathcal{R}(Z, Y) = \begin{bmatrix} Z & AZ & L \end{bmatrix} \begin{bmatrix} 0 & Y & 0 \\ Y & 0 & 0 \\ 0 & 0 & S \end{bmatrix} \begin{bmatrix} Z^T \\ Z^T A^T \\ L^T \end{bmatrix}$$

$=: FNF^T$, F 为高瘦矩阵 (Z 和 L 亦如此).

2. 计算薄 QR 分解 $F = UT$, 构造 $H = TNT^T$, 再计算谱分解 $H = Q\Lambda Q^T$.

3. 进行特征值截断, 舍去满足 $|\lambda_i| < \eta_r$ 的项:

$$\mathcal{R}(Z, Y) \approx UQ_t\Lambda_tQ_t^T U^T =: L_\Delta S_\Delta L_\Delta^T,$$

其中

$$L_\Delta = UQ_t, \quad S_\Delta = \Lambda_t.$$



1. 将 $\mathcal{R}(Z, Y) = AZYZ^T + ZYZ^T A^T + LSL^T$ 改写为

$$\mathcal{R}(Z, Y) = \begin{bmatrix} Z & AZ & L \end{bmatrix} \begin{bmatrix} 0 & Y & 0 \\ Y & 0 & 0 \\ 0 & 0 & S \end{bmatrix} \begin{bmatrix} Z^T \\ Z^T A^T \\ L^T \end{bmatrix}$$

$=: FNF^T$, F 为高瘦矩阵 (Z 和 L 亦如此).

2. 计算薄 QR 分解 $F = UT$, 构造 $H = TNT^T$, 再计算谱分解 $H = Q\Lambda Q^T$.

3. 进行特征值截断, 舍去满足 $|\lambda_i| < \eta_r$ 的项:

$$\mathcal{R}(Z, Y) \approx UQ_t\Lambda_tQ_t^T U^T =: L_\Delta S_\Delta L_\Delta^T,$$

其中

$$L_\Delta = UQ_t, \quad S_\Delta = \Lambda_t.$$



利用 Z_Δ 和 Y_Δ 更新 Z 和 Y 。

1. 构造

$$G := \begin{bmatrix} Z & Z_\Delta \end{bmatrix}, \quad G \text{ 为高瘦矩阵, 且 } \Upsilon = \begin{bmatrix} Y \\ Y_\Delta \end{bmatrix}.$$

2. 计算薄 QR 分解 $G = V\Gamma$, 构造 $K = \Gamma\Upsilon\Gamma^T$, 再计算谱分解 $K = \Theta\Sigma\Theta^T$ 。

3. 进行特征值截断, 舍去满足 $\sigma_i < \eta_s$ 的项:

$$Z_{\text{new}} = V\Theta_t, \quad Y_{\text{new}} = \Sigma_t,$$

使得

$$X_{\text{new}} \approx V\Theta_t\Sigma_t\Theta_t^T V^T = Z_{\text{new}} Y_{\text{new}} Z_{\text{new}}^T.$$



利用 Z_Δ 和 Y_Δ 更新 Z 和 Y 。

1. 构造

$$G := \begin{bmatrix} Z & Z_\Delta \end{bmatrix}, \quad G \text{ 为高瘦矩阵, 且 } \Upsilon = \begin{bmatrix} Y \\ Y_\Delta \end{bmatrix}.$$

2. 计算薄 QR 分解 $G = V\Upsilon$, 构造 $K = \Upsilon\Upsilon^T$, 再计算谱分解 $K = \Theta\Sigma\Theta^T$ 。

3. 进行特征值截断, 舍去满足 $\sigma_i < \eta_s$ 的项:

$$Z_{\text{new}} = V\Theta_t, \quad Y_{\text{new}} = \Sigma_t,$$

使得

$$X_{\text{new}} \approx V\Theta_t\Sigma_t\Theta_t^T V^T = Z_{\text{new}} Y_{\text{new}} Z_{\text{new}}^T.$$



利用 Z_Δ 和 Y_Δ 更新 Z 和 Y 。

1. 构造

$$G := \begin{bmatrix} Z & Z_\Delta \end{bmatrix}, \quad G \text{ 为高瘦矩阵, 且 } \Upsilon = \begin{bmatrix} Y \\ Y_\Delta \end{bmatrix}.$$

2. 计算薄 QR 分解 $G = V\Upsilon$, 构造 $K = \Upsilon\Upsilon^T$, 再计算谱分解 $K = \Theta\Sigma\Theta^T$ 。

3. 进行特征值截断, 舍去满足 $\sigma_i < \eta_s$ 的项:

$$Z_{\text{new}} = V\Theta_t, \quad Y_{\text{new}} = \Sigma_t,$$

使得

$$X_{\text{new}} \approx V\Theta_t\Sigma_t\Theta_t^T V^T = Z_{\text{new}} Y_{\text{new}} Z_{\text{new}}^T.$$



表：采用稳定求解器时的条件数界与极限残差。

u_s	$u_r = u$	条件数上界 $\kappa_F(\mathcal{L})$	极限 残差
bf16	fp32	10^3	fp32
fp16		10^4	
fp32		10^8	
bf16	fp64	10^3	fp64
fp16		10^4	
fp32		10^8	
fp64		10^{16}	



矩阵符号函数的 Newton 迭代

作为混合精度迭代改进的求解器

- 矩阵符号函数的 Newton 迭代 作为 LDL^T 型求解器 (Roberts, '80):

$$AX + XA^T + W = 0, \quad W = LSL^T, \quad X = ZYZ^T.$$

- 实现简单且稳健
- 具有良好的并行性
- 大量使用三级 BLAS 运算
- 其他求解器也适用, 只需返回 Cholesky/ LDL^T 型解因子



对 $\mu_{k-1} > 0$, 进行迭代 (Larin & Aliev, '93; Benner & Quintana-Ortí, '99)

$$\begin{aligned} A_k &= \frac{1}{2} (\mu_{k-1} A_{k-1} + \mu_{k-1}^{-1} A_{k-1}^{-1}), & A_0 &= A, \\ Z_k &= \begin{bmatrix} Z_{k-1} & A_{k-1}^{-1} Z_{k-1} \end{bmatrix}, & Z_0 &= L, \\ Y_k &= \frac{1}{2} \begin{bmatrix} \mu_{k-1} Y_{k-1} & \\ & \mu_{k-1}^{-1} Y_{k-1} \end{bmatrix}, & Y_0 &= S. \end{aligned}$$

收敛时,

$$\frac{1}{2} Z_k Y_k Z_k^T \longrightarrow X, \quad Z = Z_k, \quad Y = \frac{1}{2} Y_k,$$

且

$$A_k \longrightarrow -I.$$



对 $\mu_{k-1} > 0$, 进行迭代 (Larin & Aliev, '93; Benner & Quintana-Ortí, '99)

$$\begin{aligned} A_k &= \frac{1}{2} (\mu_{k-1} A_{k-1} + \mu_{k-1}^{-1} A_{k-1}^{-1}), & A_0 &= A, \\ Z_k &= \begin{bmatrix} Z_{k-1} & A_{k-1}^{-1} Z_{k-1} \end{bmatrix}, & Z_0 &= L, \\ Y_k &= \frac{1}{2} \begin{bmatrix} \mu_{k-1} Y_{k-1} & \\ & \mu_{k-1}^{-1} Y_{k-1} \end{bmatrix}, & Y_0 &= S. \end{aligned}$$

收敛时,

$$\frac{1}{2} Z_k Y_k Z_k^T \longrightarrow X, \quad Z = Z_k, \quad Y = \frac{1}{2} Y_k,$$

且

$$A_k \longrightarrow -I.$$



- 每次迭代中, Z_k 和 Y_k 的列数加倍, 导致存储量指数增长:

$$\begin{aligned} A_k &= \frac{1}{2} (\mu_{k-1} A_{k-1} + \mu_{k-1}^{-1} A_{k-1}^{-1}), & A_0 &= A, \\ Z_k &= \begin{bmatrix} Z_{k-1} & A_{k-1}^{-1} Z_{k-1} \end{bmatrix}, & Z_0 &= L, \\ Y_k &= \begin{bmatrix} \frac{\mu_{k-1}}{2} Y_{k-1} & \\ & \frac{1}{2\mu_{k-1}} Y_{k-1} \end{bmatrix}, & Y_0 &= S. \end{aligned}$$

⇒ 解决方法: 对 Z_k 和 Y_k 进行秩截断 (Benner & Quintana-Ortí, '99):

子程序 $[Z, Y] = \text{RANKTRUNCLDLT}(Z, Y)$

- 1 计算薄 QR 分解 $Z = QR$ 。
- 2 计算谱分解 $RYR^T = \tilde{V}\tilde{\Lambda}\tilde{V}^T$ 。
- 3 $\Lambda = \text{diag}(\tilde{\lambda}_i)$, $i \in I_\lambda := \{i \mid \tilde{\lambda}_i > u\|\tilde{\Lambda}\|_1\}$ 且 $V = \tilde{V}(:, I_\lambda)$
- 4 $Z = QV$, $Y = \Lambda$



- 每次迭代中, Z_k 和 Y_k 的列数加倍, 导致存储量指数增长:

$$\begin{aligned} A_k &= \frac{1}{2} (\mu_{k-1} A_{k-1} + \mu_{k-1}^{-1} A_{k-1}^{-1}), & A_0 &= A, \\ Z_k &= \begin{bmatrix} Z_{k-1} & A_{k-1}^{-1} Z_{k-1} \end{bmatrix}, & Z_0 &= L, \\ Y_k &= \begin{bmatrix} \frac{\mu_{k-1}}{2} Y_{k-1} & \\ & \frac{1}{2\mu_{k-1}} Y_{k-1} \end{bmatrix}, & Y_0 &= S. \end{aligned}$$

⇒ 解决方法: 对 Z_k 和 Y_k 进行秩截断 (Benner & Quintana-Ortí, '99):

子程序 $[Z, Y] = \text{RANKTRUNC LDLT}(Z, Y)$

- 1 计算薄 QR 分解 $Z = QR$ 。
 - 2 计算谱分解 $RYR^T = \tilde{V}\tilde{\Lambda}\tilde{V}^T$ 。
 - 3 $\Lambda = \text{diag}(\tilde{\lambda}_i)$, $i \in I_\lambda := \{i \mid \tilde{\lambda}_i > u\|\tilde{\Lambda}\|_1\}$ 且 $V = \tilde{V}(:, I_\lambda)$
 - 4 $Z = QV$, $Y = \Lambda$
-



算法：求解 Lyapunov 方程的 LDL^T 型矩阵符号函数 Newton 迭代
 $AX + XA^T + W = 0, W = LSL^T$.

-
- 1 $Z_0 = L, Y_0 = S, A_0 = A$
 - 2 对 $k \leftarrow 1$ 至 $k_{\max}$ 执行
 - 3 $A_k = \frac{1}{2}(\mu_{k-1} A_{k-1} + \mu_{k-1}^{-1} A_{k-1}^{-1})$ [*] 其中 μ_{k-1} 为缩放因子。
 - 4 $Z_k = \begin{bmatrix} Z_{k-1} & A_{k-1}^{-1} Z_{k-1} \end{bmatrix}$
 - 5 $Y_k = \frac{1}{2} \text{blkdiag}(\mu_{k-1} Y_{k-1}, \mu_{k-1}^{-1} Y_{k-1})$
 - 6 若 $\text{size}(Z_k, 2) > \rho n$ 则 $[Z_k, Y_k] = \text{RANKTRUNC LDLT}(Z_k, Y_k)$
 - 7 若 $\|A_k + I_n\|_1 \leq \tau$ 则
 - 8 再迭代两次后终止。
 - 9 $Y = Y_k/2$
-

- 参数：收敛容差： $\tau = 10\sqrt{nu}$, 秩截断容差： $\rho \ll 1$
- [*] 每次迭代的主要计算成本： $2n^3$



每个改进（外层）步骤中：

- 包含三个主要步骤
- $O(n^2)$ 次浮点运算用于残差分解和解因子更新
- 假设精度 u_r 或 u 下的一次浮点运算，成本不超过精度 u_s 下的 n 次浮点运算
- 主要成本（求解步骤）： k 次 Newton（内层）迭代共需 $2kn^3$ 次浮点运算
- 主要成本：精度 u_s 下 $2(k_0 + k_1 + \cdots + k_i)n^3$ 次浮点运算。 k_ℓ 为第 ℓ 个改进步骤中的 Newton（内层）迭代次数。
- 成本权衡：降低求解精度 $u_s \rightsquigarrow$ Newton（内层）迭代收敛变慢， k_i 增大。



每个改进（外层）步骤中：

- 包含三个主要步骤
- $O(n^2)$ 次浮点运算用于残差分解和解因子更新
- 假设精度 u_r 或 u 下的一次浮点运算，成本不超过精度 u_s 下的 n 次浮点运算
- 主要成本（求解步骤）： k 次 Newton（内层）迭代共需 $2kn^3$ 次浮点运算
- 主要成本：精度 u_s 下 $2(k_0 + k_1 + \cdots + k_i)n^3$ 次浮点运算。 k_ℓ 为第 ℓ 个改进步骤中的 Newton（内层）迭代次数。
- 成本权衡：降低求解精度 $u_s \rightsquigarrow$ Newton（内层）迭代收敛变慢， k_i 增大。



每个改进（外层）步骤中：

- 包含三个主要步骤
- $O(n^2)$ 次浮点运算用于残差分解和解因子更新
- 假设精度 u_r 或 u 下的一次浮点运算，成本不超过精度 u_s 下的 n 次浮点运算
- 主要成本（求解步骤）： k 次 Newton（内层）迭代共需 $2kn^3$ 次浮点运算
- 主要成本：精度 u_s 下 $2(k_0 + k_1 + \cdots + k_i)n^3$ 次浮点运算。 k_ℓ 为第 ℓ 个改进步骤中的 Newton（内层）迭代次数。
- 成本权衡：降低求解精度 $u_s \rightsquigarrow$ Newton（内层）迭代收敛变慢， k_i 增大。



- 事实：每个改进（外层）步骤都生成相同的序列：

$$A_1^{-1}, A_2^{-1}, \dots, \quad A_0 = A.$$

⇒ 思路：在不同改进迭代之间复用 $\hat{A}_1^{-1}, \hat{A}_2^{-1}, \dots$

- 主要成本： $2 \sum_{\ell=0}^i k_{\ell} n^3$ $2 \max_{0 \leq \ell \leq i} k_{\ell} n^3$ 次精度 u_s 下的浮点运算。 k_{ℓ} 为第 ℓ 个改进步骤中的 Newton（内层）迭代次数。
- 以额外存储换取更低的计算成本：当 $\hat{A}_1^{-1}, \hat{A}_2^{-1}, \dots$ 可容纳于高速存储器时，尤其值得考虑

比较计算成本时关注的量：

$$k^{\sigma} =: \sum_{\ell=0}^i k_{\ell} \quad \text{或} \quad k^{\max} =: \max_{0 \leq \ell \leq i} k_{\ell}.$$

比较采用不同求解器精度的混合精度迭代改进成本：

$$k_{\text{low}}^{\sigma} / k_{\text{high}}^{\sigma} \quad \text{或} \quad k_{\text{low}}^{\max} / k_{\text{high}}^{\max}$$



- 事实：每个改进（外层）步骤都生成相同的序列：

$$A_1^{-1}, A_2^{-1}, \dots, A_0 = A.$$

⇒ 思路：在不同改进迭代之间复用 $\hat{A}_1^{-1}, \hat{A}_2^{-1}, \dots$

- 主要成本： $2 \sum_{\ell=0}^i k_{\ell} n^3$ $2 \max_{0 \leq \ell \leq i} k_{\ell} n^3$ 次精度 u_s 下的浮点运算。 k_{ℓ} 为第 ℓ 个改进步骤中的 Newton（内层）迭代次数。

- 以额外存储换取更低的计算成本：当 $\hat{A}_1^{-1}, \hat{A}_2^{-1}, \dots$ 可容纳于高速存储器时，尤其值得考虑

比较计算成本时关注的量：

$$k^{\sigma} =: \sum_{\ell=0}^i k_{\ell} \quad \text{或} \quad k^{\max} =: \max_{0 \leq \ell \leq i} k_{\ell}.$$

比较采用不同求解器精度的混合精度迭代改进成本：

$$k_{\text{low}}^{\sigma} / k_{\text{high}}^{\sigma} \quad \text{或} \quad k_{\text{low}}^{\max} / k_{\text{high}}^{\max}$$



- 事实：每个改进（外层）步骤都生成相同的序列：

$$A_1^{-1}, A_2^{-1}, \dots, \quad A_0 = A.$$

⇒ 思路：在不同改进迭代之间复用 $\hat{A}_1^{-1}, \hat{A}_2^{-1}, \dots$

- 主要成本： $2 \sum_{\ell=0}^i k_{\ell} n^3$ $2 \max_{0 \leq \ell \leq i} k_{\ell} n^3$ 次精度 u_s 下的浮点运算。 k_{ℓ} 为第 ℓ 个改进步骤中的 Newton（内层）迭代次数。
- 以额外存储换取更低的计算成本：当 $\hat{A}_1^{-1}, \hat{A}_2^{-1}, \dots$ 可容纳于高速存储器时，尤其值得考虑

比较计算成本时关注的量：

$$k^{\sigma} =: \sum_{\ell=0}^i k_{\ell} \quad \text{或} \quad k^{\max} =: \max_{0 \leq \ell \leq i} k_{\ell}.$$

比较采用不同求解器精度的混合精度迭代改进成本：

$$k_{\text{low}}^{\sigma} / k_{\text{high}}^{\sigma} \quad \text{或} \quad k_{\text{low}}^{\max} / k_{\text{high}}^{\max}$$



- 事实：每个改进（外层）步骤都生成相同的序列：

$$A_1^{-1}, A_2^{-1}, \dots, \quad A_0 = A.$$

⇒ 思路：在不同改进迭代之间复用 $\hat{A}_1^{-1}, \hat{A}_2^{-1}, \dots$

- 主要成本： $2 \sum_{\ell=0}^i k_{\ell} n^3$ $2 \max_{0 \leq \ell \leq i} k_{\ell} n^3$ 次精度 u_s 下的浮点运算。 k_{ℓ} 为第 ℓ 个改进步骤中的 Newton（内层）迭代次数。
- 以额外存储换取更低的计算成本：当 $\hat{A}_1^{-1}, \hat{A}_2^{-1}, \dots$ 可容纳于高速存储器时，尤其值得考虑

比较计算成本时关注的量：

$$k^{\sigma} =: \sum_{\ell=0}^i k_{\ell} \quad \text{或} \quad k^{\max} =: \max_{0 \leq \ell \leq i} k_{\ell}.$$

比较采用不同求解器精度的混合精度迭代改进成本：

$$k_{\text{low}}^{\sigma} / k_{\text{high}}^{\sigma} \quad \text{或} \quad k_{\text{low}}^{\max} / k_{\text{high}}^{\max}$$



- 在 MATLAB 中使用 bf16、fp32、fp64, bf16 由 chop 模拟 (Higham & Pranesh, '19)
- 以 fp64 计算以下指标:

$$\text{Res}(\hat{Z}, \hat{Y}) = \frac{\|A\hat{Z}\hat{Y}\hat{Z}^T + \hat{Z}\hat{Y}\hat{Z}^T A^T + W\|_F}{\|W\|_F + 2\|\hat{Z}\hat{Y}\hat{Z}^T\|_F \|A\|_F}.$$

参数

- 混合精度迭代改进的收敛容差 = nu
- 改进 (外层) 步数上限 = 50
- Newton (内层) 迭代次数上限 = 50

运行时间模型

$$\rho = \frac{\text{一次 bf16 运算的平均时间}}{\text{高精度单次浮点运算平均时间}} = \frac{t_{\text{bf16}}}{t_{\text{high}}}$$



$$\text{bf16 的主要耗时 } T_{\text{bf16}} = 2n^3 k_{\text{bf16}} \cdot t_{\text{bf16}}$$

$$\text{高精度的主要耗时 } T_{\text{high}} = 2n^3 k_{\text{high}} \cdot t_{\text{high}}$$

$$T_{\text{bf16}} < T_{\text{high}} \iff \frac{k_{\text{bf16}}}{k_{\text{high}}} < \frac{1}{\rho}, \quad 0 \leq \rho \ll 1$$





横轴: 问题编号

 ρ 低于标记值时 bf16 方案更快图: 问题 1-8 的 $n = 100$, 问题 9-16 的 $n = 1000$ 。

- 对良态问题, bf16/fp32 组合收敛
- GB200 参考线基于稠密运算速率: bf16 TC / 原生 fp32 (NVIDIA, '25)





横轴：问题编号

 ρ 低于标记值时 bf16 方案更快图：问题 1-8 的 $n = 100$ ，问题 9-16 的 $n = 1000$ 。

- 对良态问题，bf16/fp32 组合收敛
- GB200 参考线基于稠密运算速率：bf16 TC / 原生 fp32 (NVIDIA, '25)





横轴: 问题编号

 ρ 低于标记值时 bf16 方案更快图: 问题 1-8 的 $n = 100$, 问题 9-16 的 $n = 1000$ 。

- 对良态问题, bf16/fp64 组合收敛
- GB200 参考线基于稠密运算速率: bf16 TC / fp64 TC (NVIDIA, '25)



横轴: 问题编号

 ρ 低于标记值时 bf16 方案更快图: 问题 1-8 的 $n = 100$, 问题 9-16 的 $n = 1000$ 。

- 对良态问题, bf16/fp64 组合收敛
- GB200 参考线基于稠密运算速率: bf16 TC / fp64 TC (NVIDIA, '25)



1. 混合精度简介
2. Sylvester 矩阵方程
3. 低秩 Lyapunov 矩阵方程
4. 总结



- 面向两类线性矩阵方程的混合精度算法

Sylvester 矩阵方程:

- 基于 Schur 分解 $\rightsquigarrow$ 中等规模稠密问题的首选方法
- 通过迭代改进获得三角方程的高精度解
- 利用低精度酉矩阵易于求逆或重新正交化的特点

低秩 Lyapunov 方程:

- Cholesky/LDL^T 型混合精度迭代改进框架
- 重点考虑以矩阵符号函数的 Newton 迭代为求解器
- bf16 等较低精度在良态问题上表现最佳
- 已完成但本报告未展开: 收敛性与舍入误差分析

下一步?

- 高性能混合精度实现 (低精度 Schur 分解?)
- 在混合精度迭代改进内部采用低精度 ADI/Krylov 求解器?

更多细节请参阅预印本:

arxiv.org/abs/2503.03456 和 arxiv.org/abs/2510.02126

报告幻灯片: xiaobo-liu.github.io/talks

感谢聆听!



- 面向两类线性矩阵方程的混合精度算法

Sylvester 矩阵方程:

- 基于 Schur 分解 $\rightsquigarrow$ 中等规模稠密问题的首选方法
- 通过迭代改进获得三角方程的高精度解
- 利用低精度酉矩阵易于求逆或重新正交化的特点

低秩 Lyapunov 方程:

- Cholesky/LDL^T 型混合精度迭代改进框架
- 重点考虑以矩阵符号函数的 Newton 迭代为求解器
- bf16 等较低精度在良态问题上表现最佳
- 已完成但本报告未展开: 收敛性与舍入误差分析

下一步?

- 高性能混合精度实现 (低精度 Schur 分解?)
- 在混合精度迭代改进内部采用低精度 ADI/Krylov 求解器?

更多细节请参阅预印本:

arxiv.org/abs/2503.03456 和 arxiv.org/abs/2510.02126

报告幻灯片: xiaobo-liu.github.io/talks

感谢聆听!



- 面向两类线性矩阵方程的混合精度算法

Sylvester 矩阵方程:

- 基于 Schur 分解 $\rightsquigarrow$ 中等规模稠密问题的首选方法
- 通过迭代改进获得三角方程的高精度解
- 利用低精度酉矩阵易于求逆或重新正交化的特点

低秩 Lyapunov 方程:

- Cholesky/LDL^T 型混合精度迭代改进框架
- 重点考虑以矩阵符号函数的 Newton 迭代为求解器
- bf16 等较低精度在良态问题上表现最佳
- 已完成但本报告未展开: 收敛性与舍入误差分析

下一步?

- 高性能混合精度实现 (低精度 Schur 分解?)
- 在混合精度迭代改进内部采用低精度 ADI/Krylov 求解器?

更多细节请参阅预印本:

arxiv.org/abs/2503.03456 和 arxiv.org/abs/2510.02126

报告幻灯片: xiaobo-liu.github.io/talks

感谢聆听!



- 面向两类线性矩阵方程的混合精度算法

Sylvester 矩阵方程:

- 基于 Schur 分解 $\rightsquigarrow$ 中等规模稠密问题的首选方法
- 通过迭代改进获得三角方程的高精度解
- 利用低精度酉矩阵易于求逆或重新正交化的特点

低秩 Lyapunov 方程:

- Cholesky/LDL^T 型混合精度迭代改进框架
- 重点考虑以矩阵符号函数的 Newton 迭代为求解器
- bf16 等较低精度在良态问题上表现最佳
- 已完成但本报告未展开: 收敛性与舍入误差分析

下一步?

- 高性能混合精度实现 (低精度 Schur 分解?)
- 在混合精度迭代改进内部采用低精度 ADI/Krylov 求解器?

更多细节请参阅预印本:

arxiv.org/abs/2503.03456 和 arxiv.org/abs/2510.02126

报告幻灯片: xiaobo-liu.github.io/talks

感谢聆听!



- ▶ R. H. Bartels and G. W. Stewart.
Algorithm 432: Solution of the Matrix Equation
 $AX + XB = C$.
Comm. ACM, 15(9):820–826, 1972.
- ▶ P. Benner, P. Ezzatti, D. Kressner, E. S. Quintana-Ortí, and A. Remón.
A mixed-precision algorithm for the solution of
Lyapunov equations on hybrid CPU–GPU
platforms.
Parallel Comput., 37:439–450, 2011.
- ▶ P. Benner and E. S. Quintana-Ortí.
Solving stable generalized Lyapunov equations with
the matrix sign function.
Numer. Algorithms, 20:75–100, 1999.
- ▶ E. Carson and N. J. Higham.
Accelerating the solution of linear systems by
iterative refinement in three precisions.
SIAM J. Sci. Comput., 40(2):A817–A847, 2018.
- ▶ M. Fasi and M. Mikaitis.
CPFloat: A C Library for Simulating Low-precision
Arithmetic.
ACM Trans. Math. Software, 49(2):1–32, 2023.
- ▶ N. J. Higham and S. Pranesh.
Simulating low precision floating-point arithmetic.
SIAM J. Sci. Comput., 41(5):C585–C602, 2019.
- ▶ N. Komaroff.
Simultaneous eigenvalue lower bounds for the
Lyapunov matrix equation.
IEEE Trans. Automat. Control, 33(1):126–128,
1988.
- ▶ V. B. Larin and F. A. Aliev.
Construction of square root factor for solution of
the Lyapunov matrix equation.
Syst. Control Lett., 20(2):109–112, 1993.
- ▶ NVIDIA Corporation.
NVIDIA Blackwell Architecture Technical Brief.
Tech. report, 2025.
- ▶ J. D. Roberts.
Linear model reduction and solution of the
algebraic Riccati equation by use of the sign
function.
Int. J. Control, 32(4):677–687, 1980.