

正交约束优化：理论、算法与应用

答辩人：高斌

指导教师：袁亚湘 研究员



中国科学院大学

University of Chinese Academy of Sciences



中国科学院数学与系统科学研究院

计算数学与科学与工程计算研究所
科学与工程计算国家重点实验室

博士论文答辩

2019年5月14日

1. 引言
2. 乘子校正算法
3. 子空间加速的收缩类算法
4. 基于增广 Lagrange 函数的并行算法
5. 正交约束优化在电子结构计算中的应用
6. 总结与展望

1. 引言

正交约束优化问题

一般形式


$$\begin{aligned} \min_{X \in \mathbb{R}^{n \times p}} \quad & f(X) \\ \text{s. t.} \quad & X^\top X = I_p \quad (p \ll n) \end{aligned} \tag{1.1}$$

- $f: \mathbb{R}^{n \times p} \mapsto \mathbb{R}$, 连续可微
- $p(p+1)/2$ 个约束
- Stiefel 流形:

$$\mathcal{S}_{n,p} = \{X \in \mathbb{R}^{n \times p} \mid X^\top X = I_p\}$$

难点和挑战

- 非凸约束
- NP-难的 (特殊的 f)
- 保持可行 (正交化)
- 算法的并行可扩展性



$$f(x, y, z) = x^2 + 5y^2 - 3z^2 + 5x$$

正交约束优化的应用

- 最小 p 个特征值/奇异值计算 [Liu, Wen, Yang, Zhang 2013-2016]

$$\begin{array}{ll} \min_{X \in \mathbb{R}^{n \times p}} & \text{tr}(X^\top A X) \\ \text{s. t.} & X^\top X = I_p \end{array}$$


$$\begin{array}{ll} \min_{U \in \mathbb{R}^{m \times p}} & \text{tr}(U^\top A A^\top U) \\ \text{s. t.} & U^\top U = I_p \end{array}$$

- 主成分分析 [Oja 2001; Jiang-Ma-So-Zhang 2017]

- 样本数: n , 样本空间: \mathbb{R}^m
- 观测矩阵: $A \in \mathbb{R}^{n \times m}$
- 降维: $m \rightarrow p$

$$\begin{array}{ll} \min_{X \in \mathbb{R}^{n \times p}} & -\frac{1}{m} \text{tr}(X^\top (A - \bar{A})(A - \bar{A})^\top X) \\ \text{s. t.} & X^\top X = I_p \end{array}$$

$$\text{其中 } \bar{A} = \frac{1}{m} \sum_{i=1}^m A_i \mathbf{1}^\top$$




正交约束优化的应用 (续)

- **Bose-Einstein 凝聚** [Griffin-Snoke-Stringari 1996; Hu-Jiang-Liu-Wen 2015]

$$\boxed{\min_{\phi \in \mathcal{S}} E(\phi)} \xrightarrow{\text{离散模型}} \boxed{\begin{array}{l} \min_{x \in \mathbb{R}^n} f(x) := \frac{1}{2} x^\top A x + \frac{\beta}{2} \sum_{i=1}^n x_i^4 \\ \text{s. t.} \quad \|x\|_2 = 1 \end{array}}$$

- **电子结构计算** [Liu, Yang, Wang, Wen 2006-2015; Chen, Dai, Gao, Zhou]



- **变分问题的压缩模型** [Ozoliņš-Lai-Caflisch-Osher 2013]
- **低秩相关矩阵** [Pietersz-Groenen 2004; Grubišić-Pietersz 2007]
- **联合对角化问题** [Theis-Cason-Absil 2009]
- ...


已有算法

♣ 流形优化算法

- 最速下降法: [Helmke-Moore 1994; Udriste 1994]
- 共轭梯度法: [Smith 1994; Edelman-Arias-Smith 1998; Brace-Manton 2006; Gallivan-Absil 2010]
- 牛顿法: [Smith 1994; Edelman-Arias-Smith 1998; Hu-Wen-Milzarek-Yuan 2017]
- 拟牛顿法: [Edelman-Arias-Smith 1998; Brace-Manton 2006; Huang-Gallivan-Absil 2010, 2015]
- 信赖域法: [Absil-Baker-Gallivan 2007]
- 测地线方法: [Abrudan-Eriksson-Koivunen 2008]
- 拟测地线, Cayley 变换: [Nishimori-Akaho 2005]

♣ 切空间搜索

- 直接投影法: [Manton 2002; Absil-Mahony-Sepulchre 2008]
- 保约束算法: [Wen-Yin 2012; Jiang-Dai 2014]



♣ 其他相关研究

- 分裂算法, ADMM 和邻近点算法: [Lai-Osher 2014; Chen-Ji-You 2016; Zhu-Zhang-Chu-Liao 2017; Chen-Ma-So-Zhang 2018; Chen-Ma-Xue-Zou 2019]
- 无需向量运输的 SVRG: [Liu-So-Wu 2015; Jiang-Ma-So-Zhang 2017]

♣ Absil-Mahony-Sepulchre, *Optimization algorithms on matrix manifolds*, Princeton University Press, 2008

黎曼流形优化

$$\min_{X \in \mathcal{S}_{n,p}} f(X)$$

- 黎曼度量: $\langle Z_1, Z_2 \rangle_\rho = \text{tr}(Z_1^\top (I - (1 - \frac{1}{\rho})XX^\top)Z_2)$

- 切空间:

$$\begin{aligned}\mathcal{T}_X \mathcal{S}_{n,p} &= \{Z \in \mathbb{R}^{n \times p} : X^\top Z + Z^\top X = 0\} \\ &= \{XW + X_\perp K : W^\top + W = 0, W \in \mathbb{R}^{p \times p}, K \in \mathbb{R}^{(n-p) \times p}\} \\ &= \{AX : A^\top + A = 0, A \in \mathbb{R}^{n \times n}\}\end{aligned}$$

- 流形梯度:

$$\text{grad}_\rho f(X) = (I - XX^\top)\nabla f(X) + \rho \cdot X \text{skew}(X^\top \nabla f(X)) = 0$$

- 一阶最优性条件: $\text{grad}_\rho f(X) = 0$

$$\|\nabla f(X) - XX^\top \nabla f(X)\|_F^2 + \rho^2 \|X^\top \nabla f(X) - \nabla f(X)^\top X\|_F^2 = 0$$

研究动机 (续)

欧式空间约束优化

$$\min_{X \in \mathbb{R}^{n \times p}} f(X), \quad \text{s. t. } X^\top X = I_p$$

- 欧式度量: $\langle Z_1, Z_2 \rangle_\rho = \text{tr}(Z_1^\top Z_2)$

- 一阶最优性条件:

$$\begin{cases} (I_n - XX^\top)\nabla f(X) = 0; & \text{(次稳定性)} \\ X^\top \nabla f(X) = \nabla f(X)^\top X; & \text{(对称性)} \\ X^\top X = I_p & \text{(可行性)} \end{cases}$$

	流形优化	欧式空间约束优化
流形计算	✓	-
下降方向	$\mathcal{T}_X \mathcal{S}_{n,p}$	$\mathbb{R}^{n \times p}$
正交化	收缩 (矩阵分解/线性方程组)	可行/不可行方法
附加约束	-	✓
并行可扩展性	-	✓

主要工作 (贡献)

- 系统地研究了正交约束优化问题
 - Stiefel 流形优化和正交约束优化一阶最优性条件的对应关系
 - Lagrange 乘子在一阶稳定点处具有显式表达式
- 提出了一类非收缩算法框架
 - 梯度反射法和梯度投影法 (GR, GP)
 - 以列为块的块坐标下降方法 (CBCD)
- 将乘子校正步推广到一般的 Stiefel 流形收缩类算法
- 提出了基于增广 Lagrange 函数的并行算法
 - 邻近点线性化算法 (PLAM)
 - 可并行列极小化算法 (PCAL)
- 电子结构计算中的应用

2. 乘子校正算法

算法设计思路

问题假设

$$\begin{aligned} \min_{X \in \mathbb{R}^{n \times p}} \quad & f(X) := h(X) + \text{tr}(G^\top X) \\ \text{s. t.} \quad & X^\top X = I_p \end{aligned} \tag{2.1}$$

其中 $h(X)$ 满足

- 正交不变性: $h(XQ) = h(X), \forall Q \in \mathcal{S}_{p,p}$
- $\nabla h(X) = H(X)X$, 且 $H : \mathbb{R}^{n \times p} \mapsto \mathbb{S}\mathbb{R}^{n \times n}$

一阶最优性条件

次稳定性	对称性	可行性
$\ \nabla f(X) - XX^\top \nabla f(X)\ _F^2$	$\ X^\top \nabla f(X) - \nabla f(X)^\top X\ _F^2$	$X^\top X = I_p$
↓		
0	0	✓

两阶段可行算法

步一：函数值充分下降 $X^k \rightarrow \bar{X}$

基于当前点 $X^k \in \mathcal{S}_{n,p}$, 搜索可行点 \bar{X} 使其满足

$$f(X^k) - f(\bar{X}) \geq C_1 \cdot \left\| (I - X^k X^{k\top}) \nabla f(X^k) \right\|_F^2$$

步二：乘子对称校正 $\bar{X} \rightarrow X^{k+1}$

基于中间点 $\bar{X} \in \mathcal{S}_{n,p}$, 搜索可行点 X^{k+1} 使其满足

$$X^{k+1\top} \nabla f(X^{k+1}) = \nabla f(X^{k+1})^\top X^{k+1}$$

- 注意到 $\bar{X}^\top \nabla f(\bar{X}) = \bar{X}^\top H(\bar{X}) \bar{X} + \bar{X}^\top G$, 故只需 $\bar{X}^\top G$ 对称

1) $p \times p$ 奇异值分解: $U \Sigma T^\top = \bar{X}^\top G$

2) $X^{k+1} = -\bar{X} U T^\top$

$$f(\bar{X}) - f(X^{k+1}) \geq \min \left\{ \frac{1}{8\theta}, 1 \right\} \cdot \left\| \bar{X}^\top \nabla f(\bar{X}) - \nabla f(\bar{X})^\top \bar{X} \right\|_F^2$$

⊕ 特殊情况无需校正

- $G = 0$ 或 $p = 1$

⊙ 乘子校正算法

- 1 初始化: $\epsilon > 0$, $X^0 \in \mathcal{S}_{n,p}$, 令 $k := 0$;
- 2 搜索可行点 \bar{X} , 使其满足函数值下降条件

$$f(X^k) - f(\bar{X}) \geq C_1 \cdot \left\| (I - X^k X^{k\top}) \nabla f(X^k) \right\|_{\text{F}}^2;$$

- 3 计算乘子校正步, 得到

$$X^{k+1} := \begin{cases} \bar{X}, & \text{if } \bar{X}^\top G = G^\top \bar{X}; \\ -\bar{X} U T^\top, & \text{否则} \end{cases}$$


其中 $U \Sigma T^\top$ 是 $\bar{X}^\top G$ 的奇异值分解;

- 4 若 $\left\| (I - X^k X^{k\top}) \nabla f(X^k) \right\|_{\text{F}}^2 < \epsilon$, 返回 X^{k+1} ; 否则, 令 $k := k + 1$ 并返回步 2.

步一：梯度类方法

对于任意的 $Y \in \mathcal{B}(X - \tau \nabla f(X), \tau \|\nabla f(X)\|_{\mathbb{F}})$, 下式成立

$$f(X) - f(Y) \geq \frac{1 - \rho\tau}{2\tau} \cdot \|X - Y\|_{\mathbb{F}}^2, \quad \tau \in (0, \rho^{-1})$$



梯度反射法 (GR)

♣ Householder 变换

$$\begin{aligned} V &= X^k - \tau \nabla f(X^k), \\ \bar{X} &= (-I + 2V(V^\top V)^\dagger V^\top) X^k \end{aligned}$$


其中 C^\dagger 表示伪逆

性质

- 正交性满足: $\bar{X}^\top \bar{X} = I_p$
- 充分下降性:

$$f(X^k) - f(\bar{X}) \geq \frac{2(\tau^{-1} - \rho)}{(\tau^{-1} + \rho + \theta)^2} \cdot \left\| (I - X^k X^{k\top}) \nabla f(X^k) \right\|_F^2,$$

其中 $\tau \in (0, \rho^{-1})$



梯度投影法 (GP)

♣ 正交投影

$$\begin{aligned} V &= X^k - \tau \nabla f(X^k), \\ \bar{X} &= \mathcal{P}_{\mathcal{S}_{n,p}}(V) \end{aligned}$$


其中 $\mathcal{P}_{\mathcal{S}_{n,p}}(C) = UV^\top$,
且 $C = U\Sigma V^\top$ 为奇异值分解

性质

- 正交性满足: $\bar{X}^\top \bar{X} = I_p$
- 充分下降性:

$$f(X^k) - f(\bar{X}) \geq \frac{\tau^{-1} - \rho}{(\tau^{-1} + \rho + \theta)^2} \cdot \left\| (I - X^k X^{k\top}) \nabla f(X^k) \right\|_F^2,$$

其中 $\tau \in (0, \rho^{-1})$



步一：块坐标下降法 (CBCD)

♣ 以列为块的块坐标下降法: $f_{i,X}(x) := f(X_1, \dots, X_{i-1}, x, X_i, \dots, X_p)$

$$\begin{array}{ll} \min_{x \in \mathbb{R}^n} & f_{i,X}(x) \\ \text{s. t.} & \|x\|_2 = 1, \\ & X_i^\top x = 0 \end{array}$$

• 子问题非精确求解:

$$\begin{aligned} f_{i,W^{i-1}}(X_i) - f_{i,W^{i-1}}(x^+) &\geq k_1 \|X_i - x^+\|_2^2, \\ \|X_i - x^+\|_2 &\geq k_2 \left\| (I - W^{i-1}W^{i-1\top}) \nabla f_{i,W^{i-1}}(X_i) \right\|_2 \end{aligned}$$

• 充分下降性:

$$f(X) - f(\bar{X}) \geq C_2 \cdot \left\| (I - XX^\top) \nabla f(X) \right\|_F^2$$

全局收敛性

函数值充分下降

$$f(X^k) - f(\bar{X}) \geq C_1 \cdot \left\| (I - X^k X^{k\top}) \nabla f(X^k) \right\|_F^2$$

乘子校正步

$$f(\bar{X}) - f(X^{k+1}) \geq \min \left\{ \frac{1}{8\theta}, 1 \right\} \cdot \left\| \bar{X}^\top \nabla f(\bar{X}) - \nabla f(\bar{X})^\top \bar{X} \right\|_F^2$$

定理 2.1

令 $\{X^k\}$ 是由乘子校正算法从初始点 $X^0 \in \mathcal{S}_{n,p}$ 生成的迭代点列. 则 $\{X^k\}$ 存在一个收敛子列, 并且点列 $\{X^k\}$ 的每一个聚点 X^* 都满足问题 (2.1) 的一阶最优性条件.

计算量比较

更新策略	计算量	
	首次 τ	重复 τ
测地线类算法		
$\mathcal{R}_X^{\text{geo}}$ [Abrudan-Eriksson-Koivunen 2008]	$O(n^3)$	$O(n^3)$
$\mathcal{R}_X^{\text{qgeo}}$ [Nishimori-Akaho 2005]	$O(n^3)$	$O(n^3)$
$\mathcal{R}_X^{\text{geo}}$ [Edelman-Arias-Smith 1998]	$10np^2 + 2np + O(p^3)$	$4np^2 + O(p^3)$
$\mathcal{R}_X^{\text{wy}}$ [Wen-Yin 2012]	$7np^2 + 2np + O(p^3)$	$4np^2 + np + O(p^3)$
投影类算法		
$\mathcal{R}_X^{\text{qr}}$ [Absil-Mahony-Sepulchre 2008]	$6np^2 + 3np + O(p^3)$	$2np^2 + 2np$
$\mathcal{R}_X^{\text{pd}}$ [Absil-Mahony-Sepulchre 2008]	$7np^2 + 4np + O(p^3)$	$2np^2 + 2np + O(p^3)$
$\mathcal{R}_X^{\text{pj}}$ [Manton 2002]	$7np^2 + 4np + O(p^3)$	$3np^2 + 3np + O(p^3)$
$\mathcal{R}_X^{\text{jd}}$ [Jiang-Dai 2014]	$7np^2 + 3np + O(p^3)$	$2np^2 + 3np + O(p^3)$
我们的算法		
GR	$9np^2 + 4np + O(p^3)$	
GP	$7np^2 + 3np + O(p^3)$	
CBCD-GR	$4np^2 + 8np + O(p^3)$	
CBCD-GP	$4np^2 + 5np + O(p^3)$	

测试问题

$$\begin{array}{ll} \min_{X \in \mathbb{R}^{n \times p}} & \frac{1}{2} \text{tr}(X^\top A X) + \text{tr}(G^\top X) \\ \text{s. t.} & X^\top X = I \end{array}$$

$$A := U \Lambda U^\top, \quad G := \alpha \cdot Q D$$

测试算法

- **MOptQR**: QR 收缩流形算法 + BB 步长
(<http://www.manopt.org>)
- **OptM**: [Wen-Yin 2012] (BB 步长)
(<https://github.com/wenstone/OptM>)
- **GR-BB**: 梯度反射法 + BB step size
(<https://github.com/opt-gaobin/FOForth>)
- **CBCD-C**: 以列为块的块坐标下降法

步长选取

BB 步长 [Barzilai-Borwein 1988]

$$\begin{aligned}J^{k-1} &= X^k - X^{k-1} \\W^{k-1} &= (I - X^{k-1}X^{k-1\top})\nabla f(X^{k-1}) \\K^{k-1} &= W^k - W^{k-1}\end{aligned}$$


$$\tau^{\text{BB1}} := \frac{\langle J^{k-1}, J^{k-1} \rangle}{|\langle J^{k-1}, K^{k-1} \rangle|}, \quad \tau^{\text{BB2}} := \frac{|\langle J^{k-1}, K^{k-1} \rangle|}{\langle K^{k-1}, K^{k-1} \rangle}$$

自适应步长 [Liu-Han-Guo 2019]


交替 BB 步长 (ABB) [Dai-Fletcher 2005]

$$\tau := \begin{cases} \tau^{\text{BB1}}, & \text{当 } k \text{ 是偶数;} \\ \tau^{\text{BB2}}, & \text{当 } k \text{ 是奇数} \end{cases}$$

综合性能比较



(a) CPU 时间



(b) 总迭代数

	CBCD-C	OptM	GR-BB	MOptQR
KKT 违反度	1.6075e-05	2.1730e-05	1.9501e-05	2.5072e-05
可行性违反度	1.9172e-14	1.5276e-14	1.9350e-14	2.1006e-15
相对函数值	6.5780e-06	8.1754e-06	3.0417e-06	7.9584e-06

- 相对函数值: $z_{m,s} := \left| \frac{F_{m,s} - \min_s \{F_{m,s}\}}{1 + |\min_s \{F_{m,s}\}|} \right|$ (求解器 s 求解问题 m)

3. 子空间加速的收缩类算法

乘子校正步

问题假设

$$\begin{aligned} \min_{X \in \mathbb{R}^{n \times p}} \quad & f(X) := h(X) + \text{tr}(G^\top X) \\ \text{s. t.} \quad & X^\top X = I_p \end{aligned} \tag{3.1}$$

其中 $h(X)$ 满足

- 正交不变性: $h(XQ) = h(X)$, $\forall Q \in \mathcal{S}_{p,p}$
- $\nabla h(X) = H(X)X$, 且 $H: \mathbb{R}^{n \times p} \mapsto \mathbb{S}^{n \times n}$

乘子校正步: $X^{k+1 \top} \nabla f(X^{k+1}) = \nabla f(X^{k+1})^\top X^{k+1}$

$$X^{k+1} := \begin{cases} \bar{X}, & \text{if } \bar{X}^\top G = G^\top \bar{X}; \\ -\bar{X}UT^\top, & \text{否则} \end{cases}$$

其中 $U\Sigma T^\top$ 是 $\bar{X}^\top G$ 的奇异值分解

$$f(\bar{X}) - f(X^{k+1}) \geq \min \left\{ \frac{1}{8\theta}, 1 \right\} \cdot \|\bar{X}^\top \nabla f(\bar{X}) - \nabla f(\bar{X})^\top \bar{X}\|_{\text{F}}^2$$

子空间优化

♣ 乘子校正步满足

$$\boxed{Q^* := \arg \min_{Q \in \mathcal{S}_{p,p}} f(\bar{X}Q)} \implies \boxed{X^{k+1} = \bar{X}Q^*}$$

♣ 子空间优化: $\bar{X} \in \mathcal{S}_{n,p}$

$$\begin{aligned} \min_{X \in \mathbb{R}^{n \times p}} \quad & f(X) \\ \text{s.t.} \quad & X \in \mathcal{D}_{\bar{X}} \end{aligned}$$

其中 $\mathcal{D}_{\bar{X}} := \{\bar{X}Q : Q \in \mathcal{S}_{p,p}\} \subset \mathcal{S}_{n,p}$ 是 \bar{X} 的正交不变子空间。

☺ 显式解

$$\boxed{X^{k+1} = -\bar{X}UT^\top}$$

♣ 加速算法

$$X^k \xrightarrow{\text{下降阶段: 任意可行下降方法}} \bar{X} \xrightarrow{\text{加速阶段}} X^{k+1}$$

子空间加速的收缩类线搜索算法

- 1 初始化: 给定 Stiefel 流形 $\mathcal{S}_{n,p}$ 上的收缩映射 \mathcal{R} , 常数 $\bar{\alpha} > 0, c, \beta, \sigma \in (0, 1)$; $X^0 \in \mathcal{S}_{n,p}$, 令 $k := 0$;
- 2 (函数值下降阶段)
选取搜索方向 $D^k \in \mathcal{T}_{X^k} \mathcal{S}_{n,p}$, 使用收缩类算法求解问题, 得到 $\bar{X} \in \mathcal{S}_{n,p}$;
- 3 (加速阶段)
基于 \bar{X} , 由子空间问题的解计算可行点 X^{k+1} , 也就是

$$X^{k+1} = -\bar{X}UT^\top$$

其中 $U\Sigma T^\top$ 是 $\bar{X}^\top G$ 的奇异值分解;

- 4 若停机准则满足, 则返回 X^{k+1} ; 否则, 令 $k := k + 1$ 并返回步 2.

收敛性分析

全局收敛性

定理 3.1

令 $\{X^k\}$ 是由子空间加速的收缩类线搜索算法从初始点 $X^0 \in \mathcal{S}_{n,p}$ 生成的迭代点列. 则 $\{X^k\}$ 存在一个收敛子列, 并且点列 $\{X^k\}$ 的每一个聚点 X^* 都满足问题 (3.1) 的一阶最优性条件.

局部线性收敛速度 [Absil-Mahony-Sepulchre 2008]

- 局部极小值点
- 下降方向: $D^k = -\text{grad } f(X^k)$
- Armijo 线搜索

数值实验

测试问题

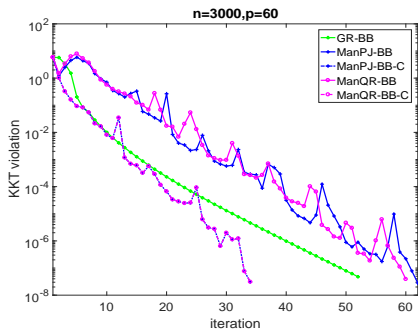
$$\begin{array}{ll} \min_{X \in \mathbb{R}^{n \times p}} & \frac{1}{2} \text{tr}(X^\top A X) + \text{tr}(G^\top X) \\ \text{s. t.} & X^\top X = I \end{array}$$

$$A := U \Lambda U^\top, \quad G := \alpha \cdot Q D$$


测试算法

- **MOptPJ**: SVD 收缩流形算法 + BB 步长
(<http://www.manopt.org>)
- **MOptPJ-C**: 子空间加速的MOptPJ
- **MOptQR**: QR 收缩流形算法 + BB 步长
(<http://www.manopt.org>)
- **MOptQR-C**: 子空间加速的MOptQR
- **GR-BB**: 梯度反射法 + BB step size
(<https://github.com/opt-gaobin/FOForth>)

数值结果



(a) 问题参数: $\xi = 0$



(b) 问题参数: $\xi = 0.5$

- 加速后收敛速度更快
- SVD 和 QR 分解得到相同的子空间 $\text{span}\{\bar{X}\}$

数值结果 (续)

变化参数	测试方法	函数值	KKT 违反度	总迭代数	CPU 时间(s)
$p = 120$	GR-BB	-25.5806718521	2.04e-08	31	1.80
	ManPJ-BB	-25.5806718521	3.51e-08	149	5.76
	ManPJ-BB-C	-25.5806718521	3.60e-08	104	5.24
	ManQR-BB	-25.5806718521	3.45e-08	158	6.22
	ManQR-BB-C	-25.5806718521	3.60e-08	104	5.18
$\zeta = 1.1$	GR-BB	-10.9204582842	1.19e-08	32	0.98
	ManPJ-BB	-10.9204582842	2.33e-08	278	5.91
	ManPJ-BB-C	-10.9204582842	2.27e-08	157	4.07
	ManQR-BB	-10.9204582842	2.34e-08	229	4.82
	ManQR-BB-C	-10.9204582842	2.24e-08	156	4.00
$\xi = 0.5$	GR-BB	-23.3612295898	3.33e-08	98	2.89
	ManPJ-BB	-23.3612295898	3.46e-08	154	3.27
	ManPJ-BB-C	-23.3612295898	1.64e-08	99	2.53
	ManQR-BB	-23.3612295898	1.57e-08	148	3.06
	ManQR-BB-C	-23.3612295898	1.64e-08	99	2.57

- 加速后迭代步数显著减少
- CPU 运行时间减少

4. 基于增广 Lagrange 函数的并行算法

主要瓶颈 — 保持可行性

♣ 函数/梯度信息计算

— 电子结构计算

L — 离散的拉普拉斯算子

V_{ion} — 低秩线性算子

计算项	复杂度	
	串行	并行 (m 核)
$\text{tr}(X^\top LX)$	$O(np)$	$O(np/m)$
$\text{tr}(X^\top V_{ion} X)$		
$\sum_i \sum_l x_i^\top w_l ^2$		
$e^\top \epsilon_{xc}(\rho)$		
$L^\dagger \rho$	$O(n)$ $O(n \log n)$	$O(n/m)$ $O(n \log n/m)$

♣ 基础线性代数操作 (BLAS)

计算项	复杂度	
	串行	并行 (m 核)
$Y_1 + Y_2$	$O(np)$	$O(np/m)$
$\text{tr}(Y_1^\top Y_2)$		
$Y_1^\top Y_2$	$O(np^2)$	$O(np^2/m)$
正交化	$O(np^2) + O(p^3)$	—

☹ **瓶颈**: 正交化过程的低可扩展性

不可行方法

Courant 罚函数 \rightarrow 增广 Lagrange 函数

- 二次罚函数不适用于一般目标函数 [Wen-Yang-Liu-Zhang 2016]
- 增广 Lagrange 函数法 [Powell 1969; Hestenes 1969]

$$\mathcal{L}_\beta(X, \Lambda) = f(X) - \frac{1}{2} \langle \Lambda, X^\top X - I_p \rangle + \frac{\beta}{4} \|X^\top X - I_p\|_F^2$$

🔄 增广 Lagrange 函数法

- 1 给定 X^k, Λ^k ;
- 2 更新原始变量 X :

$$X^{k+1} := \arg \min_{X \in \mathbb{R}^{n \times p}} \mathcal{L}_\beta(X, \Lambda^k)$$

- 3 更新对偶变量 Λ (Lagrange 乘子):

$$\Lambda^{k+1} := \Lambda^k - \beta(X^{k+1 \top} X^{k+1} - I)$$

- 4 更新罚参数 β .

乘子显式解

一阶最优性条件

$$\begin{cases} \nabla f(X) - X\Lambda = 0; & \text{(次稳定性)} \\ \Lambda = \Lambda^\top; & \text{(对称性)} \\ X^\top X = I_p & \text{(可行性)} \end{cases}$$

推论 4.1

假设 X 是正交约束优化问题的一阶稳定点, 此时正交约束对应的 *Lagrange* 乘子满足

$$\Lambda = X^\top \nabla f(X) = \nabla f(X)^\top X.$$

♣ 乘子显式更新格式

$$\Lambda^k := \Psi(\nabla f(X^k)^\top X^k)$$

其中 $\Psi: \mathbb{R}^{n \times n} \mapsto \text{SR}^{n \times n}$ 为对称化算子 $\Psi(A) := \frac{1}{2}(A + A^\top)$

乘子显式更新的增广 Lagrange 函数法

⑥ 乘子显式更新的增广 Lagrange 函数法

- 1 初始化: $X^0 \in \mathbb{R}^{n \times p}$, 令 $k := 0$;
- 2 更新对偶变量 Λ (Lagrange 乘子):

$$\Lambda^k := \Psi(\nabla f(X^k)^\top X^k);$$

- 3 更新原始变量 X :

$$X^{k+1} := \arg \min_{X \in \mathbb{R}^{n \times p}} \mathcal{L}_\beta(X, \Lambda^k)$$

- 4 若停机准则满足, 则返回 X^{k+1} ; 否则, 令 $k := k + 1$ 并返回步 2.

新乘子更新性质

一阶性质

引理 4.1

对于任意满足 $\sigma_{\min}(X^*) > 0$ 的 X^* , 假设 $\beta > \frac{\|\nabla f(X^*)\|_2 \cdot \|X^*\|_2 + \delta}{\sigma_{\min}^2(X^*)}$, 其中 $\delta > 0$. 则下式成立

$$\left\| X^{*\top} X^* - I_p \right\|_F \leq \frac{\|X^*\|_2}{\delta} \cdot \|\nabla_X \mathcal{L}_\beta(X^*, \Lambda^*)\|_F,$$

其中 $\Lambda^* = \Psi(\nabla f(X^*)^\top X^*)$. 特别的, 如果 X^* 还是如下问题

$$\min_{X \in \mathbb{R}^{n \times p}} \mathcal{L}_\beta(X, \Lambda^*)$$

的一阶稳定点, 其中 $\Lambda^* = \Psi(\nabla f(X^*)^\top X^*)$, 则 X^* 也是原问题的一阶稳定点.

- 精确罚函数

子问题求解

$$\min_{X \in \mathbb{R}^{n \times p}} \mathcal{L}_\beta(X, \Lambda^k)$$

近似模型 \rightarrow

$$\min_{X \in \mathbb{R}^{n \times p}} m_k(X)$$

♣ 邻近点线性化逼近 — 可并行策略

$$m_{k,1}(X) := \langle \nabla_X \mathcal{L}_\beta(X^k, \Lambda^k), X - X^k \rangle + \frac{\eta_k}{2} \|X - X^k\|_F^2$$

☺ 显式解

$$X^{k+1} := \arg \min_{X \in \mathbb{R}^{n \times p}} m_{k,1}(X)$$

具体来讲,

$$X^{k+1} = X^k - \frac{1}{\eta_k} \nabla_X \mathcal{L}_\beta(X^k, \Lambda^k)$$

- $1/\eta_k$ 为原始变量更新步长

邻近点线性化增广 Lagrange 算法 (PLAM)

🔄 PLAM

- 1 初始化: $X^0 \in \mathbb{R}^{n \times p}$, 令 $k := 0$;
- 2 更新对偶变量 Λ (Lagrange 乘子):

$$\Lambda^k := \Psi(\nabla f(X^k)^\top X^k);$$

- 3 (可并行) 更新原始变量 X :

$$\begin{aligned} X^{k+1} &:= \arg \min_{X \in \mathbb{R}^{n \times p}} m_{k,1}(X) \\ &= X^k - \frac{1}{\eta_k} \nabla_X \mathcal{L}_\beta(X^k, \Lambda^k); \end{aligned}$$

- 4 若停机准则满足, 则返回 X^{k+1} ; 否则, 令 $k := k + 1$ 并返回步 2.

初始点假设

假设 4.1

对于给定的 X^0 , 如果存在 $\underline{\sigma} \in (0, 1)$ 使得

$$\sigma_{\min}(X^0) \geq \underline{\sigma}, \quad 0 < \left\| X^{0\top} X^0 - I_p \right\|_{\text{F}} \leq 1 - \underline{\sigma}^2,$$

则我们称其为一个合格的初始值.

X^0 可以很容易得到

(i) $X^0 = Q\Sigma$, 其中 $Q \in \mathcal{S}_{n,p}$, $\Sigma = \text{diag}(\underbrace{1, \dots, 1}_{p-1}, \sqrt{1 - \underline{\sigma}^2})$

(ii) $X^0 \notin \mathcal{S}_{n,p}$ 满足 $\sigma_{\min}^2(X^0) > 1 - \frac{1}{\sqrt{p}}$ 且 $\sigma_{\max}^2(X^0) < 1 + \frac{1}{\sqrt{p}}$

理论分析 — 假设 (续)

记号

$$R = \left\| X^0{}^\top X^0 - I_p \right\|_F; \quad \mathcal{C} = \{X \mid \|X^\top X - I_p\|_F \leq R\}; \quad \underline{f} = \min_{X \in \mathcal{C}} f(X);$$
$$M = \max_{X \in \mathcal{C}} \|X\|_2; \quad N = \max_{X \in \mathcal{C}} \|\nabla f(X)\|_F; \quad L = \max_{X \in \mathcal{C}} \|\nabla^2 f(X)\|_2$$

评价函数

$$h(X) = f(X) - \frac{1}{2} \langle \Psi(\nabla f(X)^\top X), X^\top X - I_p \rangle + \frac{\beta}{4} \|X^\top X - I_p\|_F^2$$

- f 二次连续可微
- $\nabla f(X)$ 在紧集 \mathcal{C} 上 Lipschitz 连续
- 存在常数 $L_h > 0$, 与 β 有关, 使得

$$\|\nabla h(X) - \nabla h(y)\|_F \leq L_h \|X - Y\|_F, \quad \forall X, Y \in \mathcal{C}$$

理论分析 — 假设 (续)

参数假设

假设 4.2

$$c_1 \in \left(0, \frac{1}{2}\right); \beta > \max \left\{ \frac{MN}{\underline{\sigma}^2} + \sqrt{\frac{M^2 N^2}{\underline{\sigma}^4} + \frac{(N + LM)^2}{4\underline{\sigma}^2(1 - 2c_1)}}, \frac{MN}{\underline{\sigma}}, \frac{4MN}{\underline{\sigma}^2} \right\};$$

$$c_2 \in \left(0, \frac{R^2(\beta\underline{\sigma}^2 - 4MN)}{2N_L^2}\right]; \quad \eta^k \in [\underline{\eta}, \bar{\eta}],$$

$$\text{其中 } \underline{\eta} = \max \left\{ \frac{L_h}{2c_1}, \frac{2N_L M + N_L \sqrt{4M^2 + 2R}}{R}, \frac{R + 2M^2}{c_2} \right\},$$

$$N_L = (1 + M^2)N + \beta RM, \quad \bar{\eta} \geq \underline{\eta}.$$

全局收敛性

定理 4.1

令 $\{X^k\}$ 是由算法 PLAM 从初始点 X^0 生成的迭代点列, 其中初始点 X^0 满足假设 4.1 并且问题的参数满足假设 4.2. 则序列 $\{X^k\}$ 至少有一个聚点, 且任意聚点都是原正交约束优化问题的一阶稳定点. 进一步, 对于任意的 $K > 1$, 下式成立,

$$\min_{k=0, \dots, K-1} \|\nabla_X \mathcal{L}_\beta(X^k, \Lambda^k)\|_F < \sqrt{\frac{f(X^0) - \underline{f} + MNR + \beta R^2/4}{c_3 K}}.$$

- 次线性收敛速度
- 需要 $O(1/\epsilon^2)$ 次迭代使得

$$\max \left\{ \|\nabla_X \mathcal{L}_\beta(X^k, \Lambda^k)\|_F, \|X^{k\top} X^k - I\|_F \right\} < \epsilon$$

定理 4.2

假设 X^* 是原正交约束优化问题的一个孤立局部极小值点, 同时我们记

$$\tau := \inf_{0 \neq Y \in \mathcal{T}_X \mathcal{S}_{n,p}} \frac{\text{tr}(Y^\top \nabla^2 f(X)[Y] - \Lambda Y^\top Y)}{\|Y\|_F^2}.$$

算法的参数满足 $\beta \geq \frac{L+MN+\tau}{2}$ 和 $\eta^k \in [\underline{\eta}, \bar{\eta}]$, 其中 $\bar{\eta} \geq \underline{\eta} \geq L + MN + 2\beta$. 则存在 $\varepsilon > 0$ 使得, 算法 *PLAM* 从任意满足 $\|X^0 - X^*\|_F < \varepsilon$ 的初始点 X^0 出发生成的迭代点列 $\{X^k\}$, 以 Q -线性速度收敛到 X^* .

改进的 PLAM

PLAM 的局限

- 数值表现对参数 β_k 和 η_k 非常敏感
- 较小 $\beta_k \rightarrow$ 不收敛
- 较大 β_k 需要更大的 $\eta_k \rightarrow$ 收敛变慢

♣ 改进策略: 增加冗余单位球约束

$$\begin{aligned} \min_{X \in \mathbb{R}^{n \times p}} \quad & \tilde{\mathcal{L}}_\beta(X) := \langle \nabla_X \mathcal{L}_\beta(X^k, \Lambda^k), X - X^k \rangle + \frac{\eta_k}{2} \|X - X^k\|_F^2 \\ \text{s. t.} \quad & \|X_i\| = 1, \quad i = 1, \dots, p \end{aligned}$$

相应的乘子显式更新

$$\Lambda^k := \Psi(\nabla f(X^k)^\top X^k) + \Phi\left(X^{k\top} \nabla_X L_\beta(X^k, \Psi(\nabla f(X^k)^\top X^k))\right)$$

其中 $\Phi(M) := \text{Diag}(\text{diag}(M))$

改进的 PLAM (续)

子问题可并行求解

对 $i = 1, \dots, p$, 求解以列为块的子问题

$$X_i^{k+1} := \arg \min_{x \in \mathbb{R}^n} \quad \tilde{\mathcal{L}}_\beta^{(i)}(x) = \nabla_X \mathcal{L}_\beta(X^k, \Lambda^k)_i^\top (x - X_i^k) + \frac{\eta_k}{2} \|x - X_i^k\|_2^2, \\ \text{s. t.} \quad \|x\|_2 = 1$$

更新 $X^{k+1} = [X_1^{k+1}, \dots, X_p^{k+1}]$.

☺ 显式解

$$X_i^{k+1} = \frac{X_i^k - \frac{1}{\eta_k} \nabla_{X_i} \mathcal{L}_\beta(X^k, \Lambda^k)}{\left\| X_i^k - \frac{1}{\eta_k} \nabla_{X_i} \mathcal{L}_\beta(X^k, \Lambda^k) \right\|_2}$$

PLAM 的可并行列极小化算法 (PCAL)

PCAL

- 1 初始化: $X^0 \in \mathbb{R}^{n \times p}$, 令 $k := 0$;
- 2 更新对偶变量 Λ (Lagrange 乘子):

$$\Lambda^k := \Psi(\nabla f(X^k)^\top X^k) + \Phi\left(X^k{}^\top \nabla_X L_\beta(X^k, \Psi(\nabla f(X^k)^\top X^k))\right);$$

- 3 (可并行) 对 $i = 1, \dots, p$, 更新原始变量的第 i 列

$$X_i^{k+1} := \frac{X_i^k - \frac{1}{\eta_k} \nabla_{X_i} \mathcal{L}_\beta(X^k, \Lambda^k)}{\left\| X_i^k - \frac{1}{\eta_k} \nabla_{X_i} \mathcal{L}_\beta(X^k, \Lambda^k) \right\|_2},$$

得到 $X^{k+1} := [X_1^{k+1}, \dots, X_p^{k+1}]$;

- 4 若停机准则满足, 则返回 X^{k+1} ; 否则, 令 $k := k + 1$ 并返回步 2.

停机准则

- $\frac{\|\nabla f(X) - X\nabla f(X)^\top X\|_F}{\|\nabla f(X^0) - X^0\nabla f(X^0)^\top X^0\|_F} < 10^{-8}$ and $\|X^\top X - I\|_F < 10^{-12}$
- 最大迭代数: 3000

测试问题

问题 1: 非线性特征值

$$\begin{aligned} \min_{X \in \mathbb{R}^{n \times p}} \quad & \frac{1}{2} \text{tr}(X^\top L X) + \frac{\alpha}{4} \rho(X)^\top L^\dagger \rho(X) \\ \text{s. t.} \quad & X^\top X = I_p, \end{aligned}$$

问题 2: 正交约束二次规划

$$\begin{aligned} \min_{X \in \mathbb{R}^{n \times p}} \quad & \frac{1}{2} \text{tr}(X^\top A X) + \text{tr}(G^\top X) \\ \text{s. t.} \quad & X^\top X = I_p \end{aligned}$$

问题 3: Rayleigh-Ritz 迹极小化

$$\begin{aligned} \min_{X \in \mathbb{R}^{n \times p}} \quad & \frac{1}{2} \text{tr}(X^\top A X) \\ \text{s. t.} \quad & X^\top X = I_p \end{aligned}$$

问题 4: 一类二次问题

$$\begin{aligned} \min_{X \in \mathbb{R}^{n \times p}} \quad & \frac{1}{2} \text{tr}(A^\top X B X^\top) \\ \text{s. t.} \quad & X^\top X = I_p \end{aligned}$$


PCAL 与 ADMM 的数值比较

比较算法


– SOC [Lai-Osher 2014]

(https://homepages.rpi.edu/~lair/codes/CMs_codes_share.zip)


问题 1



(a) KKT 违反度



(b) 可行性违反度



(c) 子问题迭代数

- PCAL 内迭代只需要一步

♣ 停机准则

- $\frac{\|\nabla f(X) - X\nabla f(X)^\top X\|_F}{\|\nabla f(X^0) - X^0\nabla f(X^0)^\top X^0\|_F} < 10^{-8}$
- 最大迭代数 1000


♣ 并行加速比

$$\text{并行加速比}(m) = \frac{\text{单核墙钟时间}}{m \text{ 核墙钟时间}}$$


#cores: 1, 2, 4, 8, 16, 32, 64, 96

墙钟时间—96核

列数变化




(a) Problem 1



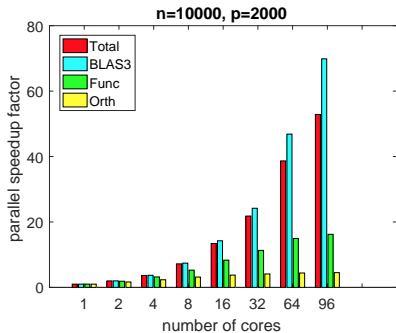
(b) Problem 2

- PCAL: 墙钟时间线性增长

并行加速比 ($p = 2000$)



(a) 问题 1: MOptQR



(b) 问题 1: PCAL

- PCAL: 更高的总并行加速比

Total

5. 正交约束优化在 电子结构计算中的应用

电子结构计算

Kohn-Sham 密度泛函理论 [Kohn-Sham 1965]

- 多体 Schrödinger 方程 \rightarrow 单体问题

Kohn-Sham 总能量极小化问题

$$\begin{array}{ll} \min_{\psi_1, \dots, \psi_p} & E_{\text{total}}^{\text{KS}}(\psi_1, \dots, \psi_p) \\ \text{s. t.} & \psi_i^* \psi_j = \delta_{ij} \end{array}$$



$$\text{其中 } \delta_{ij} = \begin{cases} 1, & \text{若 } i = j; \\ 0, & \text{否则} \end{cases}$$

- Kohn-Sham 总能量泛函 $E_{\text{total}}^{\text{KS}}(\psi_1, \dots, \psi_p)$:

$$\frac{1}{2} \sum_{i=1}^p \int_{\Omega} \|\nabla \psi_i(r)\|^2 dr + \int_{\Omega} \rho(r) V_{\text{ion}}(r) dr + \frac{1}{2} \int_{\Omega} \int_{\Omega} \frac{\rho(r)\rho(r')}{\|r - r'\|} dr dr' + E_{\text{xc}}(\rho)$$

- $\Omega \in \mathbb{R}^3$
- 原子核数: n_u
- 单粒子波函数: $\psi_i (i = 1, \dots, p)$
- 电荷密度: $\rho(r) = \sum_{i=1}^p \psi_i^*(r) \psi_i(r)$
- 离子势能: $V_{\text{ion}}(r) = \sum_{j=1}^{n_u} z_j / \|r - \hat{r}_j\|$
- 交换关联能: $E_{\text{xc}}(\rho)$

离散问题

离散的 Kohn-Sham 总能量泛函极小化

$$\begin{array}{ll} \min & E(X) \\ \text{s. t.} & X^\top X = I \end{array}$$

其中, 电荷密度 $\rho(X) := \text{diag}(X X^\top)$, 总能量泛函

$$E(X) := \frac{1}{4} \text{tr}(X^\top L X) + \frac{1}{2} \text{tr}(X^\top V_{ion} X) + \frac{1}{2} \sum_i \sum_l |x_i^\top w_l|^2 + \frac{1}{4} \rho^\top L^\dagger \rho + \frac{1}{2} e^\top \epsilon_{xc}(\rho)$$

- 1 动能 (L : 是平面波基底下拉普拉斯算子的有限维表示)
- 2 局部离子势能 (V_{ion} : 笛卡尔直角网格下的离子势)
- 3 非局部离子势能 (w_l : 投影函数的离散势)
- 4 Hartree 势能 (L^\dagger : L 的伪逆)
- 5 非经典的交换关联能 (ϵ_{xc} : 电子作用)

数值实验 — 串行

测试问题

- 工具包: KSSOLV [Yang-Meza-Lee-Wang 2009]
(<http://crd-legacy.lbl.gov/~chao/KSSOLV/>)

问题	$n \times p$
al	16879×12
alanine	12671×18
benzene	8407×15
c2h6	2103×7
c12h26	5709×37
co2	2103×8

问题	$n \times p$
ctube661	12599×48
glutamine	16517×29
graphene16	3071×37
graphene30	12279×67
h2o	2103×4
hnco	2103×8

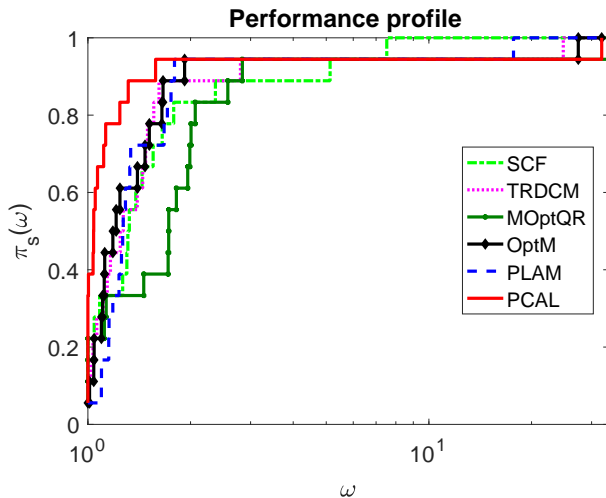
问题	$n \times p$
nic	251×7
pentacene	44791×51
ptnio	4609×43
qdot	2103×8
si2h4	2103×6
sih4	2103×4

测试算法

- SCF: 自洽场迭代
- TRDCM: 信赖域直接极小化 [Meza-Wang-Yang 2007]
- MOptQR: QR 收缩流形算法 + BB 步长
(<http://www.manopt.org>)
- OptM: [Wen-Yin 2012] (BB 步长)
(<https://github.com/wenstone/OptM>)
- PLAM: $\eta = \eta_{ABB}$, $\beta = 10$
- PCAL: $\eta = \eta_{ABB}$, $\beta = 1$
(<https://github.com/opt-gaobin/PCAL>)

Solver	E_{tot}	KKT violation	Iteration	Feasibility violation	CPU time(s)
al, $n = 16879$, $p = 12$ ($\beta_{PLAM} = 10$, $\beta_{PCAL} = 1$)					
SCF	-1.5789379003e+01	4.88e-03	200	6.53e-15	539.51
TRDCM	-1.580379151e+01	6.36e-06	154	4.94e-15	336.79
MOptQR	-1.5803814080e+01	1.88e-04	1000	1.33e-14	393.54
OptM	-1.5803791098e+01	2.38e-05	1000	3.19e-14	378.80
PLAM	-1.5803790675e+01	1.29e-05	1000	3.34e-07	399.80
PCAL	-1.5803791055e+01	8.96e-06	596	5.95e-15	228.06
graphene30, $n = 12279$, $p = 67$ ($\beta_{PLAM} = 13$, $\beta_{PCAL} = 1$)					
SCF	-1.7358453985e+02	5.19e-03	200	1.93e-14	2815.79
TRDCM	-1.7359510506e+02	4.80e-06	71	1.42e-14	765.92
MOptQR	-1.7359510505e+02	9.92e-06	456	2.59e-14	800.08
OptM	-1.7359510506e+02	2.47e-06	472	2.49e-14	904.44
PLAM	-1.7359510505e+02	8.88e-06	330	2.75e-14	601.41
PCAL	-1.7359510505e+02	8.52e-06	253	2.62e-14	548.70
ctube661, $n = 12599$, $p = 48$ ($\beta_{PLAM} = 13$, $\beta_{PCAL} = 1$)					
SCF	-1.3463843175e+02	3.88e-07	11	1.43e-14	56.43
TRDCM	-1.3463843176e+02	6.85e-06	23	1.09e-14	87.41
MOptQR	-1.3463843176e+02	7.21e-06	152	1.78e-14	107.62
OptM	-1.3463843176e+02	2.35e-06	82	2.15e-14	59.23
PLAM	-1.3463843176e+02	4.34e-06	107	2.37e-14	72.18
PCAL	-1.3463843176e+02	9.68e-06	65	1.95e-14	54.07
pentacene, $n = 44791$, $p = 51$ ($\beta_{PLAM} = 13$, $\beta_{PCAL} = 1$)					
SCF	-1.3189029494e+02	5.76e-07	13	1.58e-14	293.68
TRDCM	-1.3189029495e+02	7.60e-06	22	1.08e-14	276.25
MOptQR	-1.3189029495e+02	7.78e-06	112	3.21e-14	306.97
OptM	-1.3189029495e+02	1.39e-06	97	3.39e-14	283.02
PLAM	-1.3189029495e+02	8.66e-06	123	3.52e-14	321.04
PCAL	-1.3189029495e+02	7.67e-06	89	3.08e-14	271.32

综合性能比较



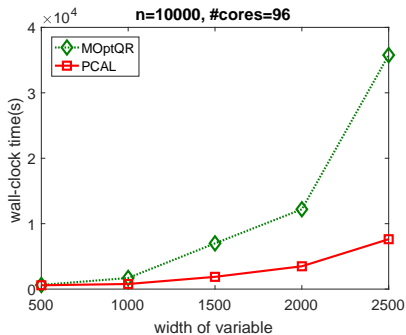
近似的离散 Kohn-Sham 总能量极小化问题

$$\begin{aligned} \min_{X \in \mathbb{R}^{n \times p}} \quad & \frac{1}{2} \text{tr}(X^\top L X) + \frac{1}{2} \rho(X)^\top L^\dagger \rho(X) - \frac{3}{4} \gamma \rho(X)^\top \rho(X)^{\frac{1}{3}} \\ \text{s. t.} \quad & X^\top X = I_p, \end{aligned}$$

- $\rho(X) := \text{diag}(X X^\top)$
- $L = \text{Diag}(L_1, \dots, L_s)$, 其中 $L_i \in \mathbb{R}^{5 \times 5}$ 为 $(-1, 2, -1)$ 类型的三对角矩阵
- $\gamma = 2\left(\frac{3}{\pi}\right)^{1/3}$
- PCAL: 罚参数 $\beta = 2$


墙钟时间

列数变化




- PCAL: 墙钟时间线性增长

并行加速比 ($p = 1000$)



(a) MOptQR



(b) PCAL

- PCAL: 更高的总并行加速比 **Total**

6. 总结与展望

总结

- 正交约束优化问题
 - 一阶最优性条件
 - 乘子显式表达式
- 非收缩算法框架
 - 收敛性
 - 数值表现优异
- 子空间加速算法
- 正交约束优化的并行算法
 - 收敛性, 局部线性收敛速度, 复杂度
 - 并行可扩展性高
- 电子结构计算中的应用

- 推广乘子校正算法
- 开发并行算法软件包
- 考虑更大规模的电子结构体系 (百万量级)

谢谢各位专家！