

連続最適化チーム 武田朗子 Continuous Optimization Team

Akiko Takeda



数理最適化(主に連続最適化)に関する研究

機械学習やデータマイニングから生じる最適化問題を うまく解き、実社会の問題解決に役立てたい

チームの強み:

- 複雑な制約をもつ問題に対する効率的解法
- 非平滑・非凸最適化問題に対する効率的解法
- 理論保証付き DC (Difference-of-Convex) アルゴリズム

複数のランク制約をもつ問題に対する DC 近似アルゴリズム

[T. Liu, I. Markovsky, T. K. Pong, and A. Takeda, submitted, 2019]

|複数のランク制約をもつ問題:

 $\min_{y=(y_1\cdots y_N)} f(y) \quad s.t. \quad y \in \Omega_1 \cap \Omega_2.$

 $\Omega_1 := \{ y : rank(\mathcal{H}_{r_i+1}(y_i)) \le r_i \ \forall i \},$

 $\Omega_2 := \{ y : rank([\mathcal{H}_{r+1}(y_1) \cdots \mathcal{H}_{r+1}(y_N)]) = r \}.$

• $y_i \in \mathbb{R}^n$

- • $\mathcal{H}_s(\cdot)$ Hankel 行列
- r_i とr: 正整数
- f: level-bound かつ 勾配は Lipschitz 連続

提案解法 SDCAM:

$$\min_{y \in \mathbb{R}^{Nn}} F(y) := f(y) + \delta_{\Omega}(y) + \sum_{i=1}^{k} \delta_{C_i}(\mathcal{A}_i(y)).$$

ペア (Ω, C_i) は3通りの設定が可能

SDCAM は以下の問題を解く: $\min_{y \in \mathbb{R}^{Nn}} F_{\lambda}(y) := f(y) + \delta_{\Omega}(y) + \sum_{i=1}^{n} \frac{1}{2\lambda} \operatorname{dist}^{2}(\mathcal{A}_{i}(y), C_{i}).$ 部分問題を解くには Ω への射影が必要だが、その計算は困難 \rightarrow 他の方法は?

 \hat{y} の Ω に対する擬似射影($u \in \Omega$ に関して)

 $\mathcal{P}_{\Omega}^{s}(\hat{y}; u) := \{ y \in \Omega : \hat{y} - y \in N_{\Omega}(y) \text{ and } ||y - \hat{y}|| \le ||u - \hat{y}|| \}.$

既存のソルバー SLRA ← を用いることで得られる 理論的な結果も存在

解の実行可能性は?

後処理:SDCAM の点から交互擬射影

 $z^{t+1} \in \mathcal{P}_{\Omega_1}^s(x^t; z^t) \text{ and } x^{t+1} \in \mathcal{P}_{\Omega_2}^s(z^{t+1}; x^t) \ t = 0, 1, \cdots$

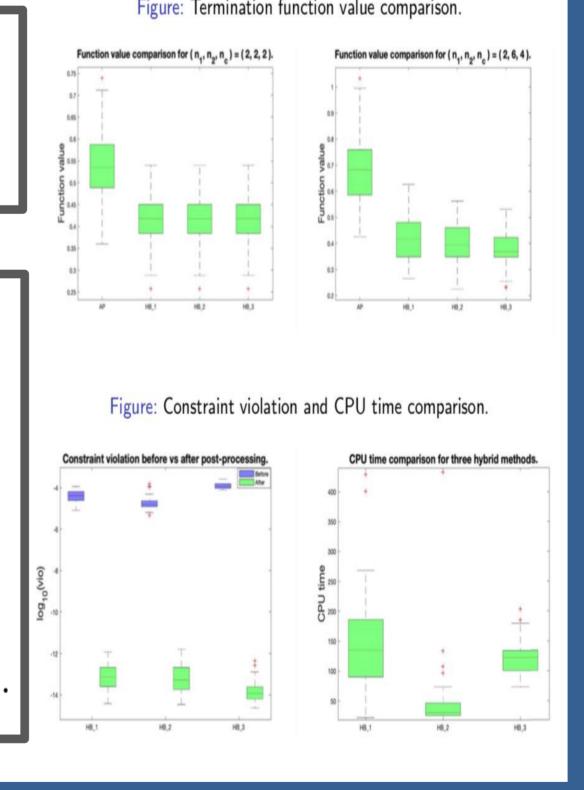
理論的成果:

SDCAM の点列は以下を満たす:

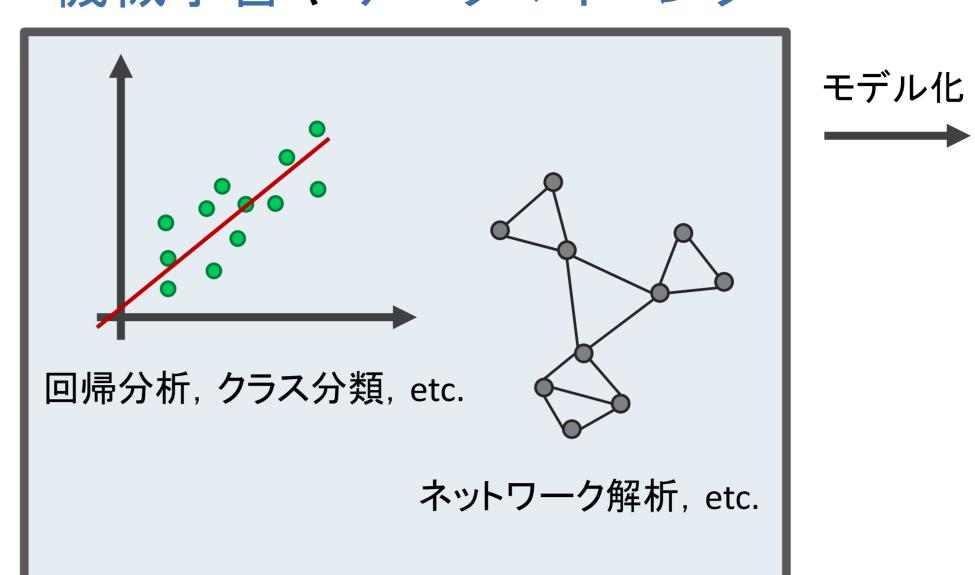
$$\operatorname{dist}(\mathcal{A}_i(y^k), C_i) \le \sqrt{2\lambda_{k-1}} f(y^{\text{feas}})$$

後処理の点列は、以下の条件を満たす $\bar{y} \in \Omega_1 \cap \Omega_2$ が存在すれば、局所 R-線形収束

 $rank([\mathcal{H}_{r+1}(\bar{y}_1)\cdots\mathcal{H}_{r+1}(\bar{y}_N)]) = r, \quad N_{\Omega_1}(\bar{y}) \cap N_{\Omega_2}(\bar{y}) = \{0\}.$



機械学習やデータマイニング



数理最適化問題 min. f(x)

s.t. $g_1(x) \le 0$, $g_2(x) \le 0,$

解法研究(例):

- 非平滑•非凸最適化法
- DCアルゴリズム
- ロバスト最適化法

チームの得意とするところ

非平滑・非凸最適化に対する確率的手法

[M. Metel, A. Takeda, ICML, 2019]

[M. Metel, A. Takeda, arXiv:1905.10188, 2019]

問題設定:

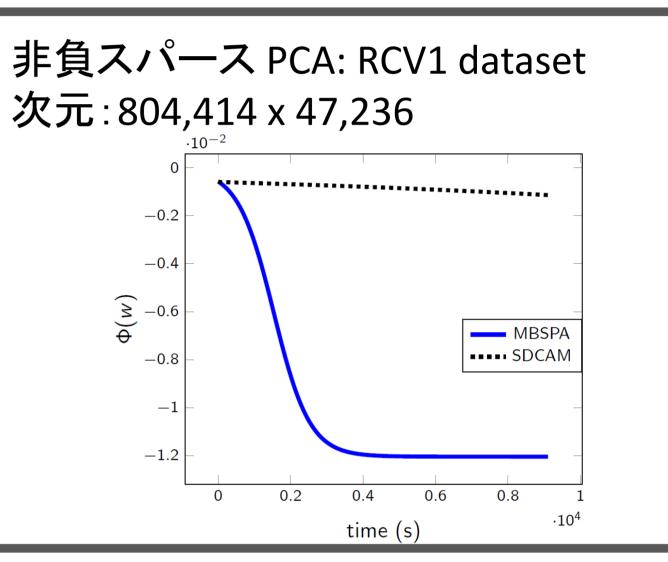
 $\min_{w \in \mathbb{R}^d} \Phi(w) := f(w) + g(w) + h(w)$

where $f(w) := \mathbb{E}_{\xi}[F(w,\xi)]$

• f(w): 損失関数 (勾配は Lipschitz 連続)

g(w):スパース正則化項 (Lipschitz 連続)

• h(w): 凸制約 (閉真凸関数)



劣微分の意味での収束:

$$\mathcal{G}^{\Phi}_{\gamma}(w) := \left\{ \frac{1}{\gamma} \left(w - \operatorname{prox}_{\gamma h}(w - \gamma s) \right) : s \in \nabla f(w) + \partial g(w) \right\}$$

収束基準: 期待値評価による ε-accurate な解

 $\mathbb{E}\left[\operatorname{dist}(0,\mathcal{G}_{\gamma}^{\Phi}(w))\right] \leq \epsilon$

 $\operatorname{dist}(0,\mathcal{G}^{\Phi}_{\gamma}(w)) = 0 \to 0 \in \nabla f(w) + \partial g(w) + \partial h(w)$ が成り立つ

ミニバッチ確率的近接法 (Mini-batch stochastic proximal algorithm; MBSPA):

f(w) + g(w) の平滑近似に対する確率的勾配

$$\nabla A_{\lambda,M}^{k}(w^{k},\xi^{k}) = \frac{1}{M} \sum_{j=1}^{M} \nabla F(w^{k},\xi_{j}^{k}) + \frac{1}{\lambda} (w^{k} - \zeta^{\lambda}(w^{k}))$$

where $\zeta^{\lambda}(w^k) \in \operatorname{prox}_{\lambda q}(w^k)$

アルゴリズムでの主な計算: $w^{k+1} = \text{prox}_{\gamma h}(w^k - \gamma \nabla A_{\lambda M}^k(w^k, \xi^k))$

|計算複雑度:

| 勾配の計算回数: $O(\epsilon^{-5})$ 近接作用素の計算回数: $O(\epsilon^{-3})$

混合整数DC最適化に対する理論保証付きDCアルゴルズム [T. Okuno and Y. Ikebe, Optimization, 2019]

混合DC最適化問題

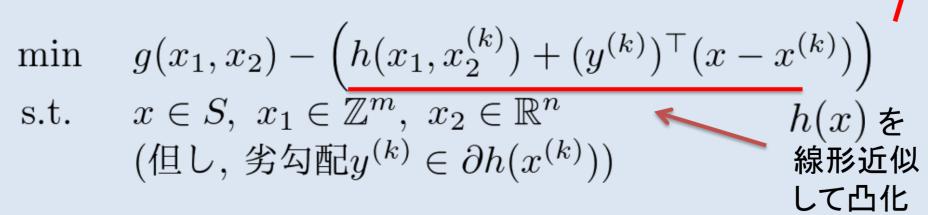
Difference-of -Convex

min $g(x_1, x_2) - h(x_1, x_2)$ $x \in S, x_1 \in \mathbb{Z}^m, x_2 \in \mathbb{R}^n$

- $g,h:\mathbb{R}^{m+n}\to\mathbb{R}:$ 微分可能な閉真凸関数
- $S \subseteq \mathbb{R}^{m+n}$: 空ではない閉凸集合
- ℤ:整数集合,ℝ:実数集合
- 離散変数と連続変数を併せもつ最適化問題 (混合整数最適化問題) の一つのクラス
- 目的関数が非凸であるため求解は非常に難しい

提案手法

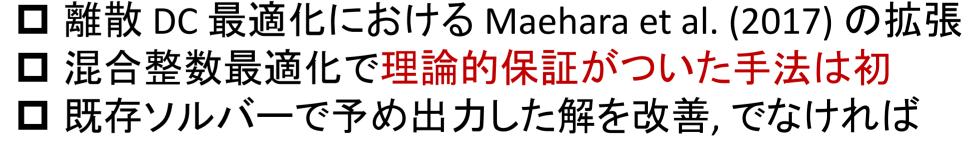
以下を収束するまで繰り返す 以下の子問題の最適解を $\mathbf{x}^{(k+1)}$ とする



子問題は混合整数凸最適化問題なので 既存のソルバーで解くことができる

主結果

- 1. 考えている問題と或等価な連続DC最適化問題の DC 停留点と呼ばれる最適性条件を満たす点への大域的収束性を証明
- 2. 平滑化法と呼ばれる非平滑最適化に対する手法と組み合わせて, 非平滑な関数をもつ混合整数 DC に対しても同様の理論結果を得た

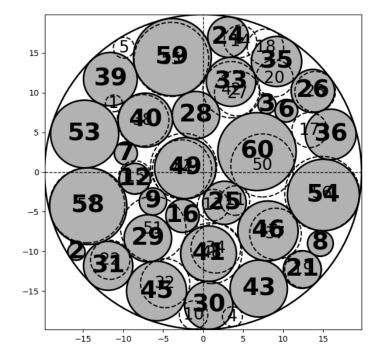


最適性の保証ができるので実用面においても優れている

応用例)円を円の中に配置する問題(2次元) [Y. Ikebe, S. Masuda, T. Okuno, submitted]

入力: n 個の小円と外円 出力:外円の中で総面積が 最大かつ, 互いに重ならな いような小円の配置

> 既存手法よりも より高速に,より良い解



提案手法に基づく 出力結果例