

# 計算が困難な目的関数をもつ凸最適化問題に対する Frank–Wolfe 法

田中未来 数理・推論研究系 数理最適化グループ, 統計的機械学習研究センター 准教授

## 1 計算が困難な目的関数をもつ凸最適化問題

- 凸関数  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , 凸集合  $S \subseteq \mathbb{R}^n$  で定まる次の凸最適化問題を考える:

$$f^* := \min_{x \in S} f(x). \quad (1)$$

- 多くの凸最適化アルゴリズムは次のような  $f$  や  $S$  に関する計算が容易であることが前提:
  - $f$  に関する計算:  $f(x)$  や  $\nabla f(x)$  の計算など.
  - $S$  に関する計算:  $x \in S?$  の判定や  $\text{proj}_S(x)$  の計算など.
- 実際の応用ではこれらの計算はしばしば困難.
- 本研究では  $S$  に関するある計算は容易だが  $f$  に関する計算が困難な設定で問題 (1) を解くアルゴリズムを考える.

## 2 目的関数に関する設定: なにが計算/利用可能?

- 0 次と 1 次の神託あり:  $f(x)$ ,  $\nabla f(x)$  の正確な値を計算可能.
  - 多くの凸最適化アルゴリズムで仮定. 本研究では仮定しない.
- 雑音入り 0 次の神託あり:  $\nabla f(x)$  は計算不可能だが,  $f(x)$  は雑音入りで計算可能.
  - Bayes 最適化や進化計算など関係がありそう.
- 神託なし雑音入りデータあり:  $f(x)$  は雑音入りでも計算不可能だが, 雑音入りデータ  $\{(x_i, y_i)\}_{i=1}^m$  が利用可能.
  - あまり考えられていない設定のようだが, 実際の応用でもありそう.

## 3 素朴な方法: 2 段階法

アルゴリズム 1 問題 (1) に対する雑音入りデータを用いた 2 段階法


- モデル  $\hat{f}(\cdot, \theta)$  を用いて目的関数を推定:  $\hat{\theta} \in \arg\min_{\theta \in \Theta} \sum_{i=1}^m (y_i - \hat{f}(x_i, \theta))^2$ .
- 推定した目的関数  $\hat{f}(\cdot, \hat{\theta})$  を用いて最適化:  $\hat{x} \in \arg\min_{x \in S} \hat{f}(x, \hat{\theta})$ .

- 問題点: 複雑な  $\hat{f}$  を用いると予測精度は上がるが, 最適化が困難になる.

## 4 Frank–Wolfe 法 (Frank and Wolfe, 1956)

アルゴリズム 2 問題 (1) に対する Frank–Wolfe 法

- $x^{(0)} \in S$  を適当に定める.
- for  $k = 0, 1, \dots$ :
- 子問題の求解:  $s^{(k)} \in \arg\min_{s \in S} \langle \nabla f(x^{(k)}), s \rangle$ .
- 解の更新:  $x^{(k+1)} := x^{(k)} + \gamma^{(k)}(s^{(k)} - x^{(k)})$ .



- 実用上は子問題が容易に解ける必要がある ( $S$  に関する神託).
  - 近似解を  $s_k$  としてもよい (Jaggi (2013),  $S$  に関する弱い神託):

$$s^{(k)} \in \left\{ s \in S: \langle \nabla f(x^{(k)}), s \rangle \leq \min_{s' \in S} \langle \nabla f(x^{(k)}), s' \rangle + \delta_k \right\}.$$

- ステップ幅  $\gamma^{(k)}$  の決め方:
  - $-\gamma^{(k)} \in \arg\min_{\gamma \in [0, 1]} f(x^{(k)} + \gamma(s^{(k)} - x^{(k)}))$  とするのが自然.
  - $-\gamma^{(k)} := \frac{2}{k+2}$  としても理論的な収束の速さは変わらない.

## 5 提案手法: 近似勾配を用いた Frank–Wolfe 法

アルゴリズム 3 問題 (1) に対する近似勾配を用いた Frank–Wolfe 法

- $x^{(0)} \in S$  を適当に定める.
- for  $k = 0, 1, \dots$ :
- 近似勾配の計算:  $g^{(k)} := \nabla f(x^{(k)})$ .
- 子問題の求解:  $s^{(k)} \in \arg\min_{s \in S} \langle g^{(k)}, s \rangle$ .
- 解の更新:  $x^{(k+1)} := x^{(k)} + \frac{2}{k+2}(s^{(k)} - x^{(k)})$ .

- 1 次の神託ありの場合,  $g^{(k)} := \nabla f(x^{(k)})$  としてアルゴリズム 2 に一致.
- 雑音入り 0 次の神託ありの場合, 勾配の差分近似を用いる.
- 神託なし雑音入りデータありの場合, 局所線形回帰の回帰係数を用いる:

$$(g_0^{(k)}, g^{(k)}) \in \arg\min_{(g_0, g) \in \mathbb{R} \times \mathbb{R}^n} \sum_{i=1}^m \kappa(x_i, x^{(k)})(y_i - g_0 - \langle g, x_i \rangle)^2. \quad (2)$$

## 6 提案手法の理論解析

### 6.1 アルゴリズムの収束解析

定理 1.  $\nabla f$  の Lipschitz 定数を  $L$ ,  $S$  の直径を  $D$  とし, アルゴリズム 3 によって生成された点列を  $\{x^{(k)}\}$  とする. このとき, 次が成り立つ:

$$f(x^{(k)}) - f^* \leq \frac{2LD^2}{k+2} + \frac{2}{k+1} \sum_{l=0}^{k-1} \delta_l \quad (k = 0, 1, \dots).$$

ここで  $\delta_k$  は  $\delta_k \geq \|\nabla f(x^{(k)}) - g^{(k)}\|$  を満たす定数.

- $S$  に関する弱い神託を用いたアルゴリズム 2 の収束解析 (Jaggi, 2013) に基づく.
- 右辺第 1 項はアルゴリズム 2 の収束率に一致:  $O(k^{-1})$ .
- 右辺第 2 項は近似勾配の誤差に由来.
  - $-\delta_k = O(k^{-1})$  のとき,  $O(k^{-1})$  の収束率で  $\lim_{k \rightarrow \infty} f(x^{(k)}) = f^*$ .
  - $-\delta_k \leq \delta$  (定数) のとき,  $O(k^{-1})$  の収束率で  $\limsup_{k \rightarrow \infty} f(x^{(k)}) \leq f^* + 2\delta$ .
- 雑音入り 0 次の神託ありの場合で勾配を差分近似したとき,  $E(\|\nabla f(x^{(k)}) - g^{(k)}\|)$  の上界が評価できる (Brekelmans et al., 2005).

### 6.2 局所線形回帰を用いた近似勾配の誤差解析

定理 2. 式 (2) で  $g^{(k)}$  を計算するとき,  $\{x_i\}_{i=1}^m$  のうち  $x^{(k)}$  の  $m'$  最近傍の添字集合を  $N_{m'}(x^{(k)})$  として,  $i \in N_{m'}(x^{(k)})$  のとき  $\kappa(x_i, x^{(k)}) = 1$ , そうでないとき 0 とする  $\kappa$  を用いる.  $\{x_i\}_{i \in N_{m'}(x^{(k)})}$  を並べた行列の最小特異値  $\rho_{\min}^{(k)}$  が正であることを仮定し,  $\{\epsilon_i := y_i - f(x_i)\}_{i=1}^m$  は独立で, 各  $i = 1, \dots, m$  について  $E(\epsilon_i) = 0$ ,  $E(\epsilon_i^2) = \sigma^2$  であることを仮定する. このとき, 次が成り立つ:

$$E(\|\nabla f(x^{(k)}) - g^{(k)}\|) \leq \frac{1}{\rho_{\min}^{(k)}} \sqrt{n\sigma^2 + \frac{m'L^2D^4}{4}} \quad (k = 0, 1, \dots).$$

本研究は山根大輝氏, 小林健氏, 中田和秀氏 (東工大) との共同研究である.