

DC問題に対する非厳密Newton型近接勾配法

05001310 東京工業大学

*リュウ ティエンシャン LIU Tianxiang

01308490 東京大学/理化学研究所

武田 朗子

TAKEDA Akiko

1. はじめに

本発表では [4] の概要を述べる. 以下の DC 問題を取り扱う.

$$\min_{\mathbf{x} \in \mathbb{R}^n} F(\mathbf{x}) = f(\mathbf{x}) + h(\mathbf{x}) - g(\mathbf{x}). \quad (\text{DC})$$

ここで, f は微分可能な関数で, 勾配 ∇f のリプシッツ定数は L である. h は凸関数であり, 有効定義域で連続である. また, g は連続凸関数である.

問題 (DC) を解くアルゴリズムの中で, 主なものは一次法 (例えば, [6, 7]) である. よって, 関数 f のヘッセ行列の情報を使う方法はまだ少ない. 一方で, 特に $g = 0$ の場合, 多くの Newton 型近接勾配法 ([1, 5] など) が存在している. それらの文献では, ヘッセ行列の情報を使うと, 数値試験のパフォーマンスはより良くなることが報告されている.

本研究では一般的な場合 ($g \neq 0$) の問題 (DC) を解くため新たな非厳密 Newton 型近接勾配法を提案し, その収束性を解析する.

まず, g が凸より, $\boldsymbol{\xi}^{k+1} \in \partial g(\mathbf{x}^k)$ を用いて, 以下の子問題を構築する.

$$\min_{\mathbf{z} \in \mathbb{R}^n} G_k(\mathbf{z}) := \langle \nabla f(\mathbf{x}^k) - \boldsymbol{\xi}^{k+1}, \mathbf{z} - \mathbf{x}^k \rangle + \frac{1}{2}(\mathbf{z} - \mathbf{x}^k)^\top \mathbf{B}_k(\mathbf{z} - \mathbf{x}^k) + h(\mathbf{z}). \quad (\text{Sub})$$

ここで, \mathbf{B}_k は対称行列である. 子問題の最適解が必要ではなく, 近似解で十分である. 具体的に, $\epsilon > 0$ が与えらると, 以下の条件を満たす近似解 \mathbf{u}^k を考える.

$$\text{dist}(\mathbf{0}, \partial G_k(\mathbf{u}^k)) \leq \epsilon_k \|\mathbf{u}^k - \mathbf{x}^k\|. \quad (\text{Rule})$$

次に, (Sub) の近似解 \mathbf{u}^k を得ると, 目的関数値 F を小さくするために, 直線探索を使う. 特に, 以下の三つの直線探索を考える: $\sigma \in (0, 1)$, $\beta \in (0, 1)$, $M \geq 0$ は整数, $\mathbf{d}_k = \mathbf{u}^k - \mathbf{x}^k$ とし, ステップサイズ α_k を $\{\beta^i : i = 0, 1, \dots\}$ の中で以下の条件を満たす最大のものとする.

$$F(\mathbf{x}^k + \alpha_k \mathbf{d}_k) \leq \max_{[k-M]_+ \leq j \leq k} F(\mathbf{x}^j) + \sigma \alpha_k \Delta_{k,1}. \quad (\text{LS}_1)$$

ここで, $\Delta_{k,1} := \langle \nabla f(\mathbf{x}^k) - \boldsymbol{\xi}^{k+1}, \mathbf{d}_k \rangle + h(\mathbf{u}^k) - h(\mathbf{x}^k)$ である.

$$F(\mathbf{x}^k + \alpha_k \mathbf{d}_k) \leq \max_{[k-M]_+ \leq j \leq k} F(\mathbf{x}^j) + \sigma \Delta_k(\alpha_k). \quad (\text{LS}_2)$$

ここで, $\Delta_k(\alpha_k) := \alpha_k \langle \nabla f(\mathbf{x}^k) - \boldsymbol{\xi}^{k+1}, \mathbf{d}_k \rangle + h(\mathbf{x}^k + \alpha_k \mathbf{d}_k) - h(\mathbf{x}^k)$ である.

$$F(\mathbf{x}^k + \alpha_k \mathbf{d}_k) \leq \max_{[k-M]_+ \leq j \leq k} F(\mathbf{x}^j) - \sigma \alpha_k \|\mathbf{d}_k\|^2. \quad (\text{LS}_3)$$

上記に基づいて, 問題 (DC) に対する非厳密 Newton 型近接勾配法 (iSQA) を示す.

Step 0. 初期点 $\mathbf{x}^0 \in \text{dom } h$, $\beta \in (0, 1)$, $\sigma \in (0, 1)$, 整数 $M \geq 0$, $\{\epsilon_k\}$ を正の数列とする. また, $k = 0$ とする.

Step 1. $\mathbf{B}_k \in \mathcal{S}^n$, $\boldsymbol{\xi}^{k+1} \in \partial g(\mathbf{x}^k)$ とする. 子問題 (Sub) に対して, \mathbf{x}^k を初期点として, (Rule) を満たす近似解 \mathbf{u}^k を探す.

Step 2. $\mathbf{d}_k = \mathbf{u}^k - \mathbf{x}^k$ とする. α_k を $\{\beta^i : i = 0, 1, \dots\}$ の中で (LS₁), (LS₂) 又は (LS₃) を満たす最大のものとする.

Step 3. $\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha_k \mathbf{d}_k$ とし, $k \leftarrow k + 1$ とする. そして, Step 1 に戻る.

2. 収束性解析

収束解析を行うため, 任意の $k \geq 0$ に対して, $G_k(\cdot)$ が μ_k -強凸関数 ($\mu_k > 0$) と仮定する. また, 以下のパラメータを定義する.

$$\delta_k := \frac{\mu_k + \lambda_{\min}(\mathbf{B}_k)}{2} - \epsilon_k.$$

ここで, $\lambda_{\min}(\mathbf{B}_k)$ は行列 \mathbf{B}_k の最小固有値である.

定理 1 (直線探索の有限回終了). $\delta_k > 0$ のとき, 直線探索 (LS₁) と (LS₂) は有限回反復で終了する; $\delta_k > \sigma$ のとき, 直線探索 (LS₃) は有限回反復で終了する. さらに,

$$\alpha_k \geq \begin{cases} \min\{1, 2\beta(1-\sigma)\delta_k/L\}, & \delta_k > 0: (\text{LS}_1), (\text{LS}_2) \text{ の場合} \\ \min\{1, 2\beta(\delta_k - \sigma)/L\}, & \delta_k > \delta: (\text{LS}_3) \text{ の場合} \end{cases}$$

が成り立つ.

定理 2 (部分列の収束). $\{\mathbf{B}_k\}$ が有界と仮定する. $\delta := \inf_k \delta_k$ とする. $\{\mathbf{x}^k\}$ はアルゴリズム (iSQA) で生成される点列とする. (LS₁) 又は (LS₂) の場合 $\delta > 0$ であれば, もしくは (LS₃) の場合 $\delta > \sigma$ であれば, 以下の結論が成り立つ.

- (i) 点列 $\{\mathbf{x}^k\}$ は有界;
- (ii) $\lim_{k \rightarrow \infty} \|\mathbf{x}^{k+1} - \mathbf{x}^k\| = 0$;
- (iii) 点列 $\{\mathbf{x}^k\}$ の任意の集積点は (DC) の停留点である。
次いで、アルゴリズム (iSQA) の複雑さの分析を行う。
そのため、最初に、 $\xi^{k+1} \in \partial g(\mathbf{x}^k)$ とし、 \mathbf{x}^k と最適解の
“距離”は次のように定義する。

$$R_k = \|\mathbf{x}^k - \text{prox}_h(\mathbf{x}^k - (\nabla f(\mathbf{x}^k) - \xi^{k+1}))\|.$$

ここで、近接写像は $\text{prox}_h(\mathbf{y}) := \arg \min_{\mathbf{x}} \{h(\mathbf{x}) + \frac{1}{2}\|\mathbf{x} - \mathbf{y}\|^2\}$ として定義される。複雑さの分析のため、 R_k を用いて、以下の近似停留点を考慮する。

定義 1 (近似停留点). $\varepsilon > 0$ が与えると、ある整数 $N \geq 0$ に対して以下の不等式が満たせば、アルゴリズム (iSQA) で「 ε -近似停留点が得られる」という。

$$\min_{0 \leq k \leq N} R_k^2 \leq \varepsilon.$$

定理 3 (定理 3.11 [4]). アルゴリズム (iSQA) において $M = 0$ とし、全ての k に対して、以下の条件を満たすとする。

$$\lambda_{\min}(\mathbf{B}_k) - \epsilon_k > \begin{cases} 0 & \text{(LS}_1\text{) 又は (LS}_2\text{) の場合;} \\ \sigma & \text{(LS}_3\text{) の場合.} \end{cases}$$

また、 c_k と θ_k を次のように定義する。

$$c_k := \frac{\sigma(\lambda_{\min}(\mathbf{B}_k) - \epsilon_k) \min\{1, 2\beta(1 - \sigma)(\lambda_{\min}(\mathbf{B}_k) - \epsilon_k)/L\}}{(1 + 1/\lambda_{\min}(\mathbf{B}_k) + \sqrt{1 - 2/\lambda_{\max}(\mathbf{B}_k) + 1/\lambda_{\min}^2(\mathbf{B}_k)})^2},$$

$$\theta_k := \frac{\sigma \min\{1, 2\beta(\lambda_{\min}(\mathbf{B}_k) - \epsilon_k - \sigma)/L\}}{(1 + 1/\lambda_{\min}(\mathbf{B}_k) + \sqrt{1 - 2/\lambda_{\max}(\mathbf{B}_k) + 1/\lambda_{\min}^2(\mathbf{B}_k)})^2}.$$

ここで、 $\lambda_{\max}(\mathbf{B}_k)$ は行列 \mathbf{B}_k の最大固有値である。 $F^* = \min_{\mathbf{x} \in \mathbb{R}^n} F(\mathbf{x})$ とすると、全ての $N \geq 0$ に対して、以下の不等式が成り立つ。

$$\min_{0 \leq k \leq N} R_k^2 \leq \begin{cases} (F(\mathbf{x}^0) - F^*) / \sum_{k=0}^N c_k & \text{(LS}_1\text{) 又は (LS}_2\text{);} \\ (F(\mathbf{x}^0) - F^*) / \sum_{k=0}^N \theta_k & \text{(LS}_3\text{) の場合.} \end{cases}$$

特に、 $\inf_k (\lambda_{\min}(\mathbf{B}_k) - \epsilon_k) > \sigma$ のとき、アルゴリズム (iSQA) の複雑さは $N = O(\varepsilon^{-1})$ である。

3. 子問題の適切な終了条件

\mathbf{B}_k が正定値行列のとき、 G_k が強凸関数なので、子問題は多くのアルゴリズムにより解ける。例えば、

$$\phi(\mathbf{z}) := \langle \nabla f(\mathbf{x}^k) - \xi^{k+1}, \mathbf{z} - \mathbf{x}^k \rangle + \frac{1}{2}(\mathbf{z} - \mathbf{x}^k)^\top \mathbf{B}_k(\mathbf{z} - \mathbf{x}^k)$$

を定義し、 $\mathbf{y}^1 = \mathbf{z}^0 = \mathbf{x}^k$ とすると、[2] におけるアルゴリズム V-FISTA の点列は以下の更新式で生成される。

$$\begin{cases} \mathbf{z}^\ell = \text{prox}_{\frac{1}{L_\phi}h}(\mathbf{y}^\ell - \nabla \phi(\mathbf{y}^\ell)/L_\phi), \\ \mathbf{y}^{\ell+1} = \mathbf{z}^\ell + \frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1}(\mathbf{z}^\ell - \mathbf{z}^{\ell-1}). \end{cases} \quad \text{(V-FISTA)}$$

ここで、 $L_\phi = \lambda_{\max}(\mathbf{B}_k)$ であり、 $\kappa = L_\phi/\lambda_{\min}(\mathbf{B}_k)$ である。(V-FISTA) の終了条件は次のように設定する。

$$\|\mathbf{z}^\ell - \mathbf{y}^\ell\| \leq \frac{\epsilon_k}{2L_\phi} \|\mathbf{z}^\ell - \mathbf{z}^0\|. \quad \text{(Ter)}$$

\mathbf{z}^ℓ と \mathbf{y}^ℓ がすでに計算されているので、終了条件 (Ter) をチェックするための計算量は小さい。さらに、(Ter) により (Rule) を満たすことが保証される。

定理 4. \mathbf{B}_k を正定値行列とする。 \mathbf{z}^ℓ が (Ter) を満たせば、(Rule) は $\mathbf{u}^k = \mathbf{z}^\ell$ で成り立つ。

また、文献 [3] における Semi-smooth Newton 法を子問題 (Sub) を適用する場合を想定して、(Ter) と同様の計算量が小さい終了条件を提案した。

参考文献

- [1] S. Becker, J. Fadili and P. Ochs. On quasi-Newton forward-backward splitting: proximal calculus and convergence. *SIAM Journal on Optimization*, 29, 2445–2482, 2019.
- [2] A. Beck. First-order methods in optimization. SIAM, 2017.
- [3] X. Li, D. Sun and K. C. Toh. A highly efficient semismooth Newton augmented Lagrangian method for solving Lasso problems. *SIAM Journal on Optimization*, 28, 433–458, 2018.
- [4] T. Liu and A. Takeda. An inexact successive quadratic approximation method for a class of difference-of-convex optimization problems. *Optimization online*, 2021.
- [5] C. P. Lee and S. J. Wright. Inexact successive quadratic approximation for regularized optimization. *Computational Optimization and Applications*, 72, 641–674, 2019.
- [6] B. Wen, X. Chen and T. K. Pong. A proximal difference-of-convex algorithm with extrapolation. *Computational Optimization and Applications*, 69, 297–324, 2018.
- [7] S. J. Wright, R. D. Nowak and M. A. T. Figueiredo. Sparse reconstruction by separable approximation. *IEEE Transactions on Signal Processing*, 57, 2479–2493, 2009.