

メモリーレス対称ランクワン法に基づいた ニュートン型近接勾配法の大域的収束性について

05000392 中央大学 *中山 舜民 NAKAYAMA Shummin
01406032 慶應義塾大学 成島 康史 NARUSHIMA Yasushi

1. はじめに

本稿では、以下の無制約最適化問題

$$\min_{x \in \mathbb{R}^n} f(x) = g(x) + h(x) \quad (1)$$

に対するニュートン型近接勾配法を考える。ここで、 $g: \mathbb{R}^n \rightarrow \mathbb{R}$ は連続的微分可能な関数 (凸とは限らない) とし、 $h: \mathbb{R}^n \rightarrow \mathbb{R}$ は凸関数ではあるが必ずしも微分可能ではないものとする。機械学習においては、 g を損失関数、 h を正則化項とした問題 (1) がよく現れる。以降、 ∇g は g の勾配、 ∂h は h の劣微分、 $\|\cdot\|$ は l_2 ノルムとし、正定値対称行列 A による重み付きノルムを $\|x\|_A = \sqrt{x^T A x}$ で表記する。また、凸関数 h に対して正定値対称行列 B を重み行列とした近接写像を

$$\text{Prox}_h^B(\bar{x}) = \operatorname{argmin}_{x \in \mathbb{R}^n} \left\{ h(x) + \frac{1}{2} \|x - \bar{x}\|_B^2 \right\} \quad (2)$$

で定義する。本研究で扱うニュートン型近接勾配法の反復式は、任意の初期点 $x_0 \in \mathbb{R}^n$ に対し、以下で与えられる：

$$x_{k+1} = x_k + \eta_k d_k, \quad (3)$$

$$d_k = \text{Prox}_h^{B_k}(x_k - H_k \nabla g(x_k)) - x_k.$$

ここで、 $d_k \in \mathbb{R}^n$ は探索方向、 $\eta_k \in (0, 1]$ はステップ幅と呼ばれる。さらに、 B_k は適当な正定値対称行列とし $H_k = B_k^{-1}$ とする。 B_k としてヘッセ行列 $\nabla^2 g(x_k)$ のものや、準ニュートン法の更新公式を用いたニュートン型近接勾配法が提案されている。特に B_k として単位行列 I を選べば、最急降下法に基づいた通常の近接勾配法に対応し、関数 h が l_1 ノルムや標示関数などの単純な正則化関数ならば (2) は閉形式で与えられるため計算が容易になる。一方、 B_k が一般的な行列の場合は、近接写像を閉形式で与えることができないため、反復法を用いて近接写像を計算する必要がある。中山ら [3] は近接写像の計算の簡略化のために、メモリーレス Broyden 公式族に基づいて、近接写像を非厳密に求めるニュートン型近接勾配法を提案した。

本講演では、厳密な近接写像を効率的に求めることが可能なメモリーレス対称ランクワン法 [2] に着目した近接勾配法を提案し、その収束性について議論する。

2. メモリーレス対称ランクワン法に基づいたニュートン型近接勾配法

$\gamma_k > 0$ をスケールパラメータ、 ν_k を正則化パラメータとしたとき、中山ら [3] は行列 B_k に

$$B_k s_{k-1} = \gamma_k y_{k-1} \quad (4)$$

という修正セカント条件に基づいたメモリーレス Broyden 公式族を提案した。ここで、 $s_{k-1} = x_k - x_{k-1}$ 、 $y_{k-1} = \nabla g(x_k) - \nabla g(x_{k-1}) + \nu_k s_{k-1}$ とする。メモリーレス Broyden 公式族はランク 2 更新という形で与えられるため、厳密な重み付き近接写像 (2) を与えることが難しい。そのため、中山ら [3] は近接写像を非厳密に求める方法を提案している。一方、 $u \in \mathbb{R}^n$ とし、 $I \pm uu^T$ という単位行列のランク 1 更新の場合、Becker and Fadili [1, Theorem 7] の定理より、効率的に重み付き近接写像の計算が可能である。

命題 1. 行列 $B = I \pm uu^T$ は正定値対称行列であるとする。このとき、重み付き近接写像は

$$\text{Prox}_h^B(\bar{x}) = \text{Prox}_h^I(\bar{x} \mp \alpha u) \quad (5)$$

で与えられる。ただし、 α は

$$u^T (\bar{x} - \text{Prox}_h^I(\bar{x} \mp \alpha u)) + \alpha = 0 \quad (6)$$

の解である。□

この定理を用いれば、高々 1 次元の方程式 (6) を解くことによって、効率的に近接写像が計算できる。さらに、関数 h が l_1 ノルムの場合などといった区分分離可能な関数であれば、厳密な近接写像を求めることが可能である。本研究では、中山ら [2] の提案した行列の正定値性を保持するメモリーレス対称ランクワン公式に着目し、大域的収束性を保証するために、修正セカント条件 (4) に基づいたメモリーレス対称ランクワン公式

$$B_k = I + \frac{(\gamma_k y_{k-1} - s_{k-1})(\gamma_k y_{k-1} - s_{k-1})^T}{s_{k-1}^T (\gamma_k y_{k-1} - s_{k-1})}, \quad (7)$$

$$H_k = I + \frac{(s_{k-1} - \gamma_k y_{k-1})(s_{k-1} - \gamma_k y_{k-1})^T}{\gamma_k y_{k-1}^T (s_{k-1} - \gamma_k y_{k-1})} \quad (8)$$

を考える。この更新式は

$$\gamma_k > \frac{s_{k-1}^T s_{k-1}}{s_{k-1}^T y_{k-1}} \text{ or } \gamma_k < \frac{s_{k-1}^T y_{k-1}}{y_{k-1}^T y_{k-1}}$$

を満たすように選べば、 B_k が正定値対称行列となる。また、

$$u = \frac{\gamma_k y_{k-1} - s_{k-1}}{\sqrt{|s_{k-1}^T (\gamma_k y_{k-1} - s_{k-1})|}}$$

とすれば、(7) の分母 $s_{k-1}^T (\gamma_k y_{k-1} - s_{k-1})$ の符号が正であるときは $B_k = I + uu^T$ 、符号が負であるときは $B_k = I - uu^T$ と表すことができる。よって、命題1を適用することで、重み付き近接写像を効率的に求めることが可能である。

メモリーレス対称ランクワン法に基づいたニュートン型近接勾配法のアルゴリズムは以下の通りである。

アルゴリズム 1

Step 0. 初期点 x_0 と $0 < \delta < 1, 0 < \beta < 1, \epsilon > 0$ を与え、 $k := 0$ とする。

Step 1. (7), (8) により B_k, H_k を与え、 d_k を計算する。ただし、 $k = 0$ のときは $B_k = H_k = I$ とする。

Step 2. $\|d_k\| < \epsilon$ を満たすならば、アルゴリズムを停止して x_k を解とする。

Step 3. バックトラッキングにより Armijo 条件:

$$f(x_k + \beta^i d_k) \leq f(x_k) + \delta \beta^i \lambda_k,$$

$$\lambda_k = \nabla g(x_k)^T d_k + h(x_k + d_k) - h(x_k)$$

を満たす最小の非負整数 i を求め、 $\eta_k = \beta^i$ とする。

Step 4. (3) によって x_{k+1} を計算する。

Step 5. $k := k + 1$ として Step1 に戻る。

ステップ1では行列 B_k や H_k を与えているが、実際には行列を生成するのではなく、 $x_k, \nabla g(x_k), s_{k-1}, y_{k-1}$ のベクトル積のみで探索方向 d_k の計算が可能である。

3. 提案手法の収束性

本節ではメモリーレス対称ランクワン法に基づいたニュートン型近接勾配法の収束性について議論する。以下の命題は、適当な仮定の下で B_k が一様正定値かつ有界な行列になることを示している。

命題2. ∇g は Lipschitz 連続とする。 ν_k は有界かつある正定数 $\bar{\nu}$ が存在して $s_{k-1}^T y_{k-1} \geq \bar{\nu} \|s_{k-1}\|^2$ を満たすように選ばれ、スケーリングパラメータ γ_k は $\underline{\gamma} \leq \gamma_k \leq \bar{\gamma}$

を満たし、さらに

$$\gamma_k \geq (1 + \rho_1) \frac{s_{k-1}^T s_{k-1}}{s_{k-1}^T y_{k-1}} \text{ or } \gamma_k \leq (1 - \rho_2) \frac{s_{k-1}^T y_{k-1}}{y_{k-1}^T y_{k-1}}$$

を満たすように選ぶ。ここで、 $\underline{\gamma}, \bar{\gamma}, \rho_1, 0 < \rho_2 < 1$ は正定数とする。このとき、正の定数 m と M が存在して、任意の $v \in \mathbb{R}^n$ に対して以下を満たす:

$$m \|v\|^2 \leq v^T B_k v \leq M \|v\|^2. \quad \square$$

次に、アルゴリズムの収束性に関する命題を与える。**命題3.** 命題2と同じ仮定が成り立つとし、点列 $\{x_k\}$ はアルゴリズム1により生成されるとする。このとき、 x_k が停留点 (つまり、 $0 \in \nabla g(x_k) + \partial h(x_k)$ を満たす点) である必要十分条件は $d_k = 0$ である。 \square

命題3から、終了判定条件として「 $\|d_k\| < \epsilon$ を満たせばアルゴリズムを終了する」を考えることができる。さらに、上記の性質を用いることで、下記の大域的収束性の定理を得る。

定理1. 命題2と同じ仮定が成り立つとし、点列 $\{x_k\}$ はアルゴリズム1により生成されるとする。このとき、目的関数 f が下に有界であれば

$$\lim_{k \rightarrow \infty} \|d_k\| = 0$$

が成立する。さらに、生成される $\{x_k\}$ が有界であれば、その任意の集積点は停留点である。 \square

さらに、 g が強凸関数の場合には、以下の収束速度に関する定理を示すことができる。

定理2. 命題2と同じ仮定が成り立つとし、 g が μ -強凸関数であり、 h は凸関数とする。アルゴリズム1により生成される点列 $\{x_k\}$ は(1)の唯一解 x^* に以下の意味で R -1 次収束する。

$$\|x_k - x^*\| \leq \rho^k \sqrt{\frac{2}{\mu} (f(x_0) - f(x^*))}.$$

ここで $\rho \in (0, 1)$ は定数である。 \square

参考文献

- [1] S. Becker and J. Fadili, A quasi-Newton proximal splitting method, In *Advances in Neural Information Processing Systems (NIPS)*, **25** (2012), 2618–2626.
- [2] S. Nakayama, Y. Narushima and H. Yabe, A memoryless symmetric rank-one method with sufficient descent property for unconstrained optimization, *Journal of the Operations Research Society of Japan*, **61** (2018), 53–70.
- [3] 中山舜民, 成島康史, 矢部博, “メモリーレス Broyden 公式族に基づいた非厳密近接勾配法”, 日本オペレーションズ・リサーチ学会 2019 年春季研究発表会アブストラクト集, 224–225 (2019).