

非線形最適化問題に対する l_2 型主双対メリット関数 を用いた主双対内点法

01702330 東京理科大学理学部 *矢部 博 YABE Hiroshi
 01701240 数理システム 山下 浩 YAMASHITA Hiroshi

1. はじめに

本稿では、非線形最適化問題

$$\begin{aligned} &\text{minimize} && f(x), \quad x \in \mathbf{R}^n, \\ &\text{subject to} && g(x) = 0, \quad x_i \geq 0, \quad i \in I_P \subset \{1, 2, \dots, n\} \end{aligned}$$

を解くための主双対内点法を考える。ただし、 $f: \mathbf{R}^n \rightarrow \mathbf{R}^1$, $g: \mathbf{R}^n \rightarrow \mathbf{R}^m$, I_P は添字集合で $n' = |I_P|$ とする。ここで、行ベクトルが $e_i^t, i \in I_P$ から成る $n' \times n$ 行列を E とすれば、非負条件は $x' \equiv Ex \geq 0$ と書ける。Lagrange 関数を

$$L(w) = f(x) - y^t g(x) - z^t Ex$$

と定義したとき、Karush-Kuhn-Tucker(KKT) 条件は

$$r_0(w) = \begin{pmatrix} \nabla_x L(w) \\ g(x) \\ X^t z - \mu e \end{pmatrix} = 0, \quad x' \geq 0, z \geq 0,$$

で表される。ただし、 $w = (x, y, z)^t$ とし、 $y \in \mathbf{R}^m$ と $z \in \mathbf{R}^{n'}$ はそれぞれ等式制約条件と非負条件に関する Lagrange 乗数であり、また、 $A(x)$ をその行ベクトルが $\nabla g_i(x)^t$ からなる $m \times n$ 行列、 $X' = \text{diag}(x'_1, \dots, x'_{n'})$, $Z = \text{diag}(z_1, \dots, z_{n'})$, $e = (1, \dots, 1)^t \in \mathbf{R}^{n'}$ とする。

主双対内点法の多くは、バリエータパラメータ μ を導入して相補条件 ($XZe = 0$) を $XZe = \mu e$ に置き換えて得られるバリエータ KKT 条件にニュートン法を適用するものである。その際、直線探索法の枠組みで大域的収束性を実現するために、Yamashita(1992) が提案した l_1 型バリエータペナルティ関数が主変数 x に対するメリット関数としてよく使われている。本稿では、 l_2 型バリエータペナルティ関数を用いることを提案し、さらに主双対空間 (w の空間) におけるメリット関数を構築して大域的収束性を示す。そのために、バリエータ KKT 条件を変形したシフト付バリエータ KKT 条件を導入する。また、この解法の超 1 次収束性についても論じる。なお、詳細については Yamashita and Yabe[1] を参照されたい。

以下では、添字 k はアルゴリズムの外部反復や内部反復の反復回数を表し、 $\|\cdot\|$ は l_2 ベクトルノルムおよびそれから導かれる作用素ノルムを表す。また $S = \{x \in \mathbf{R}^n \mid x' > 0\}$, $\mathbf{R}_+^{n'} = \{z \in \mathbf{R}^{n'} \mid z > 0\}$ とおく。

2. シフト付バリエータ KKT 条件と主双対メリット関数

次の l_2 型バリエータペナルティ関数

$$F_0(x, \mu) = f(x) - \mu \sum_{i=1}^{n'} \log x'_i + \frac{1}{2\mu} \sum_{i=1}^m g_i(x)^2$$

の最小化問題を考える。この問題の 1 次の最適性条件は

$$\nabla f(x) - \mu E^t (X')^{-1} e + \frac{1}{\mu} \sum_{i=1}^m g_i(x) \nabla g_i(x) = 0, \quad x' > 0$$

である。ここで、 $y = -g(x)/\mu$, $z = \mu (X')^{-1} e$ とおけば次の条件を得る。ただし $x' > 0, z > 0$ である。

$$r(w, \mu) \equiv \begin{pmatrix} \nabla f(x) - A(x)^t y - E^t z \\ g(x) + \mu y \\ X^t Z e - \mu e \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix}$$

この条件は Forsgren and Gill(1998) によって扱われており、本稿ではシフト付バリエータ KKT(SBKKT) 条件と呼ぶ。従来のバリエータ KKT 条件と本質的に異なる点は、等式条件をシフトして得られた条件 $g(x) + \mu y = 0$ を含んでいることである。このことによって、等式制約条件の勾配ベクトルの 1 次独立性を仮定することなしに、与えられた $\mu > 0$ に対してヤコビ行列 $\nabla r(w, \mu)$ が正則になることが保証される。したがって、このシフトは方程式の安定化を担う役割をしているともみなせる。次に直線探索法で用いるメリット関数について考える。我々は、次の l_2 型主双対メリット関数を提案する (ただし $\rho > 0, \nu \in (0, 2)$)。

$$F(w, \mu) = F_0(x, \mu) + \rho \log \frac{\{(x')^t z\}^{\nu/n'} + \|g(x) + \mu y\|^2 + \|X^t z - \mu e\|^2}{\left(\prod_{i=1}^{n'} x'_i z_i\right)^{\nu/n'}}$$

3. アルゴリズムと大域的収束性

SBKKT 条件を用いた主双対内点法のアルゴリズムは以下の通りである。

[アルゴリズム IP]

Step 0. (初期設定) パラメータ $\varepsilon > 0, M_c > 0$ および、正の数列 $\{\mu_k\}, \mu_k \downarrow 0$ を与える。 $k = 0$ とおく。

Step 1. もし $\|r_0(w_k)\| \leq \varepsilon$ ならば停止する.

Step 2. 近似SBKKT条件 $\|r(w_{k+1}, \mu_k)\| \leq M_c \mu_k$ を満たす点 w_{k+1} を求める.

Step 3. $k := k + 1$ において Step 1 へ行く. \square

このアルゴリズムの Step 2 (近似SBKKT点の計算) の部分は、次のアルゴリズムとして記述出来る.

[アルゴリズムLS]

Step 0. (初期設定) $w_0 \in S \times \mathbf{R}^m \times \mathbf{R}_+^{n'}$, $\mu > 0$, $\rho > 0$, $\varepsilon' > 0$, $\gamma \in (0, 1)$, $\beta \in (0, 1)$, $\varepsilon_0 \in (0, 1)$ を与える. $k = 0$ とおく.

Step 1. もし $\|r(w_k, \mu)\| \leq \varepsilon'$ ならばアルゴリズムIPの外部反復に戻る.

Step 2. $J(w_k, G_k, \mu)\Delta w_k = -r(w_k, \mu)$ の解 Δw_k を探索方向に選ぶ. ただし

$$J(w_k, G_k, \mu) = \begin{pmatrix} G_k & -A(x_k)^t & -E^t \\ A(x_k) & \mu I & 0 \\ Z_k E & 0 & X_k' \end{pmatrix},$$

G_k はヘッセ行列 $\nabla_x^2 L(w_k)$ もしくはその近似行列である.

Step 3.

$$\alpha_{k\max} = \min \left\{ \min_i \left\{ -\frac{(x_k')_i}{(\Delta x_k')_i} \mid (\Delta x_k')_i < 0 \right\}, \min_i \left\{ -\frac{(z_k)_i}{(\Delta z_k)_i} \mid (\Delta z_k)_i < 0 \right\} \right\},$$

$$\bar{\alpha}_k = \min \{ \gamma \alpha_{k\max}, 1 \}$$

において、アルミホ基準 $(F(w_k + \bar{\alpha}_k \beta^{l_k} \Delta w_k, \mu) - F(w_k, \mu) \leq \varepsilon_0 \bar{\alpha}_k \beta^{l_k} \nabla F(w_k, \mu)^t \Delta w_k)$ を満足する最小の非負整数 l_k を求めて $\alpha_k = \bar{\alpha}_k \beta^{l_k}$ とおく.

Step 4. $w_{k+1} = w_k + \alpha_k \Delta w_k$, $k := k + 1$ において Step 1 へ行く. \square

大域的収束性示すために次の条件を仮定する.

(G1) f と g は 2 回連続的微分可能である.

(G2) 初期点における $F(w, \mu)$ の準位集合 $\{w \in S \times \mathbf{R}^m \times \mathbf{R}_+^{n'} \mid F(w, \mu) \leq F(w_0, \mu)\}$ はコンパクトである.

(G3) 行列 G_k は一様に正定値かつ有界である. \square

このとき、固定された $\mu > 0$ に対するアルゴリズムLSの大域的収束性が示せるので、したがって、アルゴリズムIPの大域的収束性が証明出来る.

4. 超1次収束性

本節ではSBKKT条件に基づいた次の主双対内点法の超1次収束性について議論する. このアルゴリズムでは、パラメータ μ_k , γ_k の調整が必要になる.

[アルゴリズムIPLocal]

Step 0. (初期設定) $w_0 \in S \times \mathbf{R}^m \times \mathbf{R}_+^{n'}$, $\mu_0 > 0$, $0 < \gamma_0 < 1$, $\varepsilon > 0$ を与える. $k = 0$ とおく.

Step 1. もし $\|r_0(w_k)\| \leq \varepsilon$ ならば停止する.

Step 2. パラメータ $\mu_k > 0$, $0 < \gamma_k < 1$ を選ぶ.

Step 3. $J(w_k, G_k, \mu_k)\Delta w_k = -r(w_k, \mu_k)$ の解 Δw_k を探索方向に選ぶ.

Step 4. アルゴリズムLSと同様に $\alpha_{k\max}$ を計算して $\alpha_k = \min \{ \gamma_k \alpha_{k\max}, 1 \}$ とおく.

Step 5. $w_{k+1} = w_k + \alpha_k \Delta w_k$, $k := k + 1$ において Step 1 へ行く. \square

このとき次の仮定をする.

(L1) 生成される点列 $\{w_k\}$ はもとの最適化問題のKKT点 $w^* = (x^*, y^*, z^*)^t$ に収束する.

(L2) f および g の 2 回偏導関数は x^* で Lipschitz 連続である.

(L3) w^* において正規条件, 2 次の十分条件, 狭義相補条件が成り立つ.

(L4) $\mu_k = \xi_k \|r_0(w_k)\|^{1+\tau_1}$, $1 - \gamma_k = \kappa \xi_k \|r_0(w_k)\|^{\tau_2}$ によって μ_k と γ_k が更新される. ただし, $\tau_1, \tau_2, \kappa, M'$ は $\min(1, \tau_2) > \tau_1$, $0 < \kappa < 1$, $\frac{1}{M'} \leq \xi_k \leq M'$ を満たす正の定数である.

(L5) 行列 G_k は, 各 k に対して $\|G_k - \nabla_x^2 L(w^*)\| < \delta$ ($\delta > 0$ は十分小), および, $\|(G_k - \nabla_x^2 L(w_k))\Delta x_k\| = O(\|\Delta w_k\|^{1+\tau_3})$ を満たす. ただし, τ_3 は $\tau_3 > \tau_1$ となる正定数である. \square

以上の仮定のもとで次の定理が得られる.

[定理1] M_c を $0 < M_c < \sqrt{n'}$ を満たす定数とするととき, 以下のことが成り立つ.

(1) もし点 $\hat{w} = (\hat{x}, \hat{y}, \hat{z})^t \in S \times \mathbf{R}^m \times \mathbf{R}_+^{n'}$ が $\|r(\hat{w}, \mu_k)\| \leq M_c \mu_k$ を満たすならば,

$$\nu_1 \|r_0(w_k)\|^{1+\tau_1} \leq \|r_0(\hat{w})\| \leq \nu_2 \|r_0(w_k)\|^{1+\tau_1}$$

が成り立つ. ただし, ν_1 と ν_2 は正定数である.

(2) $\|r(w_k, \mu_{k-1})\| \leq M_c \mu_{k-1}$ ならば, $\alpha_k = 1$ となる.

(3) $\|r(w_k + \Delta w_k, \mu_k)\| \leq M_c \mu_k$ が成り立つ. \square

この定理は、もし w_k が μ_{k-1} に対する近似SBKKT条件を満たすならば、(2)と(3)より $\alpha_k = 1$ が採用されて $w_k + \Delta w_k$ が μ_k に対する近似SBKKT条件を満足することを示している. したがって、(1)よりアルゴリズムIPLocalの超1次収束性が得られる.

参考文献

[1] H. Yamashita and H. Yabe, *An interior point method with a primal-dual l_2 barrier penalty function for nonlinear optimization* Technical Report, Mathematical Systems, Inc., Tokyo, Japan, March 1999.