

計画数理学特論

～第13回：その他の最適化手法② 逐次2次計画法～

担当：蓮池隆（経営システム工学科）

e-mail: thasuike@waseda.jp

計画数理学特論

～第13回：その他の最適化手法② 逐次2次計画法～

担当：蓮池隆（経営システム工学科）

e-mail: thasuike@waseda.jp

今回の講義：逐次2次計画法

- 一般的な制約付きの最適化問題(

$$\begin{aligned} & \min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}) \\ & \text{subject to } g_i(\mathbf{x}) \leq 0, i = 1, 2, \dots, m \\ & \quad \quad \quad g_i(\mathbf{x}) = 0, i = m + 1, \dots, p \end{aligned}$$

- 議論をわかりやすくするため, まずは等式制約のみの最適化問題で議論する.
($f(\mathbf{x}), g_i(\mathbf{x})$ は2回連続微分可能)

$$\begin{aligned} & \min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}) \\ & \text{subject to } g_i(\mathbf{x}) = 0, i = 1, 2, \dots, p \end{aligned}$$

- この問題に対して, **凸2次計画問題を繰り返して解き**, 解を更新しながら最適解を求めていく方法が**逐次2次計画法**

(参考)ニュートン法

- 制約なし最適化問題 : $\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$ を直線探索による反復法で解く
(直線探索)
 - 現在の点 : $\mathbf{x}_k \in \mathbb{R}^n$
 - 探索方向 : \mathbf{d}_k (ただし, $\nabla f(\mathbf{x}_k)^t \mathbf{d}_k < 0$ となるように選ぶと, \mathbf{d}_k は降下方向)
 - (アルミホ条件やウルフ条件などから求めた)ステップ幅 : $\alpha_k > 0$
 - 以上を用いて, $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{d}_k$ として次の点を設定する.

(参考)ニュートン法

・ 制約なし最適化問題 : $\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$ を直線探索による反復法で解く
(直線探索による反復法)

STEP0 : 初期点 : $\mathbf{x}_0 \in \mathbb{R}^n$ を設定し, $k \leftarrow 0$ とする.

STEP1 : 停止条件が満たされるならば, \mathbf{x}_k を解として出力し, 終了.

STEP2 : 降下方向として \mathbf{d}_k を設定.

STEP3 : $\phi(\alpha) = f(\mathbf{x}_k + \alpha \mathbf{d}_k)$, $\alpha \geq 0$ に対する直線探索により, ステップ幅 α_k を計算.

STEP4 : $\mathbf{x}_{k+1} \leftarrow \mathbf{x}_k + \alpha_k \mathbf{d}_k$ と更新.

STEP5 : $k \leftarrow k + 1$ として, STEP1へ戻る.

(参考)ニュートン法

- 制約なし最適化問題 : $\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$ を直線探索による反復法で解く
- 最急降下法 : $\mathbf{d}_k = -\nabla f(\mathbf{x}_k)$ とした場合の反復法
- **ニュートン法** : ヘッセ行列 $\nabla^2 f(\mathbf{x}_k)$ が正定値行列と仮定して,
$$\mathbf{d}_k = -(\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k), \alpha_k = 1$$
 とした場合の反復法

(ニュートン法のメリット)

- 局所最適解 \mathbf{x}^* の近傍から反復法を始めた場合, 局所最適解に2次収束する
(つまり, かなり高速に局所最適解を得ることができる)

→ このニュートン法を制約付き最適化問題へ応用する

1次の必要条件

- 等式制約のみの最適化問題

$$\begin{aligned} & \min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}) \\ & \text{subject to } g_i(\mathbf{x}) = 0, i = 1, 2, \dots, p \end{aligned}$$

- 1次の必要条件

$$\begin{aligned} \nabla f(\mathbf{x}^*) + \sum \lambda_i^* \nabla g_i(\mathbf{x}^*) &= \mathbf{0} \\ g_i(\mathbf{x}^*) &= 0, i = 1, \dots, p \end{aligned}$$

反復法による点列生成

- 現在の点： $(\mathbf{x}^{(k)}, \lambda^{(k)})$
- $(\mathbf{x}^{(k+1)}, \lambda^{(k+1)}) = (\mathbf{x}^{(k)} + \Delta\mathbf{x}, \lambda^{(k)} + \Delta\lambda)$
 $\rightarrow \begin{cases} \nabla f(\mathbf{x}^{(k)} + \Delta\mathbf{x}) = \nabla f(\mathbf{x}^{(k)}) + \nabla^2 f(\mathbf{x}^{(k)})\Delta\mathbf{x} \\ g_i(\mathbf{x}^{(k)} + \Delta\mathbf{x}) = g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)})\Delta\mathbf{x} \\ \nabla g_i(\mathbf{x}^{(k)} + \Delta\mathbf{x}) = \nabla g_i(\mathbf{x}^{(k)}) + \nabla^2 g_i(\mathbf{x}^{(k)})\Delta\mathbf{x} \end{cases}$
- これらの式を先ほどの1次の必要条件で $\mathbf{x}^* = \mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \Delta\mathbf{x}$,
 $\lambda^* = \lambda^{(k+1)} = \lambda^{(k)} + \Delta\lambda$ として代入すると…

1次の必要条件

- 等式制約のみの最適化問題

$$\begin{aligned} & \min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}) \\ & \text{subject to } g_i(\mathbf{x}) = 0, i = 1, 2, \dots, p \end{aligned}$$

- 1次の必要条件

$$\begin{aligned} & \nabla f(\mathbf{x}^{(k)}) + \left(\nabla^2 f(\mathbf{x}^{(k)}) + \sum \lambda_i^{(k)} \nabla^2 g_i(\mathbf{x}^{(k)}) \right) \Delta \mathbf{x} + \sum \left(\lambda_i^{(k)} \nabla g_i(\mathbf{x}^{(k)}) \right) \\ & = \nabla f(\mathbf{x}^{(k)}) + \nabla_{\mathbf{x}\mathbf{x}}^2 L(\mathbf{x}^{(k)}, \boldsymbol{\lambda}^{(k)}) \Delta \mathbf{x} + \sum \left(\lambda_i^{(k)} \nabla g_i(\mathbf{x}^{(k)}) \right) = \mathbf{0} \end{aligned}$$

$$g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)}) \Delta \mathbf{x} = 0, i = 1, 2, \dots, p$$

2次計画問題の導入

- 等式制約のみの最適化問題

$$\begin{aligned} \min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}) \\ \text{subject to } g_i(\mathbf{x}) = 0, i = 1, 2, \dots, p \end{aligned}$$

に対して, 以下の2次計画問題を考える(先ほどのテイラー展開の $\Delta \mathbf{x}$ を \mathbf{d} として代入したものとみなせる(ヘッセ行列の部分だけ異なる))

$$\begin{aligned} \min_{\mathbf{d} \in \mathbb{R}^n} \quad & \frac{1}{2} \mathbf{d}^t \nabla_{\mathbf{x}\mathbf{x}}^2 L(\mathbf{x}^{(k)}, \boldsymbol{\lambda}^{(k)}) \mathbf{d} + \nabla f(\mathbf{x}^{(k)})^t \mathbf{d} \\ \text{subject to} \quad & g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)})^t \mathbf{d} = 0, i = 1, 2, \dots, p \end{aligned}$$

2次計画問題の1次の必要条件

- 2次計画問題

$$\begin{aligned} \min_{\mathbf{d} \in \mathbb{R}^n} \quad & \frac{1}{2} \mathbf{d}^t \nabla_{\mathbf{x}\mathbf{x}}^2 L(\mathbf{x}^{(k)}, \boldsymbol{\lambda}^{(k)}) \mathbf{d} + \nabla f(\mathbf{x}^{(k)})^t \mathbf{d} \\ \text{subject to} \quad & g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)})^t \mathbf{d} = 0, i = 1, 2, \dots, p \end{aligned}$$

- 1次の必要条件

$$\begin{aligned} \nabla_{\mathbf{x}\mathbf{x}}^2 L(\mathbf{x}^{(k)}, \boldsymbol{\lambda}^{(k)}) \mathbf{d} + \nabla f(\mathbf{x}^{(k)}) + \sum (v_i \nabla g_i(\mathbf{x}^{(k)})) &= \mathbf{0} \\ g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)})^t \mathbf{d} &= 0, i = 1, 2, \dots, p \end{aligned}$$

→ $\mathbf{d} = \Delta \mathbf{x}$, $v_i = \lambda_i^{(k)}$ とおけば, 元々の1次の必要条件と同じ.

つまり, 上記の2次計画問題を解けば元の最適化問題を解くことになる.

不等式制約の場合の2次計画問題

- 不等式制約付きの最適化問題

$$\begin{aligned} \min_{\mathbf{x} \in \mathbb{R}^n} & f(\mathbf{x}) \\ \text{subject to} & g_i(\mathbf{x}) \leq 0, i = 1, 2, \dots, p \end{aligned}$$

- 先ほどと同様に2次計画問題を導入

$$\begin{aligned} \min_{\mathbf{d} \in \mathbb{R}^n} & \frac{1}{2} \mathbf{d}^t \nabla_{\mathbf{x}\mathbf{x}}^2 L(\mathbf{x}^{(k)}, \boldsymbol{\lambda}^{(k)}) \mathbf{d} + \nabla f(\mathbf{x}^{(k)})^t \mathbf{d} \\ \text{subject to} & g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)})^t \mathbf{d} \leq 0, i = 1, 2, \dots, p \end{aligned}$$

→ $\nabla_{\mathbf{x}\mathbf{x}}^2 L(\mathbf{x}^{(k)}, \boldsymbol{\lambda}^{(k)})$ が正定値行列であれば, 内点法などで効率的に解ける

正定値行列でない場合: $\nabla_{\mathbf{x}\mathbf{x}}^2 L(\mathbf{x}^{(k)}, \boldsymbol{\lambda}^{(k)})$ を正定値対称行列 B_k で置き換える

KKT条件

- B_k で置き換えた2次計画問題(=凸2次計画問題)を導入

$$\begin{aligned} \min_{\mathbf{d} \in \mathbb{R}^n} \quad & \frac{1}{2} \mathbf{d}^t B_k \mathbf{d} + \nabla f(\mathbf{x}^{(k)})^t \mathbf{d} \\ \text{subject to} \quad & g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)})^t \mathbf{d} \leq 0, i = 1, 2, \dots, p \end{aligned}$$

- KKT条件

$$B_k \mathbf{d} + \nabla f(\mathbf{x}^{(k)}) + \sum \left(v_i \nabla g_i(\mathbf{x}^{(k)}) \right) = \mathbf{0}$$

$$\begin{aligned} g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)})^t \mathbf{d} &\leq 0, i = 1, 2, \dots, p \\ v_i \geq 0, \quad v_i \left(g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)})^t \mathbf{d} \right) &= 0 \end{aligned}$$

KKT条件の分析

- KKT条件

$$B_k \mathbf{d} + \nabla f(\mathbf{x}^{(k)}) + \sum (v_i \nabla g_i(\mathbf{x}^{(k)})) = \mathbf{0}$$

$$g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)}) \mathbf{d} \leq 0, i = 1, 2, \dots, p$$

$$v_i \geq 0, \quad v_i (g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)})^t \mathbf{d}) = 0$$

- $\mathbf{d} = \mathbf{0}$ ならば, $\mathbf{x}^{(k)}$ は元の不等式制約付き最適化問題のKKT条件となる
- $\mathbf{d} \neq \mathbf{0}$ ならば, 以下の関数(メリット関数)に対して, 直線探索を適用する

$$f(\mathbf{x}) + \rho \sum \max\{g_i(\mathbf{x}), 0\}$$

KKT条件の分析

- KKT条件

$$B_k \mathbf{d} + \nabla f(\mathbf{x}^{(k)}) + \sum (v_i \nabla g_i(\mathbf{x}^{(k)})) = \mathbf{0}$$

$$g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)}) \mathbf{d} \leq 0, i = 1, 2, \dots, p$$

$$v_i \geq 0, \quad v_i (g_i(\mathbf{x}^{(k)}) + \nabla g_i(\mathbf{x}^{(k)})^t \mathbf{d}) = 0$$

- 正定値対称行列 B_k の更新

→ パウエルの修正BFGS公式などを適用(詳しくは, 各自で調べておくこと)

逐次2次計画法のアルゴリズム

STEP1 : 初期点 $\mathbf{x}^{(0)}$ および初期の近似行列 B_0 を定め, $k = 0$ とする.

STEP2 : 凸2次計画問題を解いて, 探索方向 \mathbf{d} とラグランジュ乗数 $\lambda^{(k+1)}$ を求める.

STEP3 : ベクトル \mathbf{d} の大きさ $\|\mathbf{d}\|$ が十分に小さい場合, アルゴリズムを終了.

STEP4 : メリット関数に対して直線探索によりステップ幅 α_k を求める.

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha_k \mathbf{d} \text{とする.}$$

STEP5 : 近似行列 B_k を更新し, 新たな近似行列 B_{k+1} を生成する.

$k = k + 1$ としてSTEP2へ戻る.

今回のまとめ

- 逐次2次計画法について、アルゴリズムも含めて解説
- 前回の内点法と同様に、逐次2次計画法も非常に有用な手法であり、適用範囲もかなり広い
- これまでの手法も含めて、基本的に非線形のままでは解きにくいいため、テイラー展開による近似、直線探索、反復法をうまく組み合わせた手法が構築されている