

学習用テキスト 非線形計画法 (3)

非線形計画問題

水野 眞治

東京工業大学 大学院社会理工学研究科 経営工学専攻

http://www.me.titech.ac.jp/~mizu_lab/text/

2013 年 2 月 9 日

概要

ここでは、非線形計画問題を扱う。まず、制約のない 1 変数関数の最小化、多変数関数の最小化について、最適解であるための必要条件と十分条件を述べ、実際に最小解を求めるためのアルゴリズムについても紹介する。その後、等式制約のみの非線形計画問題、不等式制約のみの非線形計画問題、一般の非線形計画問題の最適条件等について説明する。

目次

1	非線形計画問題 (Nonlinear Programming Problem)	1
1.1	1 変数関数の最小化	1
1.2	1 変数関数最小化問題に対するニュートン法 (Newton's Method)	4
1.3	多変数関数の最小化	5
1.4	最急降下法	8
1.5	多変数関数最小化問題に対するニュートン法 (Newton's Method)	10
1.6	等式制約のみの非線形計画問題	11
1.7	不等式制約のみの非線形計画問題	11
1.8	一般の非線形計画問題	15
1.9	演習問題の略解	16

1 非線形計画問題 (Nonlinear Programming Problem)

1.1 1 変数関数の最小化

1 変数関数の最小化とは、関数 $f: \mathcal{R} \rightarrow \mathcal{R}$ が与えられたとき、任意の実数 $x \in \mathcal{R}$ に対して

$$f(x^*) \leq f(x)$$

を満たす $x^* \in \mathcal{R}$ を求める問題である。この 1 変数最小化問題を

$$\min_x f(x) \quad (1)$$

と表す。また、解 x^* を関数 f (あるいは最小化問題) の大域的最小解または大域的最適解 (global optimal solution) という。

ある $\epsilon > 0$ が存在し、 $|x - x^*| < \epsilon$ をみたす任意の x に対して

$$f(x^*) \leq f(x)$$

を満たすとき、この x^* を関数 f (最小化問題) の局所的最小解または局所的最適解 (local optimal solution) という。

関数 f は

$$x, y \in \mathcal{R}, \alpha \in [0, 1] \Rightarrow f(\alpha x + (1 - \alpha)y) \leq \alpha f(x) + (1 - \alpha)f(y).$$

を満たすとき、凸関数と呼ばれる。関数 f が凸関数ならば、任意の局所的最適解は大域的最適解となる。

f が連続微分可能で、その導関数を f' とするとき、 x^* が問題 (1) の局所的最適解ならば

$$f'(x^*) = 0 \quad (2)$$

が成立する。この条件 (2) を、 x^* が局所的最適解であるための 1 次の必要条件 (first-order necessary condition) という。 f が凸関数ならば、条件 (2) は、 x^* が局所的最適解であるための必要十分条件となる。

f が 2 回連続微分可能で、その 2 階の導関数を f'' とするとき、 x^* が問題 (1) の局所的最適解ならば

$$f'(x^*) = 0, f''(x^*) \geq 0 \quad (3)$$

が成立する。この条件 (3) を、 x^* が局所的最適解であるための 2 次の必要条件 (second-order necessary condition) という。逆に、 x^* において

$$f'(x^*) = 0, f''(x^*) > 0 \quad (4)$$

が成立するならば、 x^* は問題 (1) の局所的最適解となる。この条件 (4) を、 x^* が局所的最適解であるための 2 次の十分条件 (second-order sufficient condition) という。

例 1.1 1 変数関数 f を任意の $x \in \mathcal{R}$ に対して

$$f(x) = 3x^4 - 4x^3 - 12x^2 + 32$$

とする. x が局所的最小解ならば

$$f'(x) = 12x^3 - 12x^2 - 24x = 12x(x - 2)(x + 1) = 0$$

となるので, $x = -1, 0, 2$ がその候補である. このとき

$$f''(x) = 36x^2 - 24x - 24$$

より

$$f''(-1) = 36, f''(0) = -24, f''(2) = 72$$

となるので, $x = -1, 2$ が 2 次の十分条件を満たすので, 局所的最小解である. この関数のグラフは, 図 1 のようにあらわすことができる. これをみると, $x = 2$ が大域的最小解となっており, $x = -1$ は大域的最小解ではない.

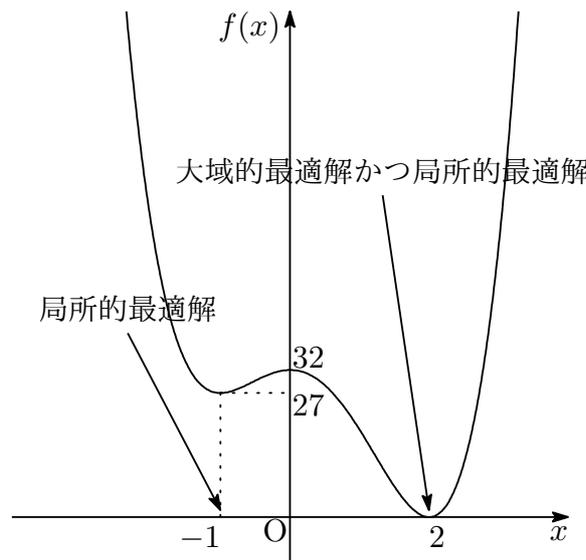


図 1 大域的最適解と局所的最適解

演習問題 1.2 次の関数の局所的最小解であるための 1 次の必要条件をみたす解 x をすべて求め, それらの解が, 2 次の必要条件および 2 次の十分条件をみたすかどうか調べよ.

(1) $f(x) = 2x^3 - 9x^2 + 12x - 2$

(2) $f(x) = 3x^4 + 4x^3 - 6x^2 - 12x - 4$

1.2 1変数関数最小化問題に対するニュートン法 (Newton's Method)

関数 $f: \mathcal{R} \rightarrow \mathcal{R}$ が2回連続微分可能なとき、次の最小化問題

$$\min_x f(x)$$

を解くためのニュートン法について解説する。

ニュートン法は、初期点 x^0 より数列 (点列) $\{x^k | k = 0, 1, \dots\}$ を生成する反復法である。この数列の第 k 項を点 x^k と呼ぶこともある。第 k 反復で得られた点を x^k とするとき、関数 f を x^k において2次近似した関数を

$$g(x) = f(x^k) + f'(x^k)(x - x^k) + \frac{1}{2}f''(x^k)(x - x^k)^2$$

とする。2階の微係数 $f''(x^k)$ が正であると仮定すれば、関数 g は凸2次関数となり、その最小値は

$$g'(x) = f'(x^k) + f''(x^k)(x - x^k) = 0$$

をみたく x^* において達成される。この解は

$$x^* = x^k - \frac{f'(x^k)}{f''(x^k)}$$

と表される。この x^* を次の点 x^{k+1} として、上記の操作を繰り返すことにより、点列 $\{x^k\}$ を生成するのが、ニュートン法である。

例 1.3 1変数関数 f を任意の $x \in \mathcal{R}$ に対して

$$f(x) = 3x^4 - 4x^3 - 12x^2 + 32$$

とし、初期点を $x^0 = 4$ とする。このとき、 $f(4) = 352$ 、 $f'(4) = 480$ 、 $f''(4) = 456$ であり、関数 f を x^0 において2次近似した関数は

$$g(x) = 352 + 480(x - 4) + 228(x - 4)^2$$

となり、 $g'(x^*) = 0$ の解は

$$x^* = 4 - \frac{480}{456} = 2\frac{54}{57}$$

となる。

演習問題 1.4 次の関数

$$f(x) = 2x^3 - 9x^2 + 12x - 3$$

に初期点 $x^0 = 3$ からニュートン法を適用したとき、1反復後の点を計算せよ。

1.3 多変数関数の最小化

多変数関数の最小化とは、関数 $f: \mathcal{R}^n \rightarrow \mathcal{R}$ が与えられたとき、任意の点 $\mathbf{x} \in \mathcal{R}^n$ に対し

$$f(\mathbf{x}^*) \leq f(\mathbf{x})$$

となる $\mathbf{x}^* \in \mathcal{R}^n$ を求める問題である。この最小化問題を

$$\min_{\mathbf{x}} f(\mathbf{x})$$

と表す。この解 \mathbf{x}^* を関数 f (最小化問題) の大域的最小解 (最適解) という。

ある $\epsilon > 0$ が存在し、 $\|\mathbf{x} - \mathbf{x}^*\| < \epsilon$ をみたす任意の $\mathbf{x} \in \mathcal{R}^n$ に対して

$$f(\mathbf{x}^*) \leq f(\mathbf{x})$$

をみたすとき、この点 \mathbf{x}^* を関数 f (最小化問題) の局所的最小解 (最適解) という。

関数 f は

$$\mathbf{x}, \mathbf{y} \in \mathcal{R}^n, \alpha \in [0, 1] \Rightarrow f(\alpha\mathbf{x} + (1 - \alpha)\mathbf{y}) \leq \alpha f(\mathbf{x}) + (1 - \alpha)f(\mathbf{y})$$

を満たすとき、凸関数と呼ばれる。関数 f が凸関数ならば、任意の局所的最適解は大域的最適解となる。

関数 f が連続微分可能であるとする。点 \mathbf{x} における偏導関数 $\frac{\partial f}{\partial x_i}$ の値を第 i 要素とする n 次元ベクトル

$$\nabla f(\mathbf{x}) = \begin{pmatrix} \frac{\partial f(\mathbf{x})}{\partial x_1} \\ \frac{\partial f(\mathbf{x})}{\partial x_2} \\ \vdots \\ \frac{\partial f(\mathbf{x})}{\partial x_n} \end{pmatrix}$$

を f の勾配ベクトル (gradient vector) という。

定理 1.5 点 \mathbf{x}^* が関数 f の局所的最適解ならば

$$\nabla f(\mathbf{x}^*) = \mathbf{0} \tag{5}$$

が成立する。

証明 点 \mathbf{x}^* が関数 f の局所的最適解であるが、 $\nabla f(\mathbf{x}^*) \neq \mathbf{0}$ であると仮定し、矛盾を導く。このとき

$$\mathbf{d} = -\frac{\nabla f(\mathbf{x}^*)}{\|\nabla f(\mathbf{x}^*)\|}$$

とすれば、 $\nabla f(\mathbf{x}^*)^T \mathbf{d} < 0$ である。平均値の定理より、任意の $\epsilon > 0$ に対して、ある $\theta \in [0, 1]$ が存在し

$$f(\mathbf{x}^* + \epsilon \mathbf{d}) = f(\mathbf{x}^*) + \epsilon \nabla f(\mathbf{x}^* + \theta \epsilon \mathbf{d})^T \mathbf{d}$$

が成立する。 ∇f の連続性より、十分小さな $\epsilon > 0$ に対し $\nabla f(\mathbf{x}^* + \theta \epsilon \mathbf{d})^T \mathbf{d} < 0$ となる。このとき、 $f(\mathbf{x}^* + \epsilon \mathbf{d}) < f(\mathbf{x}^*)$ となり、点 \mathbf{x}^* が関数 f の局所的最適解であることに矛盾する。■

上の定理の式 (5) を \mathbf{x}^* が関数 f の局所的最適解であるための 1 次の必要条件という。関数 f が凸関数ならば、必要十分条件となる。一般に、 $\nabla f(\mathbf{x}) = 0$ をみたす点 \mathbf{x} を関数 f の停留点 (stationary point) という。

関数 f が 2 回連続微分可能であるとする。点 \mathbf{x} における 2 階の偏導関数 $\frac{\partial^2 f}{\partial x_i \partial x_j}$ の値を i 行 j 列成分とする $n \times n$ 行列

$$\nabla^2 f(\mathbf{x}) = \begin{pmatrix} \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_n} \end{pmatrix}$$

をヘッセ行列 (Hessian matrix) という。

定理 1.6 点 \mathbf{x}^* が関数 f の局所的最適解ならば

$$\nabla f(\mathbf{x}^*) = \mathbf{0} \text{ かつ } \nabla^2 f(\mathbf{x}^*) \text{ が半正定値行列} \tag{6}$$

が成立する。ここで、半正定値行列 \mathbf{M} とは、任意のベクトル $\mathbf{x} \in \mathcal{R}^n$ に対して、 $\mathbf{x}^T \mathbf{M} \mathbf{x} \geq 0$ となる行列のことである。

証明 点 \mathbf{x}^* が関数 f の局所的最適解であるとき、定理 1.5 より $\nabla f(\mathbf{x}^*) = \mathbf{0}$ であるので、 $\nabla^2 f(\mathbf{x}^*)$ が半正定値でないと仮定し、矛盾を導く。このとき、大きさ 1 のあるベクトル \mathbf{d} に対して

$$\mathbf{d}^T \nabla^2 f(\mathbf{x}^*) \mathbf{d} < 0$$

となる。関数 $\nabla^2 f$ の連続性より、十分小さな $\bar{\alpha} > 0$ に対し

$$\mathbf{d}^T \nabla^2 f(\mathbf{x}^* + \alpha \mathbf{d}) \mathbf{d} < 0, \forall \alpha \in [0, \bar{\alpha}]$$

となる。一方、平均値の定理より、任意の $\epsilon > 0$ に対して、ある $\theta \in [0, 1]$ が存在し

$$f(\mathbf{x}^* + \epsilon \mathbf{d}) = f(\mathbf{x}^*) + \epsilon \nabla f(\mathbf{x}^*)^T \mathbf{d} + \frac{1}{2} \epsilon^2 \mathbf{d}^T \nabla^2 f(\mathbf{x}^* + \theta \epsilon \mathbf{d}) \mathbf{d}$$

が成立する．ここで，右辺の第 2 項は 0 であり， $\epsilon \leq \bar{\alpha}$ ならば第 3 項が負となるので， $f(\mathbf{x}^* + \epsilon \mathbf{d}) < f(\mathbf{x}^*)$ が成立し，点 \mathbf{x}^* が関数 f の局所的最適解であることに矛盾する．■

上の定理にある条件 (6) を \mathbf{x}^* が関数 f の局所的最適解であるための 2 次の必要条件という．

定理 1.7 関数 f が 2 回連続微分可能であり，条件

$$\nabla f(\mathbf{x}^*) = \mathbf{0} \text{ かつ } \nabla^2 f(\mathbf{x}^*) \text{ が正定値行列} \tag{7}$$

が成り立つならば， \mathbf{x}^* は関数 f の局所的最適解である．ここで，正定値行列 \mathbf{M} とは，任意のゼロベクトルでない $\mathbf{x} \in \mathcal{R}^n$ に対して， $\mathbf{x}^T \mathbf{M} \mathbf{x} > 0$ となる行列のことである．

証明 点 \mathbf{x}^* で条件 (7) が成り立つとする．このとき，関数 $\nabla^2 f$ の連続性より，ある $\bar{\alpha} > 0$ が存在し，大きさ 1 の任意のベクトル \mathbf{d} に対し

$$\mathbf{d}^T \nabla^2 f(\mathbf{x}^* + \alpha \mathbf{d}) \mathbf{d} > 0, \forall \alpha \in [0, \bar{\alpha}]$$

が成立する．平均値の定理より，任意の $\epsilon \in (0, \bar{\alpha}]$ に対して，ある $\theta \in [0, 1]$ が存在し

$$f(\mathbf{x}^* + \epsilon \mathbf{d}) = f(\mathbf{x}^*) + \epsilon \nabla f(\mathbf{x}^*)^T \mathbf{d} + \frac{1}{2} \epsilon^2 \mathbf{d}^T \nabla^2 f(\mathbf{x}^* + \theta \epsilon \mathbf{d}) \mathbf{d} > f(\mathbf{x}^*)$$

が成立する．これより， \mathbf{x}^* は，関数 f の局所的最適解である．■

上の定理の条件 (7) を \mathbf{x}^* が関数 f の局所的最適解であるための 2 次の十分条件という．

例 1.8 2 変数関数 f を任意の $(x_1, x_2)^T \in \mathcal{R}^2$ に対して

$$f(x_1, x_2) = x_1^2 - 2x_1x_2 + 2x_2^2 - 4x_1 + 2x_2 + 3$$

とする．このとき，

$$\nabla f(x_1, x_2) = \begin{pmatrix} 2x_1 - 2x_2 - 4 \\ -2x_1 + 4x_2 + 2 \end{pmatrix}$$

かつ

$$\nabla^2 f(x_1, x_2) = \begin{pmatrix} 2 & -2 \\ -2 & 4 \end{pmatrix}$$

となる．このとき，最小解であるための一次の必要条件は

$$\begin{aligned} 2x_1 - 2x_2 &= 4 \\ -2x_1 + 4x_2 &= -2 \end{aligned}$$

となるので, $(x_1, x_2) = (3, 1)$ が得られる. この点 (この場合, 任意の点) において, ヘッセ行列 $\nabla^2 f(x_1, x_2)$ が正定値となるので, 2 次の必要条件と十分条件を満たす. したがって, $(x_1, x_2) = (3, 1)$ は f の局所的最適解であり, そのときに最小値 -2 をとる. この場合, f が凸関数であるので, これは大域的最適解でもある.

演習問題 1.9 次の 2 変数関数

$$f(x_1, x_2) = x_1^3 + 2x_1x_2 + x_2^2 + x_1 + 2x_2$$

の局所的最小解であるための 1 次の必要条件をみたす点 $(x_1, x_2)^T$ をすべて求め, それらの点 (x_1, x_2) が, 2 次の必要条件および 2 次の十分条件をみたすかどうか調べよ.

1.4 最急降下法

関数 $f: \mathcal{R}^n \rightarrow \mathcal{R}$ が 2 回連続微分可能なとき, 次の最小化問題

$$\min_{\mathbf{x}} f(\mathbf{x})$$

を考える. この問題に対する最急降下法は, 反復解法であり, 初期点 \mathbf{x}^0 より点列 $\{\mathbf{x}^k | k = 0, 1, \dots\}$ を生成する.

第 k 反復で点 \mathbf{x}^k が求められているとし, 次の点の求め方を説明する. 勾配ベクトル $\nabla f(\mathbf{x}^k)$ は, この点における関数 f の増加方向であるから, その逆方向へ進むことにより, 関数 f の値を減少させることができる. ステップサイズを α とし, 次の点を

$$\mathbf{x}^{k+1} = \mathbf{x}^k - \alpha \nabla f(\mathbf{x}^k)$$

とする. ステップサイズ α は, 問題

$$\min_{\alpha} f(\mathbf{x}^k - \alpha \nabla f(\mathbf{x}^k))$$

を解くことにより求めることができる. 上記の問題は, 1 変数 α に関する最小化問題であるので, 直線探索 (1 変数関数の最小化, 1 次元探索, line search) により近似解を求めることができる.

アルゴリズム 1.10 最急降下法のアルゴリズムは, 次のステップからなる.

ステップ 0 初期点 \mathbf{x}^0 を選び, 十分小さな正の数 ϵ を定め, $k = 0$ とする.

ステップ 1 $\|\nabla f(\mathbf{x}^k)\| \leq \epsilon$ ならばストップし, \mathbf{x}^k を近似解とする. さもないと問題

$$\min_{\alpha} f(\mathbf{x}^k - \alpha \nabla f(\mathbf{x}^k))$$

の (近似) 解 α^* を求める.

ステップ 2 $\mathbf{x}^{k+1} = \mathbf{x}^k - \alpha^* \nabla f(\mathbf{x}^k)$ とし, k を 1 増加しステップ 1 へ戻る.

上の最急降下法のアルゴリズムにおいて, $\epsilon = 0$ とすれば, 生成される点列が有界ならば, その点列の集積点 \mathbf{x}^* は関数 f の停留点となる ($\nabla f(\mathbf{x}^*) = 0$ となる) ことが知られている.

例 1.11 2 変数関数を

$$f(x_1, x_2) = x_1^2 - 2x_1x_2 + 2x_2^2 - 4x_1 + 2x_2 + 3$$

とし, 初期点を $(x_1, x_2) = (0, 0)$ とするとき, 最急降下法による次の点 (x_1^1, x_2^1) を求めてみる. 勾配ベクトルは,

$$\nabla f(x_1, x_2) = \begin{pmatrix} 2x_1 - 2x_2 - 4 \\ -2x_1 + 4x_2 + 2 \end{pmatrix}$$

より

$$\nabla f(0, 0) = \begin{pmatrix} -4 \\ 2 \end{pmatrix}$$

となる. ステップサイズを α とすれば

$$\begin{pmatrix} x_1^1 \\ x_2^1 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} - \alpha \begin{pmatrix} -4 \\ 2 \end{pmatrix} = \begin{pmatrix} 4\alpha \\ -2\alpha \end{pmatrix}$$

となる. これより

$$f(x_1^1, x_2^1) = 16\alpha^2 + 16\alpha^2 + 8\alpha^2 - 16\alpha - 4\alpha + 3 = 40\alpha^2 - 20\alpha + 3$$

となる. この関数 $f(x_1^1, x_2^1)$ は, $\alpha = 1/4$ のときに最小値 $1/2$ をとる. $\alpha = 1/4$ であるから,

$$\begin{pmatrix} x_1^1 \\ x_2^1 \end{pmatrix} = \begin{pmatrix} 1 \\ -\frac{1}{2} \end{pmatrix}$$

が得られる.

演習問題 1.12 $(x_1^1, x_2^1) = (1, -\frac{1}{2})$ から, 関数 $f(x_1, x_2) = x_1^2 - 2x_1x_2 + 2x_2^2 - 4x_1 + 2x_2 + 3$ に最急降下法を適用したときの, 次の点 (x_1^2, x_2^2) を計算せよ.

1.5 多変数関数最小化問題に対するニュートン法 (Newton's Method)

写像 $f: \mathcal{R}^n \rightarrow \mathcal{R}$ が2回連続微分可能なとき、次の最小化問題

$$\min_{\mathbf{x}} f(\mathbf{x})$$

を考える。関数 f を点 \mathbf{x}^k において2次近似した関数を

$$g(\mathbf{x}) = f(\mathbf{x}^k) + \nabla f(\mathbf{x}^k)^T (\mathbf{x} - \mathbf{x}^k) + \frac{1}{2} (\mathbf{x} - \mathbf{x}^k)^T \nabla^2 f(\mathbf{x}^k) (\mathbf{x} - \mathbf{x}^k)$$

とする。ヘッセ行列 $\nabla^2 f(\mathbf{x}^k)$ が正定値であると仮定すれば、 g は凸2次関数となり、その最小値は

$$\nabla g(\mathbf{x}) = \nabla f(\mathbf{x}^k) + \nabla^2 f(\mathbf{x}^k) (\mathbf{x} - \mathbf{x}^k) = 0$$

をみたす点 $\hat{\mathbf{x}}$ において達成される。この解は

$$\hat{\mathbf{x}} - \mathbf{x}^k = -\nabla^2 f(\mathbf{x}^k)^{-1} \nabla f(\mathbf{x}^k)$$

と表される。 $\mathbf{d} = \hat{\mathbf{x}} - \mathbf{x}^k = -\nabla^2 f(\mathbf{x}^k)^{-1} \nabla f(\mathbf{x}^k)$ を探索方向とし、ステップ幅を α とし、問題

$$\min_{\alpha} f(\mathbf{x}^k + \alpha \mathbf{d})$$

を解き、その解 α^* に対して、次の点 $\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha^* \mathbf{d}$ を求める。

アルゴリズム 1.13 ニュートン法のアルゴリズムは、次のステップからなる。

ステップ0 初期点 \mathbf{x}^0 を選び、十分小さな正の数 $\epsilon > 0$ を定め、 $k = 0$ とする。

ステップ1 $\|\nabla f(\mathbf{x}^k)\| \leq \epsilon$ ならばストップし、 \mathbf{x}^k を近似解とする。さもなければ、

$$\mathbf{d} = -\nabla^2 f(\mathbf{x}^k)^{-1} \nabla f(\mathbf{x}^k)$$

を計算し、問題

$$\min_{\alpha} f(\mathbf{x}^k + \alpha \mathbf{d})$$

の(近似)解 α^* を求める。

ステップ2 $\mathbf{x}^{k+1} = \mathbf{x}^k + \alpha^* \mathbf{d}$ とし、 k を1増加してステップ1へ戻る。

最小解 \mathbf{x}^* においてヘッセ行列 $\nabla^2 f(\mathbf{x}^*)$ が正定値であり、初期点 \mathbf{x}^0 が \mathbf{x}^* に十分近いならば、ニュートン法で生成される点列は \mathbf{x}^* に速く収束する(局所的に2次収束する)ことが知られている。

演習問題 1.14 原点 $(0,0)$ を初期点とするとき、関数 $f(x_1, x_2) = x_1^2 - 2x_1x_2 + 2x_2^2 - 4x_1 + 2x_2 + 3$ にニュートン法を適用し、1 反復後の点を計算せよ。

1.6 等式制約のみの非線形計画問題

等式制約のみの非線形計画問題は、変数ベクトル $\mathbf{x} \in \mathcal{R}^n$ と関数 $f : \mathcal{R}^n \rightarrow \mathcal{R}$, $h_j : \mathcal{R}^n \rightarrow \mathcal{R}$ ($j = 1, 2, \dots, l$) に対し

$$\begin{aligned} \text{(NLP0)} \quad & \text{最小化} \quad f(\mathbf{x}) \\ & \text{制約条件} \quad h_j(\mathbf{x}) = 0, \quad j = 1, 2, \dots, l \end{aligned}$$

と表される。ここで、目的関数 f とすべての h_j が 2 回連続微分可能であるとする。制約条件をすべてみたす点 \mathbf{x} を実行可能解といい、すべての実行可能解の集合 $S = \{\mathbf{x} | h_j(\mathbf{x}) = 0, j = 1, 2, \dots, l\}$ を実行可能領域という。

任意の実行可能解 $\mathbf{x} \in S$ に対して、

$$f(\mathbf{x}^*) \leq f(\mathbf{x})$$

となる $\mathbf{x}^* \in S$ を非線形計画問題 (NLP0) の大域的最小解 (最適解) という。ある $\epsilon > 0$ が存在し、 $\|\mathbf{x} - \mathbf{x}^*\| < \epsilon$ をみたす任意の実行可能解 $\mathbf{x} \in S$ に対して、

$$f(\mathbf{x}^*) \leq f(\mathbf{x})$$

をみたす $\mathbf{x}^* \in S$ を非線形計画問題 (NLP0) の局所的最小解 (最適解) という。

点 \mathbf{x}^* が非線形計画問題 (NLP0) の局所的最適解であり、点 \mathbf{x}^* における勾配ベクトル $\nabla h_j(\mathbf{x}^*)$ ($j = 1, 2, \dots, l$) が 1 次独立であるならば、ある $\mathbf{v}^* = (v_1^*, v_2^*, \dots, v_l^*) \in \mathcal{R}^m$ が存在し

$$\begin{aligned} \nabla f(\mathbf{x}^*) + \sum_{j=1}^m v_j^* \nabla h_j(\mathbf{x}^*) &= \mathbf{0} \\ h_j(\mathbf{x}^*) &= 0, \quad j = 1, 2, \dots, l \end{aligned}$$

が成立する。これを最適性の 1 次の必要条件という。

1.7 不等式制約のみの非線形計画問題

不等式制約のみの非線形計画問題は、変数ベクトル $\mathbf{x} \in \mathcal{R}^n$ と関数 $f : \mathcal{R}^n \rightarrow \mathcal{R}$, $g_i : \mathcal{R}^n \rightarrow \mathcal{R}$ ($i = 1, 2, \dots, m$) に対し

$$\begin{aligned} \text{(NLP1)} \quad & \text{最小化} \quad f(\mathbf{x}) \\ & \text{制約条件} \quad g_i(\mathbf{x}) \leq 0, \quad i = 1, 2, \dots, m \end{aligned}$$

と表される. ここで, 目的関数 f とすべての g_i は 2 回連続微分可能であるとする. 制約条件をすべてみたす点 \mathbf{x} を実行可能解といい, すべての実行可能解の集合 $S = \{\mathbf{x} | g_i(\mathbf{x}) \leq 0, i = 1, 2, \dots, m\}$ を実行可能領域という.

任意の実行可能解 $\mathbf{x} \in S$ に対して,

$$f(\mathbf{x}^*) \leq f(\mathbf{x})$$

となる $\mathbf{x}^* \in S$ を非線形計画問題 (NLP1) の大域的最小解 (最適解) という. ある $\epsilon > 0$ が存在し, $\|\mathbf{x} - \mathbf{x}^*\| < \epsilon$ をみたす任意の実行可能解 $\mathbf{x} \in S$ に対して,

$$f(\mathbf{x}^*) \leq f(\mathbf{x})$$

をみたす $\mathbf{x}^* \in S$ を非線形計画問題 (NLP1) の局所的最小解 (最適解) という.

実行可能領域 S が凸集合 (すべての関数 g_i が凸関数) で目的関数 f が凸関数ならば, 任意の局所的最小解が大域的最小解となる. このとき, 問題 (NLP1) を凸計画問題という.

例 1.15 非線形計画問題の例として,

$$\begin{aligned} \text{最小化} \quad & f(x_1, x_2) = \frac{1}{2}(x_1 - 2)^2 - x_2 \\ \text{制約条件} \quad & g_1(x_1, x_2) = (x_1 - 1)^2 + x_2^2 - 1 \leq 0 \\ & g_2(x_1, x_2) = x_1 - 1 \leq 0 \\ & g_3(x_1, x_2) = -x_2 \leq 0 \end{aligned}$$

を扱う. この問題の最適解は, $\mathbf{x}^* = (1, 1)^T$ であり, そのときの最小値は $-1/2$ である.

最適解で等号が成立している制約式 ($g_1(\mathbf{x}^*) = 0$ と $g_2(\mathbf{x}^*) = 0$) を有効制約という. 図 2 には, この問題の実行可能領域と目的関数の値が $-1/2$ となる曲線を表している. これを見るとわかるように, 最適解 \mathbf{x}^* において目的関数の勾配ベクトル $\nabla f(\mathbf{x}^*) = (-1, -1)^T$ が有効制約の勾配ベクトル $\nabla g_1(\mathbf{x}^*) = (0, 2)^T$ と $\nabla g_2(\mathbf{x}^*) = (1, 0)^T$ の非負結合で釣り合っている. すなわち, ある $u_1^* \geq 0$ と $u_2^* \geq 0$ に対し,

$$\nabla f(\mathbf{x}^*) + u_1^* \nabla g_1(\mathbf{x}^*) + u_2^* \nabla g_2(\mathbf{x}^*) = \mathbf{0}$$

が成立する. 実際, $u_1^* = 1/2$, $u_2^* = 1$ とすれば, 上の式が成立する. 上記の条件と制約条件を一緒にすると,

$$\left. \begin{aligned} \nabla f(\mathbf{x}^*) + u_1^* \nabla g_1(\mathbf{x}^*) + u_2^* \nabla g_2(\mathbf{x}^*) + u_3^* \nabla g_3(\mathbf{x}^*) &= \mathbf{0} \\ g_i(\mathbf{x}^*) &\leq 0 \\ u_i^* &\geq 0 \\ u_i^* g_i(\mathbf{x}^*) &= 0 \end{aligned} \right\} i = 1, 2, 3$$

と表すことができる. ここで, $g_3(\mathbf{x}^*) < 0$ より, $u_3^* = 0$ である.

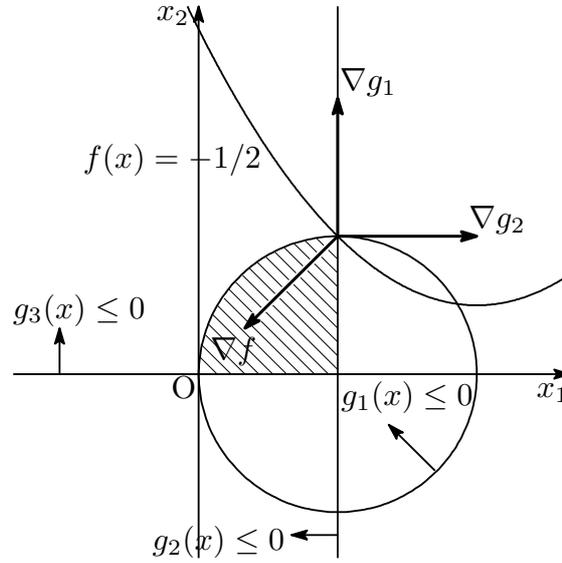


図2 最適解での目的関数と制約関数の勾配ベクトルの関係

一般には、点 \mathbf{x}^* が非線形計画問題 (NLP1) の局所最適解であり、点 \mathbf{x}^* における有効制約の勾配ベクトルが 1 次独立であるならば、ある $\mathbf{u}^* = (u_1^*, u_2^*, \dots, u_m^*) \in \mathcal{R}^m$ が存在し

$$\left. \begin{aligned} \nabla f(\mathbf{x}^*) + \sum_{i=1}^m u_i^* \nabla g_i(\mathbf{x}^*) &= \mathbf{0} \\ g_i(\mathbf{x}^*) &\leq 0 \\ u_i^* &\geq 0 \\ u_i^* g_i(\mathbf{x}^*) &= 0 \end{aligned} \right\} i = 1, 2, \dots, m \quad (8)$$

が成立する。これを最適性の 1 次の必要条件といい、カルーシュ・キューン・タッカー条件 (Karush-Kuhn-Tucker 条件, KKT 条件) またはキューン・タッカー条件 (KT 条件) ともいう。

例 1.16 次の例

$$\begin{aligned} \text{最小化} \quad & f(\mathbf{x}) = x_1 + x_2 \\ \text{制約条件} \quad & g_1(\mathbf{x}) = -x_1^3 + x_2 \leq 0 \\ & g_2(\mathbf{x}) = -x_2 \leq 0 \end{aligned}$$

では、 $\mathbf{x}^* = (x_1, x_2) = (0, 0)$ が最適解であり、最適値が 0 である。

図 3 には、この問題の実行可能領域と目的関数の値が 0 となる直線を表している。最適解において、制約 $g_1(\mathbf{x}) \leq 0$ と $g_2(\mathbf{x}) \leq 0$ は、共に等号が成立しており、有効制約である。図 3 を見るとわかるように、勾配ベクトル $\nabla f(\mathbf{x}^*) = (1, 1)^T$, $\nabla g_1(\mathbf{x}^*) = (0, 1)^T$,

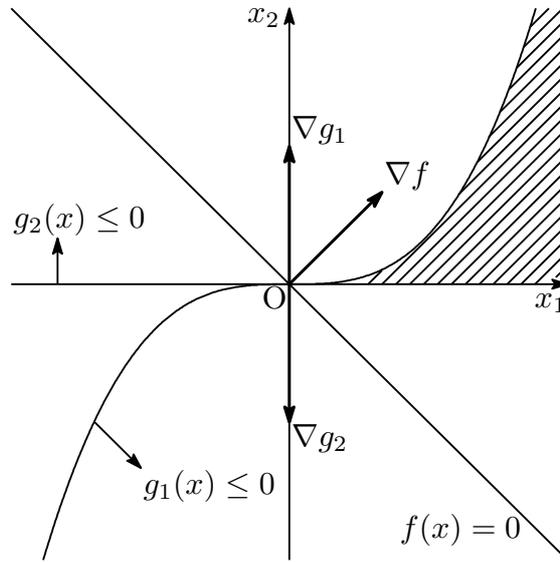


図3 最適解での有効制約の勾配ベクトルが一次独立でない例

$\nabla g_2(\mathbf{x}^*) = (0, -1)^T$ に対して KKT 条件の第 1 式

$$\nabla f(\mathbf{x}^*) + u_1^* \nabla g_1(\mathbf{x}^*) + u_2^* \nabla g_2(\mathbf{x}^*) = \mathbf{0}$$

を満たす $u_1^* \geq 0$ と $u_2^* \geq 0$ が存在しない. その理由は, この最適解において, 有効制約の勾配ベクトル $\nabla g_1(\mathbf{x}^*) = (0, 1)^T$, $\nabla g_2(\mathbf{x}^*) = (0, -1)^T$ が 1 次独立となっていないからである.

非線形計画問題 (NLP1) に対し, ラグランジュ乗数 $u_i \geq 0$ ($i = 1, 2, \dots, m$) を導入して, ラグランジュ関数 (Lagrangian) を

$$L(\mathbf{x}, \mathbf{u}) = f(\mathbf{x}) + \sum_{j=1}^m u_j g_j(\mathbf{x})$$

と定義する. ただし, ラグランジュ乗数の中に負の値をとるものがあるときは, $L(\mathbf{x}, \mathbf{u}) = -\infty$ とする. このとき, KKT 条件は,

$$\left. \begin{aligned} \nabla_{\mathbf{x}} L(\mathbf{x}^*, \mathbf{u}^*) &= \nabla f(\mathbf{x}^*) + \sum_{i=1}^m u_i^* \nabla g_i(\mathbf{x}^*) = \mathbf{0} \\ g_i(\mathbf{x}^*) &\leq 0 \\ u_i^* &\geq 0 \\ u_i^* g_i(\mathbf{x}^*) &= 0 \end{aligned} \right\} i = 1, 2, \dots, m$$

と表わされる.

最適解 \mathbf{x}^* における有効制約の集合を

$$I(\mathbf{x}^*) = \{i | g_i(\mathbf{x}^*) = 0\}$$

とし, すべての有効制約の勾配ベクトルと直交するベクトルの集合を

$$M = \{\mathbf{y} \in \mathcal{R}^n | \nabla g_i(\mathbf{x}^*)^T \mathbf{y} = 0, i \in I(\mathbf{x}^*)\}$$

とする. 非線形計画問題 (NLP1) の局所的最適解 \mathbf{x}^* において有効制約の勾配ベクトルが 1 次独立で, KKT 条件をみたすラグランジュ乗数を \mathbf{u}^* とすれば,

$$\mathbf{y}^T \nabla_{\mathbf{x}}^2 L(\mathbf{x}^*, \mathbf{u}^*) \mathbf{y} \geq 0 \text{ for } \forall \mathbf{y} \in M$$

が成立する. これと KKT 条件を合わせて, 最適性の 2 次の必要条件という.

逆に, KKT 条件をみたす $(\mathbf{x}^*, \mathbf{u}^*)$ に対して,

$$M' = \left\{ \mathbf{y} \in \mathcal{R}^n \mid \begin{array}{l} \nabla g_i(\mathbf{x}^*)^T \mathbf{y} = 0, i \in I(\mathbf{x}^*) \text{ and } u_i^* > 0, \\ \nabla g_i(\mathbf{x}^*)^T \mathbf{y} \geq 0, i \in I(\mathbf{x}^*) \text{ and } u_i^* = 0 \end{array} \right\}$$

と定義するとき

$$\mathbf{y}^T \nabla_{\mathbf{x}}^2 L(\mathbf{x}^*, \mathbf{u}^*) \mathbf{y} > 0 \text{ for } \forall \mathbf{y} \in M' \text{ and } \mathbf{y} \neq \mathbf{0}$$

が成り立つならば, \mathbf{x}^* は (NLP1) の局所的最適解となる. この条件と KKT 条件を合わせて最適性の 2 次の十分条件という.

演習問題 1.17 2 次計画問題

$$\begin{array}{ll} \text{最小化} & \mathbf{c}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{Q} \mathbf{x} \\ \text{制約条件} & \mathbf{A} \mathbf{x} \leq \mathbf{b} \\ & \mathbf{x} \geq \mathbf{0} \end{array}$$

の KKT 条件を求めよ.

1.8 一般の非線形計画問題

等式制約と不等式制約を持つ一般的な非線形計画問題は

$$\begin{array}{ll} \text{(NLP2) 最小化} & f(\mathbf{x}) \\ \text{制約条件} & g_i(\mathbf{x}) \leq 0, i = 1, \dots, m \\ & h_j(\mathbf{x}) = 0, j = 1, \dots, l \end{array}$$

と表すことができる. 関数 f とすべての g_i, h_j が 2 回連続微分可能であるとする. 問題 (NLP1) と同様に, 実行可能解, 大域的最適解, 局所的最適解などを定義できる.

問題 (NLP2) のラグランジュ関数を

$$L(\mathbf{x}, \mathbf{u}, \mathbf{v}) = f(\mathbf{x}) + \sum_{i=1}^m u_i g_i(\mathbf{x}) + \sum_{j=1}^l v_j h_j(\mathbf{x})$$

と定義する. このとき, 点 \mathbf{x}^* が非線形計画問題 (NLP2) の最適解であり, 有効制約の勾配ベクトル $\nabla g_i(\mathbf{x}^*)$ ($i \in I(\mathbf{x}^*)$), $\nabla h_j(\mathbf{x}^*)$ が 1 次独立ならば, ある \mathbf{u}^* と \mathbf{v}^* に対し次の条件 (KKT 条件)

$$\left. \begin{aligned} \nabla_{\mathbf{x}} L(\mathbf{x}^*, \mathbf{u}^*, \mathbf{v}^*) &= \mathbf{0} \\ g_i(\mathbf{x}^*) &\leq 0 \\ u_i^* &\geq 0 \\ u_i^* g_i(\mathbf{x}^*) &= 0 \end{aligned} \right\} i = 1, \dots, m \quad (9)$$

$$h_j(\mathbf{x}^*) = 0, \quad j = 1, \dots, l$$

が成立する. 問題 (NLP2) の 2 次の必要条件と十分条件も (NLP1) と同様に求めることができる.

演習問題 1.18 2 次計画問題

$$\begin{aligned} \text{最小化} & \quad \mathbf{c}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{Q} \mathbf{x} \\ \text{制約条件} & \quad \mathbf{A}_1 \mathbf{x} \leq \mathbf{b}_1 \\ & \quad \mathbf{A}_2 \mathbf{x} = \mathbf{b}_2 \end{aligned}$$

の KKT 条件を求めよ.

1.9 演習問題の略解

1.9.1 演習問題 1.2 の略解

(1) 関数

$$f(x) = 2x^3 - 9x^2 + 12x - 2$$

の局所的最小解であるための 1 次の必要条件は

$$f'(x) = 6(x-1)(x-2) = 0$$

となる. したがって, $x = 1, 2$ が 1 次の必要条件をみたす. このとき

$$f''(x) = 12x - 18$$

となる. $f''(1) = -6 < 0$ より, $x = 1$ は 2 次の必要条件も 2 次の十分条件も満たさない. したがって, $x = 1$ は, 関数 f の局所的最小解ではない. また, $f''(2) = 6 > 0$ より, $x = 2$ は 2 次の必要条件も 2 次の十分条件も満たす. したがって, $x = 2$ は, f の局所的最小解である.

(2) 関数

$$f(x) = 3x^4 + 4x^3 - 6x^2 - 12x - 4$$

の局所的最小解であるための1次の必要条件は

$$f'(x) = 12(x+1)^2(x-1) = 0$$

となる。したがって、 $x = -1, 1$ が1次の必要条件をみたす。このとき

$$f''(x) = 36x^2 + 24x - 12$$

となる。 $f''(-1) = 0$ より、 $x = 1$ は2次の必要条件を満たすが、2次の十分条件を満たさない。この条件だけでは、 $x = 1$ が局所的最小解であるかどうかかわからないが、関数 f のグラフを書くと、局所的最適解ではないことがわかる。また、 $f''(1) = 48 > 0$ より、 $x = 1$ は2次の必要条件も2次の十分条件も満たす。したがって、 $x = 1$ は、関数 f の局所的最小解である。

1.9.2 演習問題 1.4 の略解

関数 f を任意の $x \in \mathcal{R}$ に対して

$$f(x) = 2x^3 - 9x^2 + 12x - 3$$

とし、ニュートン法の初期点を $x^0 = 3$ とする。このとき、 $f(3) = 6$ 、 $f'(3) = 12$ 、 $f''(3) = 18$ であるので、関数 f を $x^0 = 3$ において2次近似した関数は

$$g(x) = 6 + 12(x-3) + 9(x-3)^2$$

となり、 $g'(x^1) = 0$ の解は

$$x^1 = 3 - \frac{12}{18} = 2\frac{1}{3}$$

となる。この x^1 がニュートン法で1反復後に計算される点である。

1.9.3 演習問題 1.9 の略解

2変数関数

$$f(x_1, x_2) = x_1^3 + 2x_1x_2 + x_2^2 + x_1 + 2x_2$$

の勾配ベクトルは

$$\nabla f(x_1, x_2) = \begin{pmatrix} 3x_1^2 + 2x_2 + 1 \\ 2x_1 + 2x_2 + 2 \end{pmatrix}$$

となり、ヘッセ行列は

$$\nabla^2 f(x_1, x_2) = \begin{pmatrix} 6x_1 & 2 \\ 2 & 2 \end{pmatrix}$$

となる。このとき、最小解であるための一次の必要条件は

$$\begin{aligned} 3x_1^2 + 2x_2 + 1 &= 0 \\ 2x_1 + 2x_2 + 2 &= 0 \end{aligned}$$

となるので, $(x_1, x_2) = (-1/3, -2/3), (1, -2)$ が得られる. 点 $(x_1, x_2) = (-1/3, -2/3)$ において, ヘッセ行列

$$\nabla^2 f\left(-\frac{1}{3}, -\frac{2}{3}\right) = \begin{pmatrix} -2 & 2 \\ 2 & 2 \end{pmatrix}$$

は, 半正定値ではない. したがって, この点 $(x_1, x_2) = (-1/3, -2/3)$ は, 2 次の必要条件と 2 次の十分条件を満たさず, f の局所的最適解ではない. また, 点 $(x_1, x_2) = (1, -2)$ において, ヘッセ行列

$$\nabla^2 f(1, -2) = \begin{pmatrix} 6 & 2 \\ 2 & 2 \end{pmatrix}$$

は, 正定値となる. したがって, この点 $(x_1, x_2) = (1, -2)$ は, 2 次の必要条件と 2 次の十分条件を満たし, f の局所的最適解である.

1.9.4 演習問題 1.12 の略解

関数

$$f(x_1, x_2) = x_1^2 - 2x_1x_2 + 2x_2^2 - 4x_1 + 2x_2 + 3$$

に点 $\mathbf{x}^1 = (x_1^1, x_2^1) = (1, -1/2)$ から最急降下法を適用したときの, 次の点 $\mathbf{x}^2 = (x_1^2, x_2^2)$ を求める. 勾配ベクトルは,

$$\nabla f(x_1, x_2) = \begin{pmatrix} 2x_1 - 2x_2 - 4 \\ -2x_1 + 4x_2 + 2 \end{pmatrix}$$

より

$$\nabla f\left(1, -\frac{1}{2}\right) = \begin{pmatrix} -1 \\ -2 \end{pmatrix}$$

となる. ステップサイズを α とすれば

$$\mathbf{x}^2 = \begin{pmatrix} x_1^2 \\ x_2^2 \end{pmatrix} = \begin{pmatrix} 1 \\ -\frac{1}{2} \end{pmatrix} - \alpha \begin{pmatrix} -1 \\ -2 \end{pmatrix} = \begin{pmatrix} 1 + \alpha \\ -\frac{1}{2} + 2\alpha \end{pmatrix}$$

となる. これより

$$f(x_1^2, x_2^2) = 5\alpha^2 - 5\alpha + \frac{1}{2}$$

となる. この関数 $f(x_1^2, x_2^2)$ は, $\alpha = 1/2$ のときに最小値 $-3/4$ をとる. $\alpha = 1/2$ であるから,

$$\mathbf{x}^2 = \begin{pmatrix} x_1^2 \\ x_2^2 \end{pmatrix} = \begin{pmatrix} \frac{3}{2} \\ \frac{1}{2} \end{pmatrix}$$

が得られる.

1.9.5 演習問題 1.14 の略解

関数

$$f(x_1, x_2) = x_1^2 - 2x_1x_2 + 2x_2^2 - 4x_1 + 2x_2 + 3$$

に点 $\mathbf{x}^0 = (x_1^0, x_2^0) = (0, 0)$ からニュートン法を適用したときの, 次の点 $\mathbf{x}^1 = (x_1^1, x_2^1)$ を求める.
勾配ベクトルは

$$\nabla f(x_1, x_2) = \begin{pmatrix} 2x_1 - 2x_2 - 4 \\ -2x_1 + 4x_2 + 2 \end{pmatrix}$$

となり, ヘッセ行列は

$$\nabla^2 f(x_1, x_2) = \begin{pmatrix} 2 & -2 \\ -2 & 4 \end{pmatrix}$$

となる. これより

$$\nabla f(0, 0) = \begin{pmatrix} -4 \\ 2 \end{pmatrix}$$

かつ

$$\nabla^2 f(0, 0) = \begin{pmatrix} 2 & -2 \\ -2 & 4 \end{pmatrix}$$

となる. したがって, ニュートン方向は

$$\mathbf{d} = -\nabla^2 f(0, 0)^{-1} \nabla f(0, 0) = - \begin{pmatrix} 2 & -2 \\ -2 & 4 \end{pmatrix}^{-1} \begin{pmatrix} -4 \\ 2 \end{pmatrix} = \begin{pmatrix} 3 \\ 1 \end{pmatrix}$$

となる. このとき,

$$f(\mathbf{x}^0 + \alpha \mathbf{d}) = f(3\alpha, \alpha) = 5\alpha^2 - 10\alpha + 3$$

となり, これは $\alpha = 1$ のとき, 最小値 -2 をとる. したがって, $\mathbf{x}^1 = \mathbf{x}^0 + \mathbf{d} = (3, 1)$ となる. これは, 2次関数 f の最適解となっている. 一般に, 関数 f が凸2次関数の場合には, ニュートン法により最適解が得られる.

1.9.6 演習問題 1.17 の略解

2次計画問題

$$\begin{array}{ll} \text{最小化} & \mathbf{c}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{Q} \mathbf{x} \\ \text{制約条件} & \mathbf{A} \mathbf{x} \leq \mathbf{b} \\ & \mathbf{x} \geq \mathbf{0} \end{array}$$

の KKT 条件は, (8) より, ある $\mathbf{u}_1 \in \mathcal{R}^m$ と $\mathbf{u}_2 \in \mathcal{R}^n$ が存在し,

$$\begin{array}{l} (\mathbf{Q} \mathbf{x} + \mathbf{c}) + \mathbf{A}^T \mathbf{u}_1 - \mathbf{u}_2 = \mathbf{0} \\ \mathbf{A} \mathbf{x} - \mathbf{b} \leq \mathbf{0} \\ -\mathbf{x} \leq \mathbf{0} \\ \mathbf{u}_1 \geq \mathbf{0}, \mathbf{u}_2 \geq \mathbf{0} \\ \mathbf{u}_1^T (\mathbf{A} \mathbf{x} - \mathbf{b}) = 0, \mathbf{u}_2^T \mathbf{x} = 0 \end{array}$$

となる.

1.9.7 演習問題 1.18 の略解

2 次計画問題

$$\begin{array}{ll} \text{最小化} & \mathbf{c}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{Q} \mathbf{x} \\ \text{制約条件} & \mathbf{A}_1 \mathbf{x} \leq \mathbf{b}_1 \\ & \mathbf{A}_2 \mathbf{x} = \mathbf{b}_2 \end{array}$$

の KKT 条件は, (9) より, ある $\mathbf{u} \in \mathcal{R}^m$ と $\mathbf{v} \in \mathcal{R}^l$ が存在し,

$$\begin{array}{l} (\mathbf{Q} \mathbf{x} + \mathbf{c}) + \mathbf{A}_1^T \mathbf{u} + \mathbf{A}_2^T \mathbf{v} = \mathbf{0} \\ \mathbf{A}_1 \mathbf{x} - \mathbf{b}_1 \leq \mathbf{0} \\ \mathbf{u} \geq \mathbf{0} \\ \mathbf{u}^T (\mathbf{A}_1 \mathbf{x} - \mathbf{b}_1) = 0 \\ \mathbf{A}_2 \mathbf{x} - \mathbf{b}_2 = \mathbf{0} \end{array}$$

となる.

謝辞: 本テキストで使用している図の作成をいただいた田中未来君 (東工大大学院生) に感謝します.