

ラグランジュ乗数法—陰関数定理の応用例

1 等式制約付き最適化問題

変数 $x \in \mathbf{R}^n$ に関する等式制約の最適化問題

$$\text{Minimize } f(x) \quad \text{s.t.} \quad g_i(x) = 0 \quad (i = 1, \dots, m)$$

に対するラグランジュ乗数法を説明する ($m \leq n$) . 記号の定義 :

$$\nabla f(x) = \left(\frac{\partial f}{\partial x_1}, \dots, \frac{\partial f}{\partial x_n} \right), \quad \nabla g_i(x) = \left(\frac{\partial g_i}{\partial x_1}, \dots, \frac{\partial g_i}{\partial x_n} \right).$$

定理 (最適性の必要条件) 点 x^* が

$$g_i(x^*) = 0 \quad (i = 1, \dots, m) \quad (1)$$

を満たすとする . 点 x^* が最適解ならば , 適当な条件 (後述) の下で

$$\nabla f(x^*) = \sum_{i=1}^m \lambda_i^* \nabla g_i(x^*) \quad (2)$$

を満たす $\lambda^* \in \mathbf{R}^m$ が存在する . ■

条件式 (1), (2) を合わせると , $m + n$ 個の変数 $\lambda_1^*, \dots, \lambda_m^*, x_1^*, \dots, x_n^*$ に関する $m + n$ 個の方程式となり , これを解けば最適解 (の候補) が求められる . これをラグランジュ乗数法あるいはラグランジュ未定乗数法という . なお , ラグランジュ関数 $L(x, \lambda)$ を

$$L(x, \lambda) = f(x) - \sum_{i=1}^m \lambda_i g_i(x) \quad (3)$$

($x \in \mathbf{R}^n, \lambda \in \mathbf{R}^m$) と定義すると , 上の二つの条件は次の形に表現できる :

$$\text{条件 (2)} \iff \frac{\partial L}{\partial x_j}(x^*, \lambda^*) = 0 \quad (j = 1, \dots, n),$$

$$\text{条件 (1)} \iff \frac{\partial L}{\partial \lambda_i}(x^*, \lambda^*) = 0 \quad (i = 1, \dots, m).$$

2 証明

第 1 段 : 線形近似による大筋の理解

方向を表すベクトル $d \in \mathbf{R}^n$ と実数 $t \in \mathbf{R}$ を使ってベクトル $x^* + td$ を考える . 内積を \cdot で表すとき , テイラー展開より

$$f(x^* + td) = f(x^*) + t (\nabla f(x^*) \cdot d) + O(t^2), \quad (4)$$

$$g_i(x^* + td) = g_i(x^*) + t (\nabla g_i(x^*) \cdot d) + O(t^2) \quad (5)$$

となるので, t の 1 次の項まで考えるとき, x^* が最適解ならば

$$\nabla g_i(x^*) \cdot d = 0 \quad (i = 1, \dots, m) \text{ を満たす任意の } d \text{ に対して } \nabla f(x^*) \cdot d = 0 \quad (6)$$

が成り立つ. $\nabla g_i(x^*)$ を第 i 行ベクトルとする $m \times n$ 行列を G とすると, 式 (6) の条件は「 $Gd = 0 \Rightarrow \nabla f(x^*) \cdot d = 0$ 」と同値であり, さらに, これは

$$(\nabla f(x^*))^\top \in (\text{Ker } G)^\perp \quad (7)$$

と言い換えることができる ($^\perp$ は直交補空間を表す). ここで

$$\text{線形代数における基本公式: } (\text{Ker } G)^\perp = \text{Im } G^\top$$

により, 条件 (7) は

$$\nabla f(x^*) \text{ が } \nabla g_1(x^*), \dots, \nabla g_m(x^*) \text{ の 1 次結合でかける} \quad (8)$$

と同値である. この 1 次結合の係数を $\lambda_1^*, \dots, \lambda_m^*$ とすれば (2) が成り立つ.

第 2 段: 陰関数定理を利用した厳密な証明

定理中の 適当な条件 とは:

- (i) 点 x^* の近傍において関数 $f(x), g_i(x)$ ($i = 1, \dots, m$) は連続微分可能 (C^1),
- (ii) $\{\nabla g_1(x^*), \dots, \nabla g_m(x^*)\}$ は 1 次独立.

$\nabla g_i(x^*)$ を第 i 行ベクトルとする $m \times n$ 行列を G とする. G の適当な m 本の列ベクトルを選べば線形独立である. 一般性を失うことなく, 最後の m 列 ($n - m + 1, \dots, n$) が線形独立と仮定し, $x = (y, z)$ (ただし $y \in \mathbf{R}^{n-m}, z \in \mathbf{R}^m$) と分けて, $x^* = (y^*, z^*), f(x) = f(y, z), g_i(x) = g_i(y, z)$ と考える.

行列 G も $G = [N \ B]$ と分ける. ここで $N = \left(\frac{\partial g_i}{\partial y_k} \mid i = 1, \dots, m; k = 1, \dots, n - m \right)$ は $m \times (n - m)$ 行列, $B = \left(\frac{\partial g_i}{\partial z_j} \mid i, j = 1, \dots, m \right)$ は $m \times m$ 行列であり, B は正則である. したがって, 陰関数定理により, (y^*, z^*) の近傍において $z = \varphi(y)$ と解ける. ここで φ は連続微分可能で,

$$\left(\frac{\partial \varphi_i}{\partial y_k} \right) = -B^{-1}N$$

である.

元の制約付き最適化問題は, 変数 z を消去した関数 $F(y) = f(y, \varphi(y))$ の制約なしの最小化問題と (局所的には) 等価であり, 後者の最適性の必要条件は $\nabla_y F(y^*) = 0$ である. 一方, (y^*, z^*) において

$$\nabla_y F = \nabla_y f - \nabla_z f \cdot B^{-1}N$$

であるから, $\lambda^* = \nabla_z f \cdot B^{-1}$ (m 次元の横ベクトル) とおくと,

$$\nabla_y f = \lambda^* N, \quad \nabla_z f = \lambda^* B$$

となる. $\nabla f = (\nabla_y f, \nabla_z f)$, $G = [N \ B]$ だから, 上の式はまとめて $\nabla f = \lambda^* G = \sum_{i=1}^m \lambda_i^* \nabla g_i(x^*)$ となる. 以上 (2012-01-10)