

正線形逆問題の解法

01701460 福岡大学 米田 清 YONEDA Kiyoshi

1. はじめに

線形逆問題において原因と結果がともに正の値をとる場合の解法を提案する。

2. 線形逆問題

原因 x が機序 f を通じて結果 y を生む因果関係を写像 $f: x \mapsto y$ として表現する。機序を仮定した上で結果を与えて原因を求めるのが逆問題である。

機序が線形の場合が線形逆問題で、 f を行列

$$F := [f_{ij}] \text{ で表現して } Fx = y \text{ を解く。}$$

この方程式は通常、矛盾を含んでいて線形代数の意味では解がない。そこで Moore-Penrose の一般化逆行列 F^+ によって最小2乗最短解 $\hat{x} := F^+y$ を求める。

すると、 y を僅かに変えると解 \hat{x} が極端に変わってしまう、不安定性、不適切性、多重共線性などよばれる問題が起きることがある。そこで F^+ の階級を何らかの方法で落とす。これは正規方程式 $F'Fx = F'y$ の $F'F$ を逆行列があるように加工することに対応するので、正則化と言う。 F^+ の計算には特異値分解を使うので計算量が多い。そこで計算量の小さい正則化法が工夫されている [1]。

3. 最適化による解法

一方、計量経済学では Golan-Judge-Miller (GJM) の方法 [2] が成功している。その方法は一般線形構造から情報量を用いた目的関数を作り、それを最適化するように x と y を決める。情報量の使用が目をつく。しかし成功の原因はむしろ最適化に定式化したことのように思う。

p を x の先験的な値とし、 $\rho(x, p)$ で両者間の遠さを座標毎に計る。 q を観測値として $\rho(y, q)$ も同様。

GJM では a, b を重みとして

$$K(x) := a'\rho(x, p) + b'\rho(y, q),$$

$$\hat{x} := \arg \min_x \{K(x) | Fx = y\} \text{ とする。}$$

K の第2項は観測値に対するあてはまりの良さで、最小2乗法と同様の思想である。第1項は先験情報に対するあてはまりの良さで、一般化逆行列 F^+ と同様の思想である。不安定性は $K(x)$ 最小化にもとづくモデル選択で処理する。

4. 最小2乗法

これが GJM の要点なら、 ρ は2乗距離でも良からう。

$0 < u, v$ をそれぞれ x, p と y, q の計測単位として p, q, u, v, a, b を外部的に与え、

$$\rho(x, p, u) := \left[\cdots \left\{ (x_j - p_j) / u_j \right\}^2 \cdots \right] \text{ とすれば}$$

$$\frac{\partial K}{\partial x_j} = \frac{2a_j}{u_j^2} (x_j - p_j) + \sum_j \frac{2b_j f_{ij}}{v_j^2} \left(\sum_k f_{ik} x_k - q_i \right)$$

で、 $\nabla K = 0$ が正規方程式。Hessian は

$$F' \text{diag}(2b_i / v_i^2) F.$$

5. 正線形逆問題

原因と結果が正値 $0 < x, y$ をとる場合を正線形逆問題とよぼう。非負の逆問題は社会現象の扱いによく現れ、0 を個別に処理すれば正逆問題になる。線形逆問題で ρ を以下のようにとれば無制約の最適化で正条件を満たせる。

6. 評価関数

$0 < x, p$ のとき、 x と p の遠さを図1のように面積 $(x - p)(\log x - \log p)$ で測りたい。これは $0 = x < p$ のときは桁数の差

$\log x - \log p$, $p < x \approx \infty$ のときは差

$x - p$, $x = p$ のときは両者の積 $(x - p) \log(x/p)$ によって x と p の遠さを測ろうというものである。すなわち x が小さければ比を問題にし、大きければ差を問題にする。この量の単位 u は x と p の共通単位なので、 u で割って無単位化し、

$$J(x, p, u) := \left\{ (x - p) / u \right\} \log(x/p), \quad 0 < x, p, u$$

で x と p の遠さを計量する。この関数は x と p に関して対称 $J(x, p, u) = J(p, x, u)$ 。 $J(x, p, u)$ は図2のよ

うな凸関数で最小値が $J(p, p, u) = 0$ で

$$J(0, p, u) = \infty, \text{ そして } x \text{ が大きいとき}$$

$$J(x, p, u) \approx x \log x.$$

誤差を ξ として加法構造に従う観測値 $p = x + \xi$ から、未知母数 x を J の最小化によって推定することを考える。 $J(x, x + \xi, u) \approx \xi^2 / ux$ から、これは最小2乗法において x の推定値が0から離れるように $1/ux$ で重み付けしたものに近い。

J 最小の条件 $dJ(x, p, u) / dx = 0$ は

$$\log(x/p) = (p - x) / x \text{ に同値である。一方}$$

$$\log(x/p) = (x - p) / p \text{ なので、} J \text{ 最小の条件は2種}$$

の相対誤差が等しい $(x-p)/p = (p-x)/x$ という意味でもある。

損失 J の最小化は図3に示す充足 e^{-J} の最大化に同値である。充足の面積を1に正規化して得られる確率密度分布は指数型分布族に属し、 p, u はそれぞれ位置、尺度母数である。つまり最尤法が効く。

7. 最適化問題

$0 < p, q, u, v, a, b$ を外部的に与え、対角行列を

$$\text{diag} \bullet \cdot x/p := [\dots x/p \dots]'$$

$$\log \bullet \cdot := [\dots \log \bullet \dots]'$$
 等と書くと

$$K(x) := (x-p)' \text{diag}(a/u) \log(x/p) + (Fx-q)' \text{diag}(b/v) \log(Fx/q)$$

は Jeffrey' divergence の各項に重み $a/u, b/v$ をかけたものである。 $\hat{x} := \arg \min_x \{K(x) | Fx = y\}$.

8. 解法

$K(x)$ は凸で gradient と Hessian はそれぞれ

$$G(x) := [\dots a_j \{ \log(x_j/p_j) - (p_j - x_j)/x_j \} \dots]' + F' [\dots b_i \{ \log([Fx]_i/q_i) - (q_i - [Fx]_i)/[Fx]_i \} \dots]'$$

$$H(x) := F' \text{diag} \left(\frac{b_i}{v_i} \frac{[Fx]_i + q_i}{[Fx]_i^2} \right) F$$

で、Newton 法が使える。 τ_a, τ_r をそれぞれ絶対および相対誤差の上限とし、

$$\epsilon_0 := \|G(x)\|$$

while $\tau_a + \tau_r \epsilon_0 < \|G(x)\|$ do

$$H(x) := LL' \text{ (Cholesky分解)}$$

$$x := x - (L^{-1})' L^{-1} G(x)$$

end_while

9. おわりに

正線形逆問題の解法を提案した。無制約の最適化に定式化され、Newton 法が使えるので、2次収束が保証される。発表では例題を示し、周辺領域との関連を論じる。

文献

- [1] S. L. Campbell and C. D. Meyer, Jr. Generalized Inverses of Linear Transformations. Dover, 1979.
- [2] A. Golan, G. Judge, and D. Miller. Maximum Entropy Econometrics. Wiley, 1996.




図1 対数面積による遠さの評価




図2 $J(x, 2, 1)$




図3 充足 $e^{-J(x, 2, 1)}$