

計算代数とモデリング

目次

1. 計算代数の基礎とモデリング, シミュレーション, 高山信毅
2. システムの代数的解析, 小松瑞果
3. 代数的統計モデルと超幾何系, 松原宰栄

1章 “計算代数の基礎とモデリング, シミュレーション” (2,3章へのイントロ) の内容紹介.

消去法

グレブナー基底をもちいた変数の消去.

Theorem 1

([CLO] など) イデアル $I = \langle f_1, \dots, f_m \rangle$ の元で x_1 を含まないもの全体, つまり

$$I_1 = I \cap \mathbb{Q}[x_2, \dots, x_n] \quad (1)$$

を考える. この時 I_1 は I の *lexicographic order* でのグレブナー基底 G の中で x_1 をふくまないもの, つまり

$$G \cap \mathbb{Q}[x_2, \dots, x_n] \quad (2)$$

で生成される.


1. Lotka-Volterra system のパラメータ推定

a, b, c, d をパラメータとする ODE (ordinary differential equation):

$$x' = ax - bxy \quad (3)$$

$$y' = -cy + dxy \quad (4)$$

このモデルはたとえば x はネズミの数, y は猫の数, を表す



問題: 猫の数の変化を観測して a, b, c, d を推定せよ

- y のみ (猫情報のみ) の ODE を求めよ.

$$-x_1 + ax - bxy, \quad -y_1 - cy + dxy,$$

$$-x_2 + ax_1 - bx_1y - bxy_1, \quad -y_2 - cy_1 + dx_1y + dxy_1$$

この多項式達の 3 番目の元は 1 番目の元の微分, 4 番目の元は 2 番目の元の微分である. $x_1 = x', x_2 = x'', x$ を消去したい. 辞書式順序

$$x_1 > x_2 > x > y > y_1 > y_2 > a > b > c > d$$

でこの集合のグレブナー基底を求めると,

$$\begin{aligned} & I^{(2)} \cap \mathbb{Q}[a, b, c, d, y, y_1, y_2] \\ &= \langle yy_2 - y_1^2 + by^2y_1 - ayy_1 + cby^3 - cay^2 \rangle \end{aligned} \quad (5)$$

最小 2 乗法で a, b, c を $y, y_1 = y', y_2 = y''$ の数値データから決めると

$$a = b = c = 1$$

d は決まらない.

$\{(a, b, c, d) \mid a = b = c = 1\}$ を **パラメータ多様体** という.

1.2 グレブナー基底による変数消去と微分方程式への応用

2 章 システムの代数的解析, 小松 に続く.

2. Bayes 統計と超幾何積分の計算代数

$p(x|w)$ をパラメータ w をもつモデル分布とする.

• 例¹. $p(x|w) = \exp(-(x-w)^2)/\sqrt{\pi}$.

Fisher の最尤推定法では, データを $X_i, i = 1, \dots, N$ とするとき,
尤度 (likelihood)

$$\prod_{i=1}^N p(X_i|w) \quad (6)$$

を最大化する w をデータに適合する w とみなす.

Bayes 推定ではデータからパラメータ w の分布を推定.

パラメータ w の確率分布は

$$\frac{(\text{データとモデルによる}) \text{ 尤度} \times \text{事前分布 (主観)}}{\text{正規化定数}} \quad (7)$$

¹ $\exp(-(x-w)^2)$ の正規化定数はこれを $(-\infty, \infty)$ で積分した値で $\sqrt{\pi}$.
 $\int_{-\infty}^{\infty} p(x|w) dx = 1$ となるので, $x \in (-\infty, \infty)$ 上のパラメータ w をもつ確率分布である.

コイン投げ (Fisher の最尤推定)

$p(\text{表} | w) = w, p(\text{裏} | w) = 1 - w. 0 \leq w \leq 1.$

表が出た回数を n_0 , 裏がでた回数を n_1 としよう. まず Fisher の最尤推定をおこなってみよう. 式 (6) によれば尤度 $w^{n_0}(1-w)^{n_1}$ を最大化する w を求めればよい. 尤度の \log をとって w で微分すると $\frac{n_0}{w} - \frac{n_1}{1-w}$ を得る. これが 0 となる条件は $w = \frac{n_0}{n_0+n_1}$ であり², 増減表を書いてみればこの値で尤度が最大となることがわかる.

²この値は直感的な w の推定値と一致している.

コイン投げ (Bayes 推定)

事前分布 (prior distribution) $p_2(w) = w^\alpha(1-w)^\beta/B(\alpha, \beta)$
を考える。ここで

$$B(\alpha, \beta) = \int_0^1 z^\alpha(1-z)^\beta dz \quad (8)$$

(ベータ関数の $\alpha + 1, \beta + 1$ での値)³。表が出た回数を n_0 , 裏がでた回数を n_1 とすれば, 事後ギブス分布 (事後分布) は (7) 式によれば

$$\frac{\text{尤度} \times \text{事前分布}}{\text{正規化定数}} = \frac{w^{n_0}(1-w)^{n_1} \times w^\alpha(1-w)^\beta/B(\alpha, \beta)}{\text{正規化定数}} \quad (9)$$

であるので,

$$\rho(w|n_0, n_1) = w^{\alpha+n_0}(1-w)^{\beta+n_1}/B(\alpha+n_0, \beta+n_1) \quad (10)$$

1.5 正確ベイズ解析

³これは $w \in [0, 1]$ 上の非正規化確率分布 $w^\alpha(1-w)^\beta$ の正規化定数である。

n_i についての差分方程式 (漸化式) は計算代数で導出できる

$$\rho(w|n_0 + 1, n_1) = \frac{\alpha + n_0 + 1 + \beta + n_1 + 1}{\alpha + n_0 + 1} w \cdot \rho(w|n_0, n_1)$$

$$\rho(w|n_0, n_1 + 1) = \frac{\alpha + n_0 + 1 + \beta + n_1 + 1}{\beta + n_1 + 1} (1 - w) \cdot \rho(w|n_0, n_1)$$

手法: D-加群の積分アルゴリズム, creative telescoping, **twisted cohomology**, 尤度方程式と **Macaulay** 行列法

3章 代数的統計モデルと超幾何系, 松原 に続く.

応用: n_i を大きくしたときの漸近行動の解析 (Bayes 推定法の解析)

$$\rho(w|n_0 + 1, n_1 + 1) = P(n_0, n_1)\rho(w|n_0, n_1),$$

$$P(n_0, n_1) = w(1-w) \frac{(\alpha + \beta + n_0 + n_1 + 2)(\alpha + \beta + n_0 + n_1 + 3)}{(\alpha + n_0 + 1)(\beta + n_1 + 1)}$$

たとえば $n = n_0 = n_1$ と仮定. $n \rightarrow \infty$ で

$$P(n, n) = \frac{\left(\frac{\alpha+\beta+2}{n} + 2\right) \left(\frac{\alpha+\beta+3}{n} + 2\right)}{\left(\frac{\alpha+1}{n} + 1\right) \left(\frac{\beta+1}{n} + 1\right)} w(1-w) \rightarrow 4w(1-w)$$

n 十分大で $\rho(w|n, n) \sim 4^n (w(1-w))^n$. $w(1-w)$ は $w = 1/2$ で最大値 $1/4$. したがって $w \neq 1/2$ なら $\rho(w|n, n)$ は $O(r^n)$, $r = 4w(1-w) < 1$ と指数関数的に減少.