

変換群を持つ統計モデルの幾何学

東大工学部 甘利 俊一 (Shun-ichi Amari)

東大工学部 倉田 耕治 (Koji Kurata)

§ 1 変換群モデルの例

R^n 上に, 2個のパラメータ a, b ($a > 0$) により,
指定される変換 g を考える。

$$g(x) = g \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} g_1(x) \\ \vdots \\ g_n(x) \end{pmatrix} = \begin{pmatrix} ax_1 + b \\ \vdots \\ ax_n + b \end{pmatrix}$$

すると, このような変換 g の集合 $G = \{(a, b) \mid a > 0\}$
は, 変換の合成という演算に関して群を成す。

$$(a, b) \circ (c, d) = (ac, ad + b)$$

$$e = (1, 0) \quad (a, b)^{-1} = \left(\frac{1}{a}, -\frac{b}{a} \right)$$

ここで, R 上の密度関数をひとつ固定すると, G を母
数空間とするモデルができる。すなわち, $p(x)$ から

$$p(x, e) = p(x_1)p(x_2)\cdots p(x_n),$$

$$\begin{aligned}
 p(x, g) &= p(g^{-1}x, e) \det \left(\frac{\partial g_i^{-1}(x)}{\partial x_j} \right) \\
 &= \frac{1}{a^n} p\left(\frac{x_1 - b}{a}\right) p\left(\frac{x_2 - b}{a}\right) \cdots p\left(\frac{x_n - b}{a}\right)
 \end{aligned}$$

のように作るわけである。

これはロケーション・スケール・モデルと呼ばれるものであるが、同じように、標本空間上の変換群と、ひとつの「種」となる分布による作らぬ分布には多次元正規分布、フィッシャーのサークルモデルなどがある。これらのモデルは、変換群モデル (transformation model) と呼ばれている。

変換群モデルに関しては、不変なロス、不変な推定量といった、自然な概念が定義される。

本稿では、変換群モデルに関して、近年筆者の一人が提唱している幾何学的な統計理論 (Amari 1985) を展開するため、変換群モデルの統計幾何学的諸量を求めた。

§ 2 変換群モデルの定式化


本節では Kariya (1983) に従って、変換群モデルの定式化を行なう。

標本空間を X 、母数空間を Θ とし、 $X \subset \mathbb{R}^n$ 、 $\Theta \subset \mathbb{R}^p$ とする。 $\theta \in \Theta$ により指定される分布関数を P_θ と書く。 $\theta_1 \neq \theta_2$ ならば、 $P_{\theta_1} \neq P_{\theta_2}$ であるとする。

モジュール $\mathbb{H} \subset \tilde{\mathbb{H}}$ を考え、 \mathbb{H} は、 $\mathcal{Y} \subset \mathbb{R}^b$ による、2 次元メトリック空間として与えられる:

$$\mathbb{H} = \{ \theta \in \tilde{\mathbb{H}} \mid \theta = \varphi(\gamma) \quad \gamma \in \mathcal{Y} \}.$$

$b < p$ と仮定する。




X 上に作用する群 G を考える。 $gP_0 = P_0g^{-1}$ と定めると、 $gP(\tilde{\mathbb{H}}) = P(\tilde{\mathbb{H}})$ か、すなわち \mathcal{Y} 上の $g \in G$ に関して成り立つとする。このとき、 G から、 $\tilde{\mathbb{H}}$ 上に作用する群 \bar{G} が induce される。つまり、 $P_0g^{-1} = P\bar{g}P_0$ とする。すると、 G は \bar{G} に準同型である。

\mathbb{H} が \bar{G} の orbit であるとは、すなわち \mathcal{Y} 上の $\bar{g} \in \bar{G}$ に対し $\bar{g}\mathbb{H} = \mathbb{H}$ であり、かつ、 \mathcal{Y} 上の $\theta_1, \theta_2 \in \mathbb{H}$ に対し、ある $\bar{g} \in \bar{G}$ が存在して $\bar{g}\theta_1 = \theta_2$ となることである。これを仮定する。なお、このふたつの条件のうち、後者が成り立つとき、 \bar{G} は \mathbb{H} に transitive に作用するといふ。

すると, φ により, \mathcal{X} 上に作用する変換群 \tilde{G} が induce される:


$$\tilde{G} = \{ \varphi \bar{g} \varphi^{-1} \mid \bar{g} \in G \}$$



$\tilde{\mathcal{O}}$ は \tilde{G} により, \mathcal{X} 上の orbit に分けられる。そのひとつが, $\tilde{\mathcal{O}}$ である。 $\tilde{\mathcal{O}}$ 上に定義された関数で, 各 orbit 内で, 一定値をとるものを invariant parameter と呼び, 特に, 異なる orbit 上では異なる値を持つものを maximal invariant parameter と呼ぶ。

$\lambda(\theta)$ を $\tilde{\mathcal{O}}$ 上の maximal invariant parameter, $u(x)$ を X 上の maximal invariant parameter とすると, u の分布は, λ のみによる。

なぜなら, θ_1 と θ_2 が同じ λ を与えたとき, この意味では, ある $\bar{g} \in G$ により, $\theta_1 = \bar{g} \theta_2$ と結ばれることは



すである), $S \subset u(X)$ に対して,

$$\begin{aligned} P_{\theta_1}(u^{-1}(S)) &= P_{\tilde{g}\theta_2}(u^{-1}(S)) \\ &= P_{\theta_2}(g^{-1}u^{-1}(S)) \\ &= P_{\theta_2}(u^{-1}(S)) \end{aligned}$$

となるからである。

このより, もしモデルを \mathcal{M} に限定せば, $u(X)$ は, *ancillary* であることが分る。

真の θ の代わりに $\gamma \in \mathcal{Y}$ により指定される分布から得られたデータを仮して, γ の推定値 $\hat{\gamma}$ を得たとする。

この時の損失を $L(\gamma, \hat{\gamma})$ とする。損失 $L(\gamma, \hat{\gamma})$ が不変であるとは, 任意の $\hat{\gamma} \in \hat{\mathcal{G}}$ に対し, $L(\gamma, \hat{\gamma}) =$

$L(\tilde{g}\gamma, \tilde{g}\hat{\gamma})$ が成立つことである。また, 推定量 $\hat{\gamma}: X \rightarrow \mathcal{Y}$ が不変であるとは, 任意の $g \in G, x \in X$ に

対し, $\hat{\gamma}(gx) = \tilde{g}\hat{\gamma}(x)$ が成立つことである。

§3 不変なロスとフィッシャー情報量

以後, X と \mathcal{M} が, G に対して μ と ν の orbit を成してあり, この ν が互いに同型である場合を考える。

群 G, \tilde{G}, \hat{G} の区別はなく, $\forall \gamma \in \mathcal{Y}, X, \mathcal{M}$ と同一視される。

\mathcal{M} 中の 1 点, 例えは, 原点を θ とし, 単位元と, 他の点との間に, ロスを定めると, このロスは, 不変性

を仮定すれば、すべての点とすべての点の間のロースに拡張される。言い換えば、1点の周りのロースは、変換群によって、すべての点の周りのロースに変換される。この変換はどのようなものかをも、ロース、各点の周りの2次の展開係数について調べてみよう。

$L(e, e+\xi)$ を ξ に関して展開すると、 $L(e, e) = 0, L \geq 0$ より ξ の1次の展開係数は0である。2次の係数を $L_{ij}(e)$ とする:

$$L(e, e+\xi) = \frac{1}{2} L_{ij} \xi^i \xi^j + \dots$$

ここで、右辺の1項は、 i, j に関して和をとることを略した記法である。すなわち、 θ の周りでは、

$$\begin{aligned} L(\theta, \theta+\xi) &= L(e, \theta^{-1}(\theta+\xi)) \\ &= L(e, e + B_i^j \xi^j + \dots) \\ &= \frac{1}{2} L_{ij}(e) B_k^i B_l^j \xi^k \xi^l + \dots, \end{aligned}$$

$$2.2 \text{に, } B_i^j(\theta) = \frac{\partial k^j(\theta, \eta)}{\partial \eta^i} \Big|_{\eta=\theta}, \quad k(\theta, \eta) = \theta^{-1}\eta.$$

よって $L_{ij}(\theta) = L_{kl}(e) B_i^k(\theta) B_j^l(\theta)$ を得る。

定理 1 フィッシャー-情報量を $g_{ij}(\theta)$ とすると、

$$g_{ij}(\theta) = g_{ke}(\theta) B_i^k B_j^e$$

これは, g_{ij} が L_{ij} と同じ変換に従うことを示している。よって 2 次の展開係数が, ファイッシャー情報量に一致するような不変な η が存在するわけである。

証明 密度関数を $p(x, \theta)$ とおく。

$$p(gx, g\theta) d(gx) = p(x, \theta) dx$$

であるから,

$$\begin{aligned} p(x, \theta + \xi) dx &= p(\theta^{-1}x, \theta^{-1}(\theta + \xi)) d(\theta^{-1}x) \\ &= p(y, e + B_j^i(\theta) \xi^j) A(\theta, x) dx \end{aligned}$$

$$\text{22に, } y = \theta^{-1}x, \quad A(\theta, x) = \det \left(\frac{\partial k^i(\theta, x)}{\partial x^i} \right)$$

A は ξ によらない事を利用して, 上式の両辺の対数をとって, ξ で微分した後, $\xi = 0$ とおくと,

$$\begin{aligned} \partial_i \ell(x, \theta) &= \frac{\partial}{\partial \xi^i} \log p(x, \theta + \xi) \Big|_{\xi=0} \\ &= \frac{\partial}{\partial \xi^i} \log p(y, e + B_j^i(\theta) \xi^j) \Big|_{\xi=0} \\ &= \partial_j \ell(y, e) B_i^j(\theta) \end{aligned}$$

2.2に ∂_i は $\frac{\partial}{\partial \theta^i}$ を意味する。

よって,

$$\begin{aligned} g_{ij}(\theta) &= E_{\theta} [\partial_i l(x, \theta) \partial_j l(x, \theta)] \\ &= E_{\theta} [\partial_k l(y, \theta) B_i^k(\theta) \partial_l l(y, \theta) B_j^l(\theta)] \\ &= B_i^k(\theta) B_j^l(\theta) g_{kl}(\theta) \end{aligned}$$

証明終

この定理を §1 であげたロケ-ション・スケールモデルで確かめてみよう。まず B_j^i を求めると,

$$\begin{aligned} h((\theta^1, \theta^2), (\eta^1, \eta^2)) &= (\theta^1, \theta^2)^{-1} \cdot (\eta^1, \eta^2) \\ &= \left(\frac{\eta^1}{\theta^1}, \frac{\eta^2 - \theta^2}{\theta^1} \right) \end{aligned}$$

よって

$$B_j^i(\theta) = \begin{pmatrix} \frac{1}{\theta^1} & 0 \\ 0 & \frac{1}{\theta^1} \end{pmatrix}.$$

次に L_{ij} の変換は,

$$L(e, (1 + d\theta^1, d\theta^2)) = \frac{1}{2} L_{ij}(e) d\theta^i d\theta^j + \dots$$

$$L((\theta^1, \theta^2), (\theta^1 + d\theta^1, \theta^2 + d\theta^2))$$

$$= L(e, (1 + \frac{d\theta^1}{\theta^1}, \frac{d\theta^2}{\theta^1}))$$

$$= \frac{1}{2} L_{ij}(e) \left(\frac{1}{\theta^1}\right)^2 d\theta^i d\theta^j + \dots$$

一方, フィッシャー情報量の方は, $l(x) = \log p(x)$,
 $y^i = (x^i - \theta^2) / \theta^1$ とおくと,

$$\begin{aligned} \log p(x, (\theta^1, \theta^2)) &= \log \left(\frac{1}{\theta^1} p \left(\frac{x - \theta^2}{\theta^1} \right) \right) \\ &= -\log \theta^1 + l(y) \end{aligned}$$

$$\begin{aligned} \therefore \partial_1 \log p(x, (\theta^1, \theta^2)) &= -\frac{1}{\theta^1} - \frac{1}{\theta^1} y l'(y) \\ &= \frac{1}{\theta^1} \partial_1 \log p(y, \theta) \end{aligned}$$

$$\begin{aligned} \partial_2 \log p(x, (\theta^1, \theta^2)) &= -\frac{1}{\theta^1} l'(y) \\ &= \frac{1}{\theta^1} \log p(y, \theta) \end{aligned}$$

$$\therefore g_{ij}(\theta_1, \theta_2) = \left(\frac{1}{\theta^1} \right)^2 g_{ij}(\theta)$$

例終

次に, 原点におけるフィッシャー情報量を具体的に求め, 2次元, 変換群と, 種に存する分布が, どのように寄与しているかを見ることにする. この結果と, 定理1を合わせれば, すべてこの点でのフィッシャー情報量が得られる.

定理2 原点 $\theta = e$ におけるフィッシャー情報量は, 次の式で与えられる.

$$g_{ij}(\theta) = E_{\theta} \left[\left(r_i^k \frac{\partial}{\partial x^k} l(x) + \frac{\partial}{\partial x^k} r_j^k(x) \right) \right. \\ \left. \times \left(r_j^l \frac{\partial}{\partial x^l} l(x) + \frac{\partial}{\partial x^l} r_i^l(x) \right) \right]$$

2.2に $r_j^i(x) = \frac{\partial}{\partial \theta^i} k^i(\theta, x)$, 変換群のみで決まる量である。

証明 $l(x, \theta) = \log p(x, \theta)$, $l(x) = l(x, \theta)$,
 $p(x) = p(x, \theta)$ と書くことにする。

$$p(x, \theta) = p(k(\theta, x)) \left| \frac{\partial k}{\partial x} \right|$$

$$\therefore l(x, \theta) = l(k(\theta, x)) + \log \left| \frac{\partial k}{\partial x} \right|$$

これを θ_i で偏微分して

$$\partial_i l(x, \theta) = \frac{\partial l}{\partial k_j} (k(\theta, x)) \frac{\partial k_j}{\partial \theta^i} + \frac{\partial}{\partial \theta^i} \log \left| \frac{\partial k}{\partial x} \right|$$

上式右辺第1項は, $\theta = \theta$ とすれば, $r_i^k \frac{\partial}{\partial x^k} l$ となる。
 第2項を計算するために, $\left| \frac{\partial k}{\partial x} \right|$ を求める。

$$k^i(\theta + \theta, x) = x^i + \theta^j r_j^i(x) + o(\theta^2)$$

$$\therefore \frac{\partial k^i}{\partial x^j} = \delta_j^i + \theta^k \frac{\partial}{\partial x^j} r_k^i(x) + o(\theta^2)$$

$$\therefore \left| \frac{\partial k^i}{\partial x^j} \right| = 1 + \theta^k \frac{\partial}{\partial x^j} r_k^i(x) + o(\theta^2)$$

上式の右辺をと、 θ^k で偏微分すると、

$$\frac{\partial}{\partial \theta^k} \left| \frac{\partial h^i}{\partial x^j} \right|_{\theta=e} = \frac{\partial}{\partial x^i} r_k^i(x)$$

$$\therefore \partial_i l(x, e) = r_i^k \frac{\partial}{\partial x^k} l(x) + \frac{\partial}{\partial x^k} r^k(x)$$

これより定理の結果を得る。

証終

§4 α 接続について

推定と深い関係を持つ α 接続について、フィッシャー情報量と同じく、その変け子変換と、原点における値を求める事ができる。しかし、計算が煩雑なので、ここでは、 $\alpha=1$ の場合の変換について、結果のみ記す。

定理3 Γ_{ijk} の変換は、次式で与えられる。

$$\hat{\Gamma}_{ijk}(\theta) = \Gamma_{lmn}(e) B_i^l B_j^m B_k^n(\theta) + g_{ml}(e) C_{ij}^m(\theta) B_k^l(\theta)$$

$$\text{ここに } C_{ij}^m(\theta) = \frac{\partial^2}{\partial \eta_i \partial \eta_j} k(\theta, \eta) \Big|_{\eta=0}$$

文献 Amari, S. (1985) *Differential-geometrical methods in statistics. Lecture notes in statistics 28* Springer-Verlag.

Kariya, E. (1983) An invariance approach to estimation in a curved model. Discussion paper ser. No. 88 Hitotsubashi Univ.