

# 統計モデルの幾何学と期待値系列

松添 博 (名古屋工業大学)

2017年10月15日-16日

統計多様体の幾何学とその周辺

- 0 導入
  - 1 統計モデルの幾何学
  - 2 統計多様体と双対平坦空間
  - 3 最尤推定量の幾何学
- 
- A 期待値系列と統計多様体

# 0 導入

そもそも情報幾何学がどのような分野を指すのかは未定義

- 狭義の情報幾何： 双対的なアファイン接続や、ダイバージェンスとよぶ距離 2乗型関数を用いた幾何学
- 広義の情報幾何： 情報の持つ数理構造を幾何学を用いて表現する方法論全般 (カーネル法や Wasserstein 幾何学も含む)

現在は、情報幾何学の研究の中心は欧州になりつつある。

# 1 統計モデル


定義 1.1

$S$  が  $\Omega$  上の **統計モデル** (または**パラメトリックモデル**)


$\stackrel{\text{def}}{\iff} S$  が  $\xi \in \Xi$  をパラメータとする確率密度関数族で

$$S = \left\{ p(x; \xi) \mid \int_{\Omega} p(x; \xi) dx = 1, p(x; \xi) > 0, \xi \in \Xi \subset \mathbb{R}^n \right\}$$

$S$  を  $\{\Xi; \xi^1, \dots, \xi^n\}$  を局所座標系とする**多様体** (曲がった空間) とみなす.



多様体



局所座標系

統計モデルが多様体となるための仮定

- (0)  $p(x; \xi) > 0, \forall x \in \Omega, \xi \in \Xi$   
(パラメータに関して確率分布のサポートが変化しない)
- (1) パラメータ空間  $\Xi$  は  $R^n$  の開集合
- (2)  $\xi \mapsto p(x; \xi)$  はほとんどすべての  $x$  に対して 1 対 1  
( $S$  は識別可能であると言う)
- (3)  $\xi \mapsto p(x; \xi)$  は (とりあえず)  $C^4$  級
- (4) 微分と積分の順序交換可能

$$\begin{aligned} \text{例えば } \int \frac{\partial}{\partial \xi^i} p(x; \xi) dx &= \frac{\partial}{\partial \xi^i} \int p(x; \xi) dx \\ & \left( = \frac{\partial}{\partial \xi^i} 1 = 0 \right) \end{aligned}$$

$S = \{p(x; \xi) \mid \xi \in \Xi\}$  に対して

$$\begin{aligned} \phi : S &\rightarrow R^n; \quad \phi(p(x; \xi)) = \xi \\ \xi &= (\xi^1, \xi^2, \dots, \xi^n) \end{aligned}$$

とおく.  $(\xi^1, \xi^2, \dots, \xi^n)$  を一つの局所座標系と考え,  $S$  を多様体とみなす.

## 1.2 Fisher 計量

統計モデルの Riemann 計量

$g^F = (g_{ij}^F)$  が  $S$  の **Fisher 計量** (Fisher 情報行列)

$$\stackrel{\text{def}}{\iff} g_{ij}^F(\xi) := E_p[\partial_i l_\xi \partial_j l_\xi] = \int_{\Omega} \frac{\partial}{\partial \xi^i} \log p(x; \xi) \frac{\partial}{\partial \xi^j} \log p(x; \xi) p(x; \xi) dx$$

Fisher 情報行列に対する仮定

(5)  $\forall \xi, \forall i, j$  に対して  $g_{ij}^F(\xi) < \infty$

(6)  $g_{ij}^F : \Xi \rightarrow R$  は (とりあえず)  $C^4$  級

## 命題 1.2

$g^F$  は非負定値対称行列である.

(証明) 任意の  $c \in R^n$  に対して

$${}^t c g^F c = \sum_{i,j=1}^n c^i c^j g_{ij}^F(\xi) = \int_{\Omega} \left\{ \sum_{i=1}^n c^i \partial_i l(x; \xi) \right\}^2 p(x; \xi) dx \geq 0$$

Fisher 計量に関する仮定

(7)  $g^F$  は正定値である.

命題 1.3 次の条件は同値

- (1)  $g^F$  は正定値.
- (2)  $\{\partial_1 p_\xi, \dots, \partial_n p_\xi\}$  は  $\Omega$  上の関数として線形独立.
- (3)  $\{\partial_1 l_\xi, \dots, \partial_n l_\xi\}$  は  $\Omega$  上の関数として線形独立.

$g^F = (g_{ij}) : S$  の Fisher 計量

$$\begin{aligned} \stackrel{\text{def}}{\iff} g_{ij}^F(\xi) &:= \int_{\Omega} \left( \frac{\partial}{\partial \xi^i} \log p(x; \xi) \right) \left( \frac{\partial}{\partial \xi^j} \log p(x; \xi) \right) p(x; \xi) dx \\ &= \int_{\Omega} \left( \frac{\partial}{\partial \xi^i} p_\xi \right) \left( \frac{\partial}{\partial \xi^j} \log p_\xi \right) dx \end{aligned} \quad (1)$$

$$= \int_{\Omega} \frac{1}{p(x; \xi)} \left( \frac{\partial}{\partial \xi^i} p_\xi \right) \left( \frac{\partial}{\partial \xi^j} p_\xi \right) dx \quad (2)$$

$\partial_i p_\xi \stackrel{\text{def}}{\iff} m$ -表現, 混合型表現

$\partial_i l_\xi = \left( \frac{\partial_i p_\xi}{p_\xi} \right) \stackrel{\text{def}}{\iff} e$ -表現, 指数型表現.

( $p(x; \theta)$  のスコア関数) (統計モデルの接ベクトル)

## 注意 1.4

$p$  の識別可能性と  $g$  の正定値性は同値ではない。

(1) 統計モデル  $S = \{p(x; u)\}$  を

$$p(x; u) = \frac{1}{\sqrt{2\pi}} \exp \left[ -\frac{(x - u)^2}{2} \right]$$

で定めると,  $S$  は正則である。

(2)

$$p(x; u) = \frac{1}{\sqrt{2\pi}} \exp \left[ -\frac{(x - u^2)^2}{2} \right] \quad (u \neq 0)$$

で定めると,  $g^F$  は正定値であるが  $p$  は識別可能ではない。

(3)

$$p(x; u) = \frac{1}{\sqrt{2\pi}} \exp \left[ -\frac{(x - u^3)^2}{2} \right]$$

で定めると,  $g^F$  は正定値ではないが  $p$  は識別可能である。

1.3  $\alpha$ -接続

統計モデルのアフィン接続, 共変微分

 $\nabla^{(\alpha)}$  :  $\alpha$ -接続 ( $\alpha \in R$ : 固定) (曲がった空間の微分)

$$\stackrel{\text{def}}{\iff} \Gamma_{ij,k}^{(\alpha)}(\xi) = E_p \left[ \left( \partial_i \partial_j l_\xi + \frac{1-\alpha}{2} \partial_i l_\xi \partial_j l_\xi \right) (\partial_k l_\xi) \right]$$

$$g^F(\nabla_{\partial_i}^{(\alpha)} \partial_j, \partial_k) = g^F \left( \sum_{l=1}^n \Gamma_{ij}^{(\alpha)l} \partial_l, \partial_k \right) = \Gamma_{ij,k}^{(\alpha)}$$

$\Gamma_{ij}^{(\alpha)l}$ : ベクトル場  $\frac{\partial}{\partial \xi^j}$  を  $\frac{\partial}{\partial \xi^i}$  方向に微分したときの  $\frac{\partial}{\partial \xi^l}$  成分

(補足) ある種の変換性を満たす  $n^3$  個の関数からアフィン接続が定義される.  
(接ベクトルが共変微分でどのように変化するか指定すれば良い)

$\nabla^{(0)}$  :  $g^F$  の Levi-Civita 接続

$\nabla^{(e)}$  :=  $\nabla^{(1)}$  : 指数型接続

$\nabla^{(m)}$  :=  $\nabla^{(-1)}$  : 混合型接続



統計モデルのアフィン接続, 共変微分

$\nabla^{(\alpha)}$  :  $\alpha$ -接続 ( $\alpha \in R$ : 固定) (曲がった空間の微分)

$$\stackrel{\text{def}}{\iff} \Gamma_{ij,k}^{(\alpha)}(\xi) = E_p \left[ \left( \partial_i \partial_j l_\xi + \frac{1-\alpha}{2} \partial_i l_\xi \partial_j l_\xi \right) (\partial_k l_\xi) \right]$$

$$g^F(\nabla_{\partial_i}^{(\alpha)} \partial_j, \partial_k) = g^F \left( \sum_{l=1}^n \Gamma_{ij}^{(\alpha)l} \partial_l, \partial_k \right) = \Gamma_{ij,k}^{(\alpha)}$$

$\Gamma_{ij}^{(\alpha)l}$ : ベクトル場  $\frac{\partial}{\partial \xi^j}$  を  $\frac{\partial}{\partial \xi^i}$  方向に微分したときの  $\frac{\partial}{\partial \xi^l}$  成分

$\nabla^{(e)} := \nabla^{(1)}$  : 指数型接続

$\nabla^{(m)} := \nabla^{(-1)}$  : 混合型接続

$$(1) \quad \partial_i g(\partial_j, \partial_k) = g^F(\nabla_{\partial_i}^{(\alpha)} \partial_j, \partial_k) + g^F(\partial_j, \nabla_{\partial_i}^{(-\alpha)} \partial_k)$$

( $\nabla^{(\alpha)}$  と  $\nabla^{(-\alpha)}$  は  $g^F$  に関する双対接続)

$$(2) \quad g^F(\nabla_{\partial_i}^{(\alpha)} \partial_j, \partial_k) = g^F(\nabla_{\partial_i}^{(0)} \partial_j, \partial_k) - \frac{\alpha}{2} C^F(\partial_i, \partial_j, \partial_k)$$

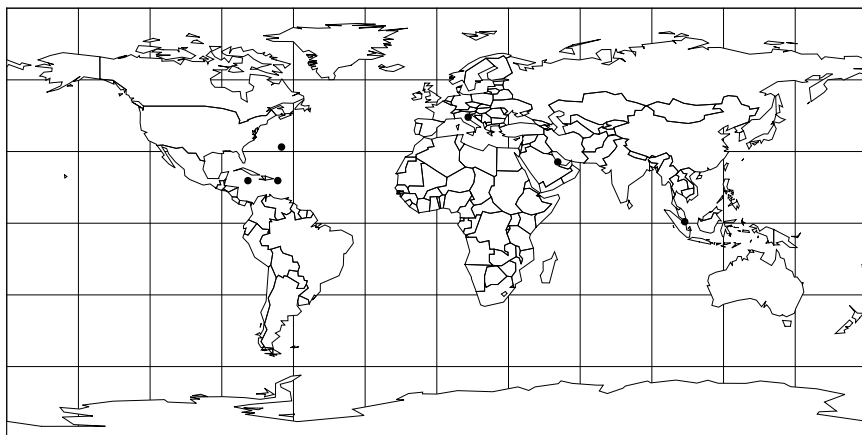
$$C_p^F(\partial_i, \partial_j, \partial_k) := E_p[(\partial_i l_\xi)(\partial_j l_\xi)(\partial_k l_\xi)] : 3 \text{ 次形式}$$

$(S, \nabla^{(\alpha)}, g^F)$  を不変統計多様体とよぶ.

## 1.4 指数型分布族

統計モデル  $S_e$  が 指数型分布族

$$\stackrel{\text{def}}{\iff} S_e = \left\{ p(x; \theta) \mid p(x; \theta) = \exp\left[C(x) + \sum_{i=1}^n \theta^i F_i(x) - \psi(\theta)\right] \right\},$$

 $C, F_1, \dots, F_n$  :  $\Omega$  上の確率変数 $\psi$  : パラメータ空間  $\Theta$  上の関数 $[\theta^i]$  を 自然座標系とよぶ.

局所座標系は目的に合わせて選ぶ

## 正規分布族

$$\Omega = \mathbb{R}, \quad n = 2, \quad \xi = (\mu, \sigma) \in \mathbb{R}_+^2 \quad (\text{上半平面})$$

$$S = \left\{ p(x; \mu, \sigma) \mid p(x; \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left[ -\frac{(x - \mu)^2}{2\sigma^2} \right] \right\}$$

Fisher 計量は次で与えられる.

$$(g_{ij}^F) = \frac{1}{\sigma^2} \begin{pmatrix} 1 & 0 \\ 0 & 2 \end{pmatrix} \quad \left( S \text{ は曲率 } -\frac{1}{2} \text{ の定曲率空間 (双曲空間)} \right).$$

$\nabla^{(1)}$  と  $\nabla^{(-1)}$  は平坦なアファイン接続.

$$\theta^1 = \frac{\mu}{\sigma^2}, \quad \theta^2 = -\frac{1}{2\sigma^2} \quad \psi(\theta) = -\frac{(\theta^1)^2}{4\theta^2} + \frac{1}{2} \log \left( -\frac{\pi}{\theta^2} \right)$$

$$\implies p(x; \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left[ -\frac{(x - \mu)^2}{2\sigma^2} \right] = \exp [x\theta^1 + x^2\theta^2 - \psi(\theta)]$$

$\{\theta^1, \theta^2\}$ : 自然パラメータ. ( $\nabla^{(1)}$ -測地座標系)

$$\eta_1 = E[x] = \mu, \quad \eta_2 = E[x^2] = \sigma^2 + \mu^2.$$

$\{\eta_1, \eta_2\}$ : 混合パラメータ. ( $\nabla^{(-1)}$ -測地座標系)

## 離散標本空間

$$\Omega_n = \{x_0, x_1, \dots, x_n\}, \quad \dim S_n = n$$

$$p(x_i; \eta) = \begin{cases} \eta_i & (1 \leq i \leq n) \\ 1 - \sum_{j=1}^n \eta_j & (i = 0) \end{cases}$$

$$\Xi = \left\{ \{\eta_1, \dots, \eta_n\} \mid \eta_i > 0 \ (\forall i), \sum_{j=1}^n \eta_j < 1 \right\}$$

( $n$ -次元確率単体)

Fisher 計量:

$$(g_{ij}) = \frac{1}{\eta_0} \begin{pmatrix} 1 + \frac{\eta_0}{\eta_1} & 1 & \dots & 1 \\ 1 & 1 + \frac{\eta_0}{\eta_2} & & \vdots \\ \vdots & & \ddots & \vdots \\ 1 & \dots & \dots & 1 + \frac{\eta_0}{\eta_n} \end{pmatrix},$$

ただし  $\eta_0 = 1 - \sum_{j=1}^n \eta_j$ .

$(S$  は曲率  $\frac{1}{4}$  の定曲率空間 (半径 2 の球面)).

## 離散標本空間

$$\Omega_n = \{x_0, x_1, \dots, x_n\}, \quad \dim S_n = n$$

$$p(x_i; \eta) = \begin{cases} \eta_i & (1 \leq i \leq n) \\ 1 - \sum_{j=1}^n \eta_j & (i = 0) \end{cases}$$

$$\Xi = \left\{ \{\eta_1, \dots, \eta_n\} \mid \eta_i > 0 \ (\forall i), \sum_{j=1}^n \eta_j < 1 \right\}$$

( $n$ -次元確率単体)

$\{\theta^1, \dots, \theta^n\}$ : 自然パラメータ. ( $\nabla^{(1)}$ -測地座標系)

where  $\theta^i = \log \frac{\eta_i}{1 - \sum_{j=1}^n \eta_j} = \log \frac{p(x_i)}{p(x_0)}$ .

$\{\eta_1, \dots, \eta_n\}$ : 期待値パラメータ. ( $\nabla^{(-1)}$ -測地座標系)

## Bernoulli 分布族

$$\Omega = \{0, 1\}, n = 1, \xi = \eta.$$

$$C(x) = 0, \quad F(x) = x, \quad \theta = \log \frac{\eta}{1 - \eta},$$

$$\psi(\theta) = -\log(1 - \eta) = \log(1 + e^\theta)$$

確率分布は次のように表される.

$$p(x; \xi) = \eta^x (1 - \eta)^{1-x} = \exp [\log \eta^x (1 - \eta)^{1-x}]$$

$$= \exp [x\theta - \psi(\theta)].$$

これはベルヌーイ分布族が指数型分布族であることを意味している.  
期待値パラメータは次のように与えられる.

$$E[x] = 1 \cdot \eta + 0 \cdot (1 - \eta) = \eta$$

Fisher 計量は次となる.

$$g(\eta) = \frac{1}{\eta(1 - \eta)}$$

## 1.5 Markov 埋め込みと Chenstov の定理

定義 1.5 (Markov 埋め込み)

$S_n, S_l$ : 離散標本空間  $\Omega_n, \Omega_l$  上の確率分布全体 (確率単体) ( $1 \leq n \leq l$ )

このとき, 以下で構成される写像  $f : S_n \rightarrow S_l$  を **Markov 埋め込み** という.

$$(1) \Omega_l = \bigcup_{i=0}^n C_{(i)}$$

ただし  $C_{(i)} \subset \Omega_l$ ,  $C_{(i)} \neq \phi$ ,  $C_{(i)} \cap C_{(j)} = \phi$  ( $i, j = 0, 1, \dots, n$ )

(2)  $Q_{(j)} : \text{supp } Q_{(j)} = C_{(j)}$  となる  $\Omega_l$  上の確率分布 ( $j = 0, 1, \dots, n$ )

すなわち  $Q_{(j)} = (Q_{(j)}^0, Q_{(j)}^1, \dots, Q_{(j)}^l)$  とすると

$$Q_{(j)}^k > 0 \quad (x_k \in C_{(j)}), \quad Q_{(j)}^k = 0 \quad (x_k \notin C_{(j)})$$

(3)  $(y_0, y_1, \dots, y_l) = f(x_0, x_1, \dots, x_n)$  を以下で定義する

$$y_k := \sum_{j=0}^n x_j Q_{(j)}^k$$

要請

$S_n$  の幾何は  $S_l$  に埋め込まれた部分多様体  $f(S_n)$  の幾何と同等であるべき

## Chentsov の定理

定理 1.6 (Markov 埋め込み)

$S_n, S_l$ : 離散標本空間

$\{g^{[n]} : n \in \mathbb{N}\}$ :  $S_n$  上の  $(0, 2)$  型テンソル場  $g^{[n]}$  からなる列

$\{C^{[n]} : n \in \mathbb{N}\}$ :  $S_n$  上の  $(0, 3)$  型テンソル場  $C^{[n]}$  からなる列

$\implies$  任意の Markov 埋め込み  $f : S_n \rightarrow S_l$  に関する不変性

$$g_p^{[n]}(X, Y) = g_{f(p)}^{[l]}(f_*X, f_*Y)$$

$$C_p^{[n]}(X, Y, Z) = C_{f(p)}^{[l]}(f_*X, f_*Y, f_*Z)$$

を満たすものは、定数倍を除いて

$$g_p^{[n]}(X, Y) = \sum_{i=0}^n p_\xi(x_i) (X \log p_\xi(x_i) (Y \log p_\xi(x_i)))$$

$$C_p^{[n]}(X, Y, Z) = \sum_{i=0}^n p_\xi(x_i) (X \log p_\xi(x_i) (Y \log p_\xi(x_i)) (Z \log p_\xi(x_i)))$$

に限られる。

$(S, g^F, C^F)$  または  $(S, \nabla^{(\alpha)}, g^F)$  を **不変統計多様体** とよぶ。



## 2 統計多様体と双対平坦空間

### 2.1 曲率テンソル場, 捩率テンソル場

$R$ :  $\nabla$  の曲率テンソル場 (curvature tensor field)

$$R(X, Y)Z := \nabla_X \nabla_Y Z - \nabla_Y \nabla_X Z - \nabla_{[X, Y]} Z$$

$$[X, Y] := XY - YX = \sum_{i, j=1}^n \{ X^i (\partial_i Y^j) \partial_j - Y^j (\partial_j X^i) \partial_i \}$$

$$R_{kij}^l = \partial_i \Gamma_{jk}^l - \partial_j \Gamma_{ik}^l + \sum_{m=1}^n \Gamma_{im}^l \Gamma_{jk}^m - \sum_{m=1}^n \Gamma_{jm}^l \Gamma_{ik}^m$$

$$\sum_{l=1}^n R_{kij}^l \partial_l = R(\partial_i, \partial_j) \partial_k$$

$\partial_k$  を  $\partial_j$  方向に微小平行移動すると  $\partial_k \mapsto \partial_k + \sum_{l=1}^n \Gamma_{jk}^l \partial_l$  と変化する.

さらにこのベクトル場を  $\partial_i$  方向に微小平行移動すると, 全体の変化は

$$\partial_k \mapsto \partial_k + \sum_{l=1}^n \Gamma_{jk}^l \partial_l + \left\{ \sum_{l=1}^n \Gamma_{ik}^l \partial_l + \sum_{l=1}^n \left( (\partial_i \Gamma_{jk}^l) + \sum_{m=1}^n \Gamma_{im}^l \Gamma_{jk}^m \right) \partial_l \right\}$$


となる.  $\partial_i, \partial_j$  と平行移動の順序を入れ換え, 差を考えると曲率テンソル場となる.

$T : \nabla$  の捩率テンソル場 (torsion tensor field)

$$T(X, Y) := \nabla_X Y - \nabla_Y X - [X, Y]$$

$$[X, Y] := XY - YX = \sum_{i,j=1}^n \{ X^i (\partial_i Y^j) \partial_j - Y^j (\partial_j X^i) \partial_i \}$$

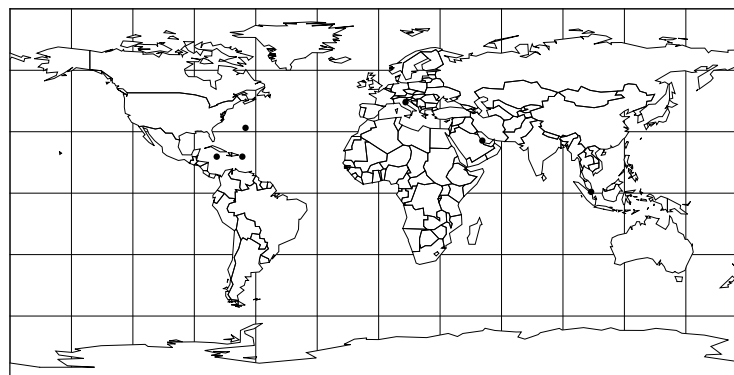
$$T_{ij}^k = \Gamma_{ij}^k - \Gamma_{ji}^k$$



球面に標準的に入る  
Riemann 計量から定まる  
Levi-Civita 接続を考える

$$R \neq 0, T = 0$$

(大円が測地線)



緯線と経線が測地線になるように  
アフィン接続を定める

$$R = 0, T \neq 0$$

## 2.2 統計多様体

 $M$  : 多様体 $h$  :  $M$  上の非退化  $(0, 2)$ -テンソル場 (気持ち:  $g$  と書くと Riemann 計量) $\nabla$  :  $M$  上のアファイン接続

## 定義 2.1

 $\nabla^*$ :  $\nabla$  の  $h$  に関する双対接続

$$\stackrel{\text{def}}{\iff} Xh(Y, Z) = h(\nabla_X Y, Z) + h(Y, \nabla_X^* Z).$$

以下  $h$  は対称 ( $h$ : semi-Riemannian),  $\nabla$  は捩れがない ( $T = 0$ ) と仮定

## 定義 1 (Kurose)

 $(M, \nabla, h)$  が統計多様体

$$\stackrel{\text{def}}{\iff} (\nabla_X h)(Y, Z) = (\nabla_Y h)(X, Z).$$

 $C(X, Y, Z) := (\nabla_X h)(Y, Z)$ , 3 次形式, Amari-Chentsov テンソル場 $(M, \nabla^*, h)$ :  $(M, \nabla, h)$  の双対統計多様体.

$$\nabla^{(0)} : h \text{ の Levi-Civita 接続} \iff \nabla^{(0)} = \frac{1}{2}(\nabla + \nabla^*)$$

注意 2.2 (Lauritzen による定義)

$(M, g)$  : Riemann 多様体

$C$  : 対称  $(0, 3)$ -テンソル場

$\implies (M, g, C)$  を **統計多様体** とよぶ.

命題 2.3

$(M, h)$  : 擬 Riemann 多様体

Levi-Civita 接続  $\nabla^{(0)}$  を持つ

$C$  : 対称  $(0, 3)$ -テンソル場

$$h(\nabla_X^{(\alpha)} Y, Z) := h(\nabla_X^{(0)} Y, Z) - \frac{\alpha}{2} C(X, Y, Z),$$

$$h(\nabla_X^{(-\alpha)} Y, Z) := h(\nabla_X^{(0)} Y, Z) + \frac{\alpha}{2} C(X, Y, Z),$$

$\implies$

(1)  $\nabla^{(\alpha)}$  と  $\nabla^{(-\alpha)}$  は互いに双対的な捩れのないアファイン接続

(2)  $\nabla^{(\alpha)} h$  と  $\nabla^{(-\alpha)} h$  は対称

$(M, \nabla^{(\alpha)}, h)$  と  $(M, \nabla^{(-\alpha)}, h)$  は統計多様体

## 2.3 双対平坦空間

$R : \nabla$  の曲率テンソル場

$$\implies h(R(X, Y)Z, V) + h(Z, R^*(X, Y)V) = 0$$

$\nabla$  が平坦  $\iff \nabla^*$  が平坦

$(M, h, \nabla, \nabla^*) : \text{双対平坦空間} \stackrel{\text{def}}{\iff} \nabla$  (と  $\nabla^*$ ) が平坦なアフィン接続

$\nabla$  が平坦なアフィン接続

$\implies M$  上の局所座標系  $\{\theta^1, \theta^2, \dots, \theta^n\}$  で次を満たすものが存在する.

$$\Gamma_{ij}^{\nabla k} \equiv 0$$

このような局所座標系  $\{\theta^i\}$  を **アフィン座標系** という.

$(M, h, \nabla, \nabla^*) : \text{双対平坦空間}$

$\implies \nabla^*$ -アフィン座標系  $\{\eta_i\}$  次を満たすものが存在する.

$$h\left(\frac{\partial}{\partial\theta^i}, \frac{\partial}{\partial\eta_j}\right) = \delta_i^j$$

$\{\eta_i\}$  を  $\nabla$  の  $h$  に関する **双対座標系** という

## 命題 2.4

$(M, h, \nabla, \nabla^*)$  : 双対平坦空間

$\{\theta^i\}$  :  $\nabla$ -アフィン座標系

$\{\eta_i\}$  :  $\{\theta^i\}$  の双対アフィン座標系

$\implies M$  上の関数  $\psi$  と  $\phi$  が存在して次が成り立つ

$$\frac{\partial \psi}{\partial \theta^i} = \eta_i, \quad \frac{\partial \phi}{\partial \eta_i} = \theta^i, \quad \psi(p) + \phi(p) - \sum_{i=1}^m \theta^i(p) \eta_i(p) = 0. \quad (3)$$

さらに次も成り立つ

$$h_{ij} = \frac{\partial^2 \psi}{\partial \theta^i \partial \theta^j}, \quad h^{ij} = \frac{\partial^2 \phi}{\partial \eta_i \partial \eta_j}, \quad (4)$$

ただし

$(h_{ij})$  : 擬 Riemann 計量  $h$  の成分行列

$(h^{ij})$  :  $(h_{ij})$  の逆行列

$\psi$  を  $\theta$ -ポテンシャル 関数,  $\phi$  を  $\eta$ -ポテンシャル 関数.

(3) の関係式を Legendre 変換とよぶ

$(M, \nabla, h)$ ,  $(M, \nabla^*, h)$  を Hesse 多様体とよぶ

## 命題 2.5

$(M, h, \nabla, \nabla^*)$  : 双対平坦空間

$\{\theta^i\}$  :  $\nabla$ -アフィン座標系

$\psi(\theta)$  :  $(M, h, \nabla, \nabla^*)$  の  $\theta$ -ポテンシャル関数

$M$  上の  $(0, 3)$ -テンソル場を次で定める

$$C_{ijk} = \frac{\partial^3 \psi}{\partial \theta^i \partial \theta^j \partial \theta^k}$$

このとき次が成り立つ.

$$h(\nabla_X Y, Z) = h(\nabla_X^{(0)} Y, Z) - \frac{1}{2} C(X, Y, Z),$$

$$h(\nabla_X^* Y, Z) = h(\nabla_X^{(0)} Y, Z) + \frac{1}{2} C(X, Y, Z)$$

ただし  $\nabla^{(0)}$  は  $h$  の Levi-Civita 接続である.

注意 2.6 3次形式から統計多様体を構成した場合と同じ

## 2.4 ダイバージェンスと拡張 Pythagoras の定理

## 正準ダイバージェンス

$(M, h, \nabla, \nabla^*)$  : 双対平坦空間

$\{\theta^i\}$  :  $\nabla$ -アファイン座標系

$\{\eta_i\}$  :  $\{\theta^i\}$  の双対アファイン座標系

$\psi$  :  $h$  の  $\theta$ -ポテンシャル

$\phi$  :  $h$  の  $\eta$ -ポテンシャル

このとき  $M \times M$  上の関数  $D$  が  $(M, h, \nabla, \nabla^*)$  の正準ダイバージェンス

$$\stackrel{\text{def}}{\iff} D(p, q) = \psi(p) + \phi(q) - \sum_{i=1}^n \theta^i(p) \eta_i(q)$$

$D$  を  $(M, h, \nabla, \nabla^*)$  の  $\nabla$ -ダイバージェンスともいう

$$D(p, q) : \nabla\text{-ダイバージェンス} \iff D(q, p) : \nabla^*\text{-ダイバージェンス}$$

命題 2.7 正準ダイバージェンス  $D$  はアファイン座標系の取り方に依存しない

$(\mathbb{R}^n, g^E, \nabla^E, \nabla^E)$ : (通常) Euclid 空間

$$D(p, q) = \frac{1}{2} \|p - q\|^2$$



## 拡張 Pythagoras の定理

### 定理 2.8

$(M, h, \nabla, \nabla^*)$  : 双対平坦空間


$p, q, r \in M$

$\gamma_1$  :  $p, q$  を結ぶ  $\nabla$ -測地線

$\gamma_2$  :  $q, r$  を結ぶ  $\nabla^*$ -測地線

$q$  において  $\gamma_1$  と  $\gamma_2$  が  $h$  に関して直交する

$$\implies D(p, r) = D(p, q) + D(q, r)$$



## 一般化した射影定理

### 定理 2.9

$(M, h, \nabla, \nabla^*)$  : 双対平坦空間

$S \subset M$  : 部分多様体

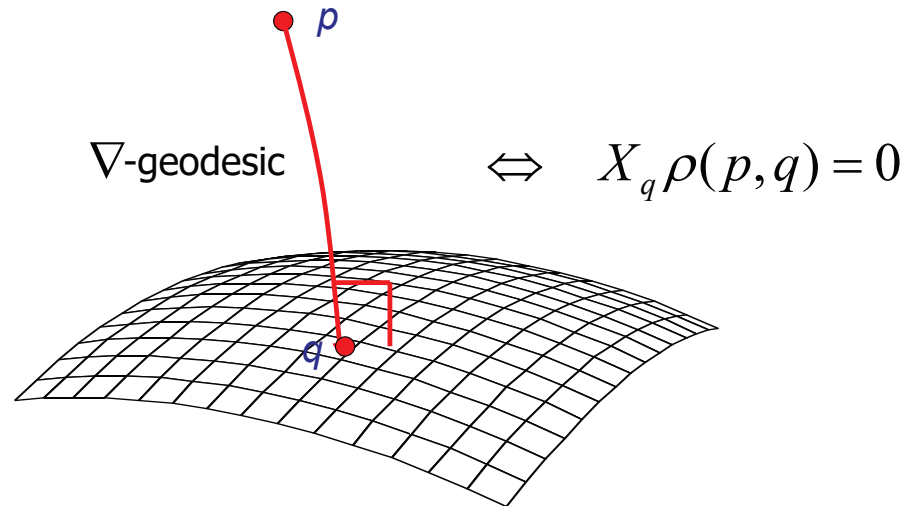
$p \in M, r \in S$

$D(p, r)$  :  $(M, h, \nabla, \nabla^*)$  の  $\nabla$ -ダイバージェンス

$p$  を固定し  $f(r) = D(p, r)$  によって  $S$  上の関数  $f$  を定める.

$f(r)$  が  $q \in S$  において停留点となる

$\iff q \in S$  において  $p, q$  を結ぶ  $\nabla$ -測地線が  $S$  と  $h$  に関して直交する



## 2.5 指数型分布族の幾何学

統計モデル  $S_e$  が **指数型分布族**

$$\stackrel{\text{def}}{\iff} S_e = \left\{ p(x; \theta) \mid p(x; \theta) = \exp\left[C(x) + \sum_{i=1}^n \theta^i F_i(x) - \psi(\theta)\right] \right\},$$

 $C, F_1, \dots, F_n$  :  $\Omega$  上の確率変数 $\psi$  : パラメータ空間  $\Theta$  上の関数 $\{\theta^i\}$  を **自然座標系** とよぶ.

命題 2.10 指数型分布族に対し次が成り立つ

(1)  $\nabla^{(1)}$  は平坦(2)  $\{\theta^i\}$  は  $\nabla^{(1)}$  に関するアファイン座標系, すなわち  $\Gamma_{ij}^{(1)k} \equiv 0$ 簡単のため  $C = 0$  を仮定する.

$$\begin{aligned} g_{ij}^F(\theta) &= E[(\partial_i \log p(x; \theta))(\partial_j \log p(x; \theta))] \\ &= E[-\partial_i \partial_j \log p(x; \theta)] = E[\partial_i \partial_j \psi(\theta)] \\ &= \partial_i \partial_j \psi(\theta) : \quad \text{Fisher 計量} \end{aligned}$$

$$\begin{aligned} C_{ijk}^F(\theta) &= E[(\partial_i \log p(x; \theta))(\partial_j \log p(x; \theta))(\partial_k \log p(x; \theta))] \\ &= \partial_i \partial_j \partial_k \psi(\theta) : \quad \text{3 次形式} \end{aligned}$$

 $(S_e, \nabla^{(e)}, g^F)$  と  $(S_e, \nabla^{(m)}, g^F)$  は **Hesse 多様体** である.

命題 2 指数型分布族  $S_e$  に対して以下が成り立つ.

- (1)  $(S_e, g^F, \nabla^{(e)}, \nabla^{(m)})$ : 双対平坦空間
- (2)  $\{\theta^i\}$ :  $S_e$  の  $\nabla^{(e)}$ -アファイン座標系
- (3)  $\psi(\theta)$ :  $\{\theta^i\}$  に関する  $g^F$  のポテンシャル

$$g_{ij}^F(\theta) = \partial_i \partial_j \psi(\theta), \quad (\partial_i = \partial / \partial \theta^i).$$

- (4) 確率変数  $F_i(x)$  の期待値を  $\eta_i = E_p[F_i(x)]$  とおく  
 $\implies \{\eta_i\}$  は  $\{\theta^i\}$  の  $g^F$  に関する双対座標系
- (5)  $\phi(\eta) = E_p[\log p(x; \theta)]$  とおく  
 $\implies \phi(\eta)$  は  $\{\eta_i\}$  に関する  $g^F$  のポテンシャルである.

$(S_e, g^F, \nabla^{(e)}, \nabla^{(m)})$  は双対平坦空間であるから, Legendre 変換も成り立つ.

$$\frac{\partial \psi}{\partial \theta^i} = \eta_i, \quad \frac{\partial \phi}{\partial \eta_i} = \theta^i, \quad \psi(p) + \phi(p) - \sum_{i=1}^m \theta^i(p) \eta_i(p) = 0$$

$$g_{ij}^F = \frac{\partial^2 \psi}{\partial \theta^i \partial \theta^j}, \quad C_{ijk}^F = \frac{\partial^3 \psi}{\partial \theta^i \partial \theta^j \partial \theta^k}$$

$S$  の **Kullback-Leibler ダイバージェンス** (または**相対エントロピー**)

$$\begin{aligned} \stackrel{\text{def}}{\iff} D_{KL}(p, r) &= \int_{\Omega} p(x) \log \frac{p(x)}{r(x)} dx \\ &= E_p[\log p(x) - \log r(x)] \\ & \left( = \psi(r) + \phi(p) - \sum_{i=1}^n \theta^i(r) \eta_i(p) = D(r, p) \right) \end{aligned}$$

指数型分布族  $S_e$  の場合,  $D_{KL}$  は平坦統計多様体  $(S_e, \nabla^{(m)}, g^F)$  のカノニカル・ダイバージェンスと一致する.

推定関数からのダイバージェンスの構成

$$s(x; \xi) = \begin{pmatrix} \partial / \partial \xi^1 \log p(x; \xi) \\ \vdots \\ \partial / \partial \xi^n \log p(x; \xi) \end{pmatrix} : p(x; \xi) \text{ のスコア関数 (推定関数)}$$

スコア関数をパラメータに関して積分し, 期待値を考える.

$$d_{KL}(p, r) := \int_{\Omega} p(x; \xi) \log r(x; \xi') dx \quad S \text{ のクロス・エントロピー}$$

クロス・エントロピーを用いて KL-ダイバージェンスは次で与えられる.

$$D_{KL}(p, r) = d_{KL}(p, p) - d_{KL}(p, r)$$

### 3 最尤推定量の幾何学

$S = \{p(x; \xi) | \xi \in \Xi\}$  : 統計モデル

$\{x_1, \dots, x_N\}$  :  $p(x; \xi) \in S$  から得られる  $N$ -個の観測値

$L(\xi)$  : 尤度関数

$$\begin{aligned} &\stackrel{\text{def}}{\iff} L(\xi) = p(x_1; \xi)p(x_2; \xi) \cdots p(x_N; \xi) \\ &\left( \iff \log L(\xi) = \sum_{i=1}^N \log p(x_i; \xi) \right) \end{aligned}$$

$\hat{\xi}$  : 最尤推定量

$$\stackrel{\text{def}}{\iff} \hat{\xi} = \arg \max_{\xi \in \Xi} L(\xi) \quad \left( = \arg \max_{\xi \in \Xi} \log p(x; \xi) \right).$$

尤度最大  $\iff$  KL-ダイバージェンス最小

$S$  : 指数型分布族

$M$  :  $S$  の曲指数型分布族 ( $S$  の部分多様体)

$\{x_1, \dots, x_N\}$  :  $p(x; u) = p(x; \theta(u)) \in M$  からの  $N$  個の観測値

尤度関数は次で計算される :

$$\begin{aligned}\log L(u) &= \sum_{j=1}^N \log(x_j; u) = \sum_{j=1}^N \left\{ \sum_{i=1}^n \theta^i(u) F_i(x_j) - \psi(\theta(u)) \right\} \\ &= \sum_{i=1}^n \theta^i(u) \sum_{j=1}^N F_i(x_j) - N\psi(\theta(u)).\end{aligned}$$

対数尤度方程式は

$$\partial_i \log L(u) = \sum_{j=1}^N F_i(x_j) - N\partial_i \psi(\theta(u)) = 0.$$

したがって,  $S$  の最尤推定量は次で与えられる.

$$\hat{\eta}_i = \frac{1}{N} \sum_{j=1}^N F_i(x_j).$$

一方 KL-ダイバージェンスは

$$\begin{aligned} D_{KL}(p(\hat{\eta}), p(\theta(u))) &= D(p(\theta(u)), p(\hat{\eta})) \\ &= \psi(\theta(u)) + \phi(\hat{\eta}) - \sum_{i=1}^n \theta^i(u) \hat{\eta}_i \\ &= \phi(\hat{\eta}) - \frac{1}{N} \log L(u). \end{aligned}$$

となる.

尤度最大  $\iff$  KL-ダイバージェンス最小



# 1 Deformed exponential family ( $\chi$ -exp. family)

$\chi : (0, \infty) \rightarrow (0, \infty) : \text{strictly increasing (a deformation function)}$

$\chi$ -exponential,  $\chi$ -logarithm

**Definition 1.1**

$$\frac{d}{dx} \exp_{\chi} x = \chi\{\exp_{\chi} x\}$$

$\chi$ -exponential

$$\log_{\chi} x := \int_1^x \frac{1}{\chi(t)} dt$$

$\chi$ -logarithm

We define a function  $\lambda$  by  $\lambda(\log_{\chi} t) = \chi(t)$

In the case  $\chi(t) = t$ ,  $\chi$ -exponential and  $\chi$ -logarithm recover the standard exponential and the standard logarithm.

**Example 1.2** *In the case  $\chi(t) = t^q$ , we have*

$$\int_1^x \frac{1}{\chi(t)} dt = \int_1^x \frac{1}{t^q} dt = \frac{x^{1-q} - 1}{1-q} = \log_q x \quad q\text{-logarithm}$$

$$\lambda(t) = (1 + (1-q)t)^{\frac{q}{1-q}}$$

$$1 + \int_0^x \lambda(t) dt = (1 + (1-q)x)^{\frac{1}{1-q}} \quad q\text{-exponential}$$

$\chi : (0, \infty) \rightarrow (0, \infty) : \text{strictly increasing (a deformation function)}$

$\chi$ -exponential,  $\chi$ -logarithm

**Definition 1.1**

$$\frac{d}{dx} \exp_{\chi} x = \chi\{\exp_{\chi} x\}$$

$\chi$ -exponential

$$\log_{\chi} x := \int_1^x \frac{1}{\chi(t)} dt$$

$\chi$ -logarithm

$F_1(x), \dots, F_n(x) : \text{functions on } \Omega$

$\theta = \{\theta^1, \dots, \theta^n\} : \text{parameters}$

$S = \left\{ p(x, \theta) \mid p(x; \theta) > 0, \int_{\Omega} p(x; \theta) dx = 1 \right\} : \text{statistical model}$

**Definition 1.4**

$S_{\chi} = \{p(x; \theta)\} : \chi$ -exponential family, deformed exponential family

$$\stackrel{\text{def}}{\iff} S_{\chi} := \left\{ p(x, \theta) \mid p(x; \theta) = \exp_{\chi} \left[ \sum_{i=1}^n \theta^i F_i(x) - \psi(\theta) \right], p(x, \theta) \in S \right\}$$

$S_q$ :  $q$ -exponential family when the deformed exponential is  $\exp_q$ .

**Example 1.5** (Student  $t$ -distribution ( $q$ -normal distribution))

$\Omega = \mathbb{R}$ ,  $n = 2$ ,  $\xi = (\mu, \sigma) \in \mathbb{R}_+^2$  (the upper half plane),  $q > 1$ .

$$p(x; \mu, \sigma) = \frac{1}{z_q} \left[ 1 - \frac{1-q}{3-q} \frac{(x-\mu)^2}{\sigma^2} \right]^{\frac{1}{1-q}}$$

Set

$$\theta^1 = \frac{2}{3-q} z_q^{q-1} \cdot \frac{\mu}{\sigma^2}, \quad \theta^2 = -\frac{1}{3-q} z_q^{q-1} \cdot \frac{1}{\sigma^2}.$$

Then

$$\begin{aligned} \log_q p_q(x) &= \frac{1}{1-q} (p^{1-q} - 1) = \frac{1}{1-q} \left\{ \frac{1}{z_q^{1-q}} \left( 1 - \frac{1-q}{3-q} \frac{(x-\mu)^2}{\sigma^2} \right) - 1 \right\} \\ &= \frac{2\mu z_q^{q-1}}{(3-q)\sigma^2} x - \frac{z_q^{q-1}}{(3-q)\sigma^2} x^2 - \frac{z_q^{q-1}}{3-q} \cdot \frac{\mu^2}{\sigma^2} + \frac{z_q^{q-1} - 1}{1-q} \\ &= \theta^1 x + \theta^2 x^2 - \psi(\theta) \\ \psi(\theta) &= -\frac{(\theta^1)^2}{4\theta^2} - \frac{z_q^{q-1} - 1}{1-q} \end{aligned}$$

The set of Student  $t$ -distributions is a  $q$ -exponential family.

**Example 1.6 (discrete distributions)**

$$\Omega = \{x_0, x_1, \dots, x_n\}$$

$$S_n = \left\{ p(x; \eta) \mid \eta_i > 0, \sum_{i=0}^n \eta_i = 1, p(x; \eta) = \sum_{i=0}^n \eta_i \delta_i(x) \right\},$$

$$\eta_0 = 1 - \sum_{i=1}^n \eta_i$$

Set  $\theta^i = \log_{\chi} p(x_i) - \log_{\chi} p(x_0) = \log_{\chi} \eta_i - \log_{\chi} \eta_0$

Then

$$\begin{aligned} \log_{\chi} p(x) &= \log_{\chi} \left( \sum_{i=0}^n \eta_i \delta_i(x) \right) \\ &= \sum_{i=1}^n (\log_{\chi} \eta_i - \log_{\chi} \eta_0) \delta_i(x) + \log_{\chi}(\eta_0) \\ \psi(\theta) &= -\log_{\chi} \eta_0 \end{aligned}$$

The set of discrete distributions is a  $\chi$ -exponential family for any  $\chi$ .

## 2 Expectation functionals

Example 2.1 ( $q$ -normal distributions)


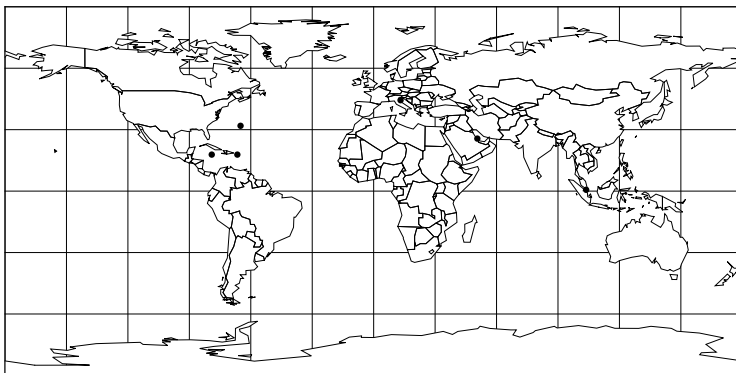
$$p(x; \mu, \sigma) = \frac{1}{z_q} \left[ 1 - \frac{1-q}{3-q} \frac{(x-\mu)^2}{\sigma^2} \right]_+^{\frac{1}{1-q}}$$

$q$	distribution	mean	variance
-1	semi-circle	○	○
1	normal	○	○
$1 + \frac{1}{n+1}$	student $t$	○	○
2	Cauchy	×	×

$q \geq \frac{5}{3}$   
 $V[X]$  does not exist.  
 $q \geq 2$   
 $E[X]$  does not exist.

Expectations give nothing but a local coordinate system.

⇒ It is better to choose a good local coordinate (expectations).



Local coordinates should be chosen to the purposes.

**Definition 2.2**

$P_\chi(x)$ ,  $P_\chi^{esc}(x)$  : an **escort distribution** and a **normalized escort distribution** of  $p(x)$

$$\stackrel{\text{def}}{\iff} P_\chi(x; \theta) = \chi(p(x; \theta)),$$

$$P_\chi^{esc}(x; \theta) = \frac{1}{Z_\chi(\theta)} \chi(p(x; \theta)), \quad Z_\chi(\theta) = \int_\Omega \chi(p(x; \theta)) dx$$

$E_{\chi,p}[f(x)]$  : the  **$\chi$ -canonical expectation** of  $f(x)$

$$\stackrel{\text{def}}{\iff} E_{\chi,p}[f(x)] = \int_\Omega f(x) P_\chi(x; \theta) dx = \int_\Omega f(x) \chi(p(x; \theta)) dx$$

$E_{\chi,p}^{esc}[f(x)]$  : the **normalized  $\chi$ -escort expectation** of  $f(x)$

$$\stackrel{\text{def}}{\iff} E_{\chi,p}^{esc}[f(x)] = \int_\Omega f(x) P_\chi^{esc}(x; \theta) dx = \frac{1}{Z_\chi(\theta)} \int_\Omega f(x) \chi(p(x; \theta)) dx$$

—  $\chi$ -exponential,  $\chi$ -logarithm —

$$\log_\chi x := \int_1^x \frac{1}{\chi(t)} dt$$

$\chi$ -logarithm

$$\exp_\chi x := 1 + \int_0^x \lambda(t) dt \quad (\text{where } \lambda(\log_\chi t) = \chi(t))$$

$\chi$ -exponential


## Why the escort expectation needs ?

$\mathcal{P}(\Omega)$ : the set of positive functions on  $\Omega$

$S$ : a statistical model

$$S = \left\{ p(x; \theta) \mid \int_{\Omega} p(x; \theta) dx = 1 \right\} \subset \mathcal{P}(\Omega)$$

Expectations should express the “embedding” of  $S$  into  $\mathcal{P}(\Omega)$



In the case of normal distributions,

$$\frac{\partial}{\partial \mu} \int_{-\infty}^{\infty} p(x; \mu, \sigma) dx = \int_{-\infty}^{\infty} \frac{(x - \mu)}{\sigma^2} p(x; \mu, \sigma) dx = 0$$

$$\frac{\partial}{\partial \sigma} \int_{-\infty}^{\infty} p(x; \mu, \sigma) dx = \int_{-\infty}^{\infty} \frac{(x - \mu)^2 - \sigma^2}{\sigma^3} p(x; \mu, \sigma) dx = 0$$

Therefore we obtain


$$E_p[X] = \mu, \quad E_p[(X - \mu)^2] = V_p[X] = \sigma^2$$

## In the case of $q$ -normal distributions

$$S_q = \left\{ p(x; \mu, \sigma) \mid p(x; \mu, \sigma) = \frac{1}{z_q} \left[ 1 - \frac{1-q}{3-q} \frac{(x-\mu)^2}{\sigma^2} \right]_+^{\frac{1}{1-q}} \right\}$$

$$S_q = \left\{ p(x; \theta) \mid \int_{\Omega} p(x; \theta) dx = 1 \right\} \subset \mathcal{P}(\Omega)$$

$$\begin{aligned} & \frac{\partial}{\partial \mu} \int_{-\infty}^{\infty} p(x; \mu, \sigma) dx \\ &= \frac{2(z_q)^{q-1}}{(3-q)\sigma^2} \int_{-\infty}^{\infty} (x-\mu) \{p(x; \mu, \sigma)\}^q dx \\ &= 0 \end{aligned}$$



Therefore we obtain

$$E_{q,p}^{esc}[X] = \frac{\int_{-\infty}^{\infty} x \{p(x; \mu, \sigma)\}^q dx}{\int_{-\infty}^{\infty} \{p(x; \mu, \sigma)\}^q dx} = \mu$$

(  $E_{q,p}^{esc}[(X - \mu)^2] = \sigma^2$  also holds. )



$\exp_{\chi}^{(m)}(x)$  : the  $m$ -th differential of deformed exponential function

**Definition 2.3** (Higher order escort distributions)

$P_{\chi,(m)}(x; \theta)$ ,  $P_{\chi,(m)}^{esc}(x; \theta)$  : the  **$m$ -th escort distribution** and the **normalized  $m$ -th escort distribution** of  $p(x; \theta)$

$$\stackrel{\text{def}}{\iff} P_{\chi,(m)}(x; \theta) = \exp_{\chi}^{(m)} \left[ \sum_{i=1}^n \theta^i F_i(x) - \Psi(\theta) \right],$$

$$P_{\chi,(m)}^{esc}(x; \theta) = \frac{1}{Z_{\chi,(m)}(\theta)} P_{\chi,(m)}(x; \theta), \quad Z_{\chi,(m)}(\theta) = \int_{\Omega} P_{\chi,(m)}(x; \theta) dx$$

$E_{\chi,(m),p}[f(x)]$  : the  **$m$ -th  $\chi$ -canonical expectation** of  $f(x)$

$$\stackrel{\text{def}}{\iff} E_{\chi,(m),p}[f(x)] = \int_{\Omega} f(x) P_{\chi,(m)}(x; \theta) dx$$

$E_{\chi,(m),p}^{esc}[f(x)]$  : the **normalized  $m$ -th  $\chi$ -escort expectation** of  $f(x)$

$$\stackrel{\text{def}}{\iff} E_{\chi,(m),p}^{esc}[f(x)] = \int_{\Omega} f(x) P_{\chi,(m)}^{esc}(x; \theta) dx$$

In the case of  $q$ -exponential family  $p_q \in S_q$ ,

$$P_{q,(m)}(x; \theta) := \{q(2q-1) \cdots ((m-1)q - (m-2))\} \{p_q(x; \theta)\}^{mq-(m-1)}$$

### 3 Geometry of deformed exponential families

$S_\chi$  : a deformed exponential family

$$\stackrel{\text{def}}{\iff} S_\chi := \left\{ p(x, \theta) \mid p(x; \theta) = \exp_\chi \left[ \sum_{i=1}^n \theta^i F_i(x) - \psi(\theta) \right], p(x, \theta) \in S \right\}$$

$P_{\chi, (m)}(x; \theta)$ : the  $m$ -th escort distribution of  $p(x; \theta) \in S_\chi$

**Definition 3.1** (A sequential structure of statistical manifolds)

$g^{(m)}$ :  **$m$ -th Riemannian metric**, and  $C^{(m)}$ :  **$m$ -th cubic form**

$$g_{ij}^{(m)}(\theta) := \int_{\Omega} (\partial_i \ln_\chi p_\theta)(\partial_j \ln_\chi p_\theta) P_{\chi, (m)}(x; \theta) dx,$$

$$C_{ijk}^{(m)}(\theta) = \int_{\Omega} (\partial_i \ln_\chi p_\theta)(\partial_j \ln_\chi p_\theta)(\partial_k \ln_\chi p_\theta) P_{\chi, (m+1)}(x; \theta) dx.$$

Then, we obtain statistical manifold structures

$$(S_\chi, g^{(1)}, C^{(1)}) \rightarrow (S_\chi, g^{(2)}, C^{(2)}) \rightarrow \dots \rightarrow (S_\chi, g^{(m)}, C^{(m)}) \rightarrow \dots$$

By setting  $\Gamma_{ij,k}^{(m)(e)} := \Gamma_{ij,k}^{(m)LC} - \frac{1}{2} C_{ijk}^{(m)}$ ,  $\Gamma_{ij,k}^{(m)(m)} := \Gamma_{ij,k}^{(m)LC} + \frac{1}{2} C_{ijk}^{(m)}$ ,

where  $\Gamma_{ij,k}^{(m)LC}$  is the connection coefficient of the Levi-Civita connection with respect to  $g^{(m)}$ , we obtain a pair of dual affine connections.

The first Riemannian metric for  $S_\chi$

$$\begin{aligned}
 g_{ij}^{(1)}(\theta) &= \int_{\Omega} \partial_i \ln_{\chi} p(x; \theta) \partial_j \ln_{\chi} p(x; \theta) P_{\chi}(x; \theta) dx \\
 &= E_{\chi, p}[(\partial_i \ln_{\chi} p_{\theta})(\partial_j \ln_{\chi} p_{\theta})] \leftarrow \chi\text{-canonical expectation} \\
 g_{ij}^M(\theta) &= \int_{\Omega} \partial_i p(x; \theta) \partial_j \ln_{\chi} p(x; \theta) dx \\
 g_{ij}^N(\theta) &= \int_{\Omega} \frac{1}{P_{\chi}(x; \theta)} \partial_i p(x; \theta) \partial_j p(x; \theta) dx
 \end{aligned}$$

**Theorem 3.2** For a deformed exponential family  $S_\chi$ ,

$$g_{ij}^{(1)}(\theta) = g_{ij}^M(\theta) = g_{ij}^N(\theta).$$

Dual affine connections  $\nabla^{(1)(e)}, \nabla^{(1)(m)}$ :

$$\begin{aligned}
 \Gamma_{ij,k}^{(1)(e)}(\theta) &= \int_{\Omega} \partial_k p(x; \theta) \partial_i \partial_j \ln_{\chi} p(x; \theta) dx \\
 \Gamma_{ij,k}^{(1)(m)}(\theta) &= \int_{\Omega} \partial_i \partial_j p(x; \theta) \partial_k \ln_{\chi} p(x; \theta) dx
 \end{aligned}$$

The quadruplet  $(S_\chi, g^{(1)}, \nabla^{(1)(e)}, \nabla^{(1)(m)})$  is a dually flat space.

## Construction of $\beta$ -divergence ( $\beta = 1 - q$ ) for $S_q$

$u_q(x; \theta)$ : a weighted score function

$$\begin{aligned} \stackrel{\text{def}}{\iff} u_q(x; \theta) &= (u_q^1(x; \theta), \dots, u_q^n(x; \theta))^T \\ u_q^i(x; \theta) &= p(x; \theta)^{1-q} s^i(x; \theta) - E_p[p(x; \theta)^{1-q} s^i(x; \theta)] \\ &= \frac{\partial}{\partial \theta^i} \ln_q p(x; \theta) - E_p \left[ \frac{\partial}{\partial \theta^i} \ln_q p(x; \theta) \right] \\ &\quad \text{generalized score function} \quad \text{bias correction} \end{aligned}$$

By integrating  $u_q(x; \theta)$ , we obtain the  $\beta$ -divergence ( $\beta = 1 - q$ ):

$$\begin{aligned} D_{1-q}(p, r) &= \frac{1}{(1-q)(2-q)} \int_{\Omega} p(x)^{2-q} dx \\ &\quad - \frac{1}{1-q} \int_{\Omega} p(x)r(x)^{1-q} dx + \frac{1}{2-q} \int_{\Omega} r(x)^{2-q} dx \end{aligned}$$

### Remark 3.3

$D_{1-q}$  induces a dually flat structure  $(S_q, g^{(1)}, \nabla^{(1)(m)}, \nabla^{(1)(e)})$ .

In the  $\chi$ -exponential case, it is known as a  $U$ -divergence.

The second Riemannian metric for  $S_\chi$

$$g_{ij}^{(2)}(\theta) = \int_{\Omega} \partial_i \ln_{\chi} p(x; \theta) \partial_j \ln_{\chi} p(x; \theta) P_{\chi, (2)}(x; \theta) dx$$

the second Riemannian metric

$$g_{ij}^{\chi}(\theta) = \partial_i \partial_j \psi(\theta) \quad (\leftarrow \chi\text{-Fisher metric})$$

**Theorem 3.4** *For a deformed exponential family  $S_\chi$ ,*

$$g_{ij}^{(2)}(\theta) = Z_{\chi, (1)}(\theta) g_{ij}^{\chi}(\theta),$$

$$\text{where } Z_{\chi, (1)} = \int_{\Omega} P_{\chi}(x; \theta) dx$$

$$C_{ijk}^{\chi}(\theta) = \partial_i \partial_j \partial_k \psi(\theta) \quad (\leftarrow \chi\text{-Fisher metric})$$

By setting

$$\Gamma_{ij,k}^{(\chi)(e)} := \Gamma_{ij,k}^{(\chi)LC} - \frac{1}{2} C_{ijk}^{(\chi)}, \quad \Gamma_{ij,k}^{(\chi)(m)} := \Gamma_{ij,k}^{(\chi)LC} + \frac{1}{2} C_{ijk}^{(\chi)},$$

where  $\Gamma_{ij,k}^{(\chi)LC}$  is the Levi-Civita connection with respect to  $g^{(\chi)}$

$\implies (S_\chi, g^\chi, \nabla^{\chi(e)}, \nabla^{\chi(m)})$  is a dually flat space.

However,  $(S_\chi, g^{(2)}, C^{(2)})$  may not define a dually flat structure.

## Construction of $\alpha$ -divergence ( $\alpha = 1 - 2q$ ) for $S_q$

$(s^q)(x; \theta) : q$ -score function

$$\begin{aligned} \stackrel{\text{def}}{\iff} \quad (s^q)(x; \theta) &= ((s^q)^1(x; \theta), \dots, (s^q)^n(x; \theta))^T \\ (s^q)^i(x; \theta) &= \frac{\partial}{\partial \theta^i} \ln_q p(x; \theta) \end{aligned}$$

A  $q$ -score function is unbiased w.r.t. the  $q$ -canonical expectation.

$$E_{q,p}[(s^q)^i(x; \theta)] = 0$$

$\implies$  We regard that  $s^q(x; \theta)$  is a generalization of estimating function.

By integrating  $s^q(x; \theta)$ , we obtain the  $\alpha$ -divergence ( $\alpha = 1 - 2q$ ):

$$\alpha\text{-divergence } (\alpha = 1 - 2q) \quad D^{(1-2q)}(p(x), r(x)) = \frac{1}{q} \int_{\Omega} p(x)^q \{ \ln_q p(x) - \ln_q r(x) \} dx$$

$D^{(1-2q)}$  induces a **non-flat** invariant statistical manifold  $(S_q, \nabla^{(1-2q)}, g^F)$ .

—  $\alpha$ -divergence ( $\alpha = 1 - 2q$ ) —

$$D^{(1-2q)}(p(x), r(x)) = \frac{1}{q} \int_{\Omega} p(x)^q \{\ln_q p(x) - \ln_q r(x)\} dx$$

$D^{(1-2q)}$  induces a **non-flat** invariant statistical manifold  $(S_q, \nabla^{(1-2q)}, g^F)$ , which coincides with  $(S_q, \nabla^{(2)(e)}, g^{(2)})$ .

— normalized Tsallis relative entropy ( $\chi$ -relative entropy) —

$$\begin{aligned} D^q(p(x), r(x)) &= E_{q,p}^{esc} [\ln_q p(x) - \ln_q r(x)] \\ &= \int_{\Omega} \frac{p(x)^q}{Z_q(p)} \{\ln_q p(x) - \ln_q r(x)\} dx \quad \left( = \frac{q}{Z_q(p)} D^{(1-2q)}(p, r) \right) \end{aligned}$$

$D^q$  induces a **dually flat structure**  $(S_q, g^q, \nabla^{q(e)}, \nabla^{q(m)})$ .

The difference is just a normalization  $Z_q(\theta)$ .

$\nu(x)$	$\xrightarrow{\times}$	$\frac{\nu(x)}{Z_q(\nu)}$	Normalization of a positive measure to a probability measure is NOT a trivial problem.
pos. measure		prob. measure	

## Summary

### Higher order escort distributions

$P_{\chi,(m)}(x; \theta)$ ,  $P_{\chi,(m)}^{esc}(x; \theta)$  : the  **$m$ -th escort distribution** and the **normalized  $m$ -th escort distribution** of  $p(x; \theta)$

$$\stackrel{\text{def}}{\iff} P_{\chi,(m)}(x; \theta) = \exp_{\chi}^{(m)} \left[ \sum_{i=1}^n \theta^i F_i(x) - \Psi(\theta) \right],$$

$$P_{\chi,(m)}^{esc}(x; \theta) = \frac{1}{Z_{\chi,(m)}(\theta)} P_{\chi,(m)}(x; \theta), \quad Z_{\chi,(m)}(\theta) = \int_{\Omega} P_{\chi,(m)}(x; \theta) dx$$

$E_{\chi,(m),p}[f(x)]$  : the  **$m$ -th  $\chi$ -canonical expectation** of  $f(x)$

$$\stackrel{\text{def}}{\iff} E_{\chi,(m),p}[f(x)] = \int_{\Omega} f(x) P_{\chi,(m)}(x; \theta) dx$$

$E_{\chi,(m),p}^{esc}[f(x)]$  : the **normalized  $m$ -th  $\chi$ -escort expectation** of  $f(x)$

$$\stackrel{\text{def}}{\iff} E_{\chi,(m),p}^{esc}[f(x)] = \int_{\Omega} f(x) P_{\chi,(m)}^{esc}(x; \theta) dx$$



First escort distribution  $(S_q, g^{(1)}, \nabla^{(1)(e)}, \nabla^{(1)(m)})$

Riemannian metric: 
$$g_{ij}^{(1)}(\theta) = \int_{\Omega} (\partial_i \ln_q p_{\theta})(\partial_j \ln_q p_{\theta}) P_q(\theta) dx$$

$(S_q, g^{(1)}, \nabla^{(1)(e)}, \nabla^{(1)(m)})$ : a **dually flat space**,  
which is induced from  **$\beta$ -divergence**.

Second escort distribution  $(S_q, g^{(2)}, \nabla^{(2)(e)}, \nabla^{(2)(m)})$

$$g_{ij}^{(2)}(\theta) = \int_{\Omega} (\partial_i \ln_q p_{\theta})(\partial_j \ln_q p_{\theta}) P_{q,(2)}(\theta) dx$$

$$= (1/q) \int_{\Omega} (\partial_i \ln p_{\theta})(\partial_j \ln p_{\theta}) p_{\theta} dx$$

$$= (1/q) g_{ij}^F(\theta) \quad ((\text{standard}) \text{ Fisher metric})$$

$(S_q, g^{(2)}, \nabla^{(2)(e)}, \nabla^{(2)(m)})$ : an **invariant statistical manifold structure**  
which is induced from  **$\alpha$ -divergence**.

### Future problem

The meaning of sequential structure is not clear at this moment.

$$(S_{\chi}, g^{(1)}, C^{(1)}) \rightarrow (S_{\chi}, g^{(2)}, C^{(2)}) \rightarrow \dots \rightarrow (S_{\chi}, g^{(m)}, C^{(m)}) \rightarrow \dots$$

Probably, projective equivalence of statistical manifolds is important for this problem.

## Markov 埋め込み

**Definition 3.5** (Markov 埋め込み)

$S_n, S_l$ : 離散標本空間  $\Omega_n, \Omega_l$  上の確率分布全体 (確率単体)  $(1 \leq n \leq l)$

このとき, 以下で構成される写像  $f : S_n \rightarrow S_l$  を **Markov 埋め込み** という.

(1)  $\Omega_l = \cup_{i=0}^n C_{(i)}$

ただし  $C_{(i)} \subset \Omega_l, C_{(i)} \neq \phi, C_{(i)} \cap C_{(j)} = \phi \quad (i, j = 0, 1, \dots, n)$

(2)  $Q_{(j)} : \text{supp } Q_{(j)} = C_{(j)}$  となる  $\Omega_l$  上の確率分布  $(j = 0, 1, \dots, n)$

すなわち  $Q_{(j)} = (Q_{(j)}^0, Q_{(j)}^1, \dots, Q_{(j)}^l)$  とすると

$$Q_{(j)}^k > 0 \quad (x_k \in C_{(j)}), \quad Q_{(j)}^k = 0 \quad (x_k \notin C_{(j)})$$

(3)  $(y_0, y_1, \dots, y_l) = f(x_0, x_1, \dots, x_n)$  を以下で定義する

$$y_k := \sum_{j=0}^n x_j Q_{(j)}^k$$

Tsallis 統計学では Markov 埋め込みの仮定は不自然?