


# Wasserstein 統計学に向けて 分布の形と変形

甘利俊一  
帝京大学先端総合研究機構

研究協力者 松田 孟留(東大計数、理研脳科学)

# 情報幾何とWasserstein幾何

確率分布族の空間






$$x \in \mathbb{R}^n$$

# 幾何学はどう違うのか

divergence  $D[p(x):q(x)]$

不変なdivergence : KL,  $\alpha$ , Hellinger  
輸送コスト : W-divergence



# 統計的推論

数理統計学 Fisher

推定、検定—統計科学 (Bayes)

情報幾何学

リーマン計量と双対接続

W幾何学:

輸送問題、物質輸送、非平衡熱力学

画像: クラスター、分類、重心 --- Cuturi

# 情報幾何とW幾何の統合

GSI (Geometric Science of Information)  
課題として掲げる

Amari-Karakida-Oizumi---regularized W幾何  
(Cuturi)

Li-Zhao理論、  
Wong理論(divergence空間上の輸送問題—双対幾何)

# W統計学----分布形と変形

推定

検定 (今泉他)

その他

consistency, efficiency

$x_1, x_2, \dots, x_n$


$$p_{emp}(x) = \frac{1}{n} \sum \delta(x - x_i)$$

$$\hat{\theta} = \operatorname{argmin} D[p_{emp}(x) : p(x, \theta)]$$

location-scale model

$$p(x, \theta) = \frac{1}{\sigma} f\left(\frac{x - \mu}{\sigma}\right)$$


# Divergence



不変なdivergence

$$D_{KL}[p(x) : q(x)] = \int p(x) \log \frac{p(x)}{q(x)} dx$$

W-divergence



$$D_W[p(x) : q(x)] = \min_{\pi} \int c(x, y) \pi(x, y) dx dy$$

$$\int \pi(x, y) dy = p(x)$$

$$\int \pi(x, y) dx = q(y)$$

$$c(x, y) = |x - y|^2$$

# Riemann計量

$$ds^2 = D[p(x) : p(x) + \delta p(x)]$$

$$ds^2 = \int \delta p(x) g \delta p(y) dx dy$$

$$ds^2 = \int \frac{(\delta p(x))^2}{p(x)} dx = E[(\delta \log p(x))^2]$$

$$ds^2 = - \int \delta p(x) (\Delta_p)^{-1} \delta p(x) dx$$

$$\Delta_p \Phi(x) = \nabla_x (p(x) \nabla_x \Phi(x))$$


$$\rho(x, t) : \rho(x, 0) = p(x), \rho(x, 1) = q(x)$$

$$D_W[p(x) : q(x)] = \inf \int_0^1 |\mathbf{v}(x, t)|^2 dt$$

$$\mathbf{v}(x, t) = \nabla_x \Phi(x, t) \quad \text{← 速度ポテンシャル}$$

連続の方程式

$$\dot{\rho}(x, t) + \operatorname{div}(\rho \mathbf{v}) = 0$$



# スコア関数（速度potential） 確率モデル

$$s_i(x, \theta) = g \circ \partial_i p(x, \theta) \quad \partial_i = \frac{\partial}{\partial \theta_i} \quad M = \{p(x, \theta)\}$$

$$s_i^F(x, \theta) = \frac{\partial_i p(x, \theta)}{p(x, \theta)} = \partial_i \log p(x, \theta)$$

$$s_i^W(x, \theta) = -\Delta_p[\partial_i p(x, \theta)]$$

$$\nabla_x \log p(x, \theta) \cdot \nabla_x s_i^W(x, \theta) + \nabla_x \cdot \nabla_x s_i^W(x, \theta) + \nabla_\theta \log p(x, \theta) = 0$$

$$E[s_i(x, \theta)] = 0$$

# スコア関数と計量

$$g_{ij}(\theta) = \langle s_i(x, \theta), g^{-1}s_j(x, \theta) \rangle$$

$$\langle a(x), b(x) \rangle = \int p(x) a(x) b(x) dx$$

$$g^F_{ij}(\theta) = \langle s_i(x, \theta), g^{-1}s_j(x, \theta) \rangle = \int p(x) s_i(x, \theta) s_j(x, \theta) dx$$

$$g^W_{ij}(\theta) = \langle s_i(x, \theta), g^{-1}s_j(x, \theta) \rangle = \int p(x) \partial_x s_i(x, \theta) \partial_x s_j(x, \theta) dx$$

# スコア関数と推定

推定関数

推定方程式

射影  
consistent,  
efficient:直交

$$E[s_i(x, \theta)] = 0$$


$$\sum_{j=1}^n s_i(x_j, \theta) = 0$$

$$E_{emp}[s_i(x, \theta)] = 0$$

観測データ

$x_1, \dots, x_n$

$$p_{emp}(x) = \frac{1}{n} \sum \delta(x - x_i)$$



# Cramer-Rao不等式—efficiency

$$Cov[\hat{\theta} - \theta] \geq \frac{1}{n} g_F^{-1}; \quad Cov[\hat{\theta}_F - \theta] \approx \frac{1}{n} g_F^{-1}$$

$$Cov_W[\hat{\theta} - \theta] \geq \frac{1}{n} g_W^{-1}; \quad Cov[\hat{\theta}_W - \theta] \approx \frac{1}{n} g_W^{-1}$$

$$Cov_W[\mathbf{T}(x)] = \int p(x) \nabla_x \mathbf{T}(x) \nabla_x \mathbf{T}(x)^T dx$$


# W-efficiencyの意味：波形安定性

$$x \rightarrow x' = x + n \quad n \sim r(n)$$

$$\theta \rightarrow \theta + d\theta$$

$$p(x') = \int p(x' - n)r(n)dn$$

$$Cov_W[d\theta] = \mathbf{n}^T Cov_W \mathbf{n}$$



# Affine-deformation model

標準波形の族  
 $\mathcal{F}_s = \{f_s(z)\}$

$$\int f(z) dz = 1$$

$$\int z f(z) dz = 0$$

$$\int z z^T f(z) dz = I$$

$$p(x, \theta) = \Lambda | f(\Lambda(x - \mu)) : M_f$$

$$z = \Lambda(x - \mu)$$

$$\Lambda = ODO^T$$


非等方的  
拡大縮小

$$\int f(x) dx = 1$$

$$\int x f(x) dx = \mu$$

$$\int x x^T f(x) dx = \Lambda^2 + \mu \mu^T$$


# 波形と変形：W-直交



$$\int \delta f(z) s_i^W(z, \theta) dz = 0$$


# 標準波形 $f$ の空間: 形と変形

波形の回転



$$\tilde{f} = f(Oz)$$

同形



# W-Score Functions

$$s_i^W(x, \theta) = -\tilde{\Delta}_p \partial_i p(x, \theta)$$

$$\partial_x \log p(x, \theta) \cdot \partial_x s_i^W(x, \theta) + \Delta s_i^W(x, \theta) + \partial_\theta \log p(x, \theta) = 0$$

# W-Score Functions $\propto$ の2次関数

$$s_{\Lambda}(\mathbf{x}, \Lambda, \mu) = -\frac{1}{2} \mathbf{x} \Lambda \mathbf{x} + c(\Lambda, \mu)$$

$$s_{\mu}(\mathbf{x}, \Lambda, \mu) = -\mathbf{x} + \mu$$


# W一推定量 $\hat{\theta}^w$

定理 W推定量は2次モーメント推定量である。

$$\hat{\mu} = \frac{1}{n} \sum x_i$$

$$\hat{\Lambda} = \frac{1}{n} \sum (x_i - \hat{\mu})(x_i - \hat{\mu})^T$$

# W-計量 : Euclidean




$$g_{ij}^W(\theta) = E[\partial_x s_i^W \cdot \partial_x s_j^W]$$

$$g^W = I \quad : \text{ユークリッド}$$

# 定理 ガウス分布波形 $f$

$$\hat{\theta}_F = \hat{\theta}_W$$

両者は一致し、ともに F-efficient,  
W-efficient.



# F の高次キュミュラント

$g^F(\theta) \cdots f$ に依存

$g^W(\theta) \cdots f$ に寄らない

$\hat{\theta}^W$ の情報量損失( efficiency )

高次の*cumulant*

# W統計学の建設に向けて

形の幾何、流れの幾何

Bayes統計学とWong理論  
exponential familyとpriorの空間

