

〔招待講演〕

セキュリティを考慮した2つの問題に対する 情報理論的解析について ～ Local Differential Privacyの下での パラメータ推定問題と、 プライバシーと有用性のトレードオフ問題 ～

電子情報通信学会 RCC・ISEC・IT・WBS合同研究会

2023年3月14日

齋藤 翔太（群馬大学）

本日の発表の概要



準備



Local Differential Privacyの下での パラメータ推定問題



プライバシーと有用性の トレードオフ問題

本講演では、


- (ϵ, δ) -local differential privacyの下でのパラメータ推定問題
- 有用性とプライバシーのトレードオフ問題

という二つの問題に対して、

- ◆ 問題設定
- ◆ 評価基準
- ◆ その評価基準のもとでの理論限界

を解説する。

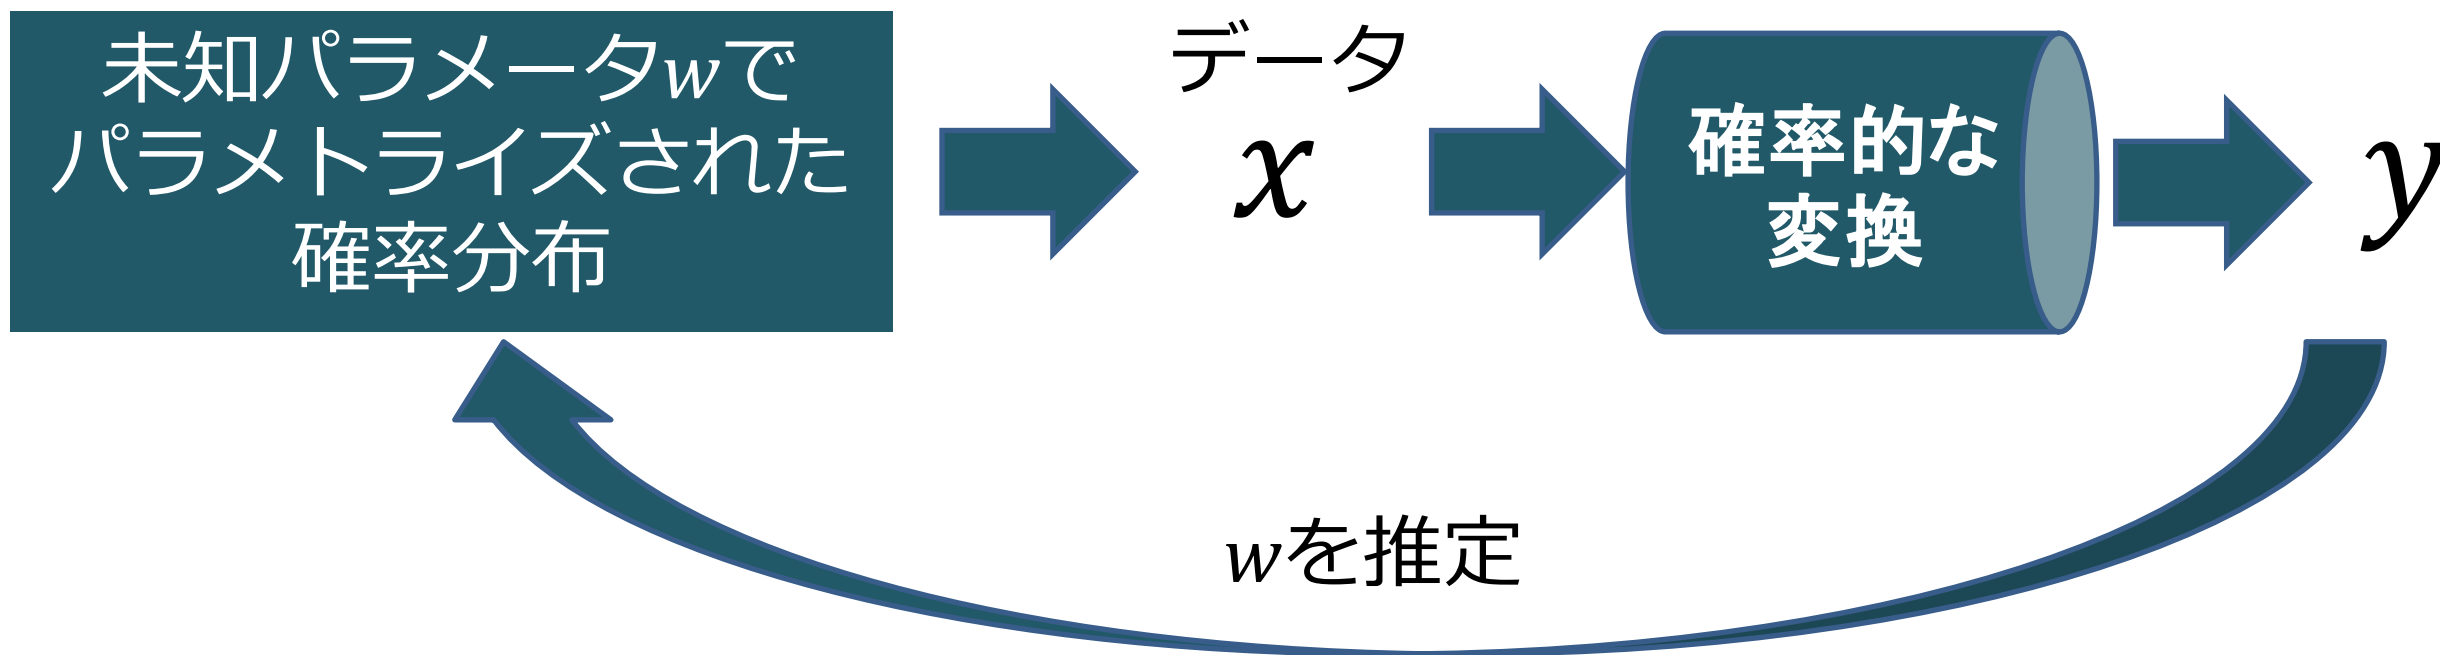
未知パラメータ w で
パラメトライズされた
確率分布



データ
 x



データ x から未知パラメータ w を推定する問題は、
統計学や機械学習等において基本的で重要な問題



データ x を確率的に変換したデータ y をもとに
未知パラメータ w を推定する問題を考える。

推定の良さを測る評価基準は？
その評価基準のもとで、理論限界は？



**有用性
(Utility)**



**プライバシー
(Privacy)**

数学的な定式化は？
情報理論的な評価は？

本日の発表の概要



準備



**Local Differential Privacyの下での
パラメータ推定問題**



**プライバシーと有用性の
トレードオフ問題**

準備①：ノーテーションに関する約束

準備②：○○ダイバージェンスと○○情報量

準備③：ランダム化メカニズム（通信路）

- 登場する確率変数は、すべて離散確率変数
- **確率変数**はアルファベットの**大文字**、その**実現値**は**小文字**で表す
- **花文字**でその確率変数が値をとる集合を表す

(例) 確率変数 A は集合 \mathcal{A} に値をとり、その実現値を $a \in \mathcal{A}$ と表す

- 確率変数 A の確率関数を $P_A(a)$ や $Q_A(a)$ 等と表し、
確率変数 A と確率変数 B の同時確率関数を $P_{A,B}(a, b)$ 、
条件付き確率関数を $P_{B|A}(b|a)$ 等と表記する
- 確率関数 $P_A(a)$ による期待値を $\mathbb{E}_{P_A}[\cdot]$ 等と表す


- $\log x$ と書いたら、 $\log_e x$ を表すとする (**自然対数**)

- 関数 f と書いたら、 $f(1) = 0$ を満たす下に凸な関数

$$f : [0, +\infty) \rightarrow \mathbb{R}$$

のことを指すものとする

(例) $f(x) = x \log x$



準備①：ノーテーションに関する約束

準備②：○○ダイバージェンスと○○情報量

準備③：ランダム化メカニズム（通信路）

確率関数 $P_A(a)$, $Q_A(a)$ に対する**KLダイバージェンス**

$$D(P_A \| Q_A) := \sum_{a \in \mathcal{A}} P_A(a) \log \frac{P_A(a)}{Q_A(a)}$$

確率変数 A と確率変数 B に対する**相互情報量**

$$I(A; B) := D(P_{A,B} \| P_A P_B)$$

相互情報量は、 A を知ることによって得た B の情報の量
(または B を知るによって得た A の情報の量) を表す

確率関数 $P_A(a)$, $Q_A(a)$ に対する f -ダイバージェンス

$$D_f(P_A \| Q_A) := \sum_{a \in \mathcal{A}} Q_A(a) f\left(\frac{P_A(a)}{Q_A(a)}\right)$$

$f(x) = x \log x$ とすると ...

$$D_f(P_A \| Q_A) = \sum_{a \in \mathcal{A}} P_A(a) \log \frac{P_A(a)}{Q_A(a)} = D(P_A \| Q_A)$$

f -ダイバージェンスは、KLダイバージェンスを一般化した量

確率変数 A と確率変数 B に対する f -informativity

$$I_f(A; B) := \inf_{Q_B} \sum_{a \in \mathcal{A}} P_A(a) D_f(P_{B|A=a} \| Q_B)$$

$f(x) = x \log x$ とすると ...

$$I_f(A; B) = \inf_{Q_B} \sum_{a \in \mathcal{A}} P_A(a) D(P_{B|A=a} \| Q_B) = I(A; B)$$

f -informativity は、相互情報量を一般化した量

準備①：ノーテーションに関する約束


準備②：○○ダイバージェンスと○○情報量

準備③：ランダム化メカニズム（通信路）

この後に述べる二つの問題では、データ X を確率的にデータ Y に変換するということを考える



これを **条件付き確率関数** $P_{Y|X}$ で表す



$P_{Y|X}$ は、**ランダム化メカニズム**と呼ばれたり、情報理論では**通信路**と呼ばれたりする

本日の発表の概要




準備



**Local Differential Privacyの下での
パラメータ推定問題**



**プライバシーと有用性の
トレードオフ問題**




\mathcal{W} : パラメータ空間

W : パラメータ空間 \mathcal{W} に値をとる確率変数

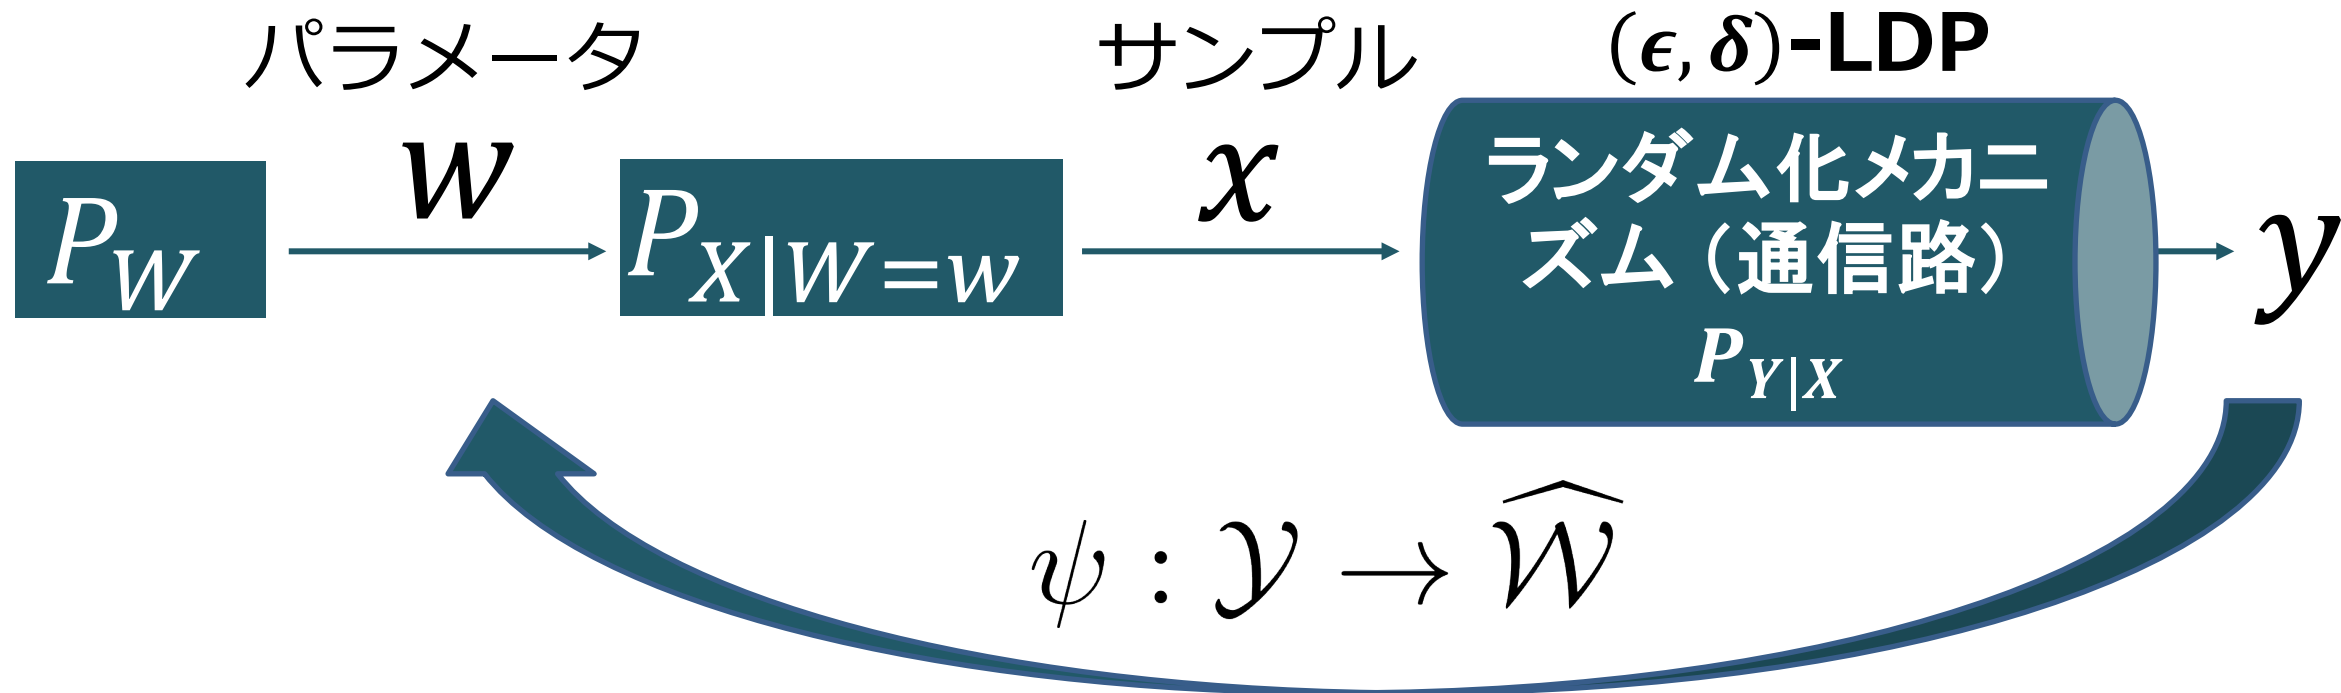
$W \sim P_W$ (←事前分布)

サンプル X は、パラメトライズされた分布 $P_{X|W=w}$ に従って発生する



(ϵ, δ) -局所差分プライバシー
 (ϵ, δ) -local differential privacy

➡ 以降では、 **(ϵ, δ) -LDP**と呼ぶ
詳細は後述



データ y から未知パラメータ w を推定量 $\psi : \mathcal{Y} \rightarrow \hat{\mathcal{W}}$ を用いて推定する

$\hat{\mathcal{W}}$ と \mathcal{W} は必ずしも一致していなくともよいとする

定義 ((ϵ, δ)-局所差分プライベート)

$\epsilon \geq 0$ と $\delta \in [0, 1]$ に対して、ランダム化メカニズム $P_{Y|X}$ が

$$\sup_{x, x' \in \mathcal{X}} \sup_{\mathcal{S} \subset \mathcal{Y}} \left[P_{Y|X}(\mathcal{S}|x) - e^\epsilon P_{Y|X}(\mathcal{S}|x') \right] \leq \delta$$

を満足するとき、(ϵ, δ)-局所差分プライベート ((ϵ, δ)-LDP) を満たすという。ここで、

$$P_{Y|X}(\mathcal{S}|x) = \sum_{y \in \mathcal{S}} P_{Y|X}(y|x)$$

である。

こちらの式について、少し考えてみる。

$$\sup_{x, x' \in \mathcal{X}} \sup_{\mathcal{S} \subset \mathcal{Y}} \left[P_{Y|X}(\mathcal{S}|x) - e^\epsilon P_{Y|X}(\mathcal{S}|x') \right] \leq \delta$$

簡単のため、 \sup を無視すると…

$$P_{Y|X}(\mathcal{S}|x) - e^\epsilon P_{Y|X}(\mathcal{S}|x') \leq \delta$$

$\delta = 0$ とすると...

$$P_{Y|X}(\mathcal{S}|x) - e^\epsilon P_{Y|X}(\mathcal{S}|x') \leq 0$$

$$\Leftrightarrow \log \frac{P_{Y|X}(\mathcal{S}|x)}{P_{Y|X}(\mathcal{S}|x')} \leq \epsilon$$

非負値損失関数 $\ell : \mathcal{W} \times \widehat{\mathcal{W}} \rightarrow \mathbb{R}^+$ と、 (ϵ, δ) -LDPを満たすランダム化メカニズム $P_{Y|X}$ が与えられたとき、**ベイズリスク** R_B は

$$\begin{aligned} R_B &:= \inf_{\psi} \mathbb{E}[\ell(W, \psi(Y))] \\ &= \inf_{\psi} \sum_{w \in \mathcal{W}} \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} \ell(w, \psi(y)) P_W(w) P_{X|W}(x|w) P_{Y|X}(y|x) \end{aligned}$$

ベイズリスク R_B は「平均的な損失の量」を表す。
そのため、ベイズリスクは小さいほうが嬉しいわけであるが、
どこまで小さくできるのだろうか？

定理 1 [Asoodeh et al., 2021 IEEE ISIT]

任意の $\rho > 0$ に対して、

$$R_B \geq \rho \left(1 - \frac{\varphi(\epsilon, \delta) I(W; X) + \log 2}{\log(1 / \sup_{\hat{w} \in \hat{\mathcal{W}}} \mathbb{P}[\ell(W, \hat{w}) \leq \rho])} \right)$$

が成り立つ。ここで、

$$\varphi(\epsilon, \delta) := 1 - (1 - \delta)e^{-\epsilon}$$

$$\mathbb{P}[\ell(W, \hat{w}) \leq \rho] = \sum_{\substack{w \in \mathcal{W}: \\ \ell(w, \hat{w}) \leq \rho}} P_W(w)$$

$$R_B \geq \rho \left(1 - \frac{\varphi(\epsilon, \delta) I(W; X) + \log 2}{\log(1 / \sup_{\hat{w} \in \hat{\mathcal{W}}} \mathbb{P}[\ell(W, \hat{w}) \leq \rho])} \right)$$

相互情報量 $I(W; X)$ は、サンプル X を知ることによって得られるパラメータ W の情報の量



直感的には、相互情報量 $I(W; X)$ が大きいほど、パラメータ推定が易しくなり、ベイズリスクは小さくなりそう



上式を見ると、 $I(W; X)$ が大きいほどベイズリスクの下界が小さくなることがわかる

$$R_B \geq \rho \left(1 - \frac{\varphi(\epsilon, \delta) I(W; X) + \log 2}{\log(1 / \sup_{\hat{w} \in \hat{\mathcal{W}}} \mathbb{P}[\ell(W, \hat{w}) \leq \rho])} \right)$$

(ϵ, δ) -LDPのパラメータである ϵ と δ が小さくなると、プライバシーに関する制約が強くなり、パラメータ推定が難しくなるため、ベイズリスクは大きくなりそう

▼
 $\varphi(\epsilon, \delta)$ は ϵ と δ の非減少関数なので、 ϵ や δ を小さくすると、上式よりベイズリスクの下界が大きくなる

$$\varphi(\epsilon, \delta) := 1 - (1 - \delta)e^{-\epsilon}$$

$$R_B \geq \rho \left(1 - \frac{\varphi(\epsilon, \delta) I(W; X) + \log 2}{\log(1 / \sup_{\hat{w} \in \hat{\mathcal{W}}} \mathbb{P}[\ell(W, \hat{w}) \leq \rho])} \right)$$

$\sup_{\hat{w} \in \hat{\mathcal{W}}} \mathbb{P}[\ell(W, \hat{w}) \leq \rho]$ が大きければ、直感的にはパラメータ推定がやりやすく、ベイズリスクは小さくなりそう



上式より、 $\sup_{\hat{w} \in \hat{\mathcal{W}}} \mathbb{P}[\ell(W, \hat{w}) \leq \rho]$ が大きいほどベイズリスクの下界が小さくなることがわかる

先ほどの定理1の不等式

$$R_B \geq \rho \left(1 - \frac{\varphi(\epsilon, \delta) I(W; X) + \log 2}{\log(1 / \sup_{\hat{w} \in \widehat{\mathcal{W}}} \mathbb{P}[\ell(W, \hat{w}) \leq \rho])} \right)$$

は、マルコフの不等式に由来する。

非負値確率変数 A と任意の $\rho > 0$ に対して $\mathbb{E}[A] \geq \rho \mathbb{P}[A \geq \rho]$

一方で、マルコフの不等式によらずに
ベイズリスクの下界を導出することもできる

定理 3 [Saito, SITA2022]

$$R_B \geq \frac{1}{2} \sup \left\{ r > 0 : \sup_{\hat{w} \in \hat{\mathcal{W}}} \mathbb{P}[\ell(W, \hat{w}) < r] \right. \\ \left. < 1 - u_f \left(\varphi(\epsilon, \delta) I_f(W; X) \right) \right\}$$

ここで、 $u_f(x)$ は x の非減少関数（詳細は予稿を参照）

定理3において、 $f(x) = x \log x$ とおくと次の系が得られる。

系 1 [Saito, SITA2022]

$$R_B \geq \frac{1}{2} \sup \left\{ r > 0 : \sup_{\hat{w} \in \hat{\mathcal{W}}} \mathbb{P}[\ell(W, \hat{w}) < r] \right. \\ \left. < \frac{1}{2} - \frac{1}{2} \sqrt{1 - e^{-2\varphi(\epsilon, \delta) I(W; X)}} \right\}$$

- ベイズリスクの下界である系1は、定理3の一般公式のひとつの特別な場合にすぎない。しかしながら、簡単な例で数値実験をしてみると、定理に比べてタイトなバウンドになっている。
- 定理3において、関数 f として様々な設定を考えることで、ベイズリスクの下界に関する様々な結果が得られる。
例えば、 $f(x) = x^2 - 1$ とすればカイ2乗ダイバージェンスを用いたバウンドが得られ、 $f(x) = |x - 1|/2$ とすれば変動距離を用いたバウンドが得られる。

本日の発表の概要




準備



**Local Differential Privacyの下での
パラメータ推定問題**




**プライバシーと有用性の
トレードオフ問題**



**有用性
(Utility)**

トレードオフ


**プライバシー
(Privacy)**



有用性の評価基準： X と Y との間の歪み関数

$$d : \mathcal{X} \times \mathcal{Y} \rightarrow [0, +\infty)$$

「オリジナルデータ X と公開データ Y との間の違い」を表す



プライバシーの評価基準 : f -informativity

$$I_f(X; Y) = \inf_{Q_Y} \sum_{x \in \mathcal{X}} P_X(x) D_f(P_{Y|X=x} \| Q_Y)$$

公開データ Y を知ることによって得られるオリジナルデータ X の情報量 (情報漏洩量) を表す



有用性の評価基準
歪み関数
 $d(X, Y)$

Y と X の差異を測る



プライバシーの評価基準
 f -informativity
 $I_f(X; Y)$

Y を知ることによって
得た X の情報量を測る

歪み関数 $d(X, Y)$ に何らかの制約を課したもとで
ランダム化メカニズム $P_{Y|X}$ をいろいろ変えたとき、
情報漏洩量 f -informativityをどこまで小さくできるのか？

すなわち、

$$\inf_{P_{Y|X}} I_f(X; Y)$$

$d(X, Y)$ に関する何らかの制約式

の理論評価を考える

定理 4 [Liao et al., IEEE Trans. IT, 2019]

$$\inf_{\substack{P_{Y|X}: \\ \mathbb{P}[d(X,Y) > D] = 0}} I_f(X; Y) = f(0) +$$

$$\inf_{Q_Y} \mathbb{E}_{P_X} \left[Q_Y(B_D(X)) \left(f \left(\frac{1}{Q_Y(B_D(X))} \right) - f(0) \right) \right]$$

ここで、

$$B_D(x) := \{y \in \mathcal{Y} : d(x, y) \leq D\}$$

$$Q_Y(B_D(x)) := \sum_{y \in B_D(x)} Q_Y(y)$$

先ほどの定理4では、有用性に関する制約として

$$\mathbb{P}[d(X, Y) > D] = 0$$

を考えたが、この制約を少し緩くすることを考えてみる。
すなわち、 $\epsilon \in [0, 1)$ に対して、

$$\mathbb{P}[d(X, Y) > D] \leq \epsilon$$

という制約を考えると、結果はどのようなようになるであろうか？

この問題を考えるにあたり、以下の定義を導入する。

定義 [Kostina et al., IEEE Trans. IT, 2015]

確率変数 Z と $\epsilon \in [0, 1)$ に対して、 ϵ -cutoff random transformationを、次式で定義する。

$$\langle Z \rangle_\epsilon := \begin{cases} Z & \text{if } Z < \eta, \\ \eta & \text{if } Z = \eta \text{ (with prob. } 1 - \alpha), \\ 0 & \text{if } Z = \eta \text{ (with prob. } \alpha), \\ 0 & \text{otherwise,} \end{cases}$$

ここで、 $\eta \in \mathbb{R}$, $\alpha \in [0, 1)$ は、 $\mathbb{P}[Z > \eta] + \alpha\mathbb{P}[Z = \eta] = \epsilon$ から定まる。

定理5 [Saito & Matsushima, IEICE Trans., 2022]

$$\inf_{\substack{P_{Y|X}: \\ \mathbb{P}[d(X,Y) > D] \leq \epsilon}} I_f(X; Y) \leq$$

$$\inf_{Q_Y} \sum_{x \in \mathcal{X}: \left\langle \log \frac{1}{Q_Y(B_D(x))} \right\rangle_\epsilon > 0} P_X(x) \mathbb{E}_{Q_Y} \left[f \left(\frac{\mathbf{1}\{d(x, Y) \leq D\}}{Q_Y(B_D(x))} \right) \right]$$

ここで、 $\mathbf{1}\{\cdot\}$ はインディケーター関数を表す

定理5において、 $\epsilon = 0$ とすると

$$\inf_{\substack{P_{Y|X}: \\ \mathbb{P}[d(X,Y) > D] = 0}} I_f(X; Y) \leq f(0) +$$

$$\inf_{Q_Y} \mathbb{E}_{P_X} \left[Q_Y(B_D(X)) \left(f \left(\frac{1}{Q_Y(B_D(X))} \right) - f(0) \right) \right]$$

定理4を思い出せば、上式の不等号は実は等号であることがわかる
したがって、定理5の上界は、特別な場合にはタイトになっている

定理5において、 $f(x) = x \log x$ とおくと次の式が得られる。

$$\inf_{\substack{P_{Y|X}: \\ \mathbb{P}[d(X,Y) > D] \leq \epsilon}} I(X; Y) \leq \inf_{Q_Y} \mathbb{E}_{P_X} \left[\left\langle \log \frac{1}{Q_Y(B_D(X))} \right\rangle_{\epsilon} \right]$$

上式は、有歪み圧縮（非可逆圧縮）の研究におけるKostinaら [Kostina et al., IEEE Trans. IT, 2015]の結果と一致

このことから、本講演で考えているプライバシーと有用性のトレードオフ問題は、情報理論の有歪み圧縮と密接な関係があることがわかる

本講演では、

- (ϵ, δ) -local differential privacyの下でのパラメータ推定問題
- 有用性とプライバシーのトレードオフ問題

という二つの問題に対して、

- ◆ 問題設定
- ◆ 評価基準
- ◆ その評価基準のもとでの理論限界

を解説した。

私は、「**工学的操作の限界**」が「**数学的な量**」を用いて特徴付けられるということが、情報理論の面白さのひとつと考えています。

情報理論をよくご存じの方には、この面白さを再確認して頂き、情報理論にあまり詳しくない方には、この面白さが少しでも伝われば幸いです。

[Asoodeh et al., 2021 IEEE ISIT]

S. Asoodeh, M. Aliakbarpour, and F. P. Calmon, "Local differential privacy is equivalent to contraction of an f -divergence," in Proc. 2021 IEEE International Symposium on Information Theory (ISIT), Melbourne, Australia, pp.545--550, 2021.

[Kostina et al., IEEE Trans. IT, 2015]

V. Kostina, Y. Polyanskiy, and S. Verdú, "Variable-length compression allowing errors," IEEE Trans. Inf. Theory, vol. 61, no. 8, pp. 4316--4330, Aug. 2015.

[Liao et al., IEEE Trans. IT, 2019]

J. Liao, O. Kosut, L. Sankar, and F. P. Calmon, "Tunable measures for information leakage and applications to privacy-utility tradeoffs," IEEE Trans. Inf. Theory, vol. 65, no. 12, pp. 8043 -- 8066, Dec. 2019.

[Saito, IEEE ISIT2022]

S. Saito, "On meta-bound for lower bounds of Bayes risk," in Proc. 2022 IEEE International Symposium on Information Theory (ISIT), Espoo, Finland, pp. 3162--3167, 2022.

[Saito & Matsushima, IEICE Trans., 2022]

S. Saito and T. Matsushima, "Upper Bound on Privacy-Utility Tradeoff Allowing Positive Excess Distortion Probability," IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences, E105.A, no.3, pp.425--427, 2022.

[Saito, SITA2022]

S. Saito, "Lower Bound of Bayes Risk in Parameter Estimation under Local Differential Privacy," 第45回情報理論とその応用シンポジウム, 2022年.