

16章: 出力摂動によるデータプライバシーの確保 Chapter 16: Private Data Analysis via Output Perturbation

in *Aggarwal & Yu (Eds.): Privacy-preserving Data Mining*

担当: 鹿島 久嗣
東京大学
情報理工学研究所
数理情報学専攻

Some figures are borrowed from the book chapter, and
Nissim et al. "Smooth Sensitivity and Sampling in Private Data Analysis" in STOC'07




この章では、問い合わせに対するデータベースからの回答(出力)に摂動(ノイズ)を加えることで、データのプライバシーを守る方法を学びます

- 出力摂動によるデータプライバシー確保の枠組みは最近のPPDM業界で結構注目されているらしい
- とくに「差分プライバシー」という概念の導入によって、攻撃者の事前知識などに左右されずにプライバシー強度を(数学的に)議論できるところが関係者にウケているようだ
 - ただし、実用的にはまだ未知数
- そこで、この章では、その「差分プライバシー」の概念と、その枠組みにおけるプライバシーの実現方法を紹介する

背景 データベース問い合わせモデルにおけるデータのプライバシー確保

この章で考えるモデル:
ユーザ(敵)がデータベースに問い合わせを行う状況

- ユーザ(ここでは敵)が、信頼におけるデータベース(DB)に対して問い合わせを行う状況を考える
 - ユーザがDBに計算してほしい関数 f を渡す
 - DBは持っているデータ集合 \mathbf{x} に対する f の値を計算してユーザに返す

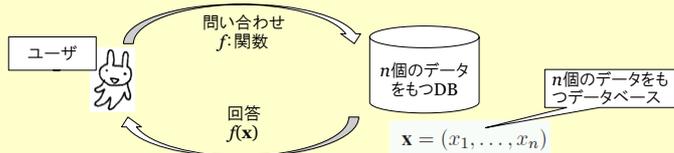


- 関数 f の具体例
 - 和の問い合わせ (Sum query): ある性質 g を満たすデータの数を数える

$$\text{sum}_g(\mathbf{x}) = \sum_{i=1}^n g(i, x_i) \text{ where } g : \mathbb{N} \times \mathcal{D} \rightarrow [0, 1]$$

達成したいこと:
DBは、ユーザの期待には応えつつも、データのプライバシーは守りたい

- 2つの相対する目標:
 - ユーザの期待には応えたい($f(x)$ は計算してあげたい)
 - データのプライバシーを守りたい(x についての情報は漏らしたくない)
- たとえば、 f として「 i 番目のデータの j 番目の次元を返す」などとすれば、データのプライバシーは完全に破られてしまう



5

THE UNIVERSITY OF TOKYO

実現のためのアイデア:
DBからの回答に、乱数による摂動を入れて返せばよいのではないか?

- 関数の値 $f(x)$ をそのまま返すのではなく、ランダム性のある摂動 Y を加えて返す(サンタイゼーション; 浄化)ことで、ユーザの要求とデータのプライバシーとを両立する
 - $f(x) \rightarrow f(x) + Y$ とする
 - たとえば、 Y は平均0、分散1の正規分布に従うなど
- 考えるべきこと:
 - どのような分布に従って Y を発生すればデータのプライバシーが守れるか?
 - ユーザの要求 (f の精度) には、どの程度応えられるか?



6

THE UNIVERSITY OF TOKYO

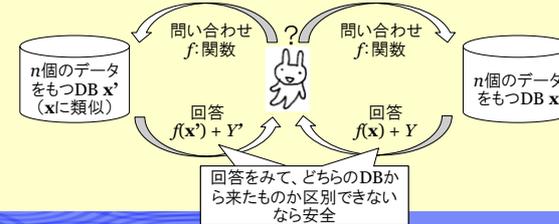
新しいプライバシーの強度指標
差分プライバシー

7

THE UNIVERSITY OF TOKYO

何をもちて“安全”とみなすか?:
良く似た別のDBの回答と区別できないならば“相対的に安全”であるとする

- ユーザの事前知識によって、プライバシーの強度はまちまちであるので、ある種の“相対的な”プライバシー強度を考える
- 「良く似た別のDBの回答と区別できないならば、(相対的に)安全」であるとする
 - いいかえれば「ユーザが回答をみたときに(自分のDBと別のDBの)どちらのDBからの回答か区別できないならば(相対的に)安全」
 - このDBが他のDBよりも多くプライベート情報を漏らすことはない、という気持ち
- 「良く似た」と「区別できない」はどのように定義できるだろうか?



8

THE UNIVERSITY OF TOKYO

「良く似た別のDB」の定義：
要素がひとつだけ異なるDB

- あるDBに対する「隣のDB」を定義するために、2つのDB間の距離を定義する
- 2つのDB \mathbf{x} と \mathbf{x}' の距離 $\text{dist}_H(\mathbf{x}, \mathbf{x}')$ は、異なる要素の数によって定義する

DEFINITION 16.4 (HAMMING DISTANCE, NEIGHBOR DATABASES)

$$\text{dist}_H(\mathbf{x}, \mathbf{x}') = |\{i : x_i \neq x'_i\}|$$

- $\mathbf{x}=\{1,2,3\}$ と $\mathbf{x}'=\{1,2\}$ の距離は1、 $\mathbf{x}=\{1,2,3\}$ と $\mathbf{x}'=\{1,2,4\}$ の距離も1
- 距離が1のDB同士を「隣接する」ということにする

差分プライバシー(differential privacy)：
ある答えが返ってくる確率が、良く似たDBとほぼ同じなら安全とする

- 「良く似た別のDBの回答と区別できないならば、(相対的に)安全」もしくは「ユーザが回答をみたときに(自分のDBと別のDBの)どちらのDBからの回答が区別できないならば(相対的に)安全」を数学的に表す
- 定義: ϵ -差分プライベート (ϵ はある正の小さい定数) であるとは、
 - あるDB \mathbf{x} から回答 $t = f(\mathbf{x})+Y$ が返ってくる確率を $h_{\mathbf{x}}(t)$
 - 隣のDB \mathbf{x}' から回答 $t = f(\mathbf{x}')+Y'$ が返ってくる確率を $h_{\mathbf{x}'}(t)$
 としたときに、2つのDBから同じ答え t が返ってくる確率の比が

$$\frac{h_{\mathbf{x}}(t)}{h_{\mathbf{x}'}(t)} \leq e^\epsilon \quad (\text{つまり、大体等しい})$$

- が、隣接する全てのDBペア $(\mathbf{x}, \mathbf{x}')$ について成立すること
- 書き換えると、 $\log h_{\mathbf{x}}(t) - \log h_{\mathbf{x}'}(t) \leq \epsilon$ ともいえる
- ϵ は小さいほど安全ということになる

差分プライバシーの重要な性質：
複数の ϵ -差分プライベートな関数を組合わせても、その性質は(ある程度)保たれる

- それぞれが ϵ -差分プライベートな、摂動操作(サニタイザー)が、 q 個あるとき、全体としては、 ϵq -差分プライベートになる
- ただし、摂動に使う確率変数は互いに独立であるとする

LEMMA 16.7 Let San_i be ϵ_i -private for $i = 1, \dots, q$. The sanitizer that answers according to $\text{San}_1, \dots, \text{San}_q$ (where the randomness of each sanitizer is chosen independently of the other sanitizers) is ϵ' -private for $\epsilon' = \sum_i \epsilon_i$.

proof:

$$\frac{\bar{h}_{\mathbf{x}}(t_1, \dots, t_q)}{\bar{h}_{\mathbf{x}'}(t_1, \dots, t_q)} = \frac{\prod_{i=1}^q h_{\mathbf{x}}^{(i)}(t_i)}{\prod_{i=1}^q h_{\mathbf{x}'}^{(i)}(t_i)} = \prod_{i=1}^q \frac{h_{\mathbf{x}}^{(i)}(t_i)}{h_{\mathbf{x}'}^{(i)}(t_i)} \leq e^{\sum_i \epsilon_i} = e^{\epsilon'}$$

差分プライバシーの実現
差分プライバシーを保つ摂動の設計

差分プライバシーを保つ摂動の設計:

ラプラス分布によって摂動を与えれば、差分プライバシーを実現できる

- 問: ϵ -差分プライバシーを実現するには、どのような摂動分布を考えればよいだろうか?
 - つまり、 $t = f(\mathbf{x}) + Y$ の Y の従う確率分布 $h(Y)$ をどのように定義すればよいか?
- こたえ: ラプラス分布を使えばよい
 - ラプラス分布は平均ゼロ、分散 $2\lambda^2$ の、正規分布よりも裾野の厚い分布

$$\text{Lap}(\lambda): h(t) = \frac{1}{2\lambda} e^{-\frac{|t|}{\lambda}}$$

- たとえば、和の問い合わせ (ある性質 g を満たすデータの数を数える) の場合、パラメータを $\lambda = 1/\epsilon$ とすればよい
 - ϵ を小さくしたいなら、摂動の分散を大きくしなければならない

差分プライバシーを保つ摂動の例:

ラプラス分布の摂動は、和の問い合わせに対して差分プライバシーを保証する

- 和の問い合わせ (Sum query): ある性質 g を満たすデータの数を数える

$$\text{sum}_g(\mathbf{x}) = \sum_{i=1}^n g(i, x_i) \text{ where } g: \mathbb{N} \times \mathcal{D} \rightarrow [0, 1]$$

- 摂動に使う確率分布 h をラプラス分布 $\text{Lap}(1/\epsilon)$ にすれば、 ϵ -差分プライベート
 - 証明: ラプラス分布であることが本質的に効いてくる (正規分布ではダメ)

$h_{\mathbf{x}}$: DB \mathbf{x} から回答 t が返ってくる確率

$$\frac{h_{\mathbf{x}}(t)}{h_{\mathbf{x}'}(t)} = \frac{h(t - f(\mathbf{x}))}{h(t - f(\mathbf{x}'))} \leq e^{\epsilon |f(\mathbf{x}) - f(\mathbf{x}')|} \leq e^{\epsilon}$$

h : 摂動に使う確率分布 (ラプラス)

$$\frac{h(t)}{h(t')} = \frac{e^{-\frac{|t|}{\lambda}}}{e^{-\frac{|t'|}{\lambda}}} = e^{\frac{|t'| - |t|}{\lambda}} \leq e^{\frac{|t - t'|}{\lambda}}$$

三角不等式より

ラプラス分布の定義より

$$\text{Lap}(\lambda): h(t) = \frac{1}{2\lambda} e^{-\frac{|t|}{\lambda}}$$

摂動に使うラプラス分布の幅の決定:

ラプラス分布の幅は (小さいほど良い) 大域的感度 (Global Sensitivity) によって決まる

- 前頁の結果を、和問い合わせ以外の場合に一般化する
- 大域的感度 (Global sensitivity): 隣接する全ての DB ペア $(\mathbf{x}, \mathbf{x}')$ に対する、関数 f の値の差の最大値

$$\text{GS}_f = \max_{\mathbf{x}, \mathbf{x}': \text{dist}_H(\mathbf{x}, \mathbf{x}') = 1} \|f(\mathbf{x}) - f(\mathbf{x}')\|_1$$

- たとえば、和問い合わせの場合、1 になる
- 定理: $t = f(\mathbf{x}) + Y$ の Y の従う確率分布 $h(Y)$ を $\text{Lap}(\text{GS}_f/\epsilon)$ にすれば ϵ -差分プライベートになる

差分プライバシーの実現例
差分プライバシーを保つことのできる関数の具体例

差分プライバシーを保つための条件:
大域的感度が小さければよい

- これまでの結果によれば、ある関数 f に対し、その大域的感度

$$GS_f = \max_{\mathbf{x}, \mathbf{x}': \text{dist}_H(\mathbf{x}, \mathbf{x}')=1} \|f(\mathbf{x}) - f(\mathbf{x}')\|_1$$

を計算できれば、その値を使ったラプラス分布 $\text{Lap}(GS_f/\epsilon)$ を使ってプライベート化できる

- ただし、大域的感度はある程度小さくないと、もともとの f の値を凌駕するほど大きな摂動を加えなければいけなくなる(=ユーザーの計算精度の要求を満たせない)
- では、どんな関数に対しては、小さな大域的感度が具体的に計算可能だろうか？
 - 和問合わせ(sum query)
 - 平均・共分散
 - ヒストグラム
 - 部分集合和(subset sum)
 - ...

17

THE UNIVERSITY OF TOKYO

小さな大域的感度が得られる関数の例:
和問合わせ、平均、分散、ヒストグラム、部分集合和、...

- では、どんな関数に対して大域的感度を具体的に計算可能だろうか？

- 和問合わせ(sum query): $GS_{\text{sum}} \leq 1$
- ベクトルの平均: $GS_{\text{mean}} \leq 2\gamma/n$
 - n 個あるベクトル(データ)のそれぞれの長さが γ 以下とすると、一個のデータの影響は大体 γ/n くらい
- 共分散: $GS_{\text{cov}} \leq 8\gamma^2/n$
 - ベクトルの長さが γ なら、分散の n 倍は、 γ^2 くらいの影響を受ける
- ヒストグラム: $GS_{\text{hist}} = 2$
 - どれかの箱に入っているデータを、別のところに移せば、2
- 部分集合和(subset sum): $GS_{\text{subsets}} = 4\gamma$
 - q はデータを k 個のグループに振り分ける関数

$$\text{subsets}_{q,g}(\mathbf{x}) = \left(\sum_{q(x_i)=1} g(x_i), \dots, \sum_{q(x_i)=k} g(x_i) \right)$$

18

THE UNIVERSITY OF TOKYO

小さな大域的感度が得られる学習アルゴリズムの例:
クラスタリング(k -平均クラスタリング法)

- k -平均クラスタリングのアルゴリズムの各ステップは

Modified k-Means Iteration:

Input: points $p_1, \dots, p_n \in \mathbb{R}^d$, and centers $c_1, \dots, c_k \in \mathbb{R}^d$.

- [Compute the number of points in each of the sets S_j]

$$(\bar{s}_1, \dots, \bar{s}_k) \leftarrow \text{hist}_q(p_1, \dots, p_n).$$

- [Compute the sum of points in each of the sets S_j]

$$(\bar{m}_1, \dots, \bar{m}_k) \leftarrow \text{subsets}_{q,g}(p_1, \dots, p_n).$$

- [Update each mean]
for $1 \leq j \leq k$:

$$\bar{c}_j \leftarrow \frac{\bar{m}_j}{\bar{s}_j}.$$

(DBが)データが各クラスタに何個づつ入るかを計算する(ヒストグラムで実装できる)

(DBが)各クラスタに入ったデータの和を計算する(部分集合和で実装できる)

(ユーザが)各クラスタに入ったデータの和を、個数で割って、平均(クラスタ中心)を計算する

- ヒストグラム、部分集合和、ともに大域的感度はすでに計算してあるので、これらに応じたラプラス分布を使って(ステップ1,2に)摂動を加えることで、 ϵ -差分プライベートにできる

- ステップ1: $\bar{s}_j = s_j + \hat{s}_j$, where $\hat{s}_j \sim (\text{Lap}(2/\epsilon'))^d$
- ステップ2: $\bar{m}_j = m_j + \hat{m}_j$, where $\hat{m}_j \sim (\text{Lap}(4\gamma/\epsilon'))^d$ where $\epsilon' = \epsilon/2$

19

THE UNIVERSITY OF TOKYO

ユーザーの計算精度に対する要求は満たされるか?:
計算すべき関数 f に対して小さい大域的感度が保たれる必要がある

- ユーザの欲しい γ の値を十分な精度で与えるためには、加える摂動の大きさは f のスケールと比較して十分に小さくしなければいけない
 - 摂動の大きさは、大域的感度 GS に従って決まる(概ね GS/ϵ くらいのスケールであると思つてよい)
- たとえば、
 - ヒストグラムでは、各箱に入るデータ数は、 $GS/\epsilon = 2/\epsilon$ よりも十分に大きい必要がある
 - 部分集合和では、各箱に入るデータ数と g の積は、 $GS/\epsilon = 4\gamma/\epsilon$ (γ は g の大きさ)よりも十分に大きい必要がある
- クラスタリング(ヒストグラムと部分集合和)の場合、各クラスタ(各箱)に入るデータの数が十分に大きければよい

20

THE UNIVERSITY OF TOKYO

小さな大域的感度が得られる学習アルゴリズムの例:
SVD(特異値分解)

- 特異値分解は、データの共分散行列の固有値問題を解く

SVD:

Input: The matrix $A \in \mathbb{R}^{d \times n}$ and a parameter $0 < k \leq n$.

1 [Approximate AA^T]

$$B \leftarrow \sum_i p_i p_i^T + Y \text{ where } Y \sim (\mathbf{Lap}(4\gamma^2))^{d \times d}.$$

(DBが) 共分散行列の各要素に摂動を加える

2 Compute the top k eigenvectors of B .

(ユーザが) 摂動の加わった行列の固有値問題を解く

- やはり、 n が大きければ、共分散は十分に正しく与えられる

21

THE UNIVERSITY OF TOKYO

一般的な結果:

統計的問い合わせ(statistical query)モデルは、差分プライバシー可能

不誠実

- 計算論的学習理論で用いられる統計的問い合わせ学習(statistical query learning)の枠組み
 - 統計的問い合わせ: ある性質 p を問い合わせると、 p を満たすデータの占める割合が、誤差 τ 以内で得られる
 - この問い合わせを使いながら、学習アルゴリズムはある関数を特定 (= 学習) する
 - 問い合わせの答えに誤差があっても学習できるような関数が、統計的問い合わせ学習可能ということになる
- ここで、統計的問い合わせは、摂動を入れた和問い合わせに似ていることに気付く
 - DBは、誤差(摂動)を入れることで、データのプライバシーを守る
 - ユーザは、誤差(摂動)のある問い合わせ結果から、所望の結果を得る
- 統計的問い合わせ学習可能な関数であれば、差分プライバシー可能ということになる

22

THE UNIVERSITY OF TOKYO

より多くの関数を安全にするために
局所的感度と平滑化感度

23

THE UNIVERSITY OF TOKYO

これまでの大域的感度を用いた議論が破綻する場合:

中央値の計算は大域的感度が大きくなるので、これまでの議論が使えない

- 0と1からなる集合の中央値の問い合わせを考えてみる
- この2つは、隣り合っているので、大域的感度は1になる

- {0, 0, 0, 1, 1, 1, 1}: 中央値 1
- {0, 0, 0, 0, 1, 1, 1}: 中央値 0

$$GS_f = \max_{\mathbf{x}, \mathbf{x}': \text{dist}_H(\mathbf{x}, \mathbf{x}')=1} \|f(\mathbf{x}) - f(\mathbf{x}')\|_1$$

- しかし、データの値域の幅も1なので、 $\text{Lap}(1/\epsilon)$ で摂動を入れると、大きすぎる

- そこで、データベースごとに異なる大きさの摂動を入れたいのでは? という気がしてくる

24

THE UNIVERSITY OF TOKYO

大域的感度が大きいときの対処法(失敗案):
データごとの摂動を入れるために「局所的感度」を定義する → やつぱりダメ

- これまで、全てのデータベースに対して、同じ確率分布を使って出力摂動を加えてきた
- しかし、一部の $(\mathbf{x}, \mathbf{x}')$ ペアが大域的感度を大きくしている

$$GS_f = \max_{\mathbf{x}, \mathbf{x}': \text{dist}_H(\mathbf{x}, \mathbf{x}')=1} \|f(\mathbf{x}) - f(\mathbf{x}')\|_1$$

- ならば、データベースごとに大きさの異なる摂動を入れたい気がする
- そこで、大域的感度から類推して、「局所的感度」を考えてみることにする

$$LS_f(\mathbf{x}) = \max_{\mathbf{x}': \text{dist}_H(\mathbf{x}, \mathbf{x}')=1} \|f(\mathbf{x}) - f(\mathbf{x}')\|_1$$

- 各 \mathbf{x} について定義されていることに注意
- 局所的感度を使って、 \mathbf{x} に対して摂動 $\text{Lap}(LS_f(\mathbf{x})/\epsilon)$ を入れれば、差分プライベート化可能だろうか? → 残念ながらNO
 - $LS_{\text{med}}(\mathbf{x}) = \max(x_{m+1} - x_m, x_m - x_{m-1})$: m はちょうど真ん中のインデックス
 - 中央値の例では、 $LS_{\text{med}}(\mathbf{x})=0$ (つまり分散0)となる \mathbf{x} がいくらでも作れる

大域的感度が大きいときの対処法(成功版):
データごとの摂動を入れるために「平滑化感度」を定義する → うまくいく

- 局所的感度ではうまくいかないの、次の「平滑化感度」を考えてみる(遠くまで見る)

$$S_f^*(\mathbf{x}) = \max_{\mathbf{x}' \in \mathcal{D}^n} \left(LS_f(\mathbf{x}') \cdot e^{-\epsilon \cdot \text{dist}_H(\mathbf{x}, \mathbf{x}')} \right)$$

局所的感度
距離とともに減衰

- 定理: $\text{Lap}(S_f^*(\mathbf{x})/\epsilon)$ による摂動は、 f を ϵ -差分プライベート化する
- 平滑化感度は、局所感度と大域的感度の間くらいのイメージ
 - $LS(\mathbf{x}) \leq S_f^*(\mathbf{x}) \leq GS(\mathbf{x})$
- いかにも計算がしにくそう...

$$LS_f(\mathbf{x}) = \max_{\mathbf{x}': \text{dist}_H(\mathbf{x}, \mathbf{x}')=1} \|f(\mathbf{x}) - f(\mathbf{x}')\|_1$$

平滑化感度の具体例:
平滑化感度の計算は自明ではないが、いくつかの場合でうまく計算できる

- 平滑化感度の計算

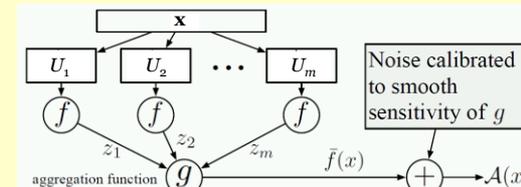
$$S_f^*(\mathbf{x}) = \max_{\mathbf{x}' \in \mathcal{D}^n} \left(LS_f(\mathbf{x}') \cdot e^{-\epsilon \cdot \text{dist}_H(\mathbf{x}, \mathbf{x}')} \right)$$

- 平滑化感度の計算は簡単ではないが、例えば、中央値の場合、比較的簡単に計算できる
 - \mathbf{x} からハミング距離 k 離れた \mathbf{x}' の $LS(\mathbf{x}')$ のなかで最大のものを $\max_{\mathbf{x}'} LS(\mathbf{x}')$ を計算してみる
 - k 個の要素を変えることで、中央値を k 個まで右か左にずらせる
 - 中央値は、 x_{m-k} から x_{m+k} の間まで持つ
 - $LS_{\text{med}}(\mathbf{x}) = \max(x_{m+1} - x_m, x_m - x_{m-1})$ を思い出すと、 $\max_{\mathbf{x}'} LS_{\text{med}}(\mathbf{x})$ は、 $\max(x_{m+1+k} - x_m, \dots, x_m - x_{m-1-k})$
 - 僕はこれをなんとなく理解するのに3日かかりました
 - $\max_{\mathbf{x}'} LS(\mathbf{x}')$ を全ての $k(\leq n)$ について計算すればOK
 - ほか、最小全域木(Minimum Spanning Tree)のコストなども計算できる

平滑化感度が計算できない時の方法:
標本抽出と集約による平滑化感度の近似

不誠実

- 一般の f では必ずしも平滑化感度が計算できるとは限らない
- 「標本中抽出と集約」の枠組み
 - \mathbf{x} から抽出したランダムな部分集合 $\{U_1, U_2, \dots\}$ に対し f の値を計算し、これらから関数 g (平滑化感度が計算できる、たとえば平均) によって f の近似値 $\tilde{f}(x)$ を求める
 - 何がよいか? → 話を g の平滑化感度にすり替える(イメージ)



サマリー：この章では、問い合わせに対するデータベースからの回答(出力)に外乱を加えることで、データのプライバシーを守る方法を学びました

- 良く似た別のDBの回答と区別できないならば“相対的に安全”であるとする「差分プライバシー」の概念を考えた
 - ユーザ(攻撃者)の知識に前提を置かないところがポイント
- 出力にどのような摂動を加えれば差分プライバシーが達成されるかを考えた
 - 答え：関数の取りうる値の幅に応じたラプラス分布を使えばよい
 - 大域的感度：隣り合ったDBに対する関数の差の最大値に応じた摂動を入れる
 - 平滑化感度：DBごとに異なった大きさの摂動を入れる
- 研究としては何ができるだろうか？
 - いろいろな関数に対する平滑化感度の計算：分散アルゴリズムをプライベート化すると同じ路線