

Sécurité Appliquée

Protection de la vie privée-PVP. TD4

Jean-François COUCHOT
couchot [arobase] femto-st [point] fr

12 décembre 2021

1 Confidentialité différentielle locale

On donne la définition suivante :

DÉFINITION 1.1 (ϵ -CONFIDENTIALITÉ DIFFÉRENTIELLE LOCALE). Soit \mathcal{X} un ensemble des valeurs possibles en entrée et $\epsilon \in \mathbb{R}^+$ un budget de fuite. \mathcal{M} est un algorithme probabiliste non déterministe qui respecte la ϵ -confidentialité différentielle locale si

$$\begin{aligned} \forall x_1, x_2 \in \mathcal{X} & \quad (x_1 \text{ et } x_2 \text{ deux données d'entrée}) \\ \forall r \text{ t.q. } r \in \mathcal{M}(\mathcal{X}), & \quad (\text{pour tte image de l'algo.}) \\ \Pr[\mathcal{M}(x_1) = r] \leq e^\epsilon \Pr[\mathcal{M}(x_2) = r] \end{aligned}$$

2 Application à l'algorithme de réponse randomisée

On considère la méthode de sondage¹ qui permet de répondre de manière "anonyme" à une question sur des données sensibles. On la particularise à la question suivante :

« Qui trouve ce cours ennuyeux² ? »

- Peu oseront dire OUI, même si c'est la vérité.
- Vous lancez une pièce 2 fois sans me montrer les résultats t_1 et t_2 :
 - Si c'est $t_1 = P$: si $t_2 = P$, vous annoncez NON, sinon OUI.
 - Si c'est $t_1 = F$: vous relancez la pièce et vous dites la vérité pour tout t_2 .

Exercice 2.1 (Code implantant le nettoyage de la réponse). Donner le code (3 lignes tout au plus) de la fonction `reponse_randomisee(rep_o)` qui prend en paramètre une réponse originale booléenne et qui retourne une réponse du même type selon l'algorithme donné ci-dessus.

Exercice 2.2 (Arbre de probabilité et estimation des réponses).

1. Construire l'arbre de probabilité associé à ce mécanisme.
2. On suppose que N personnes ont participé à ce sondage et que f est le nombre de personnes qui auraient voulu répondre OUI à la question posée. Quel est le nombre o de personnes qui devraient finalement fournir la réponse OUI à ce sondage après application de l'algorithme ci-dessus ?
3. En déduire une estimation \hat{f} du nombre de personnes qui auraient voulu répondre OUI.

Exercice 2.3 (Code implantant l'estimateur). Donner le code (3 lignes tout au plus) de la fonction `estimation_nbre_oui_initiaux(reps)` qui prend en paramètre la série de réponses nettoyées et retourne une estimation du nombre de OUI qui étaient présents initialement.

1. Warner, S. L. (1965). Randomized response : A survey technique for eliminating evasive answer bias. Journal of the American Statistical Association, 60(309), 63-69.

2. <http://www.lix.polytechnique.fr/catuscia/teaching/MPRI/19-20/lecture3.pdf>

Exercice 2.4 (Valeur de epsilon).

1. Pour $x \in \{True, False\}$ et $r \in \{True, False\}$, évaluer les quatre probabilités $\Pr[\mathcal{M}(x) = r]$.
2. Montrer alors que

$$\forall x_1, x_2 \in \mathcal{X}, \forall r \in \mathcal{M}(\mathcal{X}), \frac{\Pr[\mathcal{M}(x_1) = r]}{\Pr[\mathcal{M}(x_2) = r]} \leq 3.$$

3. En déduire que $\epsilon = \ln(3)$.
4. Trouver une formule qui donne la variance de \hat{f} . En discuter.