

# Sécurité Appliquée PVP. TD4

## Mécanismes pour la confidentialités différentielle locale

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

3 janvier 2023

### 1 Algorithme de réponse randomisée

On considère la méthode de sondage<sup>1</sup> qui permet de répondre de manière “anonyme” à une question sur des données sensibles.

#### Exercice 1.1 (Variance de l'estimateur).

1. On rappelle que la variance est définie comme la moyenne des carrés des écarts à la moyenne. Montrer que pour une VAR  $X$ ,  $\text{Var}[X] = E[X^2] - E[X]^2$ .
2. On considère un utilisateur dont la réponse originale à la question est OUI. Soit  $X$  la VAR qui vaut 1 si sa réponse randomisée est OUI et 0 sinon. Évaluer  $E[X]$ ,  $E[X^2]$ . En déduire que  $\text{Var}[X] = \delta_1(1 - \delta_1)$  avec  $\delta_1 = 3/4$ .
3. De manière similaire, on considère un utilisateur dont la réponse originale à la question est NON. Soit  $Y$  la VAR qui vaut 1 si sa réponse randomisée est OUI et 0 sinon. Montrer que  $\text{Var}[Y] = \delta_0(1 - \delta_0)$  avec  $\delta_0 = 1/4$ .
4. Soit  $R$  la VAR qui compte le nombre de réponses randomisées égales à OUI. Montrer que  $\text{Var}[R] = f \cdot \text{Var}[X] + (N - f) \cdot \text{Var}[Y]$ .
5. Montrer alors que  $\text{Var}[\hat{f}] = 4 \times \text{Var}[R] = \frac{3N}{4}$ . Discuter de cette variance.

### 2 Comparaison théorique entre $\text{Var}_{\text{Stair}}$ et $\text{Var}_{\text{Lb}}$

#### Exercice 2.1 (Etude du signe de la différence $\text{Var}_{\text{Lb}} - \text{Var}_{\text{Stair}}$ ).

On rappelle que  $\text{Var}_{\text{Lb}} = 2(\frac{\Delta}{\epsilon})^2$  et que  $\text{Var}_{\text{Stair}} = \Delta^2 \times \frac{2^{-2/3}e^{-2\epsilon/3}(1 + e^{-\epsilon})^{2/3} + e^{-\epsilon}}{(1 - e^{-\epsilon})^2}$

1. Pourquoi s'intéresse-t-on à ce signe ? Quelles sont les conséquences d'un signe toujours positif ?
2. Travailler avec ces deux fonctions de  $\epsilon$  n'est pas aisé. A lieu de cela, on comparera un autre indicateur de dispersion qu'est l'écart absolu moyen (EBM). On a  $\text{EBM}_{\text{Lb}} = \frac{\Delta}{\epsilon}$  et  $\text{EBM}_{\text{Stair}} = \Delta \frac{e^{\epsilon/2}}{e^{\epsilon} - 1}$ .  
Montrer qu'étudier le signe de  $\text{EBM}_{\text{Lb}} - \text{EBM}_{\text{Stair}}$  revient à étudier le signe de  $e^x - 1 - x \cdot e^{x/2}$  pour  $x \geq 0$ .
3. Etudier la dérivée de cette fonction. Conclure quant à cet indicateur de dispersion.

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.

### 3 Étude de GRR

On reprend dans cette partie l'algorithme GRR (transparent 12 du cours 4).

**Exercice 3.1.** On considère un ensemble de  $N$  personnes, chacune ayant une réponse personnelle dans  $\{v_1, \dots, v_k\}$ . Soit  $f_i$  le nombre de fois où la valeur  $v_i$  apparaît dans l'ensemble initial de réponses personnelles.

Soit  $r_i$  le nombre de fois où la valeur  $v_i$  apparaît dans l'ensemble obtenu après application du mécanisme  $\mathcal{M}_{GRR}$  à chaque réponse individuelle.

1. Montrer que  $\hat{f}_i$  défini par

$$\hat{f}_i = \frac{k-1+e^\epsilon}{e^\epsilon-1} r_i - \frac{N}{e^\epsilon-1} \quad (1)$$

est un estimateur de  $f_i$ .

2. Montrer que la variance de  $\hat{f}_i$ , notée  $\text{Var}[\hat{f}_i]$  est définie par

$$\text{Var}[\hat{f}_i] = \left( \frac{k-1+e^\epsilon}{e^\epsilon-1} \right)^2 \text{Var}[\hat{r}_i] \quad (2)$$

$$\text{Var}[\hat{r}_i] = f_i \times \delta_1(1-\delta_1) + (N-f_i) \times \delta_0(1-\delta_0) \quad (3)$$

$$\text{avec } \delta_1 = \frac{e^\epsilon}{k-1+e^\epsilon} \text{ et } \delta_0 = \frac{1}{k-1+e^\epsilon}$$