




# Génie Logiciel pour le Calcul Scientifique



#11

13/02/2025

jean-michel.batto@cea.fr

cea

[https://gogs.eldarsoft.com/M2\\_IHPS](https://gogs.eldarsoft.com/M2_IHPS)



- ❖ TD3 noté pour le 21/02/2024
- ❖ Dans [https://gogs.eldarsoft.com/M2\\_IHPS/GLCS-CM6-TDXMP](https://gogs.eldarsoft.com/M2_IHPS/GLCS-CM6-TDXMP)
- ❖ Nous avons vu le code XMP pour calculer un histogramme à partir d'un fichier txt.
- ❖ Le code est « pauvre », il ne donne pas un % par valeur
- ❖ Fichier input.txt // formaté avec 10 valeurs par ligne, sauf première ligne  
100 // le nombre de valeurs → pour allouer la mémoire  
1.0,2.0,3.0,4.0,5.0,6.0,7.0,8.0,9.0,10.0  
2.0,0.0,4.0,5.0,6.0,7.0,8.0,9.0,10.0,11.0  
3.0,4.0,5.0,6.0,7.0,8.0,9.0,10.0,11.0,12.0  
4.0,5.0,6.0,7.0,8.0,9.0,10.0,11.0,12.0,13.0



- ❖ Le problème : pour faire du benchmark, il faut un gros fichier.
  - ❖ Autre problème : comment permettre un travail individualisé ?
- avoir un générateur de fichier sur-mesure.

**skewseed** : An 8-digit number seed to skew the distribution of integer values.

**outputlinecount** : Number of lines in the output data set

randomhighint : Highest integer value for random data set

valueperline : Number of values per line

digitcountskew : The precision of the skew is determined by the number of digits (>10 and <300)

→ vous allez utiliser **skewseed** et y mettre votre matricule → change la distribution

→ **outputlinecount** est le paramètre à faire varier (20 millions est une limite du code histo.c dans son implémentation actuelle)

Vous ne changez pas les autres valeurs (éventuellement digitcountskew pour avoir un meilleur score d'histogramme)



- ❖ Dans un mode conteneurisé, l'espace d'allocation des ressources est finit.
- ❖ On peut « dissiper » de la puissance CPU par des optimisations inutiles.
- ❖ Par exemple, utiliser 4 nœuds MPI plutôt que 1.
- ❖ Par exemple, ne pas paralléliser (impact d'XMP, il y aussi ACC)
  
- ❖ Le code [https://gogs.eldarsoft.com/M2\\_IHPS/GLCS-CM6-TDXMP](https://gogs.eldarsoft.com/M2_IHPS/GLCS-CM6-TDXMP) est une base de travail. Il ne donne pas directement un histogramme de fréquences.



## ❖ Votre travail :

- ❖ Modifier le code histo.c pour y ajouter un chronomètre (attention au link). On veut pouvoir apprécier le temps de traitement de manière précise. Le code histo.c doit vous permettre de calculer un histogramme et de produire une figure pour votre rapport. Vous pouvez utiliser Excel ou un code à vous. Ne passez pas trop de temps sur cette partie.
- ❖ Tester différentes configurations (1 nœud, 2 nœuds, 4 nœuds)
- ❖ Vous allez choisir une configuration (2 nœuds, fichier 10 Millions) qui sera le gold standard. Lorsque vous changez de configuration, vous exprimez le gain en % par rapport au gold standard.
- ❖ Tester différentes optimisations du code avec une appréciation en fonction de la taille du fichier d'entrée (de combien il y a un impact).
- ❖ Me transmettre l'histogramme (il s'agit d'une figure avec la valeur des % d'occurrences, % écrit dans un tableau avec 4 décimales). Attention l'histogramme est dépendant du code matricule utilisé.

Quoi	Intérêt	Impact
Structure de la démarche bien présentée	On comprend le projet. SVP pas de blabla d'IA.	10%
Définition du problème, du concept de partage de la ressource	Les axes d'exploration sont présentés (effet abstraction réseau, coeurs, cache, saturation).	20%
Capacité à produire du code et à modifier le code pour illustrer la démarche	Le code remis doit être commenté. Il permet de vérifier la qualité du travail.	10%
Capacité à mettre en œuvre une IA	On voit l'utilisation d'un ou de plusieurs prompts.	10%
Diagrammes de benchmark	On s'attend à voir si une optimisation est sensible ou non à la taille du fichier d'entrée. Attention aux échelles.	20%
Dépassement du sujet	Capacité à reprendre le problème et à proposer un nouvel angle.	20%
Conclusion synthétique	Les points saillants sont exposés. SVP pas de blabla d'IA.	10%

**Dans la forge : votre rapport PDF sans matricule (je l'ai déjà), votre code source avec un README. Pas de fichiers input.txt ni output.txt. Pas de gros fichiers.**

- ❖ Introduction aux contraintes réglementaires sur les données personnelles (=survol)
- ❖ TD étude d'article : anonymisation / re-identification +K-anonymat
- ❖ Présentation d'un algorithme d'anonymisation
- ❖ RGPD

→ principe de l'homme de l'art : responsabilité

- ❖ La loi « Informatique et Libertés » 6 janvier 1978
- ❖ Modifié par Ordonnance n° 2018-1125 du 12 décembre 2018 - art. 1
- ❖ Article 1
- ❖ **L'informatique doit être au service de chaque citoyen. Son développement doit s'opérer dans le cadre de la coopération internationale. Elle ne doit porter atteinte ni à l'identité humaine, ni aux droits de l'homme, ni à la vie privée, ni aux libertés individuelles ou publiques.**

Les droits des personnes de décider et de contrôler les usages qui sont faits des données à caractère personnel les concernant et les obligations incombant aux personnes qui traitent ces données s'exercent dans le cadre du règlement (UE) 2016/679 du Parlement européen et du Conseil du 27 avril 2016, de la directive (UE) 2016/680 du Parlement européen et du Conseil du 27 avril 2016 et de la présente loi.



- ❖ La notion de donnée personnelle dans la loi « Informatique et Libertés »
- ❖ Constitue une donnée à caractère personnel toute information relative à une personne physique identifiée ou qui peut être identifiée, directement ou indirectement, par référence à un numéro d'identification ou à un ou plusieurs éléments qui lui sont propres. Pour déterminer si une personne est identifiable, il convient de considérer l'ensemble des moyens en vue de permettre son identification dont dispose ou auxquels peut avoir accès le responsable du traitement ou toute autre personne.
- ❖ Nom, prénom, adresse postale, e-mail, numéro de téléphone, adresse IP, adresse MAC, plaque d'immatriculation, numéro de sécurité sociale, ....



## La notion de donnée sensible

- ❖ Les données qui font apparaître, directement ou indirectement, les origines raciales ou ethniques, les opinions politiques, philosophiques ou religieuses ou l'appartenance syndicales des personnes.

Ou

- ❖ Les données qui sont relatives à la santé ou à la vie sexuelle de celles-ci



Les champs d'application de la loi « Informatique et Libertés »

- ❖ Traitement de données à caractère personnel
- ❖ Traitement automatisée des données (nominatives)
- ❖ Fichier de données à caractère personnel



- ❖ Les données de santé
- ❖ Définition par la jurisprudence.
  - ❖ Aspects physiques / psychiques de la santé d'une personne (par ex : handicap, fumeur, ...)
  - ❖ Des informations sur la consommation de drogues, de médicaments
  - ❖ Des informations sur la prestation de service de santé à cette personne



- ❖ Les données relatives à la santé ne sont accessibles qu'à des médecins
- ❖ Une personne non médecin ne peut accéder qu'à des données préalablement **anonymisées**
- ❖ Une distinction et une séparation des données :
  - ❖ Les données d'identification
  - ❖ Les données de résultats



Les organisations possèdent des données personnelles.

- Dans toutes les techniques d'anonymisation, il faut répondre aux questions suivantes :
  - i) Est-il toujours possible d'isoler un individu?
  - ii) Est-il toujours possible de relier entre eux les enregistrements relatifs à un individu?
  - iii) Peut-on déduire des informations concernant un individu?

## Identifiants

❖ Un attribut (ou ensemble d'attributs) qui identifie un enregistrement de façon unique, comme le nom, l'adresse mail.

## Quasi-identifiants (QID)

❖ Ce sont les attributs qui ne sont pas eux-mêmes des identifiants uniques, mais peuvent devenir identifiés lorsqu'ils sont combinés avec d'autres ensembles (par l'âge, le sexe ou l'adresse.)

## Attributs sensibles

❖ Ce sont les attributs que l'on veut conserver exemple le salaire, ou un état de maladie.

Name	ZipCode	Gender	Age	Disease
Jean	75275	Male	22	Flu
Alex	75278	Male	24	HIV+
Michel	75275	Male	27	Diabetes
Tony	75275	Male	42	HIV+
Sara	75278	Female	25	HIV+
Sandy	75278	Female	29	Diabetes
Lara	75277	Female	23	Cancer


**Identifiant**    **Quasi-identifiants**    **Attribut sensible**

## 1. Pseudonymisation

- Une clé d'identification qui permet d'établir le lien entre les différentes informations des personnes.
- Ces clés d'identification doivent être stockées de manière sécurisée.
- Réalisation très simple avec un algorithme naïf de cryptage ou hachage. (non réversible)
- La combinaison entre l'ensemble des attributs dans deux bases de données peut permettre de retrouver l'individu concerné (exemple de Sweeny).

### Sweeny

Etats-Unis en 2001  
Le croisement sur une base des données médicale pseudonymisée et une liste électorale avec des données nominatives.



**Relier les données**

## 2. Randomisation

- **Ajout de bruit** : modifier les valeurs des attributs dans l'ensemble de données pour les rendre moins précis.
- **Permutation** : mélanger les valeurs des attributs de telle sorte qu'on conserve la distribution exacte de chaque attribut dans l'ensemble de données.

## 3. Généralisation // agrégat autour d'une nouvelle classe d'équivalence

- **K-anonymat**

Name	ZipCode	Gender	Age	Disease
Jean	75275	Male	22	Flu
Alex	75278	Male	24	HIV+
Michel	75275	Male	27	Diabetes
Tony	75275	Male	42	HIV+
Sara	75278	Female	25	HIV+
Sandy	75278	Female	29	Diabetes
Lara	75277	Female	23	Cancer

Identifiant
Quasi-identifiants
Attribut sensible



Name	ZipCode	Gender	Age	Disease
X	7527*	Male	[20-29]	Flu
X	7527*	Male	[20-29]	HIV+
X	7527*	Male	[20-29]	Diabetes
X	7527*	Male	[40-49]	HIV+
X	7527*	Female	[20-29]	HIV+
X	7527*	Female	[20-29]	Diabetes
X	7527*	Female	[20-29]	Cancer

Un exemple d'un tableau de 3-anonymes



## 1. Le taux de suppression

- La quantité de suppression de toutes **les classes d'équivalence** qui sont plus petites que K, doit être inférieure à une limite définie par l'utilisateur.

$$\text{Le taux de Suppression} = \frac{\text{Le nombre des enregistrements supprimés}}{\text{Le nombre total des enregistrements.}}$$

## 2. La perte d'information // la disparition des « outliers »

## 3. La protection // la capacité à retrouver un individu ou à relier un groupe → pb des petites valeurs




Etude de paper1\_Sweeney L. Guaranteeing anonymity when sharing medical data The Datafly


- ❖ <https://dataprivacylab.org/datafly/index4.html>
- ❖ <http://dataprivacylab.org/datafly/paper4.pdf>
- ❖ [L. Sweeney](#) Guaranteeing anonymity when sharing medical data, the Datafly system. *Proceedings, Journal of the American Medical Informatics Association. (AMIA)*. Washington, DC: Hanley & Belfus, Inc., 1997.
  
- ❖ Mot anglais : Bin = corbeille
- ❖ 1/Quels sont les exemples de de-anonymisation cités dans l'article
- ❖ 2/Quelle est la taille des paquets d'information minimale pour des données de santé selon la recommandation citée dans l'article?
- ❖ 3/Quelle est l'approche scientifique de l'article ?

# Re-identification

**Netflix Prize data**  
**Dataset from Netflix's competition to improve their recommendation algorithm**  
 Netflix held the Netflix Prize open competition for the best algorithm to predict user ratings for films. The grand prize was \$1 000 000.




**Figure 2. For each  $X \leq 100$ , the number of subscribers with  $X$  ratings in the released dataset.**



Film :  
 Les Dames du Bois de Boulogne (1945)

Id netflix	score	date
2532865	4	2005-07-26
573364	3	2005-06-20
1696725	3	2004-02-27
1253431	3	2004-03-31
1265574	2	2003-09-01
1049643	1	2003-11-15
1601348	4	2005-04-05
1495289	5	2005-07-09
1254903	3	2003-09-02
2604070	3	2005-05-15
1006473	5	2005-05-23
1989892	3	2004-04-06
1517471	4	2003-12-24
1478381	4	2005-05-21
923084	2	2004-11-15
2446292	4	2005-10-06
2554745	3	2003-05-07
1133125	5	2004-08-10
349528	4	2003-08-11
1614895	5	2004-08-29
424958	4	2005-08-02
1390877	3	2003-10-07
2327422	4	2004-08-19
18103	3	2005-07-24
591075	4	2004-03-12





Etude de paper2\_shmat\_oak08netflix

Narayanan, V. Shmatikov. Robust De-anonymization of Large Sparse Datasets, or How to Break Anonymity of the Netflix Prize Dataset. S&P (Oakland) 2008.

[https://www.cs.utexas.edu/~shmat/shmat\\_oak08netflix.pdf](https://www.cs.utexas.edu/~shmat/shmat_oak08netflix.pdf)

1/Quel est l'enjeu de l'article ?

2/En 2005, que voulait faire Netflix ?


2/Page 3, quelle est l'observation qui permet l'approche de l'attaque ?

3/Page 8, pourquoi protéger son anonymat ?

4/Page 11, quels sont les enseignements de cet article sur l'anonymat des scores ?

## ❖ Distinction

$$Distinction = \frac{\text{Nombre de classes d'équivalences} \times 100}{\text{Nombre total d'enregistrements}}$$



- ❖ age-profession : 5 classes / 6 enregistrements = 83,3%
- ❖ profession : 1 classe / 6 enregistrements = 16,6%

- ❖ Approche systémique des attaques
- ❖ L'attaque du procureur
  - ❖ On connaît un individu est on veut extraire une information confidentielle
  - ❖ On veut re-identifier l'individu

QUASI-IDENTIFIERS			
ID	Gender	Decade of Birth	Test Result
1	Male	1950-1959	+ve
2	Male	1960-1969	-ve
4	Male	1950-1959	-ve
6	Female	1970-1979	-ve
7	Female	1960-1969	+ve
9	Male	1970-1979	-ve
10	Male	1970-1979	-ve
11	Female	1960-1969	-ve
12	Male	1950-1959	+ve
13	Female	1970-1979	-ve
14	Male	1960-1969	-ve




Equivalence class		Anonymized table	
Gender	Age	Count	Id
Male	1950-1959	3	1,4,12
Male	1960-1969	2	2,14
Male	1970-1979	2	9,10
Female	1960-1969	2	7,11
Female	1970-1979	2	6,13

- ❖ Par exemple la personne est née en 1955, 33% de chance d'être associée à un résultat du test

## ❖ L'attaque du journaliste :

❖ Par rapport à une liste connue, on cherche des individus



- ❖ Attaque du journaliste On anonymise
- ❖ Etape 1: Généraliser la base données d'identification

IDENTIFYING VARIABLE		QUASI-IDENTIFIERS	
ID	Name	Gender	Year of Birth
1	John Smith	Male	1959
2	Alin Smith	Male	1962
3	Alic Brown	Female	1955
4	Hercules Green	Male	1959
5	Alicia Freds	Female	1942
:			
:			
:			
30	Lisa Marie	Female	1988
31	Natasha Markhov	Female	1941



IDENTIFYING VARIABLE		QUASI-IDENTIFIERS	
ID	Name	Gender	Year of Birth
1	John Smith	Male	1950-1959
2	Alin Smith	Male	1960-1969
3	Alic Brown	Female	1950-1959
4	Hercules Green	Male	1950-1959
5	Alicia Freds	Female	1940-1949
:			
:			
:			
30	Lisa Marie	Female	1980-1989
31	Natasha Markhov	Female	1940-1949

- ❖ **Etape 2:** Calculer toutes les classes d'équivalences pour les données anonymisées.

- ❖ [1950-1979]

Equivalence Class		Anonymized table	
Gender	Age	Count	ID
Male	1950-1959	3	1, 4, 12
Male	1960-1969	2	2, 14
Male	1970-1979	2	9, 10
Female	1960-1969	2	7, 11
Female	1979-1979	2	6, 13

- ❖ **Etape 3:** Calculer toutes les classes d'équivalences pour les données d'identification généralisées (celles en possession du journaliste).

Equivalence Class		Public Database	
Gender	Age	Count	ID
Female	1940-1949	2	5, 31
Male	1950-1959	4	1, 4, 12, 27
Female	1950-1959	3	3, 28, 29
Male	1960-1969	5	2, 14, 15, 22, 26
Male	1970-1979	5	9, 10, 16, 20, 23
Female	1980-1989	2	8, 30
Female	1960-1969	5	7, 11, 18, 19, 21
Female	1970-1979	5	6, 13, 17, 24, 25

# ❖ Il s'agit de vérifier le risque

Equivalence Class		Anonymized table	
Gender	Age	Count	ID
Male	1950-1959	3	1, 4, 12
Male	1960-1969	2	2, 14
Male	1970-1979	2	9, 10
Female	1960-1969	2	7, 11
Female	1979-1979	2	6, 13



Equivalence Class		Public Database	
Gender	Age	Count	ID
Female	1940-1949	2	5, 31
Male	1950-1959	4	1, 4, 12, 27
Female	1950-1959	3	3, 28, 29
Male	1960-1969	5	2, 14, 15, 22, 26
Male	1970-1979	5	9, 10, 16, 20, 23
Female	1980-1989	2	8, 30
Female	1960-1969	5	7, 11, 18, 19, 21
Female	1979-1979	5	6, 13, 17, 24, 25

❖ Etape 5: On s'intéresse au plus grand risque de ré-identification.

Equivalence Class		Anonymized table		Public Database	
Gender	Age	Count	ID	Count	ID
Male	1950-1959	3	1, 4, 12	4	1, 4, 12, 27
Male	1960-1969	2	2, 14	5	2, 14, 15, 22, 26
Male	1970-1979	2	9, 10	5	9, 10, 16, 20, 23
Female	1960-1969	2	7, 11	5	7, 11, 18, 19, 21
Female	1979-1979	2	6, 13	5	6, 13, 17, 24, 25

- Le plus grand risque correspond à la plus petite classe d'équivalence des données publiques.
- Une probabilité (3/4) de ré-identifier une personne dans cette classe.


## ❖ L'attaque de commercialisation

Equivalence Class		Anonymized table		Public Database		Probability of match
Gender	Age	Count	ID	Count	ID	
Male	1950-1959	3	1, 4, 12	4	1, 4, 12, 27	3/4
Male	1960-1969	2	2, 14	5	2, 14, 15, 22, 26	2/5
Male	1970-1979	2	9, 10	5	9, 10, 16, 20, 23	2/5
Female	1960-1969	2	7, 11	5	7, 11, 18, 19, 21	2/5
Female	1979-1979	2	6, 13	5	6, 13, 17, 24, 25	2/5

- ❖ Est une extension de l'attaque du journaliste
- ❖ Ici 47% des enregistrements sont « ciblés »

## ❖ Comment anonymiser?

❖ Construire des classes d'équivalences (date, gender, age)





- ❖ Supposons qu'on a un attribut (a) avec un domaine  $D_a$  et  $V_a$ , le sous-ensemble des valeurs de a. La diversité de  $d(V_a)$  est calculée par :

$$da(V_a) = \begin{cases} \frac{\max(V_a) - \min(V_a)}{\max(D_a) - \min(D_a)} & \text{interval values} \\ \frac{|distinct(V_a)|}{|D_a|} & \text{discrete values} \end{cases}$$

- ❖ Telle que  $\max(V_a)$ ,  $\min(V_a)$ ,  $\max(D_a)$  et  $\min(D_a)$  sont les valeurs maximales et minimale dans  $V_a$  et  $D_a$  respectivement,  $|distinct(V_a)|$  c'est le nombre des valeurs uniques dans  $V_a$  et  $|D_a|$  la taille totale du domaine.
- ❖ Par conséquent, la diversité d'une classe d'équivalence ( $g_i$ ) qui consiste à plusieurs tuples  $\tau$ , est calculée par la suite :

$$dt(\tau, A) = \sum_{i=1}^m da(\pi_{a_i}(\tau))$$

- ❖ Ou  $|g_i| \geq k$  et  $\pi_{a_i}(\tau)$  est la diversité d'un attribut a appartient a QID ( $a_1, a_2 \dots a_m$ )
- ❖ Alors la moyenne de la diversité, de toute la classe d'équivalence, représente la perte des données dans un tableau T :
- ❖ **Utilité**  $= avg(dt(g_1, q), dt(g_2, q), \dots, dt(g_h, q))$
- ❖ Une petite valeur de cette mesure signifie que les tuples des classes sont proches, et donc les données anonymes peuvent être le plus utile.

## ❖ Protection sur les attributs sensibles

$$protection = avg\left(\frac{1}{dt(g_1, s)}, \frac{1}{dt(g_2, s)}, \dots, \frac{1}{dt(g_h, s)}\right)$$

## ❖ On peut donc avoir 2 contraintes :

- ❖ La diversité (utilité des enregistrements)
- ❖ La protection



## Application de la k-anonymisation

Nom	Age	Sport pratiqué	Membre
Jules	20	Billard	Ordinaire
Théo	23	Volley	Donateur
Alexis	28	Foot	Donateur
Eleo	30	Relais	Bienfaiteur
<b>Angela</b>	35	Saut en hauteur	Ordinaire
<b>Séraphine</b>	29	Tennis	Donateur
Inès	20	Billard	Emerite
Romain	20	Cricket	Ordinaire
Brigitte	42	Relais	D'honneur

Connaitre l'âge ou le sport, permet d'identifier (=QID)

La variable d'intérêt est le statut (Ordinaire / Donateur / Bienfaiteur / Emerite / D'honneur)

On veut faire de l'anonymisation par agrégat :  $k = 3$



Numéro id	Catégorie	Type de sport	Membre	
		Non		
1	<22	olympique	Ordinaire	€
2	22-29	Balle	Donateur	€€
3	22-29	Balle	Donateur	€€
4	>=30	Athlétisme	Bienfaiteur	€€€
5	>=30	Athlétisme	Ordinaire	€
6	22-29	Balle	Donateur	€€
		Non		
7	<22	olympique	Emerite	€€€€
		Non		
8	<22	olympique	Ordinaire	€
9	>=30	Athlétisme	D'honneur	0

→ 3 classes, avec 3 individus par classe,

pb il y a une classe qui a perdu la diversité (pas de 3-diversité)



Numéro id	Catégorie	Individuel /	
	Age	Collectif	Membre
1	<25	Individuel	Ordinaire
2	<25	Collectif	Donateur
3	>25	Collectif	Donateur
4	>25	Collectif	Bienfaiteur
5	>25	Individuel	Ordinaire
6	>25	Individuel	Donateur
7	<25	Individuel	Emerite
8	<25	Collectif	Ordinaire
9	>25	Collectif	D'honneur

En découpant autrement, avec 4 classes, on a :

**2-anonymité sur l'individu**


**2-diversité sur la variable d'intérêt**

- ❖ C'est un problème NP-Hard // *on donne une taille K*
- ❖ Il s'agit de faire des pavages sur K et de trouver un pavage optimal – « généralisation »
- ❖ Contraintes d'optimalité : suppression & protection
- ❖  **$\langle d_0, g_0, a_0 \rangle$  70% des enregistrements de la classe sont supprimés**

- ❖  **$\langle d_0, g_0, a_1 \rangle$  30%**
- ❖  **$\langle d_0, g_1, a_0 \rangle$  11%**

d : date, g : gender, a : age


- ❖ La protection est calculée pour chaque noeud



Nombre de dimensions décrites par le pavage →

❖  $\langle d_0, g_1, a_0 \rangle$  11% → 1 dimension perdue

❖ Toutes les dates, Personne (perte genre = 1 dimension), âge




# Optimal Lattice Anonymization


- ❖ Limite de Suppression = 5% -  
ratio distinction/protection = 0.6 pour un K donné (K=x).
- ❖ ➔ on ne veut pas faire disparaître plus de 5% de l'information pour une classe d'équivalence


- ❖ OLA = Optimal Lattice Anonymization


- ❖ Recherche binaire
- ❖ Tag prédictif





# ❖ Chaque nœud est en relation




























❖ 2 solutions pour 5%

❖ On veut maximiser la protection





La solution optimale



- ❖ Survol rapide de l'aspect réglementaire
- ❖ Les attaques peuvent se faire sur les QID / attributs sensibles
- ❖ Il y a différentes méthodes d'attaques
- ❖ L'anonymisation optimale est un problème difficile (NP-Hard)
- ❖ On peut faire des benchmarks sur la qualité du traitement en utilisant un oracle



## La protection de vos données est notre priorité

Notre site internet et les sociétés partenaires utilisent des cookies. Certains de ces cookies sont nécessaires au bon fonctionnement des sites du Groupe OVHcloud et ne peuvent être refusés. OVHcloud utilise d'autres cookies qui sont optionnels. [Plus d'informations :](#)

- Cookies de performance du site et de personnalisation

Si vous cliquez sur « Accepter », cette catégorie sera activée. Ces cookies ont pour finalité d'améliorer le fonctionnement de notre site, d'alimenter des services à valeur ajoutée et de sécuriser le site. Attention si toutefois vous décidez de les refuser, il se peut que votre expérience de navigation en soit limitée.

OVHcloud conserve votre choix pendant 13 mois. Vous pouvez changer d'avis à tout moment en cliquant sur [ce lien](#).

[Continuer sans accepter](#)

[Accepter](#)



- ❖ Le RGPD, mise en application le 25 mai 2018
- ❖ → Harmoniser le panorama juridique européen en matière de protection des données personnelles pour des personnes physiques.



- ❖ RÈGLEMENT (UE) 2016/679 DU PARLEMENT EUROPÉEN ET DU CONSEIL du 27 avril 2016
- ❖ Se découpe en 2 éléments :
  - ❖ Un règlement général qui couvre l'essentiel du traitement des données au sein de l'U.E.
  - ❖ Une directive sur la protection des données – non-étudiée



## Vision du RGPD par le comptage des mots

Mot	Occurences
pseudonymis*	15
profilage	22
amend*	23
secret	24
sécurité	57
santé	66
respect*	99
sous-trait*	441
contrôl*	519
responsab*	519
caractère	582
personnel*	588
données	841
traitement*	1111

Internet = 10 occurences

L'articulation des contrôles, des responsabilités et des sous-traitants



- ❖ S'applique pour les personnes physique dans l'U.E. pour des traitements hors U.E.
  - ❖ *Le traitement de données à caractère personnel de personnes concernées qui se trouvent dans l'Union par un responsable du traitement ou un sous-traitant qui n'est pas établi dans l'Union devrait également être soumis au présent règlement lorsque ledit traitement est lié au suivi du comportement de ces personnes dans la mesure où il s'agit de leur comportement au sein de l'Union. Afin de déterminer si une activité de traitement peut être considérée comme un suivi du comportement des personnes concernées, il y a lieu d'établir si les personnes physiques sont suivies sur internet, ce qui comprend l'utilisation ultérieure éventuelle de techniques de traitement des données à caractère personnel qui consistent en un **profilage d'une personne physique**, afin notamment de prendre des décisions la concernant ou d'analyser ou de prédire ses préférences, ses comportements et ses dispositions d'esprit.*



- ❖ La RGPD introduit « Privacy by design »
  - ❖ La protection de la vie privée doit être réalisée par des mesures techniques et organisationnelles adaptées au moment de la conception et lors de l'exécution du traitement.
  - ❖ Protection intégrée dans le cycle de vie de la technologie
  - ❖ Paramètres de respect de la vie privée dans les services et produits par défaut



- ❖ La RGPD introduit « Privacy by design »
  - ❖ La protection de la vie privée doit être réalisée par des mesures techniques et organisationnelles adaptées au moment de la conception et lors de l'exécution du traitement. → ie. GUID / Salt
  - ❖ Protection intégrée dans le cycle de vie de la technologie → ie. chiffrement https
  - ❖ Paramètres de respect de la vie privée dans les services et produits par défaut → ie. cookies traceurs doivent être approuvés



- ❖ Encadrement étroit des activités des sous-traitants et une responsabilité accrue.
  - ❖ → Elaborer une **documentation constante** et des missions précises pour les sous-traitants. (article 82)
  - ❖ *Tout responsable du traitement ayant participé au traitement est responsable du dommage causé par le traitement qui constitue une violation du présent règlement. Un sous-traitant n'est tenu pour responsable du dommage causé par le traitement que s'il n'a pas respecté les obligations prévues par le présent règlement qui incombent spécifiquement aux sous-traitants ou qu'il a agi en-dehors des instructions licites du responsable du traitement ou contrairement à celles-ci.*



- ❖ Analyse du risque
- ❖ *(84) le responsable du traitement devrait assumer la responsabilité d'effectuer une analyse d'impact relative à la protection des données pour évaluer, en particulier, l'origine, la nature, la particularité et la gravité de ce risque*



## ❖ Exemples de risque

- ❖ Surveillance à grande échelle de zones accessibles au public → ie. floutage
- ❖ Suivi régulier et systématique de personnes → ie. log
- ❖ Mise à disposition de données à des personnes de manière illimitée → ie. qualité de l'anonymisation
- ❖ Traitements soumis à autorisation ou à consultation du DPO



- ❖ Article 40 / Codes de conduite + (85)
- ❖ *la notification aux autorités de contrôle des violations de données à caractère personnel et la communication de ces violations aux personnes concernées;*
  - ❖ → La notification intervient dans les 72 heures
  - ❖ *Si une telle notification ne peut avoir lieu dans ce délai de 72 heures, la notification devrait être assortie des motifs du retard et des informations peuvent être fournies de manière échelonnée sans autre retard indu.*



- ❖ Profilage
- ❖ *«profilage», toute forme de traitement automatisé de données à caractère personnel consistant à utiliser ces données à caractère personnel pour évaluer certains aspects personnels relatifs à une personne physique, notamment pour analyser ou prédire des éléments concernant le rendement au travail, la situation économique, la santé, les préférences personnelles, les intérêts, la fiabilité, le comportement, la localisation ou les déplacements de cette personne physique;*
- ❖ Droit à s'opposer au profilage
- ❖ Pas de profilage < 13 ans



- ❖ Le profilage → permet de calculer un profil
- ❖ (71) *d'obtenir une explication quant à la décision prise à l'issue de ce type d'évaluation et de contester la décision. Cette mesure ne devrait pas concerner un enfant.*



- ❖ Article 20 / Droit à la portabilité des données
- ❖ Portabilité des données → permettre à la personne concernée de transférer les données personnelles fournies d'un traitement à un autre (ie. réseau social)
- ❖ Incitation à mettre au point des formats interopérables (68)
- ❖ *...dans un format structuré, couramment utilisé, lisible par machine et **interopérable**, et de les transmettre à un autre responsable du traitement. Il y a lieu d'encourager les responsables du traitement à mettre au point des formats interopérables permettant la portabilité des données.*



❖ Délégué à la protection des données = Data Privacy Officer (DPO)

Articles 37 / 38 / 39

➔ personne interne ou prestataire

➔ action gratuite dans l'entreprise où il exerce ses missions. Soumis au secret professionnel.

Tient à jour un registre des traitements de données personnelles.

## ❖ Le DPO

- ❖ d'informer et de conseiller l'organisme qui vous a désigné, ainsi que ses employés ;
  - ❖ de contrôler le respect du règlement et du droit national en matière de protection des données ;
  - ❖ de conseiller l'organisme sur la réalisation d'une analyse d'impact relative à la protection des données et d'en vérifier l'exécution ;
  - ❖ être contacté par les personnes concernées pour toute question ;
  - ❖ de coopérer avec la CNIL et d'être son point de contact.
- ❖ Le DPO interagit avec le **Responsable de Traitement**, l'équipe Juridique et le Top Management



## ❖ Êtes-vous lanceur d'alerte ? <https://www.cnil.fr/fr/lanceurs-dalerte-adresser-une-alerte-la-cnil>

- ❖ Ce dispositif de la CNIL est réservé aux personnes physiques qui signalent ou divulguent, sans contrepartie financière directe et de bonne foi, des informations portant sur les données personnelles, et plus particulièrement :
- ❖ une violation du droit de l'Union européenne, de la loi Informatique et Libertés ou du règlement général sur la protection des données (RGPD) ;

- un crime ;
- un délit ;
- une menace ou un préjudice pour l'intérêt général ;
- une autre violation ou une tentative de dissimulation d'une violation :
- d'un engagement international régulièrement ratifié ou approuvé par la France ;
- d'un acte unilatéral d'une organisation internationale pris sur le fondement d'un tel engagement.

❖ Lorsque les informations n'ont pas été obtenues dans le cadre des activités professionnelles, vous devez en avoir eu personnellement connaissance.

En date du 13 juin 2024, en vigueur au 1<sup>er</sup> août 2024

Principes fondateurs → notion de risque élevé si un principe est mis en défaut, avec exemptions si sécurité-défense.


1. action humaine et contrôle humain
2. robustesse technique et sécurité
3. respect de la vie privée et gouvernance des données
4. transparence
5. diversité, non-discrimination et équité
6. bien-être sociétal et environnemental
7. responsabilité

144 pages

Dans l'espace bibliographique

OJ\_L\_202401689\_FR\_TXT.pdf

les systèmes d'IA désignés comme étant à haut risque devraient être limités aux systèmes qui ont une incidence préjudiciable substantielle sur la santé, la sécurité et les droits fondamentaux des citoyens dans l'Union et une telle limitation devrait réduire au minimum toute éventuelle restriction au commerce international.





- ❖ Les risques liés à l'IA à prendre en compte dans une AIPD
- ❖ Les traitements de données personnelles reposant sur des systèmes d'intelligence artificielle présentent des risques spécifiques qu'il convient de prendre en compte :
- ❖ les risques pour les personnes concernées liés à des mésusages des données contenues dans la base d'apprentissage, notamment en cas de violation de données ;
- ❖ le risque d'une discrimination automatisée causée par un biais du système d'IA introduit lors du développement, par exemple lié à une performance moindre du système pour certaines catégories de personnes ;
- ❖ le risque de produire du contenu fictif erroné sur une personne réelle, particulièrement important dans le cas des systèmes d'IA génératives, et pouvant avoir des conséquences sur sa réputation ;
- ❖ le risque de prise de décision automatisée causée par un biais d'automatisation ou de confirmation dans le cas où les mesures d'explicabilité nécessaires ne sont pas prises lors du développement de la solution (comme la remontée d'un score de confiance, ou d'informations intermédiaires tel qu'une carte de saillance ou « *saliency map* ») ou si un agent utilisant le système d'IA ne peut pas prendre une décision contraire sans que cela ne lui porte préjudice ;
- ❖ les risques liés aux attaques connues spécifiques aux systèmes d'IA tel que les attaques par empoisonnement des données, par insertion d'une porte dérobée, ou encore par inversion du modèle ;
- ❖ les risques liés à la confidentialité des données susceptibles d'être extraites depuis le système d'IA ;
- ❖ les risques éthiques systémiques et graves liés au déploiement du système, tels que les impacts sur le fonctionnement démocratique de la société, ou encore sur le respect des droits fondamentaux (par exemple en cas de discrimination), et pouvant être pris en compte lors de la phase de développement.
- ❖ Enfin, le risque d'une perte de contrôle des utilisateurs sur leurs données accessibles en ligne, une collecte à large échelle étant souvent nécessaire à l'apprentissage d'un système d'IA, notamment lorsque celles-ci sont collectées par moissonnage ou *web scraping*.

	RIA	RGPD
Champ d'application	Le développement, la mise sur le marché ou le déploiement de systèmes et modèles d'IA	Tout traitement de données personnelles indépendamment des dispositifs techniques utilisés (dont les traitements visant à développer un modèle ou système d'IA (données d'entraînement), et les traitements réalisés au moyen d'un système d'IA)
Acteurs visés	Principalement les fournisseurs et déployeurs de systèmes d'IA (dans une moindre mesure les importateurs, distributeurs et mandataires)	Responsables de traitements et sous-traitants (dont les fournisseurs et déployeurs soumis au RIA)
Approche	Approche par les risques pour la santé, la sécurité ou les droits fondamentaux, notamment à travers la sécurité des produits et la surveillance du marché en ce qui concerne les systèmes et modèles d'IA	Approche fondée sur l'application de grands principes, l'évaluation des risques et la responsabilisation (accountability)
Modalité principale de l'évaluation de la conformité (non exhaustif)	Évaluation de conformité interne ou par un tiers, notamment au moyen d'un système de gestion des risques et au regard de normes harmonisées	Principe de responsabilité (documentation interne) et outils de la conformité (certification, code de conduite)
Principales sanctions applicables	Retrait du marché ou rappel de produits	Mise en demeure (pouvant enjoindre de mettre le traitement en conformité, de le limiter temporairement ou définitivement, y compris sous astreinte)
	Amendes administratives pouvant aller jusqu'à 35 millions d'euros ou <b>7% du chiffre d'affaires annuel mondial</b>	Amendes administratives pouvant aller jusqu'à 20 millions d'euros ou <b>4% du chiffre d'affaires annuel mondial</b>

- ❖ Cf. referentiel-certification-LNE-processus-IA.pdf
- ➔ la certification est recommandée
- ❖ Exemple page 38

exigence	information visée	client spécifique		client générique
		doit être tenu à disposition	doit être communiqué	doit être communiqué <u>via la fiche produit</u>
III.3.1	les spécifications relatives à la fonctionnalité d'IA et les critères d'acceptation de chacune des exigences	X		X
III.3.1	éléments de communication avec le client définis lors de la phase de conception	selon ce qui a été défini	selon ce qui a été défini	
III.4.1.3	l'infrastructure (matérielle, système d'exploitation, logicielle), les types de déploiement (cloud public ou privé, on-premise etc.) supportés par la fonctionnalité d'IA et la dépendance à des technologies d'IA sous-jacentes		X	X
III.4.1.4	les interfaces nécessaires à l'usage de la fonctionnalité d'IA		X	X
III.4.1.5	les caractéristiques du domaine d'utilisation visé, notamment les principaux facteurs d'influence sur les performances de la fonctionnalité d'IA		X	X