

# Entrepôts de Données de Santé et Protection de la Vie Privée : Synthèse de discussions Inter-CHU


PFIA 2024 - Journée Santé & IA

1 Juillet 2024


Manal Ahikki<sup>1</sup>, Marc Berard<sup>2</sup>, Camille Bouin<sup>2</sup>, Antoine Boutet<sup>3</sup>, Stéphane Breant<sup>4</sup>, Alice Calliger<sup>4</sup>, Ariel Cohen<sup>4</sup>, Jean-François Couchot<sup>5</sup>, Denis Delamarre<sup>6</sup>, Caroline Dunoyer<sup>1</sup>, Thibaut Fabacher<sup>7</sup>, Lucas W. Gauthier<sup>2</sup>, David Gimbert<sup>2</sup>, Camille Girard-Chanudet<sup>8</sup>, Romain Griffier<sup>9</sup>, Martin Hilka<sup>4</sup>, Yannick Jacob<sup>4</sup>, Vianney Jouhet<sup>9</sup>, David Laiymani<sup>5</sup>, Leonardo Moros<sup>1</sup>, Joris Muller<sup>7</sup>, David Pellecuer<sup>1</sup>, Thomas Petit-Jean<sup>4</sup>, Antoine Richard<sup>2</sup>, Maxime Salaun<sup>7</sup>, François Talbot<sup>2</sup>, Perceval Wajsburt<sup>4</sup> et Kevin Yauy<sup>1</sup>




# Contexte <sup>1 2</sup>



1. [MINISTÈRE DU TRAVAIL, DE LA SANTÉ ET DES SOLIDARITÉS 2024](#) - Dossier de presse France 2030 : 2 ans de la Stratégie "Santé numérique"
2. [MARCHAND-ARVIER et al. 2023](#) - Fédérer les acteurs de l'écosystème pour libérer l'utilisation secondaire des données de santé

Problématique<sup>3 4 5 6</sup>

3. [COMMISSION NATIONALE DE L'INFORMATIQUE ET DES LIBERTÉS \(CNIL\) 2016](#) - Le règlement général sur la protection des données - RGPD
4. Loi n° 78-17 du 6 janvier 1978 relative à l'informatique, aux fichiers et aux libertés
5. [JOURNAL OFFICIEL DE LA RÉPUBLIQUE FRANÇAISE \(JORF\) 2021](#) - Délibération n° 2021-118 du 7 octobre 2021 sur le référentiel EDS
6. [EUROPEAN UNION 2024](#) - Artificial Intelligence Act

Problématique<sup>3 4 5 6</sup>

⇒ **Quoi faire en pratique ?**

3. [COMMISSION NATIONALE DE L'INFORMATIQUE ET DES LIBERTÉS \(CNIL\) 2016](#) - Le règlement général sur la protection des données - RGPD
4. Loi n° 78-17 du 6 janvier 1978 relative à l'informatique, aux fichiers et aux libertés
5. [JOURNAL OFFICIEL DE LA RÉPUBLIQUE FRANÇAISE \(JORF\) 2021](#) - Délibération n° 2021-118 du 7 octobre 2021 sur le référentiel EDS
6. [EUROPEAN UNION 2024](#) - Artificial Intelligence Act

# Objectifs

1. Établir quelles sont les méthodes de protection de la vie privée à notre disposition

## Objectifs

1. Établir quelles sont les méthodes de protection de la vie privée à notre disposition
2. Déterminer comment intégrer ces méthodes dans un EDS

## Objectifs

1. Établir quelles sont les méthodes de protection de la vie privée à notre disposition
2. Déterminer comment intégrer ces méthodes dans un EDS
3. Proposer des bonnes pratiques

## 1 Introduction

## 2 Concepts & Définitions

- Littérature Scientifique
- Textes législatifs

## 3 Processus et méthodes de masquage

- Définition des éléments identifiants
- Détection des éléments identifiants
- Masquage des éléments identifiants

## 4 Intégration dans les EDS

## 5 Conclusion

# Protection de la Vie Privée <sup>7</sup>

---

## 7. Images générée avec Stable Diffusion XL 1.0

# Protection de la Vie Privée<sup>7</sup>

## PVP "stricte"

Suppose un attaquant quasi-omniscient  
et quasi-omnipotent



---

7. Images générée avec Stable Diffusion XL 1.0

# Protection de la Vie Privée<sup>7</sup>

## PVP "stricte"

Suppose un attaquant quasi-omniscient  
et quasi-omnipotent



## PVP "relaxée"

Suppose un investigateur honnête  
mais curieux



7. Images générée avec Stable Diffusion XL 1.0

# Protection de la Vie Privée<sup>7</sup>

## PVP "stricte"

Suppose un attaquant quasi-omniscient  
et quasi-omnipotent



⇒ Maximiser le temps d'attaque

## PVP "relaxée"

Suppose un investigateur honnête  
mais curieux



7. Images générée avec Stable Diffusion XL 1.0

# Protection de la Vie Privée<sup>7</sup>

## PVP "stricte"

Suppose un attaquant quasi-omniscient  
et quasi-omnipotent



⇒ Maximiser le temps d'attaque

## PVP "relaxée"

Suppose un investigateur honnête  
mais curieux



⇒ Minimiser les risques

7. Images générée avec Stable Diffusion XL 1.0

# Identifiants (in)directs et données sensibles<sup>8</sup>

Identifiants directs			Identifiants indirects		Données sensibles		
Numéro de Sécurité Sociale	Nom	Prénom	Âge	Adresse	Diagnostic	Allergies	Médicaments
123-45-6789	Durand	Marie	45	123 Rue de Paris, 75001 Paris	Diabète	Arachides	Metformine
234-56-7890	Martin	Jean	58	45 Avenue des Champs, 75008 Paris	Hypertension	Pollen	Lisinopril
345-67-8901	Bernard	Clara	30	78 Boulevard Saint-Germain, 75006 Paris	Asthme	Aucun	Salbutamol
456-78-9012	Petit	Louis	67	22 Rue de Rivoli, 75004 Paris	Cancer	Latex	Paclitaxel
567-89-0123	Robert	Sophie	52	15 Rue de la Paix, 75002 Paris	Insuffisance cardiaque	Antibiotiques	Digoxine

## 8. Données factices générées avec ChatGPT 3.5

# K-anonymité et I-diversité<sup>9</sup>

## K-anonymité :

Impossible d'isoler des groupes de taille plus petit que  $k$  sur les identifiants indirects

Âge	Adresse	Diagnostic	Allergies	Médicaments
40-50	Paris	Diabète	Arachides	Metformine
40-50	Paris	Maladie rénale	Aucun	Énalapril
50-60	Paris	Insuffisance cardiaque	Antibiotiques	Digoxine
50-60	Paris	Dépression	Acarien	Sertraline
50-60	Paris	Cholestérol élevé	Aucun	Atorvastatine
50-60	Paris	Hypertension	Pollen	Lisinopril
30-40	Paris	Asthme	Aucun	Salbutamol
30-40	Paris	Arthrite	Poussière	Ibuprofène
60-70	Paris	Cancer	Latex	Paclitaxel
60-70	Paris	Alzheimer	Aucun	Donepezil

9. Exemple avec données factices générées avec ChatGPT 3.5

# K-anonymité et I-diversité<sup>9</sup>

## K-anonymité :

Impossible d'isoler des groupes de taille plus petit que  $k$  sur les identifiants indirects

## L-diversité :

Avoir une diversité d'au moins  $l$  éléments différents pour chaque groupe sur les données sensibles

Âge	Adresse	Diagnostic	Allergies	Médicaments
40-50	Paris	Diabète	Arachides	Metformine
40-50	Paris	Maladie rénale	Aucun	Énalapril
50-60	Paris	Insuffisance cardiaque	Antibiotiques	Digoxine
50-60	Paris	Dépression	Acarien	Sertraline
50-60	Paris	Cholestérol élevé	Aucun	Atorvastatine
50-60	Paris	Hypertension	Pollen	Lisinopril
30-40	Paris	Asthme	Aucun	Salbutamol
30-40	Paris	Arthrite	Poussière	Ibuprofène
60-70	Paris	Cancer	Latex	Paclitaxel
60-70	Paris	Alzheimer	Aucun	Donepezil

9. Exemple avec données factices générées avec ChatGPT 3.5

Données à Caractère Personnel<sup>10 11</sup>Données à Caractère  
Personnel

Numéro de Sécurité Sociale	Nom	Prénom	Âge	Adresse	Diagnostic	Allergies	Médicaments
123-45-6789	Durand	Marie	45	123 Rue de Paris, 75001 Paris	Diabète	Arachides	Metformine
234-56-7890	Martin	Jean	58	45 Avenue des Champs, 75008 Paris	Hypertension	Pollen	Lisinopril
345-67-8901	Bernard	Clara	30	78 Boulevard Saint- Germain, 75006 Paris	Asthme	Aucun	Salbutamol
456-78-9012	Petit	Louis	67	22 Rue de Rivoli, 75004 Paris	Cancer	Latex	Paclitaxel
567-89-0123	Robert	Sophie	52	15 Rue de la Paix, 75002 Paris	Insuffisance cardiaque	Antibiotiques	Digoxine

10. Données factices générées avec ChatGPT 3.5

11. [COMMISSION NATIONALE DE L'INFORMATIQUE ET DES LIBERTÉS \(CNIL\) 2016](#) - Le règlement général sur la protection des données - RGPD

# Anonymisation <sup>12</sup>

---

## 12. (CNIL) 2020 - L'anonymisation de données personnelles

# Anonymisation <sup>12</sup>

## Risque d'individualisation :

Il ne doit pas être possible d'isoler un individu dans un jeu de données

---

12. (CNIL) 2020 - L'anonymisation de données personnelles

# Anonymisation <sup>12</sup>

## Risque d'individualisation :

Il ne doit pas être possible d'isoler un individu dans un jeu de données

## Risque de corrélation :

Il ne doit pas être possible de relier entre eux des ensembles de données distincts concernant un même individu

---

12. (CNIL) 2020 - L'anonymisation de données personnelles

# Anonymisation<sup>12</sup>

## Risque d'individualisation :

Il ne doit pas être possible d'isoler un individu dans un jeu de données

## Risque de corrélation :

Il ne doit pas être possible de relier entre eux des ensembles de données distincts concernant un même individu

## Risque d'inférence :

Il ne doit pas être possible de déduire, de façon quasi certaine, de nouvelles informations sur un individu

---

12. (CNIL) 2020 - L'anonymisation de données personnelles

# Anonymisation <sup>12</sup>

## Risque d'individualisation :

Il ne doit pas être possible d'isoler un individu dans un jeu de données

## Risque de corrélation :

Il ne doit pas être possible de relier entre eux des ensembles de données distincts concernant un même individu

## Risque d'inférence :

Il ne doit pas être possible de déduire, de façon quasi certaine, de nouvelles informations sur un individu

⇒ La RGPD ne s'applique pas sur un jeu de données "anonymisé"

---

12. (CNIL) 2020 - L'anonymisation de données personnelles

# Pseudonymisation <sup>13</sup> <sup>14</sup> <sup>15</sup>



## Définition :

"Traitement de données à caractère personnel de telle façon que celles-ci ne puissent plus être attribuées à une personne concernée précise sans avoir recours à des informations supplémentaires"

13. [\(CNIL\) 2016](#) - Le G29 publie un avis sur les techniques d'anonymisation
14. [\(CNIL\) 2020](#) - L'anonymisation de données personnelles
15. Where's Wally? 4,626 people dressed as Waldo break a record in Japan

# Pseudonymisation <sup>13</sup> <sup>14</sup> <sup>15</sup>



## Définition :

"Traitement de données à caractère personnel de telle façon que celles-ci ne puissent plus être attribuées à une personne concernée précise sans avoir recours à des informations supplémentaires"

⇒ "Cacher dans la foule"

13. (CNIL) 2016 - Le G29 publie un avis sur les techniques d'anonymisation

14. (CNIL) 2020 - L'anonymisation de données personnelles

15. Where's Wally? 4,626 people dressed as Waldo break a record in Japan

# Pseudonymisation <sup>13</sup> <sup>14</sup> <sup>15</sup>



## Définition :

"Traitement de données à caractère personnel de telle façon que celles-ci ne puissent plus être attribuées à une personne concernée précise sans avoir recours à des informations supplémentaires"

⇒ "Cacher dans la foule"

⇒ Modification des données

13. (CNIL) 2016 - Le G29 publie un avis sur les techniques d'anonymisation

14. (CNIL) 2020 - L'anonymisation de données personnelles

15. Where's Wally? 4,626 people dressed as Waldo break a record in Japan

# Pseudonymisation <sup>13</sup> <sup>14</sup> <sup>15</sup>



## Définition :

"Traitement de données à caractère personnel de telle façon que celles-ci ne puissent plus être attribuées à une personne concernée précise sans avoir recours à des informations supplémentaires"

- ⇒ "Cacher dans la foule"
- ⇒ Modification des données
- ⇒ Processus réversible

13. [\(CNIL\) 2016](#) - Le G29 publie un avis sur les techniques d'anonymisation

14. [\(CNIL\) 2020](#) - L'anonymisation de données personnelles

15. Where's Wally? 4,626 people dressed as Waldo break a record in Japan

## 1 Introduction

## 2 Concepts & Définitions

- Littérature Scientifique
- Textes législatifs


## 3 Processus et méthodes de masquage

- Définition des éléments identifiants
- Détection des éléments identifiants
- Masquage des éléments identifiants

## 4 Intégration dans les EDS

## 5 Conclusion

# Processus annotation 16



## 16. GIRARD-CHANUDET 2023 - La justice algorithmique en chantier : sociologie du travail et des infrastructures de l'intelligence artificielle

# Données Structurées <sup>17 18</sup>


Identifiants directs			Identifiants indirects		Données sensibles		
Numéro de Sécurité Sociale	Nom	Prénom	Âge	Adresse	Diagnostic	Allergies	Médicaments
123-45-6789	Durand	Marie	45	123 Rue de Paris, 75001 Paris	Diabète	Arachides	Metformine
234-56-7890	Martin	Jean	58	45 Avenue des Champs, 75008 Paris	Hypertension	Pollen	Lisinopril
345-67-8901	Bernard	Clara	30	78 Boulevard Saint-Germain, 75006 Paris	Asthme	Aucun	Salbutamol
456-78-9012	Petit	Louis	67	22 Rue de Rivoli, 75004 Paris	Cancer	Latex	Paclitaxel
567-89-0123	Robert	Sophie	52	15 Rue de la Paix, 75002 Paris	Insuffisance cardiaque	Antibiotiques	Digoxine

17. Données factices générées avec ChatGPT

18. ARX - Data Anonymization Tool




## Randomisation 19 20 21




19. [\(CNIL\) 2016](#) - Le G29 publie un avis sur les techniques d'anonymisation

20. [\(CNIL\) 2020](#) - L'anonymisation de données personnelles


21. The ABCs of Differential Privacy

Généralisation <sup>22 23</sup>


Generalization Algorithm (SWEENEY 2002)



Mondrian Algorithm (LEFEVRE, DEWITT et RAMAKRISHNAN 2006)



Bucketization (XIAO et TAO 2008)



ARX : SafePub Algorithm (BILD, KUHN et PRASSER 2018)

22. (CNIL) 2016 - Le G29 publie un avis sur les techniques d'anonymisation
23. (CNIL) 2020 - L'anonymisation de données personnelles

## 1 Introduction

## 2 Concepts & Définitions

- Littérature Scientifique
- Textes législatifs

## 3 Processus et méthodes de masquage


- Définition des éléments identifiants
- Détection des éléments identifiants
- Masquage des éléments identifiants

## 4 Intégration dans les EDS

## 5 Conclusion


En théorie<sup>24</sup>

## PVP "décentralisée"




VS

## PVP "centralisée"



24. Benjamin Nguyen - Privacy, Data Protection and Security

# En pratique



## 1 Introduction

## 2 Concepts & Définitions

- Littérature Scientifique
- Textes législatifs

## 3 Processus et méthodes de masquage

- Définition des éléments identifiants
- Détection des éléments identifiants
- Masquage des éléments identifiants

## 4 Intégration dans les EDS

## 5 Conclusion

## Pour les travaux en IA :

## Pour les travaux en IA :

- Contactez votre DPO

## Pour les travaux en IA :

- Contactez votre DPO
- Déterminez les données, la granularité et le bruit

## Pour les travaux en IA :

- Contactez votre DPO
- Déterminez les données, la granularité et le bruit
- Évaluez les risques

## Pour les travaux en IA :

- Contactez votre DPO
- Déterminez les données, la granularité et le bruit
- Évaluez les risques

⇒ Faire au mieux pour trouver un équilibre entre protection des données pour les patients et utilité des données pour les investigateurs

## Pour les travaux en IA :

- Contactez votre DPO
- Déterminez les données, la granularité et le bruit
- Évaluez les risques

⇒ Faire au mieux pour trouver un équilibre entre protection des données pour les patients et utilité des données pour les investigateurs

## Pour les travaux sur les EDS :

## Pour les travaux en IA :

- Contactez votre DPO
- Déterminez les données, la granularité et le bruit
- Évaluez les risques

⇒ Faire au mieux pour trouver un équilibre entre protection des données pour les patients et utilité des données pour les investigateurs

## Pour les travaux sur les EDS :

- Les approches mixtes sont les plus sûres

## Pour les travaux en IA :

- Contactez votre DPO
- Déterminez les données, la granularité et le bruit
- Évaluez les risques

⇒ Faire au mieux pour trouver un équilibre entre protection des données pour les patients et utilité des données pour les investigateurs

## Pour les travaux sur les EDS :

- Les approches mixtes sont les plus sûres
- Supprimez les identifiants directs par défauts

## Pour les travaux en IA :

- Contactez votre DPO
- Déterminez les données, la granularité et le bruit
- Évaluez les risques

⇒ Faire au mieux pour trouver un équilibre entre protection des données pour les patients et utilité des données pour les investigateurs

## Pour les travaux sur les EDS :

- Les approches mixtes sont les plus sûres
- Supprimez les identifiants directs par défauts
- Permettre d'ajuster la protection des données aux besoins

## Pour les travaux en IA :

- Contactez votre DPO
- Déterminez les données, la granularité et le bruit
- Évaluez les risques

⇒ Faire au mieux pour trouver un équilibre entre protection des données pour les patients et utilité des données pour les investigateurs

## Pour les travaux sur les EDS :

- Les approches mixtes sont les plus sûres
- Supprimez les identifiants directs par défauts
- Permettre d'ajuster la protection des données aux besoins

## Perspectives :

- Masquage des images, sons, etc.
- Référentiel commun
- Sûreté des modèles

## Pour les travaux en IA :

- Contactez votre DPO
- Déterminez les données, la granularité et le bruit
- Évaluez les risques

⇒ Faire au mieux pour trouver un équilibre entre protection des données pour les patients et utilité des données pour les investigateurs

## Pour les travaux sur les EDS :

- Les approches mixtes sont les plus sûres
- Supprimez les identifiants directs par défauts
- Permettre d'ajuster la protection des données aux besoins

## Perspectives :

- Masquage des images, sons, etc.
- Référentiel commun
- Sûreté des modèles

Merci pour votre attention :)

## Références I

-  BILD, Raffael, Klaus A KUHN et Fabian PRASSER (2018). “SafePub : A Truthful Data Anonymization Algorithm With Strong Privacy Guarantees.”. In : **Proc. Priv. Enhancing Technol.** 2018.1, p. 67-87. DOI : 10.1515/popets-2018-0004.
-  (CNIL), Commission nationale de l'informatique et des libertés (jan. 2016). **Le G29 publie un avis sur les techniques danonymisation.** fr. URL : <https://www.cnil.fr/fr/le-g29-publie-un-avis-sur-les-techniques-danonymisation>.
-  — (mai 2020). **Lanonymisation de données personnelles.** fr. URL : <https://www.cnil.fr/fr/lanonymisation-de-donnees-personnelles>.
-  COMMISSION NATIONALE DE L'INFORMATIQUE ET DES LIBERTÉS (CNIL) (mai 2016). **Le règlement général sur la protection des données - RGPD.** fr. URL : <https://www.cnil.fr/fr/reglement-europeen-protection-donnees>.
-  EUROPEAN UNION (mars 2024). **EU Artificial Intelligence Act.** URL : <https://www.aiact-info.eu/articles/>.
-  GIRARD-CHANUDET, Camille (déc. 2023). “La justice algorithmique en chantier : sociologie du travail et des infrastructures de l'intelligence artificielle.”. These de doctorat. Paris, EHESS. URL : <https://theses.fr/2023EHES0141>.

## Références II

-  GROUIN, Cyril (juin 2013). “Anonymisation de documents cliniques : performances et limites des méthodes symboliques et par apprentissage statistique”. fr. Thèse de doct. Université Pierre et Marie Curie - Paris VI. URL : <https://theses.hal.science/tel-00848672> (visité le 29/03/2024).
-  JOURNAL OFFICIEL DE LA RÉPUBLIQUE FRANÇAISE (JORF) (oct. 2021). **Délibération n° 2021-118 du 7 octobre 2021 portant adoption d'un référentiel relatif aux traitements de données à caractère personnel mis en uvre à des fins de création d'entrepôts de données dans le domaine de la santé - Légifrance**. URL : <https://www.legifrance.gouv.fr/jorf/id/JORFTEXT000044239566>.
-  LEFEVRE, Kristen, David J DEWITT et Raghu RAMAKRISHNAN (2006). “Mondrian multidimensional k-anonymity”. In : **22nd International conference on data engineering (ICDE'06)**. IEEE, p. 25-25. DOI : 10.1109/ICDE.2006.101.
-  MARCHAND-ARVIER, Jérôme et al. (déc. 2023). **Fédérer les acteurs de lécosystème pour libérer utilisation secondaire des données de santé**. URL : [https://sante.gouv.fr/IMG/pdf/rapport\\_donnees\\_de\\_sante.pdf](https://sante.gouv.fr/IMG/pdf/rapport_donnees_de_sante.pdf).
-  MINISTÈRE DU TRAVAIL, DE LA SANTÉ ET DES SOLIDARITÉS (jan. 2024). **Dossier de presse France 2030 : 2 ans de la Stratégie "Santé numérique"**. URL : [https://sante.gouv.fr/IMG/pdf/dp\\_2ans\\_sasn\\_18janvier2024.pdf](https://sante.gouv.fr/IMG/pdf/dp_2ans_sasn_18janvier2024.pdf).

## Références III

-  RICHARD, Antoine, François TALBOT et David GIMBERT (juill. 2023). “Anonymisation de documents médicaux en texte libre et en français via réseaux de neurones”. In : **Plate-forme Intelligence Artificielle 2023 (PFIA2023) - Journée Santé & IA**. Starsbourg, France : Association française pour l'Intelligence Artificielle (AfIA), Université de Strasbourg et Association française d'Informatique Médicale (AIM). URL : <https://hal.science/hal-04139391>.
-  SWEENEY, Latanya (2002). “k-anonymity : A model for protecting privacy”. In : **International journal of uncertainty, fuzziness and knowledge-based systems** 10.05, p. 557-570. DOI : [10.1142/S0218488502001648](https://doi.org/10.1142/S0218488502001648).
-  TANNIER, Xavier et al. (mars 2024). “Development and Validation of a Natural Language Processing Algorithm to Pseudonymize Documents in the Context of a Clinical Data Warehouse”. en. In : **Methods of Information in Medicine**. Publisher : Georg Thieme Verlag KG. ISSN : 0026-1270, 2511-705X. DOI : [10.1055/s-0044-1778693](https://doi.org/10.1055/s-0044-1778693). URL : <http://www.thieme-connect.de/DOI/DOI?10.1055/s-0044-1778693>.
-  TCHOUKA, Yakini (déc. 2023). “Dé-identification des comptes rendus médicaux pour les tâches d'apprentissage automatique : application à l'association des codes CIM-10”. fr. thesis. Bourgogne Franche-Comté. URL : <https://theses.fr/s257929>.

## Références IV

-  XIAO, Xiaokui et Yufei TAO (2008). "Dynamic anonymization : Accurate statistical analysis with privacy preservation". In : **Proceedings of the 2008 ACM SIGMOD international conference on Management of data**, p. 107-120. DOI : 10.1145/1376616.1376630.