

## Module Y5

# Masquage de données & postgresql\_anonymizer





# Table des matières

Sur ce document . . . . .	1
Chers lectrices & lecteurs, . . . . .	1
À propos de DALIBO . . . . .	1
Remerciements . . . . .	2
Forme de ce manuel . . . . .	2
Licence Creative Commons CC-BY-NC-SA . . . . .	2
Marques déposées . . . . .	3
Versions de PostgreSQL couvertes . . . . .	3
<b>1/ Masquage de données &amp; postgresql_anonymizer</b>	<b>5</b>
1.1 Cas d'usage . . . . .	6
1.1.1 Objectifs . . . . .	6
<b>2/ PostgreSQL Anonymizer</b>	<b>7</b>
2.0.1 Principe . . . . .	7
2.0.2 Masquages . . . . .	7
2.0.3 Pré-requis . . . . .	8
2.0.4 Base d'exemple . . . . .	9
<b>3/ Masquage statique avec postgresql_anonymizer</b>	<b>11</b>
3.1 L'histoire . . . . .	12
3.2 Comment ça marche . . . . .	13
3.3 Objectifs . . . . .	14
3.4 Table « customer » . . . . .	15
3.4.1 Quelques clients . . . . .	15
3.5 Table « payout » . . . . .	16
3.5.1 Quelques données . . . . .	16
3.5.2 Activer l'extension . . . . .	16
3.6 Déclarer les règles de masquage . . . . .	17
3.7 Appliquer les règles de manière permanente . . . . .	18
3.8 Exercices . . . . .	19
3.8.1 E101 - Masquer les prénoms des clients . . . . .	19
3.8.2 E102 - Masquer les 3 derniers chiffres du code postal . . . . .	19
3.8.3 E103 - Compter le nombre de clients dans chaque département. . . . .	19
3.8.4 E104 - Ne garder que l'année dans les dates de naissance . . . . .	19
3.8.5 E105 - Identifier un client particulier . . . . .	19
3.9 Solutions . . . . .	21
3.9.1 S101 . . . . .	21
3.9.2 S102 . . . . .	21
3.9.3 S103 . . . . .	21
3.9.4 S104 . . . . .	22
3.9.5 S105 . . . . .	22

---

<b>4/ Masquage dynamique avec postgresql_anonymizer</b>	<b>23</b>
4.1 Principe du masquage dynamique	24
4.2 L'histoire	25
4.3 Comment ça marche	26
4.4 Objectifs de la section	27
4.5 Table « company »	28
4.5.1 Quelques données	28
4.6 Table « supplier »	29
4.6.1 Quelques données	29
4.7 Activer l'extension	30
4.8 Activer le masquage dynamique	31
4.9 Rôle masqué	32
4.10 Masquer le nom des fournisseurs	33
4.11 Exercices	34
4.11.1 E201 - Deviner qui est le PDG de « Johnny's Shoe Store »	34
4.11.2 E202 - Anonymiser les sociétés	34
4.11.3 E203 - Pseudonymiser le nom des sociétés	34
4.12 Solutions	36
4.12.1 S201	36
4.12.2 S202	36
4.12.3 S203	36
<b>5/ Sauvegardes anonymes avec postgresql_anonymizer</b>	<b>39</b>
5.1 L'histoire	40
5.2 Comment ça marche ?	41
5.3 Objectifs	42
5.4 Table « website_comment »	43
5.4.1 Quelques données	43
5.5 Activer l'extension	44
5.6 Masquer une colonne de type JSON	45
5.6.1 Fonctions de masquage personnalisées	45
5.6.2 Utilisation de la fonction de masquage personnalisée	46
5.6.3 Sauvegarde anonymisée	46
5.7 Exercices	48
5.7.1 E301 - Exporter les données anonymisées dans une nouvelle base de données	48
5.7.2 E302 - Pseudonymiser les métadonnées du commentaire	48
5.8 Solutions	49
5.8.1 S301	49
5.8.2 S302	49
<b>6/ Généralisation avec postgresql_anonymizer</b>	<b>51</b>
6.1 Principe	52
6.2 L'histoire	53
6.3 Comment ça marche ?	54
6.4 Objectifs	55
6.5 Table « employee »	56

---

6.6	Quelques données . . . . .	57
6.7	Suppression de données . . . . .	58
6.8	Calculer le k-anonymat . . . . .	59
6.9	Fonctions d'intervalle et de généralisation . . . . .	60
6.9.1	Déclarer les identifiants indirects . . . . .	61
6.10	Exercices . . . . .	62
6.10.1	E401 - Simplifier la vue v_staff_per_month pour en réduire la granularité. . . . .	62
6.10.2	E402 - Progression du personnel au fil des années . . . . .	62
6.10.3	E403 - Atteindre le facteur 2-anonymity sur la vue v_staff_per_year . . . . .	62
6.11	Solutions . . . . .	63
6.11.1	S401 . . . . .	63
6.11.2	S402 . . . . .	63
6.11.3	S403 . . . . .	63
<b>7/</b>	<b>Conclusion sur postgresql_anonymizer</b>	<b>65</b>
7.1	Beaucoup de stratégies de masquage . . . . .	66
7.2	Beaucoup de fonctions de masquage . . . . .	67
7.3	Avantages . . . . .	68
7.4	Inconvénients . . . . .	69
7.5	Pour aller plus loin . . . . .	70
7.6	Contribuez ! . . . . .	71
7.6.1	Questions . . . . .	71
<b>Les formations Dalibo</b>		<b>73</b>
	Cursus des formations . . . . .	73
	Les livres blancs . . . . .	74
	Téléchargement gratuit . . . . .	74



## Sur ce document

---

<b>Formation</b>	Module Y5
<b>Titre</b>	Masquage de données & postgresql_anonymizer
<b>Révision</b>	24.04
<b>PDF</b>	<a href="https://dali.bo/y5_pdf">https://dali.bo/y5_pdf</a>
<b>EPUB</b>	<a href="https://dali.bo/y5_epub">https://dali.bo/y5_epub</a>
<b>HTML</b>	<a href="https://dali.bo/y5_html">https://dali.bo/y5_html</a>
<b>Slides</b>	<a href="https://dali.bo/y5_slides">https://dali.bo/y5_slides</a>

---

Vous trouverez en ligne les différentes versions complètes de ce document.

## Chers lectrices & lecteurs,

Nos formations PostgreSQL sont issues de nombreuses années d'études, d'expérience de terrain et de passion pour les logiciels libres. Pour Dalibo, l'utilisation de PostgreSQL n'est pas une marque d'opportunisme commercial, mais l'expression d'un engagement de longue date. Le choix de l'Open Source est aussi le choix de l'implication dans la communauté du logiciel.

Au-delà du contenu technique en lui-même, notre intention est de transmettre les valeurs qui animent et unissent les développeurs de PostgreSQL depuis toujours : partage, ouverture, transparence, créativité, dynamisme... Le but premier de nos formations est de vous aider à mieux exploiter toute la puissance de PostgreSQL mais nous espérons également qu'elles vous inciteront à devenir un membre actif de la communauté en partageant à votre tour le savoir-faire que vous aurez acquis avec nous.

Nous mettons un point d'honneur à maintenir nos manuels à jour, avec des informations précises et des exemples détaillés. Toutefois malgré nos efforts et nos multiples relectures, il est probable que ce document contienne des oublis, des coquilles, des imprécisions ou des erreurs. Si vous constatez un souci, n'hésitez pas à le signaler via l'adresse [formation@dalibo.com](mailto:formation@dalibo.com)<sup>1</sup> !

## À propos de DALIBO

DALIBO est le spécialiste français de PostgreSQL. Nous proposons du support, de la formation et du conseil depuis 2005.

Retrouvez toutes nos formations sur <https://dalibo.com/formations>

---

<sup>1</sup><mailto:formation@dalibo.com>

## Remerciements

Ce manuel de formation est une aventure collective qui se transmet au sein de notre société depuis des années. Nous remercions chaleureusement ici toutes les personnes qui ont contribué directement ou indirectement à cet ouvrage, notamment :

Jean-Paul Argudo, Alexandre Anriot, Carole Arnaud, Alexandre Baron, David Bidoc, Sharon Bonan, Franck Boudehen, Arnaud Bruniquel, Pierrick Chovelon, Damien Clochard, Christophe Courtois, Marc Cousin, Gilles Darold, Jehan-Guillaume de Rorthais, Ronan Dunklau, Vik Fearing, Stefan Fercot, Pierre Giraud, Nicolas Gollet, Dimitri Fontaine, Florent Jardin, Virginie Jourdan, Luc Lamarle, Denis Laxalde, Guillaume Lelarge, Alain Lesage, Benoit Lobréau, Jean-Louis Louër, Thibaut Madelaine, Adrien Nayrat, Alexandre Pereira, Flavie Perette, Robin Portigliatti, Thomas Reiss, Maël Rimbault, Julien Rouhaud, Stéphane Schildknecht, Julien Tachaires, Nicolas Thauvin, Be Hai Tran, Christophe Truffier, Cédric Villemain, Thibaud Walkowiak, Frédéric Yhuel.

## Forme de ce manuel

Les versions PDF, EPUB ou HTML de ce document sont structurées autour des slides de nos formations. Le texte suivant chaque slide contient le cours et de nombreux détails qui ne peuvent être données à l'oral.

## Licence Creative Commons CC-BY-NC-SA

Cette formation est sous licence **CC-BY-NC-SA**<sup>2</sup>. Vous êtes libre de la redistribuer et/ou modifier aux conditions suivantes :

- Paternité
- Pas d'utilisation commerciale
- Partage des conditions initiales à l'identique

### **Vous n'avez pas le droit d'utiliser cette création à des fins commerciales.**

Si vous modifiez, transformez ou adaptez cette création, vous n'avez le droit de distribuer la création qui en résulte que sous un contrat identique à celui-ci.

Vous devez citer le nom de l'auteur original de la manière indiquée par l'auteur de l'œuvre ou le titulaire des droits qui vous confère cette autorisation (mais pas d'une manière qui suggérerait qu'ils vous soutiennent ou approuvent votre utilisation de l'œuvre). À chaque réutilisation ou distribution de cette création, vous devez faire apparaître clairement au public les conditions contractuelles de sa mise à disposition. La meilleure manière de les indiquer est un lien vers cette page web. Chacune de ces conditions peut être levée si vous obtenez l'autorisation du titulaire des droits sur cette œuvre. Rien dans ce contrat ne diminue ou ne restreint le droit moral de l'auteur ou des auteurs.

Le texte complet de la licence est disponible sur <http://creativecommons.org/licenses/by-nc-sa/2.0/fr/legalcode>

---

<sup>2</sup><http://creativecommons.org/licenses/by-nc-sa/2.0/fr/legalcode>

Cela inclut les diapositives, les manuels eux-mêmes et les travaux pratiques. Cette formation peut également contenir quelques images et schémas dont la redistribution est soumise à des licences différentes qui sont alors précisées.

## Marques déposées

PostgreSQL® Postgres® et le logo Slonik sont des marques déposées<sup>3</sup> par PostgreSQL Community Association of Canada.

## Versions de PostgreSQL couvertes

Ce document ne couvre que les versions supportées de PostgreSQL au moment de sa rédaction, soit les versions 12 à 16.

Sur les versions précédentes susceptibles d'être encore rencontrées en production, seuls quelques points très importants sont évoqués, en plus éventuellement de quelques éléments historiques.

Sauf précision contraire, le système d'exploitation utilisé est Linux.

---

<sup>3</sup><https://www.postgresql.org/about/policies/trademarks/>



# 1/ Masquage de données & postgresql\_anonymizer



## 1.1 CAS D'USAGE



- Paul : le propriétaire
- Pierre : *data scientist*
- Jack : employé chargé des fournisseurs

La boutique de Paul a beaucoup de clients. Paul demande à son ami Pierre, *data scientist*, des statistiques sur ses clients (âge moyen, etc.).

Pierre demande un accès direct à la base de données pour écrire ses requêtes SQL.

Jack est un employé de Paul, chargé des relations avec les divers fournisseurs de la boutique.

Paul respecte la vie privée de ses fournisseurs. Il doit masquer les informations personnelles à Pierre, mais Jack doit pouvoir lire les vraies données, et y écrire.

### Crédits

Cet exemple pratique est un travail collectif de Damien Clochard, Be Hai Tran, Florent Jardin et Frédéric Yhuel.

La version originale en anglais est diffusée sous licence PostgreSQL<sup>1</sup>.

Le présent document en est l'adaptation en français.

*Paul's Boutique* est le second album studio du groupe de hip-hop américain les *Beastie Boys*, sorti le 25 juillet 1989 chez Capitol Records.

La photo ci-dessus est d'Erwin Bernal<sup>2</sup>, sous licence CC BY 2.0<sup>3</sup>.

### 1.1.1 Objectifs



Nous allons découvrir :

- comment écrire des règles de masquage
- la différence entre masquage dynamique et masquage statique
- comment implémenter un masquage avancé

<sup>1</sup>[https://gitlab.com/dalibo/postgresql\\_anonymizer/-/tree/master/docs/how-to](https://gitlab.com/dalibo/postgresql_anonymizer/-/tree/master/docs/how-to)

<sup>2</sup><https://www.flickr.com/photos/edogisgod/16858046971/in/photolist-rFFU3g-4NZreN-xKEkv-h9ZxgT-aMD5mr-8dAvwU-cru1CN-xFfJgh-8QhtH6-6E81fG-zUN3Rg-7dCVPA-5VbEct-ewX2Lc-hA4JqP-psCh1y-dmZpzf-pjkwX-cu5NNQ-fTyVqj-MjtjRc-cLdmvW-3fd5BM-9m6ChY-dwLhRK-9d2A9s-6WsfHq-abVSJd-dWYBD4-gmJyHe-bVyJNn-SHTV2b-BoMvci-abVPJW-5pgugb-r4oJpD-6YeAE3-6kKVpZ-e4LeQN-BLUvZG-do1bDr-o5YACZ-9karFj-dPuSLW-btYwsQ-e4L9h9-abT31z-3eWVAZ-abVN43-btYwvJ>

<sup>3</sup><https://creativecommons.org/licenses/by/2.0/deed.fr>

## 2/ PostgreSQL Anonymizer

# PostgreSQL Anonymizer

### 2.0.1 Principe



Principe :

- Extension
- Déclaratif (DDL)

`postgresql_anonymizer` est une extension pour masquer ou remplacer des données personnelles<sup>1</sup> (ou PII pour *personally identifiable information*) ou toute donnée sensible dans une base de données PostgreSQL.

Le projet a une **approche déclarative** de l'anonymisation. Vous pouvez déclarer les règles de masquage<sup>2</sup> dans PostgreSQL avec du DDL (*Data Definition Language*, ou langage de définition des données) et spécifier votre stratégie d'anonymisation dans la définition de la table.

### 2.0.2 Masquages



Principe :

- statique
- dynamique
- sauvegardes anonymisées
- « généralisation »

<sup>1</sup>[https://en.wikipedia.org/wiki/Personally\\_identifiable\\_information](https://en.wikipedia.org/wiki/Personally_identifiable_information)

<sup>2</sup>[https://postgresql-anonymizer.readthedocs.io/en/stable/declare\\_masking\\_rules/](https://postgresql-anonymizer.readthedocs.io/en/stable/declare_masking_rules/)

Une fois les règles de masquage définies, vous pouvez accéder aux données anonymisées de quatre manières différentes :

- le masquage statique<sup>3</sup> : supprime les données personnelles en fonction des règles ;
- le masquage dynamique<sup>4</sup> : cache les données personnelles uniquement des utilisateurs masqués ;
- les sauvegardes anonymisées<sup>5</sup> : export des données masquées vers un fichier SQL (sauvegarde logique) ;
- la généralisation<sup>6</sup> : crée des « vues brouillées » des données originales.

Cette présentation n'entrera pas dans le détail du RGPD et des principes généraux d'anonymisation. Pour plus d'informations, référez-vous à la présentation de Damien Clochard ci-dessous :

- Anonymisation, Au-delà du RGPD (vidéo)<sup>7</sup> (PGSession 12, Paris 2019)
- Anonymisation, Au-delà du RGPD (PDF)<sup>8</sup>
- Anonymization, Beyond GDPR (PDF en anglais)<sup>9</sup>

### 2.0.3 Pré-requis



Cet exemple nécessite :

- une instance PostgreSQL ;
- l'extension **PostgreSQL Anonymizer** ( `anon` )
  - installée, initialisée par un super-utilisateur
- une base **boutique**
  - dont le propriétaire est **paul**, super-utilisateur
- les rôles **pierre** et **jack**
  - avec droits de connexion à **boutique**

Voir section « Installation »<sup>10</sup> dans la documentation<sup>11</sup> pour savoir comment installer l'extension dans votre instance PostgreSQL.

<sup>3</sup>[https://postgresql-anonymizer.readthedocs.io/en/stable/static\\_masking/](https://postgresql-anonymizer.readthedocs.io/en/stable/static_masking/)

<sup>4</sup>[https://postgresql-anonymizer.readthedocs.io/en/stable/dynamic\\_masking/](https://postgresql-anonymizer.readthedocs.io/en/stable/dynamic_masking/)

<sup>5</sup>[https://postgresql-anonymizer.readthedocs.io/en/stable/anonymous\\_dumps/](https://postgresql-anonymizer.readthedocs.io/en/stable/anonymous_dumps/)

<sup>6</sup><https://postgresql-anonymizer.readthedocs.io/en/stable/generalization/>

<sup>7</sup><https://www.youtube.com/watch?v=KGSIp4UygdU>

<sup>8</sup>[https://public.dalibo.com/exports/conferences/20191210\\_poss\\_anonymisation/anonymisation.pdf](https://public.dalibo.com/exports/conferences/20191210_poss_anonymisation/anonymisation.pdf)

<sup>9</sup>[https://public.dalibo.com/exports/conferences/20191016\\_anonymisation\\_beyond\\_GDPR/anonymisation\\_beyond\\_gdpr.pdf](https://public.dalibo.com/exports/conferences/20191016_anonymisation_beyond_GDPR/anonymisation_beyond_gdpr.pdf)

<sup>10</sup><https://postgresql-anonymizer.readthedocs.io/en/stable/INSTALL>

<sup>11</sup><https://postgresql-anonymizer.readthedocs.io/en/stable/>

Par exemple :

### 2.0.3.1 Sous Rocky Linux 8

- Les dépôts du PGDG<sup>12</sup> doivent être installés.
- Lancer :

```
sudo yum install postgresql_anonymizer_14
```

### 2.0.3.2 Par le PGXN

Sur Debian/Ubuntu, les paquets ne sont pas disponibles au moment où ceci est écrit. Le PGXN permet d'installer l'extension (ici en PostgreSQL 14) :

```
sudo apt install pgxnclient postgresql-server-dev-14
sudo pgxn install postgresql_anonymizer
```

S'il y a plusieurs versions de PostgreSQL installées, indiquer le répertoire des binaires de la bonne version ainsi :

```
sudo PATH=/usr/lib/postgresql/14/bin:$PATH pgxn install postgresql_anonymizer
```

L'extension sera compilée et installée.

## 2.0.4 Base d'exemple



**pierre, paul, jack** et la base **boutique** :

```
CREATE ROLE paul LOGIN SUPERUSER;
CREATE ROLE pierre LOGIN;
CREATE ROLE jack LOGIN;

-- Define a password for each user with:
-- \password paul or ALTER ROLE paul PASSWORD 'change-me';

CREATE DATABASE boutique OWNER paul;

ALTER DATABASE boutique
SET session_preload_libraries = 'anon';
```

Sauf précision contraire, toutes les commandes sont à exécuter en tant que **paul**.

---

<sup>12</sup><https://yum.postgresql.org/>



### 3/ Masquage statique avec postgresql\_anonymizer



- Le plus simple
- Destructif

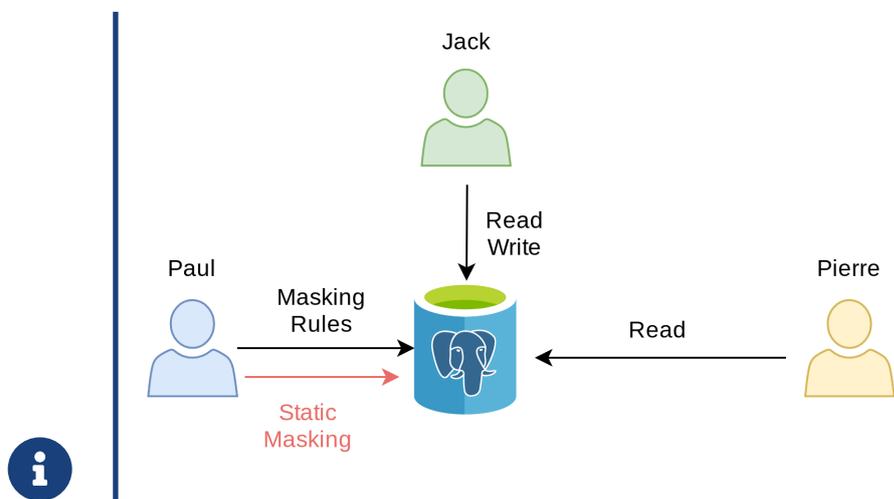
Le masquage statique est la manière la plus simple de cacher des données personnelles. L'idée est simplement de détruire les données originales et de les remplacer par des données artificielles.

### 3.1 L'HISTOIRE



- Au fil des années, Paul a accumulé des données sur ses clients et leurs achats dans une base de données très simple.
- Il a récemment installé un nouveau logiciel de ventes, et l'ancienne base est obsolète.
- Avant de l'archiver, il voudrait en supprimer toutes les données personnelles.

### 3.2 COMMENT ÇA MARCHE



### 3.3 OBJECTIFS

Nous allons voir :

- comment écrire des règles de masquage simples
- les intérêts et limitations du masquage statique
- le concept de « singularisation » d'une personne (*singling out*)

## 3.4 TABLE « CUSTOMER »



```
\c boutique paul
DROP TABLE IF EXISTS customer CASCADE;
DROP TABLE IF EXISTS payout CASCADE;

CREATE TABLE customer (
  id SERIAL PRIMARY KEY,
  firstname TEXT,
  lastname TEXT,
  phone TEXT,
  birth DATE,
  postcode TEXT
);
```

### 3.4.1 Quelques clients



Insertion de quelques personnes :

```
INSERT INTO customer
VALUES
(107,'Sarah','Conor','060-911-0911', '1965-10-10', '90016'),
(258,'Luke', 'Skywalker', NULL, '1951-09-25', '90120'),
(341,'Don', 'Draper', '347-515-3423', '1926-06-01', '04520')
;
```

```
SELECT * FROM customer;
```

id	firstname	lastname	phone	birth	postcode
107	Sarah	Conor	060-911-0911	1965-10-10	90016
258	Luke	Skywalker		1951-09-25	90120
341	Don	Draper	347-515-3423	1926-06-01	04520

(3 lignes)

## 3.5 TABLE « PAYOUT »



Les ventes sont suivies dans cette simple table :

```
CREATE TABLE payout (  
  id SERIAL PRIMARY KEY,  
  fk_customer_id INT REFERENCES customer(id),  
  order_date DATE,  
  payment_date DATE,  
  amount INT  
);
```

### 3.5.1 Quelques données



Quelques commandes :

```
INSERT INTO payout  
VALUES  
(1,107,'2021-10-01','2021-10-01','7'),  
(2,258,'2021-10-02','2021-10-03','20'),  
(3,341,'2021-10-02','2021-10-02','543'),  
(4,258,'2021-10-05','2021-10-05','12'),  
(5,258,'2021-10-06','2021-10-06','92')  
;
```

### 3.5.2 Activer l'extension



```
CREATE EXTENSION IF NOT EXISTS anon CASCADE ;  
SELECT anon.init() ;  
SELECT setseed(0) ;
```

NB : l'extension `pgcrypto` sera installée automatiquement. Ses binaires sont généralement livrés avec PostgreSQL.

## 3.6 DÉCLARER LES RÈGLES DE MASQUAGE



```
SECURITY LABEL FOR anon ON COLUMN customer.lastname
IS 'MASKED WITH FUNCTION anon.fake_last_name()';

SECURITY LABEL FOR anon ON COLUMN customer.phone
IS 'MASKED WITH FUNCTION anon.partial(phone,2,$$X-XXX-XX$$,2)';
```

Paul veut masquer le nom de famille et le numéro de téléphone de ses clients.

Pour cela, il utilise les fonctions `fake_last_name()` et `partial()`.

### 3.7 APPLIQUER LES RÈGLES DE MANIÈRE PERMANENTE



```
SELECT anon.anonymize_table('customer');
```

Cette fonction ne fait qu'appliquer la règle et doit renvoyer True. Ensuite :

```
SELECT id, firstname, lastname, phone  
FROM customer;
```

id	firstname	lastname	phone
107	Sarah	Okuneva	06X-XXX-XX11
258	Luke	Okuneva	
341	Don	Boyle	34X-XXX-XX23



Cette technique est nommée « masquage statique » car la donnée réelle a été détruite de manière définitive. L'anonymisation dynamique et les exports seront vus plus loin.

## 3.8 EXERCICES

### 3.8.1 E101 - Masquer les prénoms des clients

Déclarer une nouvelle règle de masquage et relancer l'anonymisation statique.

### 3.8.2 E102 - Masquer les 3 derniers chiffres du code postal

Paul réalise que le code postal est un bon indice sur l'endroit où vivent ses clients. Cependant, il voudrait pouvoir faire des statistiques par département.

Créer une règle de masquage pour remplacer les 3 derniers chiffres du code postal par 'x'.

### 3.8.3 E103 - Compter le nombre de clients dans chaque département.

Agréger les clients selon le code postal anonymisé.

### 3.8.4 E104 - Ne garder que l'année dans les dates de naissance

Paul veut des statistiques selon l'âge. Mais il veut aussi masquer les vraies dates de naissance de ses clients.

Remplacer toutes les dates de naissance par le 1er janvier, en conservant l'année réelle. Utiliser la fonction `make_date`<sup>a</sup>.

<sup>a</sup><https://www.postgresql.org/docs/current/functions-datetime.html#FUNCTIONS-DATETIME-TABLE>

### 3.8.5 E105 - Identifier un client particulier

Même si un client est correctement anonymisé, il est possible d'isoler un individu grâce à des données d'autres tables. Par exemple, il est possible d'identifier le meilleur client de Paul avec une telle requête :

```
WITH best_client AS (  
    SELECT SUM(amount), fk_customer_id  
    FROM payout  
    GROUP BY fk_customer_id  
    ORDER BY 1 DESC  
    LIMIT 1  
)  
SELECT c.*  
FROM customer c  
JOIN best_client b ON (c.id = b.fk_customer_id) ;
```

id	firstname	lastname	phone	birth	postcode
341	Don	Boyle	34X-XXX-XX23	1926-06-01	04520

Ce processus est appelé « singularisation » (*singling out*<sup>1</sup>) d'une personne.

Il faut donc aller plus loin dans l'anonymisation, en supprimant le lien entre une personne et sa société. Dans la table des commandes `order`, ce lien est matérialisé par une clé étrangère sur le champ `fk_company_id`. Mais nous ne pouvons supprimer des valeurs de cette colonne ou y insérer de faux identifiants, car cela briserait la contrainte de clé étrangère.

Comment séparer les clients de leurs paiements tout en respectant l'intégrité des données ?

Trouver une fonction qui mélange les valeurs de `fk_company_id` dans la table `payout`. Consulter la section *shuffling*<sup>a</sup> de la documentation<sup>b</sup>.

<sup>a</sup>[https://postgresql-anonymizer.readthedocs.io/en/stable/static\\_masking/#shuffling](https://postgresql-anonymizer.readthedocs.io/en/stable/static_masking/#shuffling)

<sup>b</sup><https://postgresql-anonymizer.readthedocs.io/en/stable/>

<sup>1</sup><https://www.pnas.org/content/117/15/8344>

## 3.9 SOLUTIONS

### 3.9.1 S101

```
SECURITY LABEL FOR anon ON COLUMN customer.firstname
IS 'MASKED WITH FUNCTION anon.fake_first_name()' ;
```

```
SELECT anon.anonymize_table('customer') ;
```

La table anonymisée devient :

```
SELECT id, firstname, lastname
FROM customer ;
```

id	firstname	lastname
107	Hans	Barton
258	Jacqueline	Dare
341	Sibyl	Runte

### 3.9.2 S102

```
SECURITY LABEL FOR anon ON COLUMN customer.postcode
IS 'MASKED WITH FUNCTION anon.partial(postcode,2,$$xxx$$,0)' ;
```

```
SELECT anon.anonymize_table('customer') ;
```

Le code postal anonymisé devient :

```
SELECT id, firstname, lastname, postcode
FROM customer ;
```

id	firstname	lastname	postcode
107	Curt	O'Hara	90xxx
258	Agusta	Towne	90xxx
341	Sid	Hane	04xxx

Noter que les noms ont encore changé après application de `anon.anonymize_table()`.

### 3.9.3 S103

```
SELECT postcode, COUNT(id)
FROM customer
GROUP BY postcode;
```

postcode	count
90xxx	2
04xxx	1

### 3.9.4 S104

```
SECURITY LABEL FOR anon ON COLUMN customer.birth
IS 'MASKED WITH FUNCTION make_date(EXTRACT(YEAR FROM birth)::INT,1,1)';

SELECT anon.anonymize_table('customer');
```

Les dates de naissance anonymisées deviennent :

```
SELECT id, firstname, lastname, birth
FROM customer ;
```

id	firstname	lastname	birth
107	Pinkie	Sporer	1965-01-01
258	Zebulon	Gerlach	1951-01-01
341	Erna	Emmerich	1926-01-01

### 3.9.5 S105

Pour mélanger les valeurs de `fk_customer_id` :

```
SELECT anon.shuffle_column('payout', 'fk_customer_id', 'id') ;
```

Si l'on essaie à nouveau d'identifier le meilleur client :

```
WITH best_client AS (
  SELECT SUM(amount), fk_customer_id
  FROM payout
  GROUP BY fk_customer_id
  ORDER BY 1 DESC
  LIMIT 1
)
SELECT c.*
FROM customer c
JOIN best_client b ON (c.id = b.fk_customer_id) ;
```

id	firstname	lastname	phone	birth	postcode
258	Zebulon	Gerlach		1951-01-01	90xxx



Noter que le lien entre un client (`customer`) et ses paiements (`payout`) est à présent complètement faux !

Par exemple, si un client A a deux paiements, l'un se retrouvera associé à un client B, et l'autre à un client C. En d'autres termes, cette méthode de mélange respectera la contrainte d'intégrité technique, mais brisera l'intégrité des données. Pour certaines utilisations, ce peut être problématique.

Ici, Pierre ne pourra pas produire de rapport avec les données mélangées.

## **4/ Masquage dynamique avec postgresql\_anonymizer**

## 4.1 PRINCIPE DU MASQUAGE DYNAMIQUE



- Masquer les données personnelles à certains utilisateurs
  - mais pas tous

Avec le masquage dynamique, le propriétaire de la base peut masquer les données personnelles à certains utilisateurs, tout en laissant aux autres les droits de lire et modifier les données réelles.

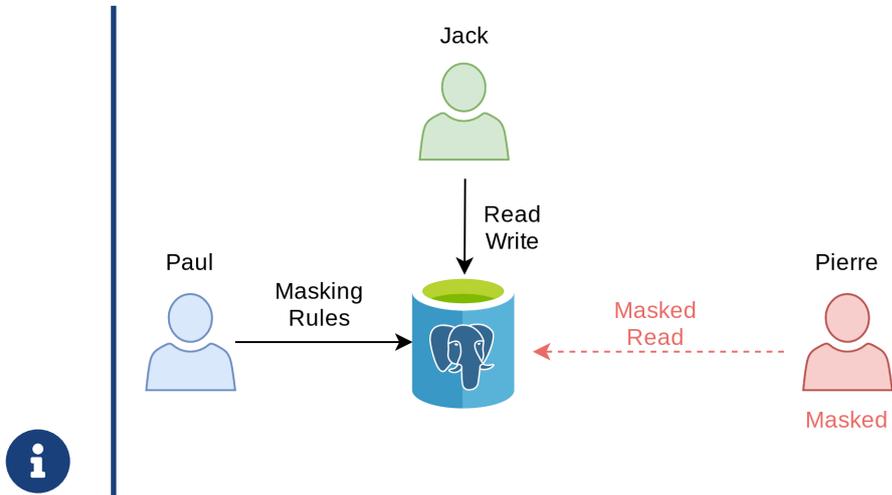
## 4.2 L'HISTOIRE



Paul a 2 employés :

- **Jack** s'occupe du nouveau logiciel de ventes.
  - il a besoin d'accéder aux vraies données
  - pour le RGPD c'est un « processeur de données »
- **Pierre** est un analyste qui exécute des requêtes statistiques
  - il ne doit pas avoir accès aux données personnelles

### 4.3 COMMENT ÇA MARCHE



## 4.4 OBJECTIFS DE LA SECTION



Nous allons voir :

- comment écrire des règles de masquage simple
- les avantages et limitations du masquage dynamique
- le concept de « recoupement » d'une personne (*linkability*)

## 4.5 TABLE « COMPANY »



```
DROP TABLE IF EXISTS supplier CASCADE;  
DROP TABLE IF EXISTS company CASCADE;  
  
CREATE TABLE company (  
  id SERIAL PRIMARY KEY,  
  name TEXT,  
  vat_id TEXT UNIQUE  
);
```

### 4.5.1 Quelques données



```
INSERT INTO company  
VALUES  
(952,'Shadrach', 'FR62684255667'),  
(194,E'Johnny\'s Shoe Store','CHE670945644'),  
(346,'Capitol Records','GB663829617823')  
;
```

```
SELECT * FROM company ;
```

id	name	vat_id
952	Shadrach	FR62684255667
194	Johnny's Shoe Store	CHE670945644
346	Capitol Records	GB663829617823

## 4.6 TABLE « SUPPLIER »



```
CREATE TABLE supplier (  
  id SERIAL PRIMARY KEY,  
  fk_company_id INT REFERENCES company(id),  
  contact TEXT,  
  phone TEXT,  
  job_title TEXT  
);
```

### 4.6.1 Quelques données



```
INSERT INTO supplier  
VALUES  
(299,194,'Johnny Ryall','597-500-569','CEO'),  
(157,346,'George Clinton','131-002-530','Sales manager')  
;
```

```
SELECT * FROM supplier;
```

id	fk_company_id	contact	phone	job_title
299	194	Johnny Ryall	597-500-569	CEO
157	346	George Clinton	131-002-530	Sales manager

## 4.7 ACTIVER L'EXTENSION



```
CREATE EXTENSION IF NOT EXISTS anon CASCADE ;  
SELECT anon.init() ;  
SELECT setseed(0) ;
```

## 4.8 ACTIVER LE MASQUAGE DYNAMIQUE



```
SELECT anon.start_dynamic_masking();
```

## 4.9 RÔLE MASQUÉ



```
SECURITY LABEL FOR anon ON ROLE pierre IS 'MASKED' ;
```

```
GRANT ALL ON SCHEMA public TO jack ;  
GRANT ALL ON ALL TABLES IN SCHEMA public TO jack ;  
GRANT SELECT ON supplier TO pierre ;
```

Le rôle **pierre** devient « masqué », dans le sens où le super-utilisateur va pouvoir lui imposer un masque qui va changer sa vision des données.

En tant que Pierre, on essaie de lire la table des fournisseurs :

```
\c boutique pierre  
SELECT * FROM supplier;
```

id	fk_company_id	contact	phone	job_title
299	194	Johnny Ryall	597-500-569	CEO
157	346	George Clinton	131-002-530	Sales manager

Pour le moment, il n'y a pas de règle de masquage : Pierre peut voir les données originales dans chaque table.

## 4.10 MASQUER LE NOM DES FOURNISSEURS



En tant que Paul, une règle de masquage se définit ainsi :

```
\c boutique paul
SECURITY LABEL FOR anon ON COLUMN supplier.contact
IS 'MASKED WITH VALUE $$CONFIDENTIAL$$';
```

Pierre essaie de lire la table des fournisseurs :

```
\c boutique pierre
SELECT * FROM supplier ;
```

id	fk_company_id	contact	phone	job_title
299	194	CONFIDENTIAL	597-500-569	CEO
157	346	CONFIDENTIAL	131-002-530	Sales manager

Si Jack essaie de lire les vraies données, ce sont encore les bonnes :

```
\c boutique jack
SELECT * FROM supplier;
```

id	fk_company_id	contact	phone	job_title
299	194	Johnny Ryall	597-500-569	CEO
157	346	George Clinton	131-002-530	Sales manager

## 4.11 EXERCICES

### 4.11.1 E201 - Deviner qui est le PDG de « Johnny's Shoe Store »

Masquer le nom du fournisseur n'est pas suffisant pour anonymiser les données.

Se connecter en tant que Pierre. Écrire une requête simple permettant de recouper certains fournisseurs en se basant sur leur poste et leur société.

Les noms des sociétés et les postes de travail sont disponibles dans de nombreux jeux de données publics. Une simple recherche sur LinkedIn ou Google révèle les noms des principaux dirigeants de la plupart des sociétés...



On nomme « recoupement » la possibilité de rapprocher plusieurs données concernant la même personne.

### 4.11.2 E202 - Anonymiser les sociétés

Nous devons donc anonymiser aussi la table `company`. Même si elle ne contient pas d'informations personnelles, certains champs peuvent être utilisés pour identifier certains de leurs employés...

Écrire deux règles de masquage pour la table `company`. La première doit remplacer le champ `nom` avec un faux nom. La seconde remplacer `vat_id` avec une suite aléatoire de dix caractères. NB : dans la documentation<sup>a</sup>, consulter les générateurs de données factices<sup>b</sup> et fonctions aléatoires<sup>c</sup> (*faking functions*).

<sup>a</sup><https://postgresql-anonymizer.readthedocs.io/en/stable/>

<sup>b</sup>[https://postgresql-anonymizer.readthedocs.io/en/stable/masking\\_functions#faking](https://postgresql-anonymizer.readthedocs.io/en/stable/masking_functions#faking)

<sup>c</sup>[https://postgresql-anonymizer.readthedocs.io/en/stable/masking\\_functions#randomization](https://postgresql-anonymizer.readthedocs.io/en/stable/masking_functions#randomization)

Vérifier que Pierre ne peut pas voir les vraies données sur la société.

### 4.11.3 E203 - Pseudonymiser le nom des sociétés

À cause du masquage dynamique, les valeurs artificielles sont différentes **à chaque fois que Pierre lit la table**. Ce n'est pas toujours très pratique.

Pierre préfère appliquer tout le temps les mêmes valeurs artificielles pour une même société. Cela correspond à la « pseudonymisation ».



La **pseudonymisation** consiste à générer systématiquement les mêmes données artificielles pour un individu donné à la place de ses données réelles.

Écrire une nouvelle règle de masquage à partir du champ `name`, grâce à une fonction de pseudonymisation<sup>a</sup>.

<sup>a</sup>[https://postgresql-anonymizer.readthedocs.io/en/stable/masking\\_functions#pseudonymization](https://postgresql-anonymizer.readthedocs.io/en/stable/masking_functions#pseudonymization)

## 4.12 SOLUTIONS

### 4.12.1 S201

```
\c boutique pierre
SELECT s.id, s.contact, s.job_title, c.name
FROM supplier s
JOIN company c ON s.fk_company_id = c.id ;
```

id	contact	job_title	name
299	CONFIDENTIAL	CEO	Johnny's Shoe Store
157	CONFIDENTIAL	Sales manager	Capitol Records

### 4.12.2 S202

```
\c boutique paul
SECURITY LABEL FOR anon ON COLUMN company.name
IS 'MASKED WITH FUNCTION anon.fake_company()';

SECURITY LABEL FOR anon ON COLUMN company.vat_id
IS 'MASKED WITH FUNCTION anon.random_string(10)';
```

En tant Pierre, relire la table :

```
\c boutique pierre
SELECT * FROM company;
```

id	name	vat_id
952	Graham, Davis and Bauer	LYFVSI3WT5
194	Martinez-Smith	9N62K8M6JD
346	James, Rodriguez and Nelson	0HB200Z4Q3

À chaque lecture de la table, Pierre voit des données différentes :

```
SELECT * FROM company;
```

id	name	vat_id
952	Holt, Moreno and Richardson	KPAJP2Q4PK
194	Castillo Group	NVGHZ1K50Z
346	Mccarthy-Davis	GS3AHXBQTK

### 4.12.3 S203

```
\c boutique paul
ALTER FUNCTION anon.pseudo_company SECURITY DEFINER;

SECURITY LABEL FOR anon ON COLUMN company.name
IS 'MASKED WITH FUNCTION anon.pseudo_company(id)';
```

Pour Pierre, les valeurs pseudonymisées resteront identiques entre deux appels (mais pas le code TVA):

```
\c boutique pierre
```

```
SELECT * FROM company;
```

id	name	vat_id
952	Wilkinson LLC	IKL88GJVT4
194	Johnson PLC	V00J6UKR6H
346	Young-Carpenter	DUR78F15VD

```
SELECT * FROM company;
```

id	name	vat_id
952	Wilkinson LLC	DIUAMTI653
194	Johnson PLC	UND2DQGL4S
346	Young-Carpenter	X6E0T023AK



## 5/ Sauvegardes anonymes avec `postgresql_anonymizer`

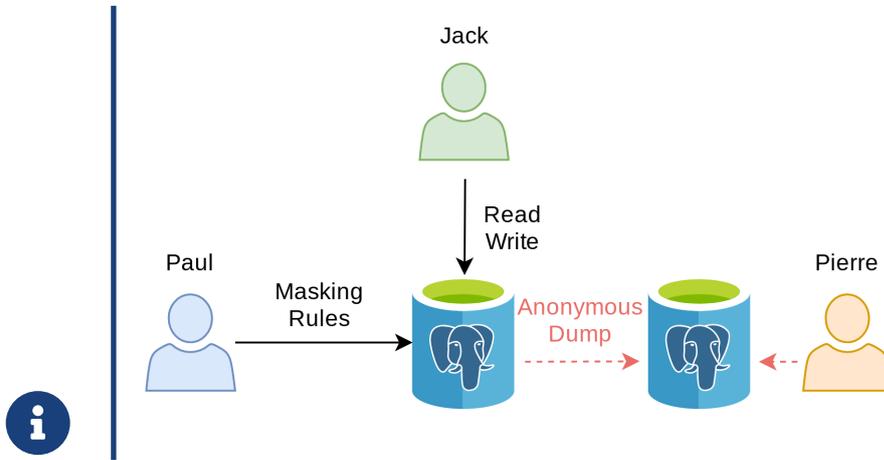
Dans beaucoup de situations, le besoin est simplement d'exporter les données anonymisées pour les importer dans une autre base de données, pour mener des tests ou produire des statistiques. C'est ce que permet de faire l'outil `pg_dump_anon`.

## 5.1 L'HISTOIRE



- Paul a un site web qui dispose d'une section commentaires où les utilisateurs peuvent partager leurs points de vue.
- Paul a engagé un prestataire pour développer le nouveau design de son site web.
- Le prestataire lui demande un export de la base de données.
- Paul veut « nettoyer » le dump et y retirer toute information personnelle qui pourrait figurer dans la section commentaire.

## 5.2 COMMENT ÇA MARCHE ?



## 5.3 OBJECTIFS



- Extraire les données anonymisées de la base de données
- Écrire une fonction de masquage personnalisée pour gérer une colonne de type JSON

## 5.4 TABLE « WEBSITE\_COMMENT »



```
\c boutique paul
DROP TABLE IF EXISTS website_comment CASCADE ;

CREATE TABLE website_comment (
  id SERIAL PRIMARY KEY,
  message jsonb
) ;
```

### 5.4.1 Quelques données



```
curl -kLs https://dali.bo/website_comment -o /tmp/website_comment.tsv
head /tmp/website_comment.tsv

1  {"meta": {"name": "Lee Perry", "ip_addr": "40.87.29.113"},
   ↪ "content": "Hello Nasty!"}
2  {"meta": {"name": "", "email": "biz@bizmarkie.com"}, "content":
   ↪ "Great Shop"}
3  {"meta": {"name": "Jimmy"}, "content": "Hi! This is me, Jimmy
   ↪ James "}
```

```
\c boutique paul
\copy website_comment from '/tmp/website_comment.tsv'
```

```
SELECT jsonb_pretty(message)
FROM website_comment
ORDER BY id ASC
LIMIT 1 ;
```

```
-----
jsonb_pretty
-----
{
  "meta": {
    "name": "Lee Perry",
    "ip_addr": "40.87.29.113"
  },
  "content": "Hello Nasty!"
}
```

## 5.5 ACTIVER L'EXTENSION



```
\c boutique paul
```

```
CREATE EXTENSION IF NOT EXISTS anon CASCADE;
```

```
SELECT anon.init();
```

```
SELECT setseed(0);
```

## 5.6 MASQUER UNE COLONNE DE TYPE JSON



Généralement, les données non structurées sont difficiles à masquer...

```
SELECT message - ARRAY['content']
FROM website_comment
WHERE id=1 ;
```

La colonne `comment` contient beaucoup d'informations personnelles. Le fait de ne pas utiliser un schéma standard pour les commentaires rend ici la tâche plus complexe.

Comme on peut le voir, les visiteurs du site peuvent écrire toutes sortes d'informations dans la section « commentaire ». La meilleure option serait donc de supprimer entièrement la clé JSON car il est impossible d'y exclure les données sensibles.

Il est possible de nettoyer la colonne `comment` en supprimant la clé `content` :

```
SELECT message - ARRAY['content']
FROM website_comment
WHERE id=1 ;
```

### 5.6.1 Fonctions de masquage personnalisées



```
\c boutique paul
```

```
CREATE SCHEMA IF NOT EXISTS my_masks;

SECURITY LABEL FOR anon ON SCHEMA my_masks IS 'TRUSTED';

CREATE OR REPLACE FUNCTION my_masks.remove_content(j jsonb)
RETURNS jsonb
AS $func$
  SELECT j - ARRAY['content']
$func$
LANGUAGE sql ;
```

- Super-utilisateurs seulement !

Créer en premier lieu un schéma dédié, ici **my\_masks**, et le déclarer en `trusted` (« de confiance »). Cela signifie que l'extension `anon` va considérer les fonctions de ce schéma comme des fonctions de masquage valides.



Seul un super-utilisateur devrait être capable d'ajouter des fonctions dans ce schéma !

Cette fonction de masquage se contente de supprimer du JSON le champ avec le message :

```
CREATE OR REPLACE FUNCTION my_masks.remove_content(j jsonb)
RETURNS jsonb
AS $func$
  SELECT j - ARRAY['content']
$func$
LANGUAGE sql ;
```

Exécuter la fonction :

```
SELECT my_masks.remove_content(message)
FROM website_comment ;

{"meta": {"name": "Lee Perry", "ip_addr": "40.87.29.113"}}
{"meta": {"name": "", "email": "biz@bizmarkie.com"}}
{"meta": {"name": "Jimmy"}}
```

La fonction va pouvoir ensuite être utilisée dans une règle de masquage.

## 5.6.2 Utilisation de la fonction de masquage personnalisée



```
SECURITY LABEL FOR anon ON COLUMN website_comment.message
IS 'MASKED WITH FUNCTION my_masks.remove_content(message)';
```

## 5.6.3 Sauvegarde anonymisée



- Export

```
pg_dump_anon.sh -U paul -d boutique --table=website_comment >
↵ /tmp/dump.sql
```

- Limitations : risque d'inconsistance, format plain

Enfin, une **sauvegarde logique anonymisée** de la table peut être exportée avec l'utilitaire `pg_dump_anon`. Celui-ci est un script, livré avec l'extension, disponible dans le répertoire des binaires :

L'outil utilise `pg_dump`, il vaut mieux qu'il n'y ait pas d'ambiguïté sur le chemin :

```
export PATH=$PATH:$(pg_config --bindir)
pg_dump_anon.sh --help

export PATH=$PATH:$(pg_config --bindir)
export PGHOST=localhost
export PGUSER=paul
pg_dump_anon.sh boutique --table=website_comment > /tmp/dump.sql
```

En ne demandant que les données (option `-a`), le résultat contient notamment :

```
COPY public.website_comment (id, message) FROM stdin;
1      {"meta": {"name": "Lee Perry", "ip_addr": "40.87.29.113"}, "content": "Hello
↵     Nasty!"}
2      {"meta": {"name": "", "email": "biz@bizmarkie.com"}, "content": "Great Shop"}
3      {"meta": {"name": "Jimmy"}, "content": "Hi ! This is me, Jimmy James "}
\.
```



`pg_dump_anon` ne vise pas à réimplémenter toutes les fonctionnalités de `pg_dump`. Il n'en supporte qu'une partie, notamment l'extraction d'objets précis, mais pas la compression par exemple. De plus, en raison de son fonctionnement interne, il y a un risque que la restauration des données soit incohérente, notamment en cas de DML ou DDL pendant la sauvegarde. Une sauvegarde totalement cohérente impose de passer un masquage statique et un export classique par `pg_dump`.

Le produit est en développement actif et la situation peut avoir changé depuis que ces lignes ont été écrites. Il est notamment prévu que le script bash soit remplacé par un script en go.

## 5.7 EXERCICES

### 5.7.1 E301 - Exporter les données anonymisées dans une nouvelle base de données

Créer une base de données nommée **boutique\_anon**. y insérer les données anonymisées provenant de la base de données **boutique**.

### 5.7.2 E302 - Pseudonymiser les métadonnées du commentaire

Pierre compte extraire des informations générales depuis les métadonnées. Par exemple, il souhaite calculer le nombre de visiteurs uniques sur la base des adresses IP des visiteurs, mais une adresse IP est un **identifiant indirect**.

Paul doit donc anonymiser cette colonne tout en conservant la possibilité de faire le lien entre les enregistrements provenant de la même adresse.

Remplacer la fonction `remove_content` par la fonction `clean_comment` (ci-dessous), qui : - supprime la clé JSON `content` ; - remplace la valeur dans la colonne `name` par un faux nom ; - remplace l'adresse IP dans la colonne `ip_address` par sa somme de contrôle `md5` ; - met à `NULL` la clé `email`.

```
CREATE OR REPLACE FUNCTION my_masks.clean_comment(message jsonb)
RETURNS jsonb
VOLATILE
LANGUAGE SQL
AS $func$
SELECT
  jsonb_set(
    message,
    ARRAY['meta'],
    jsonb_build_object(
      'name',anon.fake_last_name(),
      'ip_address', md5((message->'meta'->'ip_addr')::TEXT),
      'email', NULL
    )
  ) - ARRAY['content'];
$func$;
```

## 5.8 SOLUTIONS

### 5.8.1 S301

```
export PATH=$PATH:$(pg_config --bindir)
export PGHOST=localhost
export PGUSER=paul
dropdb --if-exists boutique_anon
createdb boutique_anon --owner paul
pg_dump_anon.sh boutique | psql --quiet boutique_anon

export PGHOST=localhost
export PGUSER=paul
psql boutique_anon -c 'SELECT COUNT(*) FROM company'
```

```
count
-----
      3
```

### 5.8.2 S302

Suite à utilisation de la fonction personnalisée `clean_comment`, les données n'ont plus rien à voir :

```
SELECT my_masks.clean_comment(message)
FROM website_comment;
```

```
clean_comment
-----
↪ -----
{"meta": {"name": "Heller", "email": null, "ip_address":
↪ "1d8cbcdef988d55982af1536922ddcd1"}}
{"meta": {"name": "Christiansen", "email": null, "ip_address": null}}
{"meta": {"name": "Frami", "email": null, "ip_address": null}}
(3 lignes)
```

On applique le masquage comme à l'habitude :

```
SECURITY LABEL FOR anon ON COLUMN website_comment.message
IS 'MASKED WITH FUNCTION my_masks.clean_comment(message)';
```



## **6/ Généralisation avec postgresql\_anonymizer**

## 6.1 PRINCIPE



- Flouter les données
- Par ex : 25 juillet 1989 ⇒ années 1980

L'idée derrière la **généralisation** est de pouvoir flouter une donnée originale.

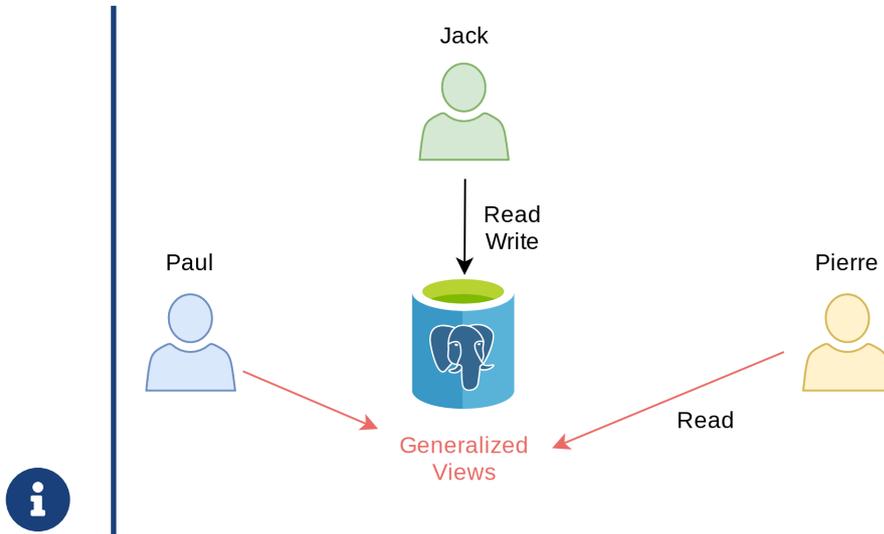
Par exemple, au lieu de dire « Monsieur X est né le 25 juillet 1989 », on peut dire « Monsieur X est né dans les années 1980 ». L'information reste vraie, bien que moins précise, et elle rend plus difficile l'identification de la personne.

## 6.2 L'HISTOIRE



- Paul a embauché des dizaines de salariés au fil du temps.
- Il conserve une trace sur la couleur de leurs cheveux, leurs tailles, et leurs conditions médicales.
- Paul souhaite extraire des statistiques depuis ces détails.
- Il fournit des vues **généralisées** à Pierre.

### 6.3 COMMENT ÇA MARCHE ?



## 6.4 OBJECTIFS



Nous allons voir :

- la différence entre le **masquage** et la **généralisation**
- le concept de « *k*-anonymat »

## 6.5 TABLE « EMPLOYEE »



```
DROP TABLE IF EXISTS employee CASCADE;  
CREATE TABLE employee (  
  id INT PRIMARY KEY,  
  full_name TEXT,  
  first_day DATE, last_day DATE,  
  height INT,  
  hair TEXT, eyes TEXT, size TEXT,  
  asthma BOOLEAN,  
  CHECK(hair = ANY(ARRAY['bald', 'blond', 'dark', 'red'])),  
  CHECK(eyes = ANY(ARRAY['blue', 'green', 'brown'])),  
  CHECK(size = ANY(ARRAY['S', 'M', 'L', 'XL', 'XXL']))  
);
```

- Légal?

Bien sûr, stocker les caractéristiques physiques d'employés est généralement illégal. Quoi qu'il en soit, il sera impératif de les masquer.

## 6.6 QUELQUES DONNÉES



```
curl -Ls https://dali.bo/employee -o /tmp/employee.tsv  
  
\c boutique paul  
\COPY employee FROM '/tmp/employee.tsv'
```

Ce fichier charge 16 lignes, dont :

```
SELECT full_name,first_day, hair, size, asthma  
FROM employee  
LIMIT 3 ;
```

full_name	first_day	hair	size	asthma
Luna Dickens	2018-07-22	blond	L	t
Paul Wolf	2020-01-15	bald	M	f
Rowan Hoeger	2018-12-01	dark	XXL	t

## 6.7 SUPPRESSION DE DONNÉES



Pierre peut trouver un lien entre asthme et yeux verts :

```
\c boutique paul
DROP MATERIALIZED VIEW IF EXISTS v_asthma_eyes ;

CREATE MATERIALIZED VIEW v_asthma_eyes AS
SELECT eyes, asthma
FROM employee ;
```

Paul souhaite savoir s'il y a une corrélation entre l'asthme et la couleur des yeux.

Il fournit à Pierre la vue ci-dessus, qui peut désormais écrire des requêtes sur cette vue :

```
SELECT *
FROM v_asthma_eyes
LIMIT 3;
```

eyes	asthma
blue	t
brown	f
blue	t

```
SELECT
  eyes,
  100*COUNT(1) FILTER (WHERE asthma) / COUNT(1) AS asthma_rate
FROM v_asthma_eyes
GROUP BY eyes ;
```

eyes	asthma_rate
green	100
brown	37
blue	33

Paul vient de prouver que l'asthme est favorisé par les yeux verts, et surtout de trouver une corrélation entre deux champs.

## 6.8 CALCULER LE K-ANONYMAT



- Les colonnes `asthma` et `eyes` sont considérés comme des identifiants indirects.

```
\c boutique paul
SECURITY LABEL FOR anon ON COLUMN v_asthma_eyes.eyes
IS 'INDIRECT IDENTIFIER';

SECURITY LABEL FOR anon ON COLUMN v_asthma_eyes.asthma
IS 'INDIRECT IDENTIFIER';

SELECT anon.k_anonymity('v_asthma_eyes');
```

```
SELECT anon.k_anonymity('v_asthma_eyes');
```

```
k_anonymity
-----
                2
```

La vue `v_asthma_eyes` a le niveau « 2-anonymity ». Cela signifie que chaque combinaison de quasi-identifiants (`eyes` - `asthma`) apparaît au moins 2 fois dans le jeu de données.

En d'autres termes, cela veut dire qu'un individu ne peut pas être distingué d'au moins un autre individu ( $k-1$ ) dans cette vue.

Pour les détails sur le K-anonymat, voir cet article sur Wikipédia<sup>1</sup>.

<sup>1</sup><https://en.wikipedia.org/wiki/K-anonymity>

## 6.9 FONCTIONS D'INTERVALLE ET DE GÉNÉRALISATION



```
\c boutique paul
DROP MATERIALIZED VIEW IF EXISTS v_staff_per_month ;

CREATE MATERIALIZED VIEW v_staff_per_month AS
SELECT
    anon.generalize_daterange(first_day, 'month') AS first_day,
    anon.generalize_daterange(last_day, 'month') AS last_day
FROM employee ;

GRANT SELECT ON v_staff_per_month TO pierre ;
```

```
\c boutique pierre
SELECT *
FROM v_staff_per_month
LIMIT 3;
```

first_day	last_day
[2018-07-01,2018-08-01)	[2018-12-01,2019-01-01)
[2020-01-01,2020-02-01)	(,)
[2018-12-01,2019-01-01)	[2018-12-01,2019-01-01)

Pierre peut écrire une requête pour trouver le nombre d'employés embauchés en novembre 2021 :

```
SELECT COUNT(1)
    FILTER (
        WHERE make_date(2019,11,1)
            BETWEEN lower(first_day)
            AND COALESCE(upper(last_day),now())
    )
FROM v_staff_per_month ;
```

```
count
-----
4
```

### 6.9.1 Déclarer les identifiants indirects



Calculer le facteur de  $k$ -anonymat de cette vue :

```
\c boutique paul
SECURITY LABEL FOR anon ON COLUMN v_staff_per_month.first_day
IS 'INDIRECT IDENTIFIER';
SECURITY LABEL FOR anon ON COLUMN v_staff_per_month.last_day
IS 'INDIRECT IDENTIFIER';

SELECT anon.k_anonymity('v_staff_per_month');
```

Dans ce cas, le résultat est 1, ce qui veut dire qu'au moins une personne peut être directement identifiée par les dates de ses premier et dernier jour en poste.

Dans ce cas, la généralisation est insuffisante.

## 6.10 EXERCICES

### 6.10.1 E401 - Simplifier la vue `v_staff_per_month` pour en réduire la granularité.

Généraliser les dates en mois n'est pas suffisant. > Écrire une autre vue > `v_staff_per_year` qui va généraliser les dates en années. > Simplifier également la vue en utilisant un intervalle de `int` pour stocker > l'année, plutôt qu'un intervalle de `date`.

### 6.10.2 E402 - Progression du personnel au fil des années

Combien de personnes ont travaillé pour Paul chaque année entre 2018 et 2021 ?

### 6.10.3 E403 - Atteindre le facteur *2-anonymity* sur la vue `v_staff_per_year`

Quel est le facteur *k*-anonymat de la vue `v_staff_per_year` ?

## 6.11 SOLUTIONS

### 6.11.1 S401

Cette vue généralise les dates en années :

```
\c boutique paul
DROP MATERIALIZED VIEW IF EXISTS v_staff_per_year;
CREATE MATERIALIZED VIEW v_staff_per_year AS
SELECT
  int4range(
    extract(year from first_day)::INT,
    extract(year from last_day)::INT,
    '[]' -- include upper bound
  ) AS period
FROM employee;

SELECT *
FROM v_staff_per_year
LIMIT 3;
```

```
   period
-----
[2018,2019)
[2020,)
[2018,2019)
```

### 6.11.2 S402

Les personnes ayant travaillé pour Paul entre 2018 et 2021 sont :

```
SELECT
  year,
  COUNT(1) FILTER (
    WHERE year <@ period
  )
FROM
  generate_series(2018,2021) year,
  v_staff_per_year
GROUP BY year
ORDER BY year ASC;
```

```
 year | count
-----+-----
 2018 |     4
 2019 |     6
 2020 |     9
 2021 |    10
```

### 6.11.3 S403

Le k-anonymat de cette vue est meilleur :

```
SECURITY LABEL FOR anon ON COLUMN v_staff_per_year.period  
IS 'INDIRECT IDENTIFIER';
```

```
SELECT anon.k_anonymity('v_staff_per_year');
```

```
k_anonymity  
-----  
2
```

## **7/ Conclusion sur postgresql\_anonymizer**

## 7.1 BEAUCOUP DE STRATÉGIES DE MASQUAGE



- Masquage statique<sup>1</sup> : parfait pour une anonymisation « une fois pour toute »
- Masquage dynamique<sup>2</sup> : utile pour masquer des informations à certains utilisateurs
- Sauvegardes anonymisées<sup>3</sup> : peuvent être utilisées dans des traitement CI/CD
- Généralisation<sup>4</sup> : adaptée aux statistiques et à l'analyse de données

## 7.2 BEAUCOUP DE FONCTIONS DE MASQUAGE



- Destruction partielle ou totale
- Ajout de bruit
- Randomisation
- Falsification et falsification avancée
- Pseudonymisation
- Hachage générique
- Masquage personnalisé

RTFM -> Fonctions de masquage<sup>5</sup>

## 7.3 AVANTAGES



- Règles de masquage en SQL
- Règles de masquage stockées dans le schéma de la base
- Pas besoin d'un ETL
- Fonctionne avec toutes les versions actuelles de PostgreSQL
- Multiples stratégies, multiples fonctions.

## 7.4 INCONVÉNIENTS



- Ne fonctionne pas avec d'autres systèmes de gestion de bases de données (comme le nom l'indique)
- Peu de retour d'expérience sur de gros volumes (> 10 To)

## 7.5 POUR ALLER PLUS LOIN



D'autres projets qui pourraient vous plaire :

- `pg_sample`<sup>6</sup> : Extraire un petit jeu de données d'une base de données volumineuse
- PostgreSQL Faker<sup>7</sup> : Une extension de falsification avancée basée sur la bibliothèque python `Faker`.

## 7.6 CONTRIBUEZ !



C'est un projet libre !

[labs.dalibo.com/postgresql\\_anonymizer](https://labs.dalibo.com/postgresql_anonymizer)<sup>8</sup>

Merci de vos retours sur la manière dont vous l'utilisez, comment il répond ou non à vos attentes, etc.

### 7.6.1 Questions



N'hésitez pas, c'est le moment !

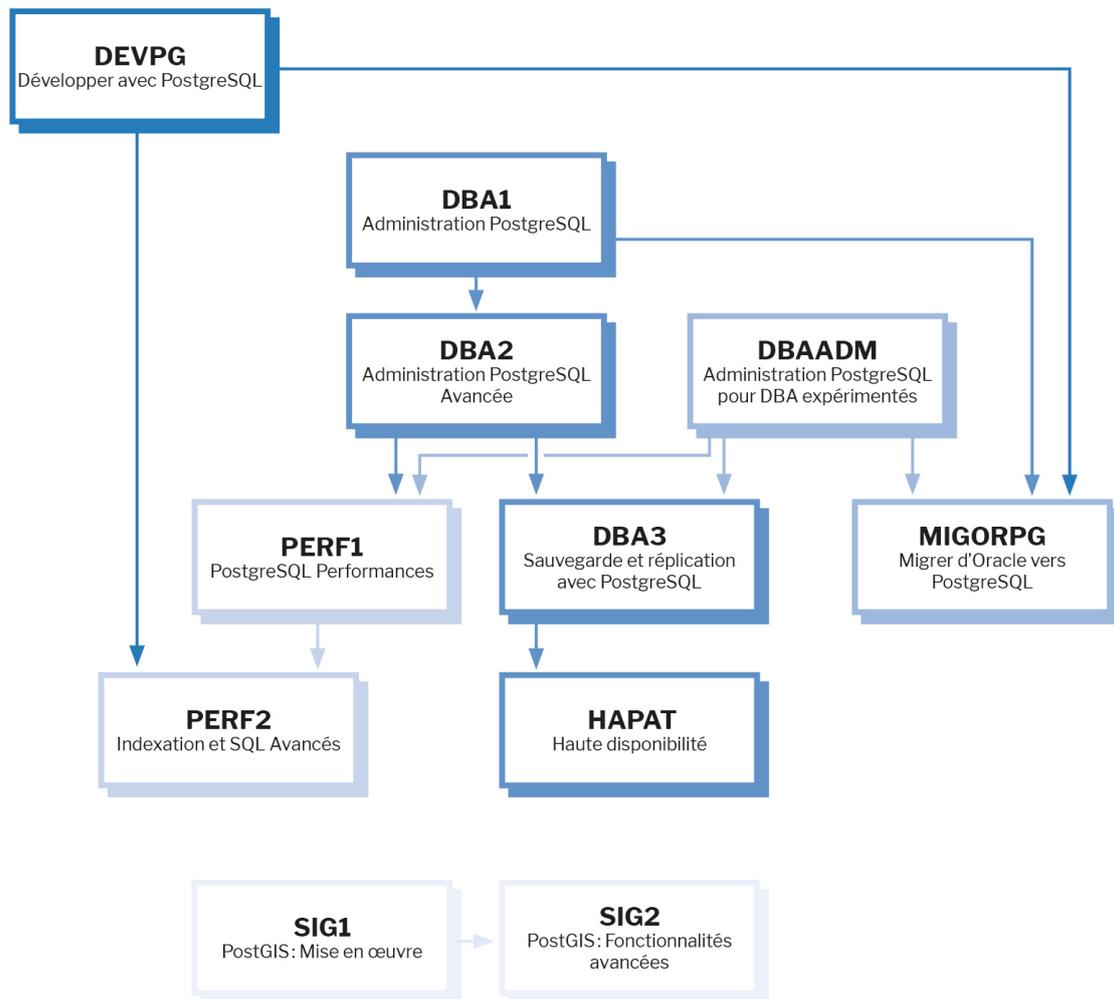


# Les formations Dalibo

Retrouvez nos formations et le calendrier sur <https://dali.bo/formation>

Pour toute information ou question, n'hésitez pas à nous écrire sur [contact@dalibo.com](mailto:contact@dalibo.com).

## Cursus des formations



Retrouvez nos formations dans leur dernière version :

- DBA1 : Administration PostgreSQL  
<https://dali.bo/dba1>
- DBA2 : Administration PostgreSQL avancé  
<https://dali.bo/dba2>
- DBA3 : Sauvegarde et réplication avec PostgreSQL  
<https://dali.bo/dba3>
- DEVPG : Développer avec PostgreSQL  
<https://dali.bo/devpg>
- PERF1 : PostgreSQL Performances  
<https://dali.bo/perf1>
- PERF2 : Indexation et SQL avancés  
<https://dali.bo/perf2>
- MIGORPG : Migrer d'Oracle à PostgreSQL  
<https://dali.bo/migorpg>
- HAPAT : Haute disponibilité avec PostgreSQL  
<https://dali.bo/hapat>

### Les livres blancs

- Migrer d'Oracle à PostgreSQL  
<https://dali.bo/dlb01>
- Industrialiser PostgreSQL  
<https://dali.bo/dlb02>
- Bonnes pratiques de modélisation avec PostgreSQL  
<https://dali.bo/dlb04>
- Bonnes pratiques de développement avec PostgreSQL  
<https://dali.bo/dlb05>

### Téléchargement gratuit

Les versions électroniques de nos publications sont disponibles gratuitement sous licence open source ou sous licence Creative Commons.







