

# Anonymization et Masquage Dynamique avec PostgreSQL





true

---

## **Anonymization et Masquage Dynamique avec PostgreSQL**

---

TITRE : Anonymization et Masquage Dynamique avec PostgreSQL  
SOUS-TITRE :



## **ANONYMISATION ET MASQUAGE DYNAMIQUE AVEC POSTGRESQL**

---

### **WHO I AM**

- Damien Clochard
  - PostgreSQL DBA & Co-fondateur de Dalibo
  - Président de l'association PostgreSQLFr
  - Je ne suis pas juriste !
- 

### **MON CHEMIN**

---

### **MENU**

- RGPD : 1 an plus tard...
  - Pour c'est difficile ?
  - Flux d'anonymisation
  - PostgreSQL Anonymizer
  - 8 Techniques d'anonymisation
-

## RGPD

---

- Droits Individuels
  - Principes
  - Impact
  - Pseudonymisation vs. Anonymisation
- 

### RGPD : LES DROITS INDIVIDUELS

- droit à l'information (Art. 13 et Art. 14)
- droit d'accès (Art. 15)
- droit de rectification (Art. 16)
- droit à la portabilité (Art 20)
- droit d'opposition (Art. 21)
- **droit à l'oubli** (Art. 17)
- **droit à la limitation du traitement** (Art. 18)
- droit de décision automatisée (Art. 22)

(sources: Individual Rights)

---

### RGPD: PRINCIPES & CONCEPTS

- Licéité, loyauté, transparence
- Sécurité
- Minimisation des données
- **Privacy By Design**
- Data Protection By Design
- **Pseudonymisation**
- **Limitation du stockage**
- Précision
- Limitation des finalités

(source: GDPR Principles)





---

## **SANCTIONS ARE COMING**

- Juillet 2019 : 110M€ pour Marriott (UK)
- Juillet 2019 : 204M€ pour British Airways (UK)
- Juin 2019 : 400k€ pour Sergic (France)
- Juin 2019 : 250 k€ pour LaLiga (Espagne)
- Mai 2019 : 170 k€ pour la ville de Bergen (Norvège)
- Avril 2019 : 200k€ pour Airbus (France)
- etc.

(source: GDPR Enforcement Tracker)

---

## **ATTENTION À L'ARTICLE 32 !**

La plupart des sanctions concernent l'article 32 :

« Mesures techniques et organisationnelles insuffisantes pour assurer la sécurité de l'information »

Autrement dit : **"Fuites de données"**

(source Article 32 - Sécurité du traitement)

---

## PSEUDONYMISATION

« 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 »

---

## PSEUDONYMISATION != ANONYMISATION

- Pseudonymisation est méthode de protection de données.
  - Exemples : Chiffrement ou Hashage
  - Les données peuvent reconstituées avec des **données supplémentaires**
  - Les données pseudonymisées reste soumises au RGPD
  - L'anonymisation est la seule véritable porte de sortie
-

## POURQUOI C'EST DIFFICILE ?

---

- Singularisation / Singling Out
- Recouplements / Linkability
- Inférence

(source: WP29 Opinion on Anonymisation Techniques)

---

### SINGULARISATION / SINGLING OUT

Identifier un sujet à partir de valeurs rares ou extrêmes

```
SELECT * FROM employees;
```

id	name	job	salary
1578	xkjefus3sfzd	NULL	1498
2552	cksnd2se5dfa	NULL	2257
5301	fnefckndc2xn	NULL	45489
7114	npodn5ltyp3d	NULL	1821

---

### RECOUPEMENTS / LINKABILITY

Identifier un sujet en utilisant des jeux de données externes

- Notes Netflix + Notes IMDB
- Registre d'un hopital + Liste électorale

Anonymization et Masquage Dynamique avec PostgreSQL

(sources: Netflix prize + Hospital Reidentification)

---

## INFÉRENCE

Identifier un sujet en regroupant plusieurs **identifiants indirects**

87% de la population des Etats-Unis est identifiable à partir de la date de naissance, du genre et du code postal.

(source : Latanya Sweeney)

---

---

## C'EST PERDU D'AVANCE !

On ne peut pas prouver que la **ré-identification** est impossible

(source: De-identification still doesn't work)

---

## LE RGPD RECONNAIT LE PROBLÈME

« Pour déterminer si une personne physique est identifiable, il convient de prendre en considération l'ensemble des **moyens raisonnablement susceptibles d'être utilisés** par le responsable du traitement ou par toute autre personne pour identifier la personne physique directement ou indirectement »

(source: Recital 26)

---

## **MESURER LA PRISE DE RISQUE**

Il faut mesurer le “risque raisonnable” de ré-identification de manière régulière.

---

## FLUX D'ANONYMISATION


---

*Objectif* : minimiser le risque de fuites de donnée réduisant la surface d'attaque

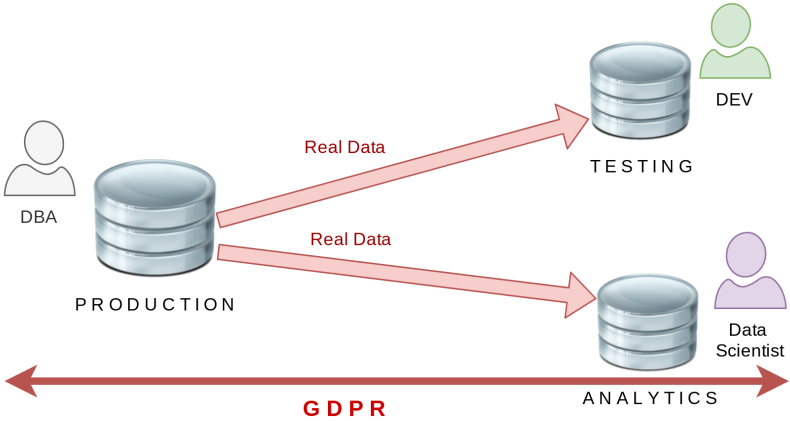
C'est aussi une application directe du principe **Limitation du stockage**

---

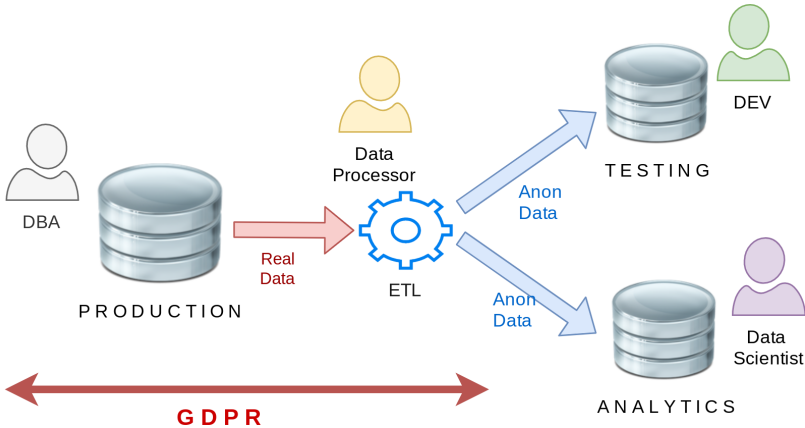
### EXEMPLE DE BASE



### PAS D'ANONYMIZATION

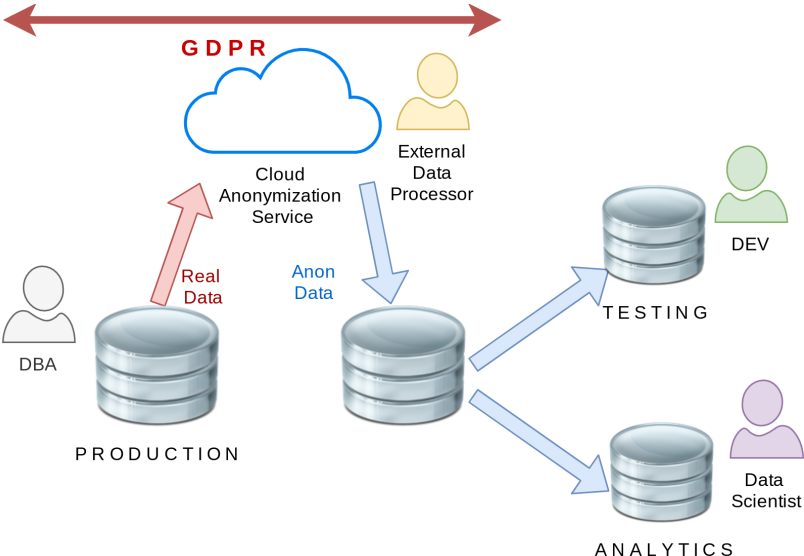


### ETL

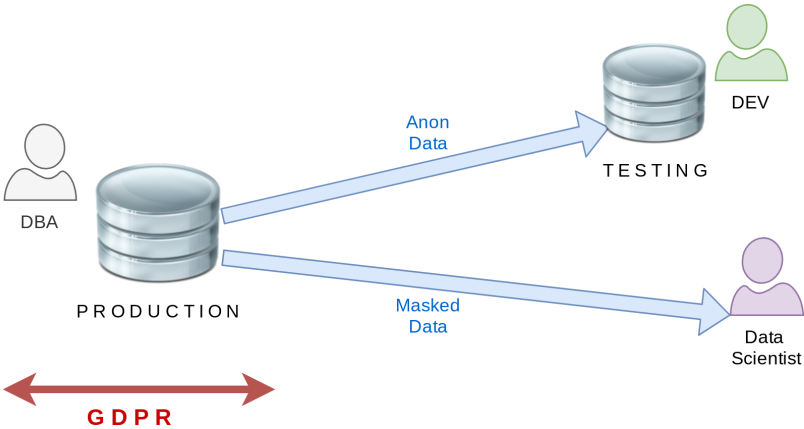




### ANONYMISATION DANS LES NUAGES (!?!)



### POSTGRESQL ANONYMIZER





# PostgreSQL Anonymizer

---

## OBJECTIFS

- Declarer des règles de masquage à l'intérieur de la base de données
  - Anonymiser à l'intérieur de PostgreSQL
  - Masquage Dynamique ou Substitution Permanente
  - Un panel de fonctions de masquage
  - Reprendre la syntaxe du Masquage Dynamique de SQL Server
- 

## EXEMPLE : DONNÉES RÉELLES

```
=# SELECT * FROM customer;  
id | full_name | birth | zipcode | fk_shop  
-----+-----+-----+-----+-----  
911 | Chuck Norris | 1940-03-10 | 75001 | 12  
112 | David Hasselhoff | 1952-07-17 | 90001 | 423
```

---

## EXEMPLE : DONNÉES ANONYMISÉES

```
=# SELECT * FROM customer;  
id | full_name | birth | zipcode | fk_shop  
-----+-----+-----+-----+-----  
911 | Michel Duffus | 1970-03-24 | 63824 | 12  
112 | Andromache Tulip | 1921-03-24 | 38199 | 423
```

---

## INSTALLER

A partir du dépôt RPM de la communauté :

```
$ yum install https://.../pgdg-redhat-repo-latest.noarch.rpm  
$ yum install postgresql_anonymizer12
```

---

## CONFIGURER

```
shared_preload_libraries = '[...], anon'
```

---

## CHARGER

```
=# CREATE EXTENSION IF NOT EXISTS anon CASCADE;  
=# SELECT anon.load();
```

---

## DECLARER UNE RÈGLE DE MASQUAGE

```
SECURITY LABEL FOR anon  
ON COLUMN customer.zipcode  
IS 'anon.random_zipcode()';
```

---

## ENSUITE 3 APPROCHES SONT POSSIBLES

- Substitution Permanente (“In-Place Anonymization”)
  - Export Anonyme (“Anonymous Dump”)
  - Masquage Dynamique (“Dynamic Masking”)
- 

## SUBSTITUTION PERMANENTE

```
=# SELECT anon.anonymize_column('customer', 'zipcode');  
=# SELECT anon.anonymize_table('customer');  
=# SELECT anon.anonymize_database();
```

---

## SUBSTITUTION PERMANENTE

Réécriture (UPDATE) de toutes les lignes de toutes les tables masquées.

---

## EXPORT ANONYME

```
=# SELECT anon.dump();
```

---

## EXPORT ANONYME

```
$ psql [...] -qtA -c 'SELECT anon.dump()' foo > foo.sql
```

---

## MASQUAGE DYNAMIQUE

Exemple de base :

```
=# SELECT * FROM people;
 id | fistname | lastname | phone
-----+-----+-----+-----
 T1 | Sarah    | Conor   | 0609110911
(1 row)
```

---

## MASQUAGE DYNAMIQUE

Etape 1 : Activer le moteur de masquage

```
=# CREATE EXTENSION IF NOT EXISTS anon CASCADE;
=# SELECT anon.start_dynamic_masking();
```

---

## MASQUAGE DYNAMIQUE

Etape 2 : Déclarer utilisateur masqué

```
=# CREATE ROLE skynet LOGIN;  
=# SECURITY LABEL FOR anon ON ROLE skynet  
-# IS 'MASKED';
```

L'utilisateur masqué a un accès en lecture seule aux données anonymisées.

---

## MASQUAGE DYNAMIQUE

Etape 3 : Declarer les règles de masquage

```
SECURITY LABEL FOR anon ON COLUMN people.name  
IS 'MASKED WITH FUNCTION anon.random_last_name()';  
SECURITY LABEL FOR anon ON COLUMN people.phone  
IS 'MASKED WITH FUNCTION anon.partial(phone,2,$$*****$$,2)';
```

---

## MASQUAGE DYNAMIQUE

Etape 4 : Se connecter avec l'utilisateur masqué

```
$ psql peopledb -U skynet -c 'SELECT * FROM people;'  
 id | fistname | lastname | phone  
-----+-----+-----+-----  
 T1 | Sarah    | Stranahan | 06*****11  
(1 row)
```

---

## TECHNIQUES D'ANONYMISATION

---

L'extension fournit toute une batterie de fonctions pour appliquer 7 techniques d'anonymization:

- Destruction
  - Bruit
  - Brassage
  - Randomization
  - Imitation (faking)
  - Destruction partielle
  - Généralisation
- 

### DESTRUCTION

```
SECURITY LABEL FOR anon
ON COLUMN users.address
IS 'MASKED WITH VALUE ''[CONFIDENTIELLE]'' ';
```

---

### DESTRUCTION

- Simple
  - Rapide
  - Efficace
- 

### BRUIT

```
=# SECURITY LABEL FOR anon
-# ON COLUMN employee.salary
-# IS 'MASKED WITH FUNCTION
-#   anon.add_noise_on_numeric_column(user, salary, 0.33)
-# ';
```

Toutes les valeurs seront décalées aléatoirement avec un ratio de +/- 33%

---

## BRUIT

- Les données restent réalistes.
  - `AVG()` et `SUM()` sont similaires à l'original
  - marche uniquement avec les dates et les valeurs numériques
  - Les “valeurs marginales” sont un risque de ré-identification (“singularisation”)
- 

## BRASSAGE

```
=# SECURITY LABEL FOR anon
-# ON COLUMN employee.fk_company
-# IS 'MASKED WITH FUNCTION
-#     anon.shuffle_column(employee, fk_company, id)
-# ';
```

---

## BRASSAGE

- Les données ne sont pas modifiées
  - Parfait pour les clés étrangères
  - Marche mal avec les distributions peu ou mal distribuées (ex: booléens)
  - La table doit avoir une clé primaire
- 

## RANDOMISATION

```
=# SECURITY LABEL FOR anon
-# ON COLUMN employee.birth
-# IS 'MASKED WITH FUNCTION
-#     anon.random_date_between('01/01/1920',now())
-# ';
```

---



## RANDOMISATION

- Simple et rapide
  - Utile pour les colonnes avec la contrainte **NOT NULL**
  - A éviter pour les stats et l'analytique
- 

## IMITATION ( FAKING )

```

=# SECURITY LABEL FOR anon
-# ON COLUMN employee.lastname
-# IS 'MASKED WITH FUNCTION
-#     anon.fake_last_name()
-# ' ;

```

---

## IMITATION ( FAKING )

- Une version plus élaborée de la randomisation
  - Parfait pour les dev, les démos, les tests CI, etc.
  - Vous pouvez charger vos propres données factices !
- 

## DESTRUCTION PARTIELLE

```

=# SECURITY LABEL FOR anon
-# ON COLUMN employee.phone
-# IS 'MASKED WITH FUNCTION anon.partial(phone,4,'*****',2)';

```

**+33142928107** devient **+331\*\*\*\*\*07**

---

## DESTRUCTION PARTIELLE

- Parfait pour les numéros de téléphone, cartes de crédit, etc.
  - Le sujet peut toujours reconnaître sa donnée
  - La transformation est **IMMUTABLE**
  - Marche seulement pour les types TEXT / VARCHAR
- 

## GENERALIZATION

```
SELECT * FROM patient;
```

ssn	firstname	zip	birth	disease
253-51-6170	Alice	47012	1989-12-29	Flu
091-20-0543	Bob	42678	1979-03-22	Allergy
565-94-1926	Caroline	42678	1971-07-22	Flu
510-56-7882	Eleanor	47909	1989-12-15	Acne

---

## GENERALIZATION

```
CREATE MATERIALIZED VIEW generalized_patient AS
```

```
SELECT
```

```
  'REDACTED'::TEXT AS firstname,  
  anon.generalize_int4range(zipcode,1000) AS zipcode,  
  anon.generalize_daterange(birth, 'decade') AS birth,  
  disease
```

```
FROM patient;
```

---

## GENERALIZATION

```
SELECT * FROM generalized_patient;
```

firstname	zip	birth	disease
REDACTED	[47000,48000)	[1980-01-01,1990-01-01)	Flu
REDACTED	[42000,43000)	[1970-01-01,1980-01-01)	Allergy
REDACTED	[42000,43000)	[1970-01-01,1980-01-01)	Flu
REDACTED	[47000,48000)	[1980-01-01,1990-01-01)	Acne

---

## GENERALIZATION

- Les données restent **vraies** mais moins précises
  - Utilise les types RANGE
  - Idéal pour les statistiques et l'analyse de données
  - Le degré d'anonymisation est quantifiable avec l'indicateur de k-anonymat
  - Le masque dynamique ne marche pas car le schéma est différent
  - Inutilisable pour les tests d'intégration
-

## EN RÉSUMÉ

---

- Les sanctions du RGPD sont bien réelles
  - Les fuites de données sont le plus gros risque
  - Réduire la surface d'attaque
  - Anonymiser dès que possible
  - Anonymiser dans la base de données
  - Différentes techniques pour différents usages
  - Le chiffrement n'est pas de l'anonymisation !
- 

## BATAILLE POUR LA VIE PRIVÉE

- Les développeurs doivent écrire les règles de masquage
  - C'est difficile.... PostgreSQL est un bon point de départ
  - La bataille de l'open source est gagnée,
  - ... il faut maintenant se battre pour protéger la vie privée
- 

## COMMENT CONTRIBUER ?

- Feedback et bugs !
- Images et geodata
- rejoindre le projet sur :

[https://gitlab.com/dalibo/postgresql\\_anonymizer](https://gitlab.com/dalibo/postgresql_anonymizer)

---

## DALIBO RECRUTE

- DBA de Production
- DBA d'études
- Développeur·se backend Python
- Commercial Grands Comptes

<https://www.dalibo.com/jobs>

---

## MERCI !

- Contact : [damien.clochard@dalibo.com](mailto:damien.clochard@dalibo.com)
- Follow : [@daamien](#)
- Nos autres Projets : Dalibo Labs