

Atelier Migration PostgreSQL Migrator

Découverte de PostgreSQL Migrator



Contents

1/ Introduction	3
1.1 Tour de table	4
1.2 Déroulé de l'atelier	5
1.3 Prérequis de l'atelier	6
2/ Présentation	7
2.1 Ambitions (1/3)	8
2.2 Ambitions (2/3)	9
2.3 Ambitions (3/3)	10
2.4 Fonctionnalités (1/4)	11
2.5 Fonctionnalités (2/4)	12
2.6 Fonctionnalités (3/4)	13
2.7 Fonctionnalités (4/4)	15
3/ Exercice #1	17
3.1 Installation de PostgreSQL Migrator	18
3.2 Inspecter le catalogue	19
3.3 Création du rapport d'évaluation	23
4/ Exercice #2	27
4.1 Conversions génériques	28
4.2 Naviguer dans l'interface graphique	29
4.3 Procéder à des modifications du modèle	32
4.4 Générer le modèle de données converti au format SQL	34
5/ Exercice #3	39
5.1 Configuration de la base cible	40
5.2 Création des tables	41
5.3 Copie des données	43
5.4 Création des index et des contraintes	45
6/ Exercice #4	49
6.1 Validation des données	50
6.2 Tâches de maintenance	53
Notes	55

Notes	57
Notes	59
Nos autres publications	61
Formations	62
Livres blancs	63
Téléchargement gratuit	64
7/ DALIBO, L'Expertise PostgreSQL	65



PostgreSQL Migrator

Modernize your database by moving
to PostgreSQL.

1/ Introduction

1.1 TOUR DE TABLE

- « Avez-vous un ou des projets de migration vers PostgreSQL ? »
 - « Depuis quel système ? Oracle, MySQL, SQL Server ? »
 - « Quels outils ou techniques avez-vous employés ? »
 - « Quelles ont été les principales difficultés ? »
-

1.2 DÉROULÉ DE L'ATELIER

- 3 heures
 - Présentation de PostgreSQL Migrator
 - Travaux pratiques sur la base **HR**
 - Manipulation de l'outil
 - Analyse de la complexité
 - Migration des tables et des données
-

1.3 PRÉREQUIS DE L'ATELIER

- Un terminal
- Une VM Rocky Linux 9 ou équivalent
- Compétences Linux et SQL
- Une instance Oracle (image gvenzl/oracle-free:23-slim)
- Une instance PostgreSQL 18

Environnement

L'ensemble des travaux pratiques nécessite une base de données Oracle dans un conteneur. Le modèle de données est le traditionnel schéma HR avec des adaptations.

Installer docker-ce et docker-compose-plugin et démarrer le service.

<https://docs.docker.com/engine/install/rhel/#installation-methods>

```
$ sudo dnf -y update
$ sudo dnf -y install dnf-plugins-core
$ sudo dnf config-manager --add-repo
  ↳ https://download.docker.com/linux/rhel/docker-ce.repo
$ sudo dnf -y install -y docker-ce docker-ce-cli containerd.io docker-compose-plugin
$ sudo systemctl enable --now docker
```

Démarrer les conteneurs Oracle et PostgreSQL

Un fichier docker-compose.yml est disponible en téléchargement.

```
$ curl -s -kL https://dali.bo/tp_migpg -o -
$ sudo docker compose up -d oracle postgres
```

2/ Présentation

2.1 AMBITIONS (1/3)

Moderniser la migration avec des logiciels libres.

- Un outil universel
 - Couplé à translatable pour la conversion du code
 - Sous licence PostgreSQL
 - Hébergé sur Gitlab.com
- Langages Go (*backend*) et Vue.js (*frontend*)

The screenshot shows the GitHub repository page for PostgreSQL Migrator. At the top, there's a navigation bar with a dropdown for branches ('master'), a search bar ('Find file'), and a 'Code' button. Below the navigation is a table of recent commits:

Name	Last commit	Last update
.circleci	test: Cleanup MySQL asap	3 weeks ago
.config/mise/tasks	test: get rid of freepdb1	5 months ago
docs	docs: Review JSON files page	1 week ago
internal	ui: Avoid wrapping in complexity repartition	5 days ago
test	ui: Show components affected by one an...	5 days ago
.air.toml	Hot reload backend with air	1 year ago
.editorconfig	Use 80 for the line length in editorconfig	5 months ago

To the right of the commits, there's a 'Project information' sidebar with the following details:

- Modernize your database by moving to PostgreSQL
- <https://postgresql-migrator.rtfd.io>
- PostgreSQL · database · Oracle · + 2 more
- 1,995 Commits
- 14 Branches
- 50 Tags
- 1.4 GiB Project Storage
- 43 Releases

2.2 AMBITIONS (2/3)

Proposer une gouvernance solide

- Le projet rejoint le Dalibo Labs
- Travail conjoint entre les DBA et les DEV
 - Itérations de deux semaines
 - Intégration et livraison continues (CI/CD)



ÉTIENNE BERSAC
etienne.bersac@dalibo.com



PIERRE GIRAUD
pierre.giraud@dalibo.com



PIERRE-LOUIS GONON
pierre-louis.gonon@dalibo.com



MARION GIUSTI
marion.giusti@dalibo.com



FLORENT JARDIN
florent.jardin@dalibo.com



2.3 AMBITIONS (3/3)

Favoriser drastiquement la prise en main

- Simplification de l'installation
 - Navigation graphique dans le modèle de données à convertir
 - Identification des points chaud du chantier
 - Peu de configurations superflues
 - Orchestration des tâches de copie automatique et optimisée
 - Documentation
-

2.4 FONCTIONNALITÉS (1/4)

Un binaire unique en Go

- Aucune dépendance à installer sur le système
 - Pilotes communautaires : Oracle, MySQL
 - Ligne de commande simple et moderne
 - Serveur Web embarqué (Vue.js)
-

2.5 FONCTIONNALITÉS (2/4)

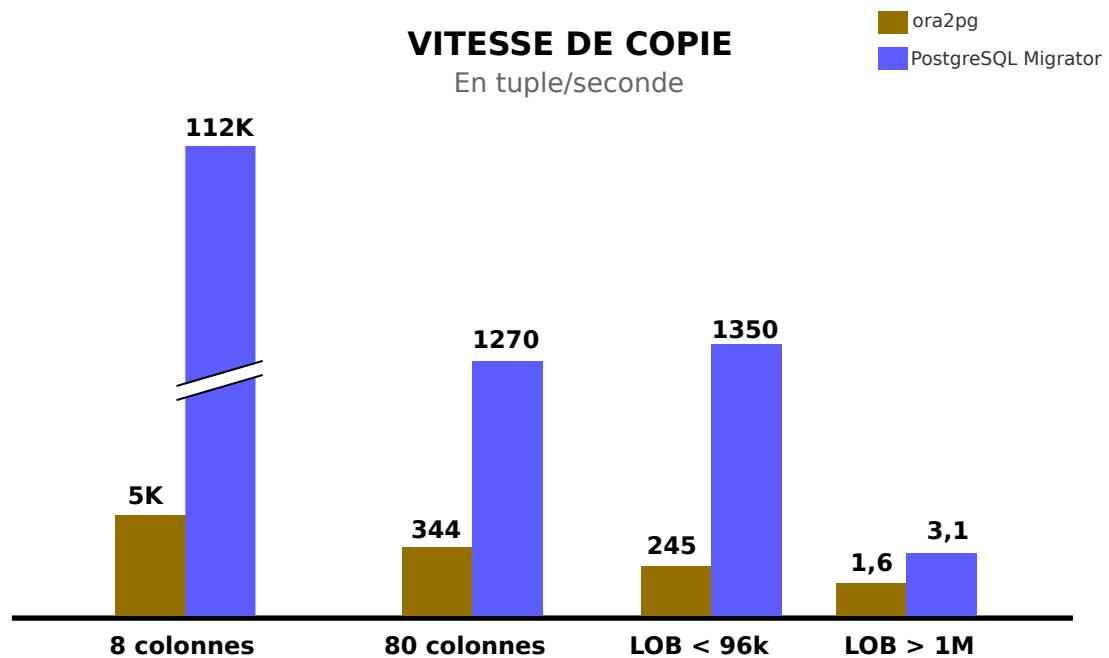
Mode hors-ligne

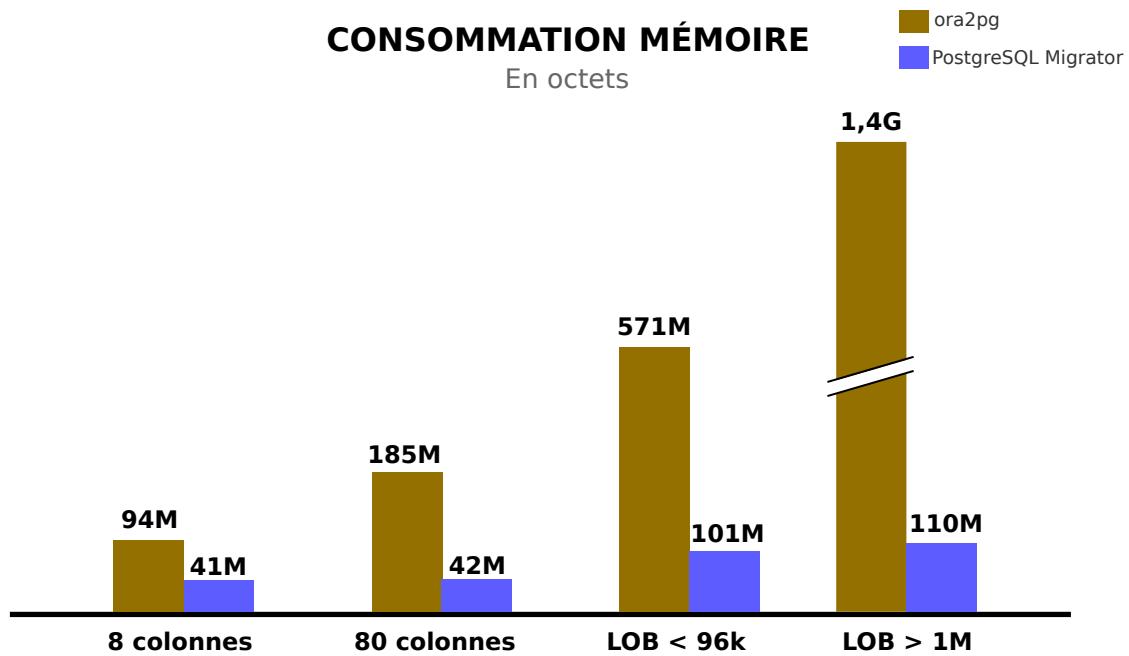
- Inspection de la base source vers des fichiers JSON
 - Exploitation des données sans besoin de connexion
 - Analyse des points chauds
 - Conversion du modèle pour PostgreSQL au format SQL
 - Versionnement pour le travail collaboratif
-

2.6 FONCTIONNALITÉS (3/4)

Transfert des données performant

- Langage compilé
- Techniques de transfert optimisé
 - COPY en flux continu
 - Maîtrise de la consommation mémoire
 - Réutilisation des connexions ouvertes
- Support des BLOB/CLOB





2.7 FONCTIONNALITÉS (4/4)

Interface graphique (Web)

- Navigation dans les modèles source et cible
 - Définition des objets relationnels et procéduraux
 - Recherche globale
 - **À terme**
 - Assistant à la conversion
 - Progression du transfert des données
 - Édition / correction du code PL/pgSQL
-

3/ Exercice #1

- Installation de PostgreSQL Migrator
- Inspection de la base source
- Générer un rapport d'évaluation

3.1 INSTALLATION DE POSTGRESQL MIGRATOR

Télécharger et installer la dernière version de l'outil

Se rendre sur la page du projet et télécharger le dernier paquet disponible pour Redhat. Les formats .deb et .rpm sont à privilégier.

- https://gitlab.com/dalibo/pg_migrate/-/releases/permalink/latest

```
$ v=1.0.0-beta.7
$ d=https://gitlab.com/dalibo/pg_migrate/-/releases/v${v}/downloads
$ sudo dnf -y install ${d}/pg-migrate_${v}_linux_amd64.rpm
```

3.2 INSPECTER LE CATALOGUE

Découvrir les sous-commandes de l'outil.

PostgreSQL Migrator dispose d'une interface en ligne de commande (CLI) nommée pg_migrate. Chaque étape du chantier de migration est rattachée à une des sous-commandes de la CLI.

```
$ pg_migrate --help
Usage: pg_migrate [OPTIONS] COMMAND
```

Commands:

convert	Convert source catalog for PostgreSQL
dump	Dumps a source database as text files or to stdin
init	Initialize a new migration project
inspect	Fetch and analyse source database catalog
report	Generate a migration report
status	Describe a migration project
ui	Interactive audit web interface

Devant chaque sous-commande, il est possible de changer le comportement de la CLI avec les options générales comme --verbose ou --plain.

General Options:

-C, --directory string	Change to directory before doing anything
-?, --help	Print help and exit
--offline	Prevent source database access
--plain	Disable log coloration
--skip-date-warning	Suppress the warning about outdated build
-v, --verbose	Show debug log messages
-V, --version	Print version and exit

Enfin, certaines variables d'environnement sont documentées et peuvent être valorisées depuis le contexte d'exécution.

Environment variables:

PGMDIRECTORY	Change to directory before doing anything.
PGMOFFLINE	Set to true prevent source database access.

Initialiser le répertoire de travail.

Pour chaque projet de migration, il est nécessaire d'initialiser un répertoire de travail à partir de la chaîne de connexion et d'un compte de connexion.

```
$ pg_migrate init --source oracle://hr:phoenix@localhost/hr atelier
09:54:08 INFO  Opening database connection pool. key=source driver=oracle
↪  dsn=or:hr@localhost/hr
```

```
09:54:08 INFO Connecting to database.          key=source count=1
09:54:08 INFO Initialized migration project.   source="Oracle Database 23ai Free"
  ↳ version=23.0.0.0.0 path=atelier
09:54:08 INFO Databases connections closed.    source=1 target=0
```

Découvrir les fichiers du projet.

La commande `init` crée une série de fichiers dans le dossier de travail. Le dossier caché `.pg_migrate` est garant de l'état du projet et ne doit pas être modifié à la main.

Le fichier `.env` contient les variables d'environnement du projet, tel que `PGMSOURCE` qui correspond au paramètre `--target` de la commande précédente. Enfin, le fichier `pg_migrate.toml` permet de configurer le comportement de PostgreSQL Migrator durant toutes les étapes du projet.

```
atelier
├── Annotations.jq
├── .env
├── .gitignore
└── .pg_migrate
    └── Info.json
├── pg_migrate.toml
├── report.md.tpl
└── Summary.jq
└── Total.jq
```

Les fichiers `.jq` et `.md.tpl` sont respectivement les filtres pour manipuler les données JSON du projet, et les *templates* pour la présentation de ces données.

Exécuter la commande d'inspection.

Avant toute chose, il faut se positionner dans le répertoire de travail, là où la commande `pg_migrate` consulte les fichiers du dossier `.pg_migrate` et le contenu du fichier `.env`.

Lancer la sous-commande `inspect`. Si besoin, l'option `--verbose` peut s'intercaler entre la commande `pg_migrate` et la sous-commande.

```
$ cd atelier/
$ pg_migrate inspect
09:55:38 INFO Opening database connection pool. key=source driver=oracle
  ↳ dsn=or:hr@localhost/hr
09:55:38 INFO Connecting to database.          key=source count=1
09:55:38 INFO Inspecting source database.     driver=oracle
09:55:38 INFO Inspected metadata.            instance=FREE software="Oracle
  ↳ Database 23ai Free" version=23.9.0.25.07
09:55:38 WARN Failed to query database size. err="ORA-00942: table or view
  ↳ \"SYS\".\"DBA_SEGMENTS\" does not exist\n error occur at position: 44"
```

```
09:55:38 INFO Found sequences.           count=4
09:55:39 INFO Found procedures.          count=2
09:55:39 INFO Found functions.           count=2
09:55:39 INFO Found packages.            count=2
09:55:39 INFO Found views.               count=1
09:55:41 INFO Found tables.              count=8
09:55:41 INFO Connecting to database.   key=source count=5
09:55:41 INFO Found table triggers.     count=6
09:55:47 INFO Found tables keys.        count=9
09:55:49 INFO Found foreign keys.       count=12
09:55:52 INFO Found tables checks.      count=2
09:55:56 INFO Found tables indexes.    count=2
09:55:56 INFO Inspected schema.        name=HR
```

Plusieurs avertissements s'affichent à l'écran pour nous informer que l'inspection a rencontré une ou plusieurs erreurs à la lecture du catalogue distant. L'inspection est dite partielle, ce qui signifie que des informations sont manquantes pour établir une évaluation complète.

Dans le cas présent, le compte de connexion “HR” n'a pas les autorisations pour consulter les vues du catalogue Oracle.

```
09:55:56 WARN Partial inspection. See errors below.
09:55:56 WARN You can use the catalog but some objects may be missing or incomplete.
09:55:56 WARN Ensure you have the necessary privileges.
09:55:56 WARN Soure database version may not be supported.
```

L'inspection se poursuit avec une phase d'audit du catalogue extrait de la base distante. Cette étape permet d'identifier des faiblesses du modèle de données, ainsi que les complications éventuelles lors de la conversion. Durant cette étape, chaque composant (table, vue, index, procédure stockée) se voit attribué un score de complexité ainsi qu'une série d'annotations si nécessaire.

Une première conversion du modèle est réalisée dans la foulée. Cette opération va consulter le catalogue local de la base source, contenu dans le fichier `.pg_migrate/Source.json` pour en produire le fichier `.pg_migrate/Target.json`. Il contient la même structure que le fichier `Source.json` mais avec certaines conversions génériques.

```
09:55:56 INFO Auditing catalog.          driver=oracle
09:55:56 INFO Catalog audited.
09:55:56 INFO Converted catalog for PostgreSQL.
09:55:56 INFO Auditing catalog.          driver=oracle
09:55:56 WARN Target catalog has pending annotations. count=16
09:55:56 INFO Databases connections closed. source=5 target=0
```

Recommencer l'inspection avec un compte privilégié.

Relancer la commande `init` depuis le répertoire pour modifier le compte de connexion. Un compte

privilégié comme **system** ne rencontrera pas les erreurs d’inspection. Il est aussi possible d’octroyer les bons privilèges au compte **hr** en respectant les prérequis indiqués dans la documentation¹.

```
$ pg_migrate init --source oracle://system:manager@localhost/hr
```

Relancer l’inspection. Le catalogue ainsi extrait est stocké dans le fichier `.pg_migrate/Source.json`.

```
$ pg_migrate inspect
```

¹<https://postgresql-migrator.readthedocs.io/en/latest/references/requirements/>

3.3 CRÉATION DU RAPPORT D'ÉVALUATION

Exécuter la sous-commande `report` depuis votre répertoire de travail.

```
$ pg_migrate report
16:25:41 INFO Generating JSON report.           report=Annotations.json
  ↵ filter=Annotations.jq
16:25:41 INFO Generating JSON report.           report=Summary.json filter=Summary.jq
16:25:41 INFO Generating JSON report.           report=Total.json filter=Total.jq
16:25:41 INFO Generating Markdown report.       report=report.md
  ↵ template=report.md tmpl
```

Consulter librement le contenu du rapport nommé `report.md`. Un tableau récapitulatif reprend le décompte des composants du catalogue, leur taille si applicable, leur score et le nombre d'annotations pour chaque catégorie.

Object	Count	Size	Score	Annotations
Roles	2		2.0	0
Schemas	1		0.1	0
Sequences	4		0.4	0
Tables	8	1.2GB	25.8	7
Triggers	6		12.7	4
Views	1		8.1	1
Indexes	13	4.1MB	2.7	0
Procedures	2		4.7	0
Functions	2		4.9	0
Packages	2		59.8	5

Plus bas, une liste des annotations est fournie pour mettre en lumière les principales causes de la complexité de la base de donnée.

- 2 Column with *missing precision*.
- 1 View with *read only view*.
- 1 Package with *translate: NULL comparison on identifier*.
- 2 Procedure with *translate: NULL comparison on identifier*.
- 4 Trigger with *translate: NULL comparison on identifier*.
- 1 Column with type *CLOB*.

- 2 Package with *unparsed statements*.

Enrichir le rapport en ajoutant un décompte des colonnes par type de données.

Il est possible de composer un rapport en manipulant deux catégories de fichiers. La nature flexible et programmable de ce mécanisme de composition vous permet d'enrichir le rapport avec les données de votre choix.

- Les filtres `.jq` permettent de réduire et de manipuler des données brutes au format JSON, ici `Source.json`;
- Les *templates* `.md` `.tmpl` incorporent les données filtrées dans un fichier final au format Markdown.

Nous souhaitons décompter les nombres de colonnes en fonction de leur type de données. Pour y parvenir, créer un fichier `Types.jq` dans le projet avec le contenu suivant :

```
[ $Source[] .Tables[]? .Columns[] .Type.Name ]  
| group_by(.)  
| map({Name: .[0], Count: length})  
| sort_by(.Count)  
| reverse
```

Ce filtre liste les types des toutes les colonnes de table du fichier `Source.json` et les regroupe par nom en créant un tableau associatif trié. Ce tableau peut ensuite être manipulé dans un *template* à l'aide d'une boucle `range`. Consulter la documentation `text/template`² du langage Go pour plus de précision.

Modifier le fichier `report.md.tmpl` en ajoutant le bout de code suivant :

```
## Types de colonnes  
{{ range $type := .Types }}  
- {{ $type.Count }} {{ $type.Name }}  
{{- end }}
```

Exécuter à nouveau la sous-commande `report`.

Le moteur de rapport détecte que le *template* a été modifié et s'appuie sur la donnée du fichier `Types.json`, lui-même déclaré par le filtre `Types.jq`. Le fichier intermédiaire est créé et le rapport `report.md` est mis à jour avec la nouvelle section « Types de colonnes ».

```
$ pg_migrate report  
15:18:17 INFO Generating JSON report.          report=Types.json filter=Types.jq  
15:18:17 INFO Generating Markdown report.       report=report.md  
↳ template=report.md.tmpl
```

²<https://pkg.go.dev/text/template>

La base HR contient 21 colonnes, dont la répartition par type est listée ci-dessous.

- 19 NUMBER
 - 15 VARCHAR2
 - 4 DATE
 - 2 CHAR
 - 1 CLOB
-

4/ Exercice #2

- Écrire des règles de conversion
- Naviguer dans l'interface graphique
- Exporter le modèle dans des fichiers plats

4.1 CONVERSIONS GÉNÉRIQUES

Exécuter la commande `pg_migrate convert --refresh` en mode verbeux.

Se positionner dans le dossier du projet et relancer une opération de conversion. La page de documentation¹ décrit les conversions génériques réalisées durant cette étape.

```
$ pg_migrate --verbose convert --refresh
...
... from=CHAR(2) to=char(2) path=Tables/HR.COUNTRIES/Columns/COUNTRY_ID
... from=VARCHAR2(60) to=varchar(60) path=Tables/HR.COUNTRIES/Columns/COUNTRY_NAME
... from=NUMBER to=numeric path=Tables/HR.COUNTRIES/Columns/REGION_ID
... from="NUMBER(4, 0)" to=smallint path=Tables/HR.DEPARTMENTS/Columns/DEPARTMENT_ID
... from=VARCHAR2(30) to=varchar(30)
↳ path=Tables/HR.DEPARTMENTS/Columns/DEPARTMENT_NAME
... from="NUMBER(6, 0)" to=integer path=Tables/HR.DEPARTMENTS/Columns/MANAGER_ID
```

Le mode verbeux vous donne plus de détails sur les modifications opérées. Par exemple, les types NUMBER(6, 0) d'Oracle sont convertis en integer. L'option `--verbose` est globale et se positionne avant la sous-commande. La deuxième option `--refresh` est propre à la sous-commande et se positionne après cette dernière. Elle force la réécriture intégrale du fichier `Source.json`.

Une exploration plus périlleuse des fichiers JSON est tout à fait possible. L'exemple ci-dessous permet de cibler les différences entre les deux fichiers pour la colonne `employees.employee_id`.

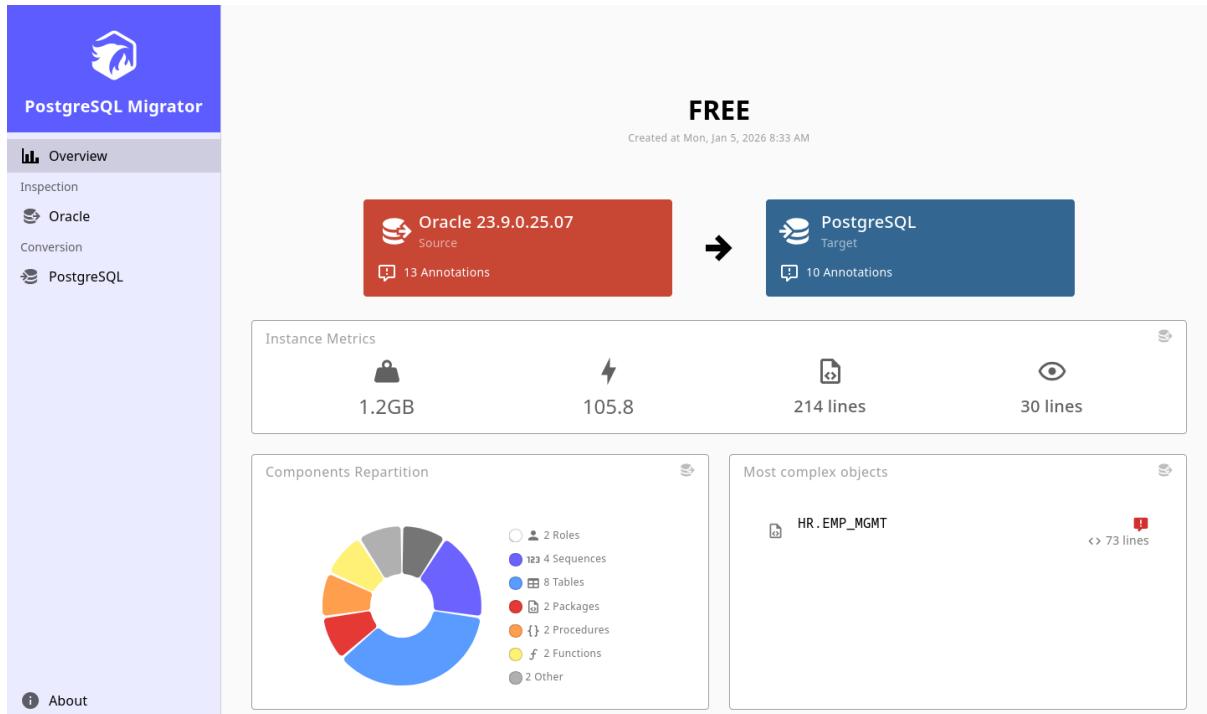
```
$ expr='.Tables[].Columns[] | select(.objectPath |
  ↳ match("Tables/hr.employees/Columns/employee_id";"i")) | .Type'
$ diff <(jq -r "$expr" .pg_migrate/Source.json) <(jq -r "$expr"
  ↳ .pg_migrate/Target.json)
2,6c2
<   "Name": "NUMBER",
<   "Params": [
<     "6",
<     "0"
<   ]
---
>   "Name": "integer"
```

¹<https://postgresql-migrator.readthedocs.io/en/latest/references/conversion/>

4.2 NAVIGUER DANS L'INTERFACE GRAPHIQUE

Exécuter la commande `pg_migrate ui`.

L'outil PostgreSQL Migrator embarque un serveur web interne pour présenter le contenu des fichiers JSON sous une forme graphique et interactive. La page d'accueil vous fournit les éléments clés de l'inspection, similaire au rapport Markdown généré précédemment. Sur la page d'accueil, on y retrouve la version du moteur, le poids cumulé des tables et des index, la somme du nombre de lignes issues des composants procéduraux, etc.



Consulter tous les composants de la base de données.

Naviguer à l'intérieur de la base Oracle pour obtenir la liste de ses objets. Il est possible de filtrer depuis une barre de recherche pour accéder à un objet en particulier. Si vous tapez le mot « history » dans la recherche globale, un résultat s'affiche pour lister les composants comportant ce mot dans leur définition ou la définition de leur parent.

Trier par score.

Le score d'un composant est calculé selon plusieurs critères, tels que son type, le nombre de colonne ou des lignes de codes qui le constituent. Un tableau récapitulatif de tous les scores est accessible sur une page de la documentation². La somme de tous les scores permet de déterminer la complexité de

²<https://postgresql-migrator.readthedocs.io/en/latest/references/toml/#scores-section>

la migration d'une base de données dans son ensemble. Les composants dont les scores sont les plus élevés, sont *a priori* les plus complexes à porter vers PostgreSQL.

The screenshot shows the PostgreSQL Migrator interface. On the left, there's a sidebar with a logo and navigation links: Overview, Inspection, Oracle (selected), Roles, Schemas, Sequences, Tables, Views, Indexes, Triggers, Packages, Procedures, Functions, Conversion, PostgreSQL, and About. The main area has a search bar at the top: "Search Oracle catalog for...". Below it, the title "FREE / Oracle" is displayed. The main content area is titled "FREE" and contains a table of database components:

Component	Description	Score	Complexity	Annotations
HR.EMP_MGMT	4 procedures - 2 functions	73 lines	105.8 Complexity	13 Annotations
HR.EMP_ACTIONS	2 procedures - 2 functions	38 lines		
HR.EMP_DETAILS_VIEW	16 columns	30 lines		
HR.EMPLOYEES	4 indexes - 11 columns - 3 foreignkeys - 3 triggers	128KB 12 lines 907 rows		
HR.JOB_EVALUATIONS	2 indexes - 6 columns - 2 foreignkeys - 1 triggers	1.2GB 5 lines 45K rows	217 lines	1.2GB
HR.LOCATIONS	3 indexes - 6 columns - 1 foreignkeys - 1 triggers	128KB 5 lines 1.5K rows		
HR.DEPARTMENTS	1 indexes - 4 columns - 2 foreignkeys - 1 triggers	64KB 5 lines 27 rows		
{}	HR.ADD_JOB_HISTORY(job_history.employee_id%type, job_history.start_date%type, job_h... 5 parameters	13 lines		
f	HR.EMP_SAL_RANKING(NUMBER) NUMBER 1 parameters	17 lines		
f	HR.LAST_FIRST_NAME(NUMBER) VARCHAR2 1 parameters	10 lines		
{}	HR.SECURE_DML	9 lines		
HR.JOB_HISTORY	3 indexes - 5 columns - 3 foreignkeys	2MB 28K rows		

On the right side, there are sections for Metrics (105.8 Complexity, 13 Annotations), Composed by (8 tables, 1 view, 2 packages, 2 procedures, 2 functions, 7 other components), and Converted to (PostgreSQL icon).

Consulter la définition de la table EMPLOYEES.

Cliquer sur la table HR.EMPLOYEES de la liste et sélectionner le tri par défaut. Les composants représentent tout objet rattaché dans la table, comme les colonnes, les index ou les triggers. L'onglet « JSON » fournit le détail du composant, tel que présenté dans le fichier d'inventaire.

DALIBO Workshops

The screenshot shows the PostgreSQL Migrator interface for converting an Oracle table. The left sidebar lists categories like Overview, Inspection, Oracle, Roles, Schemas, Sequences, Tables (selected), Views, Indexes, Triggers, Packages, Procedures, Functions, Conversion, PostgreSQL, and About. The main area displays the Oracle table **HR.EMPLOYEES** with its columns: `EMPLOYEE_ID NUMBER(6, 0)`, `FIRST_NAME VARCHAR2(20)`, `LAST_NAME VARCHAR2(25)`, `EMAIL VARCHAR2(25)`, `PHONE_NUMBER VARCHAR2(20)`, `HIRE_DATE DATE`, `JOB_ID VARCHAR2(10)`, `SALARY NUMBER(8, 2)`, `COMMISSION_PCT NUMBER(2, 2)`, `MANAGER_ID NUMBER(6, 0)`, `DEPARTMENT_ID NUMBER(4, 0)`, and `EMP_EMAIL_UNIQUE EMAIL`. The right side shows metrics: Complexity (8), Annotations (1), Lines (12), Size (128KB), Rows (907), Composed by (4 indexes, 11 columns, 3 foreignkeys, 3 triggers, 3 other components), References (HR.DEPARTMENTS, HR.JOB, HR.EMPLOYEES), and Converted to (hr.employees). A note indicates the table was converted from HR.EMPLOYEES.

Consulter la version convertie de la table EMPLOYEES.

Dans la colonne de droite, un lien permet d'aller vers la définition de l'objet converti. On y retrouve les conversions de colonnes NUMBER(6, 0) en integer.

The screenshot shows the PostgreSQL Migrator interface for the converted PostgreSQL table. The left sidebar is identical to the previous screenshot. The main area displays the PostgreSQL table **hr.employees** with columns: `employee_id integer`, `first_name varchar(20)`, `last_name varchar(25)`, `email varchar(25)`, `phone_number varchar(20)`, `hire_date timestamp`, `job_id varchar(10)`, `salary numeric(8, 2)`, `commission_pct numeric(2, 2)`, `manager_id integer`, `department_id smallint`, and `emp_email_unique UNIQUE (email)`. The right side shows metrics: Complexity (4.6), Annotations (2), Lines (128KB), Rows (907), Composed by (4 indexes, 11 columns, 3 foreignkeys, 4 other components), References (hr.departments, hr.jobs, hr.employees), and Converted from (HR.EMPLOYEES).

4.3 PROCÉDER À DES MODIFICATIONS DU MODÈLE

Renommer le schéma HR en public.

Il est possible de définir des conversions personnalisées avec le fichier de configuration `pg_migrate.toml`. Chaque composant du modèle source dispose d'un chemin unique (le *path*) pour le distinguer et lui appliquer des transformations. Éditer le fichier avec un éditeur de texte et copier les lignes suivantes :

```
[[Convert.Rules]]
```

```
Path = "Schemas/HR"  
Name = "public"
```

Déclarer toutes les colonnes faisant référence à `DEPARTMENTS.DEPARTMENT_ID` en integer.

Nous voulons définir des règles de transformation sur les colonnes de certaines tables. Éditer à nouveau le fichier `pg_migrate.toml`.

```
[[Convert.Rules]]
```

```
Path = "Tables/HR.EMPLOYEES/Columns/DEPARTMENT_ID"  
Type = "integer"
```

```
[[Convert.Rules]]
```

```
Path = "Tables/HR.DEPARTMENTS/Columns/DEPARTMENT_ID"  
Type = "integer"
```

```
[[Convert.Rules]]
```

```
Path = "Tables/HR.JOB_HISTORY/Columns/DEPARTMENT_ID"  
Type = "integer"
```

Déclarer toutes les colonnes de type DATE en date, sauf pour la colonne `JOB_EVALUATIONS.EVALUATION_DATE` qui devra être convertie en timestamp without time zone.

La règle `Convert.DataTypes` surcharge les conversions génériques et sera appliquée pour toutes les colonnes dont le type est déclaré à la gauche du symbole « = ». La casse est ignorée.

```
[Convert.DataTypes]
```

```
"DATE" = "date"
```

```
[[Convert.Rules]]
```

```
Path = "Tables/HR.JOB_EVALUATIONS/Columns/EVALUATION_DATE"  
Type = "timestamp without time zone"
```

N'oubliez pas de relancer une conversion du modèle afin que la configuration puisse être prise en compte. Pour aller plus loin, une page de documentation³ reprend les syntaxes et les règles de transformation possibles.

```
$ pg_migrate --verbose convert --refresh
...
... Overriding datatype rule.      match=date
... Converting object identifier.   from=HR to=public path=Schemas/HR
... Converting column type.        from="NUMBER(4, 0)" to=bigint
  ↳ path=Tables/HR.DEPARTMENTS/Columns/DEPARTMENT_ID
... Converting column type.        from="NUMBER(4, 0)" to=bigint
  ↳ path=Tables/HR.EMPLOYEES/Columns/DEPARTMENT_ID
... Converting column type.        from="NUMBER(4, 0)" to=bigint
  ↳ path=Tables/HR.JOB_HISTORY/Columns/DEPARTMENT_ID
... Converting column type.        from=DATE to="timestamp without time zone"
  ↳ path=Tables/HR.JOB_EVALUATIONS/Columns/EVALUATION_DATE
... Converting column type.        from=DATE to=date
  ↳ path=Tables/HR.EMPLOYEES/Columns/HIRE_DATE
... Converting column type.        from=DATE to=date
  ↳ path=Tables/HR.JOB_HISTORY/Columns/START_DATE
... Converting column type.        from=DATE to=date
  ↳ path=Tables/HR.JOB_HISTORY/Columns/END_DATE
```

³<https://postgresql-migrator.readthedocs.io/en/latest/references/toml/#convertrules>

4.4 GÉNÉRER LE MODÈLE DE DONNÉES CONVERTI AU FORMAT SQL

Consulter les annotations du modèle converti.

Revenez sur la page d'accueil pour naviguer dans le catalogue PostgreSQL. L'onglet « Annotations » vous révèle les actions requises avant l'export, ainsi que les fonctionnalités non implémentées de PostgreSQL Migrator.

Component	Description	Size	Rows
public.departments	1 indexes - 4 columns - 2 foreignkeys	64KB	27 rows
public.employees	4 indexes - 11 columns - 3 foreignkeys	128KB	907 rows
public.job_evaluations	2 indexes - 6 columns - 2 foreignkeys	1.2GB	45K rows
public.locations	3 indexes - 6 columns - 1 foreignkeys	128KB	1.5K rows

L'outil est réglé pour ne pas exporter le schéma et ses données s'il existe des annotations non prises en compte. Un message d'erreur survient lors de l'export avec la commande `pg_migrate dump`.

```
$ pg_migrate dump
15:59:13 ERROR Target model has pending annotations. len=16
15:59:13 ERROR Use --force to dump anyway.
```

Pour ignorer ce comportement, nous allons ajouter une instruction dans le fichier `pg_migrate.toml`.

```
[Dump]
Force = true
```

Exécuter la commande `pg_migrate dump --target files --schema-only`.

La sous-commande `dump` est responsable de l'export des objets et de leurs données dans un format SQL compatible avec PostgreSQL. L'option `--target` permet de définir l'endroit où seront écrites les

instructions. Pour le moment, nous souhaitons un aperçu des structures converties dans des fichiers plats.

```
$ pg_migrate dump --target files --schema-only
17:22:58 INFO  Writing queries to dump/ directory.
17:22:58 INFO  Create role.      name=pdbadmin path=00002-Roles-pdbadmin-create.sql
17:22:58 INFO  Create role.      name=hr path=00001-Roles-hr-create.sql
17:22:58 INFO  Create schema.   name=public path=00003-Schemas-public-create.sql
17:22:58 INFO  Create table.    name=public.employees
  ↳ path=00006-Tables-public.employees-create.sql
17:22:58 INFO  Create table.    name=public.jobs
  ↳ path=00007-Tables-public.jobs-create.sql
17:22:58 INFO  Create table.    name=public.departments
  ↳ path=00005-Tables-public.departments-create.sql
17:22:58 INFO  Create table.    name=public.locations
  ↳ path=00009-Tables-public.locations-create.sql
17:22:58 INFO  Create table.    name=public.countries
  ↳ path=00004-Tables-public.countries-create.sql
17:22:58 INFO  Create table.    name=public.job_history
  ↳ path=00008-Tables-public.job_history-create.sql
17:22:58 INFO  Create sequence. name=public.locations_seq.
  ↳ path=00014-Sequences-public.locations_seq-create.sql
17:22:58 INFO  Create sequence. name=public.evaluations_seq.
  ↳ path=00013-Sequences-public.evaluations_seq-create.sql
17:22:58 INFO  Create table.    name=public.regions
  ↳ path=00010-Tables-public.regions-create.sql
17:22:58 INFO  Create sequence. name=public.employees_seq.
  ↳ path=00012-Sequences-public.employees_seq-create.sql
17:22:58 INFO  Create sequence. name=public.departments_seq.
  ↳ path=00011-Sequences-public.departments_seq-create.sql
...
...
```

L'option `--schema-only` est similaire à celle de l'outil `pg_dump`. Il s'agit d'un raccourci pour les options `--section=pre-data` et `--section=post-data`. N'hésitez pas à consulter l'aide depuis la ligne de commande pour plus de détails.

```
$ pg_migrate dump --help
Usage: pg_migrate [OPTIONS] dump [OPTIONS]

Generates DDL and/or COPY for target PostgreSQL.
Executes statements in defined PostgreSQL target database
or writes to stdout or files.
Requires successful convert.

Options:
  -c, --clean           clean (drop) objects before recreating
                        or truncate table before copy
```

```
-a, --data-only      dump only the data, not the schema
-f, --force         ignore unhandled annotations
-?, --help          Show help
-j, --jobs int     use this many parallel jobs to dump (default 4)
--refresh-stats    refresh table statistics before planning dump (default true)
-s, --schema-only   dump only the schema, no data
--section string   dump named section (pre-data, data, post-data)
--target string    DSN for query execution

--target can be stdout, files or a PostgreSQL DSN.
```

If stdout is not a terminal, writes to stdout.
Else if PGMTARGET is defined, sends to PostgreSQL target database.
Force file output with --target=files.

See pg_migrate --help for more informations.

Consulter les fichiers présents dans le répertoire dump/.

Les fichiers SQL générés par la commande précédente sont accessibles depuis le dossier dump / du répertoire de travail.

```
$ tree dump/
dump/
├── 00001-Roles-hr-create.sql
├── 00002-Roles-pdbadmin-create.sql
├── 00003-Schemas-public-create.sql
├── 00004-Tables-public.countries-create.sql
├── 00005-Tables-public.departments-create.sql
├── 00006-Tables-public.employees-create.sql
├── 00007-Tables-public.job_evaluations-create.sql
├── 00008-Tables-public.job_history-create.sql
├── 00009-Tables-public.jobs-create.sql
├── 00010-Tables-public.locations-create.sql
├── 00011-Tables-public.regions-create.sql
...
└── 20029-Tables-public.job_evaluations-ForeignKeys-eval_employee_fk-create.sql
    ├── 20030-Tables-public.job_evaluations-ForeignKeys-eval_evaluator_fk-create.sql
    ├── 20031-Tables-public.job_history-ForeignKeys-jhist_dept_fk-create.sql
    ├── 20032-Tables-public.job_history-ForeignKeys-jhist_emp_fk-create.sql
    ├── 20033-Tables-public.job_history-ForeignKeys-jhist_job_fk-create.sql
    └── 20034-Tables-public.locations-ForeignKeys-loc_c_id_fk-create.sql
```

La table employees est conforme à ce que nous attendions. Le schéma de destination est bien public et les colonnes department_id et hire_date sont respectivement de type integer et date.

```
--  
-- Name: employees; Type: TABLE; Schema: public; Owner: unknown  
  
CREATE TABLE "public"."employees" (  
    "employee_id" integer,  
    "first_name" varchar(20),  
    "last_name" varchar(25),  
    "email" varchar(25),  
    "phone_number" varchar(20),  
    "hire_date" date,  
    "job_id" varchar(10),  
    "salary" numeric(8, 2),  
    "commission_pct" numeric(2, 2),  
    "manager_id" integer,  
    "department_id" integer  
);
```

5/ Exercice #3

- Création des tables
- Copie des données
- Création des index et des contraintes

5.1 CONFIGURATION DE LA BASE CIBLE

Démarrer l'instance PostgreSQL.

Si ce n'est pas déjà le cas, démarrer le conteneur PostgreSQL dans lequel nous réaliserons la copie des données. L'authentification `trust` est active et permet de ne pas s'encombrer d'un mot de passe (**mais ne le faites pas chez vous !**).

```
$ sudo docker compose up -d postgres
```

Créer une nouvelle base nommée `hr`.

La base `hr` doit être créée comme suit. Le compte `postgres` en est le propriétaire durant la phase de migration et pourra être changé *a posteriori*.

```
$ sudo docker compose exec -ti postgres createdb -U postgres hr
```

Configurer le projet pour se connecter à l'instance.

Pour la suite des commandes, nous souhaitons renseigner l'adresse de connexion de cette nouvelle instance pour que PostgreSQL Migrator y crée les composants à notre place. Lancer une initialisation avec un nouvel argument `--target` depuis le répertoire de projet.

```
$ pg_migrate init \
--source=oracle://system:manager@localhost/hr \
--target=postgres://postgres@localhost/hr
```

Cela revient à ajouter contrôler l'accès et l'authentification à l'instance avant d'ajouter une ligne dans le fichier `.env`. La variable d'environnement `PGMTARGET` est alors disponible pour déterminer la destination des instructions SQL lors de l'exécution de la commande `pg_migrate dump`.

```
$ cat .env
PGMSOURCE=oracle://system:manager@localhost/hr
PGMTARGET=postgresql://postgres@localhost/hr
```

5.2 CRÉATION DES TABLES

La première étape de la migration consiste à créer les tables converties dans la base vierge. Nous aurions pu utiliser les fichiers plats exportés précédemment avec l'option `--target=files`, nous jugeons que PostgreSQL Migrator peut s'en charger aussi bien avec son moteur interne d'exécution et d'orchestration.

Exécuter la commande `pg_migrate dump --section=pre-data`.

La phase dite « pre-data » réunit les composants initiaux qui accueilleront la donnée (comme les schémas et leurs tables), ainsi que tout autre composant dont la structure peut être définie sans relation avec la donnée (comme les rôles, les séquences ou les vues).

```
$ pg_migrate dump --section=pre-data
17:11:14 WARN  Ignoring unhandled annotations in target model. len=10
17:11:14 INFO  Executing queries in target PostgreSQL.
17:11:14 INFO  Create role.          name=pdbadmin sn=00002
17:11:14 INFO  Create schema.       name=public sn=00003
17:11:14 INFO  Create role.          name=hr sn=00001
17:11:14 INFO  Create table.        name=public.jobs sn=00009
17:11:14 INFO  Create table.        name=public.job_evaluations sn=00007
17:11:14 INFO  Create table.        name=public.departments sn=00005
17:11:14 INFO  Create table.        name=public.regions sn=00011
17:11:14 INFO  Create table.        name=public.employees sn=00006
17:11:14 INFO  Create table.        name=public.locations sn=00010
17:11:14 INFO  Create table.        name=public.job_history sn=00008
17:11:14 INFO  Create table.        name=public.countries sn=00004
17:11:14 INFO  Create sequence.      name=public.locations_seq. sn=00015
17:11:14 INFO  Create sequence.      name=public.evaluations_seq. sn=00014
17:11:14 INFO  Create sequence.      name=public.employees_seq. sn=00013
17:11:14 INFO  Create sequence.      name=public.departments_seq. sn=00012
```

Contrôler la structure de la table `public.employees`.

Utiliser la commande `docker compose exec` pour interagir avec l'instance du conteneur et l'invite `psql`. La table `employees` est conforme aux conversions vues précédemment.

```
$ sudo docker compose exec -ti postgres psql -U postgres -d hr -c "\d
\public.employees"
Table "public.employees"
 Column | Type | Collation | Nullable | Default
-----+-----+-----+-----+-----+
employee_id | integer | | | |
first_name | character varying(20) | | | |
last_name | character varying(25) | | | |
```

email	character varying(25)		
phone_number	character varying(20)		
hire_date	date		
job_id	character varying(10)		
salary	numeric(8,2)		
commission_pct	numeric(2,2)		
manager_id	integer		
department_id	integer		

5.3 COPIE DES DONNÉES

L'étape suivante va alimenter les tables PostgreSQL avec les données en provenance des tables Oracle. L'orchestrateur interne sélectionne les tables les plus volumineuses en priorité et crée autant de processus que définis par l'argument `--jobs` (4 par défaut).

Exécuter la commande `pg_migrate dump --data-only`.

L'option `--data-only` est équivalente à `--section=data`. Si vous souhaitez recommencer la copie intégrale des tables, l'option `--clean` ajoutera une instruction `truncate` avant chaque table. Toutefois, assurez-vous de ne pas avoir créé de contraintes de clé étrangère.

Enfin, il est possible de désactiver la collecte des statistiques avec l'option `--refresh-stats=false` s'il y a eu peu de changement entre deux exports. Les statistiques servent à déterminer la priorité des tables entre elles.

```
$ pg_migrate dump --section=data
17:35:17 INFO  Executing queries in target PostgreSQL.
17:35:17 INFO  Collecting statistics, this may take a while...
```

À l'issue du traitement d'une table, une série de métriques permet d'appréhender le débit de transfert pour cette migration et d'envisager des optimisations pour tenter d'accélérer la phase de copie des données.

```
... table=public.regions elapsed=80ms data=54B rows=5 rate="62 rows/s" sn=10008
... table=public.departments elapsed=90ms data=643B rows=27 rate="300 rows/s"
  ↵ sn=10002
... table=public.jobs elapsed=10ms data=1.1KB rows=29 rate="2.9K rows/s" sn=10006
... table=public.employees elapsed=50ms data=78KB rows=907 rate="18.1K rows/s"
  ↵ sn=10003
... table=public.locations elapsed=60ms data=68.2KB rows=1523 rate="25.4K rows/s"
  ↵ sn=10007
... table=public.countries elapsed=10ms data=577B rows=35 rate="3.5K rows/s" sn=10001
... table=public.job_history elapsed=390ms data=1.6MB rows=28010 rate="71.8K rows/s"
  ↵ sn=10005
... table=public.job_evaluations elapsed=17.17s data=401.5MB rows=45000 rate="2.6K
  ↵ rows/s" sn=10004
```

Un résumé de l'ensemble est fourni dès que la dernière table a été traitée. Il permet de contrôler que le débit global est satisfaisant et de connaître la quantité de mémoire consommée au plus haut de l'activité de transfert (*memory peak*).

```
17:35:40 INFO  Copy completed. tables=8 data=403.1MB elapsed=17.62s
  ↵ throughput=17.1MB/s jobs=4 mem=37.2MB
```

Une des tâches de copie consiste à rattraper les valeurs pour toutes les séquences du modèle converti.

```
17:35:23 INFO  Restart sequences.          schema=public sn=10009
```

5.4 CRÉATION DES INDEX ET DES CONTRAINTES

Exécuter la commande `pg_migrate dump --section=post-data`.

La création des index et l'activation des contraintes des tables arrivent en dernière étape, celle dite « post-data ». Durant cette étape, l'intégrité des données est mise à l'épreuve avec la validation des références de clés étrangères ou de l'unicité des données de colonne.

L'orchestrateur interne de PostgreSQL Migrator se charge de construire les index et les clés primaires en priorité et résout les dépendances croisées entre tables référencées pour limiter le risque de verrous (*deadlocks*).

```
$ pg_migrate dump --section=post-data
09:02:53 INFO Executing queries in target PostgreSQL.
09:02:53 INFO Create table key. name=public.jobs key=job_id_pk
  ↵ sn=20007
09:02:53 INFO Create table key. name=public.regions key=reg_id_pk
  ↵ sn=20009
09:02:53 INFO Create table key. name=public.job_evaluations
  ↵ key=eval_id_pk sn=20005
09:02:53 INFO Create table key. name=public.departments
  ↵ key=dept_id_pk sn=20002
09:02:53 INFO Create table key. name=public.employees
  ↵ key=emp_email_uk sn=20003
09:02:53 INFO Create table key. name=public.locations key=loc_id_pk
  ↵ sn=20008
09:02:53 INFO Create table key. name=public.job_history
  ↵ key=jhist_emp_id_st_date_pk sn=20006
09:02:53 INFO Create table key. name=public.countries
  ↵ key=country_c_id_pk sn=20001
09:02:53 INFO Create table key. name=public.employees
  ↵ key=emp_emp_id_pk sn=20004
09:02:53 INFO Create Index. name=public.departments
  ↵ idx=departments_location_id_idx sn=20010
09:02:53 INFO Create Index. name=public.locations
  ↵ idx=locations_city_idx sn=20020
09:02:53 INFO Create Index. name=public.employees
  ↵ idx=employees_department_id_idx sn=20011
09:02:53 INFO Create foreign key. name=public.countries
  ↵ fk=countr_reg_fk sn=20023
09:02:53 INFO Create Index. name=public.employees
  ↵ idx=employees_job_id_idx sn=20012
09:02:53 INFO Create Index. name=public.locations
  ↵ idx=locations_country_id_idx sn=20021
09:02:53 INFO Create Index. name=public.employees
  ↵ idx=employees_manager_id_idx sn=20013
```

```

09:02:53 INFO  Create Index.          name=public.locations
  ↵  idx=locations_state_province_idx sn=20022
09:02:53 INFO  Create Index.          name=public.employees
  ↵  idx=employees_last_name_first_name_idx sn=20014
09:02:53 INFO  Create foreign key.   name=public.departments
  ↵  fk=dept_loc_fk sn=20024
09:02:53 INFO  Create foreign key.   name=public.locations fk=loc_c_id_fk
  ↵  sn=20034
09:02:53 INFO  Create Index.          name=public.job_history
  ↵  idx=job_history_department_id_idx sn=20017
09:02:53 INFO  Create foreign key.   name=public.departments
  ↵  fk=dept_mgr_fk sn=20025
09:02:53 INFO  Create Index.          name=public.job_evaluations
  ↵  idx=job_evaluations_employee_id_idx sn=20015
09:02:53 INFO  Create foreign key.   name=public.employees fk=emp_dept_fk
  ↵  sn=20026
09:02:53 INFO  Create foreign key.   name=public.employees fk=emp_job_fk
  ↵  sn=20027
09:02:53 INFO  Create foreign key.   name=public.employees
  ↵  fk=emp_manager_fk sn=20028
09:02:53 INFO  Create Index.          name=public.job_history
  ↵  idx=job_history_employee_id_idx sn=20018
09:02:53 INFO  Create Index.          name=public.job_history
  ↵  idx=job_history_job_id_idx sn=20019
09:02:53 INFO  Create Index.          name=public.job_evaluations
  ↵  idx=job_evaluations_evaluator_id_idx sn=20016
09:02:53 INFO  Create foreign key.   name=public.job_history
  ↵  fk=jhist_dept_fk sn=20031
09:02:53 INFO  Create foreign key.   name=public.job_evaluations
  ↵  fk=eval_employee_fk sn=20029
09:02:53 INFO  Create foreign key.   name=public.job_history
  ↵  fk=jhist_emp_fk sn=20032
09:02:53 INFO  Create foreign key.   name=public.job_evaluations
  ↵  fk=eval_evaluator_fk sn=20030
09:02:53 INFO  Create foreign key.   name=public.job_history
  ↵  fk=jhist_job_fk sn=20033

```

Contrôler la structure de la table public.employees.

Les tables disposent bien de leur clé primaire et index. Les références de clé étrangères sont en place. Aucune erreur n'a été observée durant la phase *post-data*, les données sont cohérentes entre elles.

```
$ sudo docker compose exec -ti postgres psql -U postgres -d hr -c "\d
  ↵  public.employees"
Table "public.employees"
 Column | Type | Collation | Nullable | Default
-----+-----+-----+-----+-----
```

employee_id	integer		not null	
first_name	character varying(20)			
last_name	character varying(25)			
email	character varying(25)			
phone_number	character varying(20)			
hire_date	date			
job_id	character varying(10)			
salary	numeric(8,2)			
commission_pct	numeric(2,2)			
manager_id	integer			
department_id	integer			

Indexes:

- "emp_emp_id_pk" PRIMARY KEY, btree (employee_id)
- "emp_email_uk" UNIQUE CONSTRAINT, btree (email)
- "employees_department_id_idx" btree (department_id)
- "employees_job_id_idx" btree (job_id)
- "employees_last_name_first_name_idx" btree (last_name, first_name)
- "employees_manager_id_idx" btree (manager_id)

Foreign-key constraints:

- "emp_dept_fk" FOREIGN KEY (department_id) REFERENCES departments(department_id)
- "emp_job_fk" FOREIGN KEY (job_id) REFERENCES jobs(job_id)
- "emp_manager_fk" FOREIGN KEY (manager_id) REFERENCES employees(employee_id)

Referenced by:

- ↳ TABLE "departments" CONSTRAINT "dept_mgr_fk" FOREIGN KEY (manager_id) REFERENCES employees(employee_id)
- ↳ TABLE "employees" CONSTRAINT "emp_manager_fk" FOREIGN KEY (manager_id) REFERENCES employees(employee_id)
- ↳ TABLE "job_evaluations" CONSTRAINT "eval_employee_fk" FOREIGN KEY (employee_id) REFERENCES employees(employee_id)
- ↳ TABLE "job_evaluations" CONSTRAINT "eval_evaluator_fk" FOREIGN KEY (evaluator_id) REFERENCES employees(employee_id)
- ↳ TABLE "job_history" CONSTRAINT "jhist_emp_fk" FOREIGN KEY (employee_id) REFERENCES employees(employee_id)

6/ Exercice #4

- Décompter les lignes entre les deux bases
- Contrôler l'intégrité des données
- Déclencher un VACUUM FREEZE

6.1 VALIDATION DES DONNÉES

La validation de l'état des lignes est une étape cruciale pour prendre la décision de basculer les applications sur la nouvelle base PostgreSQL sans risque de perte d'information. Si le moindre doute subsiste sur la qualité ou la quantité de données, il faut envisager d'annuler les opérations de migration.

Pour le moment, PostgreSQL Migrator ne propose pas de rapport de validation d'une migration de données.

Décompter les lignes de plusieurs tables.

Il nous appartient de réaliser le décompte du nombre de lignes entre la base source et la base cible PostgreSQL. Les fonctions suivantes établissent une connexion à leur base respective et décomptent les lignes des tables issues du fichier `Source.json`.

```
function count_source {
    local SQLPLUS="sudo docker compose exec -T oracle sqlplus -S
        ↳ hr/phoenix@localhost/hr"
    local filter=".Tables | sort_by(.Name | ascii_downcase) | .[] | @text
        ↳ \"\(.Schema).\(\.Name)\\""
    local tables=$(jq -r "$filter" .pg_migrate/Source.json)
    for table in $tables; do
        cat <<- EOF | $SQLPLUS | grep -v '^$'
set newpage none head off feedback off
set markup csv on quote off
SELECT '$table', count(*) FROM $table;
EOF
    done
}

function count_target {
    local PSQL="sudo docker compose exec -T postgres psql -d hr -U postgres"
    local filter=".Tables | sort_by(.Name | ascii_downcase) | .[] | @text
        ↳ \"\(.Schema).\(\.Name)\\""
    local tables=$(jq -r "$filter" .pg_migrate/Target.json)
    for table in $tables; do
        $PSQL --csv --pset pager=off -tc "SELECT '$table', count(*) FROM $table"
    done
}
```

Exécuter le décompte avec la commande suivante.

```
$ paste -d ',' <(count_source) <(count_target) | column -s, -t
HR.COUNTRIES      35      public.countries      35
HR.DEPARTMENTS    27      public.departments    27
```

HR.EMPLOYEES	907	public.employees	907
HR.JOB_EVALUATIONS	45000	public.job_evaluations	45000
HR.JOB_HISTORY	28010	public.job_history	28010
HR.JOBS	29	public.jobs	29
HR.LOCATIONS	1523	public.locations	1523
HR.REGIONS	5	public.regions	5

Valider l'intégrité d'un échantillon de données.

Le deuxième contrôle vise à certifier que la donnée n'a pas subi de transformation au cours de la copie. Le changement d'encodage des chaînes de caractères ou la troncature non désirée d'une valeur sont des erreurs que nous souhaitons éviter à tout prix.

Créer les deux fonctions `select_*` suivantes. Elles établissent une connexion à leur base respective, exécutent la requête passée en paramètre et formatent le résultat au format CSV. Une attention particulière est nécessaire pour afficher correctement les données afin qu'elles aient un rendu équivalent entre les deux systèmes.

```
function select_source {
    test -z "$1" && return
    local SQLPLUS="sudo docker compose exec -T oracle sqlplus -S
        ↳ hr/phoenix@localhost/hr"
    n=$'\n'; cat <<- EOF | $SQLPLUS | grep -v '^$'
set newpage none head off feedback off
set markup csv on quote off
column salary format 999999.99
column commission_pct format 0.99
column score format 99.9
alter session set nls_date_format='YYYY-MM-DD';
alter session set nls_timestamp_format='YYYY-MM-DD HH24:MI:SS';
alter session set nls_timestamp_tz_format='YYYY-MM-DD HH24:MI:SSTZH';
$1;
EOF
}

function select_target {
    test -z "$1" && return
    local PSQL="sudo docker compose exec -T postgres psql -d hr -U postgres"
    $PSQL --csv --pset pager=off -tc "$1"
}
```

À présent, nous pouvons lancer la commande suivante pour comparer les résultats d'une requête qui parcourt une fraction de la table `employees`. Si la commande n'affiche aucun résultat, les données sont scrupuleusement identiques.

```
diff -u \
```

```
<(select_source "SELECT * FROM hr.employees WHERE MOD(employee_id, 10) = 0 ORDER BY
    ↵ employee_id") \
<(select_target "SELECT * FROM public.employees WHERE employee_id % 10 = 0 ORDER BY
    ↵ employee_id")
```

La comparaison des données CLOB est plus coûteuse en ressources. Pour la table `job_evaluations`, nous allons uniquement compter le nombre de caractères dans la colonne `comments` à l'aide des méthodes `DBMS_LOB.GETLENGTH` et `char_length`.

```
diff -u \
<(select_source "alter session set nls_date_format='YYYY-MM-DD HH24:MI:SS';
                SELECT evaluation_id, employee_id, evaluator_id,
                      evaluation_date, score, DBMS_LOB.GETLENGTH(comments)
                 FROM hr.job_evaluations
                WHERE MOD(evaluation_id, 500) = 0
                  ORDER BY evaluation_id") \
<(select_target "SELECT evaluation_id, employee_id, evaluator_id,
                      evaluation_date, score, char_length(comments)
                 FROM public.job_evaluations
                WHERE evaluation_id % 500 = 0
                  ORDER BY evaluation_id")
```

6.2 TÂCHES DE MAINTENANCE

La bascule du modèle et des données vers PostgreSQL s'accompagne d'une série d'opérations de maintenance qui dépend de votre organisation. L'activation de les sondes de supervision et la planification des sauvegardes sont sans conteste les premières actions à entreprendre pour assurer le suivi et la sécurité de la plateforme.

Réaliser un VACUUM FREEZE pour sécuriser les données à terme.

Une opération préventive, appelée *gel des lignes*, est fortement recommandée à l'issue d'un chargement massif de lignes dans une base PostgreSQL.

Rappelons qu'un numéro de transaction est attaché à chaque nouvelle ligne dans une base, afin de garantir l'isolation des sessions entre elles. Or ces numéros de transaction sont encodés sur 32 bits et sont recyclés à terme. Il y a donc un risque de mélanger les opérations passées et celles à venir au moment du rebouclage (*wraparound*). Afin d'éviter ce phénomène, l'opération VACUUM FREEZE « gèle » les vieux enregistrements, afin que ceux-ci ne se retrouvent pas brusquement dans le futur.

Exécuter la commande suivante pour déclencher un gel préventif des table de la base hr. Il est possible de traiter plusieurs tables simultanément avec l'option --jobs.

```
$ sudo docker compose exec -ti postgres vacuumdb -U postgres --freeze --jobs=4 hr
vacuumdb: vacuuming database "hr"
```


Notes

Notes

Notes

Nos autres publications

FORMATIONS

- 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>

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.

7/ DALIBO, L'Expertise PostgreSQL

Depuis 2005, DALIBO met à la disposition de ses clients son savoir-faire dans le domaine des bases de données et propose des services de conseil, de formation et de support aux entreprises et aux institutionnels.

En parallèle de son activité commerciale, DALIBO contribue aux développements de la communauté PostgreSQL et participe activement à l'animation de la communauté francophone de PostgreSQL. La société est également à l'origine de nombreux outils libres de supervision, de migration, de sauvegarde et d'optimisation.

Le succès de PostgreSQL démontre que la transparence, l'ouverture et l'auto-gestion sont à la fois une source d'innovation et un gage de pérennité. DALIBO a intégré ces principes dans son ADN en optant pour le statut de SCOP : la société est contrôlée à 100 % par ses salariés, les décisions sont prises collectivement et les bénéfices sont partagés à parts égales.

