

Guide d'utilisation du recensement au format parquet

Ce guide présente quelques exemples d'utilisation des données du recensement de la population diffusées au format **Parquet**.

Pour plus d'informations sur le format **Parquet**, dans un contexte de statistique publique, se référer à Dondon and Lamarche (2023). Pour un exemple sur la différence entre format **CSV** et **Parquet** illustré sur les données du recensement de la population, voir Mauvière (2022).

Initialisation

Ce guide propose d'utiliser [DuckDB](#) à travers plusieurs langages pour effectuer des traitements sur les fichiers détails du recensement. Par rapport à d'autres approches, [DuckDB](#) a été choisi pour son efficacité ainsi que pour son universalité puisque peu de différences

On va supposer que les données sont stockées dans un dossier conservé sous le nom `path_data` (par exemple `path_data = 'C:/MesDocuments/dossierpersonnel'`). Des vues sont créées afin de faciliter les requêtes ultérieures.

Python

```
import duckdb

renommage_documentation = "SELECT " +\
    "COD_VAR AS nom_variable, " +\
    "LIB_VAR AS description_variable, " +\
    "TYPE_VAR AS type_variable, " +\
    "COD_MOD AS code_modalite, " +\
    "LIB_MOD AS description_modalite"
```

```

duckdb.sql(
  f'CREATE OR REPLACE VIEW table_individu AS SELECT * FROM read_parquet("{path_data}/FD_
  )
duckdb.sql(
  f'CREATE OR REPLACE VIEW table_logement AS SELECT * FROM read_parquet("{path_data}/FD_
  )
duckdb.sql(
  f'CREATE OR REPLACE VIEW documentation AS {renommage_documentation} FROM read_csv_auto
  )

```

R

```

library(duckdb)
library(glue)

# Pour créer une base de données en mémoire
con <- dbConnect(duckdb())

renommage_documentation <- paste(
  "SELECT",
  "COD_VAR AS nom_variable,",
  "LIB_VAR AS description_variable,",
  "TYPE_VAR AS type_variable,",
  "COD_MOD AS code_modalite,",
  "LIB_MOD AS description_modalite"
)

dbExecute(
  con,
  glue(
    'CREATE OR REPLACE VIEW table_logement AS SELECT * FROM read_parquet("{path_data}/FD_I
  )
)

dbExecute(
  con,
  glue(
    'CREATE OR REPLACE VIEW table_logement AS SELECT * FROM read_parquet("{path_data}/FD_L

```

```

    )
)

dbExecute(
  con,
  glue(
    'CREATE OR REPLACE VIEW documentation AS {renommage_documentation} FROM read_csv_auto("{
  )
)

```

Pour rapidement avoir une idée des informations présentes dans ces données, le code ci-dessous peut être utilisé :

Python

```

schema_table_individu = duckdb.sql(
  "SELECT * FROM documentation"
).to_df()
schema_table_individu.head(2)

```

R

```

schema_table_individu <- dbGetQuery(
  con,
  "SELECT column_name AS colnames, data_type AS types
  FROM INFORMATION_SCHEMA.COLUMNS
  WHERE table_name = 'table_individu'"
)
print(schema_table_individu)

```

	nom_variable	description_variable	type_variable	code_modalite	descri
0	ACHL	Période d'achèvement de la construction de la ...	CHAR	A11	Avant
1	ACHL	Période d'achèvement de la construction de la ...	CHAR	A12	De 19

<IPython.core.display.HTML object>

```
documentation = transpose(documentation_raw)
```

Pour découvrir les informations présentes dans la base, il est possible d'utiliser les fonctions pré-implémentées de DuckDB pour la [manipulation de données textuelles](#). Par exemple, pour extraire les variables dont la description contient le terme “*catégorie*”:

Python

```
duckdb.sql("SELECT * FROM documentation WHERE CONTAINS(description_variable, 'Catégorie')")
```

R

```
query <- "SELECT * FROM documentation WHERE CONTAINS(description_variable, 'Catégorie')"  
dbGetQuery(con, query)
```

nom_variable	...	code_modalite	description_modalite
varchar		varchar	varchar
CATIRIS	...	A	Activité
CATIRIS	...	D	Divers
CATIRIS	...	H	Habitat
CATIRIS	...	Z	Commune non découp...
CATL	...	1	Résidences princip...
CATL	...	2	Logements occasion...
CATL	...	3	Résidences seconda...
CATL	...	4	Logements vacants

8 rows 5 columns (3 shown)

Cette approche peut permettre de récupérer les modalités d'une variable. Dans cette base de données, les valeurs Z sont à part. Il est possible d'avoir du détail sur celles-ci avec la requête suivante

Python

```
duckdb.sql(  
    "SELECT * FROM documentation WHERE CONTAINS(code_modalite, 'Z')"  
)
```

R

```
query <- "SELECT * FROM documentation WHERE CONTAINS(code_modalite, 'Z')"  
dbGetQuery(con, query)
```

nom_variable varchar	...	code_modalite varchar	description_modalite varchar
ARM	...	ZZZZZ	Sans objet
BAIN	...	Z	Logement ordinaire...
BATI	...	Z	Logement ordinaire...
CATIRIS	...	Z	Commune non découp...
CHAU	...	Z	Logement ordinaire...
CHFL	...	Z	Logement ordinaire...
CHOS	...	Z	Logement ordinaire...
CLIM	...	Z	Logement ordinaire...
CMBL	...	Z	Logement ordinaire...
CUIS	...	Z	Logement ordinaire...
.	.	.	.
.	.	.	.
.	.	.	.
ILETUDM	...	Z	Sans objet (pas d'...
ILTM	...	Z	Sans objet (sans e...
IRIS	...	ZZZZZZZZZ	Commune non découp...
RECHM	...	Z	Sans objet (en emp...
SANI	...	Z	Logement ordinaire...
SANIDOM	...	ZZ	Logement ordinaire...
TPM	...	Z	Sans objet (sans e...
TRANSM	...	Z	Sans objet
TRIRIS	...	ZZZZZZ	Commune non découp...
WC	...	Z	Logement ordinaire...

25 rows (20 shown) 5 columns (3 shown)

Lecture et affichage de quelques valeurs

Pour visualiser la table, deux approches :

- Sélectionner un échantillon restreint sur les premières lignes du **Parquet**, par exemple les 5 premières lignes ;
- Sélectionner un échantillon aléatoire.

Python

```
duckdb.sql("SELECT * FROM table_logement LIMIT 5")
```

R

```
dbGetQuery(  
  con,  
  "SELECT * FROM table_logement LIMIT 5"  
)
```

COMMUNE	ARM	IRIS	...	TYPC	TYPL	VOIT	WC
varchar	varchar	varchar		varchar	varchar	varchar	varchar
01001	ZZZZZ	ZZZZZZZZZZ	...	1	1	2	Z
01001	ZZZZZ	ZZZZZZZZZZ	...	2	1	2	Z
01001	ZZZZZ	ZZZZZZZZZZ	...	2	1	2	Z
01001	ZZZZZ	ZZZZZZZZZZ	...	1	1	1	Z
01001	ZZZZZ	ZZZZZZZZZZ	...	Y	6	X	Z

5 rows

69 columns (7 shown)

Python

```
duckdb.sql("SELECT * FROM table_logement USING SAMPLE 5")
```

R

```
dbGetQuery(  
  con,  
  "SELECT * FROM table_logement USING SAMPLE 5"  
)
```

```
FloatProgress(value=0.0, layout=Layout(width='auto'), style=ProgressStyle(bar_color='black'))
```

COMMUNE	ARM	IRIS	...	TYPC	TYPL	VOIT	WC
varchar	varchar	varchar		varchar	varchar	varchar	varchar
87001	ZZZZZ	870010101	...	1	1	1	Z
59507	ZZZZZ	595070101	...	3	2	0	Z
83016	ZZZZZ	830160101	...	3	2	1	Z
40184	ZZZZZ	401840101	...	1	1	2	Z
33422	ZZZZZ	334220102	...	1	1	2	Z

5 rows

69 columns (7 shown)

Sélectionner des observations ou des variables

Requêtes sur les colonnes (SELECT)

La liste des colonnes à extraire du fichier peut être renseignée avec le verbe **SELECT**. Celles-ci peuvent être renommées en appliquant au passage **AS**

Python

```
duckdb.sql("SELECT IPONDI AS poids, AGED, VOIT FROM table_individu LIMIT 10")
```

R

```
dbGetQuery(  
  con,  
  "SELECT IPONDI AS poids, AGED, VOIT FROM table_individu LIMIT 10"  
)
```

poids double	AGED int32	VOIT varchar
0.865065781333387	74	0
4.98793114865391	39	1
4.98793114865391	9	1
5.01354653482522	55	2
3.47836794972965	1	0
3.47836794972965	43	0
3.47836794972965	38	0
1.00358526972379	46	1
1.00358526972379	16	1
0.984086854919485	59	2

10 rows

3 columns

DuckDB offre également des fonctionnalités pour extraire des colonnes à travers des [expressions régulières](#). Plus d'exemples peuvent être trouvés sur [cette page](#).

poids double	AGED int32	AGER20 varchar	AGEREV int32	AGEREVQ varchar
0.865065781333387	74	79	73	70
4.98793114865391	39	39	38	35
4.98793114865391	9	10	8	5
5.01354653482522	55	54	54	50
3.47836794972965	1	2	0	0
3.47836794972965	43	54	42	40
3.47836794972965	38	39	37	35
1.00358526972379	46	54	45	45
1.00358526972379	16	17	15	15


```
0.984086854919485      59  64      58  55

10 rows                  5 columns
```

Requêtes sur les lignes (WHERE)

Pour extraire un sous-échantillon des données complètes, la clause `WHERE` permet d'appliquer des filtres à partir de conditions logiques. Par exemple, il est possible de ne conserver, du fichier national, que les données de l'Aude (11), la Haute-Garonne (31) et l'Hérault (34).

Python

```
duckdb.sql("SELECT * FROM table_individu WHERE DEPT IN ('11', '31', '34')")
```

Il est également possible de formater cette liste telle qu'attendue par SQL à partir d'une liste Python plus classique. Pour cela, le code suivant peut servir de modèle:

```
liste_regions = ["11", "31", "34"]
liste_regions_sql = ", ".join([f"'{dep}'" for dep in liste_regions])
duckdb.sql(f"SELECT * FROM table_individu WHERE DEPT IN ({liste_regions_sql})")
```

R

```
liste_regions <- c("11", "31", "34")
liste_regions_sql <- glue_collapse(lapply(liste_regions, function(dep) glue("'{dep}'")), "
query <- glue("SELECT * FROM table_individu WHERE DEPT IN ({liste_regions_sql})")
dbGetQuery(con, query)
```

```
FloatProgress(value=0.0, layout=Layout(width='auto'), style=ProgressStyle(bar_color='black'))
```

CANTVILLE	NUMMI	ACHLR	AEMMR	...	TYPMR	VOIT	WC
varchar	varchar	varchar	varchar		varchar	varchar	varchar
1101	1	1	6	...	32	2	Z
1101	1	1	6	...	32	2	Z
1101	2	3	8	...	32	2	Z

1101	2	3	8	...	32	2	Z
1101	3	6	9	...	41	3	Z
1101	3	6	9	...	41	3	Z
1101	3	6	9	...	41	3	Z
1101	4	1	7	...	20	2	Z
1101	4	1	7	...	20	2	Z
1101	5	6	9	...	41	2	Z
.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.
1105	1666	5	9	...	32	0	Z
1105	1666	5	9	...	32	0	Z
1105	1667	1	4	...	12	1	Z
1105	1668	6	9	...	41	2	Z
1105	1668	6	9	...	41	2	Z
1105	1668	6	9	...	41	2	Z
1105	1669	1	9	...	11	1	Z
1105	1670	5	9	...	41	2	Z
1105	1670	5	9	...	41	2	Z
1105	1670	5	9	...	41	2	Z

? rows (>9999 rows, 20 shown) 88 columns (7 shown)

Les filtres sur les observations peuvent être faits à partir de critères sur plusieurs colonnes. Par exemple, pour ne conserver que les observations de la ville de Nice où la date d’emménagement est postérieure à 2020, la requête suivante peut être utilisée:

Python

```
duckdb.sql("SELECT * FROM table_logement WHERE COMMUNE = '06088' and AEMM > 2020")
```

R

```
dbGetQuery(
  con,
  "SELECT * FROM table_logement WHERE COMMUNE = '06088' and AEMM > 2020"
)
```

Statistiques agrégées

Le langage **SQL** permet d'exécuter de manière très efficace des requêtes complexes afin de construire, à partir de données fines, des statistiques agrégées.

Cette partie illustre d'abord ceci avec deux exemples de statistiques agrégées renvoyant une unique statistique :

- Extraire la liste des codes arrondissements de Paris, Lyon, Marseille où au moins une personne a été recensée ;
- Reproduire l'exemple de (Mauvière 2022) permettant de calculer le nombre d'habitants de Toulouse qui ont changé de logement en un an;

Ensuite, des statistiques plus fines sont construites par le biais d'agrégations par groupe:

- Calculer le nombre de personnes recensées par cohorte pour les départements de l'Aude (11), de la Haute-Garonne (31) et de l'Hérault (34) ;
- Calculer le nombre de centenaires recensés par département.

Python

```
duckdb.sql("SELECT DISTINCT(ARM) FROM table_logement WHERE ARM IS NOT NULL")
```

R

```
dbGetQuery(  
  con,  
  "SELECT DISTINCT(ARM) FROM table_logement WHERE ARM IS NOT NULL"  
)
```

```
  ARM  
varchar
```

```
75112  
75109  
69389  
13215  
75103  
69381
```

```

69383
13212
13214
13208
.
.
.
75115
75116
69385
69387
13202
13204
13206
13211
13213
75120

46 rows
(20 shown)

```

Python

```

duckdb.sql("SELECT CAST(SUM(IPONDL) AS INT) AS habitants_toulouse_demenagement FROM table_lo

```

R

```

query <- "SELECT CAST(SUM(IPONDL) AS INT) AS habitants_toulouse_demenagement FROM table_lo
dbGetQuery(con, query)

```

	habitants_toulouse_demenagement
0	91195

Python

```
import matplotlib.pyplot as plt
from plotnine import *

pyramide_ages = duckdb.sql(
    """
    SELECT
        SUM(IPONDI) AS individus,
        AGED,
        DEPT AS departement
    FROM table_individu
        WHERE DEPT IN ('11', '31', '34')
    GROUP BY AGED, DEPT ORDER BY DEPT, AGED
    """
).to_df()

(
    ggplot(pyramide_ages, aes(x = "AGED", y = "individus")) +
    geom_bar(aes(fill = "departement"), stat = "identity", show_legend=False) + geom_vline
    theme_minimal() +
    labs(y = "Individus recensés", x = "Âge")
)
```

R

```
library(ggplot)

query <- "SELECT SUM(IPONDI) AS individus, AGED, DEPT AS departement FROM table_individu W
dbGetQuery(con, query)

(
    ggplot(pyramide_ages, aes(x = "AGED", y = "individus")) +
    geom_bar(aes(fill = "departement"), stat = "identity", show_legend=False) + geom_vline
    theme_minimal() +
    labs(y = "Individus recensés", x = "Âge")
)
```

Si on s'intéresse plus spécifiquement au nombre de centenaires recensés par département et qu'on désire les classer par ordre décroissant

Python

```
duckdb.sql(  
    """  
    SELECT  
        SUM(IPONDI) AS individus_recenses,  
        DEPT  
    FROM table_individu  
        WHERE AGED >= 100  
    GROUP BY DEPT  
    ORDER BY individus_recenses DESC  
    """  
)
```

R

```
query <- "SELECT SUM(IPONDI) AS individus_recenses, DEPT FROM table_individu WHERE AGED >=  
dbGetQuery(con, query)
```

individus_recenses	DEPT
int64	varchar
470	75
322	13
281	06
261	69
241	92
239	83
216	33
183	31
183	44
177	59
.	.
.	.
.	.
25	46
23	70
23	08
21	15

21	05
20	23
17	55
14	90
12	973
11	48

100 rows (20 shown)

Associer à d'autres sources de données

Le [code officiel géographique \(COG\)](#) est utile pour illustrer l'ajout d'information annexe. Le code commune va être utilisé pour associer les deux bases de données. Cette variable porte des noms différents dans les deux bases, ce qui n'est pas un problème.

Il est proposé, ci-dessous, de télécharger les données de manière reproductible via une fonction adaptée (ici à travers le *package* `requests` pour Python ou via `download.file` en R). Bien que DuckDB permette l'import direct depuis un *url*, ceci implique l'installation en amont de l'[extension httpfs](#).

Python

```
import requests
import os

url_cog = "https://www.insee.fr/fr/statistiques/fichier/6800675/v_commune_2023.csv"
if os.path.exists("cog.csv") is False:
    response = requests.get(url_cog)
    with open("cog.csv", mode="wb") as file:
        file.write(response.content)

duckdb.sql('CREATE OR REPLACE VIEW cog2023 AS SELECT * FROM read_csv_auto("cog.csv", header=1)')

duckdb.sql(
    """
    SELECT cog2023.NCCENR, CAST(SUM(table_logement.IPONDL) AS INT) AS recenses
    FROM table_logement
    LEFT OUTER JOIN cog2023 ON table_logement.COMMUNE = cog2023.COM
    GROUP BY cog2023.NCCENR
    """
)
```

```
ORDER BY recenses;
""
)
```

R

```
query <- "SELECT cog2023.NCCENR, CAST(SUM(table_logement.IPONDL) AS INT) AS recenses FROM
dbGetQuery(con, query)
```

NCCENR varchar	recenses int32
Cumières-le-Mort-Homme	1
Épécamps	3
Leménil-Mitry	3
Rouvroy-Ripont	4
Maroncourt	4
Ornes	4
Aingoulaincourt	5
Bâtie-des-Fonds	6
Casterets	6
Molring	7
.	.
.	.
.	.
Plessis-Lastelle	151
Saint-Outrille	151
Peyrouse	151
Dieulivol	151
Genettes	151
Formentin	151
Hôtellerie	151
Rotherens	151
Thennelières	151
Frasnois	151

? rows (>9999 rows, 20 shown)

- Dondon, Alexis, and Pierre Lamarche. 2023. “Quels Formats Pour Quelles Données?” *Courrier Des Statistiques*, no. 9.
- Mauvière, Éric. 2022. “Parquet Devrait Remplacer Le Format CSV.” Post de blog [Consulté le 12 octobre 2023]. 2022. <https://www.icem7.fr/cartographie/parquet-devrait-remplacer-le-format-csv/>.