

TP SQL — la base education.db — Corrigé

Écoles, collèges, lycées, spécialités et communes de France : la base education.db est décrite en détail dans README_bases.md. Ce qu'il faut savoir pour ce TP :

- **aucune valeur NULL** ; dans les tables d'effectifs, l'absence de ligne signifie un effectif nul ;
- les **codes** (code_insee, code_commune, dep_code, uai...) sont des **chaînes de caractères** : on écrit dep_code = '78', avec des apostrophes ;
- les établissements sont **datés** : la clé primaire de ecoles, colleges et lycees est le couple (uai, rentree).

Rappels hors programme : NULL, LEFT JOIN, WITH, IN/NOT IN, EXISTS, GROUP_CONCAT.

Tout ce TP se traite avec SELECT ... FROM ... JOIN ... ON ... WHERE ... GROUP BY ... HAVING ... ORDER BY ... LIMIT/OFFSET, les sous-requêtes et UNION/INTERSECT/EXCEPT.

Chargement de la base

```
from sql_fonctions import GestionnaireSQL
```

```
db = GestionnaireSQL("education.db")
db.liste_tables()
```

```
name
-----
communes
ecoles
colleges
effectifs_colleges
lycees
effectifs_lycees
specialites
combinaisons
cpge
```

```
# Les schémas des tables utilisées dans ce TP.
```

```
for table in ["communes", "ecoles", "colleges", "effectifs_colleges",
              "lycees", "effectifs_lycees", "specialites", "cpge"]:
    print(f"{table} : {db.schema('SELECT * FROM ' + table)}")
```

```
communes : ['code_insee', 'nom_standard', 'nom_sans_prenom', 'nom_a',
            'nom_de', 'nom_sans_accent', 'nom_majuscule', 'reg_code', 'reg_nom',
            'dep_code', 'dep_nom', 'epci_code', 'epci_nom', 'code_postal',
            'academie_code', 'academie_nom', 'population', 'superficie_km2',
            'altitude_moyenne', 'altitude_min', 'altitude_max',
            'latitude_mairie', 'longitude_mairie', 'latitude_centre',
            'longitude_centre', 'grille_densite', 'grille_densite_texte',
            'gentile', 'url_wikipedia']
ecoles : ['uai', 'rentree', 'denomination', 'patronyme', 'secteur',
          'code_commune', 'rep', 'rep_plus', 'nb_classes', 'pre_elementaire',
          'elementaire', 'ulis']
colleges : ['uai', 'rentree', 'denomination', 'patronyme', 'secteur',
            'code_commune', 'rep', 'rep_plus']
```

```
effectifs_colleges : ['uai', 'rentree', 'niveau', 'filles', 'garcons']
lycees : ['uai', 'rentree', 'denomination', 'patronyme', 'secteur',
         'code_commune']
effectifs_lycees : ['uai', 'rentree', 'niveau', 'serie', 'filles',
                  'garcons']
specialites : ['uai', 'rentree', 'niveau', 'code_specialite',
              'specialite', 'filles', 'garcons']
cpge : ['rentree', 'ministere', 'filiere', 'annee_etude',
        'garcons_public', 'filles_public', 'garcons_prive', 'filles_prive']
```

Exécuter une requête dans ce TP

Placer ce notebook, education.db et sql_fonctions.py dans le même dossier, puis exécuter les deux cellules de chargement ci-dessus avec **Maj + Entrée**. Dans une cellule de code, écrire une requête SQL entre les triples guillemets de `db.requete("""...""")`, puis exécuter la cellule : les noms des colonnes et les lignes du résultat s'affichent en dessous. Les triples guillemets permettent d'écrire la requête sur plusieurs lignes ; les valeurs textuelles SQL restent entre apostrophes. Par exemple :

```
db.requete("""
SELECT nom_standard
FROM communes
LIMIT 5
""")
```

Modifier la requête et réexécuter la cellule pour essayer une autre solution. Pour la partie graphique, `db.liste("""...""")` renvoie une liste de tuples à conserver dans une variable, tandis que `db.schema("""...""")` renvoie les noms des colonnes. Après un redémarrage du noyau, réexécuter les cellules de chargement.

1. Lire le schéma

Question 1. Sans écrire de requête :

1. Quelle est la clé primaire de communes ? Celle de lycees ? Pourquoi uai seul ne suffit-il pas ?
2. Quelle colonne de lycees est une clé étrangère, et vers quelle colonne de quelle table ?
3. Donner le type d'association (1 – 1, 1 – * ou * – *) entre : communes et lycees ; lycees et effectifs_lycees ; les lycées et les spécialités.

Réponse.

1. code_insee ; le couple (uai, rentree) : un même établissement apparaît une fois **par rentrée**, uai seul n'est donc pas unique dans la table.
2. code_commune référence communes(code_insee) — les deux colonnes ont le **même contenu mais pas le même nom**.
3. communes-lycees : 1 – * (une commune a plusieurs lycées, un lycée une seule commune) ; lycees-effectifs_lycees : 1 – * ; lycées-spécialités : * – *, et c'est précisément le rôle de la **table d'association** specialites, dont chaque ligne relie un lycée (clé étrangère (uai, rentree)) à une spécialité (code_specialite).

2. Une seule table

Question 2 (*projection, sélection, tri*). Le nom et la population des communes des Yvelines (`dep_code = '78'`) de plus de 20 000 habitants, par population décroissante.

```
db.requete("""
SELECT nom_standard, population
FROM communes
WHERE dep_code = '78' AND population > 20000 -- '78' entre apostrophes : dep_code_
↳est une chaîne
ORDER BY population DESC
""")
```

nom_standard	population

Versailles	84095
Sartrouville	52763
Saint-Germain-en-Laye	45931
Mantes-la-Jolie	43526
Poissy	40983
Conflans-Sainte-Honorine	36958
Trappes	34689
Les Mureaux	34632
Houilles	33983
Montigny-le-Bretonneux	32465
Plaisir	31811
Le Chesnay-Rocquencourt	30689
Chatou	30598
Guyancourt	29778
Rambouillet	27724
Élancourt	26365
Maisons-Laffitte	23093
Vélizy-Villacoublay	23011
Mantes-la-Ville	22332
Achères	22241
Saint-Cyr-l'École	21268
Carrières-sous-Poissy	20825
Maurepas	20629
La Celle-Saint-Cloud	20460

Question 3 (*DISTINCT*).

1. Comparer le nombre de lignes de colleges et son nombre d'établissements distincts. Expliquer l'écart.
2. Combien de communes distinctes comptent au moins un collège REP+ à la rentrée 2025 ?

```
db.requete("""
SELECT COUNT(*) AS lignes, COUNT(DISTINCT uai) AS etablisements
FROM colleges
""")
# 48 676 lignes pour 7 029 collèges : une ligne par établissement ET par rentrée_
↳(2019-2025).
```

lignes etablissements

48676 7029

```
db.requete("""
SELECT COUNT(DISTINCT code_commune) AS nb_communes
FROM colleges
WHERE rentree = 2025 AND rep_plus = TRUE
""")
# « au moins un » se traduit par DISTINCT : une commune à deux collèges REP+ ne
# compte qu'une fois.
# rep_plus est un booléen : on le compare à TRUE (l'écriture = 1 est acceptée).
```

nb_communes

198

Question 4 (*ORDER BY, LIMIT, OFFSET*). Les trois communes les plus peuplées de France, puis les communes des rangs 4 à 10 (nom et population).

```
db.requete("""
SELECT nom_standard, population
FROM communes
ORDER BY population DESC
LIMIT 3
""")

db.requete("""
SELECT nom_standard, population
FROM communes
ORDER BY population DESC
LIMIT 7 OFFSET 3
""")
# LIMIT sans ORDER BY renverrait des lignes non déterminées,
# et LIMIT tranche arbitrairement entre ex æquo.
```

nom_standard population

Paris 2103778

Marseille 886040

Lyon 519127

nom_standard population

Toulouse 514819

Nice 357737

Nantes 327734

Montpellier 310240

Strasbourg 293771

Bordeaux 267991

Lille 238246

Question 5 (*renommage AS*). Les dix communes les plus denses parmi celles de plus de 10 000 habitants (nom et densité en habitants/km²).

```
db.requete("""
SELECT nom_standard, population / superficie_km2 AS densite
FROM communes
WHERE population > 10000      -- l'alias n'existe pas encore ici :
ORDER BY densite DESC        -- ... mais il existe déjà là !
LIMIT 10
""")
# Ordre d'exécution : FROM -> WHERE -> SELECT (l'alias naît ici) -> ORDER BY ->
↳ LIMIT.
```

nom_standard	densite
Levallois-Perret	28137.19008264463
Vincennes	25364.736842105263
Le Pré-Saint-Gervais	24275.714285714286
Saint-Mandé	23154.945054945056
Montrouge	22378.74396135266
Clichy	20912.33766233766
Paris	19954.2634923646
Courbevoie	19928.365384615383
Asnières-sur-Seine	19449.482401656314
Boulogne-Billancourt	19321.266233766233

Agrégats

Question 6 (*agrégats simples*). En une seule requête : le nombre de communes des Yvelines, leur population totale, leur superficie totale et l'altitude du plus haut sommet du département.

```
db.requete("""
SELECT COUNT(*) AS nb_communes, SUM(population) AS nb_habitants,
      SUM(superficie_km2) AS km2, MAX(altitude_max) AS sommet
FROM communes
WHERE dep_code = '78'
""")
```

nb_communes	nb_habitants	km2	sommet
259	1485086	2305.68	201

Question 7 (*GROUP BY*). Le nombre de communes et la population totale de chaque région, par population décroissante (nom de région, nombre de communes, population de la région).

```
db.requete("""
SELECT reg_nom, COUNT(*) AS nb_communes, SUM(population) AS nb_habitants
FROM communes
GROUP BY reg_nom
ORDER BY nb_habitants DESC
""")
```

reg_nom	nb_communes	nb_habitants
Île-de-France	1266	12463067
Auvergne-Rhône-Alpes	4019	8199817

Nouvelle-Aquitaine	4293	6150451
Occitanie	4445	6123113
Hauts-de-France	3781	5992194
Grand Est	5115	5563378
Provence-Alpes-Côte d'Azur	946	5218960
Pays de la Loire	1225	3888744
Bretagne	1202	3449370
Normandie	2643	3343946
Bourgogne-Franche-Comté	3685	2802670
Centre-Val de Loire	1754	2587031
La Réunion	24	889679
Guadeloupe	32	384160
Martinique	34	360630
Corse	360	355486
Guyane	22	293996
Mayotte	17	256518

Question 8 (*WHERE et HAVING*). Les académies comptant au moins cinq communes de plus de 50 000 habitants, avec ce nombre, par ordre décroissant.

```
db.requete("""
SELECT academie_nom, COUNT(*) AS nb
FROM communes
WHERE population > 50000 -- filtre les LIGNES, avant regroupement
GROUP BY academie_nom
HAVING COUNT(*) >= 5      -- filtre les GROUPEs, après agrégation
ORDER BY nb DESC
""")
```

```
academie_nom  nb
-----
Créteil       23
Versailles    21
Nice          9
Nantes        7
Lille         6
La Réunion    6
Rennes        5
Montpellier   5
Lyon          5
Bordeaux      5
```

Question 9 (*division entière !*). La proportion de filles en terminale générale (série G) en France à la rentrée 2025.

```
db.requete("""
SELECT SUM(filles) / SUM(filles + garcons) AS proportion
FROM effectifs_lycees
WHERE rentree = 2025 AND niveau = 'terminale' AND serie = 'G'
""")
# 0 ! Les effectifs sont entiers : la division est ENTIÈRE.
```

```
proportion
-----
0
```

```
db.requete("""
SELECT 1.0 * SUM(filles) / SUM(filles + garçons) AS proportion
FROM effectifs_lycees
WHERE rentree = 2025 AND niveau = 'terminale' AND serie = 'G'
""")
# Multiplier par 1.0 force le calcul en flottant.
```

proportion

0.5562758311351282

Sous-requêtes

Question 10 (*sous-requête scalaire*). La commune la plus peuplée des Yvelines, de deux façons : avec ORDER BY ... LIMIT 1, puis avec une sous-requête scalaire. Quelle version garde les ex æquo ? Pourquoi SELECT nom_standard, MAX(population) serait-il incorrect ?

On affichera (nom, population).

```
db.requete("""
SELECT nom_standard, population
FROM communes
WHERE dep_code = '78'
ORDER BY population DESC
LIMIT 1
""")

db.requete("""
SELECT nom_standard, population
FROM communes
WHERE dep_code = '78'
  AND population = (SELECT MAX(population) FROM communes WHERE dep_code = '78')
""")
# La sous-requête scalaire garde les ex æquo ; LIMIT 1 en écarterait.
# SELECT nom_standard, MAX(population) est incorrect : une colonne non agrégée
# n'a pas de sens à côté d'un agrégat (même si certains logiciels l'acceptent).
```

nom_standard population

Versailles 84095

nom_standard population

Versailles 84095

Question 11 (*rang*). Le rang de Versailles au classement des communes françaises par population décroissante.

```
db.requete("""
SELECT 1 + COUNT(*) AS rang
FROM communes
WHERE population > (SELECT population FROM communes WHERE nom_standard =
↳ 'Versailles')
""")
# Rang = 1 + nombre de communes strictement plus peuplées.
```

```
# La sous-requête doit être SCALAIRE : on a vérifié qu'une seule commune s'appelle
↳ Versailles.
```

rang

56

Question 12 (*agrégat d'agrégat*). Le nombre moyen d'écoles par commune à la rentrée 2025 (parmi les communes qui en ont au moins une).

```
db.requete("""
SELECT AVG(nb) AS ecoles_par_commune
FROM (SELECT COUNT(*) AS nb
      FROM ecoles
      WHERE rentree = 2025
      GROUP BY code_commune)
""")
# AVG(COUNT(*)) n'existe pas : un agrégat d'agrégat exige une sous-requête dans le
↳ FROM.
```

ecoles_par_commune

2.2388224559381453

Question 13 (*compter des groupes*). Dans un département, appelons *doublon* un ensemble de communes ayant exactement la même population. Les départements comptant au moins cent doublons, avec ce nombre, par nombre décroissant.

```
db.requete("""
SELECT dep_nom, COUNT(*) AS nb_doublons
FROM (SELECT dep_nom, population
      FROM communes
      GROUP BY dep_nom, population
      HAVING COUNT(*) > 1)
GROUP BY dep_nom
HAVING COUNT(*) >= 100
ORDER BY nb_doublons DESC
""")
# Deux GROUP BY empilés et deux HAVING : celui du DEDANS ne garde que les
# groupes d'au moins deux communes (les doublons), celui du DEHORS ne garde que
# les départements qui en comptent au moins cent.
```

dep_nom	nb_doublons
-----	-----
Aisne	172
Somme	170
Côte-d'Or	163
Pas-de-Calais	153
Marne	128
Haute-Saône	120
Meuse	119
Seine-Maritime	114
Oise	113
Moselle	112
Jura	106

Meurthe-et-Moselle	103
Hautes-Pyrénées	103
Gers	103
Doubs	103
Eure	100

3. Jointures

Toute cette partie se joue dans l'univers des lycées, avec des tables introduites une à une : d'abord le couple lycées-communes, puis effectifs_lycees, et enfin la table d'association specialites.

3.1 Un premier couple : lycées et communes

Question 14 (*jointure simple*). La dénomination, le patronyme et le secteur des lycées de Versailles à la rentrée 2025.

```
db.requete("""
SELECT L.denomination, L.patronyme, L.secteur
FROM (lycees AS L JOIN communes AS C ON L.code_commune = C.code_insee)
WHERE C.nom_standard = 'Versailles' AND L.rentree = 2025
""")
# La condition de jointure apparie la clé étrangère code_commune à la clé
# primaire code_insee : deux colonnes de même contenu... mais pas de même nom.
```

denomination	patronyme	secteur
LYCEE D'ENSEIGNEMENT GENERAL	HOCHÉ	PUBLIC
LYCEE GENERAL ET TECHNOLOGIQUE	LA BRUYÈRE	PUBLIC
LYCEE POLYVALENT	JULES FERRY	PUBLIC
LYCEE GEN.ET TECHNOL.PRIVE	LES CHATAIGNIERS	PRIVE
LYCEE POLYVALENT PRIVE	ST VINCENT DE PAUL	PRIVE
LYCEE GEN.ET TECHNOL.PRIVE	SAINT JEAN ET HULST	PRIVE
LYCEE GEN.ET TECHNOL.PRIVE	NOTRE DAME DU GRANDCHAMP	PRIVE
LYCEE GENERAL ET TECHNOLOGIQUE	MARIE CURIE	PUBLIC

Question 15 (*désigner par la clé, pas par le nom*). Combien la commune nommée Saint-Denis compte-t-elle de lycées à la rentrée 2025 ? La réponse obtenue est-elle correcte ?

```
db.requete("""
SELECT COUNT(*) AS nb_lycees
FROM (lycees AS L JOIN communes AS C ON L.code_commune = C.code_insee)
WHERE L.rentree = 2025 AND C.nom_standard = 'Saint-Denis'
""")
# 11 lycées ? Non : un NOM ne désigne pas une commune.
```

```
nb_lycees
-----
11
```

```
db.requete("""
SELECT C.nom_standard, C.dep_nom, COUNT(*) AS nb_lycees
FROM (lycees AS L JOIN communes AS C ON L.code_commune = C.code_insee)
WHERE L.rentree = 2025 AND C.nom_standard = 'Saint-Denis'
GROUP BY C.code_insee, C.nom_standard, C.dep_nom
```

```

"""
# Le 11 fusionnait DEUX communes : Saint-Denis (93) et Saint-Denis (974).
# On regroupe par la CLÉ PRIMAIRE (en répétant dans le GROUP BY les colonnes
# affichées) : 1 446 noms de communes sont partagés, seul le code identifie.

```

nom_standard	dep_nom	nb_lycees
Saint-Denis	Seine-Saint-Denis	5
Saint-Denis	La Réunion	6

3.2 Un deuxième couple : lycees et effectifs_lycees

Question 16 (condition de jointure composée). Le patronyme et l'effectif de terminale G des lycées de Versailles à la rentrée 2025, par effectif décroissant. Le code INSEE de Versailles, lu dans communes à la question 14, est '78646'.

```

db.requete("""
SELECT L.patronyme, E.filles + E.garcons AS effectif
FROM (lycees AS L JOIN effectifs_lycees AS E
      ON L.uai = E.uai AND L.rentree = E.rentree)
WHERE L.code_commune = '78646' AND L.rentree = 2025
      AND E.niveau = 'terminale' AND E.serie = 'G'
ORDER BY effectif DESC
""")
# Les établissements sont datés : la jointure porte sur uai ET rentree.
# En oubliant la seconde égalité, chaque lycée serait apparié aux effectifs
# de TOUTES ses rentrées.

```

patronyme	effectif
HOCHE	377
LA BRUYERE	376
SAINT JEAN ET HULST	314
NOTRE DAME DU GRANDCHAMP	254
MARIE CURIE	236
JULES FERRY	193
LES CHATAIGNIERS	27

Question 17 (joindre avant d'agréger). Le plus grand effectif de terminale G d'un lycée privé à la rentrée 2025.

```

db.requete("""
SELECT MAX(E.filles + E.garcons) AS record
FROM (lycees AS L JOIN effectifs_lycees AS E
      ON L.uai = E.uai AND L.rentree = E.rentree)
WHERE L.secteur = 'PRIVE' AND E.rentree = 2025
      AND E.niveau = 'terminale' AND E.serie = 'G'
""")
# Le secteur est dans lycees, l'effectif dans effectifs_lycees : il faut
# JOINDRE avant d'agréger. Une sous-requête scalaire ne peut pas remplacer la
# jointure : il y a 852 lycées privés (comparer au « record de France », X 2019).

```

record
495

Question 18 (*portée d'une sous-requête scalaire*). Le ou les lycées privés atteignant ce record en 2025 (patronyme, effectif). Que renvoie la requête si la sous-requête calcule le maximum sur tous les lycées ?

```
db.requete("""
SELECT L.patronyme, E.filles + E.garcons AS effectif
FROM (lycees AS L JOIN effectifs_lycees AS E
      ON L.uai = E.uai AND L.rentree = E.rentree)
WHERE L.secteur = 'PRIVE' AND E.rentree = 2025
      AND E.niveau = 'terminale' AND E.serie = 'G'
      AND E.filles + E.garcons = (SELECT MAX(filles + garcons)
                                  FROM effectifs_lycees
                                  WHERE rentree = 2025
                                  AND niveau = 'terminale' AND serie = 'G')
""")
# Résultat vide : le maximum TOUS SECTEURS (658 élèves) est atteint par un
# lycée public. La sous-requête a une portée trop large.
```

patronyme effectif

Résultat vide.

```
db.requete("""
SELECT L.patronyme, E.filles + E.garcons AS effectif
FROM (lycees AS L JOIN effectifs_lycees AS E
      ON L.uai = E.uai AND L.rentree = E.rentree)
WHERE L.secteur = 'PRIVE' AND E.rentree = 2025
      AND E.niveau = 'terminale' AND E.serie = 'G'
      AND E.filles + E.garcons =
      (SELECT MAX(E2.filles + E2.garcons)
       FROM (lycees AS L2 JOIN effectifs_lycees AS E2
             ON L2.uai = E2.uai AND L2.rentree = E2.rentree)
       WHERE L2.secteur = 'PRIVE' AND E2.rentree = 2025
             AND E2.niveau = 'terminale' AND E2.serie = 'G')
""")
# La sous-requête doit refaire la MÊME jointure et le MÊME filtre : son maximum
# porte alors sur les seuls lycées privés (cf. CCMP 2022 Q8, 2024 Q9).
```

patronyme effectif

SAINTE MARIE LYON 495

3.3 La même table des deux côtés : autojointures

Question 19 (*autojointure*). Les paires de lycées distincts de Versailles à la rentrée 2025. Combien de lignes obtiendrait-on avec <> au lieu de <? Et sans aucune condition sur les uai ?

```
db.requete("""
SELECT L1.patronyme, L2.patronyme
FROM (lycees AS L1 JOIN lycees AS L2
      ON L1.code_commune = L2.code_commune AND L1.rentree = L2.rentree)
WHERE L1.rentree = 2025 AND L1.code_commune = '78646'
      AND L1.uai < L2.uai
```

```
ORDER BY L1.patronyme, L2.patronyme
```

```
""")
```

```
# Versailles a 8 lycées. Avec L1.uai < L2.uai : 28 paires.
```

```
# Avec <> : 56 lignes, chaque paire apparaît DEUX FOIS (cf. CCMP 2021 Q4).
```

```
# Sans condition : 64 lignes, chaque lycée est apparié à lui-même.
```

patronyme	patronyme
HOCHÉ	JULES FERRY
HOCHÉ	LA BRUYERE
HOCHÉ	LES CHATAIGNIERS
HOCHÉ	MARIE CURIE
HOCHÉ	NOTRE DAME DU GRANDCHAMP
HOCHÉ	SAINT JEAN ET HULST
HOCHÉ	ST VINCENT DE PAUL
JULES FERRY	LES CHATAIGNIERS
JULES FERRY	MARIE CURIE
JULES FERRY	NOTRE DAME DU GRANDCHAMP
JULES FERRY	SAINT JEAN ET HULST
JULES FERRY	ST VINCENT DE PAUL
LA BRUYERE	JULES FERRY
LA BRUYERE	LES CHATAIGNIERS
LA BRUYERE	MARIE CURIE
LA BRUYERE	NOTRE DAME DU GRANDCHAMP
LA BRUYERE	SAINT JEAN ET HULST
LA BRUYERE	ST VINCENT DE PAUL
LES CHATAIGNIERS	NOTRE DAME DU GRANDCHAMP
LES CHATAIGNIERS	SAINT JEAN ET HULST
LES CHATAIGNIERS	ST VINCENT DE PAUL
MARIE CURIE	LES CHATAIGNIERS
MARIE CURIE	NOTRE DAME DU GRANDCHAMP
MARIE CURIE	SAINT JEAN ET HULST
MARIE CURIE	ST VINCENT DE PAUL
SAINT JEAN ET HULST	NOTRE DAME DU GRANDCHAMP
ST VINCENT DE PAUL	NOTRE DAME DU GRANDCHAMP
ST VINCENT DE PAUL	SAINT JEAN ET HULST

Question 20 (autojointure temporelle). Pour chaque lycée de Versailles, l'effectif de terminale G à la rentrée 2019 et à la rentrée 2025, et la variation entre les deux, par variation décroissante.

```
db.requete("""
SELECT L.patronyme,
       E19.filles + E19.garcons AS effectif_2019,
       E25.filles + E25.garcons AS effectif_2025,
       (E25.filles + E25.garcons) - (E19.filles + E19.garcons) AS variation
FROM ((lycees AS L JOIN effectifs_lycees AS E25
      ON L.uai = E25.uai AND L.rentree = E25.rentree)
      JOIN effectifs_lycees AS E19
      ON E19.uai = E25.uai AND E19.niveau = E25.niveau AND E19.serie = E25.serie)
WHERE L.rentree = 2025 AND E19.rentree = 2019
      AND E25.niveau = 'terminale' AND E25.serie = 'G'
      AND L.code_commune = '78646'
ORDER BY variation DESC
```

```
""")
# Deux copies de effectifs_lycees, une par rentrée : on joint la table à
# elle-même sur (uai, niveau, serie) et chaque copie reçoit sa propre rentrée.
# Un lycée sans terminale G à l'une des deux rentrées disparaît du résultat.
```

patronyme	effectif_2019	effectif_2025	variation
SAINT JEAN ET HULST	307	314	7
NOTRE DAME DU GRANDCHAMP	254	254	0
MARIE CURIE	246	236	-10
HOCHÉ	397	377	-20
LA BRUYERE	401	376	-25
JULES FERRY	242	193	-49

3.4 Trois tables et plus

Question 21 (*jointure triple, agrégat*). Les dix académies dont l'effectif total de terminale G est le plus élevé à la rentrée 2025 (nom, effectif).

```
db.requete("""
SELECT C.academie_nom, SUM(E.filles + E.garcons) AS effectif
FROM ((effectifs_lycees AS E JOIN lycees AS L
      ON E.uai = L.uai AND E.rentree = L.rentree)
      JOIN communes AS C ON L.code_commune = C.code_insee)
WHERE E.rentree = 2025 AND E.niveau = 'terminale' AND E.serie = 'G'
GROUP BY C.academie_nom
ORDER BY effectif DESC
LIMIT 10
""")
# Trois tables, mais rien de neuf : l'effectif est dans effectifs_lycees,
# l'académie dans communes, et lycees fait le pont entre les deux.
```

academie_nom	effectif
Versailles	41509
Créteil	27218
Lille	22026
Nantes	20826
Grenoble	19135
Lyon	19027
Bordeaux	18350
Rennes	17897
Aix-Marseille	16971
Normandie	16790

Question 22 (*maximum par groupe*). Pour chaque académie, le lycée dont l'effectif de terminale G est le plus élevé à la rentrée 2025 (académie, patronyme, effectif), par effectif décroissant. Pourquoi la sous-requête scalaire de la question 18 ne suffit-elle plus ici ?

```
db.requete("""
SELECT C.academie_nom, L.patronyme, E.filles + E.garcons AS effectif
FROM ((effectifs_lycees AS E JOIN lycees AS L
      ON E.uai = L.uai AND E.rentree = L.rentree)
```

```

JOIN communes AS C ON L.code_commune = C.code_insee)
JOIN (SELECT C2.academie_nom AS academie,
        MAX(E2.filles + E2.garcons) AS record
FROM ((effectifs_lycees AS E2 JOIN lycees AS L2
      ON E2.uai = L2.uai AND E2.rentree = L2.rentree)
      JOIN communes AS C2 ON L2.code_commune = C2.code_insee)
WHERE E2.rentree = 2025 AND E2.niveau = 'terminale' AND E2.serie = 'G'
GROUP BY C2.academie_nom) AS M
ON C.academie_nom = M.academie AND E.filles + E.garcons = M.record)
WHERE E.rentree = 2025 AND E.niveau = 'terminale' AND E.serie = 'G'
ORDER BY effectif DESC
""")
# Une sous-requête SCALAIRE ne renvoie QU'UNE valeur : elle donnerait le record
# de France (658, question 18), et non celui de chaque académie. Il en faudrait
# une PAR académie.
# On les calcule donc toutes d'un coup par un GROUP BY : la sous-requête du FROM
# produit la TABLE (academie, record), qu'on JOINT au résultat de la question 21
# sur l'académie ET sur l'effectif. Ne survivent que les lignes atteignant le
# record de LEUR académie : 30 lignes, une par académie (les ex æquo seraient
# tous conservés, comme à la question 10).

```

academie_nom	patronyme	effectif

Versailles	ROSA PARKS	658
Lyon	INTERNATIONAL	649
Nice	AUGUSTE RENOIR	491
Toulouse	SAINT-SERNIN	462
Rennes	ST PAUL	460
Grenoble	CLAUDE LOUIS BERTHOLLET	445
Montpellier	FRANCOIS ARAGO	442
Aix-Marseille	GEORGES DUBY	434
Clermont-Ferrand	JEANNE D'ARC	430
Bordeaux	FRANCOIS MAURIAC	425
Nancy-Metz	HENRI POINCARÉ	415
Normandie	MALHERBE	406
Nantes	SAINT BENOIT	401
Mayotte	YOUNOUSSA BAMANA	380
Poitiers	JEAN DAUTET	380
Orléans-Tours	GRANDMONT	379
Lille	INTERNATIONAL MONTEBELLO	374
Paris	HELENE BOUCHER	368
Corse	GIOCANTE DE CASABIANCA	360
Créteil	WOLFGANG AMADEUS MOZART	349
Amiens	PIERRE D AILLY	348
Strasbourg	JEAN MERMOZ	347
Dijon	CATHERINE ET RAYMOND JANOT	338
Limoges	D ARSONVAL	325
Besançon	XAVIER MARMIER	311
Reims	JEAN JAURES	310
Guadeloupe	BAIMBRIDGE	281
Guyane	LEON-GONTRAN DAMAS	274
La Réunion	EVARISTE DE PARNY	249
Martinique	BELLEVUE	249

Question 23 (*deux jointures triples*). Les dix académies où la proportion d'élèves de terminale inscrits en voie générale (série G) est la plus élevée à la rentrée 2025 (nom, proportion).

```
db.requete("""
SELECT T1.academie, 1.0 * T1.effectif / T2.effectif AS proportion_TG
FROM ((SELECT C.academie_nom AS academie,
        SUM(E.filles + E.garcons) AS effectif
      FROM ((effectifs_lycees AS E JOIN lycees AS L
            ON E.uai = L.uai AND E.rentree = L.rentree)
          JOIN communes AS C ON L.code_commune = C.code_insee)
      WHERE E.rentree = 2025 AND E.niveau = 'terminale' AND E.serie = 'G'
      GROUP BY C.academie_nom) AS T1
JOIN
(SELECT C.academie_nom AS academie,
        SUM(E.filles + E.garcons) AS effectif
      FROM ((effectifs_lycees AS E JOIN lycees AS L
            ON E.uai = L.uai AND E.rentree = L.rentree)
          JOIN communes AS C ON L.code_commune = C.code_insee)
      WHERE E.rentree = 2025 AND E.niveau = 'terminale'
      GROUP BY C.academie_nom) AS T2
      ON T1.academie = T2.academie)
ORDER BY proportion_TG DESC
LIMIT 10
""")
# Le numérateur et le dénominateur portent sur des ENSEMBLES DE LIGNES
# DIFFÉRENTS (la terminale G, toute la terminale) : un seul GROUP BY ne peut
# pas les produire ensemble. On calcule donc chaque total dans sa propre
# sous-requête du FROM, puis on les lie académie par académie.
```

academie	proportion_TG
Paris	0.8300464967131633
Nice	0.7724336865868189
Corse	0.7682983682983683
Bordeaux	0.7581391505536275
Versailles	0.7501807272464397
Strasbourg	0.742875788557755
Poitiers	0.7420810626702997
Clermont-Ferrand	0.7409080104587592
Nantes	0.7374384759746468
Reims	0.7364384797564001

Question 24 (*table d'association : traduire un « et »*). Les lycées de l'académie de Versailles proposant, en terminale à la rentrée 2025, à la fois « Numérique et sciences informatiques » et « Arts plastiques » (patronyme du lycée, nom de la commune). Pourquoi la condition `specialite = 'Numérique et sciences informatiques' AND specialite = 'Arts plastiques'` renvoie-t-elle une table vide ?

```
db.requete("""
SELECT L.patronyme
FROM ((specialites AS S JOIN lycees AS L ON S.uai = L.uai AND S.rentree = L.rentree)
      JOIN communes AS C ON L.code_commune = C.code_insee)
WHERE S.rentree = 2025 AND S.niveau = 'terminale' AND C.academie_nom = 'Versailles'
```

```

AND S.specialite = 'Numérique et sciences informatiques'
AND S.specialite = 'Arts plastiques'
""")
# Vide : une MÊME ligne de specialites ne peut pas porter deux valeurs à la fois.

```

patronyme

Résultat vide.

```

db.requete("""
SELECT L.patronyme, C.nom_standard
FROM ((specialites AS S1 JOIN specialites AS S2
      ON S1.uai = S2.uai AND S1.rentree = S2.rentree AND S1.niveau = S2.niveau)
      JOIN lycees AS L ON S1.uai = L.uai AND S1.rentree = L.rentree)
      JOIN communes AS C ON L.code_commune = C.code_insee)
WHERE S1.rentree = 2025 AND S1.niveau = 'terminale' AND C.academie_nom =
↳ 'Versailles'
  AND S1.specialite = 'Numérique et sciences informatiques'
  AND S2.specialite = 'Arts plastiques'
ORDER BY C.nom_standard
""")
# Le « et » se traduit en joignant DEUX FOIS la table d'association : une copie
# par spécialité exigée (cf. X 2017, points et ensembles). La jointure de S1
# avec S2 est aussi une autojointure : tout de cette partie se retrouve ici.

```

patronyme

nom_standard

```

-----
SAINTE MARIE LA CROIX      Antony
EDMOND MICHELET            Arpajon
NOTRE-DAME                 Bourg-la-Reine
SAINT PIERRE                Brunoy
FRANCO ALLEMAND            Buc
EMMANUEL MOUNIER           Châtenay-Malabry
GUY DE MAUPASSANT          Colombes
JULES FERRY                Conflans-Sainte-Honorine
ROBERT DOISNEAU            Corbeil-Essonnes
ECOLE EUROPEENNE DE PARIS LA D Courbevoie
PAUL LAPIE                  Courbevoie
NIKOLA TESLA                Dourdan
RENE CASSIN                 Gonesse
MONTESQUIEU                Herblay-sur-Seine
FRAGONARD                  L'Isle-Adam
JEAN MONNET                 La Queue-les-Yvelines
L'ESSOURIAU                Les Ulis
ST EXUPERY                  Mantes-la-Jolie
NOTRE-DAME DE BURY          Margency
PARC DE VILGENIS           Massy
FUSTEL DE COULANGES        Massy
ROSA PARKS                  Montgeron
JEAN-JACQUES ROUSSEAU       Montmorency
COURS SECONDAIRE           Orsay
LE CORBUSIER                Poissy
CAMILLE PISSARRO           Pontoise
LOUIS BASCAN                Rambouillet

```

RICHELIEU	Rueil-Malmaison
MANSART	Saint-Cyr-l'École
ALBERT EINSTEIN	Sainte-Geneviève-des-Bois
JEAN-BAPTISTE COROT	Savigny-sur-Orge
MARIE CURIE	Sceaux
JEAN-PIERRE VERNANT	Sèvres
CAMILLE CLAUDEL	Vauréal
HOCHÉ	Versailles
LA BRUYERE	Versailles
NOTRE DAME DE SION	Évry-Courcouronnes

4. Ensembles et antijointure

Question 25 (*INTERSECT*). Les codes INSEE des communes des Yvelines ayant au moins un lycée à la rentrée 2025.

```
db.requete("""
SELECT code_insee FROM communes WHERE dep_code = '78'
INTERSECT
SELECT code_commune FROM lycees WHERE rentree = 2025
""")
# Les deux requêtes renvoient une colonne de MÊME TYPE (un code de commune)
# mais de noms différents : c'est la position qui compte, pas le nom.
# Variante : jointure + SELECT DISTINCT.
```

code_insee

78005
78029
78117
78124
78126
78158
78172
78297
78335
78354
78358
78361
78372
78383
78401
78423
78440
78490
78498
78501
78513
78517
78545
78551
78586
78621
78642

78646
78650
78674
78683

Question 26 (*EXCEPT et antijointure*).

1. Combien de communes de plus de 10 000 habitants n'ont aucun lycée à la rentrée 2025 ?
2. Donner le nom, le département et la population des dix plus peuplées d'entre elles.

```
db.requete("""
SELECT COUNT(*) AS nb_communes
FROM (SELECT code_insee FROM communes WHERE population > 10000
      EXCEPT
      SELECT code_commune FROM lycees WHERE rentree = 2025)
""")
```

nb_communes

334

```
db.requete("""
SELECT C.nom_standard, C.dep_nom, C.population
FROM (communes AS C
      JOIN (SELECT code_insee FROM communes WHERE population > 10000
            EXCEPT
            SELECT code_commune FROM lycees WHERE rentree = 2025) AS S
      ON C.code_insee = S.code_insee)
ORDER BY C.population DESC
LIMIT 10
""")
# EXCEPT ne renvoie que la colonne comparée : pour retrouver nom et population,
# on REJOINT le résultat à communes. C'est l'antijointure du programme
# (NOT IN est hors programme).
```

nom_standard	dep_nom	population
-----	-----	-----
Villenave-d'Ornon	Gironde	42545
Le Cannet	Alpes-Maritimes	41938
Six-Fours-les-Plages	Var	37109
Châtillon	Hauts-de-Seine	36705
Schiltigheim	Bas-Rhin	34708
Houilles	Yvelines	33983
Villiers-sur-Marne	Val-de-Marne	33162
Saint-Médard-en-Jalles	Gironde	32910
Saint-Laurent-du-Var	Alpes-Maritimes	32172
Koungou	Mayotte	32156

Question 27 (*distance*). La commune des Yvelines, autre que Versailles, dont le centre est le plus proche de celui de Versailles (au sens de la distance euclidienne sur les coordonnées latitude_centre, longitude_centre).

```
db.requete("""
SELECT nom_standard
```

```

FROM communes
WHERE dep_code = '78' AND nom_standard <> 'Versailles'
ORDER BY
    (latitude_centre - (SELECT latitude_centre FROM communes
                        WHERE nom_standard = 'Versailles'))
    * (latitude_centre - (SELECT latitude_centre FROM communes
                        WHERE nom_standard = 'Versailles'))
    + (longitude_centre - (SELECT longitude_centre FROM communes
                        WHERE nom_standard = 'Versailles'))
    * (longitude_centre - (SELECT longitude_centre FROM communes
                        WHERE nom_standard = 'Versailles'))
LIMIT 1
""")
# Minimiser la distance = minimiser son carré : inutile de calculer une racine
# (et l'écart longitude/latitude n'est qu'approximativement euclidien).

```

```

nom_standard
-----
Le Chesnay-Rocquencourt

```

5. Synthèse et compléments

Question 28 (la requête complète). Pour chaque académie, le nombre de lycées publics de la rentrée 2025 situés dans une commune de moins de 20 000 habitants ; ne garder que les académies en comptant au moins vingt, par nombre décroissant de lycées.

```

db.requete("""
SELECT K.academie_nom, COUNT(*) AS nb_lycees           -- 4. projection
FROM (lycees AS L JOIN communes AS K
      ON L.code_commune = K.code_insee)                 -- 1. jointure
WHERE L.rentree = 2025 AND L.secteur = 'PUBLIC'
      AND K.population < 20000                          -- 2. lignes
GROUP BY K.academie_nom                               -- 3. groupes
HAVING COUNT(*) >= 20                                   -- 3'. filtre des_
↳groupes
ORDER BY nb_lycees DESC                                -- 5. tri
""")

```

academie_nom	nb_lycees

Normandie	52
Toulouse	46
Grenoble	45
Bordeaux	36
Nancy-Metz	34
Lille	33
Versailles	32
Rennes	31
Nantes	31
Créteil	31
Montpellier	27
Strasbourg	25
Lyon	25
Clermont-Ferrand	22

Orléans-Tours	21
Dijon	21
Poitiers	20

Question 29 (bonus, une table pour finir). Pour chaque rentrée, le nombre total d'étudiants en CPGE et la proportion de filles. Attention à la division...

```
db.requete("""
SELECT rentree,
       SUM(garcons_public + filles_public + garcons_privé + filles_privé) AS total,
       1.0 * SUM(filles_public + filles_privé)
         / SUM(garcons_public + filles_public + garcons_privé + filles_privé)
       AS part_filles
FROM cpge
GROUP BY rentree
ORDER BY rentree
""")
```

rentree	total	part_filles
2009	81135	0.4268441486411536
2010	79874	0.41943561108746275
2011	80411	0.41892278419619206
2012	82221	0.4206711180841877
2013	83520	0.4202586206896552
2014	84151	0.41850958396216326
2015	85938	0.4207568246875655
2016	86473	0.42575139060747286
2017	86478	0.42793542866393763
2018	85121	0.42555891025716336
2019	85070	0.4224520982720113
2020	84903	0.41852466932852783

Question 30 (bonus, retour sur la question 15). Plusieurs communes peuvent porter le même nom. On s'intéresse ici aux couples de communes homonymes.

1. Combien y a-t-il de couples de communes distinctes portant le même nom ?
2. En donner les vingt premiers par ordre alphabétique (nom, et les deux départements).

```
db.requete("""
SELECT COUNT(*) AS nb_couples
FROM (communes AS C1 JOIN communes AS C2 ON C1.nom_standard = C2.nom_standard)
WHERE C1.code_insee < C2.code_insee
""")

# 3 893 couples pour 1 446 noms : certains noms sont portés par plus de deux
# communes, et n communes homonymes fournissent n(n-1)/2 couples.
```

nb_couples
3893

```
db.requete("""
SELECT C1.nom_standard, C1.dep_nom AS departement_1, C2.dep_nom AS departement_2
FROM (communes AS C1 JOIN communes AS C2 ON C1.nom_standard = C2.nom_standard)
```

```
WHERE C1.code_insee < C2.code_insee
ORDER BY C1.nom_standard
LIMIT 20
""")
# L'autojointure de la question 19 au service de la question 15.
# On compare les CLÉS PRIMAIRES et non les dep_code : avec la condition
# C1.dep_code < C2.dep_code, deux homonymes d'un MÊME département
# s'échapperaient (il n'y en a aucun ici, mais la requête serait fausse).
```

nom_standard	departement_1	departement_2
Abancourt	Nord	Oise
Aboncourt	Meurthe-et-Moselle	Moselle
Abzac	Charente	Gironde
Achères	Cher	Yvelines
Aiglun	Alpes-de-Haute-Provence	Alpes-Maritimes
Aigremont	Gard	Haute-Marne
Aigremont	Gard	Yvelines
Aigremont	Gard	Yonne
Aigremont	Haute-Marne	Yvelines
Aigremont	Haute-Marne	Yonne
Aigremont	Yvelines	Yonne
Aigueperse	Puy-de-Dôme	Rhône
Aigues-Vives	Ariège	Aude
Aigues-Vives	Ariège	Gard
Aigues-Vives	Ariège	Hérault
Aigues-Vives	Aude	Gard
Aigues-Vives	Aude	Hérault
Aigues-Vives	Gard	Hérault
Ainvelle	Haute-Saône	Vosges
Alaincourt	Aisne	Haute-Saône

6. Utilisation des données (bonus)

Cette partie ne sera pas traitée en TP. Elle montre ce que l'on fait des résultats d'une requête une fois revenu dans Python : le SQL fait le calcul, matplotlib le donne à voir.

Importation de matplotlib et de la fonction $\log_{10}$

```
import matplotlib.pyplot as plt
from math import log10
```

On écrit les requêtes en langage SQL comme précédemment, mais on utilise la fonction `db.liste` pour récupérer la liste des données demandées (sans le schéma de la table).

Création d'une carte

Question 31 (du SQL au graphique)

1. Récupérer dans une liste nommée `v` la longitude et la latitude du centre de chaque commune de France métropolitaine, ainsi que sa densité (hab/km²).
2. Stocker dans `x` la liste des longitudes, dans `y` celle des latitudes et dans `L_d` les images des densités par $t \mapsto \log_{10}(t + 1)$.

3. À l'aide d'une requête SQL, récupérer dans D la densité maximale des communes de France métropolitaine.

```
V=db.liste("""
SELECT longitude_centre, latitude_centre, population/superficie_km2 FROM communes
WHERE dep_code<'96'
""")
```

```
x = [t[0] for t in V]
y = [t[1] for t in V]
L_d = [log10(t[2]+1) for t in V]
```

```
D=db.liste("""
SELECT MAX(population/superficie_km2) FROM communes
WHERE dep_code<'96'
""")[0][0]

print(D)
```

28137.19008264463

Une fois x, y, L_d et D calculés, exécuter la cellule suivante pour tracer la carte.

```
fig, ax = plt.subplots()

# Tracé
points = ax.scatter(x, y, c=L_d, cmap="YlOrRd", vmin=0, vmax=log10(D+1),
                    marker="s", s=0.75)


# Création de la légende
cbar = fig.colorbar(points, label="Densité (hab/km²)")

# Graduations entières de 0 à la valeur maximale possible
ticks = list(range(0, int(log10(D+1)) + 1))

# Étiquettes en puissances de 10 correspondantes
labels = [f"$10^{{k}}$" for k in ticks]

cbar.set_ticks(ticks)
cbar.set_ticklabels(labels)

ax.set_axis_off()
```



4. Récupérer dans une liste nommée G les centres de gravité démographiques (barycentres des centres des communes, pondérés par leur population) des départements de France métropolitaine (dep_code strictement inférieur à '96' : c'est une chaîne de caractères).

```
G=db.liste("""
SELECT SUM(longitude_centre*population)/SUM(population),
       SUM(latitude_centre*population)/SUM(population)
FROM communes
WHERE dep_code<'96'
GROUP BY dep_code
""")

xG=[t[0] for t in G]
yG=[t[1] for t in G]
```

Une fois G calculée, extraire les longitudes dans xG et les latitudes dans yG, puis exécuter la cellule suivante pour ajouter ces points à la carte.

```
ax.scatter(xG, yG, marker="s", s=0.75, c='k')
fig
```

