

Insertion des données (initial load)

Dans cet exercice, tu vas apprendre à charger des données JSON dans une base MySQL : c'est ce qu'on appelle un **initial load**. Concrètement, nous partirons d'un fichier `films.json` contenant une liste de films (titre, année, acteurs, genres, images, etc.) et nous allons écrire un script Python qui crée les tables nécessaires (**migrations** simples), puis importe les données de manière **idempotente** : c'est-à-dire qu'on pourra **relancer le script plusieurs fois sans créer de doublons**, tout en mettant à jour les infos si elles changent. Cet exercice te permettra de comprendre les étapes clés d'un **pipeline d'import** : créer un schéma relationnel, lire du JSON, insérer avec des contraintes, gérer les relations entre tables et vérifier le résultat avec des requêtes SQL.

6TTR



Vocabulaire



Migration

En informatique (et en particulier avec les bases de données), une **migration** est une opération qui **modifie la structure de la base** afin de l'adapter aux besoins de l'application : **création** de tables, **ajout** de colonnes, ajout de **clés**, modification de types, etc.



Initial Load

Un **initial load** est la toute **première opération de chargement de données** depuis une source (JSON, CSV, API...) vers une base de données ou un système cible. L'objectif est de peupler la base à partir de zéro avec un jeu complet et propre, qui servira ensuite de référence pour les mises à jour ou les ajouts incrémentaux.



Idempotence

Dans ce contexte, l'**idempotence** veut dire que ton script d'import peut être relancé plusieurs fois sans créer de doublons ni abîmer la base.

Exemple concret :

- Si un film est déjà importé (même `external_id`), il ne doit pas être inséré une deuxième fois → il est simplement **mis à jour** si ses infos ont changé.
- Si un acteur ou un genre existe déjà, on le **réutilise** au lieu de créer une nouvelle ligne identique.
- Si une relation film-acteur existe déjà, on ne la recrée pas (ou bien on met à jour le rôle si nécessaire).

👉 Résultat : que tu lances l'import **1 fois ou 10 fois**, la base contient **le même état cohérent**. C'est ça, l'idempotence.

Objectif : écrire **un petit script Python** qui :

1. **crée** les tables MySQL (migrations simples),
2. **importe** le fichier `films.json`,
3. garantit l'**idempotence** (relancer le script ne duplique pas),
4. reste **compréhensible** (premier exercice).

Crée un schéma entités-associations d'abord, ainsi que la conversion en version "physique" pour MySQL (tables, tables de jointure, PK's, FK's...).

Prérequis

- MySQL en local (ou Docker).
- Un utilisateur MySQL avec droits de création : `user/password`.
- Paquet Python :

```
1 | pip install mysql-connector-python
```

- Fichier JSON : `data/films.json` (ton tableau de 25 films).

Schéma minimal (normalisé mais simple)

Nous allons créer 6 tables, mais de manière **guidée** :

- `film(id PK AI, external_id UNIQUE, titre, annee, realisateur, duree_min, resume)`
- `genre(id PK AI, nom UNIQUE)`
- `film_genre(film_id FK, genre_id FK, PK(film_id, genre_id))`

- `acteur(id PK AI, nom UNIQUE)`
- `film_acteur(film_id FK, acteur_id FK, role, PK(film_id, acteur_id))`
- `image(id PK AI, film_id FK, path)`

IDEMPOTENCE :

- `film.external_id` = l' id du JSON (UNIQUE) → on peut faire un *upsert*.
- `genre.nom` et `acteur.nom` sont **UNIQUE** → pas de doublons.

Étape 1 – Script “migrations simples”

But : **créer si n'existe pas** (safe à relancer).

```

1  # migrate.py
2  import mysql.connector as mysql
3
4  DB = dict(host="127.0.0.1", user="root", password="password", database="cinema", auth_plugin='
5
6  DDL = [
7      # Charset/Collation pour bien gérer les accents
8      "CREATE DATABASE IF NOT EXISTS cinema CHARACTER SET utf8mb4 COLLATE utf8mb4_0900_ai_ci;",
9      "USE cinema;",
10     """
11
12     CREATE TABLE IF NOT EXISTS film (
13         id INT PRIMARY KEY AUTO_INCREMENT,
14         external_id INT NOT NULL,
15         titre VARCHAR(255) NOT NULL,
16         annee INT NOT NULL,
17         realisateur VARCHAR(255),
18         duree_min INT,
19         resume TEXT,
20         UNIQUE KEY uq_film_external_id (external_id),
21         INDEX idx_film_titre (titre),
22         INDEX idx_film_annee (annee)
23     ) ENGINE=InnoDB DEFAULT CHARSET=utf8mb4;
24     """,
25     """
26
27     CREATE TABLE IF NOT EXISTS genre (
28         id INT PRIMARY KEY AUTO_INCREMENT,
29         nom VARCHAR(100) NOT NULL,
30         UNIQUE KEY uq_genre_nom (nom)
31     ) ENGINE=InnoDB DEFAULT CHARSET=utf8mb4;
32     """,
33     """
34
35     CREATE TABLE IF NOT EXISTS film_genre (
36         film_id INT NOT NULL,

```

```

29     genre_id INT NOT NULL,
30     PRIMARY KEY (film_id, genre_id),
31     FOREIGN KEY (film_id) REFERENCES film(id) ON DELETE CASCADE,
32     FOREIGN KEY (genre_id) REFERENCES genre(id) ON DELETE CASCADE
33 ) ENGINE=InnoDB DEFAULT CHARSET=utf8mb4;
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54 ]
55
56 def main():
57     conn = mysql.connect(**DB)
58     cur = conn.cursor()
59     for stmt in DDL:
60         cur.execute(stmt)
61     conn.commit()
62     cur.close()
63     conn.close()
64     print("✅ Migrations OK (tables prêtes).")
65
66 if __name__ == "__main__":
67     main()

```

À comprendre

- `CREATE TABLE IF NOT EXISTS` → relancer sans casser.
- Clés **UNIQUE** + **FK** → cohérence + idempotence.

Étape 2 – Import (lecture JSON → insert idempotent)

Stratégie simple :

- Upsert du film via `external_id UNIQUE` (sans dupliquer).
- `get_or_create` pour `genre` et `acteur` (sur leur `nom UNIQUE`).
- Récréer les liaisons (film-genre, film-acteur) **sans dupliquer**.

```
1  # import_films.py
2  import json
3  import mysql.connector as mysql
4
5  DB = dict(host="127.0.0.1", user="root", password="password", database="cinema", auth_plugin='
6
7  def get_conn():
8      return mysql.connect(**DB)
9
10 def get_or_create_genre(cur, nom):
11     # essaie d'insérer, sinon récupère l'id existant
12     cur.execute("INSERT IGNORE INTO genre(nom) VALUES (%s)", (nom,))
13     cur.execute("SELECT id FROM genre WHERE nom=%s", (nom,))
14     return cur.fetchone()[0]
15
16 def get_or_create_acteur(cur, nom):
17     cur.execute("INSERT IGNORE INTO acteur(nom) VALUES (%s)", (nom,))
18     cur.execute("SELECT id FROM acteur WHERE nom=%s", (nom,))
19     return cur.fetchone()[0]
20
21 def upsert_film(cur, f):
22     """
23     Retourne l'id interne du film après upsert.
24     ON DUPLICATE KEY UPDATE garantit l'idempotence.
25     """
26     cur.execute("""
27         INSERT INTO film (external_id, titre, annee, realisateur, duree_min, resume)
28         VALUES (%s, %s, %s, %s, %s, %s)
29         ON DUPLICATE KEY UPDATE
30             titre=VALUES(titre),
31             annee=VALUES(annee),
32             realisateur=VALUES(realisateur),
33             duree_min=VALUES(duree_min),
34             resume=VALUES(resume)
35     """, (f["id"], f["titre"], f["annee"], f.get("realisateur"), f.get("duree_min"), f.get("resume")))
36     # Récupérer l'id interne
37     cur.execute("SELECT id FROM film WHERE external_id=%s", (f["id"],))
38     return cur.fetchone()[0]
39
40 def link_film_genre(cur, film_id, genre_id):
41     # évite les doublons grâce à la PK(film_id, genre_id)
42     cur.execute("""
```

```

38 |         INSERT IGNORE INTO film_genre (film_id, genre_id) VALUES (%s, %s)
    |     """ , (film_id, genre_id))
39 |
40 | def link_film_acteur(cur, film_id, acteur_id, role):
    | cur.execute("""
41 |         INSERT INTO film_acteur (film_id, acteur_id, role)
42 |         VALUES (%s, %s, %s)
43 |         ON DUPLICATE KEY UPDATE role=VALUES(role)
    |     """ , (film_id, acteur_id, role))
44 |
45 | def insert_images(cur, film_id, images):
46 |     # simple: on ajoute; si tu veux l'idempotence stricte, vérifie l'existence du path avant
47 |     for p in images:
48 |         cur.execute("INSERT INTO image (film_id, path) VALUES (%s, %s)", (film_id, p))
49 |
50 | def import_json(path_json):
51 |     with open(path_json, encoding="utf-8") as f:
52 |         films = json.load(f)
53 |
54 |     conn = get_conn()
55 |     cur = conn.cursor()
56 |     try:
57 |         # petite transaction globale (ici dataset modeste)
58 |         conn.start_transaction()
59 |         for f in films:
60 |             # 1) upsert film
61 |             film_id = upsert_film(cur, f)
62 |
63 |             # 2) genres
64 |             for g in f.get("genres", []):
65 |                 gid = get_or_create_genre(cur, g.strip())
66 |                 link_film_genre(cur, film_id, gid)
67 |
68 |             # 3) acteurs
69 |             for a in f.get("acteurs", []):
70 |                 aid = get_or_create_acteur(cur, a["nom"].strip())
71 |                 role = a.get("role")
72 |                 link_film_acteur(cur, film_id, aid, role)
73 |
74 |             # 4) images (option simple : on ne déduplique pas ici)
75 |             insert_images(cur, film_id, f.get("images", []))
76 |
77 |         conn.commit()
78 |         print(f"✅ Import OK ({len(films)} films).")
79 |     except Exception as e:
80 |         conn.rollback()
81 |         print("❌ Erreur, rollback :", e)
82 |     finally:
83 |         cur.close()
84 |         conn.close()
85 |
86 | if __name__ == "__main__":
87 |     import_json("data/films.json")

```

Points pédagogiques clés

- `INSERT IGNORE` + `UNIQUE` → `get_or_create` sans si/else compliqué.
- `ON DUPLICATE KEY UPDATE` → `upsert` propre.
- **Transaction** : si ça casse, `rollback` (rien d'à moitié importé).
- **Idempotence** : relance le script → pas de doublons, les films sont **mis à jour**.

Étape 3 — Vérifications (exemples concrets)

A) Compter les films importés

```
1 | SELECT COUNT(*) FROM film;
```

B) Vérifier un film précis

```
1 | SELECT id, external_id, titre, annee FROM film WHERE external_id=101;
```

C) Genres liés à “Inception”

```
1 | SELECT g.nom
2 | FROM film f
3 | JOIN film_genre fg ON fg.film_id=f.id
4 | JOIN genre g ON g.id=fg.genre_id
5 | WHERE f.external_id=101;
```

D) Acteurs + rôle

```
1 | SELECT a.nom, fa.role
2 | FROM film f
3 | JOIN film_acteur fa ON fa.film_id=f.id
4 | JOIN acteur a ON a.id=fa.acteur_id
5 | WHERE f.external_id=101;
```

E) Images liées

```
1 | SELECT path FROM image i
2 | JOIN film f ON f.id=i.film_id
3 | WHERE f.external_id=101;
```

Bonnes pratiques (version “élève”)

- **Toujours** mettre `utf8mb4` pour gérer accents/emoji.
- Normaliser strings : `strip()`, éviter espaces doubles.
- **Ne jamais** mettre d'URL en dur côté Flask : stocke juste le **path** d'image.
- **Commence petit** : teste d'abord avec 3 films, puis 25.
- Si tu veux que les images soient aussi **idempotentes**, remplace `insert_images` par :

```
1 cur.execute("SELECT 1 FROM image WHERE film_id=%s AND path=%s", (film_id, p))
2 if not cur.fetchone():
3     cur.execute("INSERT INTO image (film_id, path) VALUES (%s, %s)", (film_id, p))
```

Variante “ultra-simplifiée” (si nécessaire)

Pour une première heure de cours : **2 TABLES** seulement.

- `film(id PK AI, external_id UNIQUE, titre, annee, resume)`
- `image(id PK AI, film_id FK, path)`

Idées : ignorer dans un premier temps `genre`, `acteur`, puis **ajouter** ces tables à l'exercice 2 (migration qui étend le schéma, et script d'import qui les remplit).

Ce que tu dois réussir à la fin

- Lancer `python migrate.py` → “✅ Migrations OK”.
- Lancer `python import_films.py` → “✅ Import OK (25 films)”.
- Relancer `python import_films.py` → **aucun doublon**, mais les valeurs mises à jour si tu modifies le JSON.
- Vérifier 2–3 films avec les requêtes SQL de contrôle.

Prochaines étapes (facultatif)

- Ajouter un **mode** `--dry-run` qui affiche les actions sans écrire.
- Écrire des **tests** (pytest) pour `get_or_create_*`.
- Ajouter des **indexes** selon les recherches que tu feras dans Flask (`WHERE annee=...` , `LIKE titre`).

Si tu veux, je te fournis une **version monofichier** qui fait *migrations + import* en un seul `python app.py` (avec un petit menu texte).