

# Approches sémantiques pour l'exploration d'un lac de donnée

Projet M2 DataScale  
Encadré par : Zoubida Kedad

Novembre 2025

1

1

## Contexte : les lacs de données

### Data Warehouse

Vs.

### Data Lake



Nombre limité de sources de données.  
Stockage après traitement  
Moins flexible  
Moins évolutif (coûteux)




- ✓ Grands volumes de données hétérogènes, brutes
  - ✓ Stockage direct
  - ✓ Plus flexible
  - ✓ Très évolutif
- MAIS :**
- ✗ Absence de schéma.
  - ✗ Métadonnées peu fiables, incohérentes et incomplètes.

2

2

## Exploration d'un lac de données

Problème : retrouver les données pertinentes pour une tâche d'analyse spécifique.




**Comment faciliter l'exploration et la recherche des données ?**

3

3

## Recherche de tables pertinentes

Problème : étant données une table requête T soumise par l'utilisateur, comment retrouver les tables du lac de données qui peuvent être combinées par jointure ou par union avec T ?



4

## Recherche de tables pertinentes

### Principe :

- Générer des annotations pour chaque table du lac de données.
- Lorsque l'utilisateur soumet une table requête, cette dernière est annotée également.
- La recherche des tables est faite en comparant les annotation de la table requête et les annotations des tables du lac de données.


### Le projet se focalise sur deux tâches (décrisées dans les 2 slides suivants) :

1. Annotation de tables : concevoir et implémenter une approche qui génère un graphe d'annotation pour une table, en utilisant des modèles de langages et des bases de connaissances en ligne.
2. Recherche de tables : définir et implémenter un processus de recherche qui retrouve des tables pertinentes à partir d'une table requête en comparant leurs graphes d'annotation.

5

## Tâche 1 : Annotation des tables d'un lac de données.

Proposer une approche d'annotation hybride qui combine l'utilisation de modèles de langages et de bases de connaissances.




- Fine-tuner des modèles de langages sur la tâche de découverte de types et de relations :
  - en testant différents LMs
  - avec différentes façons de serialiser les tables

6

## Tâche 2 : Recherche de tables dans un lac de données

- Rechercher des tables qui peuvent compléter une table requête par union (ajout de tuples) ou par jointure (ajout de colonnes), en définissant un processus de matching de graphes d'annotation.



7

## Travail à réaliser

- Etude de 2 ou 3 approches d'annotation et de recherche dans des lacs de données.
- Définir et implémenter des approches d'annotation et de recherche.
- Evaluation des approches en utilisant un benchmark existant.
- Référence bibliographique Doduo : <https://arxiv.org/pdf/2104.01785>

8