

Tirer parti de la structure des données incertaines

Antoine Amarilli

21 avril 2017

Les quatre 'V' des données massives

Volume : données très grandes

Variété : données dans des formats différents

Vélocité : données modifiées à grande vitesse

Véracité : données incertaines, imprécises, erronées

Les quatre 'V' des données massives

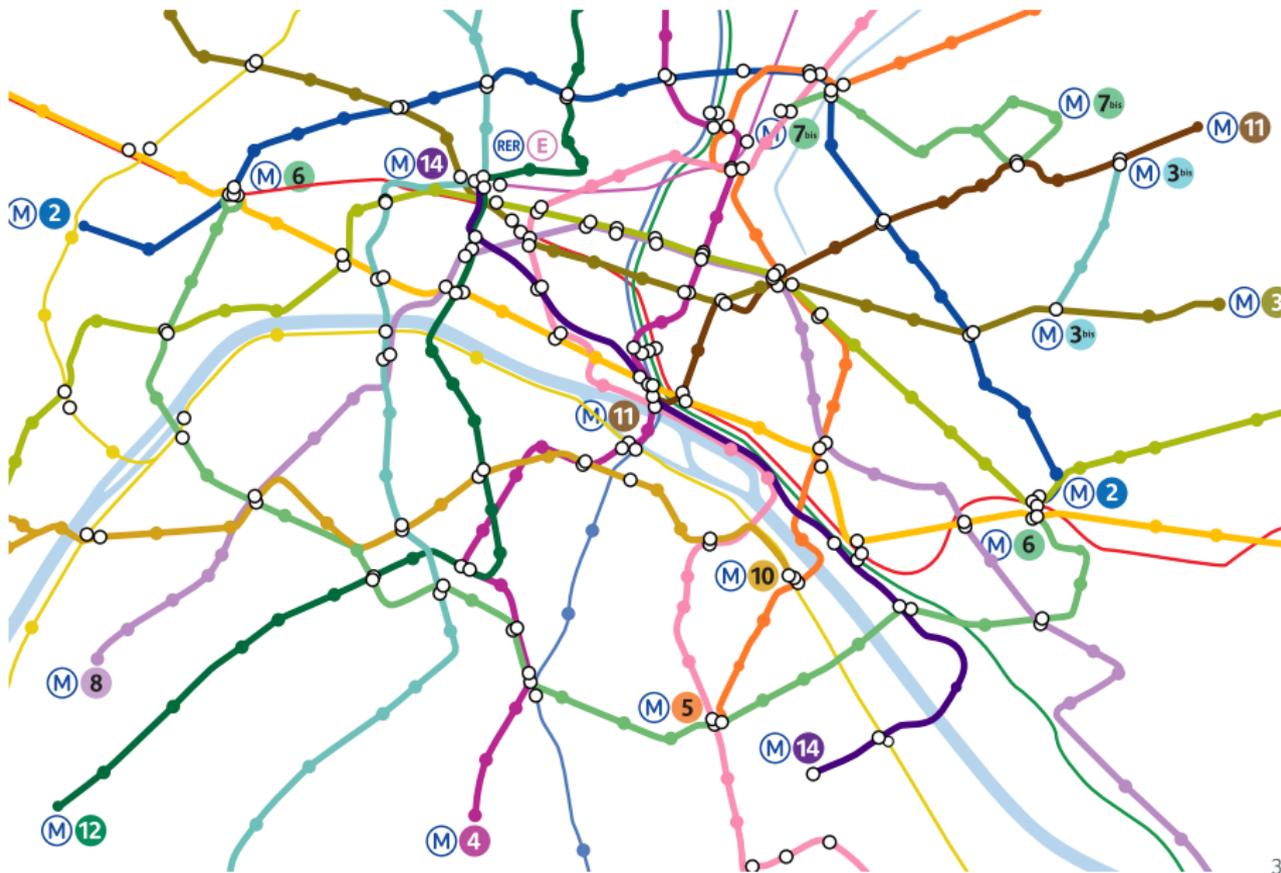
Volume : données très grandes

Variété : données dans des formats différents

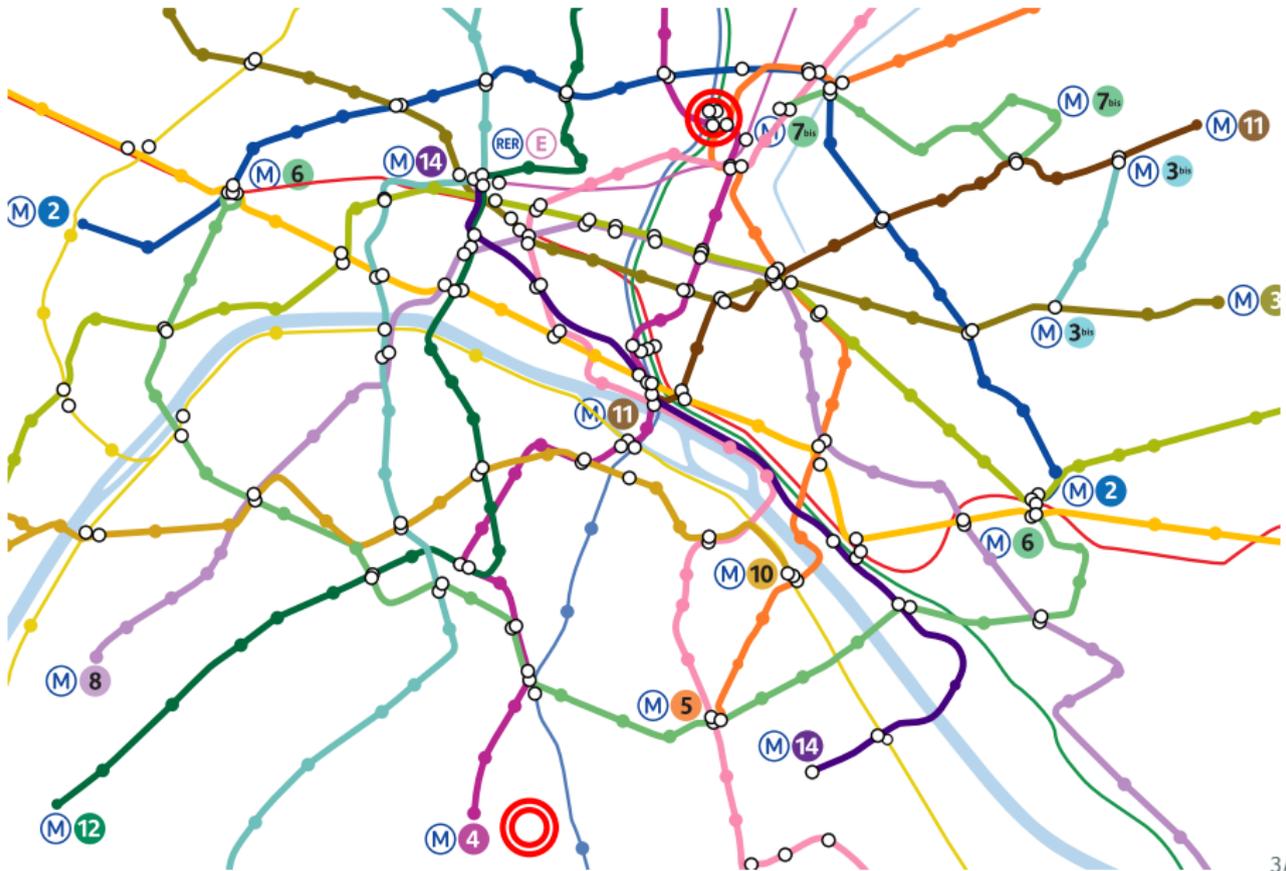
Vélocité : données modifiées à grande vitesse

⇒ **Véracité** : données incertaines, imprécises, erronées ⇐

Exemple : calcul de trajets en métro



Exemple : calcul de trajets en métro



Exemple : calcul de trajets en métro

Rechercher mon itinéraire

De Rue Monticelli  

A Gare du Nord

Aujourd'hui 

Arrivée à  21 h  05 



Requête
utilisateur

Exemple : calcul de trajets en métro

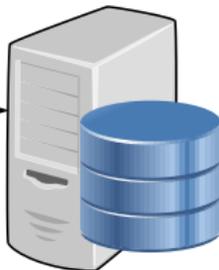
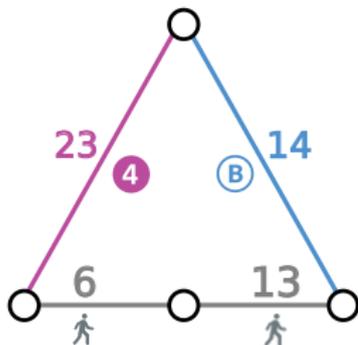
Rechercher mon itinéraire

De

A

Aujourd'hui

Arrivée à



Requête
utilisateur

Base de
données

Exemple : calcul de trajets en métro

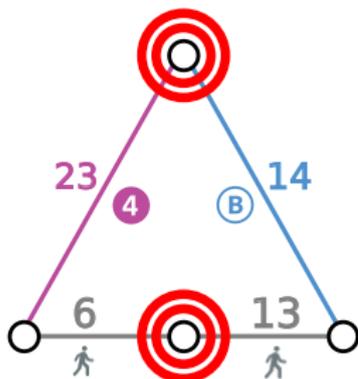
Rechercher mon itinéraire

De

A

Aujourd'hui

Arrivée à



Requête
utilisateur

Base de
données

Exemple : calcul de trajets en métro

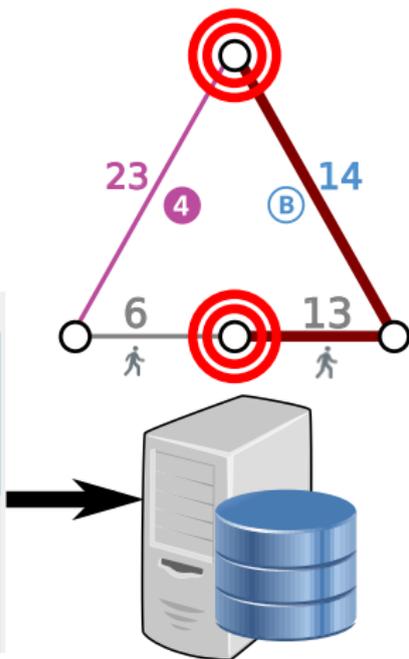
Rechercher mon itinéraire

De

A

Aujourd'hui

Arrivée à



Requête
utilisateur

Base de
données

Exemple : calcul de trajets en métro

Rechercher mon itinéraire

De

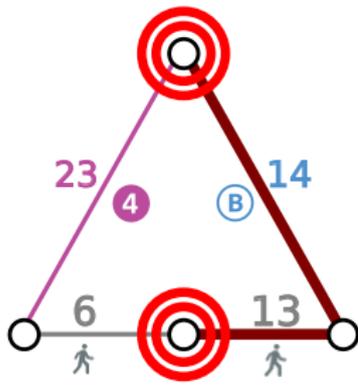
A

Aujourd'hui

Arrivée à



Requête
utilisateur



Base de
données

Départ
20h17 - 5 rue Monticelli, Paris

1.1 km | 13 min

20h30 - CITE UNIVERSITAIRE, Paris

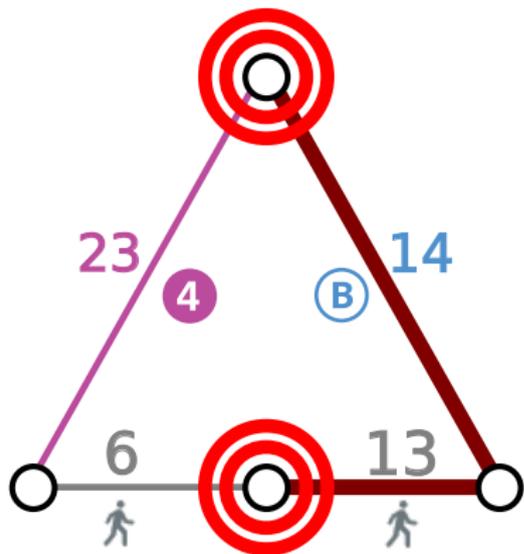
RER B - EPAU
Vers Aéroport CDG Terminal 2 TGV

6 arrêts | 14 min

Arrivée
20h44 - GARE DU NORD RER, Paris

Résultat

Exemple : calcul de trajets en métro



📍 Départ
20h17 - 5 rue Monticelli, Paris

1.1 km | 13 min

🚇 20h30 - CITE UNIVERSITAIRE, Paris

RER B - EPAU
Vers **Aéroport CDG Terminal 2 TGV**

6 arrêts | 14 min

🕒 Arrivée
20h44 - GARE DU NORD RER, Paris

Panne du RER B : trafic interrompu entre Paris et Roissy, des TGV en renfort

🏠 > Transports | 06 décembre 2016, 9h56 | MAJ : 06 décembre 2016, 17h03 | [f](#) [t](#) [m](#)



Panne du RER B : trafic interrompu entre

Paris : pourquoi il y a autant de perturbations sur le RER B et à Gare du Nord

La circulation de l'ensemble des trains au départ de gare du Nord est totalement interrompue à la suite d'une panne électrique.



Panne du RER B : trafic interrompu entre

Paris : pourquoi il y a autant de perturbations sur le RER B...

INCIDENT SUR LE RER B : QUE S'EST-IL PASSÉ CE MATIN ?

Malaise voyageur et application des mesures de sécurité : pour quelles raisons le trafic a-t-il été perturbé ce matin sur la ligne B ?

Pour beaucoup, le voyage a été difficile ce matin. Au fil de vos réactions sur Twitter notamment, je constate que les raisons de ces perturbations ne paraissent pas cohérentes. Je tiens donc à vous apporter des premiers éléments d'explication que nous pourrions développer

Exemple : calcul de trajets en métro

Panne du RER B : trafic interrompu entre

Paris : pourquoi il y a autant de perturbations sur
le RER B à Paris
INCIDENT SUR LE RER B · OUI

ACTUALITÉS

Le RER B en panne, les voyageurs n'ont pas eu d'autre choix que de descendre sur les voies

Alors que la circulation alternée a augmenté le nombre de voyageurs dans les transports en commun, le RER B s'est retrouvé à l'arrêt.

© 06/12/2016 11:57 CET | Actualisé 06/12/2016 20:14 CET



Pour beaucoup, le voyage a été difficile ce matin. Au fil de vos réactions sur Twitter notamment, je constate que les raisons de ces perturbations ne paraissent pas cohérentes. Je tiens donc à vous apporter des premiers éléments d'explication que nous pourrions développer

Exemple : calcul de trajets en métro

Panne du RER B : trafic interrompu entre

Paris : pourquoi il y a autant de perturbations sur
le RER B et D en panne, gare du Nord paralysée,
pollution: deuxième jour de galère

INCIDENT SUR LE RER B · OUIF

ACTUALITÉS

Le RER B en panne, les voyageurs n'ont pas eu

le choix que de descendre sur les voies
RER B et D en panne, gare du Nord paralysée,
pollution: deuxième jour de galère

Actualité / Société / Trafic / Par Iris Péron, publié le 07/12/2016 à 13:40 , mis à jour à 16:07

partages

f Partager

Twitter Tweeter

g+ Partager

✉

réaction

de vos réactions sur Twitter notamment, je constate
que les raisons de ces perturbations ne paraissent pas
cohérentes. Je tiens donc à vous apporter des premiers
éléments d'explication, que nous pourrions développer

Exemple : calcul de trajets en métro

Panne du RER B : trafic interrompu entre

Paris : pourquoi il y a autant de perturbations sur le RER B à l'heure de pointe

INCIDENT SUR LE RER B · OUIF

ACTUALITÉS

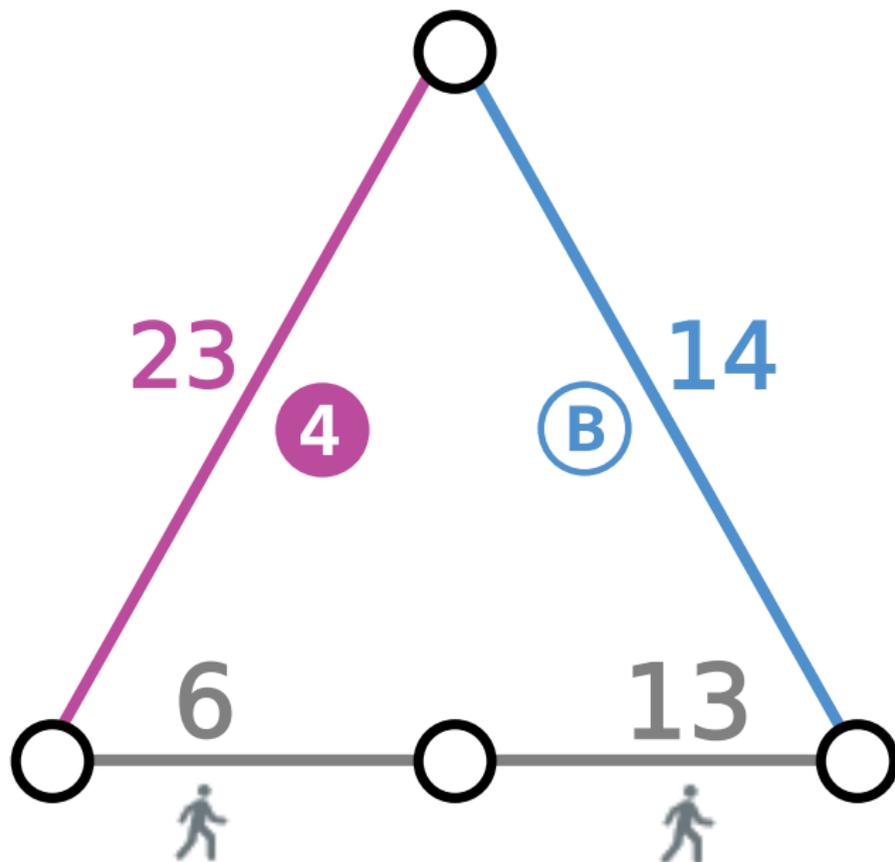
Le RER B en panne, les voyageurs n'ont pas eu

Ile-de-France : le trafic toujours interrompu sur le RER B entre Aulnay-sous-Bois et Roissy

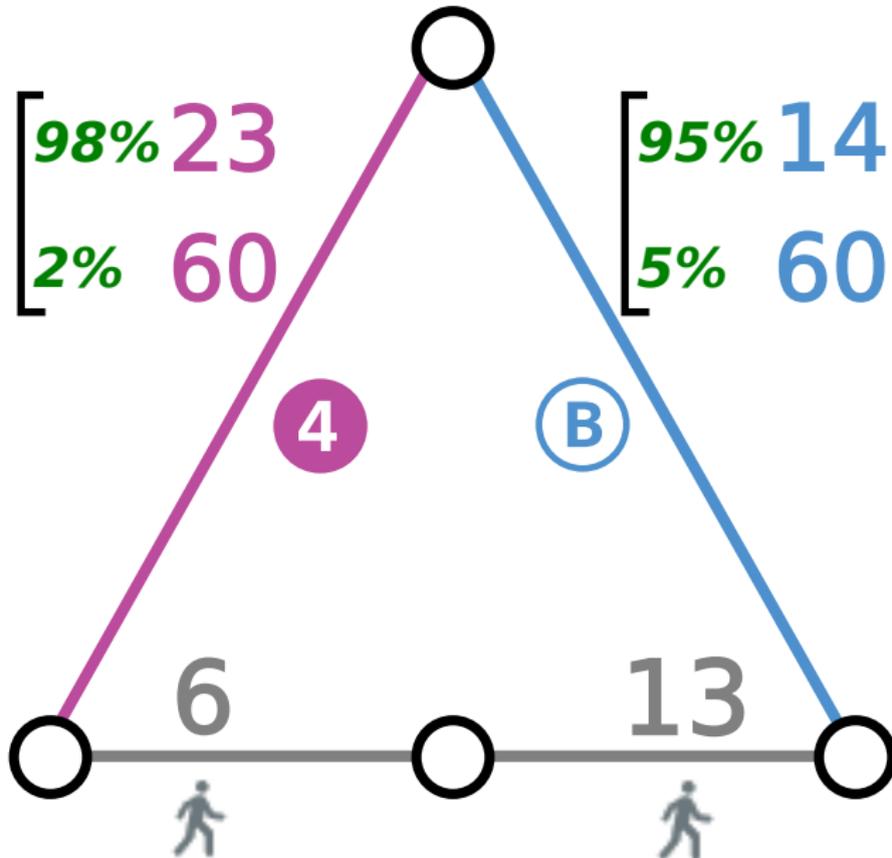
La circulation est arrêtée depuis mardi matin en raison d'une panne de caténaire. Le retour à la normale a été plusieurs fois retardé mais devrait avoir lieu mercredi vers 16 heures, selon la SNCF.

Le Monde | 07 12 2016 à 10h48 • Mis à jour le 07 12 2016 à 16h09

Exemple : calcul de trajets en métro



Exemple : calcul de trajets en métro



Exemple : calcul de trajets en métro

Rechercher mon itinéraire

De

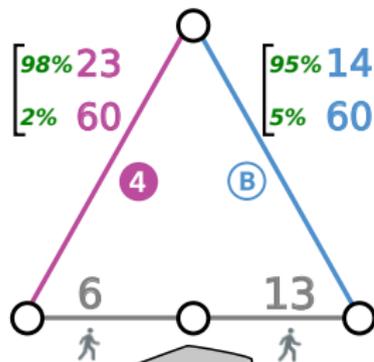
A

Aujourd'hui

Arrivée à



Requête
utilisateur



Base de
données
probabiliste

Exemple : calcul de trajets en métro

Rechercher mon itinéraire

De

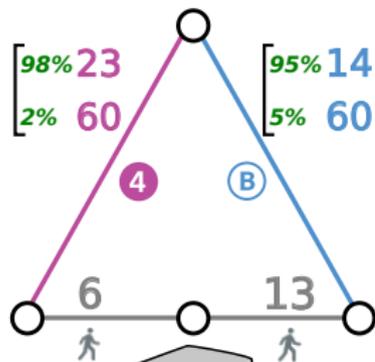
A

Aujourd'hui

Arrivée à



Requête
utilisateur



Base de
données
probabiliste

**98% de chances
d'être à l'heure**

Départ
20h14 - 5 rue Monticelli, Paris

425 m | 6 min

20h20 - Porte d'Orléans (Général Leclerc), Paris

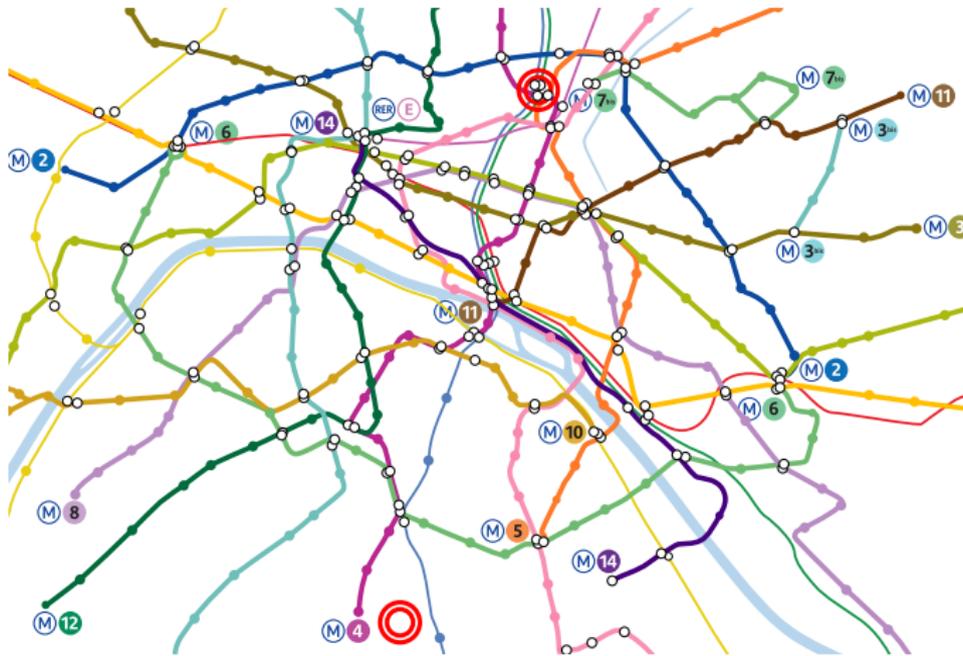
Métro 4
Vers Porte de Clignancourt

20 arrêts | 23 min

Arrivée
20h43 - Gare du Nord, Paris

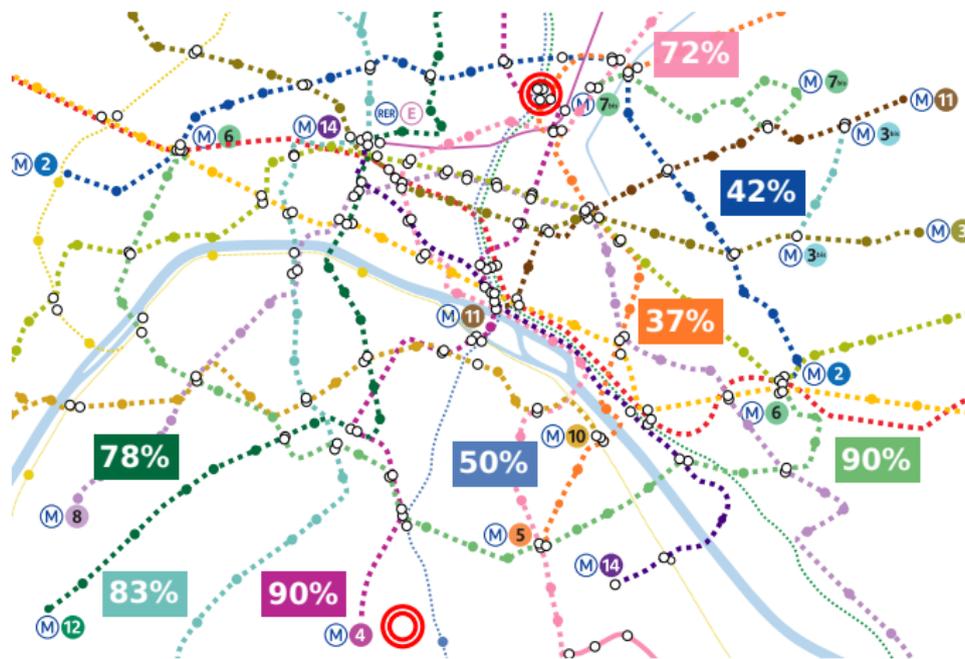
Résultat
probabiliste

Problème : difficultés de calcul



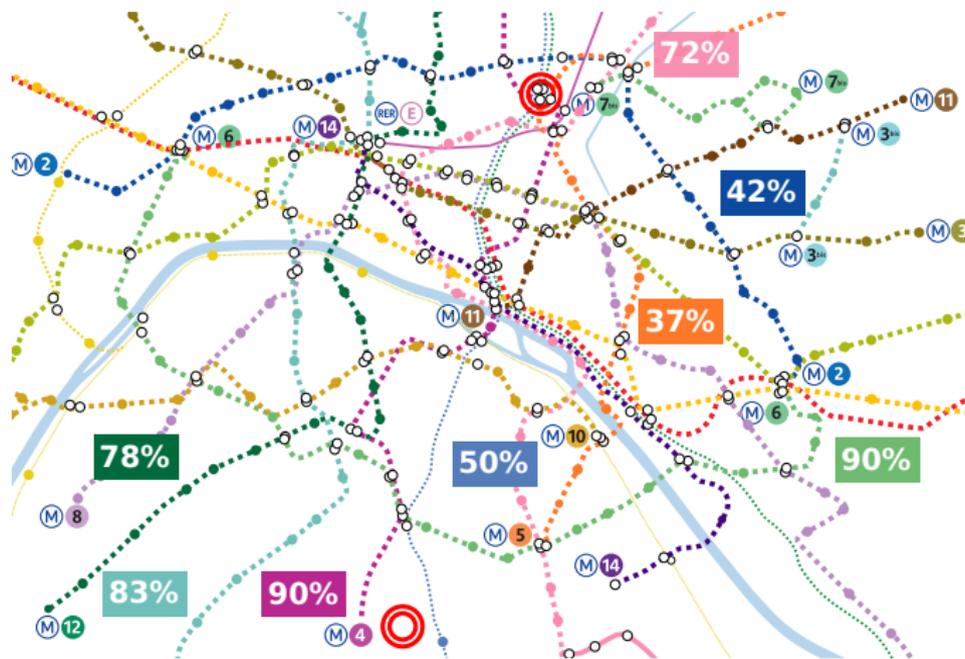
- Plus court chemin sur un grand graphe :
 - Algorithmes existants, problème bien étudié

Problème : difficultés de calcul



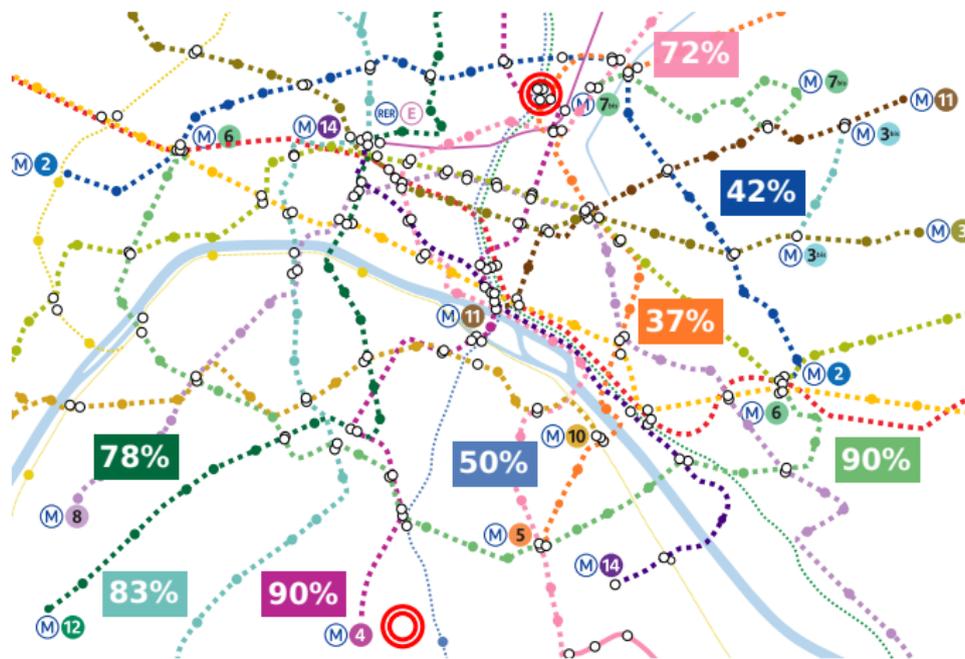
- Plus court chemin sur un grand graphe **probabiliste** :
→ ???

Problème : difficultés de calcul



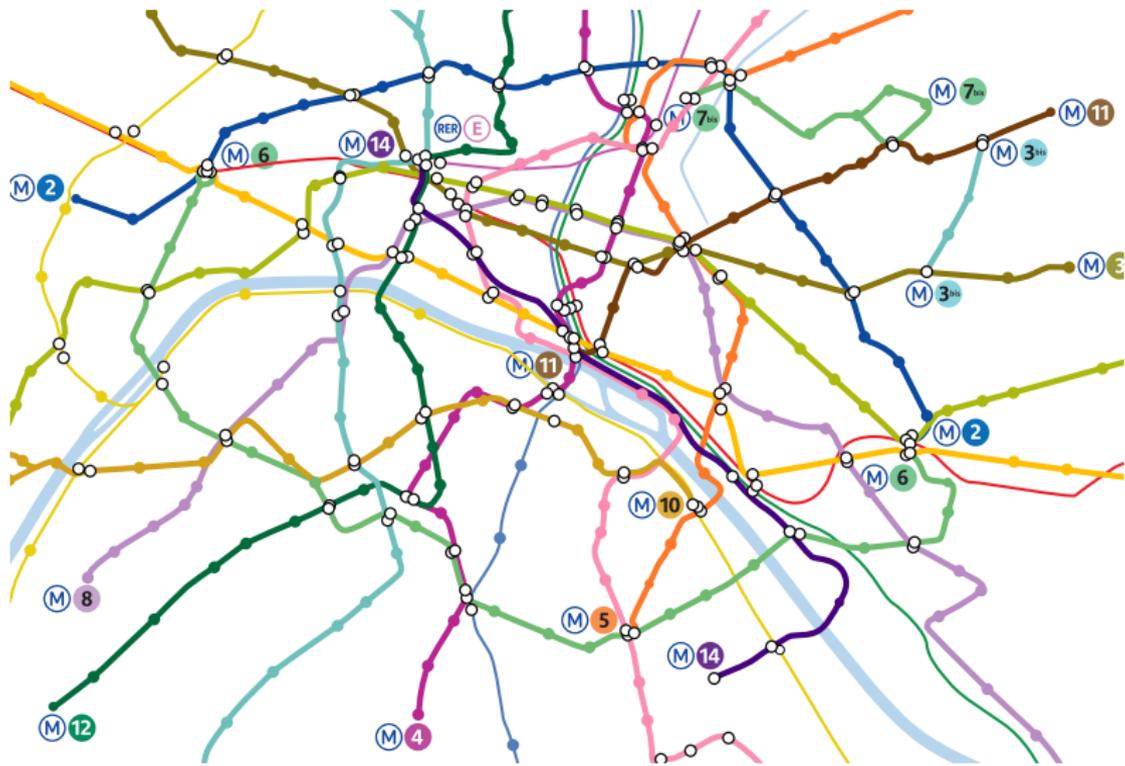
- Plus court chemin sur un grand graphe **probabiliste** :
→ Énumérer toutes les possibilités : **exponentiel**

Problème : difficultés de calcul

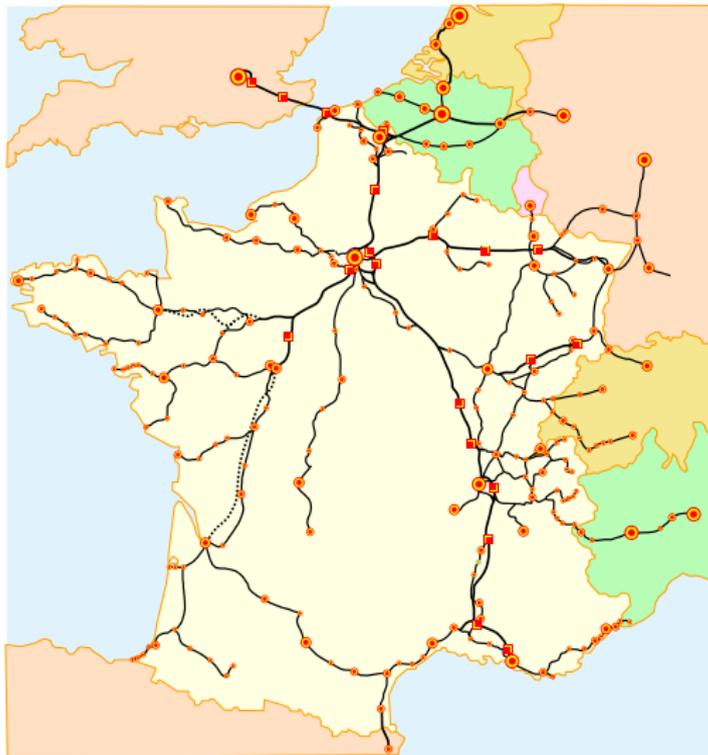


- Plus court chemin sur un grand graphe **probabiliste** :
 - Énumérer toutes les possibilités : **exponentiel**
 - **Théorie** : on ne peut pas espérer faire **mieux** en général!

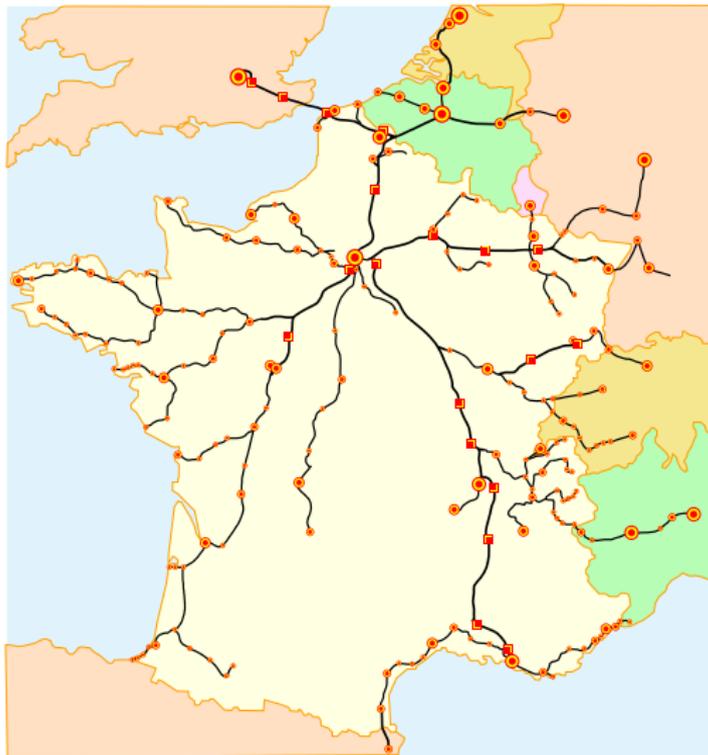
Idée : utiliser la structure des données



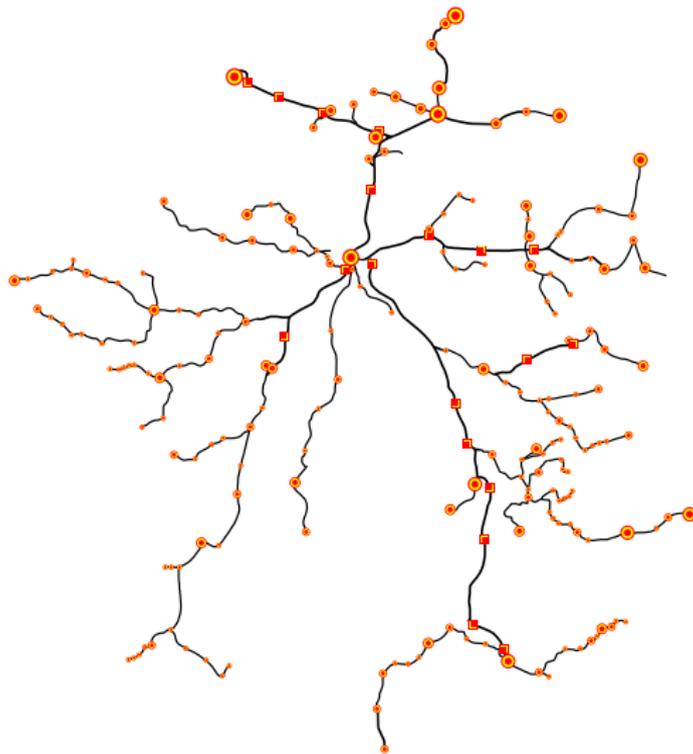
Idée : utiliser la structure des données



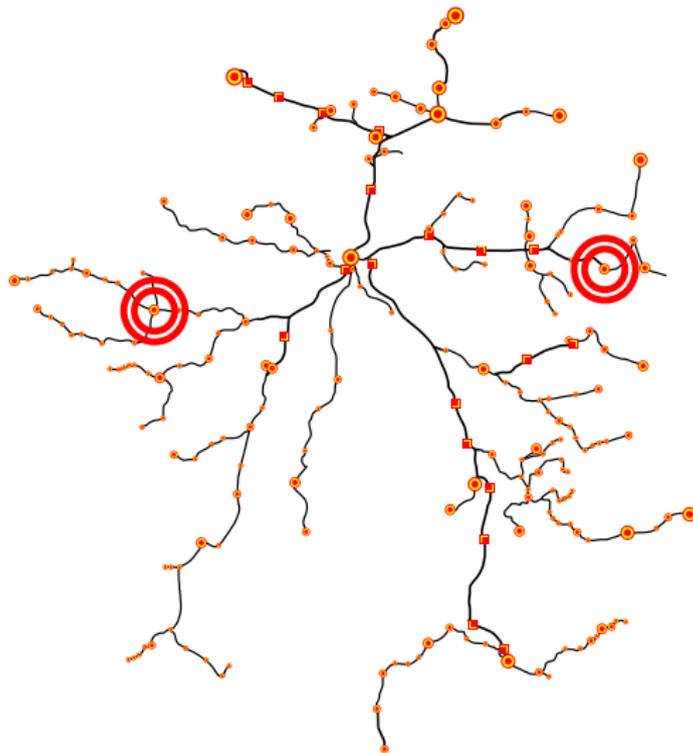
Idée : utiliser la structure des données



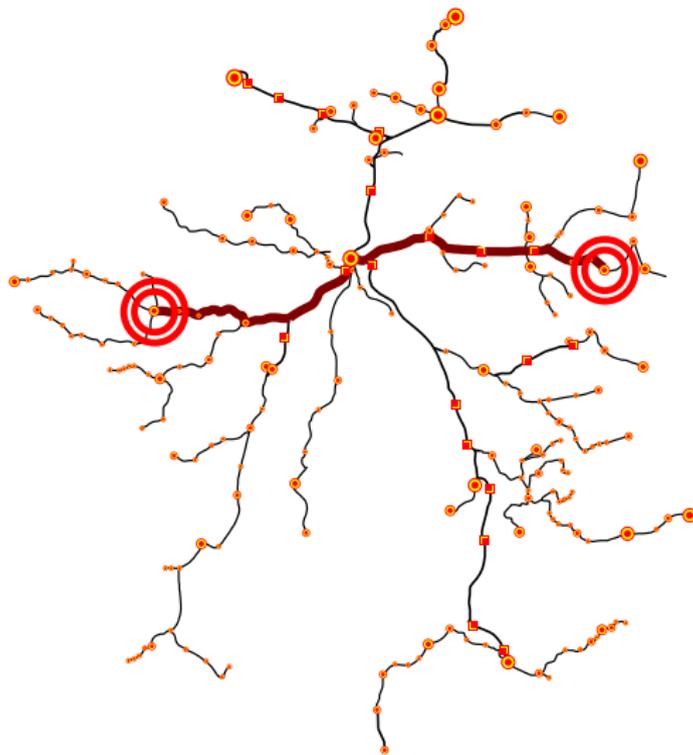
Idée : utiliser la structure des données



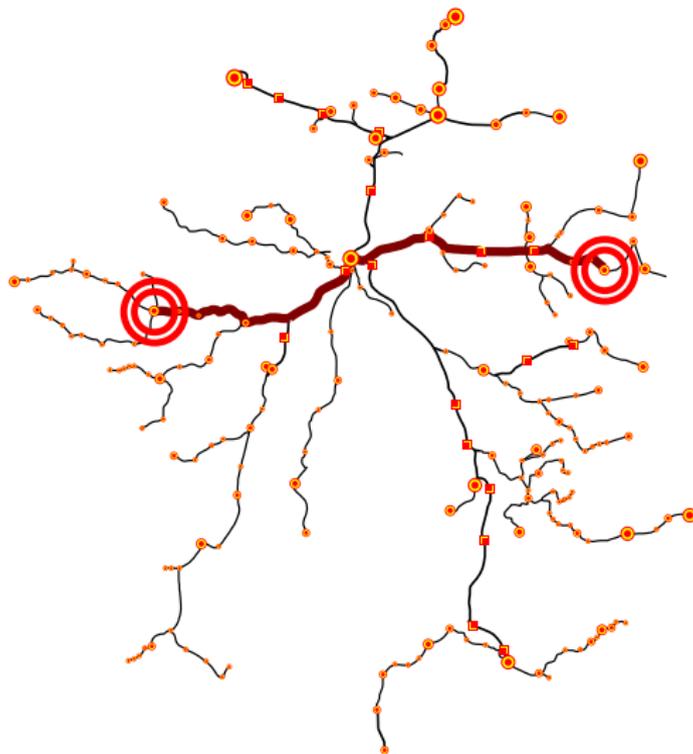
Idée : utiliser la structure des données



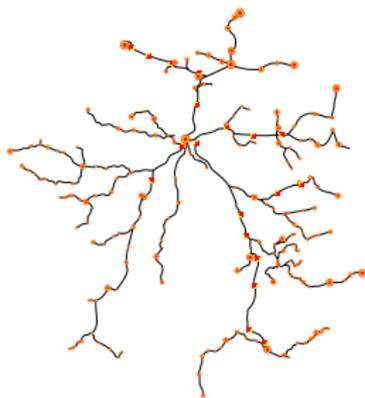
Idée : utiliser la structure des données



Idée : utiliser la structure des données

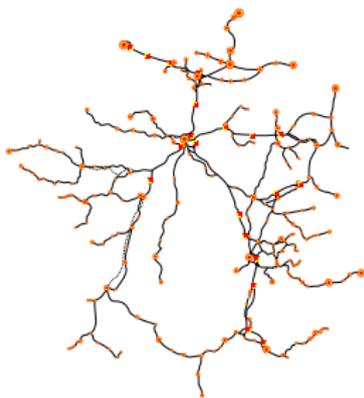


→ Plus court chemin : très facile sur un grand arbre



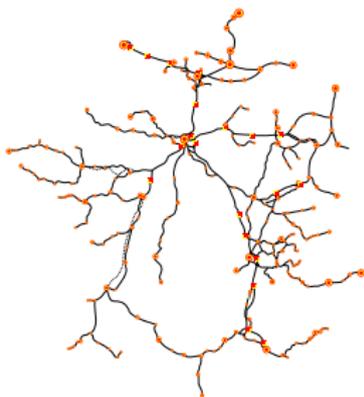
→ **Théorème** : évaluer des requêtes expressives est facile sur de grands arbres probabilistes

Résultats de ma thèse



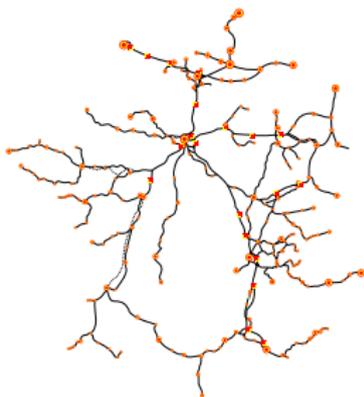
- **Théorème** : évaluer des requêtes expressives est facile sur de grands arbres probabilistes
- S'étend aux **quasi-arbres** (en un sens formel)

Résultats de ma thèse



- **Théorème** : évaluer des requêtes expressives est facile sur de grands arbres probabilistes
- S'étend aux **quasi-arbres** (en un sens formel)
- **Borne inférieure** : on ne peut pas faire mieux (#P-difficile sans borne sur la largeur d'arbre)

Résultats de ma thèse



- **Théorème** : évaluer des requêtes expressives est facile sur de grands arbres probabilistes
- S'étend aux **quasi-arbres** (en un sens formel)
- **Borne inférieure** : on ne peut pas faire mieux (#P-difficile sans borne sur la largeur d'arbre)

Caractérise les conditions sur la structure des données probabilistes qui permettent de les interroger **efficacement**
(avec P. Bourhis, P. Senellart — ICALP'15, PODS'16)

→ Autres applications :

- **Explication** de résultats de requêtes par la **provenance**
- **Énumération** efficace de résultats de requêtes (ICALP'17)
- Étude plus **fine** de la complexité (ICDT'17, PODS'17)

→ Autres applications :

- **Explication** de résultats de requêtes par la **provenance**
- **Énumération** efficace de résultats de requêtes (ICALP'17)
- Étude plus **fine** de la complexité (ICDT'17, PODS'17)

→ Autres aspects de l'incertitude étudiés :

- Sur le **raisonnement sur données incomplètes**
(avec M. Benedikt, Oxford — IJCAI'15, LICS'15, IJCAI'16)
- Sur l'**incertitude numérique** sur les données de la foule
(avec Y. Amsterdamer, T. Milo, Tel Aviv — ICDT'14, ICDT'17)

→ Autres applications :

- **Explication** de résultats de requêtes par la **provenance**
- **Énumération** efficace de résultats de requêtes (ICALP'17)
- Étude plus **fine** de la complexité (ICDT'17, PODS'17)

→ Autres aspects de l'incertitude étudiés :

- Sur le **raisonnement sur données incomplètes**
(avec M. Benedikt, Oxford — IJCAI'15, LICS'15, IJCAI'16)
- Sur l'**incertitude numérique** sur les données de la foule
(avec Y. Amsterdamer, T. Milo, Tel Aviv — ICDT'14, ICDT'17)

Merci pour votre attention !

Références I

-  Amarilli, A., Amsterdamer, Y., and Milo, T. (2014).
On the Complexity of Mining Itemsets from the Crowd Using Taxonomies.
In *ICDT*.
-  Amarilli, A., Amsterdamer, Y., Milo, T., and Senellart, P. (2017a).
Top-k Queries on Unknown Values under Order Constraints.
In *ICDT*.
-  Amarilli, A. and Benedikt, M. (2015a).
Combining Existential Rules and Description Logics.
In *IJCAI*.
-  Amarilli, A. and Benedikt, M. (2015b).
Finite Open-World Query Answering with Number Restrictions.
In *LICS*.

Références II

-  Amarilli, A., Benedikt, M., Bourhis, P., and Boom, M. V. (2016a).
Query Answering with Transitive and Linear-Ordered Data.
In *IJCAI*.
-  Amarilli, A., Bourhis, P., Jachiet, L., and Mengel, S. (2017b).
A Circuit-Based Approach to Efficient Enumeration.
In *ICALP*.
-  Amarilli, A., Bourhis, P., Monet, M., and Senellart, P. (2017c).
Combined Tractability of Query Evaluation via Tree Automata and Cycluits.
In *ICDT*.
-  Amarilli, A., Bourhis, P., and Senellart, P. (2015).
Provenance Circuits for Trees and Treelike Instances.
In *ICALP*.

Références III



Amarilli, A., Bourhis, P., and Senellart, P. (2016b).

Tractable Lineages on Treelike Instances: Limits and Extensions.

In *PODS*.



Amarilli, A., Monet, M., and Senellart, P. (2017d).

Conjunctive Queries on Probabilistic Graphs: Combined Complexity.

In *PODS*.

Crédits photographiques

- Transparent 3 :
 - plan du métro : https://commons.wikimedia.org/wiki/File:Paris_Metro_map.svg (édité), utilisateur Umx sur Wikimedia Commons, domaine public
 - captures d'écran de <http://lab.vianavigo.com>, Stif, reproduites en vertu du droit de citation
 - icônes tirées de <https://openclipart.org/download/163711/database-server.svg> et <http://4vector.com/free-vector/female-user-icon-clip-art-117435>
 - articles de journaux reproduits en vertu du droit de citation :
 - <http://www.leparisien.fr/transports/circulation-alternee-a-paris-et-en-banlieue-une-panne-de-rer-et-des-bouchons-06-12-2016-6419610.php>
 - <http://www.rtl.fr/actu/societe-faits-divers/paris-le-traffic-totalement-interrompu-gare-du-nord-7786171150>
 - <https://www.rerb-leblog.fr/incident-rer-b-sest-passe-matin/>
 - <http://www.huffingtonpost.fr/2016/12/06/le-rer-b-en-panne-les-voyageurs-nont-pas-eu-dautres-choix-que/>
 - http://www.lexpress.fr/actualite/societe/trafic/rer-b-en-panne-retards-du-d-circulation-alternee-deuxieme-journee-de-galere_1857905.html
 - http://www.lemonde.fr/entreprises/article/2016/12/07/ile-de-france-le-traffic-toujours-interrompu-sur-le-rer-b-en-direction-de-roissy_5044717_1656994.html
- Transparent 5 : https://commons.wikimedia.org/wiki/File:Carte_TGV.svg?uselang=fr (édité), utilisateurs Jack ma, Muselaar, Benjism89, Pic-Sou, Uwe Dederling, Madcap sur Wikimedia Commons, sous licence CC-BY-SA 3.0