

Inria

Intégration de données hétérogènes et detection de liens/conflits d'intérêt Système ConnectionLens



Ioana Manolescu

CEDAR team

Inria Saclay-Île-de-France, Institut Polytechnique de Paris

@ioanamanol @cedarinrialix



Plan

- ❑ **Notre domaine** : la gestion de données
- ❑ **Projet de recherche** (2018--) : intégration de données très hétérogènes sans schéma préétabli, notamment pour le journalisme
- ❑ **Application** : conflits d'intérêt dans le domaine biomédical
- ❑ **Démo** : **ConnectionStudio** sur des données HATVP

Plus d'informations:

<https://connectionstudio.inria.fr>

<https://teams.inria.fr/cedar>

La gestion des données: de l'art à l'industrie

Tout code informatique manipule des données

- Entrées, sorties, structures auxiliaires

Les données sont **volumineuses, importantes** →

Code dédié à la gestion des données (créer / modifier / trouver / effacer)

- Un code pour pour les données sur les contribuables...
- Un code pour les données sur les étudiants / cours / propriétés immobilières etc.
→ Effort multiplié pour écrire, maintenir, améliorer ces codes

Problème résolu depuis 1970: les **systèmes de gestion des bases de données !**

La gestion des données: de l'art à l'industrie

Les **systemes** (logiciels) de **gestion des bases de données (SGBD)**:

- **Encapsulent des fonctionnalités** nécessaires pour la gestion efficace des données
- Fournissent aux utilisateurs des **interfaces simples** pour mettre en oeuvre de **multiples applications** de gestion de données **sans jamais devoir coder**.
 - 1 SGBD, N applications: 1. contribuables; 2. étudiants; 3. propriétés immobilières...

SGBDs omniprésents dans toute société moderne: comptes bancaires, paiements CB, badges d'accès, toute réservation de billet, système de santé, impôts, etc. Industrie de MD\$/an

Exige que les données soient relationnelles (dans des tableaux, qui peuvent se référencer)

Fausses nouvelles et leur propagation sur Twitter (1)

Vérifications (fact-checks) mises en ligne: des documents (non pas tableaux) contenant

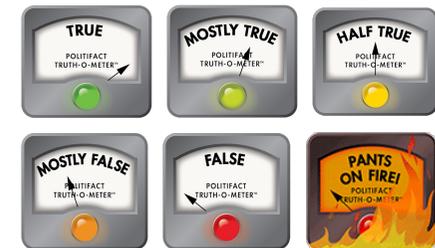
- Lien vers une affirmation (media, réseau social etc.), auteur
- Analyse, conclusion, auteur, date, institution

Parmi les premiers corpus de vérifications publiés:

<https://www.lemonde.fr/web-service/decodex/updates>

Puis **ClaimReview** (format structuré), par Google

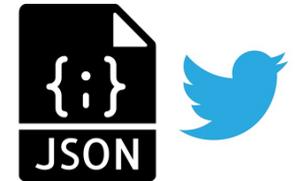
<https://www.claimreviewproject.com/>



Fausses nouvelles et leur propagation sur Twitter (2)

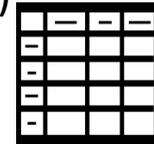
Vérifications (fact-checks) mises en ligne: des documents (non pas tableaux)

- Lien vers une affirmation (media, réseau social etc.), auteur
- Analyse, conclusion, auteur, date, institution



Base des Décodeurs (Excel): figures publiques (Parlement, Gouvernement, etc.)

- Nom, prénom, ID twitter, poste, parti

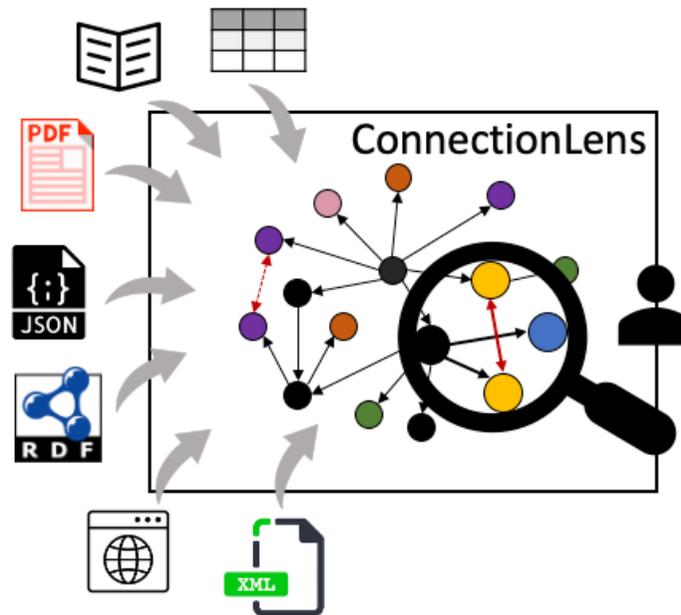


Question: Quand est-ce qu'une fausse info est propagée la première fois dans une certaine communauté (p.ex., Parlement)?

- Trouver des tweets connectés à un auteur de faux, et à une personnalité politique
- Toute structure possible pour les deux connections: écrit/rediffuse/aime/suit...

ConnectionLens: intégration de sources de données hétérogènes dans des graphes (réseaux) de données

<https://team.inria.fr/cedar/connectionlens/>

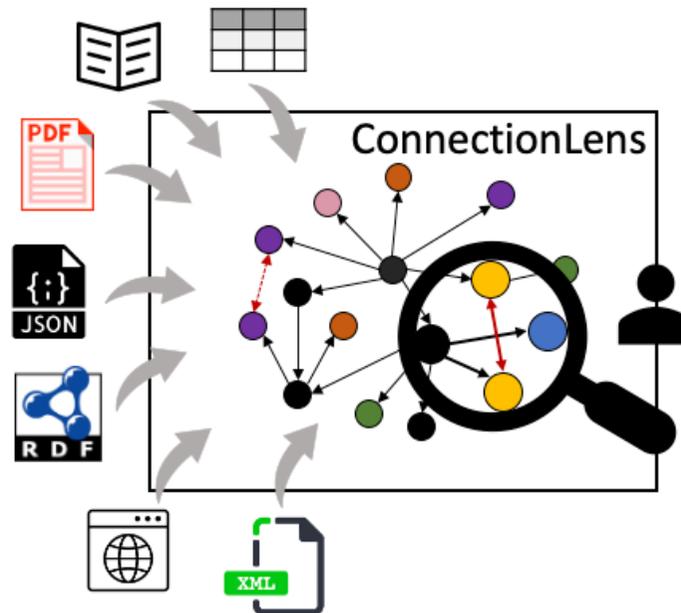


ConnectionLens: intégration de sources de données hétérogènes dans des graphes (réseaux) de données

<https://team.inria.fr/cedar/connectionlens/>

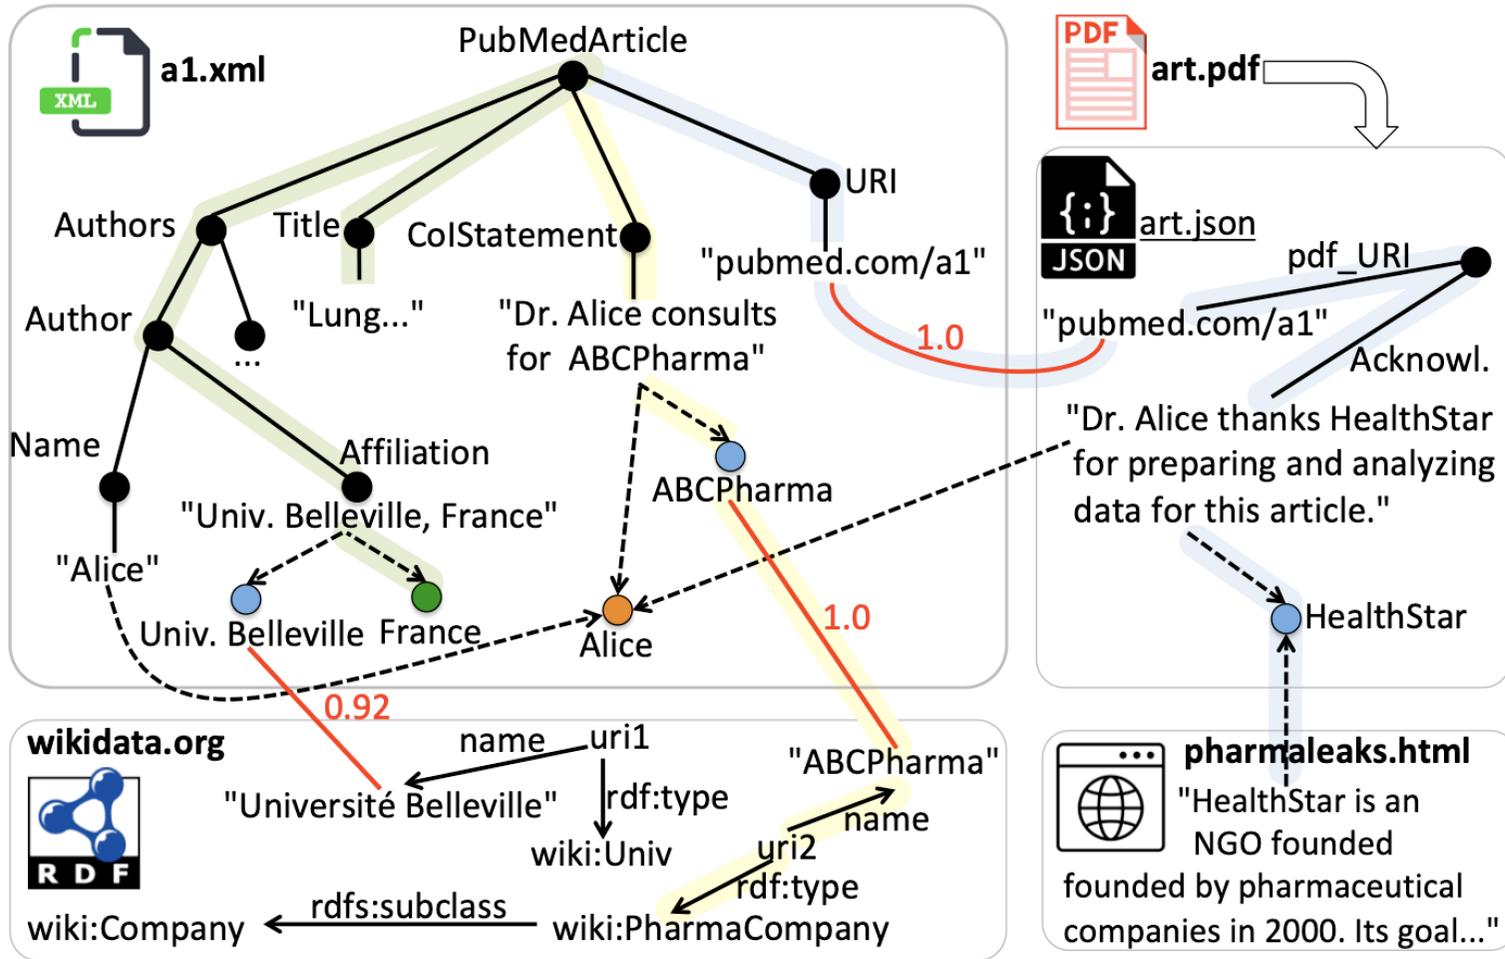
Données :

- Pages Web
- Documents (PDF, Office, ...)
- Données (CSV, RDF, JSON, XML...) notamment Open Data, réseaux sociaux
- Bases de données structurées...



Enrichies avec:

- Des **entités nommées** extraites automatiquement depuis les données, à l'aide de modèles entraînés (IA)
- Personnes, lieux, organisations, emails, hashtags, dates...
- Liens** entre des entités qui sont probablement les mêmes malgré des différentes notations



Questions / démono

ConnectionLens: <https://team.inria.fr/cedar/connectionlens/>

ConnectionStudio: <https://connectionstudio.inria.fr>

CEDAR team: <https://teams.inria.fr/cedar>