CASIMIR : un Corpus d'Articles Scientifiques Intégrant les ModIfications et Révisions des auteurs

Léane Jourdan, Florian Boudin, Richard Dufour, Nicolas Hernandez
{prénom.nom}@univ-nantes.fr

Objectifs

- Nouveau corpus d'articles scientifiques avec révisions
- Un alignement des modifications entre les versions des articles
- Enrichit avec les métadonnées des articles et les relectures par les pairs

Exemple de révisions

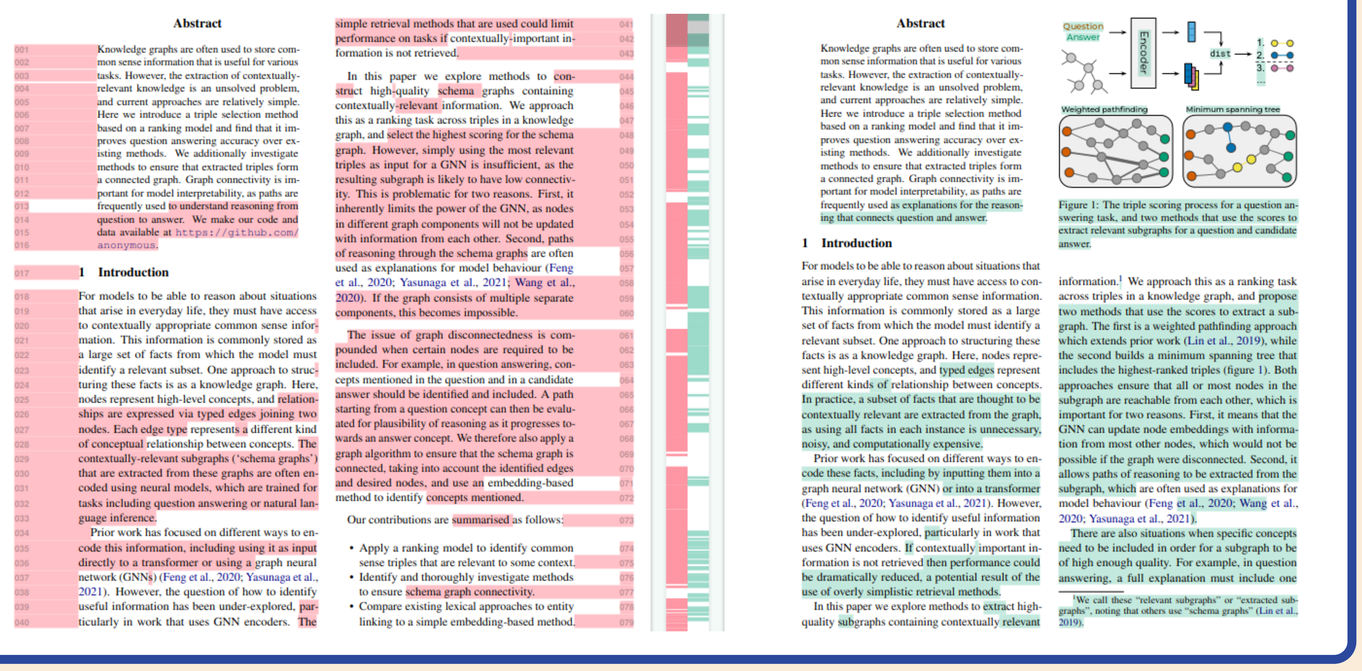

Processus de collecte

1. Collecte des événements (ateliers, conférences, etc) sur Open Review
2. Collecte des articles : métadonnées, relectures et PDF disponibles des versions des articles
3. Filtrage des articles ayant une seule version (89,33% des articles conservés soit 97,46% des PDF)
4. Conversion des PDF vers XML (outil Grobid)

Articles

les PDF des versions des articles

Fichiers de correspondance

- entre les versions finales et antérieures des articles
- entre les relectures et les articles

Contenu

Metadonnées des articles

- dates
- auteurs
- mots-clés
- événement
- identifiants

Relectures

- commentaires
- notes
- décisions
- dates

Description

Contient 730 évènements et 118 415 PDF pour 26 355 articles
Domaines : apprentissage auto, robotique, TAL, vision, etc.

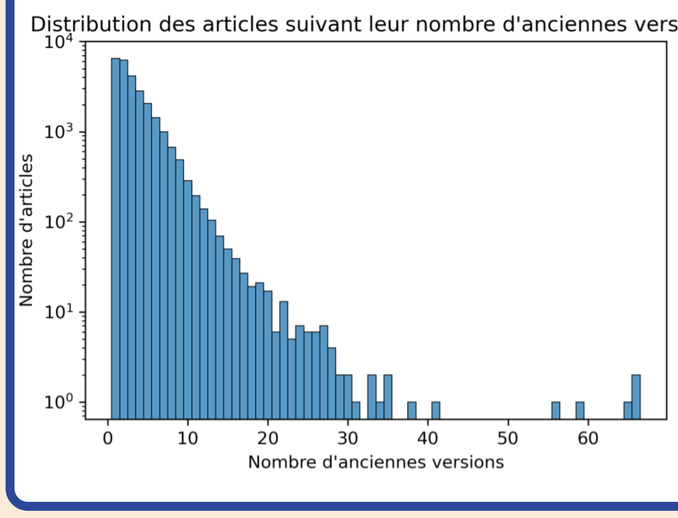

Et ensuite?

- Améliorer la conversion des PDF (choix de l'outil, traitement des figures, tables)
- Aligner les versions paragraphe à paragraphe et phrase à phrase puis extraire les révisions
- Annoter les documents selon une taxonomie de révisions à définir (ex: clarté, grammaire, style)
- Exploitation pour la mise en place d'outils d'aide à l'écriture

CORIA TALN 2023 RJCRI | RECITAL

LS2N

Nantes Université

TALN