



TextMine, 21 octobre 2022

Réflexions en cours pour dynamiser la recherche
en TAL et TDM autour des données ISTE~~X~~

Mathieu Constant
Université de Lorraine, CNRS, ATILF



ISTEX (www.istex.fr)

- Réservoir d'archives scientifiques normalisées au service de la recherche française pour un usage documentaire et TDM
 - 27 millions de documents
 - toutes les disciplines scientifiques
 - s'étalant sur 700 ans
- Une plateforme open-source, fondée sur une API, pour
 - Rechercher des documents
 - Définir et télécharger vos propres sous-corpus
 - Analyser votre corpus à partir des métadonnées et enrichissements
 - Accéder à quelques corpus prêts à l'emploi



ISTEX (2)

- Une volonté nationale
 - Née d'un programme d'investissement d'avenir (2012 – 2018, 60 millions d'euros)
 - Inscrite sur la feuille de route des infrastructures de recherche du MESRI depuis 2022
- Organisation
 - Comité de pilotage : CNRS, Consortium Couperin, Agence bibliographique de l'enseignement supérieur, Université de Lorraine, France Universités
 - Hébergement et développements : INIST (CNRS)



ISTEX (3)

- Acquisition des ressources
 - une politique massive d'achat centralisé d'archives scientifiques et de collections rétropectives
 - via le PIA ISTEX (2012 – 2018) et le GIS Collex-Persée (depuis 2019)
- Qui peut accéder à la base ?
 - Accès limité à l'ensemble des personnels de l'enseignement supérieur et de la recherche français



La base ISTE_X

- Des collections rétrospectives multilingues et multidisciplinaires de la littérature scientifique mondiale
- Jeu de métadonnées modélisées dans les normes du web sémantique
- Ressources librement accessibles, sauf les textes intégraux réservés aux membres de l'enseignement supérieur et de la recherche français



La base ISTE X – son contenu

- 28 éditeurs (70 % des documents viennent d'Elsevier, Wiley et Springer)
- Multidisciplinaire : sciences physiques (9,2M), sciences de la santé (7,4M), sciences de la vie (6,4M), sciences sociales (4,1M), général (0,4M)
- Multilingue : 50 langues, mais 90 % des documents sont en anglais
- 95 % sont des publications issues de périodiques



Projet d'infrastructure de recherche Feuille de route nationale 2022

- **Axe 1 : Développer le corpus**
 - plus d'open access
 - partenariats européens
- **Axe 2 : consolider et développer l'offre de service**
 - Enrichissement des métadonnées
 - Développement d'outils avancés avec les communautés TAL et TDM
 - Offre de service TDM pour tous



Groupe de travail pour dynamiser la recherche autour des données ISTEK

- Deux pistes
 - Une compétition autour des données ISTEK avec des tâches intéressantes
 - Un projet scientifique en TAL et fouille de textes
- Condition: constituer un jeu de données ouvert (textes intégraux + métadonnées)
 - A minima, un sous-corpus de taille suffisante pour mener des expériences de TAL et/ou fouille de textes (apprentissage de modèles et leur évaluation)
 - Accessible à tous (communauté internationale, entreprises, ...)
 - Première piste : sous-corpus des articles open-access (en cours d'exploration)



Groupe de travail pour dynamiser la recherche autour des données ISTE_X

- Quelques tâches envisagées pour la compétition
 - Prédiction de métadonnées : résumé, mots-clés, année de publication, ...
 - Analyse des textes intégraux : entités nommées, relations sémantiques, structure discursive, ...
- Quelques thématiques générales de recherche
 - Simplification
 - Multilinguisme
 - Temporalité



Conclusion

- ISTEEX : un réservoir unique d'archives scientifiques normalisé
- Textes intégraux ouverts uniquement aux personnels de l'ESR français
- Objectif : développer un terrain de jeu ouvert pour les chercheurs en TAL et TDM
- Suggestions, commentaires, questions ?