

➤ Usages de l'IA avec le Thésaurus
INRAE (et vice versa)

Thésaurus INRAE

Rencontres Hortidoc

18/11/2025 - Sophie Aubin, Magalie Weber, Maël Lesavourey

* Notre contexte

Riche, mais dispersé



périmètre large

INRAE

produits de recherche
multiples

article scientifique

jeu de données logiciel
rapport ouvrage

mémoire de thèse



INRAE DipSO

Pôle Num4Sci


Rencontres Hortidoc "Un thésaurus a t-il encore un sens dans un mode d'IA?"

18/11/2025

humain génétique végétal
ingénierie procédés imagerie végétal
génomique agronomie physiologie élevage
santé neurosciences moléculaire automatique écologie
animal environnement reproduction
mathématiques biologie sol
physique sylviculture nutrition
économie biochimie sociologie
microbiologie matériaux chimie

communautés scientifiques diverses

objets d'étude complexes



cadres de recherche variés



* **Notre problématique**

Pour les chercheurs comme pour les décideurs

Exploiter des sources d'**informations variées**, hétérogènes, silotées... pour

- identifier rapidement les **informations pertinentes**,
- repérer les **experts** d'une thématique,
- comprendre les **liens entre les acteurs**

- ✓ quelles personnes collaborent sur la séquestration du carbone dans le sols?
- ✓ quelles sont les contributions de l'Institut sur les transitions agroécologiques ?
- ✓ quels sont les domaines qui ont été financièrement les plus soutenus au sein de l'Institut?
- ✓ qui travaille sur les zoonoses dans la métropole Rennaise?



INRAE DipSO

Pôle Num4Sci

Rencontres Hortidoc "Un thésaurus a t-il encore un sens dans un mode d'IA?"

18/11/2025

* Nous expérimentons l'IA

- Au sein des communautés scientifiques (depuis longtemps)
- Au sein des directions d'appui

Pour trouver de nouvelles réponses, se décharger des tâches ingrates ou chronophages, pallier la réduction des ressources humaines...

Notre approche

- ✓ être prudent
- ✓ respecter la législation et la déontologie
- ✓ bénéficier de l'effort d'ouverture de la science
- ✓ être sobre
- ✓ envisager des approches hybrides pour tirer le meilleur parti des solutions



INRAE DipSO

Pôle Num4Sci


Rencontres Hortidoc "Un thésaurus a-t-il encore un sens dans un mode d'IA?"

18/11/2025

* **Retrieval Augmented Generation (RAG)**

L'IA générative appliquée à un corpus maîtrisé

Technique qui **combine les capacités de génération de texte des modèles de langage de grande taille (LLM) avec des techniques de récupération d'information structurée (contexte)**, afin de mieux maîtriser le contenu des réponses produites par un LLM.



* Exploration des productions scientifiques à INRAE à l'aide d'un système RAG basé sur un agent conversationnel

Données (open access)

- Multi-base : HAL et OpenAire (2019-2024), ScanR, BBI...
- Multi-objets: publications (extraits), jeux de données, projets de recherche
- Vocabulaire spécialisé : Thésaurus INRAE

Ce que fait le prototype

- ✓ Comprend une requête complexe
- ✓ Identifie les publications scientifiques pertinentes
- ✓ Génère une synthèse sur le sujet
- ✓ Liste les experts
- ✓ Montre les collaborations



INRAE DipSO

Pôle Num4Sci


Rencontres Hortidoc "Un thésaurus a t-il encore un sens dans un mode d'IA?"

18/11/2025

*

L'approche agentique

Des agents spécialisés dirigés par un LLM pour plus d'efficacité




L'«orchestrateur» (basé sur un LLM) détermine par rapport à une question utilisateur :

- la stratégie de recherche (NLP classique, requête Bdd, recherche complexe, ...)
- le(s) agent(s) à mobiliser

Les résultats (d'une recherche, d'un agent) sont redirigés vers le LLM pour produire une réponse en langage naturelle


* **Expérimentation de l'approche Graph RAG**

Augmenter la génération LLM avec des connaissances structurées



Base vectorielle

Forces : Simplicité relative de mise en œuvre, rapidité, efficacité prouvée pour améliorer la factualité et l'actualité des réponses pour des questions directes.




Base graphe

Forces : Capacité à modéliser et exploiter les relations, compréhension contextuelle approfondie, amélioration de l'interprétabilité via la visualisation du graphe


Utilisation : un exemple

- L'agent a commencé par identifier le concept 'zoonose' et les mots-clés associés.
- L'agent a ensuite récupéré toutes les publications pertinentes et les a organisées chronologiquement.
- Ce parcours a révélé que les recherches à INRAE sur les zoonoses, portent sur l'épidémiologie, la surveillance environnementale et la modélisation.



Utilisation : un exemple

- L'agent a commencé par identifier le concept 'zoonose' et les mots-clés associés.
- L'agent a ensuite récupéré toutes les publications pertinentes et les a



Outil recherche_concepts_keywords (Recherche de Concepts/Mots-clés) :

- Objectif : Identifier les concepts du thésaurus INRAE ou les mots-clés les plus proches d'un terme donné.
- Mécanisme : Effectue une recherche de similarité (distance de Levenshtein ou embedding) sur les concepts et mots-clés indexés dans le graphe
- Entrée : Terme ou sujet en langage naturel.
- Sortie : Liste des concepts ou mots-clés les plus similaires (avec le nombre de publications associées).

* **Limites et perspectives**

Liées au Thésaurus INRAE

Améliorer la pertinence de la récupération : combler le fossé sémantique entre la formulation de la requête utilisateur et la manière dont l'information est exprimée dans les documents

Améliorer la qualité des sources : peu de jeux de données, publications... indexés avec le Thésaurus INRAE

- 12 900 / 500 000 notices HAL (<3%)
- 1 024 / 4 800 notices data INRAE (21%)
- 0 projet

—> utiliser l'IA pour assister ou automatiser l'ajout de mots-clés contrôlés



INRAe DipSO

Pôle Num4Sci

Rencontres Hortidoc "Un thésaurus a t-il encore un sens dans un mode d'IA?"

18/11/2025

* Rendre le Thésaurus INRAE plus utilisable par les outils basés sur IA

Besoin d'enrichir le Thésaurus avec

- des termes anglais (réalisé en 2024-2025)
- des définitions (projet 2026)

Prochain objectif

Enrichissement semi-automatique du Thésaurus INRAE avec des définitions - Exploiter les techniques de RAG (Retrieval-Augmented Generation) pour collecter/générer des définitions de concepts à partir de publications scientifiques, en assurant la traçabilité des sources.



INRAE DipSO

Pôle Num4Sci

Rencontres Hortidoc "Un thésaurus a t-il encore un sens dans un mode d'IA?"

18/11/2025

* Et beaucoup d'autres idées pour continuer à faire vivre le Thésaurus INRAE

- 💡 Trouver des équivalents en anglais
- 💡 Vérifier la cohérence des hiérarchies
- 💡 Vérifier la qualité des descriptions de concepts
- 💡 Proposer des emplacements pour les concepts
- 💡 Calculer des alignements (correspondances) avec d'autres vocabulaires
- 💡 ...

> Merci de votre attention

Contact : vocabulaires-ouverts@inrae.fr

thesaurusINRAE@inrae.fr