

# Forum Jeunes Chercheuses Jeunes Chercheurs d'INFORSID

JCJC 2025

Actes de la 13ème édition



5 juin 2025 (Pau)  
INFORSID 2025

# Liste des articles

<b>Auteurs</b>	<b>Titre</b>	<b>Page</b>
<b>Ghislain Demonda</b>	Caractérisation computationnelle et taxonomie des styles rédactionnels de brevets : vers une automatisation stylométrique de la rédaction technique	4
<b>Yuntian Ding</b>	Une approche computationnelle pour mesurer la fiabilité de l'IA	8
<b>Romain Stevens</b>	Accompagner les carrières par une gestion proactive des connaissances organisationnelles	12
<b>Eriam Schaffter</b>	Vers un système de recommandation éducatif	16
<b>Deo Munduku</b>	Contextualisation des explications dans les systèmes de recommandation : une approche basée sur les schémas d'interprétation des utilisateurs	20
<b>Ismael Tankeu</b>	Gestion des connaissances pour les PME fondée sur les connaissances personnelles	24
<b>Clément Combier</b>	Développement d'un framework de suivi et d'évaluation de l'impact à travers un data warehouse sémantique pour les méta-organisations	28
<b>Alexandre Clause</b>	Prédiction d'expressions torturées dans des articles scientifiques : modélisation par masquage	32
<b>Mohamed Amine Lasheb</b>	Approches d'Extraction et de Structuration des Manuels Scolaires	36
<b>Kyllian Beguin</b>	Maîtrise du cycle de vie des données au sein des systèmes d'information éco-responsables	40
<b>Marwa Alali</b>	Managing Fragmented Temporal Graphs for Scalable Cyber Threat Detection	44
<b>Ghienvra Comiti</b>	[fjc] Estimation de la qualité de vie en Corse	48
<b>Yann Goetgheluck</b>	Gestion verte de la sécurité des systèmes d'information : Cas des vulnérabilités	52
<b>Jules di Scala</b>	Détection des manipulations de citations par utilisation d'heuristiques statistiques appliquées au corpus de données de Crossref	57
<b>Yara Amine</b>	Contextual Data Quality Management within Enterprise Architecture Frameworks	61
<b>Mohamed Cherif Sidhoum</b>	Développement de modèles génératifs sobres et explicables pour la rédaction de demandes de brevet	65
<b>Salomon van Ginneken</b>	Vers une ontologie à visée inclusive pour les itinéraires sémantiques	69
<b>Wendeline Swart</b>	Identification de médicaments sous-standard : Application en Afrique de l'Ouest	73

# Introduction au Forum Jeunes Chercheuses Jeunes Chercheurs d'INFORSID 2025

Lydia ABROUK

Université Bourgogne Europe, Dijon, France

lylia.abrouk@uu-bourgogne.fr

Le Forum Jeunes Chercheuses Jeunes Chercheurs (JCJC) d'Inforsid 2025 s'est tenu à Pau lors du congrès annuel de l'association INFORSID. Cet événement offre aux doctorant(e)s de première ou deuxième année de thèse l'opportunité de présenter leurs travaux à l'ensemble de la communauté française de recherche spécialisée en systèmes d'information. Il constitue un moment important pour la communauté, permettant de découvrir, à travers les doctorant(e)s, une vue d'ensemble des travaux en cours dans les différentes équipes de recherche liées à INFORSID. La douzième édition du Forum JCJC n'a pas dérogé à cette tradition, avec dix-huit doctorant(e)s présentant leurs travaux en session plénière, représentant douze équipes de recherche françaises. Chaque article a bénéficié d'une relecture approfondie de la part du comité de programme, composé de chercheurs du domaine, afin de garantir la qualité scientifique. Tous les articles ont été acceptés avec de légères modifications ou des révisions mineures, puis relus dans leur version finale.

Comme l'année dernière, l'essor de l'intelligence artificielle se manifeste de manière particulièrement marquée dans les travaux présentés, tant comme objet d'étude que comme outil au service de la gestion, du traitement et de l'exploitation de données hétérogènes. Les contributions explorent notamment l'utilisation de l'IA pour l'analyse de textes scientifiques et techniques, l'évaluation de la fiabilité de l'information, la détection de manipulations ou de biais, ainsi que pour la structuration et l'exploitation de connaissances complexes à l'aide d'ontologies et de graphes. Plusieurs travaux s'inscrivent également dans le champ des systèmes de recommandation et de l'explicabilité, en proposant des approches tenant compte du contexte utilisateur ou des schémas d'interprétation. D'autres contributions abordent des problématiques liées à la qualité des données, à leur gestion dans des architectures d'entreprise ou encore à leur intégration dans des environnements distribués et hétérogènes, notamment à travers les data warehouses sémantiques et les graphes temporels. Cette édition met en évidence une interdisciplinarité accrue, avec des applications variées allant de l'éducation à la santé, en passant par les systèmes documentaires et les connaissances organisationnelles, confirmant ainsi la richesse et la diversité des thématiques portées par la communauté.

La présentation des travaux s'est déroulée sous le format « Dragons et Chevaliers », comme lors de l'édition précédente. Chaque doctorant a endossé trois rôles : présentateur, dragon et chevalier. Le présentateur disposait de 5 minutes pour exposer son travail, suivi de 5 minutes durant lesquelles le dragon apportait trois critiques constructives, tandis que chaque chevalier soulignait trois aspects positifs du projet. L'ordre de passage et les rôles ont été définis à l'avance afin d'assurer une bonne fluidité tout au long de la session. Nous avons affiché en format A4 le titre et le résumé de chaque présentation, accompagnés de post-it distribués aux autres chercheurs du public pour noter des questions spécifiques à chaque travail. Chaque post-it était signé, permettant aux doctorants de retrouver l'auteur de la question pour des échanges plus approfondis. Ce format a favorisé des échanges interactifs grâce au jeu de rôles, tout en créant une ambiance conviviale. Les échanges se sont également poursuivis après les présentations grâce aux questions laissées sur les post-it. Je remercie chaleureusement nos auteurs pour leurs contributions scientifiques et leur participation engagée aux sessions du Forum JCJC, ainsi que les chercheurs

présents dans le public, qui ont stimulé les doctorants par leurs questions.

Je tiens à exprimer toute ma gratitude au bureau d'INFORSID pour la confiance qu'il m'a accordée en me confiant l'organisation de ce Forum. Ce fut un réel plaisir et une très belle expérience.

Lylia ABROUK  
Responsable du Forum JCJC 2025

---

# Caractérisation informatique et taxonomie des styles rédactionnels de brevets : vers une automatisation stylométrique de la rédaction technique

**Ghislain DEMONDA**

*LIUPPA, Université de Pau et des Pays de l'Adour (UPPA), LIPSTIP  
64000 Pau, France  
gdemonda@univ-pau.fr*

---

*RESUME. Dans le domaine de la propriété intellectuelle, les brevets sont des documents techniques et juridiques essentiels dont la rédaction requiert une expertise combinant des compétences techniques, juridiques et linguistiques. Les styles rédactionnels des brevets varient considérablement selon les domaines technologiques, juridictions et stratégies de protection. L'évolution rapide des technologies de l'intelligence artificielle, particulièrement en traitement automatique du langage naturel (TALN), ouvre des perspectives pour l'analyse informatique des documents techniques. La stylométrie offre des outils prometteurs pour caractériser et classer les styles rédactionnels des brevets.*

*ABSTRACT. In intellectual property, patents are essential technical and legal documents. Patent drafting requires expertise combining technical, legal, and linguistic skills, with writing styles varying by technological field, jurisdiction, and property protection strategy. AI technologies, particularly in natural language processing (NLP), opens new perspectives for computational analysis of technical documents. Stylometry offers promising tools for characterizing and classifying patent writing styles.*

*Mots-clés : Analyse de brevets, Stylométrie, Traitement automatique du langage naturel, Apprentissage automatique, Rédaction technique*

*KEYWORDS : Patent Analysis, Stylometry, Natural Language Processing, Machine Learning, Technical Writing*

*ENCADREMENT/SUPERVISION: Sébastien Laborie (LIUPPA@UPPA), Nathalie Vallès-Parlangeau (LIUPPA@UPPA)*

---

## 1. Introduction

Les brevets constituent des documents techniques et juridiques fondamentaux pour la protection de l'innovation. Leur rédaction nécessite une expertise

multidisciplinaire rare, alliant compétences techniques, juridique et linguistique. Les styles rédactionnels varient considérablement selon les domaines technologiques, juridictions et stratégies de protection intellectuelle, posant des défis pour l'analyse, la classification et la génération automatique de ces documents.

La stylométrie, discipline qui étudie le style d'écriture à l'aide de méthodes quantitatives, offre des outils prometteurs pour caractériser et classifier les styles rédactionnels des brevets. Cependant, son application au domaine spécifique des brevets reste largement inexplorée.

Notre recherche vise à répondre à la question fondamentale suivante :  
*Comment caractériser et classifier de manière informatique les styles rédactionnels des brevets pour permettre une automatisation stylométrique de la rédaction technique ?*

## **2. État de l'art**

L'analyse informatique des brevets bénéficie aujourd'hui des avancées en TALN et apprentissage profond. Les principales solutions explorées sont les transformeurs et les réseaux de neurones graphiques (GNN).

Trappey et coll. (2021) proposent une revue des applications de l'apprentissage profond pour l'analyse des brevets, soulignant le potentiel des modèles transformeurs pour améliorer la classification et l'extraction d'informations. Lee et coll. (2019) présentent PatentBERT, un modèle adapté aux brevets qui améliore les performances de 15 % par rapport aux approches traditionnelles. Su et coll. (2024) utilisent des réseaux convolutionnels graphiques pour modéliser la dynamique des citations de brevets.

Si les méthodes d'analyse stylistique sont bien établies en littérature (cf. Stamatatos, 2009), leur application aux brevets reste limitée en raison d'obstacles spécifiques : méthodologiques (inadaptation des métriques stylistiques aux structures normalisées des brevets), techniques (complexité d'extraction des caractéristiques des sections hétérogènes et multilingues) et disciplinaires (cloisonnement entre expertises techniques, juridiques et linguistiques). Chen et Zhu (2020) proposent une approche de transfert de style à faibles données, applicable aux documents juridiques. Gehrman et coll. (2019) ont développé GLTR (Giant Language model Test Room), un outil statistique pour l'analyse stylistique qui pourrait s'appliquer aux brevets, mais cette approche ne modélise pas pleinement les interactions entre style, structure et contenu juridique.

Par ailleurs, malgré l'existence de cadres de classification technique, tels que l'IPC (International Patent Classification) ou la CPC (Cooperative Patent Classification), aucune taxonomie décrivant de façon systématique les styles rédactionnels de brevets n'a encore été proposée. Les rares contributions identifiées (p. ex. WIPO Patent Drafting Manual, 2023 ; WIPO Patent Analytics Handbook, 2022) fournissent des recommandations pratiques ou des cartographies de codes techniques, mais ne

caractérisent pas les niveaux micro- et macro-stylistiques nécessaires à la comparaison et à la génération contrôlée de textes de brevets.

Concernant la génération de texte, plusieurs travaux récents explorent néanmoins la génération, la simplification et le résumé automatiques de brevets : Casola et coll. (2022) dressent un état de l'art des approches basées sur les modèles linguistiques de grande dimension, tandis que Berrios Torres (2023) applique l'« ingénierie d'instructions » pour produire différentes sections de brevet. Toutefois, aucun de ces modèles ne permet encore de contrôler la variation de style en fonction de la juridiction, du domaine technique ou de la stratégie de protection.

Plusieurs verrous subsistent :

- l'absence d'un modèle intégrant les dimensions technique, juridique et stylistique des brevets ;

- le manque de taxonomies adaptées aux spécificités rédactionnelles transjuridictionnelles, c'est-à-dire des classifications permettant de représenter les variations de style selon les juridictions, les domaines techniques et les usages, afin de faciliter la comparaison, l'analyse et la génération de textes de brevets adaptés à différents contextes ;

- les limites des approches actuelles dans la génération assistée par style.

Une nouvelle approche intégrée doit donc être proposée pour répondre à ces verrous scientifiques.

### **3. Approche proposée**

Notre recherche vise à développer des méthodes capables de capturer les subtilités linguistiques, techniques et juridiques qui définissent le style rédactionnel d'un brevet, tout en restant adaptables aux différents contextes. Nous proposons l'élaboration d'une taxonomie cohérente des styles rédactionnels de brevets intégrant les variations liées aux domaines technologiques, juridictions et stratégies de protection intellectuelle.

Les méthodes traditionnelles de stylométrie n'étant pas directement applicables aux brevets, notre recherche se concentrera sur la conception de nouveaux algorithmes capables de traiter efficacement les particularités structurelles et lexicales propres à ces documents.

Nous proposons de développer un Système de Caractérisation et d'Automatisation Stylométrique des Brevets (SCASB) articulé autour de quatre axes complémentaires :

- analyse informatique des caractéristiques stylistiques au niveau lexical et syntaxique ;

- élaboration d'une taxonomie multidimensionnelle des styles rédactionnels ;

- conception d'une architecture d'analyse stylométrique intégrant dimensions structurelles et sémantiques ;

– développement d’un système d’aide à la rédaction technique basé sur la stylométrie.

Ce système intégrera des techniques avancées de TALN et d’apprentissage automatique, s’appuyant sur des architectures de transformeurs adaptées et des GNN pour capturer efficacement les aspects structurels.

#### 4. Conclusion et perspectives

Cette recherche adresse la caractérisation informatique des styles rédactionnels de brevets en s’articulant autour de quatre axes complémentaires. Les contributions scientifiques attendues comprennent une méthodologie robuste d’analyse des styles, une taxonomie validée empiriquement, une architecture d’analyse stylométrique spécialisée et un système d’aide à la rédaction.

Sur le plan applicatif, nos travaux permettront d’améliorer la qualité rédactionnelle des brevets, de réduire les coûts de rédaction, d’assurer une meilleure conformité aux exigences juridiques et de fournir des outils d’aide à la décision.

Les perspectives incluent l’extension à d’autres types de documents techniques, l’intégration d’analyses multimodales et l’application de techniques d’explicabilité pour une meilleure transparence.

#### Bibliographie

Trappey, A. J., et coll. (2021). *Deep learning for patent analytics*. World Patent Information, 67, 102035.

Lee, J., et al. (2019). *PatentBERT: Patent classification with fine-tuning a pre-trained BERT model*. <https://arxiv.org/abs/1906.02124>.

Su, Z., et coll. (2024). *PTNS: Patent Citation Trajectory Prediction Based on Temporal Network Snapshots*. Scientific Reports.

Stamatatos, E. (2009). *A survey of modern authorship attribution methods*. Journal of the American Society for Information Science and Technology, 60(3), 538-556.

Chen, X., & Zhu, K. Q. (2020). *Small-data Text Style Transfer via Multi-task Meta-Learning*. <https://arxiv.org/abs/2004.11742>.

Gehrmann, S., Strobelt, H., & Rush, A. M. (2019). *GLTR: Statistical Detection and Visualization of Generated Text*. In Proceedings of NAACL-HLT 2019 (pp. 111-121).

Casola, S., Molino, A., & Colleoni, E. (2022). *Summarization, Simplification, and Generation: The Case of Patents*. Expert Systems with Applications, 210, 118524.

Berrios Torres, A. (2023). *Language Models for Patents: Exploring Prompt Engineering for the Patent Domain*. Master’s thesis, Politecnico di Milano.

---

# Une approche computationnelle pour mesurer la fiabilité de l'IA statistique

**Yuntian DING**

*Centre de Recherche en Informatique, Université Paris 1 Panthéon-Sorbonne,*

*31 Rue Baudricourt 75013, Paris*

*yuntian.ding@univ-paris1.fr*

---

*MOTS-CLÉS : intelligence artificielle ; confiance informatique ; quantification de la confiance*

*KEYWORDS: artificial intelligence ; computational trust ; trust quantification*

*ENCADREMENT. Camille Salinesi (PR) et Nicolas Herbaut (MCF)*

---

## 1. Introduction

Le développement des technologies de l'intelligence artificielle (IA), notamment de l'IA statistique incluant l'apprentissage automatique (machine learning), a conduit leur intégration croissant dans des domaines sensibles tels que le diagnostic médical, les véhicules autonomes et le recrutement. Cette expansion soulève des questions éthiques concernant l'IA statistique, en particulier en ce qui concerne l'équité, la transparence, et la responsabilité. Par exemple, l'opacité des algorithmes « boîte noire » peut renforcer des biais existants (Durán, 2021).

Évaluer si un système d'IA statistique est "digne de confiance" (trustworthy) demeure une démarche floue et subjective. La quantification évite de réduire la confiance à une étiquette binaire—"digne de confiance" ou "indigne de confiance". Elle permet de la concevoir comme une qualité mesurable en fonction de facteurs comme l'exactitude, l'efficacité et la transparence. Cette thèse vise à proposer un cadre (framework) pour la quantification de la confiance.

## **2. Contexte et état de l'art**

### **2.1. *Confiance dans les systèmes d'IA statistique***

La confiance dans l'IA se réfère à la volonté des humains d'adopter ces technologies en fonction de leur attitude envers la technologie et de leurs croyances quant à ses capacités. Selon McKnight, cette confiance est généralement considérée comme composée de quatre dimensions : la confiance dispositionnelle, l'intention de confiance, la croyance de confiance et la confiance institutionnelle. La confiance dispositionnelle reflète la tendance inhérente d'un individu à faire confiance à la technologie dans un large éventail de situations. L'intention de confiance désigne la volonté d'un individu d'adopter une technologie, tout en acceptant les risques et incertitudes associés à son comportement. La croyance de confiance repose sur l'évaluation raisonnée des capacités perçues de la technologie. Enfin, la confiance institutionnelle représente la confiance dans les fournisseurs de technologie (McKnight, 2005).

### **2.2. *Modèles computationnels de confiance***

Les modèles se divisent en deux catégories : les approches basées sur la théorie des jeux et les approches cognitives (Sabater, 2005). Les premières analysent la probabilité de dépendance à un système dans des environnements multi-acteurs. Les secondes, quant à elles, considèrent la confiance comme un compromis entre les bénéfices attendus et les risques perçus liés à cette dépendance. Les réseaux bayésiens dynamiques (DBN) (Fooladi, 2021), et l'intégration de logique floue (Ashtiani, 2016) ont récemment émergé pour modéliser la confiance et les risques, afin de capturer l'incertitude et la vaguité des contextes spécifiques. Cependant, la définition des valeurs pour une confiance initiales demeure difficile. Pour proposer un cadre de mesure de la confiance, il est nécessaire de mobiliser les principes fondamentaux de la science de la mesure.

### **2.3. *Science de la mesure***

La science de la mesure consiste généralement à attribuer des représentations mathématiques à des propriétés qualitatives, tout en préservant les relations structurelles entre ces propriétés. La confiance, en tant que concept multidimensionnel et dépendant du contexte, doit être d'abord décomposée en composants et attributs sur la base d'un modèle fondamental de la confiance. Ces composants peuvent ensuite être mesurés à l'aide d'échelles numériques (pour des comparaisons quantitatives), ou classés par ordres d'intervalle (pour des comparaisons qualitatives). Ces mesures sont ensuite agrégées à l'aide d'une méthode appropriée (Justwan, 2018).

### 3. Questions de Recherche

L'objectif de cette thèse est de proposer une approche computationnelle de la mesure de la confiance dans les systèmes d'IA statistique déployé dans son contexte opérationnel. Les questions de recherche suivantes guident notre étude.

- **RQ1** : Comment les métriques de confiance et de risque pour les systèmes d'IA statistique peuvent-elles être définies de manière systématique, mesurées et leurs relations établies ?
- **RQ2** : Comment développer un modèle de mesure de la confiance pour les systèmes d'IA statistique qui capture la dynamique de la confiance et son évolution ?
- **RQ3** : Comment calibrer la confiance à partir des perceptions actuelles de la confiance et du risque dans un contexte d'IA statistique ?
- **RQ4** : Quelles sont les limites potentiels de l'application du modèle proposé dans divers cas d'usage d'IA statistique à différents niveaux de risque ? contextes de risque de systèmes d'IA statistique ?

### 4. Méthode de recherche et résultats attendus

#### Phase 1 - Revue de la littérature

Identification des composantes de la confiance et du risque, ainsi que leurs métriques associées, et analyse les modèles de confiance existants pour comprendre leur cas d'application, leurs forces et leurs limites.

#### Phase 2 - Développement du modèle conceptuel

Développement d'un modèle conceptuel formalisant la perception de la confiance et du risque à partir d'interactions observables entre humains et systèmes d'IA. Les métriques associées seront intégrées à des fonctions computationnelles permettant de quantifier ces perceptions. Des méthodes probabilistes seront utilisées pour traiter l'incertitude. Le modèle sera validé par les commentaires des experts sur les mesures et les représentations mathématiques.

#### Phase 3 - Construction du cadre de mesure de la confiance

Définition d'un cadre de mesure pour les systèmes d'IA statistique dans leur contexte d'intégration. Ce cadre reposera sur un réseau nomologique des relations théoriques entre les composantes de confiance et de risque. Le modèle conceptuel sera intégré dans ce cadre afin de permettre la quantification, la calibration et l'interprétation des niveaux de confiance. Ce cadre sera évalué par des experts en confiance IA afin d'évaluer son adaptabilité et son applicabilité dans différentes situations.

#### Phase 4 - Évaluation du cadre sur une étude de cas

Validation du cadre de mesure par une étude de cas appliquée à un système d'IA. L'approche sera quantitative, avec des scores de confiance basés sur des fonctions mathématiques et des modèles probabilistes. La confiance sera calibrée dynamiquement en fonction des perceptions évolutives de la confiance et du risque. Nous comparerons ces résultats théoriques aux corrélations empiriques dérivées des analyses statistiques de l'ensemble des données pour vérifier la cohérence des modèles avec nos hypothèses.

## 5. Travaux préliminaires et Contributions Futures

Nous modélisons la confiance comme une fonction  $T : T : \mathcal{F}^* \rightarrow [0, 1]$ , où  $T$  représente la confiance,  $\mathcal{F}$  est l'ensemble des composantes de la confiance, et chaque composante  $f \in F$  est définie par  $\frac{\partial T}{\partial F}(f) \neq 0$ , indique son impact sur le score de confiance. Le résultat est un score de confiance, variant de 0 (méfiance totale) à 1 (confiance totale).

Cependant, dans de précédents travaux, nous avons défini la confiance dans les systèmes d'apprentissage (Machine Learning) à travers une approche ontologique soulignant les tensions entre différents composantes de confiance. Sur cette base, nous cherchons à représenter un modèle conceptuel intégrant les métriques collectées et des fonctions mathématiques pour illustrer les relations, parfois paradoxales, entre les composantes de la confiance et du risque. Ce modèle servira à construire un cadre de mesure pour l'évaluation et la calibration de la fiabilité. Enfin, nous évaluons notre cadre de mesure à travers un cas d'étude. Nous identifierons les limites de notre modèle conceptuel du cadre de mesure de la confiance, et proposerons des solutions potentielles.

## Bibliographie

- Ashtiani M, Azgomi M A. A hesitant fuzzy model of computational trust considering hesitancy, vagueness and uncertainty. *Applied Soft Computing*, 2016, 42 : 18-37.
- Durán J M, Jongsma K R. Who is afraid of black box algorithms? On the epistemological and ethical basis of trust in medical AI[J]. *Journal of medical ethics*, 2021, 47(5) : 329-335.
- Fooladi Mahani M, Jiang L, Wang Y. A bayesian trust inference model for human-multi-robot teams[J]. *International Journal of Social Robotics*, 2021, 13(8) : 1951-1965.
- Justwan F, Bakker R, Berejikian J D. Measuring social trust and trusting the measure. *The Social Science Journal*, 2018, 55(2), 149-159.
- McKnight D H. Trust in information technology[J]. *The Blackwell encyclopedia of management*, 2005, 7 : 329-331.
- Sabater J, Sierra C. Review on computational trust and reputation models[J]. *Artificial intelligence review*, 2005, 24 : 33-60.
- Yeung K. The health care sector's experience of blockchain : A cross-disciplinary investigation of its real transformative potential[J]. *Journal of medical Internet research*, 2021, 23(12) : e24109.

---

# Accompagner les carrières par une gestion proactive des connaissances organisationnelles

## Un pas vers la recommandation de plans de carrière

**Romain STEVENS**

*Université Paris Dauphine, PSL  
Research Universities, UMR CNRS 7243,  
LAMSADE, Paris, France*

*romain.stevens@dauphine.psl.eu*

---

*MOTS-CLÉS : Gestion des connaissances, Développement de l'expertise, Système de Gestion de carrière, Graphe de Connaissances, Système de Recommandation, Intelligence Artificielle.*

*KEYWORDS: Knowledge Management, Expertise development, Career Management system, Knowledge Graph, Recommender System, Artificial Intelligence.*

*ENCADREMENT. Dr. Elsa NEGRE (MCF HDR, LAMSADE), Dr. Armand LANG (IKOS Consulting)*

---

### 1. Contexte

La numérisation exponentielle de nos activités a généré un volume de données sans précédent. Cette surabondance excède la capacité humaine à les exploiter efficacement (Arnold *et al.*, 2023). De nombreux acteurs sont touchés par cette difficulté notamment les grandes organisations, confrontées à une croissance de données liées à leurs activités. Elle impacte la gestion des Ressources Humaines (RH), en complexifiant la cartographie des compétences, cruciale pour la réalisation des objectifs organisationnels (Alfawaire *et al.*, 2021). Alfawaire *et al.* (2021) soulignent la nécessité d'une gestion des connaissances ou *Knowledge Management* (KM) efficace dans la gestion RH pour créer des avantages concurrentiels durables.

L'état de l'art suivant permet de définir le KM, les facteurs clés intervenant dans le développement de l'expertise au sein d'une organisation et les systèmes de gestion de carrière conçus pour favoriser ce développement.

## 2. État de l'art

Le KM concerne l'acquisition, le traitement et la diffusion des connaissances (Xue, 2017). Il repose sur la hiérarchie DICS (Negre, 2015): Données (éléments bruts, e.g. chiffres, mesures), Informations (données organisées et contextualisées), Connaissance (collection d'informations utilisée pour la prise de décision) et Sagesse (applications des connaissances avec justesse et éthique). Pour favoriser la valorisation des données, elles sont centralisées et accessibles au sein de systèmes d'information (SI) (Negre, 2015). Le KM est fondé sur le transfert :

- des connaissances explicites, formalisées, codifiées, articulées logiquement et pouvant être transmises facilement (e.g. sous forme de documents) ;
- des connaissances tacites, non formalisées, basées majoritairement sur des expériences personnelles et des compétences pratiques.

Dans le contexte de l'économie du savoir (Powell *et al.*, 2004), le KM valorise et partage l'expertise métier pour atteindre les objectifs organisationnels. Le KM favorise l'innovation, l'amélioration des processus et de la qualité de ses activités, au travers notamment de la montée en compétences des acteurs (Xue, 2017). Herling (2000) définit l'expertise comme les compétences mobilisables par une organisation et identifie plusieurs éléments clés à son développement :

- la formation professionnelle permet le transfert de connaissances explicites et ainsi d'accélérer l'acquisition de compétences;
- le mentorat facilite le transfert de connaissances tacites;
- l'intégration progressive de compétences intermédiaires mène à l'obtention d'une compétence plus globale enrichie par l'expérience et les connaissances cumulées;
- la fidélisation des acteurs de l'organisation est primordiale pour accumuler et retenir des connaissances internes pouvant être valorisées.

Dajnoki *et al.* (2021) soulignent l'importance du KM pour faciliter l'accès aux connaissances dans l'élaboration des plans de carrière, une stratégie visant à atteindre les objectifs professionnels d'un acteur en définissant les étapes nécessaires. Cette gestion de carrière s'appuie sur son parcours passé, ses aspirations d'évolution et la stratégie organisationnelle globale. Les SI de gestion de carrière actuels sont fragmentés, biaisés, limitant la vision globale et la personnalisation du développement des compétences (Tambe *et al.*, 2019). Tambe *et al.* (2019) présentent Blue Match, un système d'analyse de données à grande échelle d'appariement entre les compétences des acteurs et des postes, mais limité à des correspondances immédiates sans perspectives d'évolutions.

Ce projet de thèse explore une approche prospective fondée sur un système de recommandation (SR) de plans de carrière évolutifs. Les SR proposent des éléments susceptibles d'intéresser un utilisateur à l'aide d'un filtrage d'informations personnalisé (Negre, 2015). Il favorise la fidélisation des acteurs en intégrant leurs préférences et profils individuels. Le catalogue d'éléments recommandables peut être construit à partir

de données présentes dans un Graphe de Connaissances (GC) (Rosati *et al.*, 2016). Un GC ou ontologie appliquée intègre des informations dans une ontologie de concepts et applique un raisonneur pour générer de nouvelles connaissances (Ehrlinger et al., 2016). Cette représentation structurée et sémantique des informations permettrait d'améliorer la qualité des recommandations tout en apportant une transparence dans les choix des éléments recommandés (Rosati *et al.*, 2016). Cette explicabilité faciliterait l'adoption du système ainsi que les retours utilisateurs. Une structuration dynamique des informations dans un GC évolutif soutiendrait le développement d'une stratégie de KM proactive.

### 3. Problématique

La problématique générale de ce travail de recherche : « Comment transformer les connaissances internes d'une organisation en leviers stratégiques pour améliorer la qualité de ses activités au travers d'un système de recommandation accompagnant la gestion de carrière ? » conduit à trois questions exposées ci-dessous :

Q1. Comment structurer les données internes d'une organisation (hétérogènes, multisources) afin de favoriser et automatiser leur utilisation ?

Q2. Comment accompagner les RH dans la gestion de carrière ?

Q3. Comment garantir l'éthique et l'adoption de ce système par les RH ?

Des pistes de recherche vont être proposées afin d'apporter des éléments de réponses (Ri) aux questions de recherche exposées (Qi). Ces pistes sont priorisées dans l'ordre présenté : de la construction du GC (R1/Q1), à son exploitation pour les recommandations (R2/Q2), et enfin aux enjeux d'adoption (R3/Q3)."

### 4. Pistes de recherche envisagées

R1. Cette première piste vise à structurer les données RH hétérogènes en un GC fiable et exploitable. L'approche repose sur des ontologies modulaires pour modéliser les relations clés, un enrichissement semi-automatique des données via des techniques de Traitement de Langage Naturel (spaCy, BERT), et un benchmark avec des graphes de référence (Google KG, Wikidata). La qualité du GC sera mesurée par des indicateurs de complétude et de cohérence, avec un nettoyage par clustering. L'efficacité du GC sera validée par son impact sur la pertinence des recommandations (Negre, 2015).

R2. Cette seconde piste vise à exploiter un GC pour générer des recommandations de carrières personnalisées et adaptatives. Le système combinera filtrage collaboratif (e.g. similarité entre profils et besoins), de contenu (e.g. similarité entre profils et modules de formation) (Negre, 2015) et des retours utilisateurs. La représentation sémantique du GC facilitera la pertinence des suggestions (Rosati *et al.*, 2016). Néanmoins, les SR actuels sont limités aux éléments présents dans un catalogue connu. Dans le cas où les éléments existants ne sont pas satisfaisants, il pourrait être pertinent

d'intégrer de l'IA générative afin de générer de nouveaux éléments recommandables, une approche encore peu explorée dans la littérature.

R3. Cette piste assurera la transparence et l'adoption du système par les parties intéressées. L'explicabilité sera garantie par des méthodes post-hoc ou intrinsèques au SR (Arrieta *et al.*, 2020) accompagnées de justifications en langage naturel. La conformité éthique sera assurée par une analyse des biais algorithmiques et l'anonymisation des données sensibles conformément au Règlement Général sur la Protection des Données. L'intégration technique sera facilitée par un tableau de bord RH permettant la visualisation, e.g. des écarts de compétences, des étapes et priorités de formations.

Ce projet propose un écosystème de carrière innovant (Donald *et al.*, 2024) fondé sur un GC dynamique couplé à un SR hybride et conçu pour faciliter son intégration dans les processus RHs. L'objectif est de fournir une méthodologie reproductible, un prototype de SR explicable open-source alliant IA générative et expertise humaine, ainsi qu'une aide à son intégration et adoption dans un contexte organisationnel.

## 5. Bibliographie

- Alfawaire F., Atan T., "The effect of strategic human resource and knowledge management on sustainable competitive advantages at Jordanian universities: The mediating role of organizational innovation", *Sustainability*, vol. 13, n° 15, p. 8445, 2021.
- Arnold M., Goldschmitt M., Rigotti T., "Dealing with information overload: a comprehensive review", *Frontiers in psychology*, vol. 14, p. 1122200, 2023.
- Arrieta A. B., Díaz-Rodríguez N., Del Ser J., Bennetot A., Tabik S., Barbado A., García S., Gil-López S., Molina D., Benjamins R. et al., "Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI", *Information fusion*, vol. 58, p. 82–115, 2020.
- Dajnoki K., Szondi R., Filep R., "The Role of career and knowledge management in retention", *Studia Mundi–Economica*, vol. 8, n° 1, p. 65–76, 2021.
- Donald W. E., Van der Heijden B. I., Baruch Y., "Introducing a sustainable career ecosystem: Theoretical perspectives, conceptualization, and future research agenda", *Journal of Vocational Behavior*, vol. 151, p. 103989, 2024.
- Herling R. W., "Operational definitions of expertise and competence", *Advances in developing human resources*, vol. 2, n° 1, p. 8–21, 2000.
- Negre E., *Information and recommender systems*, John Wiley & Sons, 2015.
- Powell W. W., Snellman K., "The knowledge economy", *Annu. Rev. Sociol.*, vol. 30, n° 1, p. 199–220, 2004.
- Rosati J., Ristoski P., Di Noia T., Leone R. d., Paulheim H., "RDF graph embeddings for content-based recommender systems", *CEUR workshop proc.*, vol. 1673, p. 23–30, 2016.
- Tambe P., Cappelli P., Yakubovich V., "Artificial intelligence in human resources management: Challenges and a path forward", *California Manag. Review*, vol. 61, n° 4, p. 15–42, 2019.
- Xue C. T. S., "A literature review on knowledge management in organizations", *Research in Business and Management*, vol. 4, n° 1, p. 30–41, 2017.

---

# Vers un système de recommandation éducatif

**Eriam Schaffter**

*Université de Lyon, Lyon 1*

*ERIC UR 3083*

*F69676 Bron Cedex*

*Eriam.Schaffter@etu.univ-lyon1.fr*

---

*MOTS-CLÉS : systèmes de recommandations, chemin d'apprentissage, apprenant, compétences, hypergraphe, recommandation éducative, systèmes adaptatifs d'apprentissage*

*KEYWORDS: learning path recommendation systems, learner competencies, hypergraph modeling, educational recommendation, adaptive learning systems*

*ENCADREMENT. Ahmed Bounekkar*

---

## 1. Introduction

Très largement utilisés dans des domaines tels que les médias ou encore les réseaux sociaux, les systèmes de recommandations (SR) ont démontré leur efficacité à engager des utilisateurs, à les guider dans leurs achats ou dans leurs choix culturels en prédisant une évaluation pour un *item* ou une liste d' *items* préférés. Dans le domaine de la recommandation éducative, on combine la recommandation avec un objectif qui consiste à faire acquérir un ensemble de compétences à un apprenant. On observe toutefois que les systèmes de recommandations éducatifs (SRE) peinent à s'installer parmi les outils accessibles aux apprenants, en particulier dans les cursus scolaires. Cela semble regrettable car rendre l'apprenant davantage acteur de ses apprentissages l'aide à progresser (Guay, 2022). Ainsi, pouvons nous concevoir et évaluer la valeur apportée par un SRE mettant en application des méthodes des sciences de l'ingénieur ?

## 2. État de l'art

Un SR se constitue d'un ensemble de ressources (les *items*)  $R = \{r_1, r_2, \dots, r_m\}$ , d'un moteur de recommandations (MR) et d'une interface utilisateur (IU). L'objet du MR est de sélectionner dans  $R$  le sous ensemble  $R^*$  qui contient l'élément qui aura la préférence de l'utilisateur, soit  $R^* = \{r_i; r_i \in R\}$  avec  $R^* \subseteq R, i \in \mathbb{N}$ , et nos ressources en dimension  $m \in \mathbb{N}$ . Pour y parvenir, diverses approches de MR: le filtrage collaboratif propose des ressources relatives à une préférence manifestée par les utilisateurs sur les ressources et le filtrage basé sur le contenu, exploite les représentations des ressources et des utilisateurs pour recommander (Adomavicius and Tuzhilin, 2005). En tous cas, l'apprentissage automatique peut être mis en œuvre.

Parmi les SR, certains sont concernés par un objectif long terme plutôt que court terme tel que le SRE qui vise à optimiser le processus d'acquisition de compétences, ces SR se distinguent par leur notion d'objectif. On trouve la notion de *learning path* (LP) et de *learning path recommender system* (LPRS). Ce LP est abordé soit comme une continuation de liste (*course sequence*) soit comme un calcul complet du chemin (*course generation*). Dans un SRE, la représentation de l'apprenant, soit les informations liées ou indépendantes du domaine (Tang, 2023), peut se baser sur diverses techniques. La représentation des ressources s'appuie aussi sur des approches variées (cours complets ou objets d'apprentissage). Enfin plusieurs techniques, comme les processus de décision markovien partiellement observable (Zhang, 2022), produisent le LP.

Tableau 1. Produire un LP dans un SRE

Méthode	Limites actuelles
Graphes de connaissances	Pas de véritable optimisation globale du parcours.
Renforcement	Complexité technique et nécessité de nombreuses données d'entraînement.
<b>Contrôle optimal</b>	Hypothèse linéaire et dépendance du modèle sur les matrices $A$ et $B$ définies ci-dessous.

Pour terminer, les critères d'évaluation d'un SRE diffèrent de ceux d'un SR. Plusieurs travaux se sont déjà penchés sur l'établissement de métriques adéquates: Nabizadeh et al. (2020), Zhang (2022) et on peut considérer une évaluation basée sur l'état cible qui satisfasse des critères mais aussi des évaluations relatives à la vitesse d'apprentissage ou encore à l'engagement de l'apprenant.

## 3. Proposition

Si les SR optimisent à court terme, un SRE est, lui, un système dans lequel on souhaite recommander des ressources pédagogique et emmener un apprenant d'un état

initial vers un état cible: optimiser longitudinalement. Cette description correspond à un cadre de problème utilisé pour le contrôle des systèmes dynamiques mécaniques ou biologiques mais qui n'a pas encore été exploré pour bâtir un SRE: la théorie du contrôle. Elle est pertinente pour notre SRE car elle n'est pas restrictive sur les méthodes de résolution, elle est extensible par des éléments d'incertitudes mais surtout, son cadre correspond strictement à ce que nous attendons d'un SRE: faire passer un système dynamique, les compétences d'un étudiant, d'un état  $x_0$ , soit une évaluation initiale des compétences, à un état  $x_1$ , soit un état cible des compétences, en y appliquant des commandes, soit des consignes, tout en proposant un choix à l'apprenant.

Sa formulation linéaire est la suivante (Lobry and Sari, 2003):  $x(t+1) = Ax(t) + Bu(t)$ , avec dans notre cas  $x(t) \in \mathbb{R}^n$  et  $x(t) \in \mathcal{X}$  l'état de l'apprenant ; ensuite  $u(t) \in \mathbb{R}^m$  et  $u(t) \in \mathcal{U}$  les recommandations ainsi que  $A \in \mathbb{R}^{n \times n}$  la matrice de l'évolution naturelle de l'apprenant et  $B \in \mathbb{R}^{n \times m}$  la matrice de l'effet des recommandations. Ces matrices pourront faire l'objet d'hypothèses heuristiques (telle que la courbe d'Ebbinghaus (Murre and Dros, 2015) pour  $A$ ) pour leurs quantifications. En outre, dans ce cadre très simple qui facilite l'analyse, on disposera de nombreuses méthodes de résolution (Camacho and Bordons, 2007) et on pourra explorer des dynamiques non linéaires ou hybrides (NMPC, Koopman, etc).

Pour résoudre, d'abord, la notion de contrôlabilité (Lobry and Sari, 2003) pour déterminer si notre modèle peut passer de l'état  $x_0$  à  $x_1$  avec  $A$  et  $B$  par le calcul du rang de  $\mathcal{C} = [B, AB, A^2B, \dots, A^{n-1}B]$  qui doit être égal à  $n$ . Ensuite, étant contrôlable, on souhaite alors calculer la séquence optimale à l'instant  $t$  soit  $U^*(t)$ . Pour cela, le calcul de la commande prédictive (Camacho and Bordons, 2007) consiste à calculer la séquence optimale pour faire converger  $x(t)$  vers l'origine, et ce, itérativement. Soit, dans notre cas, la séquence de ressources qui minimise une fonction de coût comme:

$$U^*(t) = \arg \min_{\{u(\tau)\}_{\tau=t}^{t+T-1}} \left[ \sum_{k=0}^{T-1} (x(t+k)^\top Q x(t+k) + u(t+k)^\top R u(t+k)) + x(t+T)^\top Q_f x(t+T) \right]$$

Avec  $Q \in \mathbb{R}^{n \times n}$ , matrice des poids pour les états, qui va agir sur la rapidité de la convergence,  $R \in \mathbb{R}^{m \times m}$  matrice des poids pour les recommandations,  $Q_f \in \mathbb{R}^{n \times n}$  matrice des poids pour l'état final et  $T \in \mathbb{N}_0$  l'horizon de calcul. Après résolution nous disposerons alors de nos recommandations, ordonnées vers l'objectif, et ainsi notre SRE consiste en une suite itérative de recommandations de ressources, soit par exemple, autour d'une thématique de cybersécurité, la séquence optimale au temps 0:

$$U^*(0) = \begin{bmatrix} u^*(0) \\ u^*(1) \\ u^*(2) \\ u^*(3) \end{bmatrix} = \begin{bmatrix} r_2 \\ r_7 \\ r_3 \\ r_5 \end{bmatrix} = \begin{bmatrix} \text{Vidéo « Repérer un e-mail de phishing »} \\ \text{Lab interactif « Configurer un pare-feu »} \\ \text{Quiz « Bonnes pratiques mots de passe »} \\ \text{Étude de cas « Incident ransomware »} \end{bmatrix}.$$

On pourra alors, lors de chaque interaction avec le SRE, enrichir l'état de l'apprenant et lui proposer, après une nouvelle résolution, de nouvelles recommandations.

#### 4. Actions futures

En l'état actuel de l'exploration bibliographique, la piste consistant à évaluer la pertinence d'un SRE basé sur la théorie du contrôle semble être une piste intéressante, et ce, en particulier, si la simplicité du modèle donne lieu à une bonne extensibilité pour modérer les limites identifiées. La proposition d'axe de travail est de bâtir un prototype accompagné d'une évaluation (exploitant par exemple *The Top learners Learning Path* ou *Performance in Learning Path* dans Zhang (2022)). La proposition s'appuiera sur un SI éducatif et consistera en la mise en œuvre d'un SRE, par exemple sous forme d'un greffon Moodle, s'appuyant sur la théorie du contrôle et sur la commande prédictive.

#### Bibliographie

- Adomavicius, Gediminas and Alexander Tuzhilin (2005). "Towards the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions". en. In: IEEE transactions on knowledge and data engineering.
- Camacho, E. F. and C. Bordons (2007). *Model Predictive control*. Ed. by Michael J. Grimble and Michael A. Johnson. Advanced Textbooks in Control and Signal Processing. London: Springer London. ISBN: 978-1-85233-694-3 978-0-85729-398-5. (Visited on 02/10/2025).
- Guay, Frédéric (Mar. 2022). "Applying Self-Determination Theory to Education: Regulations Types, Psychological Needs, and Autonomy Supporting Behaviors". en. In: *Canadian Journal of School Psychology* 37.1, pp. 75–92. ISSN: 0829-5735, 2154-3984. (Visited on 02/03/2025).
- Lobry, Claude and Tewfik Sari (2003). "Introduction à la théorie du contrôle". fr. In: Tlemcen: Ecole du CIMPA.
- Murre, Jaap M. J. and Joeri Dros (July 2015). "Replication and Analysis of Ebbinghaus' Forgetting Curve". en. In: *PLOS ONE* 10.7. Ed. by Dante R. Chialvo, e0120644. ISSN: 1932-6203. (Visited on 05/03/2025).
- Nabizadeh, Amir Hossein et al. (Nov. 2020). "Learning path personalization and recommendation methods: A survey of the state-of-the-art". en. In: *Expert Systems with Applications* 159, p. 113596. ISSN: 09574174. (Visited on 12/05/2024).
- Tang, Qing (2023). "Resource recommendation in e-learning platforms based on knowledge graph". en. PhD thesis. Université de technologie .9 de Compiègne.
- Zhang, Zhao (2022). "Learning Path Recommendation: A Sequential Decision Process". en. PhD thesis. Université de Lorraine.

---

# Contextualisation des explications dans les systèmes de recommandation : une approche basée sur les schémas d'interprétation des utilisateurs.

**Deo Munduku**

*Université Paris-Dauphine, PSL Research University.  
UMR CNRS 7243, LAMSADE, Paris, France*

*deo.munduku@lamsade.dauphine.fr*

---

*MOTS-CLÉS : Contextualisation, Explications, Systèmes de recommandation, Profils utilisateurs, Confiance.*

*KEYWORDS: contextualization, Explanations, Recommender Systems, User Profiles, Trust.*

*ENCADREMENT. Elsa Negre (MCF, HDR)*

---

## 1. Contexte

Avec la montée en puissance des plateformes numériques, les systèmes de recommandation sont devenus des outils indispensables pour guider les utilisateurs vers des choix pertinents dans des environnements complexes et saturés d'informations. Ces systèmes reposent sur des algorithmes permettant de filtrer et de proposer du contenu adapté aux préférences et aux besoins des utilisateurs. Leur objectif ultime est de fournir des suggestions à la fois pertinentes et compréhensibles afin de maximiser la satisfaction des utilisateurs (Negre, 2018). La satisfaction des utilisateurs dans les systèmes de recommandation est étroitement liée à la transparence des explications fournies. Lorsque les recommandations sont accompagnées d'explications compréhensibles, les utilisateurs ont davantage confiance dans le système et sont plus enclins à l'adopter (Zhong, 2023). Dans ce contexte, une explication désigne toute information fournie par le système visant à justifier une recommandation ou à en faciliter la

compréhension (Tintarev *et al.*, 2007). Par exemple, un système peut dire : « Ce film vous est recommandé car vous avez aimé les films *Inception* et *Interstellar*. » Ces explications ont pour objectif d'améliorer la transparence, la confiance et l'engagement des utilisateurs. Cependant, malgré ces avancées, ces systèmes sont encore souvent perçus comme manquant de transparence, ce qui limite la confiance des utilisateurs et freine leur adoption à grande échelle.

Pour répondre à ces défis, la recherche s'est orientée vers l'intégration d'explications dans les systèmes de recommandation. Ces avancées ont permis la mise en place de systèmes de recommandation explicables, où chaque recommandation est accompagnée d'une explication destinée à renforcer la compréhension des utilisateurs. L'un des principaux défis réside donc dans la manière dont chaque utilisateur interprète une explication. Une même explication peut être perçue différemment selon l'expérience, les attentes et la manière dont l'utilisateur traite l'information. En effet, les individus ne reçoivent pas passivement une explication : ils la filtrent et l'assimilent selon leur propre cadre de compréhension cognitif. Ce cadre de compréhension cognitif, qui influence la perception des explications, est aussi désigné sous le terme de schéma d'interprétation, défini comme un ensemble de filtres cognitifs comprenant les connaissances, expériences et croyances mobilisés par un individu pour comprendre, organiser et donner du sens à une information dans un contexte donné (Arduin, 2013).

Dans cette optique, la prise en compte du contexte utilisateur devient essentielle pour affiner l'adaptation des explications. En se basant sur la définition proposée par Dey (2001), nous considérons le contexte utilisateur comme toute information pouvant être utilisée pour caractériser sa situation. Dans le cadre des systèmes de recommandation, ces informations influencent la perception des utilisateurs face aux explications associées aux recommandations. Dans cette perspective, les schémas d'interprétation peuvent être considérés comme relevant de la dimension cognitive du contexte utilisateur, telle que précisée par (Ferdousi *et al.*, 2017).

Cette proposition de recherche examine comment contextualiser les explications dans les systèmes de recommandation en s'appuyant sur le schéma d'interprétation des utilisateurs.

## 2. État de l'art

La question de la contextualisation des explications dans les systèmes de recommandation suscite un intérêt de plus en plus marqué dans la recherche. Plusieurs travaux ont exploré cette problématique en proposant différentes approches pour améliorer l'adaptabilité et la pertinence des explications fournies aux utilisateurs. Guesmi *et al.* (2022) proposent une méthodologie permettant aux utilisateurs de choisir entre plusieurs niveaux de détail des explications dans les systèmes de recommandation. Ce choix se fait manuellement parmi des options prédéfinies, ce qui limite la flexibilité du système, car il ne s'adapte pas automatiquement aux interactions entre l'utilisateur et les explications fournies. Cette limite, a conduit d'autres approches à explorer

des moyens de déduire automatiquement les préférences des utilisateurs, sans leur demander d'intervention explicite. C'est dans cette optique que s'inscrit la proposition de Ramos *et al.* (2024) qui exploitent les avis textuels des utilisateurs pour construire des profils en langage naturel, reflétant leurs préférences. Contrairement aux méthodes basées sur des avis chiffrés, cette approche privilégie l'interprétation des avis textuels pour affiner les recommandations. Toutefois, elle reste statique, nécessitant une modification manuelle des profils sans adaptation aux interactions en temps réel. Pour contourner cette limitation Verma *et al.* (2024) proposent une approche qui personnalise les explications en fonction des caractéristiques des objets recommandés, améliorant ainsi la transparence et la compréhension des recommandations. Toutefois, cette approche reste centrée sur les attributs des objets et ne prend pas en compte d'autres facteurs pouvant influencer la perception des explications, tel que le schéma d'interprétation des utilisateurs. Syed *et al.* (2022) vont plus loin en proposant un système de recommandation contextuel basé sur un graphe de connaissances, exploitant les relations sémantiques pour générer des explications mieux alignées sur les préférences des utilisateurs.

### 3. Problématique

Les recherches actuelles dans le domaine des systèmes de recommandation explicables ont permis des avancées significatives, notamment en améliorant la transparence des recommandations et en offrant une meilleure compréhension aux utilisateurs. Cependant, ces systèmes souffrent encore d'une limite majeure : les explications fournies ne tiennent pas compte du schéma d'interprétation des utilisateurs. Par exemple, un utilisateur novice attendra des explications simples, tandis qu'un utilisateur expert préférera des explications plus techniques et détaillées. Si ces différences ne sont pas prises en compte, les explications risquent d'être mal perçues, réduisant ainsi la confiance et l'adhésion de l'utilisateur au système.

À notre connaissance, parmi les facteurs du contexte utilisateur proposés par Ferdousi *et al.* (2017), aucun travail n'a exploré le schéma d'interprétation comme un facteur impactant pour contextualiser les explications dans les systèmes de recommandation. Face à ce constat, une question centrale se pose : Comment contextualiser les explications dans les systèmes de recommandation en intégrant les facteurs contextuels les plus impactants, afin d'adapter leur contenu et leur niveau de détail aux besoins spécifiques de chaque utilisateur ? Cette question centrale peut être déclinée en deux sous-questions :

$q_1$  : Comment identifier les facteurs contextuels ayant le plus d'impact sur les recommandations ? ,

$q_2$  : Comment exploiter ces facteurs pour produire des explications contextualisées, adaptées aux besoins spécifiques des utilisateurs ?

#### 4. Perspectives et travaux futurs

Notre approche future consistera à répondre aux questions formulées dans la problématique.

Pour répondre à  $q_1$  nous nous appuyons sur l'approche de Ferdousi *et al.* (2017), qui utilise le coefficient de corrélation de Pearson pour identifier les facteurs contextuels le plus impactants sur les recommandations produites. Toutefois, cette méthode repose sur l'hypothèse d'une relation linéaire entre facteurs contextuels, ce qui limite la détection de relations complexes. Pour dépasser cette limite, nous mobiliserons des modèles d'apprentissage supervisé capables d'identifier des dépendances non linéaires, afin de mieux isoler le facteur contextuel le plus influent. Nous formulons l'hypothèse que ce facteur correspond au schéma d'interprétation de l'utilisateur.

Pour répondre à  $q_2$ , nous intégrerons le schéma d'interprétation dans le processus de recommandation, en adaptant dynamiquement les explications afin de les contextualiser et de mieux répondre aux besoins spécifiques de chaque utilisateur. Ce travail débouchera sur un prototype expérimental permettant de générer des explications contextualisées à partir du schéma d'interprétation d'un utilisateur.

#### 5. Bibliographie

- Dey A. K., "Understanding and Using Context", *Personal and Ubiquitous Computing*, vol. 5, Springer-Verlag, p. 4-7, 2001.
- Ferdousi Z. V., Negre E., Colazzo D., "Context factors in context-aware recommender systems", *Proceedings of the AISR 2017 Conference*, AISR, Paris, France, 2017.
- Guesmi M., Chatti M. A., Joarder S., Ain Q. U., Alatrash R., Siepmann C., Vahidi T., "Is More Always Better? The Effects of Personal Characteristics and Level of Detail on the Perception of Explanations in a Recommender System", *Proceedings of the 27th ACM Conference on Intelligent User Interfaces*, 123–132, 2022.
- Negre E., "Les systèmes de recommandation : une catégorisation", *Interstices*, septembre, 2018.
- Ramos J., Rahmani H. A., Wang X., Fu X., Lipani A., "Transparent and Scrutable Recommendations Using Natural Language User Profiles", in L.-W. Ku, A. Martins, V. Srikumar (éd.), *Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, Association for Computational Linguistics, Bangkok, Thailand, p. 13971–13984, août, 2024.
- Syed M. H., Huy T. Q. B., Chung S.-T., "Context-Aware Explainable Recommendation Based on Domain Knowledge Graph", *Big Data and Cognitive Computing*, vol. 6, n° 1, p. 11, 2022.
- Tintarev N., Masthoff J., "A Survey of Explanations in Recommender Systems", *2007 IEEE 23rd International Conference on Data Engineering Workshop*, IEEE, p. 801–810, 2007.
- Verma S., Shah C., Dickerson J. P., Beniwal A., Sadagopan N., Seshadri A., "RecXplainer: Amortized Attribute-based Personalized Explanations for Recommender Systems", *Proceedings of the Association for the Advancement of Artificial Intelligence (AAAI)*, 2024.
- Zhong J., *Generality and explainability in recommender systems*, Thèse de doctorat, Université Paris Dauphine-PSL, November, 2023.

---

# Gestion des connaissances pour les PME fondée sur les connaissances personnelles

**Ismaël Tankeu (ismael.tankeu@doctorant.uttop.fr)**

*LGP, Enit, UTTOP, Université de Toulouse, 77 av. d'Azereix, 65000 Tarbes, France*

## 1. Introduction

L'Industrie 5.0, en plaçant l'humain au cœur de la digitalisation, vise à concilier les avancées technologiques et le bien-être dans une perspective de développement durable. Elle met l'accent sur l'accès aux connaissances et une gestion des savoirs tacites, essentiels à la prise de décision. Dans ce contexte, la gestion des connaissances (Knowledge Management - KM) devient un levier stratégique pour améliorer l'efficacité des entreprises, mais les PME sont souvent limitées en ressources pour la mettre en œuvre efficacement (Celino et al., 2025). Les systèmes de gestion des connaissances personnelles (Personal Knowledge Management - PKM) apparaissent alors comme une solution pertinente pour structurer et valoriser les connaissances individuelles. Leur déploiement à l'échelle de l'organisation favorise l'émergence d'une gestion des connaissances organisationnelles (Organizational Knowledge Management - OKM), en intégrant les savoirs individuels dans la structure collective, ce qui améliore la performance et l'innovation (Mittelmann, 2016). Le principal défi réside dans l'interconnexion des systèmes de PKM pour développer un système OKM. Cet article propose une approche pour construire un système OKM à partir de plusieurs PKMs, en utilisant des techniques d'enchâssement facilitant la recherche de connaissances. La suite de l'article couvre l'état de l'art sur PKM et OKM, la contribution, la conclusion et les perspectives.

## 2. Revue de la littérature

Le PKM vise à optimiser la gestion des connaissances individuelles en facilitant leur collecte, organisation, maintenance et réutilisation pour améliorer la prise de décision et la résolution de problèmes (Liu et al., 2017). Pour les PME, le PKM constitue une porte d'entrée vers la gestion des connaissances, bien qu'il présente des inconvénients, notamment en matière de partage et de réutilisation. Il représente néanmoins une première étape vers la construction et la gestion d'une connaissance organisationnelle (OKM), qui vise à capturer et diffuser les connaissances des employés à l'échelle organisationnelle afin de créer de nouvelles connaissances et d'apporter une valeur ajoutée (Mittelmann, 2016). L'OKM hérite ainsi des bénéfices du PKM

tout en développant des capacités collaboratives propres, contribuant ainsi à la productivité et à la performance. Les systèmes de PKM permettent de constituer une base de connaissances personnelles, composée d'éléments tels que des notes ou des extraits de documents (Prilipsky et Zaeva, 2020). Cette base de connaissance peut être structurée sous forme de graphes de connaissances personnelles (Personal Knowledge Graph - PKG). Le concept de PKG, relativement récent, désignant en général un sous-ensemble personnalisé d'un graphe de connaissances (KG) (Skjæveland et al., 2024). Le terme « personnel » peut renvoyer aussi bien à des faits objectifs concernant l'utilisateur qu'à des croyances subjectives, ou encore à des informations ayant un intérêt particulier pour lui (Balog et al., 2022). Ainsi, un PKG est un graphe pouvant être dérivé d'un KG existant et géré par un service (Jiang et al., 2024); il est centré sur l'utilisateur et structuré autour de ses intérêts (Balog et Kenter, 2019); il est intégralement contrôlé par l'utilisateur, qui détient les droits d'accès et de modification (Skjæveland et al., 2024). Ainsi, l'agrégation de plusieurs PKG dans un contexte d'OKM donne naissance à un Graphe de Connaissances Organisationnelles (OKG), qui reflète les connaissances produites et partagées au sein de l'organisation. PKG et OKG sont structurés autour de nœuds, contenant des connaissances plus ou moins formalisées (textes, images, processus, etc.) et de relations, qui définissent les liens entre les nœuds.

### 3. Proposition

La proposition repose sur deux phases principales : l'enchâssement des connaissances et la recherche des connaissances comme le montre la Figure 1. Dans cette proposition, nous considérons qu'il existe déjà un OKG, que nous allons enrichir avec des nouveaux PKG qui seront partagés.

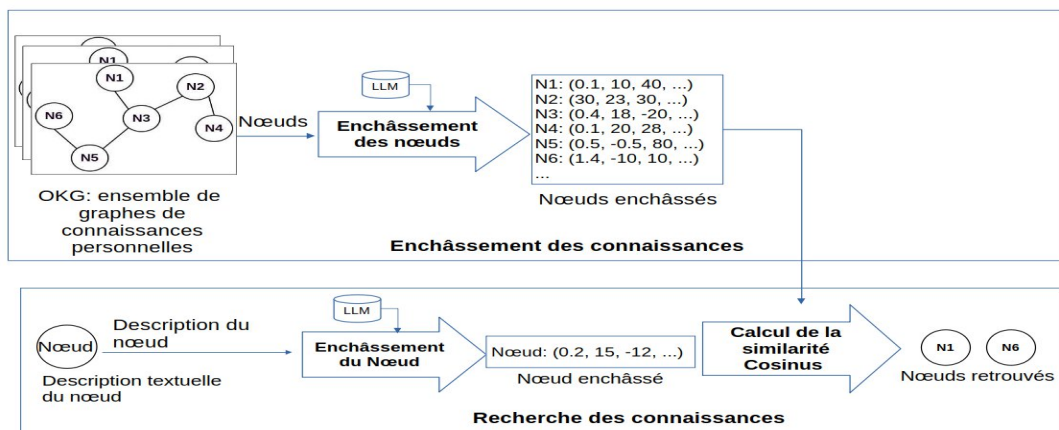


Figure 1. Processus général d'enchâssement et de recherche de connaissances.

### **3.1. Enchâssement d'un OKG**

L'enchâssement d'un OKG est réalisé grâce à un LLM et une méthode adaptée. Cela consiste à transformer l'OKG en une représentation vectorielle (embedding). Cette technique est appelée enchâssement de graphe. Selon (Choudhary et al., 2021), l'enchâssement d'un KG est une technique permettant de le transposer (nœuds, arêtes) sur un espace vectoriel de faible dimension, tout en préservant les informations du graphe. Le processus prend en entrée un graphe et retourne un ou plusieurs vecteurs de faible dimension. Le nombre de vecteurs en sortie dépend des techniques utilisées et de l'objectif visé, c'est-à-dire s'il s'agit d'enchâsser les nœuds, les relations, les sous-ensembles de nœuds ou le graphe tout entier. Dans l'approche proposée, nous nous intéressons uniquement aux nœuds de l'OKG. Le rôle du LLM est d'extraire la sémantique de chaque nœud de l'OKG à partir de sa description (texte, image, etc) et de le représenter sous forme de vecteur dense. En incorporant les éléments de connaissances dans ce processus, les enchâssements permettent de capturer des informations sémantiques plus détaillées et plus significatives de chaque nœud, ce qui les rend plus efficaces pour l'exploitation du graphe.

### **3.2. Recherche d'éléments de connaissances**

Dans le cadre de la recherche de connaissances, une requête est formulée sous forme d'un nouveau nœud, puis elle (sa description textuelle) est enchâssée à l'aide d'un LLM pour générer un vecteur requête ( $V_{req}$ ) permettant d'identifier les nœuds pertinents dans l'OKG. Le processus de recherche repose sur la comparaison entre le vecteur requête  $V_{req}$  et les vecteurs des nœuds  $V_n$  de l'OKG, en utilisant la similarité cosinus, couramment utilisée en Traitement Automatique du Langage (TAL). Les vecteurs nœuds  $V_n$  identifiés comme suffisamment similaires au vecteur requête  $V_{req}$  constituent un ensemble d'éléments de connaissances pertinents au regard de la requête, car leur proximité sémantique est avérée. Dans nos travaux, cette démarche est appliquée à la recherche de connaissances en résolution des problèmes. Différents PKG, correspondant à des expériences individuelles de résolutions de problèmes, sont fédérés dans un OKG avec pour objectif de diffuser ces connaissances dans l'organisation. Le processus de recherche de connaissances permet ensuite d'identifier des nœuds pertinents pour la résolution d'un nouveau problème.

## **4. Conclusion**

Cette étude aborde la question de la formalisation et de l'exploitation de connaissances par les PME, en construisant un OKG fédérant les connaissances provenant de différents PKG. Pour exploiter efficacement les connaissances d'un OKG, nous proposons d'enchâsser ses nœuds à l'aide d'un LLM universel. Ce modèle générique permet de capturer les éléments sémantiques de chaque élément de connaissance (nœuds de l'OKG) sous forme de vecteurs. Les différents vecteurs obtenus à partir des nœuds de l'OKG peuvent être utilisés de manière efficace pour des tâches complexes telles que la recherche de connaissances pertinentes pour la réso-

lution d'un problème. Dans le cadre de nos recherches, nous proposons d'enchâsser une requête et de calculer la similarité cosinus entre celle-ci et les enchâssements des nœuds de l'OKG afin de retourner, par ordre de priorité, les nœuds dont la similarité cosinus avec la requête est importante.

La recherche d'éléments de connaissances peut être améliorée en tenant compte des relations existantes entre les nœuds de l'OKG. Pour cela, nous développons une approche par propagation. Elle consiste à enrichir chaque nœud enchâssé de l'OKG par d'autres nœuds de l'OKG avec lesquels il existe une relation directe ou indirecte. Cela revient à renforcer, par propagation, les connaissances de chaque nœud de l'OKG avec celles des nœuds qui sont situés dans son voisinage. Dans nos travaux, nous travaillons également sur la création de l'OKG à partir de différents PKG. Pour cela, une approche par clustering consistant à regrouper les nœuds des PKG ayant une certaine proximité est à l'étude. Ce rapprochement peut avoir comme impact la création de nouvelles connaissances (généralisation), représentant une synthèse de l'ensemble des nœuds proches dans les PKG, et la suppression de toute forme de redondance dans les PKG, c'est-à-dire une fusion d'un ensemble de nœuds en un nœud unique si ceux-ci représentent le même élément de connaissance.

#### *Remerciements*

*Ce travail de thèse est le fruit d'une collaboration avec Adama ARAMA (Post-doctorant), Laurent GENESTE (Directeur de thèse) et Thierry COUDERT (co-directeur). Il est soutenu par l'Agence nationale de la recherche (projet Remind 4.0, ANR-22-LCV1-0002-01).*

#### **Bibliographie**

- Balog K., Kenter T., (2019). Personal Knowledge Graphs: A Research Agenda. Proceedings of the 2019 ACM SIGIR International Conference on Theory of Information Retrieval, 217–220. [doi](#)
- Balog K., Mirza P., Skjæveland M. G., Wang Z. (2022). Report on the Workshop on Personal Knowledge Graphs (PKG 2021) at AKBC 2021. ACM SIGIR Forum, 56(1), 1-11. [doi](#)
- Celino I., Carrero V. A., Azzini A., Baroni I., Scrocca, M. (2025). Procedural knowledge management in Industry 5.0: Challenges and opportunities for knowledge graphs. Journal of Web Semantics, 84, 100850. [doi](#)
- Choudhary S., Luthra T., Mittal A., Singh R. (2021). A Survey of Knowledge Graph Embedding and Their Applications (No. arXiv:2107.07842). arXiv. [doi](#)
- Jiang P., Xiao C., Cross A., Sun, J. (2024). GraphCare: Enhancing Healthcare Predictions with Personalized Knowledge Graphs (No. arXiv:2305.12788). arXiv. [doi](#)
- Liu C.-H., Wang J. S., Lin, C.-W. (2017). The concepts of big data applied in personal knowledge management. Journal of Knowledge Management, 21(1), 213–230. [doi](#)
- Mittelman A. (2016). Personal Knowledge Management as Basis for Successful Organizational Knowledge Management in the Digital Age. Procedia Computer Science, 99. [doi](#)
- Prilipsky R. E., Zaeva M. A. (2020). A hybrid system for building a personal Knowledge Base. Procedia Computer Science, 169, 96–99. [doi](#)
- Skjæveland M. G., Balog K., Bernard N., Łajewska W., Linjordet T. (2024). An ecosystem for personal knowledge graphs: A survey and research roadmap. AI Open, 5, 55–69. [doi](#)

---

# Développement d'un framework de suivi et d'évaluation de l'impact à travers un data warehouse sémantique pour les méta-organisations

**Clément Combier**

*Université de Pau et des Pays de l'Adour  
E2S-UPPA, LIUPPA  
1 Allée du Parc Montaury  
64600, Anglet, France  
clement.combier@univ-pau.fr*

---

*MOTS-CLÉS : data warehouse, web sémantique, méta-organisation, étude d'impact, mesure d'impact, système de suivi et d'évaluation, étude du management, théorie du changement*

*KEYWORDS: data warehouse, semantic web, meta-organisation, impact study, impact evaluation, monitoring and evaluation system, management study, theory of change*

*ENCADREMENT: Adel Nouredine, Jose Enrique Armendariz-Inigo, Phillipe Arnould*

---

## 1. Contexte

Les méta-organisations, définies comme des groupements d'organisations autour d'objectifs communs, émergent dans des domaines variés : académique, industriel, territorial, etc. Leur gouvernance distribuée, la diversité de leurs membres, et la multiplicité de leurs projets rendent l'évaluation de leur impact complexe. Cette étude propose un framework générique de suivi et d'évaluation de l'impact (S&E) adapté à ces structures. Notre proposition intègre des technologies sémantiques au sein d'un data warehouse pour faciliter l'agrégation, l'interprétation et l'exploitation de données hétérogènes issues de plusieurs organisations. Ce travail est expérimenté dans le

cadre de l'alliance universitaire européenne UNITA, utilisée ici comme cas d'usage représentatif d'une méta-organisation, sans en restreindre la portée générale.

## 2. État de l'art

La concentration sur les alliances universitaires a fortement augmenté depuis le lancement en 2019 de l'Initiative des Universités Européennes (IUE). À mesure que ces partenariats se développent, il est crucial d'évaluer leur impact sociétal et de formuler des stratégies de suivi complètes. Cette analyse explore la recherche axée sur la mesure de l'impact, la Théorie du Changement (TdC) et les systèmes de Suivi et d'Évaluation (S&E) au sein de méta-organisations comme les alliances universitaires. En investiguant ces sujets, nous visons à établir un cadre solide pour évaluer leur impact. Nous avons séparé l'étude en deux axes majeurs que nous allons explorer dans deux parties de cet état de l'art. La première section se concentre sur l'étude d'impact et la théorie du changement, fortement liées. Puis, les systèmes de suivi et d'évaluation automatisés orientés données pour la partie plus technique de la recherche.

### 2.1. Étude d'Impact et Théorie du Changement

Le terme 'impact' fait souvent référence aux effets à long terme des activités sur leur environnement. Nous adoptons la définition du Comité d'Aide au Développement (CAD) de l'Organisation de Coopération et de Développement Économiques (OCDE) : "les effets à long terme positifs et négatifs, primaires et secondaires, produits par une intervention de développement, directement ou indirectement, intentionnels ou non." (OECD, 2010). L'impact étudié dans ce travail est conçu comme global et multidimensionnel, regroupant des effets organisationnels, sociétaux, académiques, économiques et culturels, selon les objectifs propres à chaque méta-organisation. Ce choix de structure permet au framework de rester flexible et adaptable à différents types de projets ou contextes. Les indicateurs sont choisis en fonction des priorités de l'organisation analysée, tout en respectant un canevas unifié. Un outil souvent utilisé dans l'étude d'impact est la chaîne d'impact simplifiée comme expliqué par (Peersman *et al.*, 2016). Elle se compose des inputs, en entrées qui seront utilisés pour différentes activités et actions. Puis, en résultat de ces actions, nous aurons des outputs, qui mènent à un plus haut niveau aux outcomes de l'action, puis en fin de chaîne nous avons l'impact de nos actions.

La théorie du changement a évolué au fil du temps, débutant avec le "Modèle de Changement en Trois Étapes" de Kurt Lewin (Lewin, 1947) et se développant à travers des modèles cycliques élargis par Lippitt et al. (Lippitt, 1958) et Prochaska et DiClemente (Prochaska *et al.*, 1983). Ces théories, semblables à la Théorie de l'Action Raisonnée et du Comportement Planifié, intègrent des notions clés comme "le contrôle perçu", mais manquent d'une perspective sociétale. Nous examinons la théorie du changement dans le domaine de l'Alphabétisation Politique, fusionnant une approche politiquement informée et stratégique, cruciale pour planifier, suivre et évaluer les

changements au sein des méta-organisations. Elle nous permet, entre autres, d'utiliser le concept de la Narration du Changement pour planifier l'étude d'impact.

## *2.2. Système de Suivi et d'Évaluation automatisé orienté données*

Les systèmes de Suivi et d'Évaluation (S&E) combinent des évaluations régulières pour des mesures quantitatives avec une surveillance continue pour identifier les anomalies, assurant des données fiables tout au long du cycle de vie d'un projet. Avec notre approche orientée données, nous nous intéressons au cadre proposé et faisons le lien avec la sous-section suivante. Les entrepôts de données orientés vers la connaissance centralisent et exploitent des informations souvent abstraites comme l'impact sociétal. Ils fournissent une perspective unifiée au sein de la méta-organisation, facilitant des évaluations précises grâce à des indicateurs statistiques. Dans notre cas, nous proposons un entrepôt de données sémantique intégrant les technologies du Web sémantique (ontologies, RDF, SPARQL) pour améliorer l'interopérabilité entre sources hétérogènes, la compréhension machine des données et leur contextualisation.

## **3. Problématique**

La notion de méta-organisation et l'étude de l'impact existent depuis plusieurs années, mais il manque un cadre méthodologique dédié pour évaluer leur impact, particulièrement dans le contexte des alliances universitaires européennes qui nécessitent une collaboration interinstitutionnelle. Cette recherche vise à combler ce vide en créant un framework de suivi et d'évaluation basé sur les données, spécialisé pour les méta-organisations. Elle s'articule autour de trois axes clés : **(1) Définition et caractéristiques** : Comment définir une méta-organisation dans le cadre universitaire ? Les alliances universitaires européennes y correspondent-elles ou doivent-elles être reclassées ? **(2) Méthodologie d'impact** : Quelles méthodes sont appropriées pour évaluer l'impact des méta-organisations ? Comment établir des indicateurs pertinents à différents niveaux (alliance vs institution) ? Les méthodes classiques telles que le modèle de la Théorie du Changement sont-elles applicables ? **(3) Suivi technique et organisationnel** : Comment gérer des données hétérogènes de diverses institutions via un data warehouse sémantique ? Quels mécanismes d'interopérabilité et de gouvernance de données assurent une coordination efficace tout en respectant les spécificités institutionnelles ?

## **4. Actions réalisées**

Notre initiative s'aligne avec le collectif universitaire européen, UNITA - Universitas Montium, qui regroupe 12 établissements académiques dédiés à la poursuite d'objectifs communs. Cette alliance sert de terrain d'essai, mettant en avant les obstacles que doivent surmonter les universités européennes — et plus largement, les

méta-organisations — pour évaluer leur impact sociétal. Notre stratégie repose sur un cadre pluridimensionnel qui aide les méta-organisations comme UNITA à mesurer leur influence grâce à des méthodologies basées sur les données et des outils analytiques. Notre méthode se déploie en trois étapes distinctes : **(1) Discussion** : Déterminer les besoins spécifiques de chaque membre. **(2) Évaluation** : Valider l'adéquation et la fiabilité des indicateurs clés. **(3) Construction** : Intégrer les données validées dans un Entrepôt de Données (DW). Au cours de cette première année, nous avons adopté une méthodologie organisée pour rassembler les indicateurs et les besoins spécifiques aux différents travaux de l'alliance UNITA. Par le biais d'entretiens collaboratifs, nous avons dressé et approuvé une liste d'indicateurs clés. Après validation, chaque indicateur est prêt à être collecté auprès des institutions membres pour initier les analyses telles que l'élaboration de rapports et la prévision de l'impact.

## 5. Actions futures

Nous implémentons actuellement les indicateurs recueillis lors des interviews. Avec les données obtenues, nous avons une vision des sources de données d'où nous pouvons extraire les informations nécessaires au calcul des indicateurs sélectionnés par les différentes tâches du projet. L'implémentation se fait en plusieurs étapes. La première consiste à fournir une entrée utilisateur directe pour la saisie d'indicateurs bruts calculés manuellement. Cette initiale implémentation permet de commencer le suivi le plus tôt possible pendant la mise en place du processus et du pipeline de données. Parallèlement, l'utilisation de la Narration du Changement nous permettra de débiter l'étude d'impact le temps qu'un ensemble significatif de données ait pu être collecté. Cette narration permet d'interpréter les perspectives de chaque tâche sur leur environnement au niveau du projet, de l'alliance et de l'environnement de chaque institution de l'alliance.

## 6. Bibliographie

- Lewin K., "Frontiers in group dynamics: concept, method and reality in social science; social equilibria and social change", *Human Relations*, vol. 1, p. 5–41, 1947. Place: US Publisher: Sage Publications.
- Lippitt R., *The Dynamics of Planned Change: A Comparative Study of Principles and Techniques*, Harcourt, Brace, 1958. Google-Books-ID: NYBqAAAAMAAJ.
- OECD, *Quality Standards for Development Evaluation*, Organisation for Economic Co-operation and Development, Paris, 2010.
- Peersman G., Rogers P., Guijt I., Hearn S., Pasanen T., Buffardi A. L., "When and how to develop an impact-oriented monitoring and evaluation system", 2016.
- Prochaska J. O., DiClemente C. C., "Stages and processes of self-change of smoking: Toward an integrative model of change", *Journal of Consulting and Clinical Psychology*, vol. 51, n° 3, p. 390–395, 1983. Place: US Publisher: American Psychological Association.

---

# Prédiction d'expressions torturées dans des articles scientifiques : modélisation par masquage

**Alexandre Clause**

*Université de Toulouse  
Institut de recherche en informatique de Toulouse (IRIT UMR 5505)  
118 route de Narbonne  
31062 TOULOUSE CEDEX 9  
alexandre.clause@univ-tlse3.fr*

---

*RÉSUMÉ : La littérature scientifique est polluée par des articles non fiables, dont certains contiennent des expressions torturées. Ce sont des traces de dissimulation de plagiat caractéristique du recours aux « moulins à papiers ». En 2021, le Problematic Paper Screener a été mis en place afin de permettre une réévaluation post publication de ces contenus. En parallèle, des solutions de détection automatique de textes générés et reformulés ont été développées. Nous nous intéressons aux approches de modélisation de texte, qui permettent la prédiction de contenu, et proposons d'étendre les solutions existantes par l'utilisation de divers (grands) modèles de langue sur un corpus de paires de phrases reformulées. Les résultats de détection par terme et par agrégation en groupes de termes soulignent la difficulté pour les modèles à distinguer les bouts d'expressions torturés de ceux légitimes. Nos recherches futures consisteront à tester d'autres modèles, puis à retrouver le texte source d'une reformulation, par l'utilisation d'un dictionnaire inversé.*

*MOTS-CLÉS : Recherche d'information, fouille de texte, expression torturée, plagiat, intégrité scientifique.*

*ENCADREMENT : Guillaume Cabanac, Pascal Cuxac, Cyril Labbé.*

---

## 1. Contexte

La recherche scientifique est un processus fondamental pour créer de la connaissance, généralement compilée au sein d'un article. Ces articles sont publiés après une évaluation par les pairs, garantissant une validation par la communauté scientifique avant communication. Pourtant, la littérature scientifique est polluée : elle contient des articles non fiables qui nourrissent un manque de confiance à l'égard de la recherche (Van Noorden, 2023). Cela est principalement dû aux méconduites de recherche, utilisées par un petit nombre de personnes peu scrupuleuses qui manipulent les indicateurs d'évaluation scientométriques tels que l'indice de Hirsch, afin de stimuler leur carrière. Ces personnes achètent les services de « moulins à papiers » (Parker *et al.*, 2024) : des entreprises vendant des articles fabriqués, proposant de manipuler des indicateurs d'évaluation, notamment en mettant en place des cartels de citation et en compromettant plusieurs comités éditoriaux. Certains de ces articles fabriqués contiennent du texte plagié depuis d'autres articles légitimes, reformulé par des outils de reformulation tels que SpinBot<sup>1</sup>. Une telle tentative de tromperie se traduit par la présence d'expressions torturées (Cabanac *et al.*, 2021) : des concepts scientifiques établis dans une discipline donnée, dont au moins l'un des termes a été remplacé, et qui ne font pas de sens. Par exemple, le terme « organisation cérébrale convolutive » au lieu de « réseau de neurones convolutif » n'a pas de sens en informatique. Ces contenus échappent à la vigilance de certains comités éditoriaux et sont publiés tels quels. Il est nécessaire de produire une brique de filtrage à utiliser dans les processus éditoriaux, en amont de la publication de tout manuscrit.

## 2. Solutions existantes

Depuis 2017, diverses solutions de détection automatique de contenu reformulé ont été proposées, au sein de deux approches de traitement automatique des langues : par apprentissage machine et par statistiques sur les termes. Pourtant, ces approches sont limitées par l'utilisation de corpora déséquilibrés d'articles scientifiques, journalistiques, et venant de Wikipédia ; ne se focalisant pas spécifiquement sur les expressions torturées. En 2019, Gehrmann *et al.* (2019) ont développé GLTR (*Giant Language model Test Room*) : un outil qui permet la détection statistique visuelle de contenu reformulé par l'utilisation de modèles de langue. Ils ont réussi à distinguer le contenu généré du contenu rédigé grâce au rang du terme suivant (*next-word rank*). Plus tard, Lay *et al.* (2022), puis Martel *et al.* (2023), ont émis l'hypothèse que la similarité mesurée entre les termes d'une expression torturée serait différente de celle mesurée entre les termes d'une expression légitime. Ils ont testé cette hypothèse en utilisant la probabilité d'occurrence du modèle de langue BERT avec GLTR (mesure d'entropie et rang de prédiction). Ils ont obtenu une similarité cosinus permettant de distinguer les différentes expressions : légitimes ou torturées. Alternativement, une approche par évaluation par les pairs post-publication a été mise en place en 2021.

---

1. <https://spinbot.com>

Elle consiste en l'utilisation du Problematic Paper Screener (Cabanac *et al.*, 2022, (PPS)) pour filtrer les articles problématiques en fonction d'un certain nombre de caractéristiques (dont la présence d'expressions torturées), et en commenter le contenu sur PubPeer (Barbour *et al.*, 2020). Les expressions torturées nouvellement détectées alimentent une base de données utilisée par le détecteur « *tortured* » du PPS. Actuellement, l'identification manuelle d'expressions torturées est assez coûteuse, elle nécessite l'implication d'experts hautement qualifiés.

### 3. Problématique

Nous nous intéressons aux résultats obtenus par Martel *et al.* (2023), qui soulignent la possibilité pour les modèles de langue à vecteurs fixe de détecter des bouts de phrases comme torturés ou légitimes. Pour l'instant, cette évaluation propage la prédiction d'un terme torturé à l'ensemble de l'expression ; seul le modèle BERT a été testé. Même si la similarité cosinus entre les termes torturés et légitimes est moins proche qu'avec d'autres modèles, les prédictions de BERT pour ces termes restent trop similaires, ce qui empêche une nette distinction des termes. Nous souhaitons étendre cette approche par masquage en utilisant divers modèles de langues et grands modèles de langue afin d'évaluer leur différence en matière de prédiction, et de définir un meilleur détecteur d'expressions torturées.

### 4. Contribution

Nous avons mis à jour le code de GLTR afin d'assurer son fonctionnement avec les modèles SciBERT, ScholarBERT, LongFormer, Galactica, Mitral, Gemma et Llama. Pour cela, nous avons testé leurs prédictions sur le jeu de données de Martel *et al.* (2023). Ce jeu de données contient 100 paires de phrases reformulées, dont les termes torturés ont déjà été annotés. Nous l'avons enrichi avec 130 paires de phrases supplémentaires, extraites d'articles problématiques détectés par le PPS ; ce qui nous a permis de trouver 15 nouvelles expressions torturées à rajouter dans la base de données du PPS. Nous avons mis en place une chaîne de traitements qui consiste en (1) débruiter les données, (2) calculer les prédictions des termes par masquage, (3) regrouper les termes et (4) agréger les prédictions par groupes nominaux. Les fonctions d'agrégation testées sont la moyenne, le minimum, le maximum, la première valeur, la dernière valeur, les quartiles, la somme et le produit. Les résultats obtenus pour ces modèles sont similaires : les distributions des prédictions par terme (étape 2 de la chaîne de traitement) et des prédictions par groupes nominaux (étapes 3 et 4 de la chaîne de traitement) se superposent. Par conséquent, ils ne permettent pas de différencier les paires de phrases traitées. Ces résultats soulignent la difficulté pour les modèles de langue testés à modéliser la différence de signification entre les bouts de phrases torturés et légitimes.

## 5. Recherches futures

Nos recherches futures sont articulées autour de deux axes. Nous testerons d'autres modèles de langues et méthodes d'agrégation des prédictions, que nous chercherons à spécialiser. Une fois une distinction établie, nous mettrons en place un dictionnaire inversé avec BabelNet et le moteur de recherche bibliométrique Dimensions<sup>2</sup> afin de retrouver le potentiel texte source de reformulation.

## 6. Bibliographie

- Barbour B., Stell B., "PubPeer: Scientific Assessment Without Metrics", in M. Biagioli, A. Lippman (éd.), *Gaming the Metrics: Misconduct and Manipulation in Academic Research*, The MIT Press, p. 149–155, 2020. DOI: <https://doi.org/10.7551/mitpress/11087.003.0015>.
- Cabanac G., Labbé C., Magazinov A., "Tortured phrases: A dubious writing style emerging in science. Evidence of critical issues affecting established journals", 2021. *arXiv preprint*. DOI: <https://doi.org/10.48550/arXiv.2107.06751>.
- Cabanac G., Labbé C., Magazinov A., "The 'Problematic Paper Screener' automatically selects suspect publications for post-publication (re)assessment", 2022. Presented at WCRI 2022: 7th World Conference on Research Integrity. *arXiv preprint*. DOI: <https://doi.org/10.48550/arXiv.2210.04895>.
- Gehrmann S., Strobel H., Rush A., "GLTR: Statistical Detection and Visualization of Generated Text", in M.-R. Costa-Jussà, E. Alfonseca (éd.), *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics: System Demonstrations*, Association for Computational Linguistics, Kerrville, Texas, p. 111–116, 2019. DOI: <https://doi.org/10.18653/v1/P19-3019>.
- Lay P., Lentschat M., Labbé C., "Investigating the Detection of Tortured Phrases in Scientific Literature", in A. Cohan, G. Feigenblat, D. Freitag, T. Ghosal, D. Herrmannova, P. Knoth, K. Lo, P. Mayr, M. Shmueli-Scheuer, A. de Waard, L.-L. Wang (éd.), *Proceedings of the Third Workshop on Scholarly Document Processing*, Association for Computational Linguistics (ACL), Kerrville, Texas, p. 32–36, 2022. URL: <https://aclanthology.org/2022.sdp-1.4>.
- Martel E., Lentschat M., Labbé C., "Detection of Tortured Phrases in Scientific Literature", in T. Ghosal, F. Grezes, T. Allen, K. Lockhart, A. Accomazzi, S. Blanco-Cuaresma (éd.), *Proceedings of the Second Workshop on Information Extraction from Scientific Publications*, Association for Computational Linguistics (ACL), Kerrville, Texas, p. 43–48, 2023. DOI: <https://doi.org/10.18653/v1/2023.wi esp-1.6>.
- Parker L., Boughton S., Bero L., Byrne J.-A., "Paper mill challenges: past, present, and future", *Journal of Clinical Epidemiology*, vol. 176, p. 111549, 2024. DOI: <https://doi.org/10.1016/j.jclinepi.2024.111549>.
- Van Noorden R., "How Big Is Science's Fake-Paper Problem?", *Nature*, vol. 623, n° 7987, p. 466–467, 2023. DOI: <https://doi.org/10.1038/d41586-023-03464-x>.

---

2. <https://app.dimensions.ai>

---

# Approches d'Extraction et de Structuration des Manuels Scolaires

**LASHEB Mohamed Amine**

*Laboratoire Cedric, Conservatoire national des Arts et Métiers  
2, rue Conté, 75003, Paris, France  
mohamed-amine.lasheb@lecnam.net*

---

*MOTS-CLÉS : Accessibilité, Manuels scolaires, Vision par ordinateur, Modèles de langage, Inclusion scolaire, Extraction de contenu.*

*RÉSUMÉ : Les manuels scolaires sont essentiels pour l'apprentissage, et leur accessibilité est cruciale pour inclure les élèves en situation de handicap. Notre projet à long terme vise à automatiser l'adaptation de ces manuels. Cet article présente différentes approches d'extraction et de structuration des contenus, en utilisant des techniques de vision par ordinateur et des modèles de langage. Les résultats montrent une précision élevée, soulignant le potentiel de ces technologies pour améliorer l'accessibilité des ressources pédagogiques et soutenir une éducation inclusive.*

*ENCADREMENT. Olivier Pons*

---

## 1. Introduction : Contexte et enjeux de l'accessibilité éducative

L'article L. 111-1 du code de l'éducation souligne l'importance de l'inclusion scolaire. Cependant, la structure complexe des manuels scolaires pose des défis pour leur adaptation aux élèves en situation de handicap, rendant l'extraction automatisée de contenu une étape cruciale pour les rendre accessibles.

Ce travail explore des approches pour automatiser cette extraction, permettant une représentation organisée des éléments des manuels. Une fois extraits et structurés, les exercices sont classifiés et adaptés (Figure 1), puis publiés sur une plateforme dédiée. Celle-ci permet de fournir aux élèves en situation de handicap des exercices adaptés à divers modes d'accès (visuel, tactile, suivi oculaire, etc.). Cette automatisation vise une éducation équitable pour tous les élèves.




Figure 1: Exemple d'adaptation d'exercice

## 2. Travaux antérieurs et limites des approches existantes

L'analyse et la structuration de documents sont un domaine de recherche actif. Si des modèles comme BERT [1] et RoBERTa [2] sont efficaces pour le traitement du langage naturel et des outils comme Tesseract pour l'OCR, peu de travaux se concentrent spécifiquement sur l'amélioration de l'accessibilité des manuels scolaires.

Lincker et al. [3] ont proposé une approche pertinente, basée sur des modèles de mise en page et d'activités pédagogiques pour structurer les manuels scolaires en PDF. Leur méthode utilise des transformateurs multimodaux pour normaliser et organiser le contenu, visant des formats accessibles comme TEI et DocBook. Cependant, bien que précise sur des manuels d'une même collection, la performance chute significativement d'une collection à l'autre en raison des variations de mise en page. De plus, cette approche est limitée aux PDF natifs et ne gère pas les PDF scannés.

Au-delà de ce travail spécifique, les méthodes antérieures basées sur des modèles de langue ou des architectures multimodales présentent souvent une faible capacité de généralisation face aux diverses structures de manuels. L'annotation manuelle, étape coûteuse en temps, reste complexe, notamment pour associer correctement texte et éléments visuels d'un exercice. Un autre défi réside dans les erreurs volontaires intégrées à certains exercices pédagogiques, qui peuvent perturber les modèles purement linguistiques. Enfin, les modèles entraînés sur des corpus généralistes comme PubLayNet [4] ou DocBank [5] ne sont pas adaptés à notre besoin, car ils se concentrent principalement sur des éléments typographiques simples tels que (titre, tableau, numéro) et non les classes sémantiques fonctionnelles essentielles pour l'adaptation (consignes, énoncés, exemples, etc.). Ces limitations justifient l'exploration d'approches plus robustes comme la vision par ordinateur pour notre cas d'usage.

## 3. Approche basée sur la vision par ordinateur et complémentarité des LLMs

Pour surmonter ces limites, nous avons exploré des modèles de vision par ordinateur (LayoutParser, Detectron2, YOLO [6, 7, 8]), privilégiant YOLO pour sa robustesse face aux variations de mise en page, aux éléments graphiques, et sa capacité à traiter les PDF natifs comme scannés.

Notre jeu de données comprend 22 manuels scolaires français (primaire, diverses matières), moitié scannés, moitié natifs. Pour l'entraînement, les PDF natifs ont été

convertis en images. Environ 40-50 pages par manuel ont été annotées pour garantir une diversité structurelle tout en évitant un surapprentissage spécifique à un format.

Le processus d'extraction (Figure 2) commence par la détection des zones d'exercices, puis analyse le format de page (mono/multi-colonnes) et identifie les éléments spécifiques (consignes, énoncés, numéros, titres, etc.). Une vérification d'appartenance lie les éléments aux exercices. Le texte est extrait via OCR (scannés) ou PDFAlto (natifs) et associé aux éléments détectés. Le contenu est finalement organisé en JSON structuré.

Bien que la vision par ordinateur soit performante, l'utilisation de grands modèles de langage (LLMs) comme Gemini et Mistral améliore actuellement la précision de l'extraction textuelle et la structuration logique, surtout pour les manuels français. Ils affinent les résultats en vérifiant la cohérence sémantique et en tenant compte des spécificités linguistiques. Cependant, leur efficacité diminue face aux variations linguistiques et culturelles internationales.

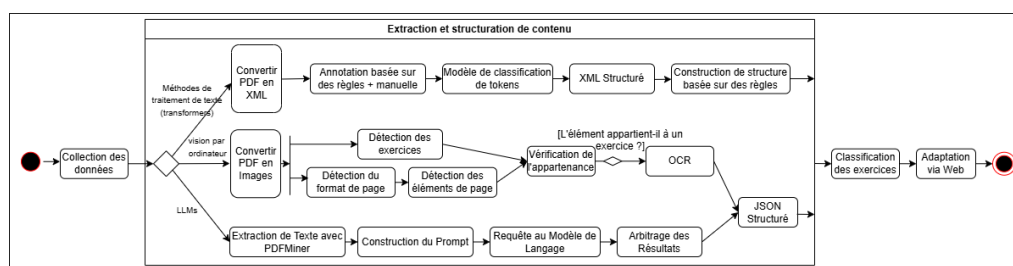


Figure 2: Pipeline global d'adaptation

#### 4. Synthèse des résultats et orientations futures

Les résultats de nos expérimentations confirment le potentiel de la vision par ordinateur pour l'analyse des manuels scolaires, YOLOv10x atteignant 97,8 % de précision pour la détection des exercices et 98 % pour l'identification du format de page. Les performances par classe sémantique sont détaillées dans le Tableau 1.

Modèle	Titres	Cons.	Énon.	Num.	Indic.	Conseils	Ex.	Cours
YOLO	97,7%	81,1%	83,7%	92,2%	82,4%	92,3%	53,8%	41,8%
LayoutParser	29,8%	23,5%	9,8%	46,1%	35,9%	47,5%	10,8%	6,3%
Detectron2	24,8%	22,7%	8,3%	45,9%	38,5%	0,1%	1,7%	7,2%

Tableau 1: Scores mAP@0.5 par classe sémantique pour chaque modèle

Notre travail s'est principalement concentré sur les exercices, car ils sont cruciaux pour l'interaction des élèves dans le cadre de l'adaptation, les cours et exemples restant inchangés et donc non prioritaires pour notre attention. Les variations (mise en forme, qualité de scan, taille/composition des exercices, langue) restent des défis majeurs

pour tous les modèles testés, influencent significativement les performances. De plus, les incohérences entre annotations manuelles et automatiques (marges, précision) constituent une source d'erreur, même pour YOLOv10x, soulignant le besoin de méthodes d'annotation semi-automatiques plus cohérentes et robustes.

Nos travaux futurs étendront l'approche à d'autres disciplines (mathématiques, géographie) et langues (arabe, roumain, anglais), présentant des défis spécifiques (orientation du texte, diversité des scripts, structures pédagogiques). Nous avons commencé à collecter ces données. Nous explorerons aussi l'application de nos stratégies d'extraction/structuration à d'autres types de documents patrimoniaux (CNUM, Gallica, OldNews, Library of Congress incl. Chronicling America), cruciaux pour la préservation et l'accessibilité dans un cadre éducatif et scientifique. Le pipeline développé sera mis en ligne sur nos ressources, accessible aux institutions intéressées sans exigence matérielle particulière.

## References

- [1] Jacob Devlin et al. "BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding". *arXiv preprint arXiv:1810.04805* (2018).
- [2] Yinhan Liu et al. "RoBERTa: A Robustly Optimized BERT Pretraining Approach". *arXiv preprint arXiv:1907.11692* (2019).
- [3] Élise Lincker et al. "Layout- and Activity-based Textbook Modeling for Automatic PDF Textbook Extraction". *AIED*. 2023, pp. 37–53.
- [4] Xu Zhong et al. *PubLayNet: largest dataset ever for document layout analysis*. 2019.
- [5] Minghao Li et al. *DocBank: A Benchmark Dataset for Document Layout Analysis*. 2020.
- [6] Zejiang Shen et al. *LayoutParser: A Unified Toolkit for Deep Learning Based Document Image Analysis*. 2021.
- [7] Yuxin Wu et al. *Detectron2*. 2019.
- [8] Joseph Redmon et al. *You Only Look Once: Unified, Real-Time Object Detection*. 2016.

---

# Maîtrise du cycle de vie des données au sein des systèmes d'information éco-responsables

**Kyllian BÉGUIN**

*Univ. Grenoble Alpes, CNRS, Grenoble INP, LIG  
Bâtiment IMAG 150 Pl. du Torrent, 38400 Saint-Martin-d'Hères, France*

*Néosoft Services  
37 Bd. Solférino, 35000 Rennes, France*

*kyllian.beguin@univ-grenoble-alpes.fr*

---

*RÉSUMÉ. Les enjeux environnementaux nous incite à réduire les impacts négatifs de nos activités, dont notre usage du numérique. Cette réduction porte principalement sur la diminution de la consommation des services numériques et des infrastructures informatiques. Au sein des organisations, les données suivent des cycles de vie allant de leur production à leur éventuelle destruction. Le volume total de données serait amené à croître fortement dans les prochaines années. Or, un volume croissant de données nécessite, à terme, l'extension de l'infrastructure informatique. Bien que faisable aujourd'hui, une telle extension n'est pas une approche durable. De plus, cela ne remet pas en question la nécessité d'un volume croissant de données. Une organisation ne peut répondre à cette question si elle s'éloigne de la maîtrise du cycle de vie de ses données. Nos recherches portent sur la proposition d'une méthode permettant de cartographier les cycles de vie des données en prenant en compte le contexte, la finalité et les patrons d'architecture. L'objectif est de mieux analyser et quantifier les impacts environnementaux des phases du cycle de vie afin d'identifier des leviers d'action pour réduire ces impacts.*

*MOTS-CLÉS. Système d'information, Données, Éco-responsabilité*

*ENCADREMENT. LIG : Claudia Roncancio et Mario Cortes-Cornax; Néosoft : Nicolas Huche*

---

## 1. Contexte : sur-production de données et impacts environnementaux

Selon Freitag *et al.* (2021), le secteur des technologies de l'information et de la communication aurait été responsable de 2,1 à 3,9% des émissions de gaz à effet de

serre en 2020. La prise de conscience de ces impacts négatifs est particulièrement importante vu que la tendance est à la hausse. En France, le Référentiel par Catégorie de Produit (RCP) des Systèmes d'Information (SI) (ADEME, 2024) montre une prise de conscience par les autorités des coûts environnementaux des SI.

Les SI permettent aux organisations de mettre en œuvre et de pérenniser leurs activités ainsi que prendre des décisions pour l'avenir. Leur architecture de données peut ainsi être définie comme un ensemble de règles, processus et logiciels (Van Den Hoven, 2003). Les données passeront par plusieurs étapes et traitements, allant de leur production à leur éventuelle destruction. C'est ce que l'on appelle le cycle de vie des données.

D'après Statista (2024), le volume de données générées en 2028 pourrait atteindre 394 zettaoctets, soit environ 300% plus qu'en 2023. Une des causes de cette croissance serait la difficulté de la gestion de la fin de vie des données au sein des organisations. La suppression des données pourrait être perçue comme une erreur de jugement de leur valeur. La valeur d'une donnée étant directement liée à un objectif à un moment donné.

Or, un volume croissant de données nécessite, à terme, l'extension de l'infrastructure informatique (e.g. plus d'espace de stockage ou de serveurs). Le problème de cette extension est que, bien que faisable aujourd'hui, elle augmente les coûts environnementaux et n'est pas une approche durable. De plus, elle ne remet pas en question la nécessité du volume croissant de données. Une organisation ne peut répondre à cette question si elle s'éloigne de la maîtrise du cycle de vie de ses données. Par exemple, ne pas maîtriser la répllication des données ou encore les stratégies de collecte. Au même titre qu'il est important d'analyser les impacts environnementaux des services numériques ou encore les systèmes cyber-physiques (Schöllhammer *et al.*, 2024), il semble tout autant nécessaire d'analyser les impacts des données avec des méthodologies robustes.

L'objectif global de cette thèse est de proposer une méthode permettant de "cartographier" les différents cycles de vie des données en fonction du contexte de leur utilisation, de leur finalité et des patrons d'architecture retenus afin d'analyser leurs impacts environnementaux et d'identifier les leviers de réduction.

## **2. État de l'art : Impacts environnementaux liés à la gestion des données**

L'Analyse de Cycle de Vie (ACV) (ISO/TC 207/SC 5, 2006), est une méthodologie d'analyse des impacts environnementaux d'un produit ou service. Cette méthodologie, largement reconnue, n'est pas spécifique au numérique mais est particulièrement intéressante. Elle préconise l'étude de toutes les phases du cycle de vie, de plusieurs critères environnementaux (e.g. l'émission de radiations ionisantes, la toxicité humaine, l'acidification des sols) et d'une Unité Fonctionnelle (UF). Selon Hauschild *et al.* (2018), l'UF "défini les aspects quantitatifs et qualitatifs d'une fonction exercée par le produit ou service".

Certains travaux analysent des phases du cycle de vie des données. Le stockage est la phase suscitant le plus d'intérêt. Par exemple, Charret *et al.* (2020) ont analysé trois plateformes de stockage. L'étude comprend un périmètre large, incluant notamment le bâtiment et les déplacements des employés. L'étude suit une approche ACV mais se focalise sur l'empreinte équivalent  $CO_2$ . Les résultats ont permis de dresser un ensemble de recommandations permettant de réduire cette empreinte.

Plusieurs phases du cycle de vie des données sont centralisées dans des lacs de données. Le lac de données AUDAL<sup>1</sup> est étudié dans Alvarez-Valera *et al.* (2024). La consommation en énergie des 8 processus opérant sur les données et métadonnées est mesurée. La granularité de la mesure ira ici jusqu'au composant physique (e.g. CPU, RAM). Les résultats démontrent une hétérogénéité de la consommation pour les composants entre les opérations. Cette étude porte sur la phase d'utilisation du lac de données et non sur une ACV complète. Il est également nécessaire d'inclure l'infrastructure physique qui héberge AUDAL dans l'étude.

Certains travaux s'intéressent aussi à la phase de collecte des données. Cortes-Cornax *et al.* (2023) étudie des systèmes cyber-physiques où la collecte de données implique l'introduction de capteurs et dispositifs dédiés. Les impacts environnementaux de ces dispositifs sont un enjeu de taille vu la tendance croissante de l'Internet des objets.

Ces travaux, parmi d'autres, se concentrent sur certaines des phases du cycle de vie des données. Analyser et quantifier les impacts de toutes les phases peut donner une vue plus systémique et aider à dégager des leviers d'action pour minimiser ces impacts. Une organisation pourrait, par exemple, revoir à la baisse le dimensionnement de son infrastructure informatique ou réduire la consommation électrique de certaines phases.

### 3. Problématiques

Dans le cadre de cette thèse CIFRE, nous nous intéressons aux questions de recherche suivantes, tout en nous focalisant sur le cycle de vie des données dans le système d'information :

– Comment caractériser et modéliser les impacts environnementaux des données dans différentes architectures ? Il n'existe pas une architecture unique de gestion des données. Est-il nécessaire de disposer des mêmes caractéristiques et modèles pour ces différentes architectures ?

– Quels aspects sont prioritaires dans la définition des UFs à analyser ? Définir une UF est complexe quand il s'agit de gestion de données. Des paramètres sont à prendre en compte, comme : l'objet d'étude, les exigences de la fonction, la temporalité.

– Quels mécanismes peuvent être activés pour réduire les impacts environnementaux en prenant en compte des possibles effets rebonds ?

---

1. <https://github.com/Pegdewende44/AUDAL>

#### 4. Travaux en cours et perspectives de recherche

Cette thèse est encore à ses débuts. Nous faisons l'état de l'art sur les impacts environnementaux du numérique, notamment l'ACV de services numériques. Cette méta-analyse nous a permis de dresser un ensemble de considérations pour la conduite d'une telle étude. Certains aspects sont à reconsidérer à l'égard de notre objet d'étude qui est le cycle de vie des données d'un système d'information.

Nous travaillons à la caractérisation des outils disponibles pour réaliser l'inventaire de cycle de vie d'un service numérique. Les premiers résultats tendent à montrer une bonne couverture des principaux impacts environnementaux. Cette taxonomie d'outils permet également d'identifier une granularité des objets d'études.

Par la suite, nous identifierons des SI de référence afin d'obtenir une caractérisation des données et une abstraction de leur cycle de vie. Nous poursuivrons nos travaux par la définition des UFs et le cadrage des études ACV. Enfin, nous formaliserons une méthodologie de diagnostic environnemental des systèmes d'information. Cette méthodologie sera testée dans des contextes clients Néosoft.

#### 5. Bibliographie

- ADEME, "Référentiel par Catégorie de Produit (RCP) des Systèmes d'Information", 2024.
- Alvarez-Valera H. H., Maurice A., Ravat F., Song J., Roose P., Valles-Parlangeau N., "Energy Measurement System for Data Lake: An Initial Approach", *Intelligent Information and Database Systems*, vol. 14795, Springer Nature Singapore, p. 15–27, 2024.
- Charret G., Arnaud A., Berthoud F., Bzeznik B., Defize A., Delay Y., Drago F., Feltin G., Gibelin N., Guennebaud G., Marchal W., Estimation de l'empreinte carbone du stockage de données, Research Report, CNRS - GRICAD, 2020.
- Cortes-Cornax M., Lago P., Roncancio C., "A case study of environmental considerations and opportunities in cyber physical systems", *IET Softw.*, vol. 17, n° 4, p. 424–434, 2023.
- Freitag C., Berners-Lee M., Widdicks K., Knowles B., Blair G., Friday A., "The climate impact of ICT: A review of estimates, trends and regulations", 2021.
- Hauschild M. Z., Rosenbaum R. K., Olsen S. I., *Life Cycle Assessment: Theory and Practice*, Springer International Publishing, 2018.
- ISO/TC 207/SC 5, "Environmental management — Life cycle assessment — Principles and framework", 2006.
- Schöllhammer F., Cortes-Cornax M., Lago P., Ramautar V., Roncancio C., Overbeek S., España S., "Method and Tool to Assess the Environmental Impacts of Cyber-Physical Systems with a Life-Cycle Approach", *CEUR Proc. RCIS WS and Research Projects*, vol. 3674, 2024.
- Statista, "Volume of data/information created, captured, copied, and consumed worldwide from 2010 to 2023, with forecasts from 2024 to 2028", 2024.
- Van Den Hoven J., "Data Architecture: Blueprints for Data", *Information Systems Management*, vol. 20, n° 1, p. 90–92, 2003.

---

# Managing Fragmented Temporal Graphs for Scalable Cyber Threat Detection

**Marwa ALALI**

*LIRMM, Univ Montpellier, CNRS, Montpellier, France*

*marwa.alali@lirmm.fr*

---

*MOTS-CLÉS : Graph de connaissances temporels, propagation des croyances, suivi des graphiques historiques, détection des relations, intégration de graphiques.*

*KEYWORDS: Temporal knowledge graphs, Belief propagation, Historical graph tracking, Relationship detection, Graph integration.*

*ENCADREMENT: Anne LAURENT, Arnaud CASTELLTORT and Sebastian CESARIO*

---

## 1. Context

Graphs are a core data model for capturing complex relationships in big data applications (Han et al., 2018). Detecting malicious newly registered domains (NRDs) in today's dynamic cyber landscape requires real-time large-scale data analysis, where domain graphs have proven effective (Manadhata et al., 2014). However, in our current system, approximately 400 isolated graphs are generated daily each corresponding to a separate processing instance without integration into a unified knowledge structure. This results in both spatial and temporal fragmentation, weakening connections between domains and preventing the detection of cross-graph relationships or historical trends. Such fragmentation significantly impacts analytical accuracy; applying Belief Propagation (BP) on these disconnected graphs leads to high false positive rates, as weak or irrelevant associations dominate the results (Khalil et al., 2018). Additionally, the system currently relies on active DNS (Domain Name System) data, which offers only point-in-time snapshots and lacks historical context, further limiting the ability to build rich, connected graphs (Khalil et al., 2018). Prior research has demonstrated the value of integrating historical data sources. For example, (Khalil et al., 2016) showed that combining passive DNS data with other network and application data can

achieve over 95% true positive rates while maintaining false positives below 0.5%. Passive DNS data, containing historical records of both current and obsolete domains, significantly enhances the detection of meaningful relationships. Similarly, (Nabeel et al., 2020) emphasized the role of passive DNS as a critical resource for identifying and mitigating malicious online activities. In our approach, we leverage ground truth (GT) data comprising labeled malicious and benign domains to apply BP and assess the threat level of newly registered domains (NRDs). BP operates over the network structure, passing the knowledge from GT to NRD and assigning each NRD a score indicating its likelihood of being malicious. This paper begins by outlining the current challenges and problem statement, reviews related literature, presents our proposed methodology, and concludes with the future research directions.

## 2. Current Process Challenges

The current system generates 400 isolated subgraphs daily, lacking integration and resulting in severe fragmentation. This separation obscures cross-domain relationships and prevents comprehensive analysis. Each day’s data remains spatially and temporally disconnected, hindering the detection of historical trends and evolving patterns. Consequently, belief propagation operates without global context, increasing false positives and negatives. Additionally, DNS data is limited to point-in-time snapshots, restricting longitudinal insights. As illustrated in Figure 1, each process handles its own isolated graph, unaware of others, further amplifying the absence of temporal and structural continuity.

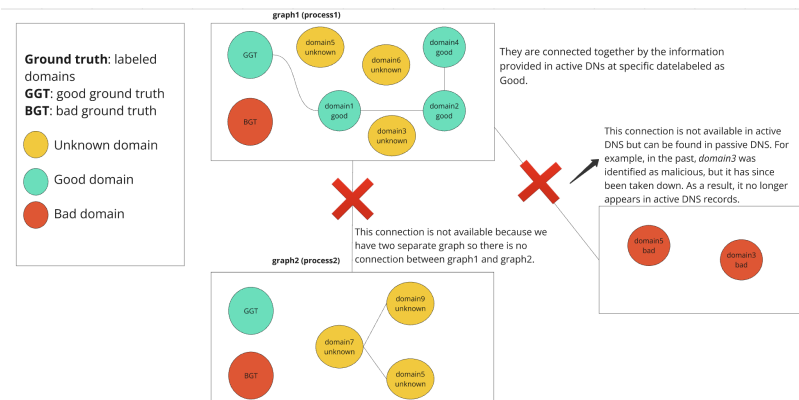


Figure 1: Illustration of Subgraph Isolation and Fragmentation Challenges

## 3. Research problem statement

The current domain graph system, characterized by isolated temporal subgraphs, poses significant challenges for accurate relationship detection and limits the effectiveness of Belief Propagation (BP). This research primarily addresses the question of how

to effectively integrate information across these temporally disconnected subgraphs to enhance BP performance and reduce false positive and negative rates. To systematically explore this, the study focuses on three key aspects: quantifying the reduction in false positive rates achieved through integration, analyzing the influence of previously unobserved cross-subgraph relationships on BP accuracy, and determining the optimal temporal and structural boundaries for belief propagation to balance accuracy with computational efficiency.

#### 4. Relevant Literature

This section reviews the state-of-the-art in temporal graphs and historical data management systems. (Kostakos, 2009) compared temporal graphs with traditional static graphs, highlighting how static models fail to capture dynamic processes over time. To overcome this, he introduced temporal graphs, emphasizing metrics like temporal proximity to analyze how quickly entities, such as domains connecting to multiple IPs, evolve potentially signaling malicious behavior. (Han et al., 2018) proposed a novel temporal graph management system that organizes data into spatio-temporal chunks, improving query efficiency while minimizing space overhead. Benchmarking against DeltaGraph, Neo4j, PostgreSQL, and HBase demonstrated that their system, Auxo, consistently outperforms these solutions due to reduced disk access and optimized graph rearrangement (Han et al., 2018). Similarly, (Khurana et al., 2015) introduced the Historical Graph Store, featuring the Temporal Graph Index (TGI) for efficient storage using structured deltas and partitioning, and the Temporal Graph Analysis Framework (TAF) for scalable analysis using Spark. They also compared storage strategies Log, Copy, and a hybrid Copy+Log approach to balance storage efficiency and query performance (Khurana et al., 2015). Additionally, (Massri., 2020) provided a comprehensive comparison of various temporal graph models and management systems, summarized available at the following: <https://seafiler.lirmm.fr/f/ad91db5018ee46b2b866>.

#### 5. Proposed Methodology

Assuming that the high false positive rate stems mainly from graph fragmentation and lack of historical context, rather than limitations inherent to the Belief Propagation algorithm, we propose two key solutions. First, a Graph Integration Approach to merge daily subgraphs into a unified knowledge graph, preserving original connections while introducing cross-subgraph relationships to enable belief propagation over the entire integrated structure. Second, a Temporal Graph Management strategy to implement historical graph tracking and enrich the dataset by incorporating passive DNS data, thereby providing richer historical context and improving the accuracy of relationship detection.

## 6. Conclusion and Future Work

As the dataset grows daily and Belief Propagation (BP) is used to compute domain scores based on ground truth, it becomes essential to adopt an effective graph model that ensures strong connectivity, structural coherence, and availability of information over time. To achieve this, we propose creating a persistent graph database containing all ground truth data, including domain relationships. The chosen graph model will influence both the volume of scores derived from consolidated versus fragmented graphs and the efficiency of BP in propagating accurate scores. Our objective is to enhance Cyber Threat Intelligence (CTI) system performance by reducing false positives and negatives, while assessing knowledge graph models for scalability and efficiency. To validate the impact of graph integration, we will follow a systematic approach selecting representative samples, manually integrating them, conducting comparative and causal analyses, and applying statistical methods to confirm the significance of the improvements. This will provide empirical evidence of how integration strengthens BP accuracy and overall threat detection.

## Bibliographie

- Han W, Li K, Chen S, Chen W. "*Auxo: a temporal graph management system*", Big Data Mining and Analytics. 2018 Nov 18;2(1):58-71.
- Khalil IM, Guan B, Nabeel M, Yu T. "*A domain is only as good as its buddies: Detecting stealthy malicious domains via graph inference.*" In Proceedings of the Eighth ACM Conference on Data and Application Security and Privacy 2018 Mar 13 (pp. 330-341).
- Khalil I, Yu T, Guan B. "*Discovering malicious domains through passive DNS data graph analysis.*" In Proceedings of the 11th ACM on Asia Conference on Computer and Communications Security 2016 May 30 (pp. 663-674).
- Khurana U, Deshpande A. "*Storing and analyzing historical graph data at scale.*" arXiv preprint arXiv:1509.08960. 2015 Sep 29.
- Kostakos V. "*Temporal graphs.*" Physica A: Statistical Mechanics and its Applications. 2009 Mar 15;388(6):1007-23
- Massri, Maria. "*Designing a temporal graph management system for IoT application domains.*" PhD diss., Université de Rennes, 2022.
- Nabeel M, Khalil IM, Guan B, Yu T. "*Following passive DNS traces to detect stealthy malicious domains via graph inference.*" ACM Transactions on Privacy and Security (TOPS). 2020 Jul 6;23(4):1-36.
- Manadhata P, Yadav S, Rao P, Horne W. "*Detecting malicious domains via graph inference.*" In Proceedings of the 2014 Workshop on Artificial Intelligent and Security Workshop 2014 Nov 7 (pp. 59-60).

---

# Estimation de la qualité de vie en Corse

## à l'aide de techniques d'Intelligence Artificielle

**Ghinevra Comiti**

*UMR CNRS 6134 SPE, Université de Corse Pasquale Paoli  
7 Avenue Jean Nicoli  
20250 Corte  
comiti\_g@univ-corse.fr*

---

*MOTS-CLÉS : Apprentissage machine, Données, Qualité de vie*

*KEYWORDS: Machine Learning, Data, Quality of life*

*ENCADREMENT. Paul-Antoine Bisgambiglia (MCF) et Nathalie Lameta (MCF)*

---

### 1. Contexte

Ces travaux s'inscrivent dans le cadre de la Chaire Mutations et Innovations Territoriales de l'Université de Corse<sup>1</sup>. Ils adoptent une approche pluridisciplinaire, croisant sciences de gestion et informatique, afin d'apporter une contribution méthodologique et empirique à la mesure de la qualité de vie.

La mesure de la qualité de vie est un enjeu central pour l'analyse du développement territorial et l'élaboration des politiques publiques (Stiglitz *et al.*, 2009).

En Corse, territoire insulaire aux spécificités marquées, il est essentiel de disposer d'indicateurs adaptés pour évaluer objectivement les dynamiques locales. Cette recherche vise à construire et évaluer des indices de qualité de vie en s'appuyant sur des approches innovantes, combinant intelligence artificielle et exploitation de données hétérogènes, quantitatives et qualitatives.

L'objectif est de développer des outils analytiques permettant d'identifier la manière dont les habitants perçoivent les points forts et les fragilités des communes corses. En

---

1. <https://chaire-territoires.universita.corsica/>

mobilisant des algorithmes de traitement des données, ainsi que des analyses de ces dernières, nous cherchons à produire des indicateurs fiables et interprétables, utiles pour comprendre les perceptions des acteurs et orienter les choix stratégiques des acteurs publics.

## 2. État de l'art

La mesure de la qualité de vie est une problématique complexe et multidimensionnelle, mobilisant des approches variées principalement issues des sciences sociales et économiques. Traditionnellement, elle repose sur des indicateurs quantitatifs, comme le Produit Intérieur Brut (PIB) par habitant, ou l'Indice de Développement Humain (IDH) (Accardo, 2009). Toutefois, ces indicateurs économiques sont insuffisants pour refléter pleinement la qualité de vie des populations. Des approches plus intégratives ont émergé mais, la qualité de vie étant étroitement liée au territoire considéré, il nous paraissant important de définir un indice spécifique pour la région.

Dans ce contexte, le machine learning paraît être un outil pertinent. Son essor ouvre de nouvelles perspectives pour l'analyse et l'exploitation de données hétérogènes, combinant à la fois des sources quantitatives et qualitatives. Ces données, issues d'enquêtes ou de bases de données publiques, permettent d'affiner et d'enrichir les mesures de la qualité de vie en intégrant des dimensions plus complexes et diversifiées.

Les avancées récentes dans le domaine du traitement automatique du langage naturel (NLP), notamment avec l'émergence des modèles basés sur l'architecture Transformer (Vaswani *et al.*, 2017) et des variantes comme BERT (Devlin *et al.*, 2018), ont considérablement amélioré les capacités d'analyse des données textuelles. Ces modèles permettent d'extraire des informations pertinentes à partir de textes non structurés, facilitant ainsi l'exploitation des données qualitatives issues d'entretiens, ou de questions ouvertes. Toutefois, bien que ces avancées aient déjà montré leur efficacité, l'application des modèles de langage de grande taille (LLM) au traitement des données qualitatives reste un champ encore en pleine exploration, offrant des perspectives prometteuses (Ferreira Barros *et al.*, 2023).

En parallèle, L'essor du data mining et de l'apprentissage automatique transforme les méthodes d'analyse en sciences sociales. En complément des approches classiques, ces techniques permettent d'extraire des schémas et d'identifier des corrélations complexes au sein de vastes ensembles de données hétérogènes. Selon (Shu *et al.*, 2023), l'application du "Knowledge Discovery" en sciences sociales ne se limite pas à une simple recherche exploratoire, mais constitue un processus dialectique combinant approches déductives et inductives. En mobilisant des méthodes supervisées et non supervisées, telles que les arbres de décision, les réseaux de neurones et l'analyse des séquences, ces approches enrichissent la compréhension des phénomènes sociaux et économiques. Ainsi, dans l'étude de la qualité de vie, le recours à ces outils permettrait d'affiner la mesure des déterminants subjectifs et objectif.

### 3. Problématique

La création d'un indicateur de qualité de vie à l'aide de techniques de machine learning soulève plusieurs problématiques méthodologiques et épistémologiques. Tout d'abord, l'hétérogénéité des données mobilisées – mêlant sources quantitatives (statistiques socio-économiques, indicateurs de santé) et qualitatives (enquêtes, avis citoyens, contenus issus des réseaux sociaux) – nécessite le développement de méthodes analytiques adaptées capables de traiter ces différentes natures d'information de manière cohérente et intégrée. Ensuite, bien que le deep learning ait démontré son efficacité pour l'analyse des données numériques, l'exploitation des modèles de traitement du langage naturel (NLP), notamment les modèles de langage de grande taille (LLM), reste encore un champ en exploration pour l'analyse des données textuelles liées à la perception du bien-être et de la qualité de vie. Enfin, la question de l'interprétabilité des modèles prédictifs constitue un enjeu clé : un indicateur de qualité de vie doit être à la fois précis et explicable, afin d'être utilisé de manière pertinente par les décideurs et de refléter fidèlement les réalités vécues par les populations.

### 4. Actions réalisées

Depuis le début de cette recherche, une approche méthodologique en plusieurs étapes a été mise en place. Tout d'abord, une revue de la littérature a été réalisée afin de définir les termes du sujet et de recenser les principales méthodes et indicateurs utilisés dans l'évaluation de la qualité de vie.

Parallèlement, une collecte de données quantitatives issues d'institutions publiques, dites "froides", a été menée, permettant d'obtenir des informations objectives sur les différentes communes. Ces données ont ensuite été exploitées dans un processus de clustering, mobilisant plusieurs algorithmes (K-Means, Affinity Propagation) pour regrouper les communes selon des profils homogènes (Comiti *et al.*, 2024).

Nous avons également développé une approche d'extraction de connaissances à partir d'entretiens semi-dirigés afin de mieux appréhender la qualité de vie à l'échelle locale. Pour ce faire, nous avons combiné des techniques de traitement automatique du langage naturel (TALN), notamment RoBERTa et VADER, afin de classifier les thèmes abordés et d'analyser les sentiments exprimés par les participants. Notre méthodologie s'est articulée autour de plusieurs étapes : prétraitement des données, classification des interventions, suppression des mots vides et traduction en anglais pour pallier les limites des modèles francophones. L'analyse a révélé des tendances intéressantes, notamment une perception négative des services de santé en raison de leur éloignement, ainsi qu'un biais inattendu lié au thème des revenus. Cette approche permet d'automatiser et d'optimiser l'analyse qualitative des entretiens, offrant ainsi une aide précieuse aux chercheurs et aux décideurs (Comiti *et al.*, 2025).

Cette méthodologie hybride, combinant données quantitatives et qualitatives, vise à produire une évaluation fine et contextualisée du territoire, tout en explorant le potentiel des outils d'intelligence artificielle pour l'analyse territoriale.

## 5. Actions futures

Les actions futures incluent notamment le traitement de données qualitatives et quantitatives recueillies à l'aide d'un questionnaire de qualité de vie diffusé au sein de la population Corse. Il s'agit notamment de mettre en oeuvre des techniques de data mining afin d'extraire des données des réponses textuelles.

Nous aimerions également utiliser des algorithmes de machine learning supervisé (par exemple Random Forest) pour lier certaines données relatives aux aspirations de la population et à son bien-être ressenti à sa commune de résidence. Cela permettrait d'affiner et/ou de valider les clusters.

Les résultats définitifs ne sont pas encore établis, mais l'objectif de cette recherche est de parvenir à une combinaison cohérente des différents indices issus des données quantitatives et qualitatives. À terme, cette approche doit permettre la construction d'un indice de qualité de vie reflétant fidèlement les attentes et les aspirations de la population corse.

## 6. Bibliographie

- Accardo J., Indicateurs de développement humain : limites et perspectives, Technical report, INSEE, 2009.
- Comiti G., Belarif L., Bisgambiglia P.-A., Lameta N., Bisgambiglia P., "Aide à l'extraction de connaissances d'entretiens semi-dirigés", *Proceedings of EGC 2025*, 2025.
- Comiti G., Bisgambiglia P. A., Lameta N., Millet M., Luisi G., Bisgambiglia P., "Using Clustering Methods to Enhance Data Representativeness: Toward a Well-Being Indicator for Corsican Municipalities", *The 2024 International Conference on Computational Science and Computational Intelligence*, 2024.
- Devlin J., Chang M.-W., Lee K., Toutanova K., "BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding", *arXiv preprint arXiv:1810.04805*, 2018.
- Ferreira Barros C., Borges Azevedo B., Vicente Graciano Neto V., Kassab M., Kalinowski M., do Nascimento H. A. D., Bandeira M. C., "Large Language Model for Qualitative Research – A Systematic Mapping Study", *arXiv preprint arXiv:2311.14473*, 2023.
- Shu X., Ye Y., "Knowledge Discovery: Methods from data mining and machine learning", *Social Science Research*, vol. 110, p. 102817, 2023.
- Stiglitz J. E., Sen A., Fitoussi J.-P., Report by the Commission on the Measurement of Economic Performance and Social Progress, Technical report, Commission Stiglitz-Sen-Fitoussi, 2009.
- Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser L., Polosukhin I., "Attention Is All You Need", *Advances in Neural Information Processing Systems (NeurIPS)*, vol. 30, 2017.

---

# Gestion verte de la sécurité des systèmes d'information : Cas des vulnérabilités.

Yann Goetgheluck<sup>1,2</sup>

1. Université Paris-Dauphine, PSL, LAMSADE UMR CNRS 7243

2. Université Paris-Dauphine, PSL, DRM UMR CNRS 7088

{prenom.nom}@dauphine.psl.eu

---

*RÉSUMÉ.* Le Système de Management de la Sécurité de l'Information (SMSI) joue un rôle crucial dans la continuité des activités. Il est un composant clé des systèmes d'information (SI) qui se doivent d'être durables tout en prenant en compte les objectifs de responsabilité environnementale des organisations. Un aspect important mais souvent négligé de la sécurité SI est la gestion des vulnérabilités, qui peut établir un lien entre la sécurité SI et la responsabilité environnementale. En intégrant les aspects organisationnels et humains dans la gestion des vulnérabilités, il est possible d'identifier celles qui sont réellement critiques pour l'organisation concernée. Grâce à cette approche, nous découvrons un autre aspect souvent ignoré : la durabilité de la sécurité SI. Dans ce document, nous proposons d'étendre une méthode standard actuelle afin d'améliorer la priorisation des vulnérabilités, réduisant ainsi le nombre de correctifs, d'analyses et de déploiements énergivores et coûteux, tout en améliorant la sécurité SI.

*ABSTRACT.* The Information Security Management System (ISMS) plays a crucial role in business continuity. It is a key component of information systems (IS) that must be sustainable while taking into account the environmental responsibility objectives of organizations. An important but often overlooked aspect of IS security is vulnerability management, which can establish a link between IS security and environmental responsibility. By integrating organizational and human aspects into vulnerability management, it is possible to identify those that are truly critical for the concerned organization. Through this approach, we discover another often ignored aspect: the sustainability of IS security. In this document, we propose extending a current standard method to improve vulnerability prioritization, thereby reducing the number of energy-intensive and costly patches, analyses, and deployments, while enhancing IS security.

*MOTS-CLÉS :* Sécurité des SI, Responsabilité Environnementale, Gestion des Vulnérabilités, CVSS

*KEYWORDS:* IS Security, Environmental Responsibility, Vulnerability Management, CVSS

---

## 1 Introduction

Les systèmes d'information (SI) sont essentiels aux organisations modernes, soutenant les processus d'entreprise et la prise de décision. Pour assurer leur sécurité, les organisations mettent en œuvre un système de management de la sécurité de l'information (SMSI), visant à préserver la confidentialité, l'intégrité et la disponibilité (triade CIA). Les normes ISO/IEC 27001 et 27002 fournissent un cadre basé sur les risques et adapté aux activités de l'organisation, permettant un contrôle et une amélioration continus. La gestion des vulnérabilités est un aspect crucial mais souvent négligé, largement centrée sur les technologies de l'information, ignorant les dimensions commerciales et humaines. Cette recherche aborde la question suivante : Comment renforcer la sécurité des SI par la gestion des vulnérabilités tout en réduisant la consommation d'énergie liée au SMSI et en améliorant le rapport coût-efficacité ?

## 2 SMSI et gestion des vulnérabilités : Limites et améliorations

Un système d'information comporte trois dimensions : technologique, humaine et commerciale. Alors que le SMSI intègre ces dimensions dans la gestion des risques, la gestion des vulnérabilités reste principalement axée sur les technologies de l'information, négligeant le contexte organisationnel et les contraintes opérationnelles (Al-Dhahri *et al.*, 2017). La gestion des vulnérabilités repose sur le système commun de notation des vulnérabilités (CVSS) du National Institute of Standards and Technology (NIST), mais cette approche est insuffisante pour hiérarchiser efficacement les vulnérabilités (Nyanchama, 2005). Une méthode personnalisable est nécessaire pour déterminer quelles vulnérabilités sont réellement critiques pour une organisation. Après avoir mis en œuvre un processus efficace de gestion des correctifs, il faut hiérarchiser la correction des vulnérabilités critiques en fonction du contexte spécifique de l'organisation et de l'emplacement de la vulnérabilité. Les premières études (Choi, Lee, 2015) ont exploré l'importance de l'information dans cette priorisation, donnant des résultats prometteurs mais limités. D'autres facteurs doivent être pris en compte, tels que le chaînage des vulnérabilités, la criticité des environnements, l'importance des actifs et la sensibilité des données (Choi, Lee, 2015).

## 3 SMSI et développement durable : Conflits et compromis

La recherche universitaire montre que les systèmes d'information (SI) peuvent atténuer leur impact environnemental (Chen *et al.*, 2008). Les SI jouent un rôle essentiel dans la formation des croyances sur l'environnement, l'introduction de processus durables et l'amélioration des performances environnementales et économiques (Melville, 2010). Par exemple, le système local d'information environnementale évalue les risques de désertification dans le Sahel en utilisant les SI pour l'analyse des données et la formulation des politiques (Loireau *et al.*, 2007). Le concept d'écologie de l'information positionne les SI comme des écosystèmes interconnectés optimisant les flux d'information pour des bénéfices environnementaux (Davenport, Prusak, 1997; Pritchard, Martel, 2019). Nous voulons découvrir la voie *Green for IT* (Fauchaux, Nicolai, 2011). L'informatique verte consiste à concevoir, fabriquer, utiliser et mettre au rebut des ordinateurs et des serveurs de manière efficace et avec un impact minimal sur

l'environnement (Dedrick, 2010). La société de l'information présente également des défis en matière de durabilité. Wang (2021) décrit une théorie écologique des écosystèmes d'innovation numérique, où la société de l'information doit équilibrer performances technologiques et impératifs environnementaux. Les innovations en matière de SI, telles que les télécommunications et le télétravail, réduisent la pollution liée aux déplacements (Chen *et al.*, 2008), mais leurs besoins croissants en stockage de données posent des problèmes énergétiques. Les systèmes d'information verts désignent un ensemble intégré de personnes, de processus, de logiciels et de technologies de l'information visant à soutenir les objectifs individuels, organisationnels ou sociétaux (Watson *et al.*, 2010). Cette tension est particulièrement évidente dans la gestion de la sécurité des SI. Le renforcement de la sécurité des SI nécessite souvent des mesures à forte intensité énergétique, telles qu'une infrastructure redondante et une surveillance en temps réel. Les centres de données sécurisés dans le nuage demandent beaucoup d'énergie en raison des redondances matérielles (Akhter, Othman, 2016). Bien que les optimisations énergétiques dans l'informatique en nuage aient été explorées (Mastelic *et al.*, 2014), elles restent limitées par les exigences élevées en matière de sécurité. Cela crée un paradoxe : renforcer la sécurité des SI tend à augmenter la consommation d'énergie, alors que ne pas sécuriser les SI entraîne des risques commerciaux et écologiques plus importants. Nous proposons de trouver des métriques pour déterminer le niveau de durabilité des SMSI et plus spécifiquement de la gestion des vulnérabilités. Notre méthode vise à augmenter la résilience du SMSI et à réduire la consommation d'énergie. Si nous sommes capables de réduire la consommation d'énergie tout en augmentant la sécurité, nous serons capables de réduire le coût des SI et des SMSI. Pour ce faire, nous devons trouver des métriques de durabilité et de rentabilité capables de mesurer la différence entre la situation avant et après la mise en place de la méthode que nous allons créer.

#### **4 SMSI, Durabilité et Optimisation des coûts : Une approche sécurité**

La « stratégie verte » (Watson *et al.*, 2010) suggère qu'une stratégie axée sur les coûts met l'accent sur des mesures telles que le refroidissement des centres de données et la réduction de la consommation d'énergie des serveurs pour améliorer l'efficacité. En revanche, une stratégie axée sur l'environnement privilégie les défis écologiques plutôt que les considérations financières (Saldanha *et al.*, 2022). Ce principe s'aligne sur la stratégie « Green IT », qui suggère que donner la priorité à la qualité conduit à une réduction des coûts et à une amélioration des performances (Krishnan *et al.*, 2000). Les organisations qui adoptent une stratégie axée sur l'environnement tendent à renforcer leurs capacités de suivi de la durabilité et à accroître leur rentabilité à long terme (Watson *et al.*, 2010). Une stratégie verte à double orientation, équilibrant objectifs environnementaux et rentabilité, modère positivement la relation entre écologie et rentabilité, démontrant que l'intégration des préoccupations en matière de durabilité peut générer des avantages financiers (Krishnan *et al.*, 2000; Watson *et al.*, 2010). La réduction de la consommation d'énergie tout en améliorant la sécurité pourrait conduire à une réduction des coûts. En mettant en œuvre des correctifs basés sur les risques et des mesures de sécurité automatisées, les organisations peuvent rationaliser les tâches de sécurité, réduisant ainsi la consommation d'énergie et les dépenses opé-

rationnelles (Stefan, Paul, 2008). Cela confirme que la durabilité et la rentabilité se renforcent mutuellement lorsqu'elles sont abordées de manière stratégique dans une logique de SMSI (Watson *et al.*, 2010).

### **Méthodologie**

Cette recherche utilise la méthode inductive ITDTA (*Inductive Top-Down Theorizing Approach*), qui fait partie de la tradition pragmatique (Shepherd, Sutcliffe, 2011). Cette méthode développe une théorie à partir de données empiriques, plutôt que de tester des hypothèses préétablies. Pour établir une classification des critères de criticité des vulnérabilités répondant aux besoins des organisations, nous adopterons la méthode Delphi (Rowe, Wright, 1999), reposant sur les jugements d'experts. L'ITDTA privilégie une approche ancrée dans le terrain, où la compréhension des dynamiques se construit progressivement à travers les interactions et les contextes étudiés (Shepherd, Sutcliffe, 2011).

### **Conclusion et travaux futurs**

Cette recherche, effectuée au cours de notre première année de doctorat, montre comment la gestion durable des vulnérabilités améliore la résilience du SGI tout en optimisant la sécurité et le rapport coût-efficacité. L'intégration d'une approche centrée sur l'environnement peut créer des synergies renforçant les avantages économiques et écologiques. En adoptant des stratégies de correction basées sur les risques et une automatisation intelligente de la sécurité, les organisations peuvent réduire les opérations de sécurité redondantes, diminuant ainsi la consommation d'énergie et les dépenses opérationnelles. Notre étude vise à combler le fossé entre les systèmes normalisés d'évaluation des vulnérabilités et les besoins réels des organisations en établissant une classification personnalisable des critères de criticité des vulnérabilités. D'autres recherches sont nécessaires pour valider ces résultats dans la pratique. De futures études sont prévues pour quantifier l'impact d'une gestion optimisée des vulnérabilités sur les économies d'énergie et la résilience de la sécurité, pour établir des mesures de durabilité pour les SMSI et pour explorer les implications réglementaires.

### **Bibliographie**

- Akhter N., Othman M. (2016, 5). Energy aware resource allocation of cloud data center: review and open issues. *Cluster Computing*, vol. 19, n° 3, p. 1163–1182. Consulté sur <https://doi.org/10.1007/s10586-016-0579-4>
- Al-Dhahri S., Al-Sarti M., Abdaziz A. (2017). Information security management system. *International Journal of Computer Applications*, vol. 158, p. 29–33.
- Chen A. J., Boudreau M.-C., Watson R. T. (2008). Information systems and ecological sustainability. *Journal of Systems and Information Technology*, vol. 10, n° 3, p. 186–201.
- Choi M., Lee C. (2015). Information security management as a bridge in cloud systems from private to public organizations. *Sustainability*, vol. 7, n° 9, p. 12032–12051.
- Davenport T. H., Prusak L. (1997). *Information ecology: Mastering the information and knowledge environment*. Oxford University Press, USA.
- Dedrick J. L. (2010). Green is: Concepts and issues for information systems research. *Communications of the Association for Information Systems*, vol. 27, n° 1, p. 173–184.

- Faucheux S., Nicolai I. (2011). It for green and green it: A proposed typology of eco-innovation. *Ecological Economics*, vol. 70, n° 11, p. 2020–2027.
- Krishnan M. S., Kriebel C. H., Kekre S., Mukhopadhyay T. (2000). An empirical analysis of productivity and quality in software products. *Management Science*, vol. 46, n° 6, p. 745–759.
- Loireau M., Sghaier M. M., Fétoui M., Abdelrazik M., D’Herbès J., Desconnets J. *et al.* (2007). *Local environmental information system to assess the risk of desertification: circum saharan compared situations (roselt network)*. (<https://doi.org/10.1684/sec.2007.0104>)
- Mastelic T., Oleksiak A., Claussen H. e. a. (2014). Cloud computing: Understanding infrastructure energy consumption for cloud environments. *Future Generation Computer Systems*, vol. 37, p. 101–112.
- Melville N. (2010). Information systems innovation for environmental sustainability. *MIS Quarterly*, vol. 34, n° 1, p. 1.
- Nyanchama M. (2005). Enterprise vulnerability management and its role in information security management. *Information Systems Security*, vol. 14, p. 29–56.
- Pritchard M. J., Martel J. (2019). Information system ecology: An application of dataphoric ascendancy. *Information Systems*, vol. 89, p. 101486.
- Rowe G., Wright G. (1999). The delphi technique as a forecasting tool: issues and analysis. *International Journal of Forecasting*, vol. 15, n° 4, p. 353–375.
- Saldanha T., Mithas S., Khuntia J., Whitaker J., Melville N. (2022). How green information technology standards and strategies influence performance: Role of environment, cost and dual focus. *MIS Quarterly*, vol. 46, n° 4, p. 2367–2386.
- Shepherd D. A., Sutcliffe K. M. (2011). Inductive top-down theorizing: A source of new theories of organization. *Academy of Management Review*, vol. 36, n° 2, p. 361–380.
- Stefan A., Paul L. (2008). Does it pay to be green? a systematic overview. *Academy of Management Perspectives*, vol. 22, n° 4, p. 45–62.
- Wang P. (2021). Connecting the parts with the whole: Toward an information ecology theory of digital innovation ecosystems. *MIS Quarterly*, vol. 45, n° 1, p. 397–422.
- Watson R., Boudreau M.-C., Chen A. (2010). Information systems and environmentally sustainable development: Energy informatics and new directions for the is community. *MIS Quarterly*, vol. 34, n° 1, p. 23–38.

---

# Détection des manipulations de citations par utilisation d'heuristiques statistiques appliquées au corpus de données de Crossref

**Jules di Scala**

*Université de Toulouse  
Institut de Recherche en Informatique de Toulouse (IRIT UMR 5505 CNRS)  
118 Route de Narbonne  
31062 TOULOUSE CEDEX 9  
jules.di-scala@univ-tlse3.fr*

---

*RÉSUMÉ : Les travaux présentés dans ce document concernent trois heuristiques statistiques que j'ai développées dans le but de déceler des manipulations de citations dans la littérature scientifique. La première est fondée sur l'analyse de citations dupliquées dans les méta-données de Crossref, et les deux suivantes (la saturation et la concentration) concernent des proportions de citations bénéficiant à certains auteurs.*

*MOTS-CLÉS: Métriques, Scientométrie, Bibliométrie, Heuristiques statistiques, Crossref, Manipulation des citations, Littérature scientifique*

*ENCADREMENT. Guillaume Cabanac (PR) et Ronan Tournier (MCF)*

---

## 1. Introduction

Le domaine scientifique est gouverné par les métriques (Lawrence 2007). Ces métriques impactent directement la carrière des chercheurs et les décisions prises par les décideurs : elles deviennent donc un but à atteindre, et cessent d'être des outils de mesures fiables (Loi de Goodhart). Ce phénomène incite malheureusement certains acteurs du domaine scientifique — des chercheurs, des maisons d'édition, des institutions — à commettre à des méconduites pour gonfler les métriques les concernant (Biagioli, 2020).

---

Certaines de ces méconduites concernent le contenu des publications scientifiques : fabrication de contenu/données, falsification et plagiat (Fanelli, 2009). Ma recherche porte principalement sur l'analyse des méta-données produites dans le cadre du processus de publication et de partage du savoir scientifique. J'exploite les méta-données fournies par Crossref<sup>1</sup> — qui sont publiées tous les mois en tant que jeu de données public. Mon but est d'identifier des relations suspectes à l'aide d'heuristiques statistiques. Ces relations peuvent être des citations, des liens de co-auteurs, des liens d'affiliations, des publications, et lient des articles, des auteurs et des maisons d'édition. Détecter ces anomalies me permet d'identifier des articles suspects que je soumetts à des spécialistes pour être manuellement vérifiés.

## 2. Références subrepticement insérées (ou *sneaked references*)

Mes premiers travaux prolongent la recherche d'une méconduite appelée « *sneaked references* » (Besançon et al., 2024). Celle-ci consiste à altérer des méta-données d'articles, avant que la maison d'édition ne les envoie à Crossref, en ajoutant des références indues dans leur bibliographies, en favorisant spécifiquement certains chercheurs (Besançon et al., 2024). En 2023, une maison d'édition (que nous appellerons TA) a inséré plus de 4500 *sneaked references* dans les articles qu'elle a publiés. Cette manipulation bénéficiait principalement à deux auteurs qui, par coïncidence, étaient membres du comité d'édition de la revue. Nous avons poursuivi cette recherche et trouvé une autre revue pratiquant ce type de fraude à grande échelle en 2024 (Besançon et al., 2025), montrant que ce phénomène n'était pas isolé et pouvait se reproduire. J'ai découvert que certaines des *sneaked references* envoyées par TA étaient dupliquées : les enregistrements affectés contenaient par erreur la même référence plusieurs fois, ce qui ne devrait pas arriver. La découverte de ces anomalies m'a permise de concevoir un score  $s_d$ , représentant la différence, pour toutes les paires auteurs–revues scientifiques dans Crossref, entre :

- La proportion **effective** des citations dupliquées, bénéficiant à l'auteur, et venant des articles publiés dans la revue.
- La proportion **attendue** des citations dupliquées, bénéficiant à l'auteur, et venant des articles publiés dans la revue.

Par exemple, supposons que les articles de la revue  $J$  citent 1000 autres articles, dont 200 citations ont été dupliquées. Si 50 citations de  $J$  bénéficient à l'auteur  $A$ , dont 40 ont été dupliquées, le score  $s_d$  serait alors calculé comme suit :  $s_d = \frac{40}{200} - \frac{50}{1000} = \frac{1}{5} - \frac{5}{100} = \frac{3}{20}$ . Il est possible de multiplier ce score par le nombre de citations dupliquées dans  $J$  qui pointent vers  $A$  pour faire remonter dans le classement les auteurs qui bénéficient de beaucoup de citations dupliquées.

Cette heuristique s'est montrée pertinente dans le cadre de l'identification de manipulations volontaires de citations. Celle-ci fait ressortir plusieurs cas intéressants

---

1. <https://www.crossref.org/> est un grand entrepôt de méta-données scientifiques.

---

— dont les *sneaked references* de TA, et celles d’une autre revue que nous appellerons BJ, ainsi que d’autres cas de manipulations de citations connus (Besançon et al., 2025).

### 3. Heuristiques pour détecter les manipulations de citations

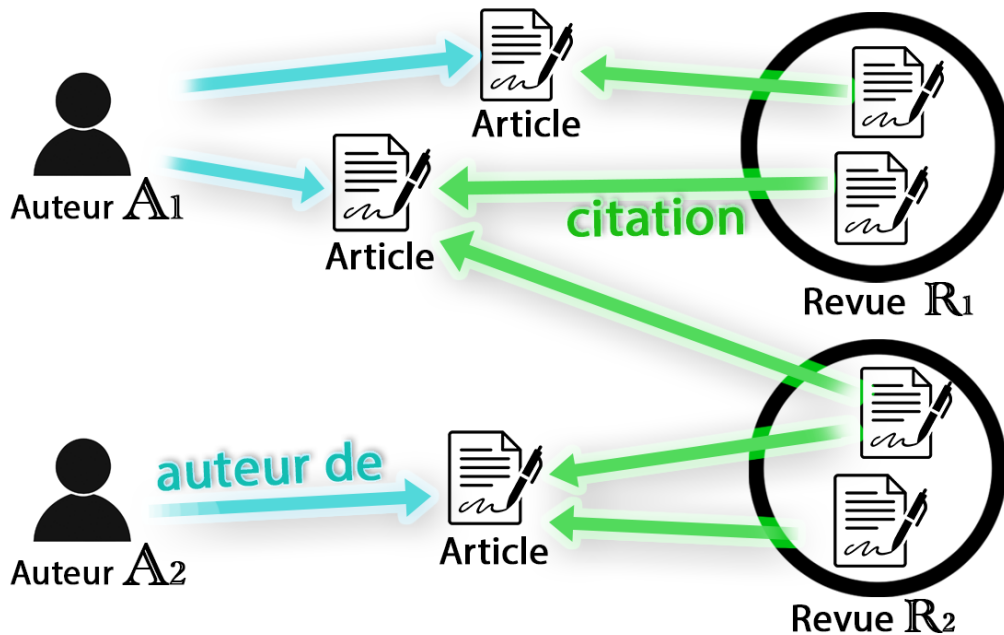
À l’issue des six premiers mois de ma thèse, ma recherche se concentre principalement sur la conception de nouvelles heuristiques pour fouiller le corpus de Crossref afin de trouver de nouvelles méconduites. Je les ai au départ conçues dans le but de trouver des *sneaked references*, mais celles-ci se sont montrées efficaces pour débusquer des méconduites dans un spectre plus large. J’ai principalement exploité deux heuristiques fondées sur l’analyse de paires auteurs–revues scientifiques (voir Figure 1) :

– la **concentration**  $s_c$  des citations qu’un auteur reçoit des articles d’une revue : cette heuristique reflète pour un auteur donné le pourcentage de citations lui bénéficiant qui proviennent d’articles publiés dans la revue.

– la **saturation**  $s_s$  d’une revue par un auteur : cette heuristique donne le pourcentage des références citées dans les articles publiés dans une revue qui bénéficient à un auteur donné.

Ces deux heuristiques font ressortir des paires particulièrement suspectes lorsqu’elles sont appliquées au corpus de données de Crossref (de janvier 2025), dont certaines concernent BJ, et deux autres cas que nous approfondirons dans de futurs travaux. Pour finir, je combine ces deux heuristiques pour trouver des liens forts entre certains auteurs et certaines revues scientifiques : une telle paire auteur–revue trouvée respectivement en haut des classements des concentrations et des saturations est suspecte. En effet cela signifierait que l’auteur bénéficie uniquement de citations venant d’une seule revue qui cite exclusivement ses travaux.

Il est important de noter que cette méthode possède des limitations : ces heuristiques excluent les liens entre un auteur et plusieurs revues scientifiques (des auteurs malintentionnés ne mettront pas forcément tous leurs œufs dans le même panier!), et les groupes d’auteurs non co-auteurs qui saturent une revue par des références qui leur bénéficient — si un groupe de cinq auteurs bénéficie de 90 % des citations d’une revue scientifique équitablement, leur métrique saturation associée sera de 20 % pour chacun d’entre eux. Je prévois de surmonter cet écueil en combinant ces métriques avec des méthodes basées sur des représentations en graphe, permettant ainsi de mieux modéliser les collaborations. Pour finir, il est possible que certaines paires positionnées en haut de ces classements correspondent à des revues très spécialisées ou à l’un des auteurs phares de leur domaines — c’est la raison pour laquelle il est important de montrer ces classements à des experts humains.



$$s_s(A_1, J_1) = 2/2 = 1$$

$$s_s(A_1, J_2) = 1/3$$

$$s_s(A_2, J_2) = 2/3$$

$$s_c(A_1, J_1) = 2/3'$$

$$s_c(A_1, J_2) = 1/3$$

$$s_c(A_2, J_2) = 2/2 = 1$$

**FIGURE 1.** Illustration d'un petit écosystème scientifique.  $A_1$  est cité par deux articles publiés dans  $R_1$  et par un article publié dans  $R_2$ ;  $A_2$  est cité par deux articles publiés dans  $R_2$ .

## Bibliographie

- Lawrence, P. A. (2007). *The mismeasurement of science*. In *Current Biology* (Vol. 17, Issue 15, pp. 583–585). Elsevier. <https://doi.org/10.1016/j.cub.2007.06.014>
- Biagioli, M., & Lippman, A. (Eds.). (2020). *Gaming the Metrics : Misconduct and Manipulation in Academic Research*. The MIT Press. <https://doi.org/10.7551/mitpress/11087.001.0001>
- Fanelli, D. (2009). *How many scientists fabricate and falsify research ? A systematic review and meta-analysis of survey data*. In *PLoS ONE* (Vol. 4, Issue 5, e5738). <https://doi.org/10.1371/journal.pone.0005738>
- Besançon, L., Cabanac, G., Labbé, C., & Magazinov, A. (2024). Sneaked references : *Fabricated reference metadata distort citation counts*. In *Journal of the Association for Information Science and Technology* (Vol. 75, Issue 12, pp. 1368–1379). Wiley. <https://doi.org/10.1002/asi.24896>
- Besançon, L., Cabanac, G., Labbé, C., & Magazinov, A., di Scala, J., Tkaczyk, D., and Weber-Boer, K. (2025). *Detection of metadata manipulations : Finding sneaked references in the scholarly literature*. arXiv preprint. <https://doi.org/10.48550/arXiv.2501.03771>

---

# Contextual Data Quality Management within Enterprise Architecture Frameworks

**Yara Amine**

*Laboratoire CEDRIC, Conservatoire National des Arts et Métiers (CNAM)  
292 Rue Saint-Martin, 75003 Paris, France  
[yara.amine@lecnam.net](mailto:yara.amine@lecnam.net)*

---

*RESUME. À l'ère où la prise de décision basée sur les données est essentielle, le maintien d'une qualité élevée des données et de pratiques de gestion des données robustes au sein de l'architecture d'entreprise (AE) est une priorité où l'AE sert de modèle qui intègre la qualité et la gestion des données dans les processus et systèmes organisationnels. Dans cette thèse, nous visons à améliorer la qualité de la gestion des données au sein des couches EA en utilisant l'apprentissage automatique. L'intégration de l'apprentissage automatique dans les composants d'architecture d'entreprise améliore la qualité des données, automatise les processus de gestion des données, et fournit des informations prédictives optimisant ainsi la prise de décision et alignant la gouvernance des données sur les objectifs organisationnels. Notre recherche est centrée sur une organisation immobilière où la mise en œuvre et le maintien d'une qualité de données optimale et de pratiques efficaces de gestion des données présentent un intérêt significatif.*

*ABSTRACT. In the era where data-driven decision-making is essential, maintaining high data quality and robust data management practices within Enterprise Architecture (EA) is a priority, where EA serves as a blueprint that integrates data quality and data management into organizational processes. In our thesis we aim to improve data quality within EA layers using Machine Learning. Embedding Machine Learning into EA components enhances data quality, automates data management processes, and provides predictive insights, optimizing decision-making and aligning data governance with organizational objectives. Our research is focused on a real estate organization where the implementation and maintenance of optimal data quality and effective data management practices present significant challenges.*

*Mots-clés : Architecture d'entreprise, Qualité des Données, Gestion des Données, Gouvernance des Données, Apprentissage Automatique*

*KEYWORDS: ENTERPRISE ARCHITECTURE, DATA QUALITY, DATA MANAGEMENT, DATA GOVERNANCE, MACHINE LEARNING*

*ENCADREMENT. Elena KORNYSHOVA, Samira CHERFI.*

---

DOI:10.3166/RCMA.25.1-n © 2016 Lavoisier [AR\\_DOI](#)

## 1. Introduction

The era of big data has introduced opportunities and challenges, prompting companies to adapt their information systems to support decision-making. The management of this data is a real challenge requiring the use of new technologies and the development of adapted data governance solutions. A contextual data quality management approach requires a global vision of the information system to better determine and understand the risks related to non-quality, and which is based on the enterprise architecture (EA), which addresses the management problems of the company and its information system. Software, systems and EA have become established disciplines in both industry and academia (Narman et al., 2009). With the growing need to leverage the power of Big Data Analysis, the role of EA is recognized to provide an overview of data and understand its impact (Gong et Janssen, 2021). Authors in (Rashed et Drews, 2021) pointed out the fact the companies are under-exploiting EA facilities when designing or enhancing their data driven business models. Moreover, more and more companies express the need to integrate Machine Learning facilities in their business. However, the gap between ambition and execution is large at most companies and there is a need for approaches helping companies to reach such an objective (Sjödin et al., 2021).

Our research explores a range of methodologies for enhancing data quality assessment tasks. Through this approach, we will implement effective solutions that contribute to a context-dependent data quality management within EA and apply them in BNP Paribas Realestate to ultimately ensure robust data governance and optimized decision-making processes. Section 2 provides an overview of the research approach, followed by Section 3 detailing our current work. Finally, we conclude in Section 4 with our future work.

## 2. Overview of the Research Approach

Achieving optimal data quality can be resource-intensive; however, contextual data quality management tailors data quality criteria to specific usage scenarios, rendering it more pertinent and cost-effective for organizations. Our research approach which is depicted in Figure 1 explores methodologies ranging from established frameworks like TOGAF (The Open Group, 2022), the most widely recognized reference framework developed by The Open Group for enterprise architecture, and meta-models to advanced techniques like Machine Learning to enhance contextual data quality and management processes within EA components. Based on this, our research questions of interest are the following:

- RQ1. What are the data quality dimensions of interest, and what are the interdependencies between these dimensions?
- RQ2. How should data architecture be defined for quality management?
- RQ3. How EA frameworks like TOGAF should be adapted to achieve contextual data quality management?
- RQ4. How can Machine Learning techniques contribute to achieve contextual data quality management?

To establish a solid foundation for our research, we conducted a systematic literature review (SLR) detailed in Section 3 which provides an understanding of the state of the art in data quality management within EA. The empirical study supporting our approach is carried out in collaboration with BNP Paribas Real Estate where we will address their practical challenges and requirements for data quality management. Based on these requirements, we will elaborate on the solutions that address the identified gaps and subsequently evaluate their effectiveness in the organizational context of BNP Paribas Real Estate.




Figure 1. Our Research Approach

### 3. Current Work

We are currently conducting an SLR following the methodology outlined in the article of Rouhani et al. (2015). We used Scopus API which is an academic search engine to run the search query below that is derived from our research questions:

*“(TITLE-ABS-KEY("Data Quality")OR TITLE-ABS-KEY("Information Quality")OR TITLE-ABS-KEY("Data Architecture")OR TITLE-ABS-KEY("Information Architecture")OR TITLE-ABS-KEY("Data Value")OR TITLE-ABS-KEY("Information Value")OR TITLE-ABS-KEY("Data Management")OR TITLE-ABS-KEY("Information Management")OR TITLE-ABS-KEY("Data Governance")OR TITLE-ABS-KEY("Information Governance")) AND (TITLE-ABS-KEY( "Enterprise Architecture")OR TITLE-ABS-KEY( "EA") OR TITLE-ABS-KEY( " EA Framework TOGAF")OR TITLE-ABS-KEY(" EA Framework DODAF")OR TITLE-ABS-KEY(" EA Framework EA3"))”.*

The objective of the query is to identify academic papers addressing the subjects of Data Management, Data Quality, Data Architecture, Data Security, and Data Governance within the context of EA frameworks, management, and modeling. Upon executing the query, we retrieved a total of 839 articles. After applying all the inclusion and exclusion criteria, a final set of 42 articles were selected, which are now undergoing an in-depth analysis and study. Figure 2 shows the detailed steps of the procedure we followed to find our primary studies.

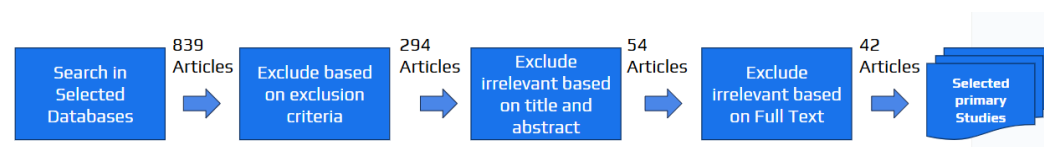


Figure 2. Procedure of identifying primary studies

We are now conducting an in-depth review of all relevant articles, systematically analyzing their contributions to EA based data management and data quality aspects. The results showed that 35% of reviewed studies incorporated Enterprise Architecture (EA) reference frameworks to enhance data management and architectural

methodologies. Additionally, 28% of the articles concentrated on data quality topics. Within this subset, the majority (83%) focused on data quality dimensions, encompassing the assessment of these dimensions and the development of corresponding measurement metrics. The remaining studies addressed data quality models (8%) and explored data quality concerns and characteristics (16%).

#### 4. Conclusion

Maintaining high data quality is a critical factor for enhancing the effectiveness of Enterprise Architecture (EA). As enterprise architects develop and align complex systems with organizational objectives, high-quality data acts as a foundational element, supporting accurate modeling, streamlined processes, and evidence-based decision-making. Integrating robust data quality practices into EA frameworks not only strengthens system resilience and scalability but also fosters sustainable organizational growth. Moving forward, our research will focus on completing the SLR and initiating the practical implementation of the proposed methods to improve data quality and data management within EA frameworks.

#### Bibliographic

- Narman, P., Johnson, P., Ekstedt, M., Chenine, M., & Konig, J. (2009). *Enterprise architecture analysis for data accuracy assessments*. 2009 IEEE International Enterprise Distributed Object Computing Conference, IEEE, pp. 24-33.
- Rouhani, B. D., Mahrin, M. N., Nikpay, F., Ahmad, R. B., & Nikfard, P. (2015). *A systematic literature review on Enterprise Architecture Implementation Methodologies*. Information and Software Technology, 62, 1-20, Elsevier.
- Gong, Y., & Janssen, M. (2021). *Roles and capabilities of enterprise architecture in big data analytics technology adoption and implementation*. Journal of theoretical and applied electronic commerce research, 16(1), 37-51.
- Rashed, F., & Drews, P. (2021). *How does enterprise architecture support the design and realization of data-driven business models? An empirical study*. In Innovation Through Information Systems: Volume III: A Collection of Latest Research on Management Issues (pp. 662-677). Springer International Publishing.
- Sjödin, D., Parida, V., Palmié, M., & Wincent, J. (2021). *How AI capabilities enable business model innovation: Scaling AI through co-evolutionary processes and feedback loops*. Journal of Business Research, 134, 574-587.
- The Open Group. (2022). *The TOGAF Standard, 10th Edition*. The Open Group. <https://www.opengroup.org/togaf-standard-10th-edition-downloads>

---

# Développement de modèles génératifs sobres et explicables pour la rédaction de demandes de brevet

**Mohamed chérif SIDHOUM<sup>1</sup>**

*Université de Pau et des Pays de l'Adour (UPPA), CY-TECH, LIPSTIP  
64000 Pau, France  
csidhoum@lipstip.com*

---

*RESUME. L'IA révolutionne de nombreux secteurs, y compris le domaine juridique, notamment dans la rédaction de demandes de brevets. La rédaction d'une demande de brevet est fondamentale pour protéger une innovation technologique. Ce document, soumis à un Office de Propriété Intellectuelle, définit la portée de la protection. Une rédaction initiale de qualité est essentielle pour éviter des coûts supplémentaires et assurer une protection adéquate. Le secteur exige confidentialité, explicabilité et adaptation aux spécificités des offices de PI. Cette thèse vise à développer des modèles d'IA pour générer du texte juridique, en garantissant l'explicabilité et la sécurité des données. Les algorithmes doivent relier les textes générés à des contextes clairs et maintenir les données localement. L'objectif est de créer des technologies performantes pour aider les professionnels du droit des brevets.*

*ABSTRACT. AI is revolutionizing numerous sectors, including the legal field, particularly in drafting patent applications. Drafting a patent application is fundamental for protecting a technological innovation. This document, submitted to an Intellectual Property Office, defines the scope of protection. A high-quality initial draft is essential to avoid additional costs and ensure adequate protection. The sector requires confidentiality, explainability, and adaptation to the specificities of IP offices. This thesis aims to develop AI models for generating legal text, ensuring explainability and data security. The algorithms must link the generated texts to clear contexts and keep data locally. The goal is to create high-performing technologies to assist patent law professionals.*

*KEYWORDS : Patent Analysis, Natural Language Processing, Machine Learning, Technical Writing, Legal text generation*

---

## 1. Introduction

L'Intelligence Artificielle est en train de bouleverser un nombre considérable de secteurs. Celui du juridique (Broecke, 2021) sera l'un des premiers impactés, selon toutes les principales études prospectives (EU report, 2022). Au sein de ce marché,

une spécificité très forte caractérise le sous-segment sur lequel se positionne ce sujet de thèse, à savoir l'accompagnement à la protection des innovations et, notamment, celui de l'aide à la rédaction de demandes de brevets.

La rédaction d'une demande de brevet est une étape essentielle dans la protection d'une innovation technologique par brevet ; cela consiste en la rédaction d'une description de l'invention, de l'état de l'art dans lequel s'inscrit la protection et des revendications qui définissent la portée de la protection recherchée.

Ceci implique des besoins de : confidentialité des données, explicabilité des propositions et prise en compte des spécificités des Offices de Propriété Intellectuelle (Office Européen vs Office Américain) restreignant le développement rapide de solutions performantes universelles.

Cette thèse vise à développer des modèles d'IA et des algorithmes pour simuler les mécanismes de génération de texte juridique. Ces algorithmes et modèles seront développés avec l'objectif de créer des technologies permettant d'assurer :

- L'explicabilité : les professionnels du droit des brevets ne peuvent pas se permettre de baser leur rédaction de demande de brevet sur des notions issues de boîtes noires sans en comprendre l'origine et la pertinence.
- La sécurité : les données doivent rester sur l'ordinateur de l'utilisateur.

## **2. État de l'art**

En 2018, seulement 57 articles scientifiques abordaient l'utilisation de l'intelligence artificielle (Aristodemou & Tietze, 2018). Des avancées récentes incluent l'application de réseaux neuronaux convolutifs et de Transformers pour comparer des images brevetées (Higuchi & Yanai, 2023).

La majorité des publications concerne l'analyse des demandes de brevet par vectorisation pour évaluer nouveauté ou brevetabilité, en utilisant des word embeddings et modèles neuronaux avancés (BERT, GPT-2).

Ce travail de thèse se distingue en ciblant la génération automatique de demandes de brevet plutôt que leur analyse. Les approches Lee (2019, 2020) présentent des limites en cohérence, répétition et exactitude du texte généré. La dépendance entre revendications indépendantes et dépendantes reste un défi majeur.

Les modèles juridiques spécialisés (LegalBERT (Chalkidis et al., 2020), CaseLawBERT (Zheng et al., 2021), LexGLUE (Chalkidis et al., 2022)) montrent des performances supérieures dans les textes juridiques mais restent inadaptés aux brevets.

Les travaux de Ferrero et al. (2021) sur l'alignement de textes juridiques multilingues apportent des méthodes pertinentes pour gérer les aspects multilingues des brevets, particulièrement dans les dépôts internationaux.

Le modèle SpanBERT (Joshi et al., 2020) sera expérimenté, avec évaluation d'architectures alternatives comme Longformer (Beltagy et al., 2020), LUKE (Yamada et al., 2020) et BigBird (Zaheer et al., 2020) pour le traitement de documents longs.

La classification préalable des revendications selon leur domaine technique constituera un axe important pour ajuster les modèles aux spécificités des domaines techniques.

### **3. Verrous scientifiques et approche proposée**

Le premier verrou scientifique concerne la gestion de la complexité des revendications de brevets. Leur organisation et interdépendance rendent difficile l'apprentissage automatique.

Un deuxième défi provient de la diversité technique des domaines techniques. La polysémie des termes selon les contextes techniques nécessite une classification rapide et explicable. Une méthode de classification multi-label combinant algorithmes supervisés et mécanismes d'attention offrira performance et interprétabilité.

La transparence des modèles d'IA constitue un autre enjeu. Ce projet privilégie des méthodes explicables permettant un contrôle humain régulier. Nous implémenterons des architectures d'attention visualisant les parties du texte source influençant chaque portion générée.

### **4. Méthodologie et contributions attendues**

Cette thèse développera une méthodologie utilisant des modèles avancés pour analyser les caractéristiques des revendications de brevets. Le pipeline technique comprendra, le prétraitement avec segmentation structurelle, la classification multi-domaine des sections techniques, la vectorisation contextuelle des revendications, la modélisation des dépendances entre revendications, et la génération de texte contrainte par style et domaine.

Les jeux de données incluront des corpus de brevets de l'USPTO, l'OEB et INPI couvrant divers domaines techniques.

Les métriques d'évaluation incluront, la précision, recall et F1-score pour la classification ; BLEU, ROUGE et BERTScore pour la qualité textuelle ; les métriques spécifiques aux brevets (taux de couverture des éléments techniques).

Des évaluations qualitatives seront menées avec des experts en propriété intellectuelle.

Une méthodologie de classification multi-label explicable sera mise en œuvre pour capturer les caractéristiques permettant l'identification rapide des domaines techniques.

Des approches de TALN explicables assureront la transparence du processus et le contrôle humain permanent.

La méthodologie inclura une segmentation détaillée des revendications interdépendantes, facilitant l'identification des éléments structurants des descriptions de brevets.

Une contribution majeure sera la création d'une base de données qualifiée, couvrant divers domaines techniques, pour l'évaluation rigoureuse des modèles proposés.

Enfin, nous développerons des outils d'IA optimisés pour des environnements à ressources limitées, améliorant qualité rédactionnelle et sécurité.

## **. Bibliographie**

Aristodemou, L., Tietze, F. (2018). The state-of-the-art on Intellectual Property Analytics (IPA): A literature review on artificial intelligence, machine learning and deep learning methods for analyzing intellectual property (IP) data. *World Pat. Inf.*, 55, 37–51.

Beltagy, I., et al. (2020). Longformer: The long-document transformer. *arXiv:2004.05150*.

Broecke, J. (2021). AI and Legal Practice: Opportunities and Challenges. *Int. J. Legal Tech.*, 5(2), 87-102.

Chalkidis, I., et al. (2022). LexGLUE: A benchmark dataset for legal language understanding. *arXiv:2110.00976*.

European Commission. (2022). The impact of AI on the Legal Sector. EU Technical Report.

Ferrero, J., et al. (2021). Cross-lingual legal document retrieval using multilingual semantic network. *J. Law Tech.*, 35(3), 215-231.

Higuchi K., Yanai.K. (2023). Patent image retrieval using transformer-based deep metric learning. *World Patent Information*, 74.

Joshi, M., et al. (2020). SpanBERT: Improving pre-training by representing and predicting spans. *Trans. ACL*, 8, 64-77.

Yamada, I., et al. (2020). LUKE: Deep contextualized entity representations. *arXiv:2010.01057*.

Zaheer, M., et al. (2020). Big bird: Transformers for longer sequences. *NeurIPS*, 33, 17283-17297.

Zheng, L., et al. (2021). When does pretraining help? The CaseHOLD dataset. *arXiv:2104.08671*.

---

# Vers une ontologie à visée inclusive pour les itinéraires sémantiques

**Salomon van Ginneken**

Université Lumière Lyon 2, CNRS, INSA Lyon, Université Claude Bernard Lyon 1,  
LIRIS,  
UMR5205, 69007 Lyon, France

---

*RESUME.* Cet article présente le prototype d'une ontologie ayant pour but la sémantisation d'itinéraires prenant en compte des données contextuelles (e.g. données météorologiques, urbaines) afin de répondre à des besoins utilisateurs (e.g. éviter la pluie, faire une pause sur un banc). Pour cela, il est nécessaire d'agrèger des informations hétérogènes et aux multiples modalités (caractéristiques de l'espace parcouru, besoins de l'utilisateur). Nous présentons ici les avantages de l'utilisation d'une ontologie pour modéliser cette hétérogénéité et les bases du modèle sémantique proposé.

*ABSTRACT.* This paper presents a prototype ontology aimed at semanticizing itineraries by using contextual data (e.g., meteorological data, urban features) to address user requirements (e.g., avoiding rain, finding resting spots on benches). This approach necessitates the alignment of heterogeneous information across multiple modalities (characteristics of the traversed space, user needs). We discuss the advantages of using an ontology to capture this heterogeneity and present the foundations of the proposed semantic model.

*MOTS-CLÉS :* Itinéraire, Modélisation spatio-temporelle, Ontologie, Inclusion

*KEYWORDS :* Itinerary, Spatio-temporal modelling, Ontology, Inclusion

---

## 1. Introduction

L'accessibilité des itinéraires au sein d'un territoire est un enjeu essentiel pour améliorer l'expérience des usagers, en particulier ceux ayant des besoins spécifiques. Les applications de navigation classiques optimisent les itinéraires selon des critères standards (distance, temps) sans considérer les contraintes individuelles des utilisateurs. Nous voulons nous placer dans une démarche largement inclusive, tant du point de vue moteur (incapacité à prendre les escaliers, etc.) que cognitif (aversion pour les espaces à forte affluence/bruit, etc.). Pour cela, la prise en compte de ces contraintes individuelles est primordiale et nécessite des informations contextuelles décrivant chaque étape du parcours. Ces informations sont diverses et proviennent de sources hétérogènes, d'où la nécessité d'une agrégation préalable.

Depuis plus de deux décennies, les technologies du Web sémantique ont été explorées comme une approche efficace pour structurer, interconnecter et raisonner

sur des ensembles de données hétérogènes. Dans ce papier, nous proposons une solution innovante en introduisant le concept d'itinéraire sémantique et nous posons les bases d'une ontologie modulaire qui s'appuiera sur trois ontologies: GeoSPARQL (Battle et Kolas, 2002), SAREF<sup>1</sup> et OWL time<sup>2</sup>.

## 2. État de l'art sur la modélisation sémantique des trajectoires

Dans les travaux présentés ci-dessous, les trajectoires sont mesurées *a posteriori* tandis que les itinéraires que nous voulons à terme produire seront calculés *a priori*, en amont du déplacement. La plupart des conclusions restent toutefois valides pour notre cas d'étude. Spaccapietra *et al.* (2008) définissent une trajectoire sémantique comme une séquence ordonnée temporellement de segments spatio-temporels enrichis de données contextuelles. Ils proposent deux types de segments : les *arrêts* et les *mouvements*. Spaccapietra et Parent (2011) complètent le modèle précédent avec la notion d'épisode. Un épisode est un ensemble de segments spatio-temporels consécutifs satisfaisant un même prédicat, lequel décrit une situation concrète. Par exemple le prédicat "vitesse  $\leq$  3km/h" définit les *stops*.

Bogorny *et al.* (2014) modélisent les trajectoires sémantiques comme une séquence de points spatio-temporels plutôt que comme une séquence de segments. Damiani (2021) propose trois approches. La première est inadaptée pour les itinéraires car elle ne prend pas en compte la dimension spatiale. La deuxième développe les travaux de Bogorny *et al.* centrés sur les points et introduit la notion d'*événement*. La dernière se place dans la continuité des articles de 2008 et 2011.

Pour conclure, nous insistons sur la différence entre la modélisation par des points (Bogorny *et al.* (2014), approche n°2 de Damiani (2021)) et la modélisation par des segments (Spaccapietra *et al.* (2008), Spaccapietra et Parent (2011), approches n°1 et 3 de Damiani (2021)). En effet, elle est aussi importante dans le cadre de la modélisation d'itinéraires et nous devons nous positionner dans les approches que nous développons.

## 3. Approche proposée : poser les bases d'une nouvelle ontologie

Le schéma de la Figure 1 représente les entités et les relations qui forment la base de notre future ontologie. Dans la partie gauche de la Figure 1, nous introduisons notre module qui s'appuie sur trois ontologies du domaine : SAREF pour les applications intelligentes, GeoSPARQL d'OGC pour les données spatiales et W3C OWL time pour les entités temporelles. L'entité fondamentale de notre module est le point spatial (*SpatialPoint*), représenté par ses coordonnées géographiques  $\{lon, lat\}$ . Certains points spatiaux constituent des points d'intérêt (POI) pour l'utilisateur, tandis que d'autres servent uniquement aux calculs. Un point spatio-temporel (*SpatioTemporalPoint*) est un point spatial à un instant donné, par exemple "l'intersection des couloirs  $C_1$  et  $C_2$  du bâtiment B mardi 06 juin 2025 à

---

<sup>1</sup> SAREF: Smart Application REFerence Ontology: <https://saref.etsi.org/core/v4.1.1/>

<sup>2</sup> W3C OWL Time Ontology: <https://www.w3.org/TR/owl-time/>

14h12". La granularité temporelle dépend des besoins et des capacités de l'administrateur du service. Un autre élément est la région d'intérêt spatio-temporelle (*SpatioTemporalROI*), laquelle représente un sous-ensemble de l'espace navigable possédant des caractéristiques spécifiques. Finalement, un segment spatio-temporel (*SpatioTemporalSegment*) est l'union de deux points spatio-temporels indiquant les endroits et les moments de début et de fin. Un tel segment peut inclure des points intermédiaires servant à modéliser des polygones.

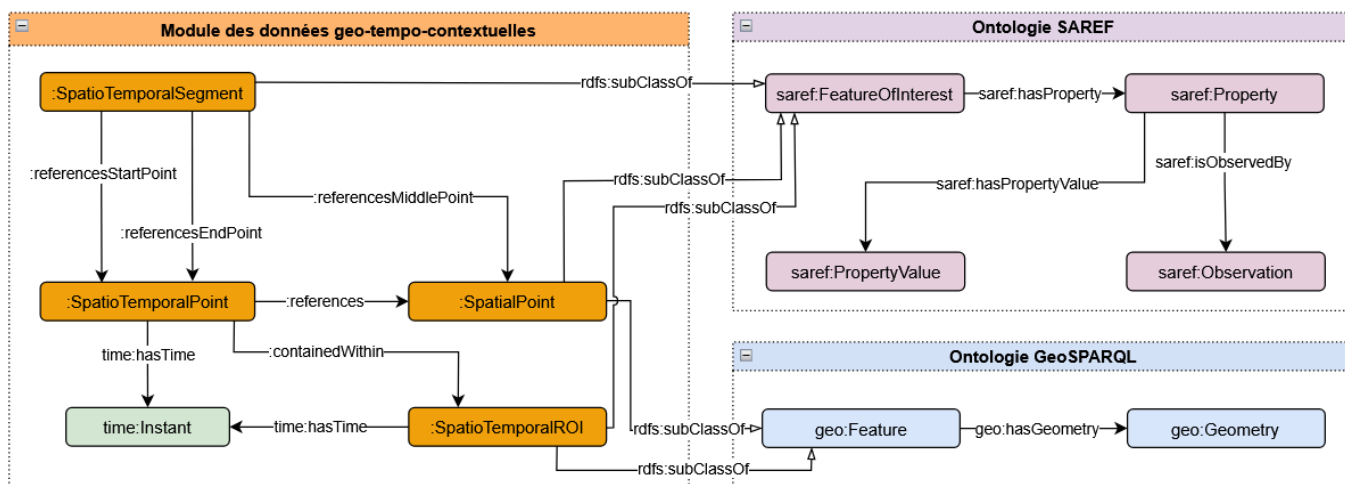


Figure 1 : Schéma de notre projet d'une ontologie modulaire pour l'agrégation de données contextuelles pour des itinéraires sémantiques inclusifs

Ces 4 entités peuvent être enrichies par des informations contextuelles. Par exemple, un point spatial peut représenter diverses ressources (salle, banc) ou éléments fonctionnels (porte) et peut être décrit par différentes propriétés observables (accessibilité) ou mesurables (affluence). Un point spatio-temporel “hérite” des propriétés du point spatial qu’il référence mais présente également des données dynamiques (météo, affluence). Enfin, un segment spatio-temporel “hérite” de certaines propriétés de ses points constitutifs mais peut porter des informations supplémentaires comme la qualité du sol. Les ROI permettent d'attribuer des caractéristiques communes à tous les éléments qu'elles contiennent. En s'appuyant sur l'ontologie SAREF, nous introduisons ces 4 entités comme des sous-classes de *saref:FeatureOfInterest* qui représente toute entité du monde réel sur les propriétés ou les états desquelles il est possible d'agir (García-Castro *et al.*, 2023).

**Définition formelle.** À partir de ces notions, nous définissons un *itinéraire* comme une séquence temporellement ordonnée de segments spatio-temporels enrichis :  $I = \{T_1, \dots, T_n\}$  avec  $T_i = \{int_{t,i}, segm_{s,i}, L_i\}$  des segments spatio-temporels (enrichis si  $L_i \neq \emptyset$ ). Les segments spatiaux  $segm_{s,i}$  d'un itinéraire se suivent et les intervalles temporels  $int_{t,i}$  se suivent sans se chevaucher.

Nous nous positionnons donc en choisissant de modéliser les itinéraires sémantiques selon le formalisme “continu” introduit par Damiani. Ce choix nous semble plus pertinent pour plusieurs raisons. D’abord, comme évoqué ci-dessus, des

propriétés peuvent émerger de la considération de segments plutôt que de points (qualité du sol, accessibilité aux PMR). Ensuite, modéliser les itinéraires comme des séquences de segments à parcourir offrira à l'utilisateur un meilleur contrôle de son itinéraire et des détours potentiels. Pour finir, et peut être surtout, un itinéraire est conçu pour être parcouru. Dans ce contexte, il nous semble plus adapté de présenter une séquence de segments à parcourir qu'une séquence de points à visiter.

#### 4. Conclusion et travaux futurs

Notre proposition nous permettra, à terme, de décrire, modéliser et agréger les données relatives à des itinéraires inclusifs de sorte à couvrir un large éventail de besoins utilisateurs. Avant de concrètement produire de tels itinéraires, il nous reste plusieurs verrous à lever : déterminer la forme concrète que prendront les itinéraires (un prolongement de notre ontologie serait pertinent pour décrire non pas les données mais les itinéraires eux mêmes), identifier des caractéristiques contextuelles présentant un intérêt réel pour les utilisateur (lesquelles sont pertinentes, importantes, redondantes, etc. ?), récupérer ou produire des données qui peupleront notre ontologie (depuis des sources hétérogènes qu'il faudra agréger avec robustesse) ou encore oeuvrer au développement d'un moteur générant des propositions d'itinéraires riches et pertinentes tout en les ordonnant en fonction de leur pertinence pour l'utilisateur (plusieurs itinéraires peuvent convenir, et il s'agit de déterminer l'ordre dans lequel on les présente à l'utilisateur).

Les perspectives les plus pertinentes à nos yeux sont la validation de notre ontologie et le développement d'un cadre applicatif concret permettant l'évaluation de notre système de proposition d'itinéraires. Cette avancée constituera la première occasion de retours d'utilisateurs sur notre approche pour l'instant très théorique.

#### 5. Références

Battle et Kolas (2012). *Enabling the geospatial Semantic Web with Parliament and GeoSPARQL*. *Semantic Web 3* (2012), p.355–370

Bogorny *et al.* (2014). CONSTAnT - A Conceptual Data Model for Semantic Trajectories of Moving Objects. *Transactions in GIS*, vol.18, n° 1, p.66-88.

Damiani (2021). Semantic Trajectories Data Models. *Handbook of Big Geospatial Data*. Cham, Springer International Publishing, p.185-197.

García-Castro *et al.* (2023). *The ETSI SAREF ontology for smart applications: a long path of development and evolution*, p.183-215.

Spaccapietra *et al.* (2008). A conceptual view on trajectories. *Data & Knowledge Engineering*, vol. 65, n° 1, p. 126-146.

Spaccapietra et Parent (2011). Adding Meaning to Your Steps, *Conceptual Modeling – ER 2011*, Berlin, Heidelberg.

---

# Contrôle de la qualité des médicaments sur le terrain par la méthode proche infrarouge portable : construction d'un système d'information

**Wendeline Swart**

*Université de Toulouse  
Institut de Recherche en Informatique de Toulouse (IRIT UMR 5505)  
118 route de Narbonne  
31062 Toulouse cedex 9  
wendeline.swart@irit.fr*

---

*RÉSUMÉ : Le projet NIR4MED explore l'utilisation de la spectroscopie proche infrarouge (PIR) pour contrôler la qualité des médicaments en temps réel sur le terrain. Des tests en laboratoire ont montré que des dispositifs PIR portables peuvent distinguer les médicaments de qualité et les médicaments falsifiés. L'objectif est de développer un système d'information comparant les spectres PIR et métadonnées des médicaments de référence à ceux collectés sur le terrain, en intégrant l'intelligence artificielle (IA) pour affiner l'analyse. Actuellement en phase de collecte de données, le projet vise à concevoir une solution sécurisée incluant potentiellement la reconnaissance optique de caractères (OCR) pour l'analyse des emballages et la blockchain pour la traçabilité des données.*

*MOTS-CLÉS : Système d'informations, méthode portable proche infrarouge, intelligence artificielle, qualité des médicaments.*

*ENCADREMENT : Guillaume Cabanac (PR) et Gilles Hubert (MCF)*

---

## 1. Contexte

Mon travail de thèse s'inscrit dans le cadre du [projet NIR4MED](#) (*Near InfraRed Spectroscopy for monitoring MEDicines in Africa*). Ce projet pilote repose sur l'uti-

lisation de la méthode proche infrarouge (PIR) portable pour contrôler la qualité du médicament sur le terrain.

L'OMS distingue 3 catégories de médicaments, les *médicaments de qualité*, les *médicaments falsifiés* et les *médicaments sous-standards*. Les médicaments *falsifiés* trompent intentionnellement sur leur composition ou leur origine. Les médicaments *sous-standards* sont non conformes aux normes de qualité, en raison de défauts de fabrication, de stockage ou de contrôle, avec ou sans intention frauduleuse.

La spectroscopie proche infrarouge est une technique qui utilise la lumière infrarouge absorbée par un échantillon pour le caractériser et obtenir ainsi des informations sur les molécules présentes.

C'est une méthode portable, ne nécessitant peu ou pas de préparation de l'échantillon, ne générant pas de déchets, rapide et non destructive de l'échantillon, et potentiellement utilisable par des personnes peu qualifiées.

## 2. État de l'art

Nous résumons ici l'analyse comparative faite par la [Fondation Pierre Fabre](#) qui compare les dispositifs portables pour le contrôle de la qualité des médicaments sur le terrain, notamment le *Global Pharma Health Fund's GPHF-Minilab*, la spectroscopie PIR (à réflexion ou transmission), la spectroscopie Raman et les dispositifs analytiques sur papier (Nepveu, 2023). La spectroscopie PIR a été retenue pour l'étude NIR4MED en raison de sa capacité d'analyse qualitative et quantitative. L'analyse par réflexion, rapide et non destructive, permet d'identifier des médicaments falsifiés sans préparation complexe, contrairement à l'analyse par transmission nécessitant la mise en solution des solides. Les dispositifs PIR portables sont abordables mais présentent des limites, notamment lorsque la concentration du principe actif varie peu. L'analyse par réflexion en PIR nécessite un traitement des spectres via le *data mining*, impliquant la construction d'une vaste base de données d'échantillons de référence. Chaque formulation pharmaceutique requiert un modèle de régression spécifique, ce qui freine une adoption à grande échelle. Cependant, des modèles plus globaux intègrent les effets environnementaux et instrumentaux pour améliorer la calibration. Le Centre Interdisciplinaire de Recherche sur le Médicament (CIRM) de l'Université de Liège a développé une méthode de transfert entre un instrument de laboratoire (FT-NIR) et un appareil portable, offrant de bonnes performances.

Des chercheurs ont évalué le retour sur investissement des dispositifs portables pour le contrôle de l'amoxicilline au Kenya, en tenant compte des impacts économiques et humains des médicaments falsifiés. Le PIR et les dispositifs analytiques sur papier offrent le meilleur rendement, suivis du GPHF-Minilab et du Raman (Higgins *et al.*, 2023). Une autre étude au Laos a comparé six dispositifs portables pour l'analyse des combinaisons antipaludiques à base d'artémisinine. Le NIR-SG-1, retenu pour NIR4MED, a été classé comme le meilleur en termes de rapport qualité/prix (Ozawa *et al.*, 2022).

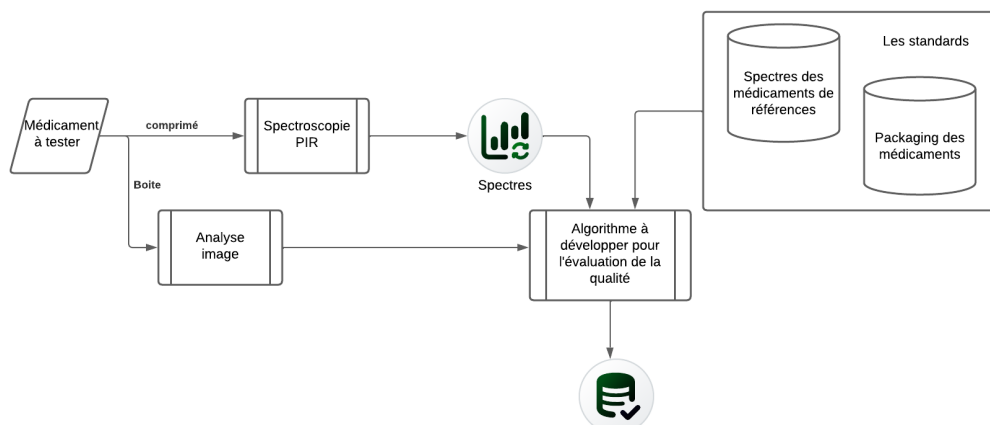
Les partenaires du projet estiment que l'Intelligence Artificielle (IA) pourrait améliorer l'analyse des données spectrales. L'IA a déjà prouvé son efficacité en spectrophotométrie médicale, notamment grâce aux réseaux neuronaux convolutifs unidimensionnels (1D-CNN). Une étude sur les spectres du SARS-CoV-2 a ainsi atteint une précision de 96,5 %, une spécificité de 98 % et une sensibilité de 94 %, illustrant son potentiel pour des diagnostics rapides et précis (Krohling *et al.*, 2023).

### 3. Problématique

Le Bénin a été choisi pour la phase pilote du projet NIR4MED en raison de son engagement contre les médicaments non conformes. Son gouvernement renforce l'accès aux médicaments de qualité par la traçabilité et l'installation de pharmacies en zones reculées, créant un contexte favorable à l'implémentation de la spectroscopie PIR. Le pays dispose de compétences scientifiques solides, notamment via la Faculté des Sciences de la Santé (UAC) et ses partenariats avec ULiège et UCLouvain. Son infrastructure réglementaire, soutenue par l'OMS et la Banque Mondiale, inclut l'ABMED et l'ANCO. Cette thèse, débutée en avril 2025, s'inscrit dans un projet interdisciplinaire visant à développer un système d'information permettant d'évaluer en temps réel la qualité des médicaments avec des dispositifs PIR portables, facilitant ainsi une action rapide des autorités. Cette thèse va également devoir se confronter à plusieurs enjeux tels que la variabilité des spectres, le manque de données étiquetées, l'hétérogénéité des médicaments et l'environnement instable.

### 4. Actions réalisées

Les appareils proche infrarouge (trois catégories) sont en cours de certification, tandis que les médicaments de référence sont en phase d'achat auprès de grossistes certifiés avant leur analyse dans un laboratoire qualifié par l'OMS. Les modalités de collecte sont soumises à confidentialité. Mais une fois l'analyse effectuée nous comparerons les frameworks envisageables et recueillerons les besoins des utilisateurs finaux. Parallèlement, j'effectue un état de l'art sur les aspects liés à cette thèse et me forme aux notions de pharmacie et de physico-chimie analytique essentielles au projet. La [Figure 1](#) illustre les étapes à suivre pour le traitement des données.



**FIGURE 1.** Schématisation du traitement à effectuer pour l'évaluation de la qualité d'un médicament.

## 5. Actions futures

Le projet NIR4MED a été lancé mi-décembre 2024. Une fois la certification des médicaments de référence obtenue, l'enregistrement de leur spectre PIR et de leurs métadonnées devra être fait. Ensuite les spectres PIR devront être modélisés. Nous pourrons alors concevoir une première approche pour les analyser, les sécuriser dans une base de données et afficher le résultat des comparaisons des spectres dans une solution que nous aurons développée. Au cours de l'avancement du projet il faudra également inclure la reconnaissance optique de caractères (OCR), pour contrôler les emballages des médicaments qui peuvent être eux aussi contrefait, et la blockchain pour sécuriser les données manipulées. Il faudra aussi mettre en oeuvre toute la partie système d'information qui rassemblera tous les éléments développés ci-dessus et qui permettra aux personnes sur le terrain de se connecter à une interface permettant de rajouter des spectres et obtenir des résultats pertinents.

## 6. Bibliographie

- Higgins C. R., Kobia B., Ozawa S., "Comparing the return on investment of technologies to detect substandard and falsified amoxicillin: A Kenya case study", *PLOS ONE*, vol. 18, n° 1, p. e0268661, 2023.
- Krohling B. A., Krohling R. A., "1D Convolutional neural networks and machine learning algorithms for spectral data classification with a case study for Covid-19", 2023, arXiv.
- Nepveu F., "Projet NIR4MED du programme WEAQUAM", 2023, Fondation Pierre Fabre.
- Ozawa S., Higgins C. R., Nwokike J. I., Phanouvong S., "Modeling the Health and Economic Impact of Substandard and Falsified Medicines: A Review of Existing Models and Approaches", *The American Journal of Tropical Medicine and Hygiene*, vol. 107, n° 1, p. 14–20, 2022.