



MÉMOIRE DE RECHERCHE

Département des Sciences du Langage

M2 Linguistique, Informatique et Technologies du Langage (LITL)

Étude de la sous-spécification dans les titres d'articles scientifiques

Damien GOUTEUX

Sous la direction de Mme Josette Rebeyrolle et M. Ludovic Tanguy

2018 – 2019

Table des matières

Résumé	5
Remerciements	6
Introduction	7
I. Exploration du corpus à la lumière de l'état de l'art	12
I.1 Origine et prétraitements des données.....	12
I.1.1 Récupération des données	12
I.1.2 Étiquetage et analyse syntaxique en dépendances.....	13
I.1.3 Segmentation des titres.....	14
I.1.4 Sélection de la tête des segments	15
I.2 Constitution d'un corpus de travail représentatif	18
I.2.1 Sélection selon la structure des titres.....	18
I.2.2 Sélection selon la nature des têtes	19
I.2.3 Un corpus de travail représentatif du matériau de base.....	21
I.3 Structures semblables des domaines et têtes spécifiques	23
I.3.1 Variations de la structure en fonction du domaine	23
I.3.2 Têtes spécifiques à un domaine.....	25
II. Têtes transdisciplinaires et NSS dans le corpus	32
II.1 Sélection des têtes transdisciplinaires.....	32
II.1.1 Principe de sélection.....	32
II.1.2 Résultats et évaluations des têtes transdisciplinaires	32
II.1.3 Études des têtes selon leurs segments et la structure segmentale du titre.....	36
II.2 Noms sous-spécifiés et constructions spécificationnelles.....	38
II.2.1 Définitions des noms sous-spécifiés	38
II.2.2 Les constructions spécificationnelles classiques	40
II.2.3 Recherche des constructions spécificationnelles classiques dans le corpus.....	46
II.3 Schémas récurrents d'emploi des têtes transdisciplinaires	50
II.3.1 Recherche des schémas d'emplois des têtes transdisciplinaires	50
II.3.2 Lexique des noms et détermination de l'emploi	56
II.3.3 Transdisciplinarité des schémas	61

III. Discussion sur nos résultats : limites et perspectives.....	65
III.1 Limites de notre travail	65
III.1.1 Limite de l'analyse en dépendances automatique de Talismane	65
III.1.2 Limitations des têtes spécifiques aux domaines.....	65
III.1.3 Limitations des têtes transdisciplinaires.....	66
III.1.4 Opérationnalisation des NSS.....	66
III.1.5 Manque d'un corpus de contraste.....	66
III.1.6 Disponibilité des listes de NSS et des lexiques scientifiques	66
III.2 Perspectives	67
III.2.1 Utilisation de la typologie de Schmid	67
III.2.2 Étude de la relation entre tête transdisciplinaire et éléments de contexte.....	67
III.2.3 Extension aux noms coordonnées à la tête ou au nom commun.....	67
Conclusion.....	69
Bibliographie	71
A1. Distance des domaines de par leurs têtes spécifiques.....	77
A2. Combinaisons des têtes de titres bisegmentaux.....	78
A3. Liste des têtes transdisciplinaires	80
A4. Étiquettes utilisées par Talismane et HAL	84
A4.1 Catégories morphosyntaxiques de Talismane.....	84
A4.2 Code des 27 domaines de HAL retenus	85
A5. Éléments techniques	87
A5.1 Présentation de l'API de requêtage de notre corpus	87
A5.2 Description de nos données informatiques	88
A5.3 Analyse de 100 titres traités par Talismane	89
A6. Index des tableaux.....	95

Résumé

Nous étudions la sous-spécification des têtes transdisciplinaires dans les titres de publications scientifiques. Nous rapprochons ces têtes transdisciplinaires, très fréquentes dans de nombreux domaines scientifiques, des noms employés de façon sous-spécifiée : des noms dont la carence sémantique est comblée par le contexte, nom et contexte étant reliés par une construction spécificationnelle. Pour mener à bien ce rapprochement, nous étudions les schémas récurrents dans lesquels s'insèrent les têtes transdisciplinaires des titres. Nous étudions ces schémas pour les rapprocher des constructions spécificationnelles déjà relevées dans la littérature. Ce rapprochement syntaxique et fonctionnel nous permet de dresser une liste des têtes transdisciplinaires s'employant le plus souvent de façon sous-spécifiée. Enfin, nous mettons en rapport les têtes sous-spécifiées et les schémas récurrents trouvés avec les différents domaines scientifiques.

Mots-clés : titre, tête, schéma, patron, nom porteur, emploi sous-spécifié, sous-spécification, construction spécificationnelle, contenu spécifiant, publication, article, domaine, discipline.

Remerciements

Je tiens à remercier mes deux codirecteurs de recherche, Mme Josette Rebeyrolle et M. Ludovic Tanguy, pour leur suivi, leur aide et leurs précieux retours sur mon travail tout au long de l'année.

Mes remerciements vont également à Mme Cécile Fabre et Mme Lydia-Mai Ho-Dac qui, avec M. Tanguy, ont accueilli ma démarche de reprise d'études avec intérêt et bienveillance, me permettant d'intégrer le master LITL tout en conservant mon emploi salarié.

Je tiens également à remercier M. Jean Favre, M. Olivier Dunyach et M. Frédéric Gil de la société Scalian DS et M. Dimitri Cognet de la société Thales Alenia Space pour avoir accueilli mon projet de reprise d'études favorablement.

Je veux remercier aussi mes camarades de promotion du master LITL qui ont bien voulu accepter mes contraintes d'emploi du temps liés à mon double statut d'étudiant et de salarié et avec qui j'ai partagé de nombreux moments studieux et amicaux.

Enfin, je tiens à remercier ma famille et mes amis, pour leur patience et leurs encouragements, pour m'avoir eux aussi accompagné durant les deux années de ce master.

Introduction

Un titre de document scientifique est un énoncé singulier d'une importance cruciale. D'une part, il s'agit d'un texte très court d'une dizaine de mots. D'autre part, il constitue le premier contact entre un document et ses lecteurs, suivi du résumé et enfin du document en lui-même (Whissell, 2012). Dans 92 % des cas, le lecteur s'arrêtera au titre (Mabe et Amin, 2002) : soit car le titre lui apporte la réponse qu'il cherche (Salager-Meyer et Alcaraz Ariza (2013) rapportent ainsi que certains médecins prennent des décisions cliniques fondées uniquement sur les titres), soit le plus souvent car le lecteur détermine que l'article ne l'intéresse pas. C'est donc sur la lecture du titre seul, indépendamment du document titré, que le chercheur fait son tri parmi la littérature scientifique (Goodman et al., 2001) dont la production augmente constamment en doublant tous les 12 ans (Stix, cité dans Salager-Meyer et Alcaraz Ariza, 2013).

Le tri effectué sur la seule lecture du titre soulève de nombreuses questions concernant l'information que contient un titre, les mots et les structures utilisés pour convoier l'information et leurs évolutions au fil du temps, le fonctionnement du titre et son intégration dans le discours, la recherche de règles prescriptives pour écrire un bon titre, ou encore la définition de ce qu'est un bon titre et les différentes mesures de performances d'un titre comme le nombre de téléchargements ou de citations du document. L'intérêt des chercheurs pour ces questions s'est traduit par de nombreux articles sur les titres en anglais. Les titres en français ont été moins étudiés. On peut néanmoins citer les travaux de Ho-Dac et al. (2004), Rebeyrolle et al. (2009) et Tanguy et Rebeyrolle (à paraître).

Un consensus émerge pour accorder deux fonctions principales aux titres (Haggan, 2004 ; Hartley, 2005, 2007 ; Salager-Meyer et Alcaraz Ariza. 2013 ; Whissell, 2012). La première est d'informer le lecteur sur le contenu du document en présentant ses points principaux : son sujet et son périmètre d'étude au minimum et éventuellement la méthode employée et les résultats obtenus (Anthony, 2001 ; Cheng et al., 2012 ; Jamali et Nikzad, 2011 ; Paiva et al., 2012 ; Swales et Feak, 1994, p. 205). La seconde fonction est d'attirer l'attention du lecteur (Hartley, 2005). Dans notre travail, nous prenons en compte uniquement la fonction informationnelle du titre, considérant, comme Grant (2013), Haggan (2004) et Hartley (2005), qu'elle est la plus importante. Notamment car elle oblige à ce que les mots du titre reflètent le contenu du document pour faciliter son appréhension cognitive lors du parcours d'une liste de titres par un chercheur, une activité scientifique régulière (Soler, 2007, p. 91), ou pour faciliter sa sélection automatique par des algorithmes (Haggan, 2004 ; Hartley, 2007 ; Merrill et Knipps, 2014), même si la recherche en plein texte diminue cet aspect. La fonction informationnelle est également plus facile à analyser que la fonction d'attraction qui peut considérablement obscurcir le sens d'un titre pour susciter l'intérêt (Hartley, 2005) ou faire appel à des notions complexes pour le traitement automatique des langues comme l'humour (Sagi et Yechiam, 2008 ; Subotic et Mukherjee, 2014). Enfin, Jalilifar et al. (2010) soutiennent qu'un titre ne peut pas être uniquement attractif, car ce serait une bien piètre indication pour les lecteurs. Un titre doit toujours donner des indices informationnels sur le contenu du document, l'attractivité étant là pour le distinguer des autres titres. En suivant ces auteurs, on peut donc considérer que la fonction d'attraction est secondaire par rapport à la fonction informationnelle.

La majorité de la littérature sur les titres traitant de titres d'articles de journaux scientifiques et de communications (Goodman et al., 2001, Haggan, 2004, Soler, 2007, Wang et Bai, 2007), notre travail se limite à ce type de publication et à celles dont les titres sont construits de manière similaire : chapitres d'ouvrages collectifs et communications ou posters dans des congrès ou des conférences.

Notre travail de première année avait consisté à étudier les noms apparaissant immédiatement après un double point dans les titres de publications scientifiques. Nous disposions d'un corpus de 85 500 titres en français de différents types de publications scientifiques, dont les plus nombreux étaient les articles, les communications et les chapitres d'ouvrage, issus d'un grand nombre de domaines scientifiques (voir la partie I.1.1 Récupération des données qui reprend la méthode de constitution de ce premier corpus pour établir notre corpus de travail de cette année).

Nous avons observé trois schémas lexico-syntaxiques récurrents d'emplois de ces noms couvrant 65 % des titres de notre corpus : 1) un syntagme nominal dont le noyau avait pour complément un syntagme prépositionnel enchâssant lui-même un syntagme nominal, couvrant 50 % de notre corpus, 2) un syntagme prépositionnel enchâssant le premier cas, couvrant 5 %, et 3) deux syntagmes nominaux coordonnés, couvrant 10 %. Nous avons également constaté l'utilisation récurrente et transdisciplinaire, commune aux différentes disciplines scientifiques, d'un lexique de noms communs placés immédiatement après le double point, dont les onze plus fréquents étaient : *étude, cas, approche, analyse, application, pratique, exemple, enjeu, perspective, modélisation, limite*.

Les noms distingués sont tous abstraits, ils ne dénotent pas un objet tangible du monde réel, et sont liés au domaine scientifique : on les retrouve tous, sauf *enjeu*, dans le lexique transdisciplinaire des écrits scientifiques (LTES) décrit par Tutin (2008). Par ailleurs, nous avons remarqué une similitude lexicale avec une classe de noms employés de façon très fréquente dans le discours académique (Flowerdew et Forest, 2015, p. 1) avec un contenu sémantique très faible spécifié par le contexte. On appelle les membres de cette classe des noms (en emploi) sous-spécifiés (NSS). Nous nous interrogeons donc sur l'éventuelle sous-spécification des noms employés dans les titres.

Pour enquêter plus largement sur ce phénomène de sous-spécification, nous souhaitons étendre notre périmètre d'étude à l'ensemble du titre, avant et après le double point, ou toute autre marque de ponctuation segmentant le titre en deux, et l'étendre également aux titres composés d'un seul segment. Nous prenons comme objet d'étude la tête, aussi appelée noyau ou racine, de ces segments. Le premier nom immédiatement après le double point étudié en première année était, à une préposition près dans le cas du deuxième schéma, la tête du second segment du titre. La redéfinition de notre objet d'étude englobe donc les noms appartenant au lexique commun trouvé en première année. La question est donc de savoir si les têtes de segments sont employées de manière sous-spécifiée.

Dans l'exemple (1)¹ ci-dessous, le titre est constitué de deux segments, délimités par un double point. L'exemple (2) montre lui un titre constitué d'un seul segment. Nous mettons en gras la tête de chaque segment.

(1) Un nouvel **OVNI** dans le ciel réunionnais : la **transparence** des prix

¹ Tous les exemples donnés sur fond gris sont tirés de notre corpus de titres.

(2) **Problème** d'acquisition de données par une torpille

Ce nouveau travail doit donc commencer par le découpage de nos titres en segments en reprenant et en amendant une liste de signes de ponctuation qui segmentent les titres en anglais, établie par Anthony (2001). Ensuite, pour trouver les têtes de syntagmes, plutôt que de simplement parcourir le segment et prendre le premier nom rencontré comme nous le faisons en première année, nous avons décidé d'utiliser l'analyse syntaxique en dépendances (Tesnière, dans Schwischay, 2001) pour identifier les têtes de segments.

Ce sont les têtes transdisciplinaires, très fréquentes dans de nombreux domaines scientifiques, qui nous semblent les meilleures candidates pour être rapprochées des NSS. On prend pour hypothèse que leur capacité à apparaître très fréquemment dans la plupart des domaines n'est possible qu'à cause d'un faible contenu sémantique, au contraire de noms sémantiquement pleins bien plus associés à un domaine particulier. *Céramique* évoque ainsi directement l'archéologie, l'art et l'histoire de l'art ou l'histoire, alors que *problème* semble sémantiquement creux. Seule la prise en compte du contexte de la tête transdisciplinaire permet d'accéder à son sens complet : de quel problème s'agit-il, sur quoi porte-t-il ?

Deux difficultés apparaissent déjà : les NSS sont une classe considérée comme ouverte (Flowerdew et Forest, 2015, p. 12 ; Schmid, 2000, p. 4) et une classe d'emploi, non une nature lexicale (Flowerdew et Forest, 2015, p. 7 ; Schmid, 2000, p. 13). On ne peut donc déterminer s'il s'agit d'un NSS qu'en fonction de son contexte où il est relié à un contenu qui le spécifie. La liaison entre le contenu spécifiant et le NSS se fait via une construction spécificationnelle (CS). Les deux constructions spécificationnelles les plus fréquemment étudiées, notamment par Schmid (2000, p. 22) pour l'anglais et transposées par Legallois (2008, p. 2) en français, sont :

CS-I. **NSS** + *être* + proposition subordonnée conjonctive commençant par *que* :

Le **problème** est que je n'avais pas d'argent.

CS-II. **NSS** + *être* + proposition subordonnée infinitive commençant par *de* :

Le **problème** est de ne pas avoir d'argent.

La question se pose de savoir si on retrouve nos noms dans de telles constructions dans les titres. Si le verbe *être* est optionnel pour Schmid (2000, p. 22), il n'en reste pas moins que la proposition doit contenir un verbe, conjugué dans le cas d'une proposition subordonnée conjonctive ou à l'infinitif pour une proposition subordonnée infinitive. Or, de nombreux travaux (Leech, 2000 ; Haggan, 2004 ; Soler, 2007 ; Cheng et al., 2012 ; Wang et Bai, 2007) soulignent la nature nominale des titres. Un milieu largement « averbal » comme les titres fait douter de retrouver les CS-I et CS-II dedans.

Néanmoins, Schmid (2000, p. 26) mentionne une autre CS de la forme **NSS** + *de* + syntagme nominal. Or, la complémentation des noms est une caractéristique de l'écriture académique (Biber et Gray, 2010), nos têtes pourraient donc s'insérer dans cette CS. Prenons les deux exemples (3) et (4), pour éclairer l'hypothèse d'un rapprochement possible entre les têtes et les NSS :

(3) Le **problème** de l'abandon de l'habitat dans la Corse médiévale

(4) Le **problème** du Paléolithique final de Haute-Normandie

Problème est un terme employé très fréquemment dans un emploi sous-spécifié selon Flowerdew et Forest (2015) et Schmid (2000, p. 85). Selon Schmid (2018, p.118), ce qui unit les contenus désignés comme un problème est qu'il s'agit d'un « *fait étant un obstacle au progrès* » ou, citant Tuggy dans ce même article (2018, p. 122), « *une chose qui n'est pas en conformité avec quelque chose établi ou désiré* ». On peut rajouter à ces définitions, une chose qui a des conséquences négatives. Ainsi est catégorisé à chaque fois un concept temporaire créé par l'énoncé : l'abandon de l'habitat dans la Corse médiévale pour (3) et le Paléolithique final de Haute-Normandie pour (4). Le choix de catégoriser ce concept de *problème*, au lieu de *question* par exemple, indique une volonté de l'interlocuteur de souligner qu'il y a un obstacle ou du moins un imprévu dans le raisonnement scientifique. On peut également voir que *problème* crée une liaison à son contenu spécificationnel dès le titre. Il pourra également créer des références anaphoriques en étant repris avec un démonstratif, *ce problème*, si ce n'est dans le titre du fait sa trop grande concision, dans le résumé ou le texte de la publication scientifique².

Outre les trois CS déjà mentionnées, il est également possible que les têtes s'intègrent à d'autres schémas d'utilisation très fréquents qui pourraient jouer le rôle de CS.

Des travaux précédents ont montré qu'il existe des spécificités disciplinaires dans l'écriture des titres pour l'anglais (Anthony, 2001 ; Haggan, 2004 ; Lewison et Hartley, 2005 ; Soler, 2007, 2011 ; Nagano, 2015) et le français (Tanguy et Rebeyrolle, à paraître). Nous ne manquerons pas de déterminer dans le cadre de notre problématique s'il existe des variations des têtes et des schémas suivant les domaines. Nous pourrions ainsi mettre au jour des têtes spécifiques à certains domaines et d'autres qui seraient transdisciplinaires.

Nous voulons déterminer la proximité de fonctionnement entre têtes transdisciplinaires et NSS en identifiant :

- Une liste de têtes transdisciplinaires dont nous déterminerons le statut par rapport aux NSS.
- Une liste de schémas récurrents dans lesquels s'inscrivent nos têtes transdisciplinaires que nous confronterons aux constructions spécificationnelles dans lesquelles les NSS s'inscrivent.
- Une répartition des têtes transdisciplinaires et des schémas par rapport aux domaines scientifiques.

Pour ce programme, nous utiliserons une approche se fondant sur le traitement automatique des langues et la linguistique de corpus (Biber et al., 1998 ; Cori et David, 2008 ; Williams, 2005). Pour les NSS, nous nous appuyons plus particulièrement sur Legallois (2008), sur la perspective constructionnelle et cognitive de Schmid (2000) et celle, discursive et constructionnelle, de Flowerdew et Forest (2015)

² Une recherche dans l'archive ouverte HAL sur « Le problème » dans le titre et « Ce problème » dans le résumé donne 192 résultats. La recherche sur « Le problème » dans le titre et « Ce problème » dans le texte intégral donne 336 résultats. Ramené au nombre des 2 millions de références de HAL, cette possibilité de reprise anaphorique est donc très faiblement employée.

(voir Adler et Moline, 2018 et Schmid, 2018, pour une comparaison des divergences et des points communs entre les deux approches).

Notre étude se déroulera en trois temps. Dans un premier temps, nous partons des données rassemblées pour délimiter un corpus de travail. Nous décrivons certains traits saillants de notre corpus à l'aide de différentes mesures, en faisant référence aux nombreux travaux existants. Notre démarche nous amènera à révéifier la nature éminemment nominale des titres. Nous étudierons les variations entre les différents domaines scientifiques, notamment les têtes de segments spécifiques à certains domaines. Dans un deuxième temps, nous construirons la liste des têtes de segments transdisciplinaires. Nous rappellerons les apports des travaux sur les noms sous-spécifiés et essayerons de détecter les constructions spécificationnelles dans lesquelles ils s'inscrivent généralement dans notre corpus. Nous détecterons ensuite les schémas récurrents dans lesquels s'inscrivent nos têtes transdisciplinaires pour essayer de rapprocher les schémas des constructions spécificationnelles et les têtes transdisciplinaires des noms sous-spécifiés. Nous nous appuierons notamment sur la forte fréquence et la transdisciplinarité des têtes transdisciplinaires pour fournir une liste de têtes transdisciplinaires se comportant comme des NSS. Enfin, dans un troisième temps, nous discuterons de nos résultats, des limites de notre travail et ouvrirons de nouvelles perspectives.

I. Exploration du corpus à la lumière de l'état de l'art

I.1 Origine et prétraitements des données

I.1.1 Récupération des données

L'accès aux titres a été grandement facilité par la création de bases de données bibliographiques, dont celles des archives ouvertes. Les chercheurs ou les documentalistes d'un centre de recherche sont libres de déposer un document sur une archive ouverte avec l'accord de ses auteurs. Une archive ouverte présente l'avantage de centraliser l'accès aux travaux scientifiques, d'aider à leur diffusion et de les conserver de manière pérenne, par rapport au site d'une institution particulière ou le site web personnel d'un chercheur, et de façon gratuite et accessible à tous, au contraire des éditeurs.

Nous utilisons le corpus constitué par Tanguy et Rebeyrolle (à paraître) comprenant près de 340 000 titres. Pour obtenir une si grande quantité de titres français, ils se sont tournés vers l'archive ouverte Hyper Article en Ligne (HAL, <https://hal.archives-ouvertes.fr>) (Nivard, 2010). Cette archive fonctionne depuis 2001 et est gérée par le Centre pour la Communication Scientifique directe du Centre National pour la Recherche Scientifique (CNRS). Elle contient plus de 1,6 million de références, qui sont soit des travaux dont elle possède une copie, soit des notices. HAL possède de nombreux types de documents différents : articles scientifiques mais aussi vidéo, cours, ouvrages ou thèses. Plusieurs institutions, dont le CNRS, encouragent le dépôt sur HAL des travaux produits par leurs chercheurs, garantissant un nombre important de titres issus de plusieurs domaines scientifiques. Alors que la majorité de la littérature traite des titres en anglais, HAL permet d'avoir accès à un grand corpus de titres en français. Nous veillerons dans ce premier chapitre à vérifier sur notre corpus certains enseignements tirés de l'étude des titres en anglais, notamment la nature des titres.

Notre matière de départ se restreint aux titres en français, d'articles scientifiques, de chapitre, de poster ou de communication, car nous prenons comme hypothèse qu'ils sont construits de manière similaire. Chaque titre est fourni avec cinq informations supplémentaires relatives à la publication titrée :

1. un **identifiant** unique de la publication et donc du titre ;
2. les prénoms et noms des **auteurs** de la publication dont on peut déduire le nombre d'auteurs ;
3. le **type** du document qui ne peut être qu'un article scientifique, un chapitre d'un ouvrage collectif, une communication ou un poster dans un congrès ou une conférence ;
4. l'**année** de publication ;
5. les **domaines scientifiques**, ou disciplines académiques, auxquels est associée la publication dont nous déduisons un domaine principal selon la méthode établie par Tanguy et Rebeyrolle (à paraître).

L'exemple (5) ci-dessous montre les différentes informations pour un titre donné :

(5) Villes durables et changement climatique : quelques enjeux sur le renouvellement des ressources urbaines

Identifiant	609897
Auteurs	Véronique Peyrache-Gadeau et Bernard Pecqueur
Type de document	Article scientifique (code ART)
Année de publication	2011
Domaines scientifiques	0.sde et 1.sde.mcg, le premier correspond aux sciences de l'environnement et le second à un sous-domaine des sciences de l'environnement.

HAL permet d'attribuer plusieurs domaines à un document. Les domaines sont organisés en une taxonomie possédant quatre niveaux de profondeur. Néanmoins la granularité des branches est très variable. Sciences de l'Homme et Société est une des racines de l'arbre, regroupant sous son égide de nombreux domaines scientifiques, allant de l'histoire aux littératures, alors que toutes les sciences exactes bénéficient quant à elles d'une racine propre comme informatique ou chimie. Tanguy et Rebeyrolle (à paraître) ont proposé une méthode de recodage des domaines pour n'en garder qu'un seul, le plus important et discriminant, que nous utilisons. Dorénavant, un titre est associé à un seul domaine principal : le domaine de premier niveau pour les sciences exactes, le domaine de second niveau pour les sciences humaines et sociales.

Nous avons relevé les domaines suivants, avec en gras les sciences exactes (voir pour l'annexe [A4.2 Code des 27 domaines de HAL retenues](#) pour une correspondance entre les codes et les domaines scientifiques) : anthropologie, archéologie et préhistoire, architecture, art et histoire de l'art, autres, **chimie**, droit, **économie et finance quantitative**, éducation, géographie, gestion et management, histoire, **informatique**, linguistique, littératures, **mathématiques**, philosophie, **physique, planète et univers**, psychologie, science politique, **sciences cognitives**, **sciences de l'environnement**, sciences de l'information et de la communication, **sciences du vivant** et sociologie.

I.1.2 Étiquetage et analyse syntaxique en dépendances

Les titres ont été analysés à l'aide du logiciel Talismane (Urieli et Tanguy, 2013 ; Urieli, 2013) qui fournit un découpage en différents tokens, mots et signes de ponctuation, et réalise un étiquetage morphosyntaxique des mots et une analyse syntaxique en dépendances des tokens. Pour chaque token du titre nous avons :

- sa **forme** dans le titre ;
- son **lemme** (pour les mots) ;
- sa **classe grammaticale/catégorie** (pour les mots, sinon nous avons "signe de ponctuation") ;
- des **informations complémentaires** ;
- son token **recteur** ;
- la **relation de dépendance** qui le lie à son recteur.

Les informations complémentaires dépendent de la classe grammaticale, comme le genre pour les noms, le mode et le temps pour les verbes. Les titres étant des textes très travaillés, ils ne nécessitent pas de prétraitement pour corriger les fautes, même s'il y en a de très rares comme la

concaténation d'un titre et d'un sous-titre sans token séparateur (6) ou le redoublement d'une préposition (7) :

(6) Développement stratégique du tourisme sportif de rivière par régulation corporatiste L'expérience du bassin de Saint Anne (Québec) appliquée aux Rivières de Provence

(7) Dispositif **de de** caractérisation simultanée de l'abondance de pucerons et de la croissance végétative d'arbres fruitiers

Il est à noter que Talismane a été conçu pour analyser des phrases beaucoup plus longues que des titres et entraîné sur de tels textes. On peut peut-être douter de sa capacité à analyser correctement les titres. Notamment, comme nous le verrons plus tard, les titres ne comportent souvent pas de verbes conjugués au contraire des phrases plus longues, ce qui pourrait pousser Talismane à reconnaître comme verbes des mots n'en étant pas. Nous avons donc décidé d'inclure une phase de vérification de l'analyse de Talismane lors de l'étape de sélection des têtes pour vérifier son comportement.

I.1.3 Segmentation des titres

Nous avons segmenté les titres selon la liste des signes de ponctuation segmentants établie par Anthony (2001). Nous en retranchons le tiret car il est utilisé pour lier de nombreux mots en français comme *e-commerce*, *semi-figement* ou *petit-déjeuner*. Nous avons pu vérifier que Talismane traitait les formes en *e-X* et *semi-X* comme un *e* ou *semi* suivi d'un tiret suivi d'un nom (voir la section **I.3.2.B Corrections de Talismane**). Nous y ajoutons le point d'exclamation et les points de suspension dont l'absence ne nous semble pas justifiée. Nous avons donc les signes segmentants suivants :

Type de ponctuation	Signe de ponctuation
Ponctuation forte	. ? ! ...
Ponctuation faible	; :

Tableau 1: signes de ponctuation segmentants

Il y a dans cette liste des signes de ponctuation forte, comme le point ou le point d'interrogation, et des signes de ponctuation faible comme le point-virgule ou le double-point. Le type de segmentation effectué découle directement du type de ponctuation : forte ou faible.

L'avantage d'utiliser le segment est qu'il s'agit d'une unité que nous définissons clairement à la suite d'Anthony (2001), directement applicable computationnellement, au contraire de la proposition dont la définition est selon Joseph Donato dans l'ouvrage collectif sous la direction de Mounin (1974, p. 273) « *très empirique* » et pour la laquelle la « *distinction entre syntagme et proposition n'était pas toujours très claire ni très systématique dans l'analyse des phrases spécifiques* ».

Dans notre matériau de départ, nous comptons 221 674 occurrences de signes de ponctuation segmentants. Le signe le plus fréquent est le double-point, qui compte pour 47 % de ces occurrences,

suivi du point pour 36 %, du point d'interrogation pour 13 %, et du point-virgule pour près de 2 %. Ces quatre signes comptent pour 98 % des occurrences. Ces chiffres témoignent de l'importance du double point dans les titres, qui est au centre de nombreux travaux (Diers et Downs, 1994 ; Dillon, 1981, 1982 ; Townsend, 1983) et de notre travail de première année.

I.1.4 Sélection de la tête des segments

Nous voulons ensuite récupérer la tête des segments, qui s'assimile à la notion de prédicat suivant la définition de Conrad Bureau, toujours dans Mounin (1974, p. 267) :

« Désigne, en syntaxe, l'élément central de la phrase, celui par rapport auquel tous les autres éléments de la phrase marquent leur fonction. Est prédicat celui des éléments : 1° qui ne dépend syntaxiquement d'aucun autre élément ; 2° par rapport auquel la phrase s'organise, et 3° dont la disparition détruit l'énoncé. »

Pour trouver les têtes et les compter, deux solutions s'offraient à nous. La première est une règle qui consiste à prendre le verbe conjugué du segment comme tête s'il y en a un, sinon une préposition si elle occupe la première position du segment et sinon le premier nom rencontré. Cette solution présente l'avantage d'être très simple mais nous avons peur de manquer des phénomènes remarquables ou de sélectionner le mauvais mot comme tête en nous fondant si fortement sur la position.

Nous avons donc opté pour la seconde solution qui consiste à utiliser l'outil Talisman pour effectuer une analyse syntaxique en dépendances du titre. Il s'agit d'une utilisation à minima de l'analyse en dépendances, uniquement pour faire émerger une tête, mais nous avons rencontré deux difficultés.

Notre but est que chaque segment ait une tête correctement identifiée mais la segmentation que nous effectuons, fondée sur des signes de ponctuation, est décorrélée de l'analyse de Talisman qui possède sa propre segmentation, que nous nommerons partition et le résultat des parties pour les distinguer de nos segments. Talisman va produire pour chaque partie un arbre avec une racine unique. Dans le cas nominal, chaque partie de Talisman correspond à un segment, et la tête de chaque segment est directement la racine de l'arbre produit par Talisman.

Mais si notre titre est constitué d'une seule partie elle-même composée de plusieurs segments, nous obtenons des segments sans tête. Nous avons décidé de nous limiter aux titres avec au maximum deux parties et deux segments car ils sont les plus nombreux dans notre matériau : nous comptons 87 % de titres avec une partie et 11 % avec deux et 58 % titres avec un segment et 37 % avec deux. On peut classer nos résultats d'analyse en trois cas :

1. Des titres ayant un segment et une tête ;
2. Des titres ayant deux segments dont un seul a une tête (soit le premier, soit le second) ;
3. Des titres ayant deux segments avec une tête dans chaque.

L'exemple (8) montre un titre à deux segments avec une segmentation faible, le double-point et l'exemple (9) montre un titre à deux segments avec une segmentation forte, le point. Les deux exemples ont pour Talisman une seule partie.

(8) L'**omniprésence** de la famille au sein de l'exploitation agricole : une *situation* de fait encouragé par les règles de droit

(9) **MODÈLES** THÉOTIQUES DE LA STRUCTURE DES JOINTS DE GRAINS. LES *MODÈLES* DE STRUCTURE DES JOINTS DE GRAINS ET LEUR UTILISATION³

Dans les deux exemples précédents, *omniprésence* et *modèles* (en gras) sont reconnus comme des têtes des premiers segments mais pas *situation* et *modèles* (en italique) pour les seconds segments. Nous utilisons Talismane comme une « boîte noire » et nous ne voulons pas entrer dans les détails de sa partition des titres et de son analyse. Nous voulons néanmoins prendre en compte les spécificités des résultats donnés pour mieux les exploiter dans la perspective de notre travail : trouver des têtes aux différents segments d'un titre.

Avant d'aborder notre méthode pour résoudre le premier problème des segments sans tête, nous devons présenter le second problème de notre approche. La fiabilité de Talismane n'étant pas assurée sur des énoncés courts et généralement averbaux comme des titres, nous avons décidé d'estimer sa fiabilité. Nous avons choisi un échantillon de 20 titres aléatoirement pour chaque structure, en différenciant le cas numéro deux selon que le segment sans tête est le premier et le second. Nous avons également choisi 20 titres ayant un segment et deux têtes pour observer cet ensemble et éventuellement tenter d'en reprendre des titres. Nous avons vérifié manuellement pour ces 100 titres le choix de la tête, sa catégorisation morphosyntaxique et son lemme. Les résultats complets sont dans l'annexe **A5.C Analyse de 100 titres traités par Talismane**. Si globalement, Talismane arrive à étiqueter morphosyntaxiquement et à trouver le lemme correctement dans des énoncés aussi courts que des titres, la fiabilité pour sélectionner les têtes diffère grandement selon la structure segments-têtes.

Avant d'aborder les résultats structure par structure, nous voulons aborder un premier point : Talismane ne catégorise comme type de dépendance racine, « root » dans sa nomenclature, que les verbes. Pour les autres catégories, il reconnaît que la tête est le token racine de l'arbre de l'analyse en dépendances mais sans qualifier sa relation de dépendance de racine : il indique « _ » au lieu de « root ».

Un second point concerne les segments sans racine dans les titres bisegmentaux. On observe dans ces segments sans racine un mot qui est uniquement régi par un mot de l'autre segment. D'après nos analyses manuelles, ce mot est le plus souvent la tête de l'autre segment. Nous avons donc développé un algorithme de sélection des têtes pour suppléer les déficiences de Talismane tout en gardant le bénéfice de l'analyse syntaxique en dépendances. Notre algorithme est présenté en détail après les résultats.

A. Titres avec un segment et une tête

Sur les 20 titres pris aléatoirement, Talismane a à chaque fois détecté la bonne tête, avec la bonne catégorie morphosyntaxique et le bon lemme, sauf une fois, où l'absence d'un accent ne lui a pas

³ Dans cet exemple, il n'y a pas d'espaces autour du point qui est pourtant bien reconnu comme marque de ponctuation.

permis de retrouver le lemme à partir de la forme. On peut donc estimer que les titres qui suivent cette structure sont correctement analysés par Talismane.

B. Titres avec un segment et deux têtes

Sur les 20 titres considérés, Talismane a analysé incorrectement douze titres et huit ont une analyse discutable. Nous ne considérons pas le tiret et la virgule comme des caractères segmentants alors qu'ils sont clairement utilisés comme tels par un titre pour le tiret et deux titres pour la virgule. De plus, les mots composés provoquent des erreurs d'analyse dans Talismane qui désigne comme tête la partie après le tiret. Enfin, on remarque un oubli de signe de ponctuation segmentant et un crochet droit utilisé comme signe de ponctuation segmentant qui entraînent à chaque fois une mauvaise analyse.

Nous pourrions changer notre liste de caractères segmentants, mais cela reviendrait à créer potentiellement de nouvelles erreurs. Nous décidons donc de ne pas utiliser les titres ayant deux têtes dans un seul segment.

C. Titres avec un segment ayant une tête suivie d'un segment sans tête

Sur les 20 titres, notre algorithme permet de sélectionner une tête valide dans le segment n'en contenant pas pour 17 d'entre eux. Deux titres utilisent la virgule comme un caractère segmentant. Enfin un dernier échappe à notre algorithme de sélection d'un mot pour sa promotion en tête de segment.

D. Titres avec un segment sans tête suivi d'un segment avec tête

Sur les 20 titres, notre algorithme permet de sélectionner une tête valide dans le segment n'en contenant pas pour 18 d'entre eux. On note des erreurs d'analyse de Talismane liées à une mauvaise catégorisation morphosyntaxique de mots dont cinq entraînent une mauvaise sélection de la tête.

E. Titres avec un segment avec tête suivi d'un segment avec tête

Sur les 20 titres, 16 sont correctement analysés par Talismane qui trouve les têtes des segments. Pour trois titres la tête est mal catégorisée et pour un dernier le lemme n'est pas trouvé.

F. Algorithme de sélection de tête de segment

Notre algorithme pour détecter la tête d'un segment à partir du résultat de l'analyse de Talismane est le suivant :

- Soit un mot du segment sans tête est régi par la tête de l'autre → promotion de ce mot comme tête. 46 798 titres ont une tête sélectionnée de cette façon.
- Soit le premier mot du segment sans tête est régi par un mot de l'autre segment → promotion de ce mot comme tête. 8 866 titres ont une tête sélectionnée ainsi.

Nous récupérons en tout 55 664 titres, soit 98 % des 56 851 titres ayant deux segments mais une seule tête. Ces titres problématiques comptent pour 18 % de l'ensemble des titres à un ou deux segments. Cela nous permet de récupérer plus de titres valides selon notre définition qu'il doit y avoir une tête par segment et au maximum deux segments par titre.

Une fois les données récupérées et prétraitées, nous constituons notre corpus de travail. Il faut pour cela établir un périmètre qui le délimitera. Il faut expliquer le choix de notre périmètre et effectuer des mesures dessus, afin de mettre en relation notre corpus de travail avec ceux étudiés précédemment dans la littérature.

I.2 Constitution d'un corpus de travail représentatif

Un périmètre de recherche établit dans le matériau de base une dichotomie claire entre ce que nous allons étudier et ce que nous n'étudierons pas. Plus un corpus est grand, plus la confrontation d'une hypothèse à son contenu aura de validité dans une approche *corpus-based*. Plus un corpus est grand, plus la formulation d'une hypothèse, à partir de la généralisation des faits observés dans le corpus, aura du poids dans une approche *corpus-driven* (Anthony, 2001 ; Biber, 2009).

Mais plus un corpus est large, plus nous risquons de nous confronter à des hapax remettant en cause confirmations et infirmations, ou rendant l'établissement de celles-ci beaucoup plus difficile. Nous pensons que, pour notre travail, le juste milieu est d'essayer de prendre le maximum de matériel tout en écartant les cas les plus rares, suivant ainsi le principe de *From-Corpus-To-Cognition* de Schmid (2000, p. 47) qui est que « *despite the indisputable charm of rare or exotic examples, one should mainly be interested in frequent and therefore systemically and cognitively more important items* ». Notre périmètre sera constitué sur deux points : la structure segmentale des titres et la nature des têtes.

I.2.1 Sélection selon la structure des titres

Nous avons décidé de prendre les titres composés de seulement un ou deux segments. Nous justifions ce choix par le fait qu'il s'agit de la plus grande majorité des titres (320 561 soit 94 % des titres initiaux) et qu'ils sont plus faciles à analyser. De nombreux travaux didactiques sur l'écriture des titres (Aleixandre-Benavent et al., 2014 ; Swales et Feak, 1994 ; Gustavii, 2008) conseillent d'ailleurs d'organiser les titres en deux segments autour d'un double point soit la forme *segment 1: segment 2*.

Un autre délimiteur que nous utilisons pour établir notre périmètre, en plus du nombre de segments dans le titre, est le nombre de têtes par segments. Nous nous limiterons aux titres avec au maximum une tête par segment. L'analyse en dépendance ne devant produire qu'une tête par segment, on peut considérer les segments bicéphales comme une aberration à écarter, souvent due au fait qu'une segmentation n'a pas été détectée, comme le montre l'étude des titres dans [A5.C Analyse de 100 titres traités par Talismane](#). On distingue donc deux cas : les titres composés d'un seul segment avec une tête et les titres composés de deux segments avec une tête chacun.

Il y a 171 890 titres composés d'un seul segment ayant une seule tête de segment, soit près de 51 % des données initiales, comme les exemples (10) et (11). Il y a 124 938 titres composés de deux segments, soit près de 37 % des données initiales, comme les exemples (12), (13) et (14). Nous indiquons en indice la catégorie morphosyntaxique du lemme.

(10) L'**actualité** _{nom} de la jurisprudence communautaire et internationale

(11) **Doit** _{verbe} -on écouter Björk ?

(12) Un nouvel **OVNI** _{nom} dans le ciel réunionnais : la **transparence** nom des prix

(13) La **performativité** _{nom} de l'évidence : **analyse** _{nom} du discours néolibéral

(14) **Traces** _{nom} de contenus africains sur Internet : **entre** _{préposition} homogénéité et identité

Du fait des limites entre les capacités de Talismane et notre définition des segments, certains segments n'ont pas de tête. Nous avons appliqué notre algorithme pour suppléer ces limitations.

Pour finir, nous gardons 110 785 titres composés de deux segments avec une tête dans chaque. Nous avons donc 171 890 titres monosegmentaux (61 %), 110 785 bisegmentaux (39 %), soit un corpus de travail de 282 675 titres, ce qui représente 83 % du matériau initial, les 340 000 titres collectés sur HAL. Nous avons réussi à conserver 83 % du matériau initial dans cette première étape de définition du périmètre de notre corpus de travail, néanmoins nous restreignons encore notre périmètre dans l'étape suivante pour nous intéresser à une catégorie morphosyntaxique particulière.

I.2.2 Sélection selon la nature des têtes

A) Répartition des natures des têtes

Nous nous sommes interrogé sur la nature de la tête des segments pour opérer une sélection sur ce critère. Cette question est directement liée à la question de la nature des titres. D'après Schwischay (2001, p. 11), « *un nœud forme avec tous les nœuds qu'il domine (directement ou indirectement) un syntagme ; et, par convention, ce syntagme porte le nom du nœud dominant* ». Nous pouvons donc, grâce à la complémentarité du modèle de l'analyse en constituants immédiats et celui de l'analyse en dépendances, déterminer le type de syntagme de chaque segment en étudiant la catégorie morphosyntaxique de sa tête à l'aide du tableau (2). La dernière colonne indique ces valeurs sur tous les segments des titres, soit 354 168 segments, en considérant les segments des titres bisegmentaux de façon indépendante.

Catégorie morphosyntaxique de la tête du segment	Titres monosegmentaux	Titres bisegmentaux, segment 1	Titres bisegmentaux, segment 2	Sur tous les segments (354168 segments)
Noms communs	136 734 80 %	82 959 75 %	84 960 77 %	304 653 86 %
Noms propres	11 094 6 %	10 406 9 %	4 758 4 %	26 258 7 %
Σ Tous les noms	147 828 86 %	93 365 84 %	89 718 81 %	330 911 93 %
Verbes à l'indicatif	8 186 5 %	3 478 3 %	3 513 3 %	15 177 4 %
Verbes à l'infinitif	5 135 3 %	6 004 5 %	2 140 2 %	13 279 4 %
Σ Tous les verbes	15 749 9 %	10 672 10 %	6 549 6 %	32 970 9 %
Prépositions	6 792 4 %	5 456 5 %	10 456 9 %	22 704 6 %

Tableau 2: Distribution des catégories morphosyntaxiques des têtes de segments

On peut remarquer des points communs : la grande majorité des têtes sont des noms, et a fortiori des noms communs, pour toutes les configurations segmentales. Les autres catégories les plus représentées sont les verbes à l'indicatif ou à l'infinitif et les prépositions. La différence la plus notable entre les premiers et seconds segments des titres bisegmentaux est que pour les seconds segments, la seconde catégorie la plus fréquente sont les prépositions et non les verbes : les têtes prépositionnelles sont presque deux fois plus fréquentes (9 %) que dans les segments des titres monosegmentaux (4 %) et dans les premiers segments des titres bisegmentaux (5 %).

On peut ensuite s'interroger sur les combinaisons possibles dans les titres bisegmentaux entre les catégories des deux têtes de segments. Nous agrégeons les différentes catégories nominales, verbales et prépositionnelles en trois catégories : Nom, Verbe et Préposition. Le tableau (3) présente les cinq combinaisons les plus fréquentes, sur 96 en tout. L'annexe **A2. Combinaisons des têtes de titres bisegmentaux** liste l'ensemble des 96 combinaisons existantes. Les cinq combinaisons les plus fréquentes couvrent 93 % des titres bisegmentaux. On constate là-aussi que la grande majorité des titres bisegmentaux ont à chaque fois un nom pour tête de segment.

Catégorie de la tête du premier segment	Catégorie de la tête du second segment	Nombre de titres et pourcentage
Nom	Nom	75 592 (68 %)
Nom	Préposition	8 996 (8 %)
Verbe	Nom	8 506 (8 %)
Nom	Verbe	5 426 (5 %)
Préposition	Nom	4 650 (4 %)

Tableau 3 : Combinaisons agrégées les plus fréquentes de têtes dans les titres bisegmentaux

Notons qu'il existe 409 titres dont le premier et le second segment ont le même lemme pour tête. Ce qui vient à l'esprit en regardant les exemples de (15) à (20), c'est la possibilité de produire un effet stylistique de répétition et la possibilité d'introduire une comparaison ou un questionnement :

- (15) La **crise** ? Quelle **crise** ?
 (16) **Crise** du logement ? Quelle **crise** ?
 (17) **Ville** de jour. **Ville** de nuit
 (18) **Linux** embarqué. **Linux** Temps Réel
 (19) **Feu** l'arrêt Mercier ! **Feu** l'arrêt Mercier ?
 (20) **Corps** dansant. **Corps** glorieux

Cette répétition est à rapprocher de l'usage dans les titres de la figure de style du chiasme détectée par Tanguy et Rebeyrolle (à paraître, 2.2) où deux mots sont repris dans l'ordre inverse. Ici, la reprise ne joue pas sur l'ordre inversée mais sur la détermination différente dans (15) et (16), la

complémentation par un groupe nominal dont les noyaux sont antonymes (17), le changement de point final (19), ou simplement une différence dans l'expansion du nom (18, 20).

B) La nature nominale des titres

Chercher la nature d'un titre revient à s'interroger sur la nature de ses têtes de segments. Pour les titres monosegmentaux, déterminer la nature du titre revient à prendre la nature de son unique segment. On obtient à partir du tableau (2) directement 86 % de titres nominaux. Pour les titres bisegmentaux, on peut considérer deux options. La première est qu'un titre est nominal si son premier segment l'est. On obtient alors 84 % de titres nominaux. L'autre option est de considérer qu'un titre est "purement" nominal si et seulement si les deux têtes de ses segments sont des noms. On obtient alors 68 % de titres nominaux.

Quelle que soit la solution choisie, les titres sont majoritairement constitués d'un ou plusieurs syntagmes nominaux et non d'une phrase avec un noyau verbal, ce qui rejoint les conclusions de nos prédécesseurs (Leech, 2000 ; Haggan, 2004 ; Soler, 2007 ; Cheng et al., 2012 ; Wang et Bai, 2007). Cheng et al. (2012) relèvent jusqu'à 93 % de titres nominaux pour leur corpus et Wang et Bai (2007) 99 % pour le leur. Jalilifar et al. (2010) résument les raisons de cette prédominance, qui s'applique aussi bien aux titres monosegmentaux (Jalilifar, 2010, p. 45) que bisegmentaux (Jalilifar, 2010, p. 47) : « *the ability to compact information in an economical way through various pre and postmodifiers (Wang et Bai, 2007) makes noun phrase titles more informative and explanatory than other structures (Yakhontova, 2002).*

Pour notre corpus de travail, nous décidons de nous restreindre aux titres monosegmentaux dont la tête est un nom et aux titres bisegmentaux dont au moins une des têtes de ses segments est un nom, l'autre pouvant être un nom, une préposition ou un verbe. Ce choix nous permet de garder la grande majorité de nos titres et d'éliminer les cas les moins fréquents. Nous obtenons un corpus de 250 998 titres, soit 74 % du matériau initial, ce qui nous semblait important pour renforcer nos hypothèses en les établissant sur le plus grand nombre possible de faits linguistiques.

Une fois le périmètre des titres étudiés défini sur la structure segmentale des titres et la nature grammaticale de leurs têtes, nous avons constitué notre corpus de travail. Nous pouvons alors effectuer plusieurs mesures sur notre corpus et les mettre en rapport avec les mêmes mesures effectuées dans des travaux précédents, avant d'étudier plus avant les têtes de syntagmes.

I.2.3 Un corpus de travail représentatif du matériau de base

Nous avons défini notre périmètre d'étude comme portant sur 250 998 titres constitués d'un ou deux segments. Les titres monosegmentaux (147 828 soit 59 %) ont une tête nominale, les titres bisegmentaux (103 170, 41 %) ont au moins un segment ayant une tête nominale, l'autre ayant une tête verbale, nominale ou prépositionnelle.

On notera que les différentes caractéristiques des titres ne sont pas indépendantes : Kutch (1978), Yitzhaki (1994) et Tanguy et Rebeyrolle (à paraître) ont ainsi montré que le nombre d'auteurs est corrélé positivement à la longueur du titre. Larivière et al. (2015) ont montré que le domaine est lié au nombre d'auteurs : il y a en moyenne plus d'auteurs dans les sciences exactes. Baethge (2008) a montré que le nombre d'auteurs augmente avec le temps. Tanguy et Rebeyrolle (à paraître) ont également

montré, en partant des mêmes données de base et donc avec le même déséquilibre de répartition, que la longueur était très légèrement corrélée à l'année de publication.

Sur la longueur des titres, les titres monosegmentaux ont une longueur moyenne de 10,38 mots, avec une longueur minimale de 1 mot et une longueur maximale de 77 mots, tandis que les titres bisegmentaux ont une longueur moyenne de 14,45 mots, avec une longueur minimale de 2 mots et une longueur maximale de 228 mots. Les titres bisegmentaux les plus courts sont au nombre de 64. Quarante-neuf utilisent comme signe segmentateur le double point et 51 sont des chapitres d'ouvrage dont 29 sont de la forme *Entrée : NC*, indiquant une entrée dans un ouvrage de type dictionnaire ou encyclopédie. La longueur supérieure des titres bisegmentaux s'explique par la facilité de traitement qu'apporte la segmentation à l'interlocuteur : la segmentation sert à la fois de pause et d'articulation pour sa compréhension. La longueur moyenne des titres du corpus de travail est de 12,05 mots, alors que celle des données de départ est de 13,8 mots. Cette constatation est normale car il existe des titres ayant plus de deux segments que notre corpus de travail n'inclut pas.

On peut regarder comment notre corpus se répartissent en fonction du type de publication scientifique :

Type de publication	Titres monoseg.	Titres biseg.	Corpus
Article	63 993 43 %	45 827 44 %	109 820 44 %
Communication	53 148 36 %	35 350 34 %	88 498 35 %
Chapitre d'ouvrage	29 413 20 %	21 221 21 %	50 634 20 %
Poster	1 274 1 %	772 1 %	2 046 1 %

Tableau 4 : Distribution des structures des titres selon le type

La structure des titres n'est pas corrélée au type de publication, la distribution des deux ensembles étant presque identique. De plus, cette répartition est quasi identique à celle de l'ensemble des 340 000 titres qui constituent nos données de départ (Tanguy et Rebeyrolle, à paraître).

On peut aussi mesurer le nombre d'auteurs en fonction de la structure du titre :

Nombre d'auteurs	Titres monoseg.	Titres biseg.	Corpus
1	87 646 59 %	65 199 63 %	152 845 61 %
1-4	135 564 92 %	96 581 94 %	232 145 92 %
1-9	146 767 99 %	102 307 99 %	249 074 99 %

Tableau 5 : Distribution des structures des titres selon le nombre d'auteur

On voit bien que quelle que soit la structure du titre, la répartition par le nombre d'auteurs est la même pour les deux sous-ensembles de notre corpus de travail que pour le corpus de travail pris dans sa totalité et sur l'ensemble des données où 62 % des articles avaient également un seul auteur.

On regarde également la répartition par années de publication. Pour l'ensemble du corpus, elles s'étendent de 2019 pour les sept publications les plus récentes à 1779 pour la plus ancienne. On note que 85 % des publications ont été publiées en 2000 ou après, 90 % après 1994 et 99 % après 1933. Pour l'ensemble des données, Tanguy et Rebeyrolle (à paraître) trouvent les mêmes années pour les deux premiers pourcentages et un peu plus tard, 1940, pour le dernier. Notre corpus ne peut donc pas servir pour des études diachroniques du fait de sa répartition totalement inégale sur le temps. La période qui comporte le plus de titres, de 2005 à 2017, soit 74 % du corpus, est également trop courte. La répartition est similaire pour nos deux sous-corpus, titres monosegmentaux et bisegmentaux. Nous pouvons à présent étudier comment la structure segmentaire des titres et les têtes varient selon les domaines.

I.3 Structures semblables des domaines et têtes spécifiques

I.3.1 Variations de la structure en fonction du domaine

Nous regardons à présent la répartition des titres par domaine pour le corpus et les deux sous-corpus. Nous rappelons que nous avons sélectionné, grâce à la méthode décrite dans Tanguy et Rebeyrolle (à paraître), un seul domaine principal pour chaque titre. Le tableau (6) présente les 27 domaines qui existent dans notre corpus. Nous avons mis en gras les domaines des sciences exactes.

N°	Domaine	Corpus Nb/fréq/fréq. cumul	Répartition entre	
			Titres monosegmentaux	Titres bisegmentaux
01	Physique	26 559 11% 11%	81 %	19 %
02	Sociologie	23 732 9% 20%	48 %	52 %
03	Droit	21 486 9% 29%	67 %	33 %
04	Histoire	19 093 8% 36%	54 %	46 %
05	Pas de domaine associé	18 941 8% 44%	59 %	41 %
06	Gestion et management	18 318 7% 51%	45 %	55 %
07	Sciences du vivant	17 498 7% 58%	66 %	34 %
08	Informatique	13 505 5% 63%	74 %	26 %
09	Linguistique	11 556 5% 68%	52 %	48 %
10	Littératures	10 712 4% 72%	52 %	48 %
11	Archéologie et Préhistoire	10 124 4% 76%	61 %	39 %
12	Science politique	7 152 3% 79%	46 %	54 %

13	Éducation	7 062	3%	82%	50 %	50 %
14	Art et histoire de l'art	6 471	3%	85%	53 %	47 %
15	Philosophie	6 152	2%	87%	60 %	40 %
16	Sciences de l'environnement	5 542	2%	89%	54 %	46 %
17	Sciences de l'information et de la communication	5 481	2%	91%	46 %	54 %
18	Anthropologie	5 166	2%	93%	51 %	49 %
19	Architecture	3 444	1%	95%	51 %	49 %
20	Planète et Univers	2 781	1%	96%	62 %	38 %
21	Mathématiques	2 377	1%	97%	81 %	19 %
22	Sciences cognitives	2 370	1%	98%	53 %	47 %
23	Chimie	2 185	1%	99%	69 %	31 %
24	Psychologie	2 006	1%	99%	54 %	46 %
25	Géographie	860	0%	100%	51 %	49 %
26	Économie et finance quantitative	346	0%	100%	47 %	53 %
27	Autres	79	0%	100%	54 %	46 %
	Sciences exactes	73 163	29%		72 %	28 %
					moyenne 65 % écart-type 0.11 écart-type relatif 18 %	
	Sciences humaines et sociales	177 835	71%		54 %	46 %
					moyenne 53 % écart-type 0.06 écart-type relatif 10 %	

Tableau 6 : Distribution des structures selon le domaine

On compte 73 163 titres en sciences exactes, ce qui représente 29 % de notre corpus et 177 835 titres en sciences humaines et sociales, soit 71 %.

Les titres des sciences exactes ont tendance à être plus souvent monosegmentaux que les titres des sciences humaines et sociales. Si l'on regarde la moyenne des répartitions par domaine, l'écart-type relatif important nous pousse néanmoins à la prudence. Parmi les sciences exactes, les mathématiques et la physique utilisent le plus fréquemment des titres monosegmentaux, où ils représentent 81 % des titres. Ces domaines sont suivis par l'informatique, où ils représentent 74 % des titres, suivie de la chimie avec 69 %, des sciences du vivant avec 66 % et des sciences des planètes et de l'univers avec 62 %.

Les sciences humaines et sociales sont globalement plus équilibrées entre l'utilisation de titres monosegmentaux et bisegmentaux. L'écart-type relatif de 10 % montre néanmoins que cet équilibre global varie d'un domaine à l'autre. Ainsi le droit avec 67 %, l'archéologie et la préhistoire avec 61 % et la philosophie avec 60 % privilégient elles aussi le titre monosegmental.

Si on compare la répartition par domaine de notre corpus de travail par rapport à l'ensemble des données initiales, nous avons le même ordre que celui relevé par Tanguy et Rebeyrolle (à paraître). Nous notons également que la répartition entre les domaines n'est pas homogène, certains étant très peu représentés, les plus faiblement dotés étant la géographie avec 860 titres, l'économie et finance quantitative avec 346 titres, et le domaine autres avec 79 titres. D'où la nécessité de travailler en fréquence relative pour les phénomènes que nous étudierons tout en retenant qu'une fréquence relative peut dissimuler un très petit phénomène : un phénomène ayant une fréquence relative importante de 15 % dans le domaine autre, ne concernera finalement que onze titres, rendant ce calcul très sensible à l'ajout ou au retrait d'un titre dans l'ensemble considéré.

I.3.2 Têtes spécifiques à un domaine

A) Définition et principe de sélection

Nous souhaitons faire émerger une liste de têtes spécifiques aux domaines et interpréter ce qu'on y trouve. Intuitivement, on peut penser retrouver les principaux objets d'étude des différents domaines. Pour chaque tête, on peut établir deux séries statistiques ayant autant de valeurs qu'il y a de domaines :

1. Les fréquences relatives de la tête dans les différents domaines :

$$\frac{\text{nombre d'occurrences de la tête dans le domaine}}{\text{total des occurrences des têtes du domaine}}$$

2. La répartition relative des occurrences de la tête entre les différents domaines :

$$\frac{\text{nombre d'occurrences de la tête dans le domaine}}{\text{total des occurrences de la tête dans le corpus}}$$

Nous cherchons dans cette partie indifféremment les noms communs et les noms propres. Pour un résultat plus interprétable, lorsqu'une tête de segment qui est un nom propre est suivie par un autre nom propre, ou *de* et un autre nom propre, nous concaténons cette séquence en une seule forme qui devient la nouvelle tête, pour éventuellement réunir un prénom, optionnellement la particule et un

nom. Nous estimons qu'il est plus intéressant de tester si *Gustave Eiffel*, *Gustave Flaubert* et *Gustave Guillaume* sont des têtes spécifiques à un domaine que *Gustave* qui est beaucoup plus générique.

Pour être véritablement spécifique à un domaine, une tête doit y être très fréquente mais également apparaître le moins possible dans d'autres domaines. Nous avons décidé d'utiliser pour sélectionner les têtes spécifiques le calcul de TF*IDF en l'adaptant à notre configuration particulière. Nous considérons en effet chaque domaine comme un seul vaste document où apparaîtraient tous les titres, le TF est alors la fréquence du terme dans le domaine. Le TF*IDF adapté devient alors :

$$TF * \log_{10}(\text{nombre total de domaines} / \text{nombre de domaines avec ce terme})$$

Le calcul de têtes spécifiques à un domaine n'a pas de sens pour le domaine Autres et les titres sans domaine associé : nous gardons donc seulement 25 domaines pour nos calculs. Chaque tête aura alors une valeur de TF*IDF par domaine, son coefficient de spécificité. Une tête présente dans les 25 domaines aura un TF*IDF de zéro.

B) Corrections de Talismane

Nos résultats, fondés sur un faible nombre d'occurrences, peuvent être très sensibles à une lemmatisation ou une catégorisation erronée d'un mot. Pour les améliorer, nous avons corrigé certaines erreurs et limitations de l'étiquetage morphosyntaxique et de la lemmatisation opérés par Talismane en établissant un dictionnaire de corrections. Le tableau (7) liste nos 13 catégories d'erreurs. Pour savoir comment les corriger, nous avons regardé les différents titres concernés pour établir à chaque fois une règle ad-hoc, la colonne Nombre indiquant le nombre de corrections effectuées :

Erreur ou limitation	Correction	Exemples	Nombre
1. Faux nom propre Nom commun catégorisé à tort comme nom propre avec un lemme inconnu car forme avec une majuscule	Lemme ajouté, catégorie corrigée à nom commun	Effet, Adolescence, Autoformation, Approche, Cohomologie, Teneur, Polyhandicap	228
2. Faux nom commun Nom propre erronément catégorisé commun nom	Catégorie corrigée à nom propre	bitcoin, crétaçé	16
3. Lemme de nom commun non reconnu car erreur d'orthographe	Lemme corrigé, catégorie corrigée pour Synthçse	Quantification, évènement, indicateus (-r), Synthçse	17
4. Lemme de nom commun non reconnu car caractère non compris	Lemme corrigé (en écrivant oeuvre)	œuvre	876
5. Lemme de nom commun non reconnu	Lemme ajouté	démotorisation, maritimisation,	849

		Compactification, Ondelettes	
6. Lemme de nom propre non reconnu	Lemme corrigé	Paris, Freud	1927
7. Lemme de nom propre non reconnu car concaténation du prénom et du nom	Lemme corrigé (nous concaténons prénom et nom lorsque nous avons une tête constituée d'une suite de deux noms propres : ceci n'est pas pris en compte par Talismane et n'est pas à proprement parler une erreur de celui-ci)	Jacques Androuet, Claude Perrault, Jean Cocteau	66
8. Forme faussement reconnue comme nom alors qu'il s'agit d'un adjectif	Forme non prise en compte et retirée de nos calculs	Cyber, Environnemental, Global	36
9. E- et Semi- considérés comme un nom propre indépendant	Lemme corrigé en e- ou semi- + lemme suivant	E-chronic, E-commerce, E-administration, e-inclusion, Semi-figement	608
10. s considéré comme un nom commun à cause d'un signe de ponctuation	On regarde à gauche et à droite du s pour trouver un nom commun ou un nom propre après un signe de ponctuation	mobilité.s, Linguistique(s), Quel(s) avenir(s)	404
11. Mot anglais non reconnu catégorisé à tort comme nom commun	Forme non prise en compte et retirée de nos calculs, provenant de titres en anglais	The	59
12. Nom commun anglais non reconnu	Prise en considération de son lemme en français	Synthesis, risk, Treatment	21
13. Emploi d'un nom propre au pluriel	Lemme corrigé à la forme singulière	Venises	1

Tableau 7 : Corrections opérées sur l'étiquetage et la lemmatisation

Une fois ces corrections effectuées sur notre corpus de travail, nous pouvons passer notre filtre dessus pour obtenir les têtes spécifiques à certains domaines, en les classant par leur valeur de TF*IDF.

C) Évaluation des résultats

Avec la formule du TF*IDF, toutes les têtes d'un domaine seront classées par ce facteur de spécificité. Le nombre de têtes différentes par domaine va de 272, pour l'économie et finance quantitative, à 7 005 pour l'histoire en comptant les têtes ayant un facteur d'une valeur de zéro. On

compte en tout 30 410 têtes différents. Nous présentons dans le tableau (8) ci-dessous un extrait de notre résultat en prenant les dix premières têtes, selon leur score de TF*IDF, pour nos 25 domaines. Pour tous les domaines, classés par ordre alphabétique, nous indiquons trois nombres : le nombre de lemmes de têtes, le nombre d'occurrences de têtes et le nombre de titres.

	Domaine	Têtes associées
01	Anthropologie 2 579 / 6 942 / 5 166	ethnologie, ethnologue, anthropologie, ethnographie, Népal, sépulture, pentecôtisme, François Cadic, rite, rituel
02	Archéologie et préhistoire 3 444 / 13 391 / 10 124	céramique, sanctuaire, décor, nécropole, sépulture, occupation, mobilier, archéologie, vaisselle, habitat
03	Architecture 1 624 / 4 629 / 3 444	ambiance, urbanisme, ville, fortification, habitat, château, photogrammétrie, quartier, Broadacre City, concepteur
04	Art et histoire de l'art 3 376 / 8 685 / 6 471	vitrail, verrière, décor, musique, peinture, sculpture, notice, théâtre, artiste, peintre
05	Chimie 788 / 2 710 / 2 185	catalyse, catalyseur, oxydation, ligand, polymère, spectroscopie, hydrogénation, nanoparticule, membrane, préparation
06	Droit 4 189 / 26 398 / 21 486	droit, juge, clause, obligation, contentieux, chronique, garantie, cession, responsabilité, jurisprudence
07	Économie et finance quantitative 272 / 489 / 346	aversion, GRP, déterminant, complexification, aluminium, assuabilité, polyhandicap, Solvency II, traitement, Paul W
08	Éducation 1 786 / 9 445 / 7 062	autoformation, didactique, éducation, e-inclusion, hypermédia, enseignant, informatique, scolarisation, ordinateur, TICE
09	Géographie 604 / 1 191 / 860	démographie, excision, SIDA, fécondité, vigie, mutilation, écologie, appui, géomorphologie, scolarisation
10	Gestion et management 3 546 / 25 955 / 18 318	comptabilité, management, finance, financement, déterminant, gouvernance, marketing, GRH, RSE, internationalisation
11	Histoire 7 005 / 25 671 / 19 093	évêque, noblesse, historiographie, manuscrit, femme, guerre, notice, abbaye, protestant, italien
12	Informatique 3 281 / 16 241 / 13 505	algorithme, ordonnancement, segmentation, extraction, optimisation, routage, détection, minimisation, visualisation, spécification
13	Linguistique	néologie, figement, verbe, préposition, grammaticalisation,

	3 435 / 15 512 / 11 556	phonologie, syntaxe, prosodie, adjectif, corpus
14	Littératures 5 142 / 14 278 / 10 712	littérature, roman, Proust, poétique, Perceforest, poésie, théâtre, Montaigne, René Char, poème
15	Mathématiques 888 / 2 745 / 2 377	cohomologie, théorème, estimation, package, approximation, optimisation, mathématique, algorithme, compactification, Mixmod
16	Philosophie 2 800 / 7 856 / 6 152	philosophie, Leibniz, Spinoza, Descartes, Bergson, Kant, Habermas, Nietzsche, Poincaré, Henri Poincaré
17	Physique 3 603 / 30 667 / 26 559	antenne, optimisation, spectroscopie, spectre, laser, propagation, absorption, excitation, commande, diffraction
18	Planète et Univers 1 244 / 3 675 / 2 781	ammonite, géologie, Crétacé, gisement, forage, métamorphisme, excursion, datation, bassin, massif
19	Psychologie 943 / 2 663 / 2 006	autisme, psychologie, psychologue, sevrage, psychanalyse, scarification, psychodrame, psychose, clinique, hallucination
20	Science politiques 2 520 / 9 864 / 7 152	élection, parti, sociologie, justice, Turquie, État, politisation, décentralisation, vote, parlement
21	Sciences cognitives 1 164 / 3 141 / 2 370	précocité, proverbe, adjectif, grammaticalisation, catégorisation, phonologie, but, psychologie, prosodie, NBIC
22	Sciences de l'environnement 1 983 / 7 484 / 5 542	brève, bibliographie, agriculture, karst, muraille, Pralognan, cadastre, émission, forêt, Médiaterre
23	Sciences de l'information et de la communication 2 053 / 7 523 / 5 481	journalisme, média, bibliothèque, télévision, sémiotique, journaliste, SIC, communication, blog, open
24	Sciences du Vivant 3 800 / 22 149 / 17 498	dosage, protéine, lait, acide, sécrétion, digestion, infection, alimentation, teneur, nutrition
25	Sociologie 5 268 / 32 398 / 23 732	sociologie, ville, géographe, géographie, tourisme, nuit, quartier, socialisation, déscolarisation, territoire

Tableau 8 : Les dix têtes les plus spécifiques de chaque domaine

On constate plusieurs faits : le premier est une mise en garde sur la limite de dix têtes choisies pour la présentation du tableau (8). Selon le nombre de titres et le nombre de lemmes différents dans le domaine, les mots sélectionnés peuvent avoir des nombres d'occurrences très variés. Plus le nombre de titres étudiés est faible, plus le nombre d'occurrences sur lequel est fondé le résultat est bas. Un résultat dépendant d'un faible nombre d'occurrences est beaucoup moins fiable quant à sa reproductibilité sur un autre corpus et donc sa généralisation.

Dans l'éducation, on constate la présence dans les dix premières spécifiques de *ordinateur* alors qu'il apparaît en 72^e position en informatique. Avec seulement 12 occurrences en informatique, on peut présumer qu'il s'agit là d'un terme trop générique pour la science dont c'est le principal objet et donc délaissé dans les titres soumis à une forte contrainte informationnelle et de concision.

Les sciences cognitives, avec seulement 2 370 titres, sont à la croisée de plusieurs domaines, notamment la linguistique et la psychologie, ce qui peut expliquer la non-présence de têtes « propres ».

Seule l'évaluation des résultats permet de juger de la pertinence de notre méthode. Le premier contrôle que nous pouvons effectuer, bien que très subjectif et limité, et de parcourir nous-même ces têtes, classées par TF*IDF pour voir si les premières semblent plus correspondre au domaine associé que les suivantes. Ce premier contrôle est positif : les têtes avec le plus haut TF*IDF semblent effectivement les plus proches des objets d'études des domaines, comme *céramique* et *nécropole* pour l'archéologie. L'extrême majorité des têtes ayant un TF*IDF élevé est ce que Schmid (2000, p. 15) appelle des *full-content nouns* ayant un contenu sémantique important. Nous remarquons néanmoins la tête *brève*, pour le domaine des sciences de l'environnement, qui ne désigne pas un objet d'étude mais un support de publication.

Une méthode d'évaluation possible était de comparer les têtes avec des lexiques spécialisés pour mesurer la précision et le rappel. Néanmoins, cela exige de ne sélectionner qu'une partie des têtes spécifiques à l'aide d'un filtre pour ne pas avoir trop de bruit. Ce filtre peut être un seuil appliqué à la valeur de TF*IDF plutôt que de prendre les X premières têtes. Il faudrait dans ce cas faire attention au taux de couverture des têtes sélectionnées par un tel seuil : plus il sera élevé, plus on sera sûr d'avoir des têtes spécifiques au détriment du nombre de titres couverts.

Une autre approche est de calculer une distance entre les domaines : si on assimile les domaines à un sac de têtes, où pour chaque tête, on met la valeur de son TF*IDF ou 0 si la tête n'apparaît pas dans le domaine, on obtient un vecteur à 30 410 dimensions. On peut ensuite calculer une distance généralisée entre les domaines pour savoir lesquels sont les plus proches et les plus éloignés en termes de têtes dont l'annexe **A1. Distance des domaines de par leurs têtes spécifiques** présente le résultat. On constate ainsi que la sociologie a pour domaine le plus proche le domaine gestion et management et comme domaine le plus éloigné la chimie. Cette représentation permet d'avoir un aperçu de comment les domaines se positionnent les uns par rapport aux autres par la spécificité de leurs têtes et ainsi vérifier la validité de notre approche.

Un lemme peut avoir une valeur distinctive de TF*IDF dans plusieurs domaines, ce qui traduit que cet objet d'étude est partagé par les différents domaines et qu'il n'a pas de pertinence pour un grand nombre d'autres. L'importance dans chaque domaine est pondérée par la valeur de TF*IDF. Par exemple, *femme* a une valeur de 0,0003 en géographie, sciences de l'information et de la communication et psychologie, 0,0004 en sociologie, anthropologie et littérature et 0,0007 en histoire. Néanmoins, une forte limite de cette approche est la polysémie de certaines têtes. *l'architecture* en informatique n'est pas la même que dans le domaine de l'architecture, de même qu'une *tempête* en sciences exactes et en sciences humaines et sociales.

Nous avons dans cette partie établi le périmètre délimitant notre corpus de travail et mesuré ses contours. Nous avons décidé d'étudier le cas majoritaire : celui des titres monosegmentaux ou bisegmentaux possédant au moins une tête nominale.

Notre corpus de travail se compose de 250 998 titres, soit 74 % du matériau initial. Notre corpus de travail est représentatif du matériau initial en ce qui concerne la répartition des titres par type de publication, nombre d'auteurs ou domaine. Nous avons démontré que les titres sont essentiellement des syntagmes nominaux à 85 % si on ne considère que le premier segment des titres bisegmentaux et les titres monosegmentaux.

La répartition des titres par domaine n'est pas homogène, 71 % des titres se rapportent aux sciences humaines et sociales contre 39 % pour les sciences exactes. Les premières utilisent de façon à peu près égale les titres monosegmentaux et bisegmentaux alors que les sciences exactes favorisent les titres monosegmentaux. Nous avons également calculé un indice de spécificité des têtes par rapport à un domaine particulier en se fondant sur le TF*IDF.

Nous voulons à présent étudier des têtes qui sont à l'inverse des têtes spécifiques : des têtes fréquentes dans toutes les disciplines, que nous appellerons têtes transdisciplinaires.

II. Têtes transdisciplinaires et NSS dans le corpus

Dans cette partie, nous poursuivons notre étude des têtes de nos segments. Nous avons vu que nous avons une tête par segment et de un à deux segments par titre. Cela fait donc trois sous-ensembles de notre corpus de travail : les segments des titres monosegmentaux, les premiers segments des titres bisegmentaux et les seconds segments des titres bisegmentaux. Nous allons étudier dans ces trois ensembles les têtes de segments qui sont très fréquentes dans de nombreux domaines, des têtes que nous appellerons transdisciplinaires. Ce sont ces dernières têtes, que nous voulons rapprocher des noms sous-spécifiés que nous décrivons dans la sous-partie suivante. Enfin, nous abordons les schémas récurrents dans lesquels s'insèrent nos têtes transdisciplinaires pour essayer d'en faire le rapprochement avec les constructions spécificatiologiques des noms sous-spécifiés.

II.1 Sélection des têtes transdisciplinaires

II.1.1 Principe de sélection

Pour être véritablement transdisciplinaire, une tête ne doit pas seulement se retrouver dans de nombreux domaines. Elle doit se retrouver *fréquemment* dans de nombreux domaines. Nous nous méfions de la moyenne des fréquences relatives de la tête dans les différents domaines car elle peut cacher des situations très disparates. Nous préférons prendre les têtes qui apparaissent avec un seuil minimum dans la moitié des domaines étudiés dans notre corpus. Nous établissons donc un seuil arbitraire de 0,001 (0,1 %), que nous nommons **seuil de médiane**, au-dessus duquel nous sélectionnons nos têtes transdisciplinaires.

II.1.2 Résultats et évaluations des têtes transdisciplinaires

Sur les 123 227 lemmes de têtes de notre corpus de travail, cela en sélectionne 94 soit 0,08 %. Elles ont en tout 94 739 occurrences, soit près de 27 % des 354 168 occurrences de têtes que compte notre corpus. Elles se répartissent ainsi :

- 40 270 des titres monosegmentaux ont une tête transdisciplinaire, soit 27 %,
- 8 147 titres bisegmentaux ont une tête transdisciplinaire dans chaque segment,
- 9 592 premiers segments de titres bisegmentaux ont une tête transdisciplinaire, soit 17 % des premiers segments,
- 28 583 seconds segments de titres bisegmentaux ont une tête transdisciplinaire, soit 36 % des seconds segments,
- 86 592 des titres ont au moins une tête transdisciplinaire, soit 34 %.

Les occurrences de ce très petit nombre de têtes transdisciplinaires concentrent plus d'un quart de toutes les têtes et plus d'un tiers de tous les titres.

Les 20 premières têtes des 94 classés par la médiane sont : *étude, analyse, cas, approche, exemple, enjeu, évolution, apport, rôle, modèle, réflexion, évaluation, outil, question, représentation,*

application, construction, introduction, histoire et développement. La liste complète est fournie dans l'annexe **A3. Liste des têtes transdisciplinaires.**

La répartition des têtes transdisciplinaires par rapport aux autres têtes est variable selon le domaine comme le montre le tableau (9).

	Domaine	Têtes transdisciplinaires	Têtes	%
01	Physique	13 515	30 667	44 %
02	Éducation	4 091	9 445	43 %
03	Sciences du Vivant	9 232	22 149	42 %
04	Économie et finance quantitative	202	489	41 %
05	Gestion et management	10 445	25 955	40 %
06	Sciences cognitives	1 252	3 141	40 %
07	Sciences de l'environnement	2 978	7 484	40 %
08	Psychologie	1 059	2 663	40 %
09	Géographie	436	1 191	37 %
10	Planète et Univers	1 341	3 675	36 %
11	Informatique	5 923	16 241	36 %
12	Chimie	959	2 710	35 %
13	Mathématiques	964	2 745	35 %
14	Sciences de l'information et de la communication	2 599	7 523	35 %
15	Linguistique	5 223	15 512	34 %
16	Sociologie	10 310	32 398	32 %
17	Architecture	1 328	4 629	29 %
18	Science politiques	2 712	9 864	27 %
19	Anthropologie	1 731	6 942	25 %
20	Archéologie et préhistoire	3 141	13 391	23 %
21	Philosophie	1 726	7 856	22 %
22	Histoire	4 956	25 671	19 %

23	Droit	4977,00	26 398	19 %
24	Art et histoire de l'art	1475,00	8 685	17 %
25	Littératures	2159,00	14 278	15 %

Tableau 9 : Nombre de têtes transdisciplinaires par domaines

La fréquence des têtes transdisciplinaires a une étendue de 15 %, pour les littératures, à 44 %, pour la physique. La moyenne est de 32 % et la médiane est très proche de 35 %. Les têtes transdisciplinaires sont donc très présentes dans tous les domaines.

Aucun nom propre ne figure dans cette liste ce qui semble logique en égard aux principales catégories de noms propres. Sur le plan des personnes et des titres d'œuvres, on peut difficilement imaginer un individu présent dans la plupart des domaines ou une œuvre relative à la plupart des domaines, l'*Encyclopédie* relevant plus d'un intérêt historique que scientifique de nos jours. Sur le plan des périodes historiques, elles sont surtout propres aux domaines aux études diachroniques et ne sont pas toutes les mêmes pour les différents domaines : le *Crétacé* n'intéresse par exemple que les préhistoriens. Sur le plan des lieux, on pourrait imaginer qu'un lieu soit étudié selon différents domaines des sciences humaines et sociales comme la géographie, l'histoire ou la sociologie, mais cela est plus difficilement concevable pour les sciences exactes, l'exemple forgé *la mathématique de Paris* ayant peu de sens, à moins de parler d'une école de pensée. En classant par la médiane, les deux premiers noms propres sont *Europe* avec 0,02 % et *Paris* avec 0,01 %, les deux sont présents dans 16 domaines, dont 14 sont communs et 12 font partie des sciences humaines et sociales.

Une autre remarque est qu'il s'agit de noms communs abstraits ayant un faible contenu sémantique dénotant des entités de second ou troisième ordres définis par Lyons (1977) : elles n'existent pas mais peuvent avoir une localisation spatiotemporelle (Benítez-Castro (2014, p. 96). Néanmoins, certaines têtes peuvent avoir plusieurs sens, par exemple *outil* peut dénoter une entité ayant une matérialité tangible, fabriquée dans un but précis, comme un tournevis. Mais dans une acception plus figurative et métaphorique selon le TLF⁴, *outil* peut désigner toute entité étant un moyen « qui permet d'obtenir un résultat, d'agir sur quelque chose » ce qui est très vaste. Notons que nous avons déjà remarqué ce lemme dans notre travail de première année et statué que dans ce cas, il était équivalent à d'autres lemmes comme *système* ou *dispositif* qui sont eux-aussi présents dans notre liste de têtes transdisciplinaires. On peut rapprocher les têtes transdisciplinaires des noms généraux de Halliday et Hasan (1976), des noms ayant une « sous-spécification sémantique » et une « large couverture référentielle » (Huyghe, 2018).

Le premier contrôle possible pour tester la validité de notre filtre est de compter les domaines où ces têtes sont présentes. Tutin (2008) fixe la transdisciplinarité au fait d'avoir au moins 15 occurrences dans les trois domaines étudiés par son étude, soit 100 % des domaines étudiés. Hatier et al. (2016) fixent la transdisciplinarité au fait d'apparaître dans quatre domaines sur les dix que comporte leur étude, soit 40 %. Dans notre cas, 40 % de nos 25 domaines retenus pour nos calculs

⁴ <https://www.cnrtl.fr/definition/outil>

donne un seuil de dix domaines. Nos 94 têtes transdisciplinaires sont au minimum présentes dans 20 domaines, soit 80 % des 25 domaines. 35 têtes transdisciplinaires sont présentes dans 100 % des 25 domaines. Le nombre moyen de domaines où les 94 têtes sont présentes est 23,95 ce qui est extrêmement élevé sachant que le nombre minimum de domaines est de 20.

Un second contrôle consiste à confronter nos têtes transdisciplinaires à des lexiques de noms transdisciplinaires préétablis par d'autres méthodes que la nôtre. Ainsi, si nous retombons sur les mêmes lemmes, nous corroborons à la fois les études précédentes et notre travail. Nous avons utilisé le lexique transdisciplinaire des écrits scientifiques (LTES) établie par Tutin (2007, 2008), qui compte 363 noms, et le lexique scientifique transdisciplinaire (LST) de Hatier (2016) qui compte 495 noms. Dans notre annexe **A3. Liste des têtes transdisciplinaires** nous indiquons pour chaque tête son appartenance au LTES et au LST.

Sur les 94 têtes transdisciplinaires, 74 sont présentes dans le LTES, soit 79 %. Les 20 têtes qui ne figurent pas dans le LTES sont : *conception, discours, dynamique, défi, émergence, enjeu, enseignement, essai, formation, histoire, impact, jeu, méthodologie, note, point, politique, regard, remarque, retour, science*. On peut se demander pourquoi des lemmes sémantiquement liés directement à la science comme *méthodologie* ou *science* ne figurent pas dans le LTES. Une raison possible est que Tutin a établi son lexique sur trois domaines seulement, médecine, économie et linguistique, où les lemmes mentionnés pourraient être moins fréquents. Les autres peuvent avoir été considérés comme trop génériques : il en effet difficile de délimiter ce qui est propre au vocabulaire scientifique, le lexique transdisciplinaire des écrits scientifiques étant considéré comme un sous-ensemble d'un lexique abstrait plus général (Tutin, 2007). De plus, Tutin (2008, p. 247) effectue un filtrage manuel et donc potentiellement subjectif.

Sur les 94 têtes transdisciplinaires, 82 sont présentes dans le LST, soit 87 %. Les têtes non présentes dans le LST sont *an, défi, enseignement, formation, gestion, histoire, jeu, modélisation, place, politique, regard, retour*. Le corpus sur lequel Hatier a construit son lexique contenait uniquement des articles de sciences humaines et sociales ce qui peut expliquer cette différence. La validation manuelle effectuée par des experts (Hatier, 2016, p. 80) sur les candidats au LST peut aussi expliquer leur non prise en compte.

On peut s'interroger sur cette non-concordance entre nos têtes transdisciplinaires, le LTES et le LST, avec huit têtes transdisciplinaires n'appartenant à aucun des deux : *défi, enseignement, formation, histoire, jeu, politique, regard, retour*. On peut l'imputer au matériau de départ, seulement trois domaines pour Tutin (2008) et des domaines exclusivement issus des sciences humaines et sociales pour Hatier (2016). On pourrait l'imputer à un seuil de médiane trop bas : *jeu* est la 93^e tête sur 94 dans l'ordre décroissant des valeurs de médiane, *an* la 89^e et *défi* la 88^e. Néanmoins *rapport* qui est la 94^e tête dans ce même classement appartient bien au LTES et au LST. A contrario, *histoire* qui n'appartient ni au LTES ni au LST est placé à la 19^e place dans notre classement. Il ne s'agit donc pas d'une conséquence liée à la valeur de seuil choisie. Reste qu'aussi bien Hatier que Tutin sélectionnent un vocabulaire à la fois transdisciplinaire et *spécifique* à la science, à l'aide pour Hatier d'un corpus de contraste qui représente « *la compétence linguistique générale* » (Hatier, 2016, p. 30). De notre côté, nous affirmons par le calcul seulement la transdisciplinarité de nos têtes, pas leur appartenance à un lexique

scientifique propre. Lexique scientifique propre non pas par l'exclusivité des lemmes y figurant mais par leurs fréquences plus élevées. L'hypothèse intuitive que les têtes les plus fréquentes dans des titres d'articles scientifiques seraient forcément des lemmes membres d'un lexique scientifique propre est donc à nuancer : *jeu, regard* et *retour* ne connotent rien de scientifique.

II.1.3 Études des têtes selon leurs segments et la structure segmentale du titre

Nous avons ensuite étudié les variations des têtes transdisciplinaires entre trois sous-ensembles de notre corpus de travail : les titres monosegmentaux, les premiers segments des titres bisegmentaux, puis leurs seconds segments. Nous traitons les segments des titres bisegmentaux séparément pour essayer de déterminer d'éventuelles différences entre les deux. L'hypothèse d'une différence repose sur les modèles de titres données par Swales et Feak (1994) où chaque segment à un rôle particulier :

1. Problème : solution
2. Général : spécifique
3. Sujet : méthode
4. Majeure : mineure

D'autres auteurs ont étendu cette typologie comme Anthony (2001) avec cinq types ou Cheng et al. (2012) avec onze types, et à chaque fois, les deux segments ont un but sémantique différencié. Nous voulons savoir si cette différenciation sémantique se reflète par des différences dans les têtes transdisciplinaires émergeant des différents sous-corpus.

Pour les titres monosegmentaux, les têtes transdisciplinaires relevées sont au nombre de 81. Six seulement d'entre elles n'apparaissent pas dans les 94 têtes transdisciplinaires relevés sur tout le corpus. Les six têtes sont : *contrôle, fonction, notion, temps, transformation* et *valeur*. Les six appartiennent au LTES. Seuls les lemmes *contrôle, temps* n'appartiennent pas au LST. On peut noter que dans le corpus général, les têtes *fonction, temps* et *valeur* ont une valeur de médiane de 0,09 %, *transformation* de 0,08 % et *contrôle* et *notion* de 0,07 %. En changeant le corpus sur lequel on fait nos calculs, ces têtes passent en dessous ou au-dessus de notre seuil, fixé à 0,1 %, mais dans les deux cas, elles ont une valeur de médiane proche.

Pour le premier segment des titres bisegmentaux, nous relevons 63 têtes transdisciplinaires. Cinq têtes n'apparaissent pas dans les 94 précédemment relevées : *compte, contribution, culture, économie* et *identité*. Dans le second segment, nous relevons 99 têtes transdisciplinaires et 19 têtes n'apparaissent pas dans les 94 têtes transdisciplinaires relevés sur tout le corpus : *condition, contexte, définition, démarche, donnée, illustration, leçon, limite, mode, mythe, paradoxe, parcours, piste, problématique, réalité, revue, source, synthèse* et *voie*. Si on dénombre toutes les têtes transdisciplinaires relevées par l'étude du corpus et des trois sous-corpus, on obtient le nombre de 123. Le tableau (10) résume le nombre de têtes transdisciplinaires trouvées par corpus.

Corpus	Nombre de têtes transdisciplinaires
Ensemble du corpus de travail	94
Titres monosegmentaux	81
Premier segment des titres bisegmentaux	63
Second segment des titres bisegmentaux	99

Tableau 10 : Nombre de têtes transdisciplinaires selon le corpus choisi

Pour le sous-corpus des seconds segments des titres bisegmentaux, on remarque que cinq têtes, *cas*, *exemple*, *étude*, *application* et *approche* représentent 13 % des têtes du sous-corpus, il y a donc une concentration remarquable sur un très petit nombre de têtes. Pour atteindre 13 % en cumulant les têtes les plus fréquentes dans le corpus général, il faut prendre 19 têtes. Individuellement, les occurrences des têtes *cas*, *exemple*, *étude*, *application* et *approche* représentent respectivement 4 % pour *cas*, 3 % pour *exemple* et 2 % pour les trois dernières des 95 282 occurrences de têtes du sous-corpus.

On remarque également une surreprésentation de certaines têtes dans le sous-corpus des seconds segments par rapport au corpus général. Ainsi, *cas* ne compte que pour 1 % des têtes du corpus général contre 4 % dans le sous-corpus, et de même pour *exemple* avec 1 % dans le corpus général et 3 % dans le sous-corpus. Cette affirmation rejoint nos résultats de première année, où nous montrions que certains lemmes privilégiaient très fortement une position après le double-point, et donc dans un deuxième segment. 97 % des occurrences de la tête *cas* apparaissent ainsi dans un deuxième segment, 93 % des occurrences de la tête *exemple* suivent la même logique. Cette répartition montre bien l'application du schéma général : spécifique de Swales et Feak (1994). Haggan (2004) appelle cette opération un resserrement, « *narrowing* » (Haggan, 2004), sur l'objet de l'article. La juxtaposition de ces deux informations par le double point rend plus facile leur interprétation, soulignée par le choix d'une tête transdisciplinaire qui indique bien un point spécifique, un cas, un exemple, d'un concept plus large.

Néanmoins, il faut prêter attention ne pas faire de contresens en interprétant ce schéma sémantique. Si les exemples (21) et (22) présentent bien, dans leurs premiers segments, le concept général suivi, dans leurs seconds segments, d'un exemple spécifique, le (23) l'inverse. L'exemple (21) utilise *l'exemple de* alors que l'exemple (23) utilise *un exemple de*. La détermination de la tête oriente donc l'interprétation du schéma. L'exemple (22) utilise une troisième association qui juxtapose, via une virgule, *un exemple*, avec le point spécifique et montre bien que s'appuyer seulement sur la détermination ne suffit pas pour interpréter ce schéma.

(21) La **cohésion** 'to-textuelle' de l'oral : l'**exemple** d'une interview de Jean-Claude Van Damme

(22) **Ressources** lexicales pour une sémantique inférentielle : un **exemple**, le mot quitter

(23) L'**internet** des mouvements transgressifs : un **exemple** de "transnationalisation" des identités militantes.

Une dernière étude possible est, au lieu d'étudier d'un côté les têtes du premier segment et de l'autre celle du second segment des titres bisegmentaux, d'étudier les couples de têtes ainsi formés. On forme ainsi des couples ordonnés de la forme (tête premier segment, tête second segment) et on peut, pareillement qu'une tête seule, calculer une fréquence relative sur l'ensemble des titres bisegmentaux.

Seuls cinq couples ont une médiane différente de zéro : (*de*, *exemple*), (*rôle*, *cas*), (*approche*, *cas*), (*apport*, *exemple*) et (*effet*, *cas*). Nous rappelons que les titres bisegmentaux peuvent avoir une tête non nominale, verbe ou préposition, d'où l'apparition de la préposition *de* dans ce classement. La préposition *de* étant la plus fréquente, il est logique qu'elle apparaisse dans les couples les plus

fréquents. Notre étude portant essentiellement sur les têtes nominales, nous ne retenons que les trois derniers couples. Les exemples (24), (25) et (26) montrent respectivement les couples (*rôle, cas*), 60 titres, (*apport, exemple*), 37 titres, et (*effet, cas*), 36 titres.

(24) Le **rôle** des confréries durant les premières années de la proscription du catholicisme : Le **cas** du fief de Shimabara

(25) L'**apport** des archives privées à l'histoire politique : l'**exemple** de Louis Costa, le notaire rouge

(26) Les **effets** pervers de la solidarité: le **cas** des femmes seules avec enfants

Du fait des têtes transdisciplinaires du second segment, *cas* et *exemple*, nous retombons sur le schéma de Swales et Feak (1994) général : spécifique.

Nous avons donc identifié 94 têtes transdisciplinaires dans notre corpus de titres, à la fois très fréquentes et ayant un très faible contenu sémantique. Nous avons identifié également des têtes transdisciplinaires émergeant si l'on ne considère que les titres monosegmentaux, le premier ou le second segment des titres bisegmentaux comme *cas* ou *problème*. Dans notre travail de première année, nous avons déjà souligné cette répartition, en faveur d'une position post-double-point, de certains lemmes assimilés à nos têtes. N'importe quel concept peut avoir des exemples ou des cas : la très forte capacité référentielle de ces deux lemmes n'est possible que parce qu'ils dénotent uniquement une relation, de l'entité qu'il référence envers une autre, sans donner plus d'information sur leurs référents. Partant de ces deux cas exemplaires étudiés en première année, nous avons souhaité étendre notre recherche de noms fréquents avec un faible contenu sémantique à l'ensemble des têtes d'un titre, en particulier les têtes transdisciplinaires. Ces deux caractéristiques de fréquence et de sous-spécification rapprochent les têtes transdisciplinaires d'une classe d'emploi des noms, les noms sous-spécifiés, très fréquente dans le discours académique (Flowerdew et Forest, 2015).

II.2 Noms sous-spécifiés et constructions spécificationnelles

II.2.1 Définitions des noms sous-spécifiés

De nombreux travaux avec différentes perspectives se sont penchés sur les noms sous-spécifiés en anglais et plus tardivement en français. Les définitions théoriques et opératoires de ces différents auteurs ne se recoupent pas exactement, ainsi que la liste des noms pouvant être employés de la sorte, ce qui se traduit par un foisonnement terminologique (Flowerdew et Forest, 2015, p. 9 ; Schmid, 2000, p. 10-11) : *container nouns* (Vendler, 1968), *signalling nouns* (Flowerdew 2003, 2006 ; Flowerdew et Forest, 2015), *type 3 vocabulary* (Winter, 1977), *metadiscursive nouns* ou *anaphoric nouns* (Francis, 1986), *enumerables* et *advance labels* (Tadros, 1994), *carrier nouns* (Ivanic, 1991), *advance labels* et *retrospective labels* (Francis, 1994), *unspecific nouns* ou *metalinguage nouns* (Winter, 1992), *shell nouns* (Hunston et Francis, 1999 ; Schmid, 2000, 2018), *noms sous-spécifiés* (Legallois, 2008) et *noms porteurs* (Huygue, 2018). Nous retenons que la plupart de ces travaux s'accordent pour définir les NSS comme un emploi particulier et non une classe lexicale : un nom peut ainsi être employé de façon sous-spécifiée ou non, nous reprenons pour le 1^{er} cas un exemple de Huygue (2018) :

Emploi sous-spécifié du nom *fait* : le fait que Pierre soit arrivé en retard à la réunion

Emploi spécifié du nom *fait* : Il n'y a aucun fait qui étaye cette supposition.

Cette différenciation entre emploi sous-spécifié et emploi sémantique plein est le cœur du problème d'un traitement automatique. Nous devons pouvoir rendre la différenciation computationnelle, c'est-à-dire déterminable par un programme. Nous nous tournons donc vers les définitions théorique et opératoire pour construire un tel algorithme.

Comme définition théorique, nous nous proposons de reprendre celle de Flowerdew (2006, p. 348) pour sa concision et sa clarté : « *potentially any abstract noun which is unspecific out of context, but specific in context* ». Un exemple d'emploi sous-spécifié pour le lemme *défi* est le suivant : *Pour les Américains, le défi est de marcher à nouveau sur la Lune*. Le sens complet de *défi* ne peut être appréhendé qu'en faisant référence au contexte, ici *marcher à nouveau sur la Lune*.

La définition de Flowerdew est néanmoins très générale. Pour compléter notre définition théorique, on peut donner une définition fonctionnelle en rappelant les trois fonctions clés de l'emploi sous-spécifié selon Schmid (2000, p. 14 ; 2018, 112) :

- Fonction cognitive de **conceptualisation** ou d'**encapsulation** : un morceau d'information est encapsulé dans la création d'un concept temporaire nominal. Dans notre exemple, *marcher à nouveau sur la Lune* est encapsulé dans un concept nominal, le *défi*.
- Fonction sémantique de **catégorisation** ou de **classification** : catégorisations de concepts, il s'agit d'une mise en perspective par le locuteur d'un morceau d'information qu'il souhaite transmettre à l'interlocuteur en lui imposant son point de vue (Legallois, 20108, p. 8). Le fait d'utiliser *défi* et non *problème* n'est pas neutre, comme nous le verrons plus bas, car si le NSS a un manque de contenu sémantique, il n'en est toutefois pas dénué complètement.
- Fonction textuelle ou discursive de **liaison** : capacité de référence quasi-pronominale au concept créé qui structure le texte, qui pourra être repris par exemple par l'énoncé *ce défi*. C'est cette fonction qui assure une cohérence et une continuité au texte et qui intéresse d'un point de vue discursif Flowerdew et Forest (2015, p. 2)

On peut noter, à la suite de Huyghe (2018, p. 36), que même si c'est une classe d'emplois et non une classe lexicale, la fonction d'encapsulation est néanmoins conditionnée par leurs propriétés sémantiques. Legallois (2008, p. 2) parle d'une « *interdéfinition entre lexique et grammaire* ». Schmid (2000, p. 63-73) reprend la distinction en trois ordres de Lyons (1977) des entités dénotées par les noms. Nous traduisons ci-dessous la définition qu'en fait Benítez-Castro (2014, p. 96) :

« *Les entités de premiers ordres sont des éléments tangibles du monde réel, comme les personnes, les animaux et les objets, ayant une localisation spatiale et temporelle, les entités de second ordre, qui n'existent pas mais arrivent ou prennent place, avec une localisation spatiotemporelle, comme un crime, un mouvement ou un combat, enfin les noms de troisièmes ordres convoient purement des significations abstraites, idées, propositions ou faits, comme théorie, affirmation, aspect. Les second et troisième ordres partagent une nominalisation comme origine mais les entités de troisième ordre ne sont pas observables et en dehors de toute dimension spatiotemporelle.* »

Schmid (2000, 63-73) considère que les emplois de NSS ne concernent que les noms qui dénotent des entités de second ou de troisième ordres. Schmid (2000, p. 85 ; 2018 p. 118) distingue également trois grandes catégories de shell nouns selon leur contenu sémantique. La première est les *prime shell nouns*, des noms utilisés de façon privilégiée et fréquente dans des emplois de NSS comme *concept, fact, issue, idea, notion, principle, problem, reason, rumour, legend* et *thing*. La seconde est celle des *good shell nouns* (Schmid, 2000, p. 86) qui sont moins interchangeable entre eux comme *order*. La troisième catégorie se compose des *less good* ou *peripheral shell nouns* comme *move, measure, reaction, situation, way, procedure*.

Comme Flowerdew et Forest (2015, p. 12), nous considérerons les NSS comme une classe ouverte même s'ils empruntent à la classe fermée des pronoms la caractéristique d'avoir besoin d'un contenu spécifiant (Flowerdew et Forest, 2015, p. 11). Le fait qu'ils proviennent de la classe lexicale des noms leur confèrent un statut intermédiaire entre la classe fermée pronominale et la classe ouverte nominale (Huyghe, 2018, p.44 ; Legallois, 2006, p. 11).

Huyghe (2018) distingue les noms généraux tels que définit par Halliday et Hasan (1976), « *a small set of nouns having generalized reference* », servant à construire la cohérence du texte, des NSS, appelés noms porteurs dans son article, tout en reconnaissant la possibilité d'appartenir aux deux classes. Cette distinction n'est pas aussi franche pour Flowerdew et Forest (2015, p. 9) et les deux se rejoignent sur la notion de non-spécification (Schmid, 2000, p. 10). Ce qui distingue les NSS des noms généraux, c'est le focus mis sur les structures grammaticales dans lesquelles ils s'insèrent et qui en devient une définition opératoire.

II.2.2 Les constructions spécificationnelles classiques

A) Définitions des constructions spécificationnelles

Un NSS s'insère au sein d'une construction spécificationnelle (CS) qui va relier le NSS à un contenu qui va le spécifier ou le « remplir » (Legallois, 2008, p. 6). Cette opération est appelée spécification ou identification (Nakamura, 2017, p. 3).

Nous recensons ici les deux constructions spécificationnelles les plus fondamentales étudiées par Schmid (2000, p. 22) pour l'anglais. Legallois (2008, p. 2) a transposé ces constructions en français et elles ont été reprises par Huyghe (2018, p. 36), Roze et al. (2014, p. 4) et Nakamura (2017, p. 2) :

- CS-I. **NSS** + être + proposition subordonnée conjonctive :
Le problème est que l'homme abandonne son habitat.
- CS-II. **NSS** + être + de + proposition subordonnée infinitive :
Le plus grand **effort** est de vaincre les passions.

Kolhatkar et Hirst (2014, p. 4) montrent que les NSS ont une préférence pour certaines constructions spécificationnelles. En se fondant sur une étude du corpus du français frWac en son état du 25 avril 2017, Huyghe (2018, p. 37) indique qu'un NSS peut n'accepter qu'une des deux constructions : ainsi le NSS *capacité* s'utilise avec une infinitive, comme dans *la capacité de sélectionner les candidats*, et non avec une conjonctive, **la capacité que le jury sélectionne les candidats*. Cette « *compatibilité propositionnelle* » conditionne la syntaxe, le type de proposition subordonnée, mais elle conditionne également la sémantique du contenu propositionnel (Huyghe, 2018, p. 38) : *action* implique

la dynamicité, *propriété*, la stativité. Ainsi chaque NSS a une « *capacité de portage propositionnel* » plus ou moins étendue (Huyghe, 2018, p. 37).

Il existe pour (CS-I) et (CS-II) à chaque fois une variante qui peut être rapprochée des pseudo-clivées en insérant, entre le NSS et *être*, une virgule et le pronom de reprise *ce* (Legallois et Gréa, 2006, p. 161 ; Roze et al., 2014, p. 4), variantes qui se rencontrent notamment à l'oral :

CS-III. **NSS** + virgule + *c'/ce* + être + proposition subordonnée conjonctive :

Le problème, c'est que l'homme abandonne son habitat.

CS-IV. **NSS** + virgule + *c'/ce* + être + de + proposition subordonnée infinitive :

Le plus grand **effort**, c'est de vaincre les passions.

De plus, Schmid propose notamment trois autres constructions spécificionnelles (Schmid, 2000, p. 22, 26) que Legallois (2008, p. 2) n'a pas reprises :

CS-V. **NSS** + proposition subordonnée conjonctive :

Le **problème** que l'homme abandonne son habitat n'a toujours pas été discuté en commission.

CS-VI. **NSS** + de + proposition subordonnée infinitive :

Le plus grand **effort** de vaincre ses passions a été exigé de lui.

CS-VII. **NSS** + **of** + syntagme avec pour noyau un verbe au gérondif :

The **problem** of raising money

CS-V et CS-VI reprennent CS-I et CS-II mais sans le verbe *être*. Legallois (2008, p. 2) qualifie ces constructions « *d'apparentées* » et indique que les shell nouns de Schmid (2000) sont « *une catégorie plus large que les NSS* ».

La CS-VII réunit dans un syntagme nominal complexe le NSS et le contenu spécifiant, dont le noyau est un déverbal, un gérondif en anglais. Cette dernière contrainte se retrouve implicitement dans les exemples de son ouvrage (Schmid, 2000). Schmid lève la contrainte du gérondif de la CS-VII dans l'exemple qu'il donne dans son article de 2018 (p.115) : « *The **notion** of love* ». On remarque néanmoins que le déverbal *love*, de *to love*, est toujours un nom dénotant une entité d'ordre supérieur à un, l'action d'aimer. Le gérondif anglais n'ayant pas d'équivalent direct en français, une traduction possible vers le français est l'infinitif, choix (A), rejoignant alors la construction CS-VI ou d'un nom déverbal choix (B), rejoignant alors la construction CS-VII.

(A) The problem of raising money → le problème de lever/réunir/recueillir de l'argent/des fonds

(B) The problem of raising money → le problème de la levée / du recueil / de la réunion des fonds

En français, dans le cas d'un déverbal dénotant une action ou une activité, la difficulté se pose pour la CS-VII de distinguer automatiquement les emplois proprement sous-spécifiés des emplois en nom plein suivi d'un complément de nom. Ainsi Roze et al. (2014, p. 8) indiquent que les énoncés « *marché de travail, contrat de travail* » ne sont pas des NSS alors que *travail* est le déverbal de travailler. Cela nous semble justifié par le degré de figement des ces énoncés qui fait de *contrat de travail* une locution nominale où *contrat* n'est pas substituable par un autre nom.

On peut se demander jusqu'à quel point cette contrainte d'avoir pour contenu spécifiant un nom désignant une action est vérifiée. Prenons « *projet de loi* » qui est également refusé par Roze et al. (2014, p. 8) comme toutes les formes *projet de NC*. Il nous semble néanmoins possible de rapprocher les trois énoncés suivants qui reprennent les trois constructions spécificationnelles :

5. CS-I Le projet que l'État légifère contre le vapotage dans les lieux publics.
6. CS-II Le projet de légiférer contre le vapotage dans les lieux publics.
7. CS-VII Le projet de loi contre le vapotage dans les lieux publics

L'équivalence des trois peut se comprendre en sous-tendant une action implicite dans la CS-VII, celle de rédiger/émettre une loi. L'interprétation sémantique dans ce dernier cas est ambiguë, à savoir si le *projet* concerne l'acte de rédiger, on se rapproche d'un NSS, si le *projet* concerne la loi en elle-même, ou si l'on doit interpréter *projet de loi* comme une locution nominale dénotant une classe distincte, en ne dissociant pas *projet* et *loi*. Si nous rejetons le dernier emploi comme NSS, le second ouvre la possibilité d'avoir une action implicite sous-tendue par un nom.

Aktas et Cortes (2008) avaient également relevé cette construction sans contrainte particulière sur le nom la terminant. Mousavi et Rauof Moini (2014), dans une étude sur un corpus d'articles scientifiques sur l'éducation, ont constaté que cette construction était la plus fréquente.

Nakamura (2017, p. 2) reprend également la construction suivante comme CS, cette fois toujours avec le verbe *être* :

CS-VIII. **NSS** + être + syntagme nominal :

Notre **objectif** majeur est la rédaction d'une proposition de loi.

On remarque que le noyau du syntagme nominal droit est *rédaction*, un nom qui renvoie à l'action de rédiger. L'équivalence avec *notre objectif majeur est de rédiger* est ainsi directe.

Nakamura (2017, p. 5) présente également une variante pseudo-clivée pour CS-VIII à la manière dont sont dérivées CS-III et CS-IV de CS-I et CS-II respectivement. Nous la nommons CS-IX :

CS-IX. **NSS** + virgule + c'/ce être + syntagme nominal :

Notre **objectif** majeur, c'est la rédaction d'une proposition de loi.

Les NSS étant une classe fonctionnelle et non lexicale, les différentes constructions spécificationnelles traditionnelles sont autant de définitions opératoires des NSS (Schmid 2000). L'annotation manuelle d'un grand corpus pour détecter de tels emplois n'est pas envisageable. L'annotation purement automatique à partir d'un repérage structurel semble moins difficile mais présente de sérieuses difficultés, notamment pour les CS les plus ouvertes comme la CS-V.

Nous proposons comme solution une présélection automatique suivie d'une évaluation manuelle des résultats pour déterminer s'il s'agit bien d'un NSS. La seconde étape impose que la présélection automatique soit la plus efficace possible pour restreindre le nombre de résultats à examiner manuellement.

Pour pouvoir utiliser le traitement automatique des langues en vue d'effectuer cette présélection automatique, il faut faire une analyse syntaxique préalable des différentes constructions

spécificationnelles recensées. Le point qui nous semble le plus important est d'analyser la nature et la fonction du contenu spécifiant de chaque construction spécificationnelle.

B) Nature et fonction du contenu spécifiant dans les constructions spécificationnelles classiques

CS-I, CS-II, CS-III, CS-IV, CS-V et CS-VI : NSS [(, ce être) | être] proposition en **que** ou **de**

Sur la nature du contenu spécifiant, pour CS-I et CS-II, nous suivons Legallois (2008) et Schmid (2000) en affirmant que le contenu spécifiant est avant tout une proposition subordonnée, pour CS-I une conjonctive commençant par *que*, et pour CS-II, une infinitive même si cela pose plus de questions. Roze et al. (2014) assimile la nature des CS-III et CS-IV, les pseudo-clivées, à CS-I et CS-II respectivement.

Pour déterminer la nature du contenu spécifiant des CS-II et CS-IV, la première hypothèse est de considérer qu'il s'agit d'une proposition subordonnée infinitive incluse dans un syntagme prépositionnel commençant par *de*. La seconde hypothèse de considérer l'ensemble, en y incluant *de*, comme une seule proposition subordonnée infinitive. La préposition *de* joue alors le même rôle de complémentateur subordonnant que *que* (Huot, 1981 ; Kalmbach, 2019, p. 675).

À l'appui de la seconde hypothèse, Kalmbach (2019, p. 675) indique qu'« *on peut facilement mettre en parallèle les deux types de construction* », conjonctive et infinitive, par la paraphrase :

« le fait que le jury sélectionne les candidats » ↔ « le fait de sélectionner les candidats ».

La principale différence soulignée par l'auteur entre les deux subordonnées est que « *le sujet [ici, le jury] n'est pas exprimé dans l'infinitive. Par rapport à la construction conjonctive, la construction infinitive prend donc une valeur impersonnelle ou générale* ». Ce sujet implicite conforte la seconde hypothèse car la définition de la proposition en grammaire traditionnelle, rappelée par Joseph Donato dans l'ouvrage collectif sous la direction de Mounin (1974), stipule qu'il s'agit d'« *un groupe de mots qui a son propre sujet et son propre prédicat* », ici implicite. Ce même auteur rappelle également que la « *distinction entre syntagme et proposition n'était pas toujours très claire ni très systématique* ».

Ainsi, par symétrie avec la proposition subordonnée conjonctive des CS-I et CS-III, nous parlerons donc de proposition subordonnée infinitive pour la nature du contenu spécifiant des CS-II et CS-IV. Nous privilégions donc deux appellations se référant à la catégorie morphosyntaxique d'un terme distinctif de chaque construction : la conjonction de coordination que dans un cas, l'infinitif dans l'autre.

Les constructions CS-V et CS-VI, qui reprennent CS-I et CS-II mais sans le verbe être, sont rejetées par la majorité des travaux français comme constructions spécificationnelles. Schmid (2000, p. 20), adoptant le point de vue de la grammaire traditionnelle sur cet aspect, ne statue pas (p. 23) entre *noun complements* et *appositive modifiers*. Legallois (2008, p. 8) les rapproche des noms à compléments prépositionnels (NCP) de Riegel. Or Riegel (2006, p. 38) estime pour les CS-V qu'il s'agit de propositions attributives réduites, par rapport à la proposition attributive copulative avec le verbe être et qu'elles sont « *les deux réalisations syntaxiques d'un même schéma prédictif, la première sous la forme d'une construction copulative, la seconde sous celle d'une configuration propositionnelle averbale* ». On peut en effet transformer les CS-I en CS-V par l'ajout du verbe copulatif. La même chose est possible pour les

CS-II en CS-VI, nous nous permettons de reprendre le terme de proposition subordonnée infinitive. Pour Riegel, la fonction est donc celle d'attribut.

CS-VIII et CS-IX : NSS [, ce] être syntagme nominal

La nature du contenu spécifiant est syntagme nominal pour les CS CS-VIII et CS-IX et la fonction est celle de complément attribut.

CS-VII : NSS **de** syntagme nominal

La construction CS-VII n'a pas été reprise en français. Depuis l'anglais, si le noyau du syntagme est un verbe au gérondif, on peut la rapprocher de la construction CS-VI pour le français que nous verrons ci-dessous. Mais si son noyau est un nom dénotant une action, on considère que le contenu spécifiant est un syntagme prépositionnel avec *de* comprenant un syntagme nominal, que nous appelons syntagme prépositionnel-nominal. On peut alors la rapprocher des constructions CS-VIII et CS-IX du fait que le contenu spécifiant soit aussi un syntagme nominal mais l'articulation avec le NSS se fait par le verbe être dans CS-VIII et CS-IX.

La fonction du syntagme prépositionnel-nominal dans CS-VII se rapproche formellement de celle de complément du nom. Néanmoins, le fait que le contenu spécifiant soit de la même nature que pour CS-VII et CS-VIII, l'équivalence entre le noyau nominal de ce syntagme et le verbe dénotant la même action et activité dans les constructions avec une proposition, le fait qu'il puisse y avoir des constructions attributives non copulatives (Riegel, 2006), le fait enfin que le contenu spécifiant remplisse le NSS, tout cela rapproche le contenu spécifiant de la fonction attribut.

Un test possible est l'appel au contenu : un véritable complément de nom peut être supprimé alors qu'un attribut est essentiel à la phrase. On peut comparer les deux suppressions qui suivent :

- « le chat de Julie est blanc » vs « le chat est blanc »
- « l'**objectif de rédiger la loi** est important » vs « l'objectif est important »

L'« *attente de spécification* » est plus forte pour le NSS *objectif* qui « *appelle un complément d'information* » (Huyghe, 2018, p. 45). Sur le plan sémantique, *chat* dénote une entité de premier ordre, alors qu'*objectif* dénote une entité de troisième ordre. Néanmoins on pourrait toujours affirmer que la différence d'attente de spécification entre les deux est une affaire de degré, de quel chat parle-t-on, plutôt qu'une dichotomie franche entre attente et non-attente. Sur le plan syntaxique, *chat* est en revanche incapable d'accepter un contenu propositionnel ce qui le disqualifie comme NSS.

Cela amène à considérer le contenu spécifiant comme obligatoire. Si l'attribut est essentiel à une phrase, **Le problème est*, le complément du nom ne l'est pas : *Le problème de définir une nouvelle loi est complexe vs Le problème est complexe*. Mais ce deuxième cas n'est pas un NSS en lui-même. S'il est précédé d'un emploi de *problème* comme NSS, il peut s'agir d'une reprise anaphorique du concept déjà formé, l'utilisation de l'adjectif démonstratif *ce* renforcerait cette reprise mais n'est pas obligatoire. Or, nous nous intéressons au moment précis où le contenu spécifiant est associé au NSS, non aux reprises qui, dans l'étroitesse d'un titre, nous semblent peu pertinentes. Nous pouvons donc, pour identifier les NSS, parler d'une obligation de complémentation du nom si l'on adopte ce point de vue.

Pour notre part, nous privilégions la relation de complément attribut car il s'agit bien de conférer une propriété à un nom, ici donc de le remplir sémantiquement, et elle doit être au moins une fois obligatoire : la fonction de cohérence devient caduque si un NSS est seulement repris en anaphore sans jamais avoir été utilisé dans une construction spécificationnelle. Le cas d'une définition extralinguistique par le contexte de communication n'est pas recevable dans le contexte des titres qui introduisent un sujet.

La question se pose de la possibilité de transformer la CS-VIII en CS-VII. Si l'on reprend l'exemple de Nakamura (2017, p. 2), *Notre objectif majeur est la rédaction d'une proposition de loi* on a :

- *Notre objectif majeur la rédaction d'une proposition de loi
- Notre objectif majeur, la rédaction d'une proposition de loi,
- ?Notre objectif majeur de la rédaction d'une proposition de loi

La première phrase est agrammaticale par la suppression du verbe copule entre sujet et attribut. La seconde transforme l'attribut en apposition. La troisième regroupe le NSS et le contenu spécifiant en un seul syntagme nominal complexe, en utilisant la préposition *de*. On retombe alors sur le type de construction CS-VII de Schmid (2000, p. 26 ; 2018, p. 155) : *The notion of love*. Néanmoins on peut se demander si l'énoncé formé est grammatical et acceptable. Les exemples (27, 28) tirés de notre corpus montre que le NSS objectif peut s'insérer dans une CS-VII.

(27) L'objectif de **satisfaction** de victimes en droit pénal international

(28) Comment l'**objectif** de maîtrise des flux de polluants est-il traduit dans les critères de gestion à l'amont des eaux pluviales ? - Analyse des pratiques en France et à l'international

On remarque pour les deux exemples (27, 28), le noyau nominal du contenu spécifiant est également un nom désignant une action ou une activité. Nous pensons qu'il s'agit d'une bonne contrainte pour les constructions spécificationnelles CS-VIII et CS-IX, comme pour la CS CS-VII, même si des cas épineux subsistent comme dans l'exemple (38) discuté plus bas.

Pour finir, on peut donc construire le tableau d'équivalence (10) entre les différentes CS, même si nous ne plaçons pas les transformations entre CS-I, CS-III et CS-V et CS-II, CS-IV et CS-VI sur le même niveau que la paraphrase possible entre CS-VII et CS-VIII.

CS-I, III NSS + [ce] + être + proposition subordonnée conjonctive	CS-V NSS + proposition subordonnée conjonctive
CS-II, IV NSS + [ce] + être + de + proposition subordonnée infinitive	CS-VI NSS + de + proposition subordonnée infinitive
CS-VII NSS + syntagme prépositionnel-nominal	CS-VIII NSS + être + syntagme nominal

Tableau 11: Tableau d'équivalence entre construction copulative et réduire

Nous rassemblons donc tous les contenus spécifiants sous la bannière de la fonction complément attribut. Les quatre natures possibles pour les contenus spécifiants sont donc une proposition subordonnée conjonctive introduite par *que* (CS-I, CS-III et CS-V), une proposition subordonnée infinitive (CS-II, CS-IV et CS-VI) introduite par *de*, un syntagme prépositionnel-nominal (CS-VII) ou un syntagme nominal (CS-VIII et CS-IX). Pour ces deux derniers, le noyau nominal doit être un

nom d'action, ce qui revient à demander que le noyau du contenu spécifiant dénote toujours une action, soit par l'entremise du verbe conjugué de la proposition subordonnée conjonctive (CS-I, CS-III et CS-V), soit par l'entremise du verbe à l'infinitif de la proposition subordonnée infinitive (CS-II, CS-IV et CS-VI), soit par le nom noyau du syntagme nominal des trois dernières constructions (CS-VII, CS-VIII et CS-IX). À présent que nous avons rappelé la définition des NSS et des CS qui les incluent et observer la nature et la fonction du contenu spécifiant, nous allons essayer de chercher les CS classiques dans notre corpus.

II.2.3 Recherche des constructions spécificationnelles classiques dans le corpus

L'annotation manuelle des NSS sur un grand corpus comme le nôtre n'est pas envisageable. Le seul moyen de trouver des NSS est de rechercher, à la manière de Legallois (2008) pour CS-I et CS-II et de Roze et al. (2014) pour CS-I, CS-II, CS-III et CS-IV, les occurrences de constructions spécificationnelles dans notre corpus, ce qui nous a fait adopter le terme de définition opératoire malgré la mise en garde de Schmid (2018, p. 5) de ne pas confondre définition et opérationnalisation, ce qui se traduit chez nous par la distinction faite entre définition théorique et définition opératoire.

Pour notre recherche, nous allons définir des schémas lexico-syntaxiques. Un schéma est défini par une séquence de tokens qui peut comporter :

- des choix entre plusieurs tokens, un choix entre A et B est noté **A | B**,
- des tokens optionnels, l'optionalité de A est notée **[A]**,
- des répétitions de tokens, la répétition du token A entre i et j fois est notée A^{i-j} .

Un token de schéma peut être :

- une classe grammaticale (nom commun - NC, adjectif qualificatif - ADJ, préposition - P, déterminant - DET, préposition et déterminant fusionnés P+D),
- un marqueur spécial comme INIT qui indique le début du titre, SEG qui indique un signe de ponctuation segmentant ou TRANSHEAD indiquant une tête transdisciplinaire de segment,
- un lemme (*et*),
- la combinaison d'un lemme et d'une classe grammaticale, notée LEMME_{classe}.

Une recherche de correspondance d'un énoncé avec un schéma peut se faire de deux façons. En mode strict, aucun token non prévu par la définition du schéma n'est autorisé lorsqu'on le recherche dans les titres. Une séquence de tokens dans un titre, mots ou signes de ponctuation, correspond à un schéma lorsque la séquence du titre se conforme à une des réalisations possibles définies par le schéma. Les réalisations étant l'ensemble des séquences possibles à partir de sa définition.

En mode flexible, pour prendre en compte une flexibilité de la langue non prévue par la définition, comme un adjectif ou un déterminant devant un nom où un adverbe après un verbe, nous faisons correspondre nos schémas à des relations de dépendance. Soit les deux exemples suivant :

- i. Ce cheval brun est un bel animal.
- ii. Le cheval est un animal.

En mode strict, le schéma **NC est** verbe conjugué **DET NC** se retrouve dans l'énoncé (ii) mais pas dans l'énoncé (i), car l'adjectif *bel*, n'est pas dans la définition. En mode flexible, les deux énoncés correspondent aux schémas, car on va chercher dans les dépendants de *est* s'il y a un nom, *animal*, et si ce nom a lui-même pour dépendant un déterminant. Le mode flexible permet ainsi d'obtenir plus de résultats au détriment de la spécificité de ce que l'on cherche.

A) Constructions avec une proposition subordonnée conjonctive CS-I, CS-III et CS-V

Contrairement aux travaux de Legallois (2008) et Roze et al. (2014), dans un contexte averbal comme les titres, nous ne pouvons faire l'économie de ne pas considérer les CS sans verbe être conjugué comme dans les CS-VI et CS-VI. Nous cherchons donc les schémas suivant dans notre corpus :

NSS⁵ nom commun [(, **ce** clitique sujet⁶ **être**) | **être** conjugué] **que** conjonction de subordination

Nous prenons l'exemple (e1) pour illustrer qu'un syntagme prépositionnel peut s'insérer entre le NSS et le contenu spécificationnel.

(e1) Le **problème** de cette nouvelle présentation est qu'elle n'est pas satisfaisante.

La difficulté est ici d'écarter toutes les propositions relatives. Schmid (2000, p. 3) indique clairement qu'une proposition relative ne peut être employée dans une construction spécificationnelle et qu'il ne faut pas confondre le *que* pronom relatif du *que* conjonction de subordination. A priori, les deux ayant des étiquettes différentes dans Talismane, cela ne devrait pas poser de problème.

En recherchant ce schéma, nous trouvons 26 titres qui correspondent. Néanmoins, Talismane étiquette des lemmes *que* comme conjonctions de subordination alors qu'il s'agit de pronoms relatifs. Sur un si faible nombre de résultats, nous pouvons manuellement les filtrer et ne gardons que trois titres, (29), (30) et (31) qui possèdent un nom en emploi sous-spécifié :

(29) Condamnation d'une société au paiement de ses cotisations volontaires obligatoires en l'absence de **preuve** que ces cotisations faisaient l'objet d'un emploi contraire au droit européen des aides d'État

(30) Bibliothèque implicite ou les **représentations** que les enseignants se font d'une culture humaniste

(31) Démystification de l'**idée** que le réseau d'aide informelle se délite

On remarque qu'il n'y a jamais de verbe *être* conjugué pour relier le NSS à la proposition subordonnée conjonctive. Néanmoins on peut facilement construire une telle phrase à partir du couple NSS / proposition comme par exemple *L'idée est que le réseau d'aide informelle se délite* pour valider qu'il s'agit bien d'un emploi sous-spécifié. On peut donc constater que ce schéma est très peu présent dans nos titres, même sans verbe être conjugué.

⁵ Dans les faits nous cherchons un nom commun mais nous utilisons cette mise en forme pour mettre le signaler l'emplacement du nom sous-spécifié dans notre schéma.

⁶ Nous ajoutons une capacité à nos schémas : celle de définir conjointement un lemme et une catégorie morphosyntaxique pour un token, toujours en indice dans ce cas, lorsqu'il y a une ambiguïté possible.

B) Constructions avec une proposition subordonnée infinitive CS-II, CS-IV et CS-VI

Pour ces CS, nous cherchons le schéma suivant :

NSS nom commun [(, **ce** clitique sujet **être**) | **être** conjugué] **de** préposition **VINF**

L'exemple (e2) montre que la négation *ne pas* peut s'insérer entre le *de* et le verbe à l'infinitif en plus d'avoir un syntagme prépositionnel entre le NSS et le contenu. Nous continuons pour cette raison à faire correspondre nos schémas à des relations de dépendance.

(e2) Le **problème** de cette nouvelle présentation est de ne pas satisfaire le client.

En cherchant ce schéma, nous trouvons 1 161 titres qui correspondent. Néanmoins, Talismane n'arrive souvent pas à correctement choisir le recteur de la préposition *de*, entraînant des faux positifs comme dans l'exemple (32) où le dernier *de* devant « faire le genre » a pour recteur le premier nom *corps*.

(32) Le corps recteur des filles à l'épreuve des filières scolaires masculines. Le rôle des socialisations primaires et des contextes scolaires dans la manière de dépendant « faire le genre »

Nous ajoutons des filtres pour trouver des occurrences de véritables constructions spécificationnelles : suppression des 27 titres avec « en vue de + infinitif », correction de la mauvaise dépendance si on trouve un nom commun immédiatement avant le *de* qui précède l'infinitif, non inclusion des sept titres avec la forme *Grégoire* étiquetée comme un verbe à l'infinitif, des six titres faisant de même pour *Alexandre*, des 12 titres avec *bien-être* dont Talismane considère l'*être* comme un infinitif et des 34 titres où un nombre était considéré comme infinitif, on tombe à 1 075 résultats.

Il n'y a que neuf résultats avec le verbe *être* conjugué. Nous pouvons rapidement les parcourir manuellement. Parmi ces résultats, il n'y a qu'une seule construction spécificationnelle avec une proposition subordonnée infinitive et le verbe *être*, l'exemple (33).

(33) Situation palestinienne : le plus grand **effort** de la CPI est de vaincre les passions

Pour les 1066 résultats sans le verbe *être* conjugué, nous décidons d'en tester manuellement 10 %, soit 107, pour avoir une estimation du nombre véritable de constructions spécificationnelles dans ces résultats. Sur les 107, 59 % ne sont pas des CS. Si on applique ce taux à nos 1 066 résultats, nos résultats ne comptent plus que 629 faux positifs et 437 utilisations estimées comme véritables de NSS. Parmi les CS trouvées, on peut citer les exemples (34), (35), (36) et (37).

(34) La **tentation** d'instituer des « Cours constitutionnelles régionales »

(35) **Possibilités** de réduire les émissions de gaz à effet de serre et d'autres impacts environnementaux dans les systèmes de production de viande bovine

(36) L'**obligation** de renégocier le contrat au nom de la lutte contre les gaz à effet de serre

(37) Réversibilités post-coloniales : les mobilités d'**art** de vivre à Marrakech

On peut également construire une phrase à partir du couple NSS / proposition avec le verbe *être* comme par exemple *La tentation est d'instituer des « Cours constitutionnelles régionales »* pour valider

qu'il s'agit bien d'une construction spécifique. On remarque que pour les exemples (34), (35) et (36), le NSS est également une tête de segment ce qui va dans le sens d'un rapprochement.

C) CS avec verbe copule et syntagme nominal, CS-VIII et CS-IX

Le schéma pour les deux constructions spécifiques CS-VIII et CS-IX est le suivant :

NSS nom commun [, **ce** clitique sujet] **être** verbe conjugué **NC**

Le nom final doit désigner une action ou une activité, néanmoins, ce schéma laisse ouverte la possibilité d'avoir des noms n'en étant pas pour que nous puissions étudier un maximum d'occurrences.

En cherchant le schéma correspondant à CS-VIII et CS-IX, toujours sur les relations de dépendances pour permettre une certaine flexibilité comme la présence de déterminants ou d'adjectifs, nous trouvons 226 résultats. Manuellement, nous éliminons des résultats qui nous semblent incorrects. Si les erreurs de Talismane comme confondre le verbe être avec le point cardinal *est* sont triviales, distinguer un emploi sous-spécifié ne l'est pas toujours. Si écarter les *full content nouns* comme *remariage*, *miroir* ou *misère* ne pose pas de problème, d'autres exemples se révèlent plus ardues à l'inspection du jugement intuitif, à défaut d'heuristique plus déterminante. Une technique consiste à essayer de paraphraser l'énoncé en une CS-I ou CS-II qui sont plus restrictives dans leurs syntaxes, ou CS-III et CS-IV, mais cela n'est pas toujours évident.

Nous retenons, sur les 226 résultats, un seul titre utilisant le pronom de reprise :

(38) Le plus grand **danger** social, c'est le bandit imberbe. La justice des mineurs à la Belle Époque

On voit bien ici que *danger* va créer un concept temporaire, que le locuteur caractérise sous un jour négatif, qui encapsule *le bandit imberbe*. Une phrase équivalente en CS-III serait *Le plus grand danger social, c'est que le bandit imberbe existe/menace/rôle*. On voit bien avec la phrase équivalente qu'il y a une action implicite, l'action du bandit, ne serait-ce que l'action d'*être*. Il serait très difficile pour un traitement automatique de déduire d'un tel énoncé un emploi sous-spécifié, c'est pour cela que la détection d'action implicite est hors de la portée de ce travail.

Sur nos 226 résultats, un seul autre titre correspond à un emploi sous-spécifié :

(39) L'activité d'évaluation et les systèmes d'information. L'**évaluation** est aussi un travail langagier, assisté, organisé

La tête *évaluation* figure parmi nos têtes transdisciplinaires.

Les exemples (40) et (41) ont été rejetés :

(40) La **connaissance** est un réseau : perspective sur l'organisation archivistique et encyclopédique

(41) La **théorie** des chances n'est pas un jeu d'esprit : le statut de la probabilité mathématique selon Cournot

On touche ici aux limites de la capacité de jugement intuitive pour cette tâche : on ne peut pas dire que *travail*, *réseau* et *un jeu d'esprit* remplissent complètement le NSS sur le plan sémantique. On effectue les tests suivants :

- Est-il possible d'utiliser le nom dans une CS-I ou une CS-II : si oui, il y a un potentiel de portage d'une proposition, mais cela ne prouve que l'emploi étudié en est un.
- Est-ce que le nom du syntagme nominal désigne une action ?

Si l'on répond par l'affirmative à ces deux réponses, nous sommes bien présence d'un NSS. Ce qui est certain, c'est le faible nombre de résultats qui ont le potentiel de correspondre à un emploi en NSS. Sur les dix exemples de NSS que nous avons extraits, *preuve*, **représentation**, *idée*, *effort*, *tentation*, *possibilité*, *obligation*, *art*, *danger*, **évaluation** deux sont des têtes transdisciplinaires. Nous savons donc que 2 % de nos 94 têtes transdisciplinaires admettent un emploi sous-spécifié néanmoins cet emploi semble rare : deux occurrences sur les 94 738 que comptent les têtes transdisciplinaires. Il reste enfin la dernière CS classique.

D) CS avec un syntagme prépositionnel-nominal, CS-VII

Cette dernière construction utilise le schéma suivant, très généraliste, où le premier NC est employé en NSS, que nous recherchons sur les liens de dépendance pour permettre une plus grande flexibilité :

NSS nom commun **de** préposition **NC**

Schmid (2018, p. 115) indique que son étude de 2000 n'a pas pris la définition CS-V-N pour des raisons techniques, car elle rapporte trop de résultats et avec beaucoup de bruits, comme les relations partie-totalité comme dans *le cœur du problème*. Or nos titres étant majoritairement averbaux, nous avons bien plus de chance d'y trouver des contenus spécifiants nominaux comme Mousavi et Rauof Moini (2014). Ne pas retenir cette construction nous ferait perdre de nombreux exemples. De plus, nous n'avons, pour une recherche automatique, pas d'autres alternatives qu'une définition structurelle. Dans notre corpus, cette requête rapporte 179 931 résultats ce qui est beaucoup trop large pour permettre ensuite une sélection manuelle.

Une possibilité, reprise de Roze et al. (2014, p. 8) est de contraindre la requête en prenant le résultat uniquement si le premier nom appartient à un lexique. Ces auteurs utilisent un lexique pour découvrir de nouvelles CS en fournissant en entrée un lexique de noms déjà identifiés dans un ensemble de CS de type CS-I, CS-II, CS-III et CS-IV. Nous ajoutons à l'appartenance à un lexique, l'hypothèse que le premier nom soit également une tête de segment transdisciplinaire.

II.3 Schémas récurrents d'emploi des têtes transdisciplinaires

II.3.1 Recherche des schémas d'emplois des têtes transdisciplinaires

Du fait que les NSS sont une classe ouverte, et que les définitions varient d'un auteur à l'autre, aucune liste définitive n'est possible. Schmid liste 670 *shell nouns* (2000, p. 381), Flowerdew et Forest (2015), 845 *signalling nouns*, et Tutin (2008, p. 3), 356 *noms sous-spécifiés*. Néanmoins, Schmid (2018, p. 118) souligne la convergence de sa liste avec celle de Flowerdew et Forest (2015) sur les NSS les plus fréquents malgré leurs différentes méthodes. Ces listes peuvent donc servir d'indices, mais en aucun cas de preuves, pour prendre en compte le potentiel d'emploi sous-spécifié de nos têtes transdisciplinaires.

Sur les 94 têtes transdisciplinaires, 23 sont reconnues comme pouvant être un NSS par Legallois (2008, p. 3), soit seulement 24 %. Cependant, la définition opératoire de Legallois repose uniquement sur les CS CS-I et CS-II, et son corpus, les articles de l'année 1995 du quotidien *Libération*, est très éloigné du nôtre. Or, une définition opératoire est toujours dépendante du corpus sur lequel elle est appliquée.

Sur les 94 têtes transdisciplinaires, 83 ont un lemme dont la traduction en anglais apparaît dans la liste de Flowerdew et Forest (2015), soit 88 %. Son corpus est beaucoup plus proche de notre matériau, puisqu'il s'agit du Flowerdew Corpus of Academic English (Flowerdew et Forest, 2015, p. 68) composé de journaux académiques, de discours et de leçons. Cela nous amène à vouloir chercher les schémas récurrents des têtes transdisciplinaires dans nos titres.

A) Recherche de schémas émergents via la fouille de données

L'existence de nos têtes transdisciplinaires, fréquentes, abstraites, dotées d'un faible contenu sémantique, le fait que 83 % d'entre elles apparaissent dans la liste des signalling nouns, nous pousse à nous demander s'il n'existerait pas d'autres constructions spécificationnelles, propres aux titres. Nous allons à présent essayer de rechercher des schémas récurrents dans lesquels s'inséreraient nos têtes transdisciplinaires et d'évaluer si ceux-ci pourraient jouer le rôle de construction spécificationnelle.

La question se pose de distinguer les schémas récurrents des têtes transdisciplinaires des autres. Pour cela, nous allons utiliser la fouille de données séquentielles et ses notions de *séquences* et de *motifs*. Nous reprenons directement une méthode formulée par Roze et al. (2014, p. 8), qui s'inspiraient déjà de Quiniou et al. (2012). Tout d'abord, nous construisons des séquences de mots à partir des titres autour des têtes nominales transdisciplinaires ou non. Nous écartons les têtes non nominales ainsi que les têtes non transdisciplinaires noms propres car nous voulons comparer les têtes transdisciplinaires avec celles qui ne le sont pas, or, nos têtes transdisciplinaires sont exclusivement des noms communs. Les comparer à une autre catégorie lexico-syntaxique ferait intervenir d'autres paramètres qui sortent du périmètre de cette étude.

Une séquence est une suite d'items ou d'ensembles d'items ordonnés. Nous calculons toutes les séquences existantes autour des têtes en utilisant une taille minimale de deux mots et une taille maximale de cinq mots. Chaque séquence est constituée d'items qui peuvent être :

- l'étiquette PONCT pour les marques de ponctuation, sauf s'il s'agit d'une marque segmentatrice, où on aura SEG
- le lemme pour un mot si c'est une préposition, une conjonction de coordination, une conjonction de subordination, ou le verbe *être* ou *avoir*,
- son étiquette morphosyntaxique pour les autres classes de mot, selon la nomenclature de Talismane reprise dans l'annexe **A4.1 Catégories morphosyntaxiques de Talismane** dont on rappelle les principales étiquettes : NC pour nom commun, DET pour déterminant, ADJ pour adjectif, NPP pour nom propre, VPP pour verbe au participe passé.
- Lorsqu'il s'agit d'une tête transdisciplinaire, l'item sera TransHead (forme abrégée : TT) au lieu de son étiquette NC.

- Lorsqu'il s'agit d'une tête non transdisciplinaire, l'item sera Head (forme abrégée : HH) au lieu de son étiquette NC.
- Nous ajoutons les items INIT pour le début du titre et END pour sa fin.

L'exemple (42) possède deux têtes, la première, *problème*, est transdisciplinaire, l'autre, *région*, ne l'est pas.

(42) Les **problèmes** d'environnement dans une région d'extraction pétrolière : la **région** de Nijnevartovsk situé sur le territoire Khanti-Mansi (Russie)

Nous allons extraire pour chaque tête les séquences suivantes avec un taille minimum de deux et une taille maximum de 5 :

Longueur	Séquences extraites pour <i>problème</i>	Longueur	Séquences extraites pour <i>région</i>
2	DET TT	2	DET HH
2	TT de	2	HH de
3	INIT DET TT	3	SEG DET HH
3	DET TT de	3	DET HH de
3	TT de NC	3	HH de NPP
4	INIT DET TT de	4	ADJ SEG DET HH
4	DET TT de NC	4	SEG DET HH de
4	TT de NC dans	4	DET HH de NPP
5	INIT DET TT de NC	4	HH de NPP VPP
5	DET TT de NC dans	5	NC ADJ SEG DET HH
5	TT de NC dans DET	5	ADJ SEG DET HH de
		5	SEG DET HH de NPP
		5	DET HH de NPP VPP
		5	HH de NPP VPP sur

Tableau 12 : Séquences extraites de l'exemple (42)

Nous répartissons les séquences dans deux bases : d'un côté, la base transdisciplinaire qui contient les séquences avec une tête transdisciplinaire, et de l'autre la base commune qui contient les séquences qui ont pour pivot une tête non transdisciplinaire.

Nous calculons ensuite le support de chaque séquence. Le support de la séquence *S*, c'est le nombre de séquences qui la contiennent dans une base donnée. Une séquence *S* est contenue dans une séquence *S'* si on y retrouve tous les items de *S*, toujours dans le même ordre, mais éventuellement de façon disjointe. Ainsi, la séquence **DET TT** est contenue dans la séquence **DET TT de**, **DET ADJ TT de**, **DET NC PONCT TT**. Le support relatif est le support divisé par le nombre de séquences dans la base. Selon Roze et al. (2014, p. 383), « un motif fréquent est une séquence dont le support est supérieur ou égal à un seuil fixé » que nous fixerons ultérieurement.

Nous faisons deux extractions, EX1 et EX2, de séquence et de calculs de support. Pour la première extraction, nous utilisons une taille minimale de deux et une taille maximale de trois. Pour la seconde, nous utilisons la même taille minimale et une taille maximale de quatre. Par cette taille

maximale limitée, nous souhaitons avant tout étudier l'environnement immédiat des têtes. Le tableau (13) présente les résultats des deux extractions.

	EX1 : séquence de 2 à 3 items	EX2 : séquence de 2 à 4 items
Nombre de séquences avec pour pivot une tête transdisciplinaire	510 980	919 764
Nombre de séquences avec pour pivot une tête non transdisciplinaire.	992 815	1 787 067

Tableau 13 : Nombre de séquences pour les deux bases de chaque extraction

Les motifs émergents sont « les motifs dont le support augmente de manière significative d'un ensemble de données à un autre » (Roze et al., 2014, p. 383), ce qui se traduit par un taux de croissance supérieur à une valeur p que nous fixons à un pour être le plus large possible. Tout motif transdisciplinaire dont le support est supérieur au support du motif commun correspondant sera sélectionné. Notre but est de trouver des motifs qui seraient propres aux têtes transdisciplinaires et fréquents. Pour cela, nous écartons à chaque fois les motifs dont le support est inférieur à 0,1 % du nombre de séquences dans la base transdisciplinaire, soit 511 pour EX1 et 920 pour EX2.

B) Découvertes de schémas émergents liés à une position particulière des têtes

Notons que la technique de la fouille de données séquentielles, applicable dans d'autres domaines scientifiques, ignore complètement le fonctionnement linguistique des items. Si la séquence S2 **DET NC PONCT TT** contient bien la séquence S1 **DET TT**, dans la première, DET est dépendant de NC alors que dans la seconde DET est dépendant de TT. La relation « est contenu dans » est vérifiée, et le support de **DET TT** augmenté, mais on ne peut pas dire que le syntagme nominal que l'on pourrait voir dans S1 se retrouve dans S2. De ce fait, notre exploration des résultats pour retourner des séquences et motifs de la fouille de données vers les schémas lexico-syntaxiques doit se faire à la lumière de nos connaissances linguistiques.

Dans le cadre de l'extraction EX1, où les séquences comportent entre deux et trois items, 13 motifs fréquents sont émergents. Le tableau (14) liste les différents motifs, leurs supports et leurs taux de croissance. Lorsqu'un lemme est présent dans les items, sa catégorie est également donnée après un double-point.

N°	Longueur	item 1	item 2	item 3	Support	Croissance
1	3	SEG	TransHead	à::P+D	757	7,01
2	3	SEG	TransHead	à::P	1102	4,73
3	3	SEG	TransHead	sur::P	1264	4,48
4	3	INIT	TransHead	sur::P	1613	2,83
5	3	TransHead	sur::P	DET	3744	2,57
6	2	TransHead	sur::P	(aucun)	12788	2,20
7	3	SEG	TransHead	de::P+D	2188	1,43
8	3	TransHead	ADJ	sur::P	762	1,43
9	3	SEG	TransHead	de::P	4856	1,37
10	3	DET	TransHead	sur::P	664	1,20

11	3	ADJ	SEG	TransHead	5800	1,18
12	3	NC	SEG	TransHead	7994	1,04
13	3	SEG	TransHead	NC	633	1,01

Tableau 14 : Motifs émergents avec une longueur maximale de séquence de trois items

Nous écartons d'emblée le 13^e motif car il s'agit d'une erreur de Talismane qui pousse à reconnaître comme un nom commun ce qui est un adjectif comme dans l'exemple (43) où *archéozoologique* est reconnu à tort comme nom commun.

(43) Le Plan Saint-Jean (Brignoles) : étude archéozoologique

Pour les autres motifs, on peut remarquer un point principal : la tête transdisciplinaire est très fréquemment en début du titre (motif 4), après **INIT**, ou après une ponctuation segmentatrice **SEG** (motifs 1, 2, 3, 7, 9). Néanmoins les motifs correspondants à **INIT TransHead** et **SEG TransHead**, avec un taux de croissance respectivement de 0,47 et de 0,96, ne sont pas spécifiques aux têtes transdisciplinaires. C'est la conjonction de cette position avec la préposition *sur*, pour les têtes en positions initiales (motif 4), et avec les prépositions *à*, *sur* et *de* pour les têtes immédiatement après un signe de ponctuation segmentant (motif 1, 2, 3, 7, 9), qui rend ces motifs spécifiques aux têtes transdisciplinaires. Notons que l'utilisation de la préposition *sur* à la suite d'une tête transdisciplinaire est déjà un signe distinctif de ces têtes par rapport aux têtes non transdisciplinaires (motif 6). L'emplacement privilégié des têtes transdisciplinaires après un signe de ponctuation segmentant se rapproche de notre travail de première année, mais par un autre cheminement.

Un comptage sur notre corpus confirme ce que nous avons trouvé par la fouille de données : 19 235 têtes transdisciplinaires sont après un signe de ponctuation. Et 18 638 de ces signes, soit près de 97 %, sont des signes segmentants.

On remarque que les prépositions sont éventuellement fusionnées avec un déterminant comme *du* ou *au* (motifs 1 et 7). Selon la syntaxe, ces motifs doivent être suivis par un nom.

Cela signifie que la tête transdisciplinaire est majoritairement en tête de son segment, soit du premier segment et donc en tête du titre (motif 4), soit du second segment (motifs 1, 2, 3, 7, 9, 11, 12). Nous donnons ci-dessous des exemples de titres avec le motif correspondant.

(44) Vers le Web Socio Sémantique : introduction aux ontologies sémiotiques	motif 1
(45) Investitures et rapports de pouvoirs : Réflexions sur les symboles de la Querelle en Empire	motif 3
(46) Conception Isotropique d'une morphologie parallèle : Application à l'usage	motif 2
(47) Remarques sur le polythéisme étrusque	motif 4

Dans le cadre de l'extraction EX2, où les séquences comportent entre deux et quatre items, 43 motifs fréquents sont émergents. Nous nous intéressons parmi ceux-ci aux 19 qui comptent quatre items, car c'est eux qui apportent des informations supplémentaires sur l'environnement immédiat des têtes transdisciplinaires, dans le tableau (15).

N°	Longueur	item 1	item 2	item 3	item 4	Support	Croissance
----	----------	--------	--------	--------	--------	---------	------------

1	4	SEG	TransHead	à::P	DET	930	7,75
2	4	SEG	TransHead	sur::P	DET	1219	4,63
3	4	INIT	TransHead	sur::P	DET	1557	3,36
4	4	TransHead	sur::P	DET	NC	3509	2,57
5	4	ADJ	SEG	TransHead	de::P	1524	1,70
6	4	SEG	DET	TransHead	de::P+D	4447	1,59
7	4	SEG	TransHead	de::P+D	NC	2047	1,45
8	4	SEG	TransHead	de::P	DET	2585	1,45
9	4	NC	SEG	TransHead	de::P+D	939	1,44
10	4	SEG	TransHead	de::P	NC	2120	1,39
11	4	NC	SEG	TransHead	de::P	2007	1,34
12	4	de::P	NC	SEG	TransHead	1598	1,31
13	4	SEG	DET	TransHead	de::P	6819	1,24
14	4	NPP	SEG	TransHead	de::P	925	1,19
15	4	NC	ADJ	SEG	TransHead	4524	1,19
16	4	INIT	TransHead	de::P	DET	7461	1,15
17	4	ADJ	SEG	DET	TransHead	6174	1,12
18	4	NC	SEG	TransHead	ADJ	1474	1,05
19	4	ADJ	SEG	TransHead	ADJ	987	1,05
20	4	de::P+D	NC	SEG	TransHead	1087	1,00

Tableau 15 : Motifs émergents pour les séquences de longueur de quatre items

On voit apparaître dans cette seconde extraction que les motifs à prépositions non fusionnées sont suivis par un déterminant, ce qui appelle un nom (motifs 1, 2, 3, 4, 8, 16). On voyait déjà apparaître le déterminant lorsqu'il était fusionné avec la préposition dans EX1, comme ici avec les motifs 6, 7 et 9. Dans certains motifs, le nom apparaît directement, sans déterminant (motif 10) ou avec (motif 4).

Il apparaît également qu'avant la ponctuation qui précède la tête transdisciplinaire on trouve des noms communs (motifs 9, 11, , 12, 15, 18, 20) ou des noms propres (14).

Une autre information est la possibilité d'avoir un adjectif qui doit qualifier la tête transdisciplinaire (motifs 18 et 19) ainsi qu'un déterminant pour la tête (motifs 6, 13, 17).

Nous donnons ci-dessous des exemples de titres avec le motif correspondant.

(48) Classification floue généralisée : Application à la quantification de la stéatose sur des images histologiques couleurs	motif 1
(49) Word Wild West : remarques sur les glissements de forme et de sens du mot west	motif 2
(50) Réflexions sur l' économie cubaine	motif 3

C) Analyse des résultats : construction de deux schémas de recherche

Les motifs émergents ont fait apparaître des spécificités dans l'emploi des têtes transdisciplinaires :

- La position en début de segment, que cela soit en début de titre (premier segment) ou en début de second segment après un signe de ponctuation segmentant
- Une préférence à être suivie par les prépositions *à, sur, de* dans cette position.

Nos connaissances linguistiques nous permettent d'interpréter les motifs émergents détectés, de les combiner entre eux, par exemple pour y intégrer des tokens optionnels comme un déterminant ou un adjectif, pour en tirer les deux schémas suivants :

Schéma 1 :

INIT [DET] **TRANSHEAD** [ADJ] (((à_P | sur_P | de_P) [DET]) | (à_{P+D} | de_{P+D})) NC

Schéma 2 :

SEG [DET] **TRANSHEAD** [ADJ] (((à_P | sur_P | de_P) [DET]) | (à_{P+D} | de_{P+D})) NC

Nous rappelons cette syntaxe dans la partie **II.2.3 Recherche des constructions spécificationnelles classiques dans le corpus**. Cette fois-ci, nous recherchons nos schémas de façon stricte : aucun token non prévu dans la définition n'est autorisé.

D) Rapprochement des deux schémas avec la CS-VII

Le fait le plus remarquable est que les deux schémas se rapprochent de la CS-VII, NSS de NC., en prenant l'hypothèse que les têtes transdisciplinaires sont sous-spécifiées. D'un côté, les schémas sont plus contraignants, sur l'emplacement dans le titre de la tête : uniquement au début d'un segment, éventuellement après son déterminant. D'un autre côté les schémas élargissent la CS-VII : ils autorisent *à* et *sur* comme préposition.

Si la capacité de portage propositionnel (Huyghe, 2018) est une propriété qui distingue les NSS, l'expansion du nom par un syntagme prépositionnel complément du nom commençant par *de* ne l'est pas. La préposition *de*, peut se rapprocher du *of* anglais, qui est, selon Schmid (2018, p. 115), « *highly polysemous and frequently encodes a possessive or part-whole relation rather than one of identity* ». La relation sémantique *partie-tout* peut très bien s'exprimer en français de la même manière : *le capot de la voiture*. Pour déterminer s'il s'agit d'emplois sous-spécifiés, il faut à présent s'interroger sur la sémantique du nom commun présent à la fin de chacun des deux schémas.

II.3.2 Lexique des noms et détermination de l'emploi

Dans notre corpus de travail, 36 664 titres correspondent à notre premier schéma, 18 175 à notre second schéma et 3 065 aux deux à la fois. On remarque que toutes les têtes transdisciplinaires apparaissent dans nos résultats. Cela fait un total de 60 969 emplois de têtes transdisciplinaires à analyser pour déterminer l'éventuelle sous-spécification, soit 64 % de leurs occurrences, ce qu'il est inenvisageable de faire manuellement. Nous décidons de prendre un exemple avec la tête *problème*.

A) L'étude de *problème*

Le choix d'étudier la tête transdisciplinaire *problème* repose sur deux points :

- Il est un *prime shell noun* de Schmid (2000, p. 85 ; 2018 ; p. 118) et

- dans la liste de Flowerdew et Forest (2015, p. 203), il est le 3^e par ordre de fréquence normalisée.

Il y a donc une forte probabilité que *problème* puisse avoir des emplois en NSS dans notre corpus des titres. La tête *problème* est la 52^e dans l'ordre de fréquence dans nos résultats des schémas un et deux. Selon notre méthode de sélection des têtes transdisciplinaires, elle est la 58^e tête transdisciplinaire, sur 94, en les classant par valeur de médiane.

On restreint donc nos schémas en prenant pour TRANSHEAD uniquement les occurrences de *problème*. Dans notre corpus de travail, 256 titres correspondent au premier schéma et 145 titres correspondent au second schéma avec *problème*. Aucun titre ne correspond aux deux, signifiant qu'il n'y a pas de titres bisegmentaux ayant deux fois comme têtes *problème* comme nous l'avions vu dans [A](#)) **Répartition des natures des têtes.**

En ce qui concerne les prépositions, on compte 389 *de* 12 à et 0 *sur*. On peut donc constater l'incompatibilité de certaines têtes transdisciplinaires avec certaines prépositions.

En ce qui concerne les noms communs, il y a 283 lemmes différents qui correspondent au nom commun final des deux schémas, celui que nous voulons analyser. Nous retenons certains exemples de titres comme (34), (35) et (36).

(34) Quelques **problèmes** d'analyse de la délinquance juvénile à la fin du XIXe siècle. L'exemple parisien

(35) Le **problème** du regroupement des activités dans la modélisation ABC. Une approche possible

(36) **Problèmes** de création en multimédia : marier l'expérience de l'audiovisuel et la rigueur de la qualité

On peut à chaque fois paraphraser ces exemples en utilisant une autre CS. Pour l'exemple (35), on peut paraphraser par la CS-II, avec être suivi d'une préposition et d'un infinitif : *le problème est de regrouper*. Pour les exemples (34) et (36), on peut les paraphraser avec la CS-VI, qui reprend la CS-II sans le verbe être : *Quelques problèmes d'analyser, Problèmes de créer en multimédia. Analyse, regroupement, création* sont des déverbaux dénotant une action ou une activité.

Nous avons également recherché les deux schémas dans les titres en enlevant la contrainte que *problème* soit une tête. Deux occurrences seulement correspondent au schéma sans que *problème* ne soit une tête de segment : les exemples (37) et (38).

(37) Problème d'interprétation des enclos quadrangulaires de La Tène moyenne **découverts** en Flandre française : l'exemple de Borre (Nord)

(38) Les problèmes **viennent** du fonctionnement du système, pas des individus. Entretien avec Maurice Godelier

Une seule de ces deux occurrences peut être reçue comme un emploi de *problème* en NSS, l'exemple (37) qui paraphrasé devient : *Le problème est d'interpréter les enclos quadrangulaires de La Tène moyenne découverts en Flandre française*. La possibilité de correspondre avec nos schémas, et donc d'un éventuel emploi sous-spécifié, semble donc fortement liée au fait que le lemme soit tête. Nous nous contentons par la suite d'étudier uniquement le cas initial, où le lemme recherché est tête.

On remarque une construction de la forme *le problème posé par X* comme dans l'exemple (39) et qui semble correspondre à un emploi NSS. L'exemple (39) peut en effet être paraphrasé en *Problèmes de prédire en persan*. Néanmoins, cet emploi est propre à *problème*, on ne peut pas mettre un autre lemme à la place. Nous ne le retenons pas dans notre tentative de trouver une détermination générale de l'emploi des têtes transdisciplinaires en NSS.

(39) **Problèmes** posés par la prédication en persan. **Approche** contrastive persan

Nous avons déjà évoqué la nécessité que le nom commun du contenu spécifiant dénote une action, faute d'un verbe pour le faire comme dans les CS avec des propositions conjonctives ou infinitives. On peut s'appuyer sur la morphologie car les noms désignant une action utilisent préférentiellement les suffixes *-(a)tion, -sion, -age, -ment* comme dans nos résultats : *évaluation, inversion, réglage désencastrement*. Mais ce travail est ardu car certains noms n'utilisent aucun suffixe, comme *commande* ou *transport*. De plus, il peut y avoir une modification du radical ou des noms avec ces terminaisons mais ne désignant pas une action.

Nous avons néanmoins à notre disposition une ressource, VerbAction⁷ (Tanguy et Hathout, 2002) qui contient 9 393 paires (verbe, nom) comme par exemple : abandonner → abandon, abandonner → abandonnement. Nous pouvons donc, en utilisant cette base, restreindre encore plus nos deux schémas pour ne prendre que les titres où le nom commun final est dans cette base.

Nous obtenons 136 résultats qui, analysés manuellement, correspondent dans leur grande majorité à des emplois sous-spécifiés, comme les exemples (40, 41, 42 et 43). Nous mettons en gras les éléments qui correspondent aux tokens de nos schémas.

(40) Un **problème de remplissage** de verres

(41) LE **PROBLEME DE LA DEFINITION** DES ENTITES LINGUISTIQUES CHEZ FERDINAND DE SAUSSURE.

(42) Les unités verbales polylexicales : **problèmes de repérage** en traitement automatique.

(43) Pierre noire et anagrammes saussuriens: **un problème d'écriture**

Néanmoins nous détectons certains titres correspondants à nos schémas qui ne sont pas des emplois sous-spécifiés comme dans les exemples (45, 46, 47).

(45) **Le problème de l'union** gréco-latine

(46) **Problèmes actuels de l'Union** européenne

(47) **Le problème du sac** à dos

Les titres (45) et (46) utilisent le nom *union* qui peut être associé au verbe unir. Néanmoins, le nom ne désigne pas l'action mais le résultat de l'action ce qui fait que la paraphrase n'a pas de sens. A cela s'ajoute la non-détection par Talismane du nom propre *Union européenne*. Le titre (47) utilise *sac*

⁷ <http://redac.univ-tlse2.fr/lexicons/verbaction.html>

qui est polysémique : d'un côté un *sac*, le nom désignant l'action de saccager une ville par exemple, et de l'autre le *sac*, le contenant transportable.

Les exemples (48) et (49) sont des cas intermédiaires : la paraphrase est possible pour les deux, mais *tournées* ne doit pas être relié à *tourner* mais à *faire une tournée*. Pour (49), la paraphrase est possible mais s'éloigne trop du sens initial : *le problème d'économiser de l'eau* est bien plus restrictif que ce que désigne *le problème de l'économie de l'eau*. Par économie, il ne s'agit pas seulement de l'action d'économiser, mais plus globalement de la gestion d'une ressource, ici l'eau.

(48) **Problème de tournées** de véhicules avec routes multiples pour réaliser des traitements phytosanitaires

(49) **Le problème de l'économie** de l'eau en pisciculture

Si on compte tous les résultats ayant pour nom *union, sac, économie*, on obtient un nombre de faux positifs égal à quatre, soit une précision de 97 %. Nous pouvons donc, à l'aide de nos schémas et de la base VerbAction, estimer l'emploi sous-spécifié des têtes transdisciplinaires.

B) Estimation globale à l'aide des deux schémas

Nous recherchons donc dans notre corpus de travail les titres correspondants à nos deux schémas, en retenant le résultat uniquement si le nom final commun aux deux schémas se trouve dans la base VerbAction. Comme les noms qui désignent une action sont une classe ouverte, nous ne pouvons qu'admettre que notre résultat ne sera qu'une estimation large. De plus, nous avons vu que Roze et al. (2014) mettent en garde contre des locutions ne pouvant être considérés comme des emplois NSS. Ainsi, « système d'information » ne peut se paraphraser en « système pour informer » car le sens de ce syntagme n'est pas une simple opération de composition sémantique des deux mots dont on pourrait faire varier la catégorie, mais renvoie à une classe d'objet réel bien précise, celle des éléments constitués d'applications (software) et d'infrastructures (hardware) fournissant des services dans une entreprise ou une organisation.

Nous obtenons, sur l'ensemble de notre corpus, 15 040 titres correspondants au schéma 1, 7 561 correspondants au schéma 2 et 448 titres correspondants aux deux schémas, soit 23 497 têtes transdisciplinaires candidates ce qui en représente 25 %. Nous donnons ci-dessous quelques exemples (50, 51, 52, 53) en mettant en gras la partie correspondante à nos schémas et en proposant en italique une paraphrase vers la CS-VI, en élargissant les possibilités de celles-ci à d'autres prépositions que *de*.

(50) **Modèles de publication** sur le web, Rapport d'activités AS-CNRS 103

Modèles pour publier sur le web, Rapport d'activités AS-CNRS 103

(51) **Effets de la substitution** du maïs par du sorgho sur la durabilité de la production de foie gras d'oie

Effets de substituer du maïs par du sorgho sur la durabilité de la production de foie gras d'oie

(52) **Approche intégrée de la gestion** de l'environnement, conférence invitée dans le cadre de la formation doctorale

Approche intégrée pour gérer l'environnement, conférence invitée dans le cadre de la formation doctorale

(53) **Le cas de la gestion** des blessés de l'avant.

Le cas de gréer des blessés de l'avant.

Néanmoins certains titres sélectionnés ne correspondent pas un emploi sous-spécifié comme les exemples (54, 55 et 56).

(54) **Enquête sur le confort** thermique en situation réelle au Cameroun

** Enquêter sur conforter thermiquement en situation réelle au Cameroun*

(55) **Brève histoire de la proposition**

** Brève histoire de proposer*

(56) **Système d'information** stratégique dédié à l'environnement universitaire

** Système pour informer stratégiquement dédié à l'environnement universitaire*

Aucune des paraphrases des exemples (54, 55, 56) n'est satisfaisante, déformant le sens initial. Dans (54), il y a une distance sémantique trop importante dans l'emploi du nom *confort*, désignant ici, à l'aide de l'adjectif *thermique*, le chauffage, et le verbe *conforter*. Dans (55), le nom *proposition* ne désigne pas l'action de proposer, mais l'objet linguistique d'après le domaine du titre. Dans (56), que nous avons vu plus haut, la locution *système d'information* doit s'interpréter globalement et non en additionnant le sens de ses éléments.

Nos schémas lexico-syntaxiques ne sont donc pas encore assez restrictifs pour sélectionner uniquement les emplois sous-spécifiés. On peut se demander si de tels schémas peuvent réussir à saisir ces emplois, puisque ces constructions sont définies aussi bien sur le plan lexical, syntaxique que sémantique. Nous pouvons néanmoins dire que nos schémas sélectionnent un lot de têtes transdisciplinaires candidates à un emploi sous-spécifié, dans une proportion qui reste à déterminer. Le taux de précision de 97 % que nous avons calculé pour *problème* ne saurait être qu'une estimation fragile pour la précision globale et l'évaluation du rappel est inaccessible sur un corpus aussi large.

Nous pouvons néanmoins donner une liste des têtes transdisciplinaires avec le nombre de correspondances relevées par nos schémas, en gardant à l'esprit qu'il s'agit d'une indication de potentialité de transdisciplinarité. Nous indiquons dans le tableau (16) celles dont le nombre d'occurrences dans les résultats est supérieur à 1 % du total, soit 235 :

N°	Tête	Nombres d'occurrences dans les résultats
1	étude	1776
2	analyse	964
3	cas	915
4	exemple	791
5	application	740
6	méthode	724
7	effet	706

8	modélisation	647
9	contribution	596
10	influence	559
11	enjeu	508
12	approche	500
13	modèle	497
14	impact	484
15	apport	471
16	outil	444
17	évaluation	442
18	système	442
19	essai	409
20	évolution	396
21	point	393
22	stratégie	391
23	élément	339
24	rôle	335
25	réflexion	316
26	politique	316
27	mesure	278
28	processus	265
29	dynamique	254

Tableau 16 : Tableau des têtes transdisciplinaires les plus fréquemment retrouvées dans nos schémas

Nous pouvons également regarder le potentiel d'emploi sous-spécifié des têtes non transdisciplinaires. En cherchant les schémas un et deux en remplaçant TRANSHEAD par HEAD, nous obtenons 19 033 titres dont la première tête est potentiellement en emploi sous-spécifié, 5 141 titres dont la seconde tête est potentiellement un NSS, et 301 titres où les deux têtes sont potentiellement en emploi sous-spécifié, pour un total de 24 776 têtes. Si ce chiffre est proche de notre total de têtes transdisciplinaires candidates, 23 497, il faut le ramener au nombre de têtes nominales non transdisciplinaires du corpus, soit 9 %, contre 25 % de candidates chez les têtes transdisciplinaires.

Après avoir estimé le potentiel de sous-spécification des têtes transdisciplinaires ou non, nous pouvons voir comment ce potentiel se répartit dans les différents domaines.

II.3.3 Transdisciplinarité des schémas

On peut chercher comment les deux schémas identifiés précédemment se répartissent dans les différents domaines de notre corpus. Le tableau est classé selon la dernière colonne, le pourcentage que représente les têtes transdisciplinaires candidates par rapport au nombre de total de têtes transdisciplinaires.

Têtes transdisciplinaires	Têtes transdisciplinaires en emploi de NSS selon schéma 1	Têtes transdisciplinaires en emploi de NSS selon schéma 2	Total têtes transdisciplinaires en emploi de NSS	Total têtes transdisci-	%
Domaines					

				plinaires	
Physique	3 245	610	3 855	13 515	29 %
Éducation	640	422	1 062	4 091	26 %
Psychologie	184	90	274	1 059	26 %
Sciences de l'environnement	511	255	766	2 978	26 %
Informatique	1 090	401	1 491	5 923	25 %
Sciences du Vivant	1 787	509	2 296	9 232	25 %
Gestion et management	1 501	1 062	2 563	10 445	25 %
Géographie	66	39	105	436	24 %
Sciences cognitives	174	117	291	1 252	23 %
Science politiques	334	288	622	2 712	23 %
Planète et Univers	232	69	301	1 341	22 %
Sciences de l'information et de la communication	343	239	582	2 599	22 %
Mathématiques	157	57	214	964	22 %
Économie et finance quantitative	27	17	44	202	22 %
Linguistique	636	474	1 110	5 223	21 %
Sociologie	1 169	996	2 165	10 310	21 %
Droit	750	289	1 039	4 977	21 %
Archéologie et préhistoire	212	294	641	3 141	20 %
Chimie	148	41	189	959	20 %
Architecture	149	105	254	1 328	19 %
Anthropologie	160	165	325	1 731	19 %
Philosophie	164	139	303	1 726	18 %
Art et histoire de l'art	120	133	253	1 475	17 %
Histoire	389	457	846	4 956	17 %
Littératures	139	161	300	2 159	14 %

Tableau 17 : répartition des schémas dans les différentes disciplines

Nous constatons des écarts dans l'utilisation de ces schémas, et donc dans la présence de têtes transdisciplinaires candidates à un emploi sous-spécifié. L'étendue a pour minimum 14 % en littératures, et pour maximum 29 % en physique.

Nous avons dans cette partie identifié un petit nombre de têtes transdisciplinaires, 123 en tout si on reprend tous les lemmes identifiés dans les différents sous-corpus, et 94 si on applique nos calculs globalement au corpus de travail. Les têtes transdisciplinaires sont très fréquentes et donc utilisées dans de nombreux titres de notre corpus de travail et, à 70 % pour les 123 têtes et à 79 % pour les 94 têtes, déjà relevées dans le lexique transdisciplinaire des écrits scientifiques de Tutin (2008), et respectivement à 82 % et 87 % dans le lexique scientifique transdisciplinaire de Hatier (2016).

L'étude du second segment des titres bisegmentaux a mis en avant deux têtes transdisciplinaires qui le caractérisent tout particulièrement, *cas* et *exemple*. Les têtes transdisciplinaires sont caractérisées par une haute fréquence en tant que têtes et un haut degré d'abstraction. Nous conservons le nombre de 94 pour garder un point de vue global sur le corpus.

Nous avons ensuite rappelé le concept de NSS, un nom fréquent au faible contenu sémantique dont la particularité est d'être spécifié par son contexte à l'aide de plusieurs constructions spécificationnelles. Nous avons montré que le contenu spécifiant qui est relié au NSS joue une fonction d'attribut. Nous avons également montré que, si le NSS en a la capacité, on peut facilement passer de certaines CS à d'autres, que cela soit par l'ajout du pronom de reprise *ce* ou par l'ajout du verbe copule *être*. Nous avons également montré que, dans le cas d'un syntagme nominal comme contenu spécifiant, il faut toutefois que son nom noyau soit un déverbal qui dénote une action ou une activité.

Nous avons essayé de détecter les différentes occurrences de constructions spécificationnelles dans nos titres où une tête transdisciplinaire serait employée comme NSS. Nous nous sommes heurtés au problème que les définitions les plus contraignantes retournaient très peu de résultats, du fait qu'elles utilisent des verbes alors que les titres sont essentiellement averbaux, et au problème que la CS-VII en retournait trop.

Nous avons donc décidé d'utiliser la fouille de données séquentielles pour mettre à jour des schémas d'utilisation récurrents des têtes transdisciplinaires. Nous avons trouvé deux schémas qui se rapprochent de la CS-VII en la situant au début du titre ou après une marque de segmentation. En la restreignant ainsi, nous pouvons plus facilement déterminer un ensemble de têtes transdisciplinaires potentiellement dans un emploi sous-employé. Nous appliquons également la restriction que le nom noyau du contenu spécifiant dans la CS-VII doit désigner une action. Nous les comparons avec la base VerbAction pour déterminer cela.

Si nos schémas détectent bien des emplois sous-spécifiés de têtes transdisciplinaires, nous avons constaté également que nos schémas ne sont pas suffisants pour déterminer la sous-spécification d'une tête. Nous devons recourir à la fin à notre jugement pour interpréter la sémantique des résultats retournés. Nos schémas sont donc seulement des sélectionneurs de têtes candidates à un emploi sous-spécifié. Nous avons déjà constaté que le nombre de candidates monte à 25 % chez les têtes transdisciplinaires contre 9 % chez les têtes non transdisciplinaires.

Nous avons aussi constaté que les candidatures à la sous-spécification ne sont pas équitablement réparties entre les domaines.

Nous pouvons résumer nos découvertes d'emplois sous-spécifiés des têtes transdisciplinaires ou des candidatures pour un tel emploi dans le tableau (17).

Construction spécifique	Nombre de têtes intégrant une construction spécifique
CS-I NSS + être + que	3
CS-II NSS + être + de + inf	1
C-III NSS + , + ce + être + que	0
C-IV NSS + , + ce être + de + inf	0
C-V NSS + que	0
CS-VI NSS + de + inf	estimé à 437
CS-VII NSS + de + nom d'action	nombre de candidates : 23 497
CS-VIII NSS + être + nom d'action	1
CS-IX NSS + , + ce + être + nom d'action	1
Total	23 940 soit près de 9 % des 278 185 têtes nominales

Tableau 18: Présence des constructions spécifiques classiques dans notre corpus

III. Discussion sur nos résultats : limites et perspectives

Dans cette dernière partie nous revenons sur notre travail et nos résultats pour les mettre en perspective. Il s'agit de montrer leurs limites et éventuellement les perspectives d'améliorations pour nous en affranchir.

III.1 Limites de notre travail

III.1.1 Limite de l'analyse en dépendances automatique de Talismane

Si de prime abord Talismane a donné une très bonne satisfaction pour étiqueter morphosyntaxiquement les titres, il n'en est pas de même pour les relations en dépendance, notamment celles reposant sur la préposition *de* que Talismane relie souvent au mauvais recteur. Cela a peuplé nos résultats de nombreux faux positifs lors de recherches de schéma en mode flexible. Par exemple, l'énoncé A de B de C, se voit souvent attribué un arbre de dépendance où le second *de* a le même recteur que le premier, A, alors qu'il s'agit le plus souvent de B. Ce cas peut-être très ambigu en français. Voici un exemple : *Un indicateur de politique d'ouverture à l'immigration*

Le premier *de* est régi par *indicateur*. Mais le second, *d'*, devrait être régi par *politique*, or Talismane lui attribue comme recteur *indicateur*, de même pour le *à* qui suit.

Des problèmes de liens de dépendances ayant une portée encore plus grande et fausse ont également été observés mais non quantifiés.

Nous avons essayé de corriger certaines relations de dépendance en analysant les mots qui séparaient un recteur de son dépendant, par exemple de détecter B dans l'exemple précédent, et de réassigner la dépendance, mais il n'y a pas d'automatisme certaine.

Cela nous laisse penser qu'on ne peut s'appuyer autant que nous le pensions initialement sur l'analyse en dépendances. L'utilisation d'un outil doit toujours être précautionneuse et le chercheur doit savoir s'en détacher. Réaliser un post-traitement de correction des résultats en sortie, comme nous l'avons fait, permet d'exploiter au mieux les puissants outils à notre disposition.

La segmentation rencontre un problème avec la virgule, à la fois signe pour une énumération, mais parfois également utilisée comme segmentateur. Nous ne lui avons pas reconnu ce rôle, ce qui fait que certains titres à segments à deux têtes sont écartés. Une étude plus approfondie du caractère segmentant de la virgule dans les titres serait intéressante.

III.1.2 Limitations des têtes spécifiques aux domaines

Pour la question de la variation des têtes par rapport au domaine, nous avons finalement opté pour l'attribution d'une pondération à chaque tête. Nous sommes libres de choisir dans un deuxième temps un seuil minimum, un nombre minimum ou un pourcentage de têtes pour passer à une appréciation binaire du fait qu'il s'agit d'une tête spécifique ou non. Il manque surtout un moyen d'évaluer la pertinence des têtes.

De plus, on peut s'étonner du manque de certains noms propres dans certains domaines comme Claude Lévi-Strauss en anthropologie, au profit de François Cadic, folkloriste breton bien moins connu. Nous sommes toujours « prisonniers » de notre corpus mais ce résultat demanderait investigation.

III.1.3 Limitations des têtes transdisciplinaires

La sélection des têtes transdisciplinaires sur un simple seuil de médiane, représentant le fait que la tête doit avoir dans au moins la moitié des domaines une fréquence supérieure à ce seuil est empirique. La définition d'une classe nominale par la statistique ou la structure syntaxique se prête très bien à l'automatisation. Néanmoins, il ne nous semble pas aussi simple de sélectionner automatiquement des noms sur des critères sémantiques, lorsqu'il s'agit d'aller plus loin que l'appartenance à une liste.

III.1.4 Opérationnalisation des NSS

L'opérationnalisation des NSS est ardue, surtout dans une perspective de traitement automatique des langues. L'idée de Huyghe (2018) de se retravailler au concept de nom porteur, noms capables de porter un contenu prépositionnel qui correspond aux constructions CS-I et CS-II, présente l'avantage de réduire considérablement le périmètre d'investigation pour pouvoir l'analyser plus profondément, comme il le fait pour *fait* dans son article.

Avec les constructions les moins contraintes, le bruit augmente considérablement. L'obligation d'un nom dénotant une action ou une activité permet de les restreindre. Néanmoins une telle liste de noms n'est jamais complète, puisqu'il s'agit d'une classe ouverte également. Enfin, l'appartenance à cette liste ne garantit pas qu'il s'agit d'un emploi sous-spécifié : le jugement final reste pour l'instant d'ordre sémantique et fait par l'humain et non automatisable.

Nous avons laissé de côté encore d'autres constructions spécificationnelles, faute de temps. Notamment Nakamura (2017) a commencé à développer des constructions attributives avec le verbe avoir : « Il a pour **objectif de rédiger une loi** » / « Il a pour **objectif la rédaction d'une loi** » / « Il a pour objectif qu'une loi soit rédigée ». Roze et al. (2016) ont également mis au jour de nouvelles constructions spécificationnelles dont une est celle proposée par Nakamura avec *pour*. Nous aurions pu également les chercher dans notre corpus de titres.

III.1.5 Manque d'un corpus de contraste

Il aurait été avantageux de disposer d'un corpus de contraste, de textes scientifiques par exemple, pour essayer d'analyser comment se comportent les têtes et les noms en emploi sous-spécifiés dans ces textes par rapport à nos titres.

III.1.6 Disponibilité des listes de NSS et des lexiques scientifiques

Une grande difficulté a été de mettre la main sur des listes numériques des différentes acceptations des NSS et des lexiques scientifiques. Pour les NSS, elles peuvent servir seulement d'indices, car les NSS sont un emploi et non une classe lexicale a priori, bien qu'il existe des propriétés lexicales indiquant une capacité à pouvoir être employé comme NSS. Certains articles pointaient sur un

site web qui n'était plus en ligne, d'autres ne prenaient même pas cette peine, et d'autres proposaient seulement un format PDF.

Pour la linguistique de corpus, la mise à disposition pérenne des listes produites par les calculs est parfois aussi importante que l'article lui-même, si la répétition de ces calculs n'est pas triviale. La capacité de stocker un article avec des pièces-jointes, parfois volumineuses, nous semble importante, notamment pour les archives ouvertes. L'ensemble de nos données et de notre code est de notre côté disponible sur la plate-forme GitHub, à l'URL : <https://github.com/Xitog/tal/tree/master/master2>

III.2 Perspectives

III.2.1 Utilisation de la typologie de Schmid

Schmid définit une typologie des NSS (2000, p. 88) selon leurs caractéristiques sémantiques. Il définit six classes, *factual*, *mental*, *linguistic*, *modal*, *eventive*. Chaque classe est divisée en plusieurs sous-classes selon leurs utilisations, ainsi la classe *factual* se divise-t-elle en *Neutral*, *Causal*, *Evidential*, *Comparative*, *Partitive*, *Attitudinal* (Schmid, 2000, p. 92). Nous pourrions étudier la classification des têtes transdisciplinaires employées de façon sous-spécifiée, pour essayer de déterminer si une classe est plus présente que les autres ou comment les classes se répartissaient entre les différents domaines.

III.2.2 Étude de la relation entre tête transdisciplinaire et éléments de contexte

Nous avons remarqué que les têtes transdisciplinaires étaient fréquemment cooccurentes avec les prépositions *à*, *de*, *sur*. Il est envisageable d'étudier l'affinité des différentes têtes pour ces prépositions. Ainsi, *problème* semble incompatible avec *sur* dans notre corpus. Mais nous pouvons étendre cette étude à d'autres éléments du contexte pour déterminer des constructions spécificationnelles propres à certaines têtes. Nakamura (2017) a ainsi mis en avant *avoir pour objectif de*, avec *objectif* en emploi sous-spécifié. Nous avons de notre côté recensé plusieurs utilisations de *le problème posé par* qui mériteraient d'être investiguées.

III.2.3 Extension aux noms coordonnés à la tête ou au nom commun

Cette perspective regroupe deux cas. Le premier (57) est que le nom commun désignant une action est coordonné à une autre locution nominale, *mise en réseau*. Le second (58), repose sur le fait que la tête transdisciplinaire peut être coordonnée à un autre nom, qui lui aussi pourrait être sous-spécifié.

(57) **Effets de la numérisation** et de la mise en réseau sur le concept de document

(58) **Résultats et bilan** critique d'une recherche partenariale pour la construction d'un système d'information de gestion du développement durable des collectivités rurales au Québec

L'étude de la combinaison de la coordination avec la tête pourrait amener à avoir des exemples de double catégorisation d'un concept temporairement formé : dans (58), ce concept regroupe à la fois des résultats et un bilan d'une recherche.

L'étude de la combinaison de la coordination du nom commun pourrait amener à construire des concepts plus complexes, comme dans (57), ou l'on regarde les effets de numériser et de mettre en réseau sur le concept de document.

Conclusion

Nous sommes reparti du travail effectué pour notre mémoire de Master 1. L'identification de schémas récurrents après le double point dans les titres de publications scientifiques avait permis de mettre en avant une classe de noms communs abstraits, très fréquents et pluridisciplinaires. Ces caractéristiques se rapprochent d'un type d'emploi des noms, les noms sous-spécifiés. Nous avons voulu savoir si des noms étaient employés de cette façon dans les titres. Nous avons pris comme hypothèse que les têtes des segments des titres étaient les noms les plus propices à être employés de façon sous-spécifiée.

Nous avons, dans un premier temps, constitué un corpus de travail au sein du matériau initial qui compte près de 340 000 titres tirés de HAL, fournis par Tanguy et Rebeyrolle (à paraître). Puis, nous avons utilisé la lemmatisation, la catégorisation morphosyntaxique et l'analyse en dépendances syntaxiques fournies par l'outil Talismane (Urieli, 2013). Enfin, nous avons sélectionné les titres monosegmentaux ou bisegmentaux avec pour chacun une tête par segment, dont au moins une de nature nominale. Lorsque Talismane trouvait un segment à deux têtes, nous avons écarté le titre. Lorsque Talismane trouvait un segment sans tête dans un titre à deux segments, nous avons essayé d'en trouver une en promouvant un mot qui serait régi uniquement par un mot de l'autre segment disposant déjà d'une tête. Nous avons pu conformer à notre règle « un segment une tête » près de 98 % des 56 851 titres auxquels il manquait une tête. Pour finir, nous avons constitué un corpus de travail de 250 998 titres, gardant près de 74 % du matériau initial.

Après avoir constitué notre corpus de travail et identifié toutes les têtes, nous nous sommes d'abord interrogé sur le nombre de segments des titres en fonction du domaine. Il apparaît que les sciences humaines utilisent dans les mêmes proportions titres monosegmentaux et titres bisegmentaux, tandis que les sciences exactes privilégient les titres monosegmentaux. Nous nous sommes interrogés sur la nature grammaticale des titres. Il s'est avéré que l'extrême majorité des têtes étaient des noms conférant ainsi une nature nominale aux titres : 86 % dans le cas des titres monosegmentaux. Dans le cas des titres bisegmentaux, cette majorité est très claire si on ne regarde que le premier segment, 84 %. Si on ne considère comme nominal que les titres bisegmentaux dont les deux têtes sont des noms, cette proportion tombe à 68 %. Nous pouvons donc conclure que les titres sont essentiellement des syntagmes nominaux.

Partant de cette constatation, nous avons voulu savoir s'il existait des têtes nominales spécifiques à certains domaines. Utilisant la valeur de TF*IDF, en considérant les domaines comme un document unique et leurs titres comme autant de phrases de ce document, nous avons pondéré chaque tête par un indice de spécificité. Les têtes sélectionnées sont des noms pleins, qui révèlent les objets d'étude des différents domaines.

Nous avons également recherché les têtes transdisciplinaires, fréquentes dans tous les domaines. Nous avons identifié 94 têtes transdisciplinaires dans le corpus général, 74 sont présentes dans le lexique transdisciplinaire des écrits scientifiques (Tutin, 2008), soit 79 %, et 82 sont présentes dans le lexique scientifique transdisciplinaire (Hatier, 2016), soit 87 %.

Nous avons ensuite essayé de rapprocher les têtes transdisciplinaires, dont la fréquence et la transdisciplinarité impliquent un faible contenu sémantique, des noms sous-spécifiés qui se caractérisent par une très grande fréquence et un faible contenu sémantique également. Après avoir défini notre perception des noms sous-spécifiés, nous avons vu que leur définition opératoire est structurelle : les noms sous-spécifiés s'insèrent dans des constructions spécificationnelles dont la fonction est de lier le nom général sous-spécifié à un contenu présent dans son contexte et qui va le « remplir ».

Nous nous sommes heurté d'un côté à l'absence dans notre corpus de constructions spécificationnelles facilement identifiables, estimées à moins de 500 occurrences, et de l'autre à une structure pas assez sélective malgré la mise en évidence de la nécessité que le contenu spécifiant soit lié à une action ou une activité, soit par le truchement d'un verbe conjugué s'il s'agit d'une proposition subordonnée conjonctive, soit par le truchement d'un verbe à l'infinitif s'il s'agit d'une proposition infinitive, soit, s'il s'agit d'un syntagme nominal pouvant être inclus dans un syntagme prépositionnelle, que le noyau nominal soit un nom dénotant une action ou une activité.

Faute de construction spécificationnelle classique, nous avons donc étudié les schémas récurrents dans lesquels s'insèrent nos têtes transdisciplinaires en utilisant la fouille de données pour les trouver. Nous avons pu établir deux schémas qui sont situés en début de segment et averbaux, ce qui est en accord avec les spécificités des titres. Ces deux schémas détectés se rapprochent d'une construction spécificationnelle, la CS-VII, qui est la moins contraignante des CS étudiées. Les schémas ajoutent comme contrainte que le schéma doit se trouver en début de titre ou de segment et acceptent également d'autres prépositions en plus du *de* de la CS-VII. Nous avons ensuite voulu étudier si, outre la correspondance syntaxique entre les deux schémas récurrents détectés et la CS-VII, il y avait effectivement un emploi sous-spécifié des têtes transdisciplinaires.

Nous avons rencontré des problèmes pour estimer l'utilisation en emploi sous-spécifié. La détermination de l'emploi repose moins, dans la configuration de la CS-VII, sur des critères syntaxiques que sur des critères lexicaux et sémantiques. Pour le lexical, nous avons utilisé VerbAction pour obtenir une liste de noms qui désignent des actions. Même si elle n'est pas complète, car il s'agit d'une classe ouverte, nous nous heurtons au problème que l'appartenance à cette liste ne garantit pas l'emploi sous-spécifié : le critère de jugement est à la fin sémantique. Nos schémas sont donc un estimateur grossier, qui demanderait à être affiné. Nous avons néanmoins fourni une liste des têtes transdisciplinaires candidates avec le nombre d'occurrences dans nos résultats.

Nous avons enfin étudié la répartition des schémas récurrents parmi les différents domaines, en constatant que certains domaines pouvaient avoir près d'un tiers de leurs têtes transdisciplinaires candidates à un emploi sous-spécifié.

Notre travail a permis de déterminer plusieurs caractéristiques des emplois sous-spécifiés dans les titres. Ils délaissent les constructions spécificationnelles avec une proposition conjonctive ou infinitive. Ils occurrent essentiellement sur des têtes de segments transdisciplinaires, qui sont généralement le premier nom d'un segment, avec un contenu spécifiant de la forme d'un syntagme prépositionnel commençant par *à*, *de* ou *sur*, incluant un syntagme nominal dont le nom désigne une action.

Bibliographie

- Adler, S. et Moline, E. (2018). Les noms généraux: présentation. *Langue française*, 2018(2), 5-18.
- Aktas, R. N. et Cortes, V. (2008). Shell nouns as cohesive devices in published and ESL student writing. *Journal of English for Academic Purposes*, 7(1), 3-14.
- Aleixandre-Benavent, R., Montalt-Resurecció, V. et Valderrama-Zurián, J. (2014). A descriptive study of inaccuracy in article titles on bibliometrics published in biomedical journals. *Scientometrics*, 101(1), 781-791.
- Anthony, L. (2001). Characteristic features of research article titles in computer science. *IEEE Transactions on Professional Communication*, 44(3), 187-194.
- Ball, R. (2009). Scholarly communication in transition: The use of question marks in the titles of scientific articles in medicine, life sciences and physics 1966–2005. *Scientometrics*, 79(3), 667-679.
- Baethge, C. (2008). Publish together or perish: the increasing number of authors per article in academic journals is the consequence of a changing scientific culture. *Deutsches Arzteblatt international*, 105(20), 380-383.
- Benítez-Castro, M. Á. (2014). *Formal, syntactic, semantic and textual features of English shell nouns*. Thèse de doctorat, Universidad de Granada.
- Biber, D., Conrad, S. et Reppen, R. (1998). *Corpus linguistics: Investigating language structure and use*. Cambridge : Cambridge University Press.
- Biber, D. et Gray, B. (2010). Challenging stereotypes about academic writing: Complexity, elaboration, explicitness. *Journal of English for Academic Purposes*, 9(1), 2-20.
- Cheng, S. W., Kuo, C. W. et Kuo, C. H. (2012). Research article titles in applied linguistics. *Journal of Academic Language and Learning*, 6(1), A1-A14.
- Cori, M. et David, S. (2008). Les corpus fondent-ils une nouvelle linguistique ? *Langages*, 171, 111-129.
- Delhay, C. (2014). Pour un «complément-attribut». *Repères. Recherches en didactique du français langue maternelle*, (49), 57-76.
- Diers, D. et Downs, F. S. (1994). Colonizing: a measurement of the development of a profession. *Nursing research*, 43(5), 316.
- Dillon, J. T. (1981). The emergence of the colon: an empirical correlate of scholarship. *American Psychologist*, 36, 879-884.
- Dillon, J. T. (1982). In Pursuit of the Colon, A Century of Scholarly Progress: 1880–1980. *The Journal of Higher Education*, 53(1).
- Flowerdew, J. (2003). Signalling nouns in discourse. *English for specific purposes*, 22(4), 329-346.
- Flowerdew, J. (2006). Use of signalling nouns in a learner corpus. *International Journal of Corpus Linguistics*, 11(3), 345-362.

- Flowerdew, J. & Forest, R. W. (2015). *Signalling nouns in English*. Cambridge University Press.
- Francis, G. (1986). *Anaphoric nouns*. English Language Research, Department of English, University of Birmingham.
- Francis, G. (1994). Labelling discourse: an aspect of nominal-group lexical cohesion. In Coulthard, M. ed, (1994), *Advances in written text analysis*, London: Routledge, 83-101.
- François, J. et Legallois, D. (2006). Autour des grammaires de constructions et de patterns. *Cahiers du CRISCO*. Université de Caen.
- Goodman, R. A., Thacker, S. B. et Siegel, P. Z. (2001). What's in a title? A descriptive study of article titles in peer-reviewed medical journals. *Science*, 24(3), 75-78.
- Grant, M. J. (2013). What makes a good title? *Health Information & Libraries Journal*, 30(4), 259-260.
- Gustavii, B. (2017). *How to write and illustrate a scientific paper*. Cambridge University Press.
- Haggan, M. (2004). Research paper titles in literature, linguistics and science: dimensions of attraction. *Journal of Pragmatics*, 36(2), 293-317.
- Halliday, M. A. K. et Hasan, R. (1976). *Cohesion in English*. London: Longman.
- Hartley, J. (2005). To attract or to inform: What are titles for? *Journal of technical writing and communication*, 35(2), 203-213.
- Hatier, S. (2016). *Identification et analyse linguistique du lexique scientifique transdisciplinaire*. Approche fouillée sur corpus d'article de recherche en SHS, Thèse de doctorat, Université Grenoble Alpes.
- Hatier, S., Augustyn, M., Tran, T. T. H., Yan, R., Tutin, A. & Jacques, M. P. (2016). French cross-disciplinary scientific lexicon: extraction and linguistic analysis. In *Proceedings of Euralex*, 355-366.
- Ho-Dac, L.-M., Jacques, M.-P. & Rebeyrolle, J. (2004). Sur la fonction discursive des titres. Dans S. Porhiel et D. Klingler (éds). *L'unité texte*, Pleyben, Perspectives, 125-152.
- Hunston, S. & Francis, G. (1999). *Pattern Grammar. A Corpus-driven Approach to the Lexical Grammar of English*. Amsterdam: Benjamins (Studies in Corpus Linguistics 4).
- Huot, H. (1981). *Constructions infinitives du français: le subordonnant de* (Vol. 12). Genève : Librairie Droz.
- Huyghe, R. (2018). Généralité sémantique et portage propositionnel: le cas de fait. *Langue française*, 2018(2), 35-50.
- Ivanic, R. (1991). Nouns in search of a context: A study of nouns with both open- and closed-system characteristics. *International Review of Applied Linguistics in Language Teaching*, 2, 93-114.
- Jacques, T. S. et Sebire, N. J. (2010). The impact of article titles on citation hits: an analysis of general and specialist medical journals. *Journal of the Royal Society of Medicine Short Reports*, 1(1), 1-5.
- Jalilifar, A., Hayati, A. et Mayahi, N. (2010). An exploration of generic tendencies in Applied Linguistics titles. *Journal of Faculty of Letters and Humanities*, 5(16), 35-57.

- Jamali, H. R. et Nikzad, M. (2011). Article title type and its relation with the number of downloads and citations. *Scientometrics*, 88(2), 653-661.
- Kalmbach, J.-P. (2019). *La grammaire du français langue étrangère pour étudiants finnophones*. Repéré à <http://research.jyu.fi/grfle/675.html>
- Kolhatkar, V., & Hirst, G. (2014). Resolving shell nouns. Dans *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 499-510.
- Kutch, T. D. C. (1978). Relation of title length to numbers of authors in journal articles. *Journal of the American Society of Information Science*, 19(4), 200-202.
- Larivière, V., Gingras, Y., Sugimoto, C. R. and Tsou, A. (2015). Team size matters: Collaboration and scientific impact since 1900. *Journal of the Association for Information Science and Technology*, 66(7), 1323-1332.
- Leech, G. N. (2000). Grammars of spoken English: New outcomes of corpus-oriented research. *Language Learning*, 50(4), 675-724.
- Legallois, D. (2006). Quand le texte signale sa structure : la fonction textuelle des noms sous-spécifiés. *Corela HS-5* : <http://corela.edel.univ-poitiers.fr/index.php?id=1465>
- Legallois, D. (2008). Sur quelques caractéristiques des noms sous-spécifiés. *Scolia*, 23, 109-127.
- Legallois, D., & Gréa, P. (2006). L'objectif de cet article est de... Construction spécifique et grammaire phraséologique. *Cahiers de praxématique*, (46), 161-186.
- Lyons, J. (1977). *Semantics (Vol. 2)*. Cambridge: Cambridge university press.
- Mabe, M. A. et Amin, M. (2002). Dr. Jekyll and Dr. Hyde: Author-reader asymmetries in scholarly publishing. *Aslib Proceedings*, 54(3), 149-157.
- Merrill, E. et Knipps, A. (2014). What's in a Title?. *The Journal of Wildlife Management*, 78(5), 761-762.
- Mounin, G. (dir.) (2004). *Dictionnaire de la linguistique*. Paris : PUF (Quadrige).
- Mousavi, A. et Moini, M. R. (2014). A corpus study of shell nouns in published research articles of education. *Procedia-Social and Behavioral Sciences*, 98, 1282-1289.
- Nagano, R. L. (2015). Research article titles and disciplinary conventions: A corpus study of eight disciplines. *Journal of Academic Writing*, 5(1), 133-144.
- Nakamura, T. (2017). Extensions transitives de constructions spécifiques. *Langue française*, 2017 (2), 69-84.
- Nivard, J. (2010). Les Archives ouvertes de l'EHESS. Récupéré sur *La Lettre de l'École des hautes études en sciences sociales n°34*: <http://lettre.ehess.fr/index.php?5883>
- Paiva, C. E., da Silveira Nogueira Lima, J. P. et Ribeiro Paiva, B. S. (2012). Articles with short titles describing the results are cited more often. *Clinics*, 67(5), 509-513.

- Quiniou, S., Cellier, P., Charnois, T. et Legallois, D. (2012). Fouille de données pour la stylistique: cas des motifs séquentiels émergents. Dans *Journées Internationales d'Analyse Statistique des Données Textuelles (JADT'12)*, Liège, 821-833.
- Rebeyrolle, J., Jacques, M. et Péry-Woodley, M. (2009). Titres et intertitres dans l'organisation du discours. *Journal of French Language Studies*, 19, 269-290.
- Riegel, M. (2006). Grammaire des constructions attributives : avec ou sans copule. Dans *Construction, acquisition et communication : Études linguistiques de discours contemporains*, Engwall, G. (éd.). Stockholm : Université de Stockholm (Acta Universitatis Stockholmiensis Romanica Stockholmiensia 23).
- Roze, C., Charnois, T., Legallois, D., Ferrari, S. et Salles, M. (2014). Identification des noms sous-spécifiés, signaux de l'organisation discursive. Dans *Proceedings of TALN 2014*, 1, 377-388.
- Sagi, I., & Yechiam, E. (2008). Amusing titles in scientific journals and article citation. *Journal of Information Science*, 34(5), 680-687.
- Salager-Meyer, F. & Alcaraz Ariza, M. Á. (2013). Titles are "serious stuff": a historical study of academic titles. *Jahr*, 4(7), 257-271.
- Schmid, H.-J. (2000). *English Abstract Nouns as Conceptual Shells. From Corpus to Cognition*. Berlin: Mouton de Gruyter (Topics in English Linguistics 34).
- Schmid, H. J. (2018). Shell nouns in English-a personal roundup. *Caplletra. Revista Internacional de Filologia*, (64), 109-128.
- Schwischay, B. (2001). Notes d'exposés sur deux modèles de description syntaxique [Document PDF]. Repéré à <http://www.home.uni-osnabrueck.de/bschwisc/archives/deuxmodeles.pdf>
- Soler, V. (2007). Writing titles in science: An exploratory study. *English for Specific Purposes*, 26, 90–102.
- Soler, V. (2011). Comparative and contrastive observations on scientific titles written in English and Spanish. *English for Specific Purposes*, 30(2), 124-137.
- Subotic, S. & Mukherjee, B. (2014). Short and amusing: The relationship between title characteristics, downloads, and citations in psychology articles. *Journal of Information Science*, 40(1), 115-124.
- Swales, J. M. et Feak, C. B. (1994). *Academic Writing for Graduate Students*. Ann Arbor: University of Michigan Press.
- Tadros, A. (1994). Predictive categories in expository text. In Coulthard, M. ed, (1994), *Advances in written text analysis*, London: Routledge, 83-96.
- Tanguy, L. et Hathout, N. (2002). Webaffix : un outil d'acquisition morphologique dérivationnelle à partir du Web. Dans *Actes de la 9e Conférence Annuelle sur le Traitement Automatique des Langues Naturelles (TALN-2002)*. Nancy : ATALA.
- Tanguy, L., Rebeyrolle, J. (à paraître). Les titres des publications scientifiques en français : fouille de texte pour le repérage de schémas lexico-syntaxiques.
- Townsend, M. A. (1983). Titular Colonicity and Scholarship: New Zealand Research and Scholarly Impact. *New Zealand Journal of Psychology*, 12, 41-43.

- Tutin, A. (2007). Autour du lexique et de la phraséologie des écrits scientifiques. *Revue Française de Linguistique Appliquée*, 12(2), 5-14.
- Tutin, A. (2008). Sémantique lexicale et corpus : l'étude du lexique transdisciplinaire des écrits scientifiques. *Lublin studies in modern languages and literature*, 32, 242-260.
- Urieli, A. (2013). *Robust French syntax analysis: reconciling statistical methods and linguistic knowledge in the Talismane toolkit*. Toulouse: Doctoral dissertation, Université de Toulouse II-Le Mirail.
- Urieli, A. et Tanguy, L. (2013). L'apport du faisceau dans l'analyse syntaxique en dépendances par transitions : études de cas avec l'analyseur Talismane. *Actes de TALN*, Sables D'Olonne.
- Wang, Y. et Bai, Y. (2007). A corpus-based syntactic study of medical research article titles. *System*, 35(3), 388-399.
- Williams, G. (2005). *La linguistique de corpus*. Rennes : Presses universitaires de Rennes.
- Winter, E. O. (1977). A clause-relational approach to English texts: a study of some predictive lexical items in written discourse. *Instructional science*, 6(1), 1-92.
- Winter, E. O. (1992). The notion of unspecific versus specific as one way of analysing the information of a fund-raising letter. *Discourse description: Diverse linguistic analyses of a fund-raising text*, 131-170.
- Whissell, C. (2012). The trend toward more attractive and informative titles: *American Psychologist* 1946-2010. *Psychological reports*, 110(2), 427-444.
- Yakhontova, T. (2002). Titles of conference presentation abstracts: A cross-cultural perspective. Dans E. Ventola, C. Shalom et S. Thompson (éds.), *The language of conferencing*, 277-300. Francfort-sur-le-Main : Peter Lang.
- Yitzhaki, M. (1994). Relation of title length of journal articles to number of authors. *Scientometrics*, 30(1), 321-332.
- Yitzhaki, M. (2002). Relation of the title length of a journal article to the length of the article. *Scientometrics*, 54(3), 435-447.

Annexes

A1. Distance des domaines de par leurs têtes spécifiques

Distances	0.math	1.sht.infocom	1.sht.droit	1.sht.ling	1.sht.gestion	0.phys	1.sht.hist	0.se	1.sht.phil	0.sdv	1.sht.archi	0.info	1.sht.edu	1.sht.litt	0.scco	1.sht.socio	1.sht.geo	1.sht.art	0.chim	0.sdv	1.sht.art	1.sht.py	1.sht.scpo	0.qfin
0.math	0.00000	0.00751	0.00631	0.01926	0.01727	0.01780	0.01947	0.00613	0.01976	0.01829	0.01121	0.01764	0.01890	0.02048	0.01943	0.01748	0.02171	0.02263	0.01056	0.01892	0.01056	0.01892	0.01892	0.02592
1.sht.infocom	0.00751	0.00000	0.01451	0.01257	0.00947	0.01275	0.01232	0.01073	0.01479	0.01369	0.01131	0.01303	0.01037	0.01357	0.01305	0.00523	0.01614	0.01607	0.01548	0.01607	0.01607	0.01607	0.01607	0.02080
1.sht.droit	0.00631	0.01451	0.00000	0.01545	0.02442	0.01538	0.01359	0.01629	0.01582	0.01414	0.01344	0.01478	0.01385	0.01616	0.01578	0.01640	0.01823	0.01806	0.01852	0.01852	0.01852	0.01852	0.01852	0.02380
1.sht.ling	0.01926	0.01257	0.01545	0.00000	0.01441	0.01362	0.01347	0.01204	0.01569	0.01461	0.01315	0.01618	0.01504	0.01452	0.01381	0.01580	0.01734	0.01760	0.01740	0.01740	0.01740	0.01740	0.01740	0.02156
1.sht.gestion	0.01727	0.00947	0.02442	0.01441	0.00000	0.01176	0.01180	0.00929	0.01327	0.01249	0.00946	0.01198	0.00932	0.01237	0.01170	0.00716	0.01265	0.01265	0.01265	0.01265	0.01265	0.01265	0.01265	0.01961
0.phys	0.01780	0.01275	0.01538	0.01362	0.01176	0.00000	0.01340	0.01237	0.01496	0.01610	0.01176	0.01555	0.01480	0.01375	0.01385	0.00871	0.01479	0.01479	0.01479	0.01479	0.01479	0.01479	0.01479	0.02194
1.sht.art	0.02263	0.01056	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.02148
1.sht.py	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.02007
1.sht.scpo	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.02624
0.se	0.00613	0.01947	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.01629	0.02464
1.sht.phil	0.01976	0.01369	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.01461	0.02246
0.sdv	0.01829	0.01121	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.01344	0.02092
1.sht.archi	0.02132	0.01056	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.02091
0.info	0.01764	0.01304	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.01545	0.02172
1.sht.edu	0.01890	0.01037	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.02058
1.sht.litt	0.02048	0.01943	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.01748	0.02291
0.scco	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.01943	0.02161
1.sht.socio	0.01748	0.01056	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01963
1.sht.geo	0.02171	0.01056	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.02613
1.sht.art	0.02263	0.01056	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.01607	0.02575
0.chim	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.02340
0.sdv	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.02340
1.sht.py	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.01056	0.02376
1.sht.scpo	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.01892	0.02376
0.qfin	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592	0.02592

A2. Combinaisons des têtes de titres bisegmentaux

Ce tableau liste toutes les combinaisons possibles des têtes de titres bisegmentaux en termes de catégories morphosyntaxiques et en agrégeant les catégories nominales, propositionnelles et verbales en une seule à chaque fois, respectivement NOUN, PREP et VERB. La requête pour obtenir ce tableau est donné en première ligne, ainsi que le nombre de titres sur lesquels la requête a été lancée : ici l'ensemble des titres bisegmentaux de notre corpus de travail.

```
*** ['roots.0.pos:agg', 'roots.1.pos:agg'] *** (110785)
```

01.	NOUN-NOUN	75592	68.2331 %	68.23 %
02.	NOUN-PREP	8996	8.1202 %	76.35 %
03.	VERB-NOUN	8506	7.6779 %	84.03 %
04.	NOUN-VERB	5426	4.8978 %	88.93 %
05.	PREP-NOUN	4650	4.1973 %	93.13 %
06.	NOUN-CC	1209	1.0913 %	94.22 %
07.	VERB-PREP	1015	0.9162 %	95.13 %
08.	NOUN-ADJ	1000	0.9026 %	96.04 %
09.	VERB-VERB	661	0.5967 %	96.63 %
10.	ADJ-NOUN	537	0.4847 %	97.12 %
11.	NOUN-PONCT	395	0.3565 %	97.47 %
12.	NOUN-CS	368	0.3322 %	97.81 %
13.	PREP-VERB	333	0.3006 %	98.11 %
14.	PREP-PREP	310	0.2798 %	98.39 %
15.	CS-NOUN	270	0.2437 %	98.63 %
16.	VERB-PONCT	145	0.1309 %	98.76 %
17.	VERB-CC	140	0.1264 %	98.89 %
18.	NOUN-PRO	133	0.1201 %	99.01 %
19.	NOUN-ADV	105	0.0948 %	99.10 %
20.	VERB-ADJ	91	0.0821 %	99.18 %
21.	ADJ-PREP	82	0.0740 %	99.26 %
22.	PREP-CC	64	0.0578 %	99.32 %
23.	PRO-NOUN	63	0.0569 %	99.37 %
24.	ADJ-VERB	59	0.0533 %	99.43 %
25.	VERB-CS	50	0.0451 %	99.47 %
26.	NOUN-DET	42	0.0379 %	99.51 %
27.	PREP-ADJ	38	0.0343 %	99.54 %
28.	CS-PREP	37	0.0334 %	99.58 %
29.	PREP-CS	30	0.0271 %	99.60 %
30.	CS-VERB	27	0.0244 %	99.63 %
31.	CC-NOUN	27	0.0244 %	99.65 %
32.	NOUN-I	27	0.0244 %	99.68 %
33.	VERB-ADV	24	0.0217 %	99.70 %
34.	PREP-PONCT	23	0.0208 %	99.72 %
35.	ADV-VERB	20	0.0181 %	99.74 %
36.	NOUN-ADVWH	18	0.0162 %	99.75 %
37.	PONCT-NOUN	15	0.0135 %	99.77 %
38.	NOUN-ET	14	0.0126 %	99.78 %
39.	ADJ-CC	14	0.0126 %	99.79 %
40.	ADV-NOUN	14	0.0126 %	99.81 %
41.	NOUN-CLO	14	0.0126 %	99.82 %
42.	DET-NOUN	13	0.0117 %	99.83 %

43.	ET-NOUN	13	0.0117 %	99.84 %
44.	PRO-VERB	13	0.0117 %	99.85 %
45.	VERB-ADVWH	13	0.0117 %	99.87 %
46.	VERB-PRO	12	0.0108 %	99.88 %
47.	CLR-NOUN	11	0.0099 %	99.89 %
48.	NOUN-DETH	11	0.0099 %	99.90 %
49.	ADJ-CS	9	0.0081 %	99.90 %
50.	NOUN-PROREL	8	0.0072 %	99.91 %
51.	CS-PONCT	6	0.0054 %	99.92 %
52.	CS-CC	6	0.0054 %	99.92 %
53.	ADJ-ADJ	6	0.0054 %	99.93 %
54.	PRO-PREP	5	0.0045 %	99.93 %
55.	CC-PREP	5	0.0045 %	99.94 %
56.	NOUN-CLS	5	0.0045 %	99.94 %
57.	VERB-DET	5	0.0045 %	99.95 %
58.	CS-ADJ	4	0.0036 %	99.95 %
59.	PONCT-VERB	4	0.0036 %	99.95 %
60.	ADJ-PONCT	3	0.0027 %	99.96 %
61.	PONCT-PREP	2	0.0018 %	99.96 %
62.	VERB-ET	2	0.0018 %	99.96 %
63.	NOUN-CLR	2	0.0018 %	99.96 %
64.	VERB-DETH	2	0.0018 %	99.96 %
65.	PREP-I	2	0.0018 %	99.96 %
66.	ADJ-PRO	2	0.0018 %	99.97 %
67.	VERB-I	2	0.0018 %	99.97 %
68.	VERB-PROREL	2	0.0018 %	99.97 %
69.	I-NOUN	2	0.0018 %	99.97 %
70.	CS-CS	2	0.0018 %	99.97 %
71.	I-VERB	2	0.0018 %	99.98 %
72.	CLO-NOUN	2	0.0018 %	99.98 %
73.	ADVWH-NOUN	2	0.0018 %	99.98 %
74.	CLS-VERB	1	0.0009 %	99.98 %
75.	PONCT-CC	1	0.0009 %	99.98 %
76.	CC-VERB	1	0.0009 %	99.98 %
77.	PRO-PONCT	1	0.0009 %	99.98 %
78.	PRO-CC	1	0.0009 %	99.98 %
79.	PRO-ADJ	1	0.0009 %	99.98 %
80.	PREP-ADV	1	0.0009 %	99.99 %
81.	PREP-CLR	1	0.0009 %	99.99 %
82.	CLR-VERB	1	0.0009 %	99.99 %
83.	ET-PREP	1	0.0009 %	99.99 %
84.	I-PREP	1	0.0009 %	99.99 %
85.	PREP-ET	1	0.0009 %	99.99 %
86.	CC-CLS	1	0.0009 %	99.99 %
87.	DET-PREP	1	0.0009 %	99.99 %
88.	ET-VERB	1	0.0009 %	99.99 %
89.	PREP-DETH	1	0.0009 %	99.99 %
90.	CLS-NOUN	1	0.0009 %	99.99 %
91.	PREP-DET	1	0.0009 %	100.00 %
92.	VERB-PROWH	1	0.0009 %	100.00 %
93.	CC-ADJ	1	0.0009 %	100.00 %
94.	ADVWH-PREP	1	0.0009 %	100.00 %
95.	VERB-CLO	1	0.0009 %	100.00 %
96.	PREP-PRO	1	0.0009 %	100.00 %

A3. Liste des têtes transdisciplinaires

Le tableau suivant présente nos 123 têtes transdisciplinaires si on rassemble toutes les têtes qui correspondent à notre définition de la transdisciplinarité dans les trois sous-corpus et le corpus général de travail. Est indiqué le lemme, la catégorie du discours, si le lemme appartient aux formes du lexique transdisciplinaire des écrits scientifiques (LTES) (Tutin, 2008), au lexique scientifique transdisciplinaire (LST) (Hatier, 2016) et si le lemme appartient à la liste des signalling nouns (Flowerdew et Forest, 2015) avec la fréquence normalisée dans leur corpus. Nous notons que :

- Sur les 94 têtes transdisciplinaires relevées dans le corpus général, 74 sont présentes dans le LTES, soit 79 %, et 82 sont présentes dans le LST, soit 87 %.
- Sur les 123 têtes transdisciplinaires relevées, 86 sont présentes dans le LTES, soit 70 %, et 101 sont présentes dans le LST, soit 82 %.
- Sur les 123 têtes transdisciplinaires relevées, 110 sont également relevées par Flowerdew et Forest comme étant utilisées comme signalling nouns, soit 89 %.

N°	Lemme	Tout le corpus	Titres monosegmentaux	1 ^{er} segment des titres bisegmentaux	2 ^e segment des titres bisegmentaux	Présence dans le LTES / LST	Présence dans signalling nouns
1	activité	1		1		LTES / LST	59
2	an	1			1	LTES	
3	analyse	1	1	1	1	LTES / LST	178
4	application	1	1	1	1	LTES / LST	44
5	apport	1	1	1	1	LTES / LST	16
6	approche	1	1	1	1	LTES / LST	246
7	aspect	1	1		1	LTES / LST	78
8	bilan	1			1	LTES / LST	83
9	cadre	1	1		1	LTES / LST	31
10	cas	1			1	LTES / LST	890
11	changement	1			1	LTES / LST	209
12	comparaison	1	1		1	LTES / LST	44
13	compte			1			18
14	concept	1			1	LTES / LST	143
15	condition				1	LTES / LST	248
16	conséquence	1	1		1	LTES / LST	132
17	construction	1	1	1	1	LTES / LST	2
18	contexte			1	1	LTES / LST	73
19	contribution	1	1		1	LTES / LST	16
20	contrôle		1			LTES	3
21	culture			1			
22	défi	1			1		26
23	définition				1	LTES / LST	68
24	démarche				1	LTES / LST	112

25	développement	1	1	1	1	LTES / LST	39
26	dimension	1				LTES / LST	8
27	discours	1			1	/ LST	51
28	dispositif	1		1	1	LTES / LST	7
29	donnée				1	LTES / LST	44
30	dynamique	1	1	1	1	/ LST	
31	économie			1			
32	effet	1	1	1	1	LTES / LST	393
33	élément	1	1		1	LTES / LST	33
34	émergence	1	1		1	/ LST	
35	enjeu	1	1	1	1	/ LST	
36	enquête	1			1	/ LST	16
37	enseignement	1			1		
38	espace	1	1	1	1	/ LST	
39	essai	1	1		1	/ LST	41
40	état	1	1	1	1	LTES / LST	10
41	étude	1	1	1	1	LTES / LST	18
42	évaluation	1	1	1	1	LTES / LST	10
43	évolution	1	1	1	1	LTES / LST	39
44	exemple	1		1	1	LTES / LST	421
45	expérience	1	1	1	1	LTES / LST	3
46	figure	1	1	1	1	/ LST	88
47	fonction		1			LTES / LST	150
48	formation	1	1	1	1	/ LST	
49	forme	1	1	1	1	LTES / LST	88
50	gestion	1	1	1		LTES	
51	histoire	1	1	1	1		20
52	identité			1		/ LST	3
53	illustration				1	/ LST	33
54	image	1	1	1	1	LTES / LST	5
55	impact	1	1	1	1	/ LST	96
56	influence	1	1	1	1	LTES / LST	44
57	intégration	1	1	1		LTES / LST	
58	interaction	1	1	1	1	LTES / LST	15
59	intérêt	1	1		1	LTES / LST	29
60	introduction	1	1	1	1	LTES / LST	70
61	jeu	1	1	1	1		
62	leçon				1		51
63	lecture	1	1		1	LTES / LST	33
64	limite				1	LTES / LST	10
65	mesure	1	1	1		LTES / LST	46
66	méthode	1	1	1	1	LTES / LST	280
67	méthodologie	1	1		1	/ LST	13

68	mode				1	LTES / LST	11
69	modèle	1	1	1	1	LTES / LST	474
70	modélisation	1	1	1	1	LTES	3
71	mythe				1		2
72	note	1	1	1	1	/ LST	13
73	notion		1			LTES / LST	73
74	objet	1			1	LTES / LST	3
75	organisation	1	1	1		LTES / LST	13
76	outil	1	1	1	1	LTES / LST	7
77	perception	1				LTES / LST	85
78	paradoxe				1	/ LST	11
79	parcours				1		36
80	perspective	1	1		1	LTES / LST	36
81	piste				1		2
82	place	1	1	1	1	LTES	21
83	point	1	1		1	/ LST	393
84	politique	1	1	1	1		2
85	pratique	1	1	1	1	/ LST	73
86	présentation	1	1	1	1	LTES / LST	11
87	principe	1			1	LTES / LST	251
88	problématique				1	/ LST	287
89	problème	1	1		1	LTES / LST	619
90	processus	1	1	1		LTES / LST	230
91	production	1	1	1		LTES / LST	2
92	projet	1	1	1	1	LTES / LST	37
93	proposition	1	1		1	LTES / LST	46
94	question	1	1	1	1	LTES / LST	313
95	rapport	1			1	LTES / LST	10
96	réalité				1	LTES	23
97	recherche	1	1	1	1	LTES / LST	2
98	réflexion	1	1	1	1	LTES / LST	16
99	regard	1	1		1		5
100	relation	1	1	1	1	LTES / LST	93
101	remarque	1	1		1	/ LST	21
102	représentation	1	1	1	1	LTES / LST	11
103	réseau	1	1	1		LTES / LST	7
104	résultat	1			1	LTES / LST	572
105	retour	1	1	1	1		29
106	revue				1		8
107	rôle	1	1	1	1	LTES / LST	153
108	science	1				/ LST	
109	source				1	LTES / LST	10
110	stratégie	1	1	1	1	LTES / LST	205

111	structure	1	1	1	1	LTES / LST	13
112	synthèse				1	LTES / LST	2
113	système	1	1	1	1	LTES / LST	109
114	temps		1			LTES	184
115	théorie	1	1		1	/ LST	494
116	traitement	1	1			LTES / LST	300
117	transformation		1			LTES / LST	2
118	travail	1	1	1		LTES / LST	24
119	usage	1	1	1	1	LTES / LST	73
120	utilisation	1	1	1	1	/ LST	5
121	valeur		1			LTES / LST	13
122	variation	1	1			LTES / LST	15
123	voie				1	LTES / LST	668
	123	94	81	63	99	86 / 101	110 / 123 83 / 94

A4. Étiquettes utilisées par Talismane et HAL

A4.1 Catégories morphosyntaxiques de Talismane

Ces informations sont tirées de <http://jolicieel-informatique.github.io/talismane/#tagset>.

Code	Catégorie morphosyntaxique
ADJ	Adjectif
ADV	Adverbe
ADVWH	Adverbe interrogatif
CC	Conjonction de coordination
CLO	Clitique objet
CLR	Clitique réflexif
CLS	Clitique sujet
CS	Conjonction de subordination
DET	Déterminant
DETH	Déterminant interrogatif
ET	Mot étranger
I	Interjection
NC (que nous rassemblons dans NOUN)	Nom commun
NPP (que nous rassemblons dans NOUN)	Nom propre
P (que nous rassemblons dans PREP)	Préposition
P+D (que nous rassemblons dans PREP)	Préposition et déterminant combinés (“du”)
P+PRO (que nous rassemblons dans PREP)	Préposition et pronom combiné (“duquel”)
PONCT	Ponctuation
PRO	Pronom
PROREL	Pronom relatif
PROWH	Pronom interrogatif

V (que nous rassemblons dans VERB)	Verbe à l'indicatif
VIMP (que nous rassemblons dans VERB)	Verbe à l'impératif
VINF (que nous rassemblons dans VERB)	Verbe à l'infinitif
VPP (que nous rassemblons dans VERB)	Verbe au participe passé
VPR (que nous rassemblons dans VERB)	Verbe au participe présent
VS (que nous rassemblons dans VERB)	Verbe au subjonctif

A4.2 Code des 27 domaines de HAL retenus

Ces informations sont tirées de HAL : <https://hal.archives-ouvertes.fr>

01	0.chim	Chimie
02	0.info	Informatique
03	0.math	Mathématiques
04	0.phys	Physique
05	0.qfin	Économie et finance quantitative
06	0.scco	Sciences cognitives
07	0.sde	Sciences de l'environnement
08	0.sdu	Planète et Univers
09	0.sdv	Sciences du Vivant
10	1.shs.anthro	Anthropologie
11	1.shs.archeo	Archéologie et Préhistoire
12	1.shs.archi	Architecture
13	1.shs.art	Art et histoire de l'art
14	1.shs.autre	Autres
15	1.shs.droit	Droit
16	1.shs.edu	Éducation

17	1.shs.geo	Géographie
18	1.shs.gestion	Gestion et management
19	1.shs.hist	Histoire
20	1.shs.infocom	Sciences de l'information et de la communication
21	1.shs.ling	Linguistique
22	1.shs.litt	Littératures
23	1.shs.phil	Philosophie
24	1.shs.psy	Psychologie
25	1.shs.scipo	Science politique
26	1.shs.socio	Sociologie
27	NONE	Pas de domaine associé

A5. Éléments techniques

A5.1 Présentation de l'API de requêtage de notre corpus

Nous présentons dans cette partie notre interface de programmation de l'application (API) que nous avons développée afin d'interroger notre corpus.

Requêtes sur notre corpus pour filtrer le corpus, trouver des titres et faire des statistiques.

```
stat('domain')
```

Produit un comptage des titres selon le domaine des titres. Le résultat est un dictionnaire où la clé est le domaine et la valeur le nombre de titre dans ce domaine.

```
stat(('nb_parts', 'nb_segments'))
```

Produit un comptage des titres selon les combinaisons des valeurs possibles pour le nombre de parties et le nombre de segments. Le résultat est un dictionnaire où la clé est un tuple constitué d'une combinaison existante de valeurs des deux dimensions, par exemple 1 partie, 2 segments, et la valeur le nombre de titre correspondant à cette combinaison, le nombre de titres ayant 1 partie et 2 segments.

```
count({'nb_parts' : 1, 'nb_segments' : 2})
```

Compte le nombre de titre ayant une partie et deux segments.

```
t12 = select({'nb_parts' : 1, 'nb_segments' : 2})
```

Création d'un sous-corpus composé des titres ayant une partie et deux segments. On peut ensuite utiliser les requêtes stat et count sur celui-ci via une variable globale qui contient le corpus courant.

```
find({'nb_roots' : 2}, nb=20)
```

Cherche et affiche 20 titres ayant 2 têtes.

```
find({'roots.0.lemma' : 'rôle', 'roots.1.lemma' : 'cas',  
      'segments.0.lemma' : '.'})
```

Cherche et affiche 5 titres dont la tête du premier segment est le lemme *rôle*, celle du second segment le lemme *cas* et dont le signe de ponctuation segmentant est un point. Cette requête ne marche que sur un corpus constitué de titres à au moins deux segments.

```
avg('nb_segments')
```

```
minn('nb_segments')
```

```
maxx('nb_segments')
```

Obtient respectivement la moyenne des valeurs, la valeur minimum et la valeur maximum pour la clé *nb_segments* dans le corpus actuel.

A5.2 Description de nos données informatiques

Nous avons comme données de base un ensemble de 339 687 titres ayant les caractéristiques suivantes :

- identifiant,
- année,
- type de support (article, chapitre ou communication),
- domaine,
- auteurs,
- nombre d'auteurs,
- texte du titre,
- liste de mots et de signes de ponctuation que nous appelons tokens du titre :
 - Pour chaque token :
 - forme
 - étiquette morphosyntaxique
 - lemme (toujours égale à sa forme pour un signe de ponctuation)
 - informations supplémentaires
 - token recteur
 - type de relation de dépendance
 - sa position dans le titre
- longueur du titre en nombre de tokens (mots + signes de ponctuation),
- longueur du titre en nombre de mots uniquement,
- segments :
 - Permet d'accéder aux différents segments du titre et notamment :
 - sa tête,
 - son caractère segmentant (si ce n'est pas un premier segment)
 - la position de la tête dans le titre,
 - la position du caractère segmentant s'il y en a un
- nombre de segments.

A5.3 Analyse de 100 titres traités par Talismane

Nous avons analysé 100 titres traités par Talismane pour vérifier qu'il catégorisait bien les têtes de segments. Nous prenons 20 titres pour chaque structure (nombre de segments et position des têtes dans les segments) qui nous intéresse. Nous indiquons :

- Son identifiant dont la couleur indique le résultat de l'analyse pour le titre :
 - en **vert** si le titre a été analysé correctement en ce qui concerne la détection de têtes de segments,
 - en **orange** si l'analyse de Talismane est discutable mais n'impacte pas notre analyse,
 - en **rouge** si elle est fautive en ne détectant pas la bonne tête de segment,
 - en **violet** si la promotion d'un mot en tête de segment par notre algorithme fait changer le titre de catégorie structurelle,
 - en **rose** si une tête n'a pas été détectée.
- Pour les cinq structures qui nous intéressent, un code segment- tête de la forme :
 - 1__ pour un titre ayant 1 segment et 1 tête,
 - 2__ pour un titre ayant 1 segment et 2 têtes,
 - 1:0 pour un titre ayant 1 tête dans son premier segment et 0 dans son second,
 - 0:1 pour l'inverse,
 - 1:1 pour un titre ayant 1 tête dans chacun de ses deux segments.
- Les têtes de segment sont en gras et :
 - en **vert** si elles sont correctement catégorisées et lemmatisées,
 - en **bleu** si le lemme est incorrect ou inconnu (lemme ignoré pour NPP),
 - en **orange** si la catégorie morphosyntaxique est incorrecte,
 - en **rouge** s'il ne s'agit pas d'une tête,
 - en **violet** si elles ne sont pas détectées par Talismane mais par notre algorithme,
 - en **rose** si elles ne sont pas détectées ni par Talismane ni par notre algorithme.

001 **62230** 1__ Un possible **modele** semiotique global de la communication
Note 01 : L'absence d'accent fait que Talismane n'associe pas ce NC au Lemme modèle.

002 **62250** 1__ L'**IMPACT** DE L'EDITION ELECTRONIQUE SUR LA CRISE DU KOSOVO

003 **460613** 1__ Un **indicateur** de politique d'ouverture à l'immigration

004 **62244** 1__ Le **déplacement** médiatique du débat politique

005 **110369** 1__ L'**imprimerie** et sa diffusion en Extrême-Orient

006 **911256** 1__ Les **enfants** d'Hygie

007 **410464** 1__ **Optimisation** de la précipitation des métaux lourds en mélange

008 **911470** 1__ L'**héritage** du Boiteux d'Orgemont

009 **216325** 1__ **DIFFUSION** INTERGRANULAIRE ET ÉNERGIE DES JOINTS DE GRAINS

010 **760276** 1__ **Dépôt** sec des aérosols à l'interface air-eau

011 **1808328** 1__ **Modélisation** de la structure d'un mélange à haute dilution

012 **1015139** 1__ **Analyse** écophysiological de la nitrophilie des espèces adventices

013 **264210** 1__ Un **regard** sur les approches basées sur la vision par ordinateur

014 **1759146** 1__ L'**implantation** de l'abbaye de Conques dans les environs de Sainte-Foy-la-Grande
au XIe siècle

- 015 **215986** 1__ La **persistance** du droit successoral de l'Ancien Régime dans l'Europe du XIXe siècle
Note 02 : On remarque que Talismane fait dépendre Le du de persistance plutôt que Europe mais cela n'affecte pas notre analyse qui se limite à la tête de segment.
- 016 **162355** 1__ **Faut-il** jeter la Méditerranée avec l'eau du bain ?
- 017 **215983** 1__ La **défense** de la victime en France au XIXe et au XXe siècle
- 018 **110374** 1__ **Rédaction** de 120 notices
- 019 **62249** 1__ **Vers** une approche ethnographique des usages des Technologies de l'Information et de la Communication au sein des petites et moyennes entreprises malaisiennes
Note 03 : L'enchaînement de compléments de nom peut perdre Talismane : il ne sait plus par quoi est régi la préposition de. Ici celui avant l'Information est indiqué comme étant régi par approche au lieu de Technologies. Cela n'a pas d'incidence sur notre travail.
- 020 **1808326** 1__ **Algorithme** de construction de modèles markoviens multidimensionnels pour le mélange des poudres
-
- 021 **216380** 2__ **DIFFUSION** AVANT ET **ARRIÈRE** D'IONS LOURDS ET MOMENTS ANGULAIRES COMPLEXES
- 022 **1258669** 2__ **Contenu** et **exigences** du travail
Note 04 : Talismane normalement ne désigne que le premier NC d'un schéma NC CC NC comme tête. Ici, il désigne les deux NC ce qui n'est pas cohérent.
- 023 **312877** 2__ **Demain** la **géographie** sociale.
Note 05 : La promotion de l'adverbe comme tête est discutable.
- 024 **1015192** 2__ **Évaluation** de la dispersion des propriétés mécaniques d'un matériau composite par sous-**échantillonnage**
Note 06 : La présence d'un tiret provoque une erreur dans Talismane.
- 025 **1808361** 2__ Conditionnement des boues par gel-**dégel**
Note 07 : dégel est désigné comme tête alors que ce n'est clairement pas le cas à cause du tiret.
- 026 **264579** 2__ **Institutions** [Les **humanités** et les grandes institutions du savoir en France]
Note 08 : On peut considérer le texte entre crochets comme un segment non détecté.
- 027 **1258688** 2__ **Comparaison** isoenzymatique de deux populations boliviennes (altitude et plaine)
de *Triatoma infestans* (Hemiptera\, Reduviidae)
Note 09 : de est désigné comme tête alors que ce n'est clairement pas le cas.
- 028 **162715** 2__ **Transfert** de chaleur et de masse dans une salle d'opérations conditionnée\, **comparaison** entre deux modes de soufflage
Note 10 : La virgule n'est pas considérée comme segmentante mais ici elle devrait l'être.
- 029 **264613** 2__ **Accès** à l'information et reconnaissance d'un droit à l'information environnementale - Le nouveau **contexte** juridique international
Note 11 : Le tiret n'est pas considéré comme segmentant mais ici il devrait l'être. Cela est facilité par la présence d'une majuscule.
- 030 **62420** 2__ **De** l'appropriation inachevée du concept de genre (gender) **en** communication organisationnelle
Note 12 : en est désigné comme tête alors que ce n'est clairement pas le cas.
- 031 **216445** 2__ **APPLICATION** DES MÉTHODES STATISTIQUES AU CALCUL DES CHAMPS THERMIQUES TURBULENTS
NON HOMOGÈNES
Note 13 : HOMOGÈNES est désigné comme tête alors que ce n'est clairement pas le cas.
- 032 **960687** 2__ **Amitiés**\, des **sciences** sociales aux réseaux sociaux de l'internet
- 033 **216532** 2__ **TRANSITION** MÉTAL-**SEMICONDUCTEUR** DANS LES COMPOSÉS Cr2S3-xSex ET Cr2+eSe3

- Note 14 : La présence d'un tiret provoque une erreur dans Talismane.
- 034 1609898 2__ Les **Vigiles debout**
- Note 15 : Talismane ne devrait prendre que Le verbe conjugué.
- 035 960764 2__ **Misère** de l'hyper-**spécialisation** et dérivés du professionnalisme
- Note 16 : La présence d'un tiret provoque une erreur dans Talismane.
- 036 62668 2__ **Bibliothèques** numériques et Google-**Print**
- Note 17 : Print est désigné comme tête alors que ce n'est clairement pas le cas.
- 037 1559698 2__ Dispositif **de de** caractérisation simultanée de l'abondance de pucerons et de la
la
croissance végétative d'arbres fruitiers
- Note 18 : La répétition de La préposition entraîne une erreur dans Talismane.
- 038 264587 2__ Le **jeu**\, une **approche** philosophique
- Note 19 : ici, La virgule a une valeur segmentante.
- 039 460685 2__ Surveillance de chorégraphies de Web Services basées sur WS-**CDL**
- Note 20 : La présence d'un tiret provoque une erreur dans Talismane.
- 040 62434 2__ **Développement** stratégique du tourisme sportif de rivière par régulation
corporatiste L'**expérience** du bassin de Saint Anne (Québec) appliquée aux
Rivières
de Provence
- Note 21 : Oubli d'un point entre les deux segments du titre. La présence d'une majuscule
permet de bien repérer la segmentation manquante.
-
- 041 62397 1:0 **Réinterroger** les structures documentaires : **de** la numérisation à
l'informatisation
- 042 62226 1:0 Les **temporalités** médiatiques des personnes âgées : des **évolutions** dans la
stabilité
- 043 360068 1:0 La **performativité** de l'évidence : **analyse** du discours néolibéral
- Note 22 : Le mot n'est pas rattaché à son lemme par Talismane car son statut lexical est
discutable.
- 044 1061179 1:0 La **Société** de la Carte géologique de France (1869-1872) : une éphémère
réaction à la création du Service de la Carte géologique de la France
- 045 360074 1:0 **Dynamique** technologique controversée et débat démocratique : le **cas** des micros
et nanotechnologies
- 046 62256 1:0 **Traces** de contenus africains sur Internet : **entre** homogénéité et identité
- 047 216312 1:0 **MODÈLES** THÉOTIQUES DE LA STRUCTURE DES JOINTS DE GRAINS. LES **MODÈLES** DE
STRUCTURE DES JOINTS DE GRAINS ET LEUR UTILISATION
- Note 23 : Les deux têtes sont les mêmes.
- 048 1759477 1:0 Les **objets** communicants\, La **problématique** des Antennes: **Dispositif pour**
détecter le vèlage des vaches.
- Note 24 : pour est détecter faussement par notre algorithme comme un mot à promouvoir en
tête car Dispositif et pour sont régis par objets. De plus, on a une virgule
segmentante, la majuscule qui la suit montrant clairement le début d'un segment.
Il s'agit donc d'un titre à trois segments.
- 049 760329 1:0 L'**omniprésence** de la famille au sein de l'exploitation agricole : une
situation de fait encouragé par les règles de droit
- 050 1208785 1:0 **SymbAphidBase** : une **base** de données nouvelle dédiée aux symbiotes de pucerons
pour stocker et visualiser les génomes séquencés en standardisant leurs
annotations
- 051 264568 1:0 **Bill** Viola : **voir** l'eau ou la transparence en mouvement
- Note 25 : Bill est caractérisé comme un NC au lieu d'un NPP.
- 052 1759420 1:0 Les **objets** communicants\, La **problématique** des Antennes; **Balises** de Détresse
- Note 26 : trois problèmes dans ce titre : problématique est considérée comme un adjectif, la
virgule n'est pas segmentante mais ici elle l'est, et Balises est détecté par
notre algorithme. En fait, il s'agit d'un titre à trois segments et non deux.

- 053 460618 1:0 PERCEPTION DE L'INDÉPENDANCE DE L'AUDITEUR : ANALYSE PAR LA THÉORIE D'ATTRIBUTION
- 054 1707597 1:0 Élités maléfiques et ""complot pédophile"" : paniques morales autour des enfants
- 055 1759142 1:0 Formation et évolution des paroisses de la basse vallée du Drot : essai de synthèse
- 056 859899 1:0 Classification floue généralisée : Application à la quantification de la stéatose
sur des images histologiques couleurs
- 057 510693 1:0 Les gastroentérites aiguës à rotavirus de l'enfant : une priorité de santé publique.
- 058 960530 1:0 Monde pluriel : penser l'unité des sciences sociales
- 059 659177 1:0 Reconnaissance et appropriation : pour une anthropologie du travail
- 060 62190 1:0 Métiers émergents de la nouvelle économie: identification des compétences attendues et typologie des métiers exercés
-
- 061 1660207 0:1 Quel pouvoir de stabilisation à l'échelle de l'UEM : le pacte de stabilité et de croissance est-il viable ?
- 062 659285 0:1 L'Etat et les "" autres "" : comparer la visibilisation de la main-d'œuvre immigrée
- 063 62609 0:1 Le Libre Accès (Open Access) : partager les résultats de la recherche
Note 27 : Libre est caractérisé comme NPP ainsi que Accès. On peut se poser la question si ce n'est pas le syntagme nominale entier Libre Accès qui devrait être tête.
- 064 960680 0:1 De l'apprenti footballeur au petit-rat de l'Opéra : comment les institutions d'excellence agissent face aux dispositions sociales des apprentis ?
Note 28 : Notre algorithme devrait se contenter de ne prendre que de.
- 065 1258715 0:1 Référentiels de compétences : ce que l'instrument fait à la logique compétence
- 066 860275 0:1 La question périurbaine : la repenser en tenant enfin compte de ce qui motive les périurbains
- 067 62568 0:1 Transférabilité des connaissances : une re-conceptualisation de la distinction tacite / explicite
Note 29 : Talismane catégorise explicite comme V au lieu d'ADJ. De ce fait, il désigne explicite comme tête au lieu de re-conceptualisation.
- 068 264762 0:1 Théophile Gautier : Regardez\, mais ne touchez pas (comédie)
Note 30 : On peut se poser la question si ce n'est pas le syntagme nominal entier Théophile Gautier qui devrait être pris comme tête par notre algorithme.
- 069 1015049 0:1 Les (il)légalités ambiguës dans le travail policier : comment l'espace devient prétexte
*Note 31 : L'utilisation du suffixe entre parenthèses il perd Talisman. Il le catégorise comme
CLS. Notre algorithme ensuite trouve deux mots à prendre pour têtes au lieu d'un.*
- 070 1358243 0:1 Evolution de l'arboricole chez les Cercopithèques: analyse combinée de données moléculaires\, morpho-anatomiques et comportementales
Note 32 : combinée est choisi comme tête alors qu'analyse devrait l'être.
- 071 1061109 0:1 ImPAC Lyon : évaluer l'impact environnemental et thermique de l'exploitation des aquifères superficiels pour la climatisation
- 072 1759247 0:1 Relation image/son : de l'illustration sonore à la fusion multi-modale
*Note 33 : sonore est caractérisé comme V au lieu de ADJ et comme tête alors que de est de est un meilleur candidat. On remarque la construction de X à Y.
Notre algorithme propose Relation est bien la tête du premier segment et*

- incorrectement son qui est mal catégorisé : DET au lieu de NC.*
- 073 **760065** 0:1 D'une catastrophe\, l'**autre** : **vivre** avec l'atome
Note 34 : Notre algorithme détecterait autre également comme tête car il est régi par vivre. Mais nous limitons notre algorithme à ne prendre que le premier mot comme tête.
- 074 **110247** 0:1 **Vers** une économie des fonctionnalités: **changer** nos rapports avec le produit pour
des économies d'échelle et des nouvelles logiques de responsabilités
- 075 **809358** 0:1 **Après** la délocalisation...les PME **doivent**-elles relocaliser ?
- 07 6 **460346** 0:1 Une jeune **fil**le changée en jeune homme : homélie sur un miracle survenu dans le
monastère **couvent** de Qartmin\, dans le Tur Abdin
Note 35 : Erreur classique de confondre le NC couvent avec le V couvrir, de plus il ne s'agit pas de la tête de segment, homélie y prêtant plus sûrement.
- 078 **1060698** 0:1 **Extension** de procédure: ""Le législateur nous **garde** de l'opportunité du juge
- 079 **312714** 0:1 **Mise** au point sur ""Les cathares devant l'histoire"" et retour sur ""L'histoire
du catharisme en discussion: le débat sur la charte de Niquinta n'est pas **clos**
Note 36 : Mise, détecté par notre algorithme, est catégorisé comme VPP au lieu de NC.
- 080 **162674** 0:1 **Communication** financière : quelles **sont** les pratiques des entreprises ?

- 081 **1258625** 1:1 Un nouvel **OVNI** dans le ciel réunionnais : la **transparence** des prix
- 082 **62241** 1:1 **De** l'anarchisme au combat identitaire : l'**internet** comme média révolutionnaire ?
- 083 **62366** 1:1 **Communication** et changement organisationnel : le **concept** de chaîne d'appropriation
- 084 **264580** 1:1 Mystique et **magie** naturelle : les **paysages** mystiques de l'Espagne
Note 37 : Mystique est catégorisée comme ADJ, Talismane privilégie donc le NC magie comme tête. Mais il aurait dû soit choisir Mystique.
- 085 **216338** 1:1 **MIGRATION** DES JOINTS DE GRAINS.LA **MIGRATION** DES JOINTS INTERGRANULAIRES
Note 38 : La capitalisation ne pose pas de problème à Talismane. Les deux têtes sont le même mot.
- 086 **1609872** 1:1 La **création** d'entreprise en réponse au rêve d'île : l'**ambivalence** d'une attractivité fondée sur le cadre de vie.
- 087 **659340** 1:1 **Mise** à disposition des données géologiques de surface : **Création** d'un accès sous
InfoTerre
Note 39 : La nominalisation de la locution verbale "mettre à disposition" n'est pas bien catégorisée.
- 088 **960668** 1:1 **Brevet** et patrimoine génétique : la **brevetabilité** des organismes génétiquement modifiés
- 089 **62616** 1:1 **Projet** DigiCulture : **pour** un portrait des usages et des usagers des ressources culturelles numériques canadiennes
- 090 **62386** 1:1 **PRATIQUES** ENONCIATIVES HYPERTEXTUELLES : **VERS** DE NOUVELLES ORGANISATIONS MEMORIELLES.
- 091 **110466** 1:1 L'**avenir** de la Common law en français : un **point** de vue d'Europe continentale
- 092 **1109003** 1:1 **Estimation** des quantiles conditionnels par quantification optimale : nouveaux **résultats**
- 093 **1108914** 1:1 **Présentation** d'une langue: le **hongrois**
- 094 **609991** 1:1 **Variation** du risque de cancer du sein en fonction de la nature de la mutation du
gène ATM. **Étude** familiale rétrospective
- 095 **62386** 1:1 **PRATIQUES** ENONCIATIVES HYPERTEXTUELLES : **VERS** DE NOUVELLES ORGANISATIONS MEMORIELLES.

- 096 1015246 1:1 L'**impact** des enceintes urbaines médiévales sur le territoire et ses limites.
L'**exemple** de la Lorraine et de l'Alsace
- 097 1258763 1:1 **Phèdre** janséniste ? **retour** sur un lieu commun (2)
Note 40 : Phèdre n'est pas catégorisée comme un NPP mais comme un NC.
- 098 1409780 1:1 **Développement** et politique. Le **cas** d'une politique de santé en Géorgie.
- 099 62382 1:1 Quels **modèles** pour la publication sur le web? Le **cas** des contenus
informationnels
et culturels.
Note 41 : Talismane arrive à scinder Le ? du mot web.
- 100 560355 1:1 Un **tournant** participatif ? Une **mise** en perspective historique de la
participation
du public dans les politiques scientifiques américaines
Note 42 : Ici, mise est bien reconnu comme une nature nominale.

A6. Index des tableaux

Tableau 1: signes de ponctuation segmentants	14
Tableau 2: Distribution des catégories morphosyntaxiques des têtes de segments	19
Tableau 3 : Combinaisons agrégées les plus fréquentes de têtes dans les titres bisegmentaux ..	20
Tableau 4 : Distribution des structures des titres selon le type	22
Tableau 5 : Distribution des structures des titres selon le nombre d'auteur	22
Tableau 6 : Distribution des structures selon le domaine	24
Tableau 7 : Corrections opérées sur l'étiquetage et la lemmatisation.....	27
Tableau 8 : Les dix têtes les plus spécifiques de chaque domaine	29
Tableau 9 : Nombre de têtes transdisciplinaires par domaines	34
Tableau 10 : Nombre de têtes transdisciplinaires selon le corpus choisi	37
Tableau 11: Tableau d'équivalence entre construction copulative et réduire.....	45
Tableau 12 : Séquences extraites de l'exemple (42)	52
Tableau 13 : Nombre de séquences pour les deux bases de chaque extraction.....	53
Tableau 14 : Motifs émergents avec une longueur maximale de séquence de trois items	54
Tableau 15 : Motifs émergents pour les séquences de longueur de quatre items	55
Tableau 16 : Tableau des têtes transdisciplinaires les plus fréquemment retrouvées dans nos schémas	61
Tableau 17 : répartition des schémas dans les différentes disciplines.....	62
Tableau 18: Présence des constructions spécificationnelles classiques dans notre corpus	64