

Référentiels et vocabulaires

Pistes méthodologiques pour
la construction
d'un vocabulaire contrôlé



Blandine NOUVEL, Centre Camille Jullian (Aix-Marseille Univ, CNRS) & Frantiq
7 novembre 2023

Méthode

Concepts &
termes

Relations
sémantiques

Outils

Normalisation
& FAIR

Rappel sur ce qu'est un référentiel

- Types de Référentiels et vocabulaires contrôlés
 - Du dictionnaire au **thésaurus**
 - Organisation +/- structurée
- Objectifs
 - Normaliser une terminologie pour éviter les ambiguïtés du langage naturel (synonymie, polysémie)
 - Partager un langage validé par une communauté
- Usages
 - Enrichir les métadonnées d'une ressource (indexation) en qualifiant son contenu (avec des mots-clés)
 - Faciliter la recherche documentaire en évitant le bruit et le silence (index et filtres)

Une affaire de longue haleine

PACTOLS 1987-2019

59727 concepts

- >  Anthroponymes
- >  Chronologie
- >  Lieux
- >  Oeuvres
- >  Peuples
- >  Sujets



Pactols 2022

Sujets

12037 concepts

- >  activités
- >  entités immatérielles
- >  entités matérielles
- >  entités nommées
- >  entités sociales collectives
- >  entités spatiales
- >  entités temporelles
- >  matériaux
- >  organismes vivants
- >  processus naturels
- >  rôles
- >  unités géopolitiques
- >  ~[termes dépréciés]

Lieux

50305 concepts

- >  entités actuelles
- >  entités du passé
- >  espaces aquatiques
- >  espaces terrestres
- >  sites archéologiques
- >  ~[termes dépréciés]

Par quel bout commencer ?

- Etat des lieux : qu'existe-il comme outil sur mon sujet ?
 - Les dictionnaires et lexiques spécialisés...
 - Les sites de référencement



- Les vocabulaires numériques disponibles sont-ils normalisés, évolutifs, ouverts, réutilisables (FAIR) ?
 - Les adopter, y participer ou les utiliser comme source d'inspiration ?
- Le cas Pactols :
 - Recréer un nouveau à partir d'un lexique (mettre à jour et réorganiser)
 - Conserver le lien avec le Catalogue Collectif Indexé
 - Exploiter les fonctions de Opentheso


Définir le·s public·s, le·s usage·s

La transformation de Pactols d'un thésaurus documentaire à un référentiel du web pour l'archéologie a eu des incidences sur son contenu et son organisation

Évolution des ressources à indexer



De nouveaux utilisateurs



Constituer une équipe

- Des compétences
 - Compétences sur le web sémantique et la structuration de terminologies
 - Compétences techniques et scientifiques sur le domaine
 - Utilisateurs finaux (métiers IST et Données, archéologues)
- Un calendrier
 - Objectifs tenables
 - Séances de travail régulières
 - Processus itératif de discussion/validation
 - Lexique (ateliers de spécialistes)
 - Structuration (formalisation, définition, relations sémantiques)

Constituer son réservoir de mots-clés

- Extraction (automatique) de mots-clés dans un corpus (publications scientifiques) ou un ou des vocabulaires existants
- Viser l'exhaustivité terminologique du domaine?
 - Lien avec un fonds documentaire = pas de concept s'il n'y a pas au moins une ressource correspondante dans le catalogue
- Combien de termes ? de 100 à +10 000 ^{aines}

« La collecte des termes ne peut être efficace que si elle prend aussi en compte le vocabulaire des utilisateurs. » (M. Hudon, 2013)

Ré-organiser un vocabulaire

- Top-down:
 - Définir les branches principales, puis les sous-branches
 - Y positionner les concepts
- Down-top :
 - Rassembler les concepts par « famille »
 - Identifier des thématiques, de la plus précise à la plus large
- Un mélange des 2...

Les concepts & les termes

- Un terme représente un concept
 - réception de l'Antiquité ; vente d'esclave ; nucléus
- Se méfier des termes apparemment sans difficultés
 - Préférer des concepts plébiscités par les spécialistes
 - crémation plutôt qu'incinération
 - inhumation ≠ sépulture à inhumation
 - Mais quand la terminologie n'est pas [encore] stabilisée ou que le terme a des acceptations différentes selon les époques...
 - sarcophage vs cercueil vs coffre funéraire
 - charnier médiéval ≠ charnier moderne
- Exploiter les variantes et les notes d'application

L'écriture du concept

- Un substantif
 - simple ou composé
 - au singulier, sauf cas particulier (catacombes)
 - ni adjetif : pas **gravé**, mais galet gravé, plaquette gravée, signe gravé
 - ni verbe : pas **fouiller**, mais fouille, fouille subaquatique, fouille programmée
- Justesse des libellés et de leurs variantes
 - skos:prefLabel = la forme choisie/préférée
 - skos:altLabel = formes rejetées (synonymes, équivalent (ou antonymes) dans le thésaurus, formes obsolètes)
 - skos:hiddenAltLabel = formes erronées

bouton de préhension // bouton (réciipient) vs bouton de costume // bouton (vêtement)

instrument de musique // musique (instrument)

oppidum plutôt qu'habitat fortifié de hauteur protohistorique

archéologie préventive // archéologie de sauvetage

Définition et notes d'application

- Norme ISO 1087: 2019

Terminology work and terminology science — Vocabulary

Travaux terminologiques et science de la terminologie — Vocabulaire

* Les critères de qualité

Une définition...

- Ne décrit qu'un seul concept
- Concise : tout ce qui n'est pas indispensable à la compréhension est à supprimer
- Est de forme affirmative
- Mentionne le concept supérieur
- Réutilise des termes définis par ailleurs, si possible dans un dictionnaire de langue générale ou dans le même référentiel
- Tient en une seule phrase

 INRAE DipSO
Rédiger une définition
2021 / Vocabulaires Ouverts @INRAE



* Bonnes pratiques

- La définition d'un nom débute par un nom, celle d'un verbe par un verbe
- La définition ne doit commencer ni par un article, ni par un adjectif démonstratif, ni par un pronom démonstratif.
- La définition ne doit pas commencer par "espèce de", "type de" ... (à quelques exceptions près)
- Une définition ne doit pas être introduite par le terme à définir ni comprendre ce terme (ou un de ses synonymes) ou un terme de la même famille.

 INRAE DipSO
Rédiger une définition
2021 / Vocabulaires Ouverts @INRAE



p. 5

Péloponèse dans Pactols



Péloponèse (péphérie)

• **Définition** : Région administrative de Grèce ou péphérie comprenant cinq des sept districts régionaux de la péninsule du Péloponnèse.

• **Note d'application** : À différencier du concept "péninsule du Péloponnèse" qui est un espace géographique et qui ne couvre pas la même étendue que la péphérie du Péloponnèse.

Péninsule du Péloponèse

• **Définition** : Espace géographique désignant la péninsule du Péloponnèse, bordée par la mer Ionienne et la mer Égée et reliée à la Grèce continentale par l'isthme de Corinthe.

• **Note d'application** : À différencier du concept "Péloponnèse (péphérie)" qui est une région administrative de Grèce et qui ne couvre pas la même étendue géographique que la péninsule du Péloponnèse.

Structurer le thésaurus

- Norme ISO25964 -1 et 2, *Information and documentation – Thesauri and interoperability with other vocabularies*
- Langage SKOS, *Simple Knowledge Organisation System* (Modèle FAIR développé par le W3C) [Version FR](#)
 - des objets : thésaurus, concepts, groupes
 - des propriétés : les relations sémantiques
- Bonnes pratiques pour structurer un thésaurus
(<https://opentheso.hypotheses.org/67>)

Branches thématiques vs organisation ontologique

2 ARCHIVES DE FRANCE THESAURUS POUR L'INDEXATION DES ARCHIVES LOCALES

SOMMAIRE

1. Administration	7. Extérieur
1.1 Droit public	7.1 Défense du territoire
1.2 Administration générale	7.2 Guerre
1.3 Finances publiques	7.3 Relations internationales
1.4 Fiscalité	
1.5 Police	
1.6 Protection civile	
1.7 Régime seigneurial	
2. Agriculture	8. Justice
2.1 Economie rurale	8.1 Condition pénitentiaire
2.2 Forêt	8.2 Justice civile
2.3 Production agricole	8.3 Justice pénale
	8.4 Décision de justice
	8.5 Organisation judiciaire
3. Communications	9. Opinion
3.1 Messagerie	9.1 Mouvement d'idées
3.2 Transport	9.2 Election
4. Economie	9.3 Vie politique
4.1 Action économique	9.4 Vie publique
4.2 Commerce	9.5 Vie religieuse
4.3 Entreprise	9.6 Croyances et sciences
4.4 Industrie	parallèles
4.5 Energie	
5. Education	10. Société
5.1 Enseignement	10.1 Condition des personnes
5.2 Organisation scolaire	et des biens
5.3 Recherche scientifique	10.2 Emploi
5.4 Vie scolaire	10.3 Population
6. Equipment	10.4 Protection sociale
6.1 Environnement	10.5 Santé
6.2 Immobilier	10.6 Travail
6.3 Urbanisme	
6.4 Voie de communication	
	11. Temps libre et sociabilité
	11.1 Culture
	11.2 Loisir
	11.3 Tourisme
	11.4 Vie quotidienne

https://francearchives.gouv.fr/file/efb9242a3d6d4e5557940d65a95d4f830dc1a30b/static_5372.pdf

Backbone Thesaurus

Alphabetical	Hierarchy	Groups
+000001 activities		
-000010 disciplines		
-000013 functions		
-000011 human interactions		
-000012 intentional destructions		
+000006 conceptual objects		
-000024 concepts		
-000023 methods		
-000022 propositional objects		
-000021 symbolic objects		
+000049 geometric extents		
-000052 3d-volumes		
-000053 linear extents		
-000050 points		
-000051 surface areas		
-000009 geopolitical units		
-000007 groups and collectivities		
+000004 material things		
-000018 built environment		
-000017 mobile objects		
-000019 physical features		
-000020 structural parts of material objects		
-000003 materials		
+000002 natural processes		
-000016 geneses		
-000015 natural disasters		
+000008 roles		
-000025 offices		
-000026 roles of interpersonal relations		
-000005 types of epochs		

<https://vocabs.dariah.eu/bbt/en/?clang=fr>

La subordination

- Caractéristique du thésaurus, représenté en arbre hiérarchique
terme générique (TG) / terme spécifique (TS & TSI)
- Subordination en ISO :
 - Générique = IS A
plan d'eau *est un* lac / lac *est un* plan d'eau
 - Instantielle = IS A (déclinaison)
lac Érié *est une instance de* (iso-thes:narrowerInstantial) lac
 - Partitive = IS PART OF
lac Érié *est une partie de* (iso-thes:narrowerPartitive) Grands lacs
- SKOS définit la direction de la subordination:
 - skos:broader / skos:narrower
plan d'eau <skos:narrower = lac> / lac <skos:broader = plan d'eau>



https://upload.wikimedia.org/wikipedia/commons/c/c3/Canada_relief_map_2.svg

Les niveaux de profondeur

- La norme :
 - 4 niveaux ou plus
- L'usage et la visibilité,
 - Un compromis entre le nombre de niveaux et le nombre de branches
- La nécessité :
 - Respecter les besoins du public (spécialiste)

- >  activités
- >  entités immatérielles
- ✓  entités matérielles
 - >  caractéristiques physiques
 - >  environnements bâtis
 - >  objets mobiles
 - ✓  parties structurelles d'entités matérielles
 - ✓  élément de préhension
 - ✓  anse
 -  anse en flûte de pan
 -  anse surbaissée
 - ✓  bouton (réciipient)
 -  bouton perforé
 -  languette perforée
 - ✓  manche
 -  hampe
 -  préhampe
 -  oreille (préhension)
 -  poignée
 -  queue (réciipient)

La polyhiérarchie

- Un concept à plusieurs génériques

France

Bourgogne-Franche-Comté

Département de la Nièvre

Glux-en-Glenne

Bibracte


Bibracte EPCC

Larochemillay

Bibracte

Saint-Léger-sous-Beuvray

Bibracte



La grande *domus* de Bibracte

Photo et plan du site <https://www.bibracte.fr>

Les relations d'association

Équivalent à un « Voir aussi »

• **Lier des termes de niveau équivalent**

entités matérielles > objets mobiles > **matériel de broyage** > meule > meule va-et-vient
TA
entités immatérielles > méthodes > technique de fabrication > **broyage (technique)**



• **Une solution alternative à la polyhiérarchie ou à des relations génériques transitives fautives**

entités actuelles > ... > France > ... > Département de la Nièvre > Glux-en-Glenne > **Bibracte**
entités actuelles > ... > France > ... > Département de la Nièvre > Larochemillay > **Bibracte**
entités actuelles > ... > France > ... > Département de la Nièvre > Saint-Léger-sous-Beuvray > **Bibracte**
TA
espaces terrestres > ... > Massif central > Morvan > **mont Beuvray**

ET PAS (dans l'organisation Pactols)

entités actuelles > ... > France > ... > Département de la Nièvre > Glux-en-Glenne > **Bibracte**
entités actuelles > ... > France > ... > Département de la Nièvre > Larochemillay > **Bibracte**
entités actuelles > ... > France > ... > Département de la Nièvre > Saint-Léger-sous-Beuvray > **Bibracte**
espaces terrestres > ... > Massif central > Morvan > **mont Beuvray** > **Bibracte**

Préparer-1



Préparer-2

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S
1	Code couleur	bbt : noir gras ; candidat ventilé : vert ; nouveau terme : rouge ; pactols : normal	à débattre : fête/manifestation ?																
2	facettes BBT	tt BBT					TA	EM	autre TG	Définition	commentaire								
3	F - activités																		
4	F - activités	TT - activités																	
5	F - activités	TT - disciplines																	
6		construction de phénomènes																	
7		histoire du sport																	
8		compréhension de phénomènes																	
9		fourniture de savoir et/ou d'expertise																	
10		production d'oeuvres et/de phénomènes à valeur esthétique																	
11		chant																	
12		aulodie																	
13		musique																	
14		littérature																	
15		poésie																	
16		genre dramatique																	
17		danse																	
18		sport [renommé exercice physique]																	
19		acrobatie																	
20		agonistique																	
21		athlétisme																	
22		co																	
23		pe																	
24		sport de combat (en																	
25		pu																	
26		pa																	
27		lut																	
28		gymnastique																	
29																			
30																			
31	F - activités	TT - interactions humaines																	
32		TS événements sociaux																	
33		fête																	
34		commémoration																	
	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P			
1	MOT CLE / CANDIDAT	STATUT	ID INTERNE	POIDS FRANCTION	EN FAVEUR	DEFINITION	TRADUCTION	SYN	TERME ASSOC.	POSITION (BBT 1)	POSITION (BBT 2)	POSITION (BBT 3)	TG	COMMENTAIRE	PROPOSITION				
2	agriculture	concept	13130																
3	exploitation agricole	concept	14676																
4	plantation	concept	178384																
5	fertilité	concept	18262																
6	produit agricole	concept	16416																
7	saison agricole	concept	13131																
8	labour	concept	15381																
9	récolte	concept	16740																
10	battage	concept	13557																
11	moisson	concept	15699																
12	vernage	concept	177758																
13	vendange	concept	17485																
14	structure agraire	concept	17056																
15	colonat	concept	13966																
16	fermage	concept	14728																
17	technique agricole	concept	13132																
18	amendement	concept	13168																
19	assolément	concept	13434																
20	culture en terrasse	concept	14232																
21	culture extensive	concept	14233																

De CSV à SKOS

Skos Play! > « convertir une feuille de calcul Excel en fichier SKOS »




The screenshot shows the Skos Play! interface. At the top, there are navigation links: Accueil, Play!, Convertir, Tester, A propos, Forum, and Fr. Below this, a section titled "Où se trouvent les données excel à convertir ?" (Where are the Excel data to convert?) offers three options: "Dans un des Fichiers d'exemple fourni" (With an example file provided), "Dans un Fichier sur mon ordinateur" (On my computer), and "Sur le web" (On the web). The "Dans un des Fichiers d'exemple fourni" section contains a dropdown menu with "Example 1 (simple exemple, in english)" selected, and a link to "Télécharger l'exemple : Example 1 (simple exemple, in english)". The "Dans un Fichier sur mon ordinateur" section has a file input field and a "Selectionner un fichier" button. The "Sur le web" section has a URL input field with "http://...".

OpenRefine + extension RDF-openRefine



The screenshot shows the OpenRefine interface with a table titled "12 rows". The columns are: Libellé FR, ID, Libellé FR, Synonyme FR, Libellé EN, and Définition. The data includes rows for various agricultural equipment like Matériel, Matériel Agricole, Broyeur, Trituateur, etc., with their English equivalents and definitions. On the left, there is a facet panel for "Libellé FR" showing 12 choices: Activité, Andainage, Andaineuse, Aplatissage de grains, Broyeur, Conditionneur de fourrage, Faneuse, Matériel, Matériel Agricole, Matériel d'élevage, Matériel de récolte, and Trituateur.

VocBench + Sheet2RDF



The screenshot shows the VocBench interface. At the top, there are links: About VocBench, VocBench, Projects, Data, Metadata, SPARQL, and Tools. Below this, a "Spreadsheet file" section shows a preview of a spreadsheet with 26 rows. The columns are: ID, Libellé FR, Synonyme FR, Libellé EN, Définition, and Hiérarchie (parents). The data includes rows for Matériel, Matériel Agricole, Broyeur, and Trituateur. Below the spreadsheet, a "Generated triples preview" section shows "Subject" and "Predicate" columns.

Opentheso



The screenshot shows the Opentheso interface with a section titled "Correction 1 - Restructuration". It says: "Permet de corriger les incohérences dans le théssaurus en cours :". It lists three steps: 1- détecter les concepts TT erronés : si le concept n'a pas de BT, alors, il est forcément TopTerm. 2- compléter le théssaurus par les relations qui manquent NT ou BT. 3- supprimer les relations en boucle (100 -> BT -> 100) ou (100 -> NT -> 100) ou (100 -> RT -> 100). A note at the bottom says "!!! Ne pas oublier de recharger le théssaurus à la fin du traitement !!!". A "Lancer la correction" button is at the bottom.

<https://vocabulaires-ouverts.inrae.fr/2022/10/13/3-outils-transformer-tabule-skos/>

FAIRiser un thésaurus

Un vocabulaire FAIR doit être

- **Facile à trouver :**
 - être enregistré (indexé, répertorié) dans un entrepôt dédié aux vocabulaires ou généraliste
 - avoir des identifiants uniques et pérennes (PID)
- **Accessible :**
 - être accessible sur le web (<https://>)
 - téléchargeable dans des formats standardisés (csv, rdf, Json)
 - requêtable via des APIs (open API)
- **Interopérable :**
 - encodé dans une représentation standard, telle que le langage d'ontologie Web (OWL) ou SKOS
 - et les extensions spécifiques aux domaines
- **Réutilisable :**
 - avec une licence explicite
 - une documentation
 - et une organisation pour sa maintenance

Outils spécialisés open-source

Construire et gérer
« AtoZ »

- Intelligent Taxonomy Manager - <https://mondeca.com/logiciels/>
- TemaTres - <https://sourceforge.net/projects/tematres/>
- Protégé - <https://protege.stanford.edu/>
- Ginco, Gestion informatisée de nomenclatures collaboratives ouvertes - <https://github.com/culturecommunication/ginco>
- Opentheso - <https://github.com/miledroussset/Opentheso2>

Contrôler


- SKOSPlay - <https://skos-play.sparna.fr/play/>

Publier et consulter

- Skosmos - <https://www.skosmos.org/>
- VocBench - <https://bitbucket.org/art-uniroma2/vocbench3/downloads/>

Opentheso & Pactols

- Depuis 2005 pour Frantiq
- Outil complet
 - Création
 - Gestion et administration
 - Collaboration (4 niveaux d'autorisation)
 - Publication
- Outil normalisé
 - ISO 25964
 - Multilingue
 - SKOS
 - API
- Diffusé
 - Github
 - IR* Huma-Num
 - Projets nationaux & internationaux
- Documenté
<https://opentheso.hypotheses.org/>



The screenshot shows the Opentheso interface for managing concepts. The left sidebar has a green header and contains a tree view of concepts, with 'objet en cuir' selected. The main content area is titled 'Concept' and shows the following details for 'objet en cuir':

- Libellé:** objet en cuir (fr)
- Variante du libellé:**
- Collection:** P2-ENTITÉS MATÉRIELLES_P1-SUJETS
- Facettes:** objets mobiles par matériau
- Total de la branche:** 16 notices
- Corpus lié:** Catalogue Frantiq (16 notices)
- Concept générique:** objets mobiles
- Concept spécifique:**
- Concept associé:** caveçon, cuir, tannerie, travail des peaux
- Traduction:**
 - leather object (en)
 - Lederobjekt (de)
 - objeto de cuero (es)
 - oggetto di cuoio (it)
- Notes:**
- Alignment:** exactMatch : <https://www.wikidata.org/wiki/Q99689314> (Wikidata)
- Notation:**
- ID Interne:** 178439
- URI:** <https://ark.frantiq.fr/ark:/26678/crtFzipjOlgB>
- ID Ark:** 26678/crtFzipjOlgB
- Exporter le concept en SKOS:** RDF/XML, JSON, JSONLD, Turtle

At the bottom right, there is a QR code and a button to "Proposer une amélioration".

Faire vivre le thésaurus

Mise à jour le lexique

- Gérer les candidats
- Administrer les propositions d'améliorations

Révision des branches

Mise à niveau des traductions

Suivi des alignements

- Wikidata
- IdRef
- Geonames, Pleiades
- PeriodO

Communication

- En interne GT Pactols
- utilisateurs-pactols@listes.services.cnrs.fr
- Web et RS

Formation

- Les catalogueurs Frantiq
- Les autres utilisateurs (MASA)

Expériences publiées

- MENG Fan, ZHOU Kaile, BU Yi, HUANG Win-Bin, ZHANG Pengyi, LONG Fei et LI Yan, « Keywords Extraction and Thesaurus Construction for Domain News », *Procedia Computer Science*, vol. 214, 2022, p. 837-844.
<https://www.sciencedirect.com/science/article/pii/S1877050922019597>
- Building the DEFC thesaurus / Digitizing Early Farming Cultures project
<https://defc.acdh.oeaw.ac.at/blog/post03/>
- KOMBOLO Moïse, YON Jérémie, LANDRIEU François, RICHON Brigitte, AUBIN Sophie et HOCQUETTE Jean-François, « Le Thésaurus de la viande: un nouvel outil accessible à tous Une nouvelle ressource sémantique répondant aux principes de la science ouverte: le thésaurus de la viande comme outil informatique de dialogue entre les acteurs de la filière », *Viandes & produits carnés*, 4 avril 2022, p. 14.
<https://hal.inrae.fr/hal-03670992/document>
- Thesaurus sur la diaspora canadienne sud-asiatique :
<https://doi.org/10.18357/kula.223>

Quelques sites de référencement

- AgroPortal / Univ de Montpellier, CNRS, Inrae <https://agroportal.lirmm.fr/ontologies>
 - + 160 référentiels et ontologies sur l'agronomie
- BARTOC, Basic Register of Thesauri, Ontologies & Classifications <https://bartoc.org/>
 - Recense + 3400 vocabulaires
- FAIRsharing <https://fairsharing.org/FAIRsharing>
 - Plusieurs milliers de standards, terminologies, formats... tous domaines
- Glossary links / Term Coord (European Parliament, DG TRAD, Terminology coordination) <https://termcoord.eu/glossarylinks/>
 - Recense + 2000 glossaires sur tous les sujets traités par l'UE, évolutif
- Loterre / CNRS-Inist <https://www.loterre.fr/>
- TemaTres / Diego Ferreyra <https://vocabularyserver.com/web/items/browse?collection=1>
 - Recense les utilisateurs de l'application (690)
- Data Geo-science Vocabularies / BRGM <https://data.geoscience.fr/ncl/>