



**HAL**  
open science

# Extraction de contextes riches en connaissances à partir d'un corpus comparable de textes médicaux (français-arabe)

Rim Abouwarda

## ► To cite this version:

Rim Abouwarda. Extraction de contextes riches en connaissances à partir d'un corpus comparable de textes médicaux (français-arabe). 11e Journées Internationales de la Linguistique de Corpus, Jul 2023, Grenoble, France. . hal-04728973

**HAL Id: hal-04728973**

**<https://hal.science/hal-04728973v1>**

Submitted on 9 Oct 2024

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution - NonCommercial - NoDerivatives 4.0  
International License

# Extraction de contextes riches en connaissances à partir d'un corpus comparable de textes médicaux

Rim ABOUWARDA – Doctorante en cotutelle (Université d'Alexandrie / Université Grenoble Alpes)  
rim.abouwarda@univ-grenoble-alpes.fr / rim.abouwarda@alexu.edu.eg

## INTRODUCTION

Les langues de spécialité suscitent actuellement un grand intérêt du fait que les sciences et les techniques connaissent une évolution continue, ce qui est reflété par les besoins linguistiques accrus. La présente analyse, inscrite dans le cadre de notre projet de thèse, est basée sur l'étude d'un corpus comparable de textes médicaux (français-arabe) dans le but de répondre aux besoins d'ordre traductionnel dépendant du contexte. En effet, les sources d'informations auxquelles ont recours les traducteurs sont souvent les dictionnaires ou les glossaires offrant un nombre limité de contextes. Il s'ensuit donc que la consultation des bases de données terminologiques présentant des informations lexicales et conceptuelles est fortement recommandée.

## OBJECTIFS DE L'ÉTUDE

L'étude s'adresse aux traducteurs en tant qu'« utilisateurs prioritaires » de la terminologie (Cabré, 1998). Notre recherche s'est donc fixée comme objectif de fournir aux traducteurs une contextualisation des termes dans les deux langues source et cible leur permettant de mieux saisir le sens des termes et d'en faire un usage à bon escient.

## CADRE THÉORIQUE



Dans la littérature, plusieurs études se sont intéressées à l'identification et à l'extraction des CRC en corpus comparable. Notons, à ce propos, la thèse de Hmida (2017) consacrée à l'étude des patrons de connaissances pour l'identification des définitions dans des corpus comparables portant sur l'oncologie et la volcanologie. Cette étude a mis l'accent sur l'instabilité des marqueurs de relations due à la polysémie. Hypothèse corroborée par d'autres travaux comme Condamines (2002) et Marshman (2014). De plus, les marqueurs conceptuels ont été également étudiés dans une perspective diachronique par Picton (2009) pour définir des marqueurs d'évolution servant à identifier des CRC dans le domaine spatial.

Bien que la littérature sur le sujet soit assez riche, la dimension contrastive axée sur la combinaison linguistique français-arabe n'a pas été explorée. Dans ce sillage, il nous semble donc intéressant de se pencher sur les marqueurs lexico-syntaxiques en langue arabe permettant d'identifier des CRC. Pour ce faire, et en se basant sur les études menées sur le sujet, nous avons pu formuler l'hypothèse qu'une variation au niveau des patterns linguistiques entre le français et l'arabe pourrait être observée.

## PROBLÉMATIQUE

Comment, à partir de l'interrogation d'un corpus de textes comparable dans le domaine médical, extraire des contextes définitoires et identifier les marqueurs lexico-syntaxiques dans une perspective contrastive dans les deux langues français et arabe ?

## CORPUS COMPARABLE

Critères	Corpus français	Corpus arabe
Période	2000-2021	1980-2021
Type de documents	Articles scientifiques Manuels de psychiatrie	Ouvrages scientifiques Articles scientifiques
Degré de spécialisation	Rédigés par des experts Destinés à des spécialistes Destinés au grand public	Rédigés par des experts Destinés à des spécialistes Destinés au grand public
Taille	18 revues scientifiques (n° de 2000 à 2021) + 7 manuels de psychiatrie	20 ouvrages scientifiques + 5 revues scientifiques (n° de 2014 à 2021)
Format	XML et TXT	TXT

## CADRE MÉTHODOLOGIQUE



Extraction des contextes définitoires en français: liste MAR-EL pour les marqueurs conceptuels (Lefevre, 2017)



Traitement outillé du corpus: le Lexicoscope (Kraif, 2019)



Absence d'une liste existante de marqueurs linguistiques en arabe: Extraction et analyse des contextes où apparaissent les candidats-termes grâce aux patterns productifs prédéfinis dans le cadre de notre thèse sur la base d'une liste de fréquence de référence.

Il nous revient de noter que Lehmann et Martin-Berthet (2008) ont classé les types de contextes en trois catégories : définitoires, encyclopédiques et linguistiques. Nous nous focalisons, aux fins de notre analyse, sur les contextes définitoires renfermant des éléments permettant de se renseigner sur la signification du terme.

## ANALYSES ET RÉSULTATS

• Convergences dans l'emploi de certains marqueurs linguistiques:

Français	Terme + V. être +	Déterminant Nom +	+ Caractérisé(e) par
Arabe	المصطلح + هو +	اسم نكرة +	ب يتميز +

□ La schizophrénie est une affection caractérisée par un ensemble de signes particuliers, incluant des idées délirantes, des hallucinations, un discours désorganisé, (...)

□ اضطراب وجداني ثنائي قطبي هو اضطراب يتميز بنوبات متكررة يضرب فيها مزاج الشخص ومستوى نشاطه بشكل عميق.

اضطراب وجداني ثنائي قطبي	هو اضطراب يتميز ب	اضطراب	ب	توب	متكررة	ب	ب	مزاج	الشخص و	مستوى	نشاطه	بشكل عميق		
Le trouble affectif bipolaire	est un trouble caractérisé par	une	trouble	des	récurrentes	crises	qui	trouble	l'individu	de	son	niveau	d'activité	profondément

• Prédominance des indices typo-dispositionnel comme « : » dans le corpus arabe:

□ اضطراب التوافق: هي حالات من الضيق الذاتي والضيق الانفعالي (...)

اضطراب التوافق	هي	حالات	من	الضيق	الذاتي	و	الضيق	الانفعالي	
Le trouble d'adaptation :	des	états	de	malaise	personnel	et	du	malaise	émotionnel

• Emploi du mot « التعريف » (la définition) précédant le contexte définitoire :

□ الهذيان الارتعاشي: التعريف: هو مرض عقلي ذهاني ونوع خاص من الهذيان الحاد (...)

الهذيان الارتعاشي: التعريف:	هو	مرض	عقلي	ذهاني	و	نوع	خاص	من	الهذيان	الحاد
Le delirium tremens	est	une	maladie	déli	et	typ	de	grave	déli	grave

• Emploi plus fréquent des indices lexicaux « comme, c'est-à-dire » dans le corpus français:

□ L'autisme est défini comme une maladie complexe du développement du SNC et est associé à une étiologie multifactorielle.

□ L'anorexie mentale chez les adolescentes se présente comme un syndrome qui associe simultanément ou progressivement : une perte d'appétit ; un amaigrissement ; l'arrêt des règles (aménorrhée) ; (...)

□ La survenue d'attaques de panique régulières peut aussi conduire à l'installation d'une agoraphobie, c'est-à-dire la crainte de se trouver dans un lieu ou une situation d'où il sera impossible de s'échapper en cas de survenue d'une attaque de panique.