

# *Outils de veille : typologie*

**Claire FRANCOIS**  
**Unité de recherche et Innovation**  
**INIST / CNRS**

# Plan

---

- Introduction
- Les grands types d'outils de veille
- Les différentes fonctionnalités
- Les technologies mises en œuvre
- 2 exemples : Stanalyst<sup>®</sup> et Leximine

# Introduction

---

- Veille : différents besoins selon étapes du processus
  - Recherche d'information et surveillance
  - Collecte et gestion
  - Analyse :
    - Textuelle
    - Bibliométrie
    - Infométrie
    - Visualisation
  - itérations et interactions

# Types d'outils de veille

---

- Recherche d'information
  - Bases de données ,
  - Internet :
    - portails, annuaires
    - Moteurs de recherche, Agents intelligents
- Surveillance
  - Outils de surveillance des différentes sources
  - Outils de push
- Gestion documentaire et gestion des connaissances
- Exploration du contenu :
  - Analyse texte
  - Classification et Cartographie
  - Évolutions temporelles
- Systèmes complets de gestion de l'information

Keywatch  
ApertoLibro

# Méthodes utilisées

---

- **Bibliométrie**
  - différents modes de représentation des résultats
- **Analyse textuelle**
  - requêtes et textes collectés
  - Statistique ou linguistique
- **Infométrie**
  - Classement ou catégorisation
  - Classification automatique
  - Evolution temporelle
- **Visualisation de l'information**
  - Arborescence
  - graphes
  - Cartographie

# *Les méthodes bibliométriques*

Exemples :

Tétralogie, WordMapper, Simbad,  
Stanalyst

## Quelles analyses ?


Construire des tableaux de répartition des références selon un ou plusieurs critères

Type d'Information	Type d'Analyse
<b>Mots-clés, titres et résumés des documents</b> <b>Code de classement</b>	<b>Analyse de contenu</b>
<b>Auteurs</b> <b>Affiliations (Établissement, pays)</b>	<b>Analyse des acteurs et de leurs relations</b>
<b>Type de document : revues, rapports, communications de congrès</b> <b>Pays éditeur</b> <b>Langue de communication</b>	<b>Analyse de leurs moyens de communication</b>
<b>Date de publication</b>	<b>Analyse de l'évolution de l'activité de différents domaines</b>

# Les lois bibliométriques

- **Bradford** : productivité des revues scientifiques

- Une relative petite proportion de périodiques peut satisfaire la requête d'une grande proportion d'articles.
- Permet de de déterminer le noyau des périodiques qui cernent le mieux le sujet



- **Lotka** : productivité des auteurs

- Il y a, par rapport au nombre d'auteurs qui publient un article,  $n^2$  fois moins d'auteurs qui publient  $n$  articles.

- **Zipf** : répartition des mots-clés

- Principe du moindre effort, on utilise plus facilement des mots familiers que des mots inhabituels

# *Analyse textuelle*

# *Approches statistiques*

---

- Traitements de l'ématisation
- Fréquence et cooccurrence des termes
- Segments répétés
- Utilisation de ressources terminologiques :
  - Dictionnaires de mots vides,
  - Dictionnaires d'équivalence,
- Outils :
  - Alceste, Tétralogie, WordMapper, Sphynx Lexica ...

# Approches linguistiques (1)

---

- Utilisation de ressources terminologiques :
  - Reconnaissance des termes sous la forme d'origine ou sous des formes variantes
- Analyse des phrases :
  - basée sur les patrons syntaxiques et marqueurs linguistiques
- Analyse sémantique
- Résumé ou traduction automatique
  - Ex : Leximine, DigOut4U, Pertimm, Tropes, Insight Discoverer

## *Les variantes flexionnelles*

---

- **La variation flexionnelle** permet d'identifier, pour chaque terme, les formes singulier / pluriel des noms

Anglais	Français
<i>bacterium/bacteria</i>	<i>cheval/chevaux</i>
<i>activity/activities</i>	<i>eau/eaux</i>
	<i>corail/coraux</i>

# Les variantes syntaxiques (1)

---

- Variation d'insertion :
  - ajout de tout mot à l'intérieur du groupe nominal
    - *structural erm genes* -> *Structural genes*
    - *Système racinaire de surface* -> *Système de surface*
- Variation de coordination :
  - formes coordonnées de mots (adjectifs ou noms) à l'intérieur du groupe nominal
    - *structural and regulatory genes* -> *Structural genes*
    - *gène de régulation et de structure* -> *Gène de structure*

## ***Les variantes syntaxiques (2)***

---

- **Variation de permutation :**
  - **tout mot ou groupes de mots pouvant permuter autour d'un élément pivot (prépositions ou séquences verbales) :**
    - *mechanism of clarithromycin resistance -> Resistance mechanism*
    - Quasi-inexistante pour le français

# ***Variantes morpho-derivatives***

---

- Propriétés linguistiques de mots pouvant être dérivés en d'autres mots de catégories grammaticales différentes :
  - ***abdomen /abdominal***
    - dérivations nom adjectif
  - ***abort/abortion***
    - dérivation verbe nom
  - ***Rare species ->rarely encountered enterococcus species***
    - dérivation de l'adjectif *rare* en adverbe : *rarely*,
    - insertion de *encountered enterococcus*
  - ***Variation de alimentation -> Alimentation hydrique d'un arbre varie***
    - dérivation du nom *variation* en verbe *varie*

## ***Exemple : Processus ILC (1)***

---

- Le traitement automatique des ressources terminologiques :
  - étiquetage grammatical du lexique (TreeTagger)
  - création/utilisation de ressources morpho-dérivationnelle à partir des mots du lexiques
  - formatage des lexiques en règles *PATRII*
    - règles sur les mots et règles sur les termes
  - compilation des lexiques en *PATRII* par l'analyseur *FASTR*

## ***Exemple : Processus ILC (2)***

---

- **Le traitement du corpus**
  - **étiquetage grammatical du corpus (TreeTagger)**
  - ***PATRII***
  - **indexation du corpus**

# *Infométrie*

# *Classement - classification*

---


- **Classement ou catégorisation**
  - Mode supervisé
  - Affectation des documents dans une arborescence
  - Ex : Exalead, Vivisimo, ...
- **Classification automatique**
  - Méthodes d'analyse de données
  - Méthodes neuronales

# Analyse de données (1)

---

- **Méthodes factorielles**
  - **Produisent des représentations graphiques permettant de positionner les objets sur un plan**  
= réduction dimensionnelle
  - **Les composantes des axes factoriels**  
= la solution d'une équation mathématique
- **Méthodes de classification**
  - **Produisent des classes permettant de grouper les objets à décrire**
  - **Définissent les classes à partir d'une formulation**

# Analyse de données (2)



# *Classification automatique*

---

- **Mots associés**
  - Distance : cooccurrence entre descripteurs
  - Classification hiérarchique
  - Ex : Leximine, WordMapper, SDOC
- **K-means axiales**
  - Classification non hiérarchique
  - Ex : CartoWeb, Neurodoc
- **SOM : cartes auto-adaptatives de Kohonen**
  - Méthode neuronale : apprentissage compétitif,
  - Contraintes topographiques
  - Ex : Websom, MultiSom

# *Evolution temporelle*

---

- Courbe de suivi dans le temps d'un sujet ou d'un terme
  - Ex : Péricles, Leximine
- Evolution entre 2 analyses à T et T+1
  - WordMapper
- Distinction des thèmes émergents, stabilisés et déclinants.
  - Calliope

# *Visualisation*


# Approches utilisées

---


- Arborescence
  - Ex : Exalead, Vivisimo
- Graphes des classes, réseaux
  - Ex : Leximine, Wordmapper, Tétralogie
  - moteurs Webbrain, kartoo, Mapstan
- Cartographies :
  - Analyses factorielles
    - Ex : Tétralogie, CartoWeb, Neurodoc,
  - Centralité, densité, ex : Sdoc
  - Cartographie par pavage , ex : Miner 3D, Map.net

# Mots associés : graphe de cluster

Classe : cysteine endopeptidase




# WordMapper



# MapStanSearch


Cartographie de sites, capitalisation des requêtes des autres internautes.



<http://search.mapstan.net/fr>

# Webbrain

Navigation  
dans une  
hiérarchie de  
concepts




[http://www.webbrain.com/html/default\\_win.html](http://www.webbrain.com/html/default_win.html)

# *Les méthodes factorielles*

---

- Analyse en Composantes principales
  - **S'applique aux tableaux de mesures**
    - Objets \* caractères quantitatifs
- Analyse factorielle des Correspondances
  - **S'applique aux tableaux de contingence**
    - Caractères qualitatifs \* Caractères qualitatifs
    - Ce tableau contient des effectifs
- Analyse factorielle discriminante
  - **Expliquer un caractère qualitatif par un ensemble de caractères quantitatifs.**

# Exemple d'ACP




Neurodoc



# Mots associés : cartographie

Densité : moyenne des associations internes




SDOC

Centralité : moyenne des associations externes

# mimer3D

Visualisation des sites sous un pavage 3D coloré




<http://www.mimer3d.com>

Rencontres des professionnels de l'IST, 19 juin 2003, PARIS

# Map.net (1)

Navigation  
dans les  
classes de  
premier  
niveau

Requête :  
linguistique




<http://maps.map.net>

Rencontres des professionnels de l'IST, 19 juin 2003, PARIS

# Map.net (2)

Navigation  
 dans les  
 sous-classes  
 d'une classe  
 premier  
 niveau :  
 la catégorie  
 informatique



Intégré dans le site  
 de PubMed

# Kartoo

Métamoteur,  
Cartographie  
de sites



<http://www.kartoo.com>

Rencontres des professionnels de l'IST, 19 juin 2003, PARIS

# WebMap

**Progress**

A/C	Ticker	Symbol	House	Position	Filled	Remaining
<input type="checkbox"/>	WCOM	2222000	123000	12000		
<input type="checkbox"/>	BUD	1002300	12456	3456		
<input type="checkbox"/>	MSFT	3000000	2000000	1000000		
<input type="checkbox"/>	MCST	3000000	2000000	1000000		
<input type="checkbox"/>	DK	2345000	12345	1234		
<input type="checkbox"/>	TXN	2000000	100000	34560		
<input type="checkbox"/>	DIS	4000000	1900000	1200		

**Manager Trader**

Display

- Order Velocity
- Buy Only  Sell Only
- Depth Of Interest
- Relative Volume

Enter Stock Symbol:

Symbol	Last	Qty	Bid	Ask	High	Low	Traded
GE	36.400	15	36.30	36.40	1x2	80	37.090 36.299 16:30
GT	18.639	600			2		18.820 18.630 15:48
DD	40.099	200			0		40.460 40.099 15:42
MMM	36.400	15	36.30	36.40	1x2	80	37.090 36.299 16:30

