

Influence des domaines de spécialité dans l'extraction de termes-clés

Adrien Bougouin Florian Boudin Béatrice Daille

Université de Nantes, LINA

2 Juillet 2014



Introduction

Contexte

Termes-clés (mots-clés)

- Mots ou expressions polylexicales
- Aperçu d'un document
- Donnés par les auteurs, des lecteurs ou des documentalistes

Applications

- Indexation de documents
- Expansion de requêtes
- Résumé automatique
- Ciblage (*marketing*)
- Classification de documents
- etc.

Introduction

Contexte

Termes-clés (mots-clés)

- Mots ou expressions polylexicales
- Aperçu d'un document
- Donnés par les auteurs, des lecteurs ou des documentalistes

Applications

- Indexation de documents
- Expansion de requêtes
- Résumé automatique
- Ciblage (*marketing*)
- Classification de documents
- etc.

Introduction

Contexte

Termes-clés (mots-clés)

- Mots ou expressions polylexicales
- Aperçu d'un document
- Donnés par les auteurs, des lecteurs ou des **documentalistes**

Applications

- **Indexation de documents**
- Expansion de requêtes
- Résumé automatique
- Ciblage (*marketing*)
- Classification de documents
- etc.

Introduction

Contexte (suite)

Indexation de documents scientifiques

Création de notices bibliographiques :

- Titre
- Auteurs
- Résumé
- Codes de classement
- **Descripteurs conceptuels** \Leftrightarrow **termes-clés**

Introduction

Exemple

Variabilité du **Gravettien** de Kostienki (bassin moyen du Don) et des territoires associés

Dans la région de Kostienki-**Borschevo**, on observe l'expression, à ce jour, la plus orientale du modèle européen de l'évolution du **Paléolithique supérieur**. Elle est différente à la fois du modèle Sibérien et du modèle de l'Asie centrale. Comme ailleurs en **Europe**, le **Gravettien** apparaît à Kostienki vers 28 ka (Kostienki 8 /II/). Par la suite, entre 24-20 ka, les techno-complexes **gravettiens** sont représentés au moins par quatre faciès dont deux, ceux de Kostienki 21/III/ et Kostienki 4 /II/, ressemblent au **Gravettien** occidental et deux autres, Kostienki-**Avdevo** et Kostienki 11/II/, sont des faciès propres à l'**Europe** de l'Est, sans analogie à l'Ouest.

Descripteurs (termes-clés) : Europe, Kostienko, Borschevo, variation, typologie, industrie osseuse, industrie lithique, Europe centrale, Avdevo, Paléolithique supérieur, Gravettien.

Archéologie

Introduction

Problématique

Mais...

L'assignation de termes-clés est une tâche coûteuse.
⇒ Il faut extraire les termes-clés automatiquement.

Extraction automatique de termes-clés

- Supervisée/**non-supervisée**
- Extraction des termes-clés **contenus** dans le titre/résumé
- Terme-clé = unité textuelle **importante** dans le titre/résumé
 - ▶ Fréquente et spécifique (TF-IDF)
 - ▶ Centrale (Mihalcea et Tarau, 2004, TextRank)

Introduction

Problématique

Mais...

L'assignation de termes-clés est une tâche coûteuse.
⇒ Il faut extraire les termes-clés automatiquement.

Extraction automatique de termes-clés

- Supervisée/**non-supervisée**
- Extraction des termes-clés **contenus dans** le titre/résumé
- Terme-clé = unité textuelle **importante** dans le titre/résumé
 - ▶ Fréquente et spécifique (TF-IDF)
 - ▶ Centrale (Mihalcea et Tarau, 2004, TextRank)

Introduction

Hypothèse

Il est plus difficile d'extraire les termes-clés pour certaines disciplines que pour d'autres.

⇒ Quels sont les facteurs qui influent sur cette difficulté ?

Plan

- 1 Données
- 2 Extraction de termes-clés
- 3 Expérience
- 4 Conclusion et perspectives

Plan

- 1 Données
- 2 Extraction de termes-clés
- 3 Expérience
- 4 Conclusion et perspectives

Données

■ Cinq disciplines :

- ▶ Archéologie
- ▶ Linguistique
- ▶ Sciences de l'information
- ▶ Psychologie
- ▶ Chimie

■ Entre 700 et 800 notices par discipline :

- ▶ Titre
- ▶ Résumé
- ▶ Descripteurs (termes-clés de références)
 - Contrôlés : appartenant au vocabulaire de la discipline
 - Non-contrôlés : choisis librement

Données

■ Cinq disciplines :

- ▶ Archéologie
- ▶ Linguistique
- ▶ Sciences de l'information
- ▶ Psychologie
- ▶ Chimie

■ Entre 700 et 800 notices par discipline :

- ▶ Titre
- ▶ Résumé
- ▶ Descripteurs (termes-clés de références)
 - Contrôlés : appartenant au vocabulaire de la discipline
 - Non-contrôlés : choisis librement

Données (suite)

	Archéologie	Linguistique	Sciences de l'information	Psychologie	Chimie
Notices	718	715	706	720	782
Mots/doc.	219,1	156,7	119,7	185,7	105,2
Termes-clés/doc.	16,6	8,0	8,5	11,6	12,8
Mots/terme-clé	1,3	1,8	1,7	1,6	2,2
Diversité des termes-clés	25,5 %	23,0 %	25,0 %	17,4 %	40,6 %
Termes-clés contrôlés	79,8 %	86,9%	85,8 %	90,9%	83,0 %
Termes-clés non contrôlés	20,2 %	13,1%	14,2 %	9,1%	17,0 %
Termes-clés extractibles (Rappel max.)	62,9 %	38,8 %	32,4 %	27,1 %	23,7 %

- Peu de contenu
- Différence d'organisation du discours
- Différence de complexité des termes-clés
- Diversité plus importante en chimie
- Difficulté a priori très importante

Données (suite)

	Archéologie	Linguistique	Sciences de l'information	Psychologie	Chimie
Notices	718	715	706	720	782
Mots/doc.	219,1	156,7	119,7	185,7	105,2
Termes-clés/doc.	16,6	8,0	8,5	11,6	12,8
Mots/terme-clé	1,3	1,8	1,7	1,6	2,2
Diversité des termes-clés	25,5 %	23,0 %	25,0 %	17,4 %	40,6 %
Termes-clés contrôlés	79,8 %	86,9%	85,8 %	90,9%	83,0 %
Termes-clés non contrôlés	20,2 %	13,1%	14,2 %	9,1%	17,0 %
Termes-clés extractibles (Rappel max.)	62,9 %	38,8 %	32,4 %	27,1 %	23,7 %

- Peu de contenu
- Différence d'organisation du discours
- Différence de complexité des termes-clés
- Diversité plus importante en chimie
- Difficulté a priori très importante

Données (suite)

Variabilité du Gravettien de Kostienki (bassin moyen du Don) et des territoires associés

Dans la région de Kostienki-Borschevo, on observe l'expression, à ce jour, la plus orientale du modèle européen de l'évolution du Paléolithique supérieur. Elle est différente à la fois du modèle Sibérien et du modèle de l'Asie centrale. Comme ailleurs en Europe, le Gravettien apparaît à Kostienki vers 28 ka (Kostienki 8 /II/). Par la suite, entre 24-20 ka, les techno-complexes gravettiens sont représentés au moins par quatre faciès dont deux, ceux de Kostienki 21/III/ et Kostienki 4 /II/, ressemblent au Gravettien occidental et deux autres, Kostienki-Avdeevo et Kostienki 11/II/, sont des faciès propres à l'Europe de l'Est, sans analogie à l'Ouest.

Descripteurs (termes-clés) : Europe, Kostienko, Borschevo, variation, typologie, industrie osseuse, industrie lithique, Europe centrale, Avdeevo, Paléolithique supérieur, Gravettien.

Archéologie

Etude d'un condensat acide isocyanurique-urée-formaldéhyde

La synthèse d'un condensat acide isocyanurique-urée-formaldéhyde utilisant la pyridine en tant que solvant a été effectuée par réaction sonochimique.

Descripteurs (termes-clés) : Réaction sonochimique, hétérocycle azote, cycle 6 chaînons, ether.

Chimie

Données (suite)

	Archéologie	Linguistique	Sciences de l'information	Psychologie	Chimie
Notices	718	715	706	720	782
Mots/doc.	219,1	156,7	119,7	185,7	105,2
Termes-clés/doc.	16,6	8,0	8,5	11,6	12,8
Mots/terme-clé	1,3	1,8	1,7	1,6	2,2
Diversité des termes-clés	25,5 %	23,0 %	25,0 %	17,4 %	40,6 %
Termes-clés contrôlés	79,8 %	86,9%	85,8 %	90,9%	83,0 %
Termes-clés non contrôlés	20,2 %	13,1%	14,2 %	9,1%	17,0 %
Termes-clés extractibles (Rappel max.)	62,9 %	38,8 %	32,4 %	27,1 %	23,7 %

- Peu de contenu
- Différence d'organisation du discours
- Différence de complexité des termes-clés
- Diversité plus importante en chimie
- Difficulté a priori très importante

Données (suite)

	Archéologie	Linguistique	Sciences de l'information	Psychologie	Chimie
Notices	718	715	706	720	782
Mots/doc.	219,1	156,7	119,7	185,7	105,2
Termes-clés/doc.	16,6	8,0	8,5	11,6	12,8
Mots/terme-clé	1,3	1,8	1,7	1,6	2,2
Diversité des termes-clés	25,5 %	23,0 %	25,0 %	17,4 %	40,6 %
Termes-clés contrôlés	79,8 %	86,9%	85,8 %	90,9%	83,0 %
Termes-clés non contrôlés	20,2 %	13,1%	14,2 %	9,1%	17,0 %
Termes-clés extractibles (Rappel max.)	62,9 %	38,8 %	32,4 %	27,1 %	23,7 %

- Peu de contenu
- Différence d'organisation du discours
- Différence de complexité des termes-clés
- Diversité plus importante en chimie
- Difficulté a priori très importante

Données (suite)

	Archéologie	Linguistique	Sciences de l'information	Psychologie	Chimie
Notices	718	715	706	720	782
Mots/doc.	219,1	156,7	119,7	185,7	105,2
Termes-clés/doc.	16,6	8,0	8,5	11,6	12,8
Mots/terme-clé	1,3	1,8	1,7	1,6	2,2
Diversité des termes-clés	25,5 %	23,0 %	25,0 %	17,4 %	40,6 %
Termes-clés contrôlés	79,8 %	86,9%	85,8 %	90,9%	83,0 %
Termes-clés non contrôlés	20,2 %	13,1%	14,2 %	9,1%	17,0 %
Termes-clés extractibles (Rappel max.)	62,9 %	38,8 %	32,4 %	27,1 %	23,7 %

- Peu de contenu
- Différence d'organisation du discours
- Différence de complexité des termes-clés
- Diversité plus importante en chimie
- Difficulté a priori très importante

Données (suite)

Variabilité du Gravettien de Kostienki (bassin moyen du Don) et des territoires associés

Dans la région de Kostienki-Borschevo, on observe l'expression, à ce jour, la plus orientale du modèle européen de l'évolution du Paléolithique supérieur. Elle est différente à la fois du modèle Sibérien et du modèle de l'Asie centrale. Comme ailleurs en Europe, le Gravettien apparaît à Kostienki vers 28 ka (Kostienki 8 /II/). Par la suite, entre 24-20 ka, les techno-complexes gravettiens sont représentés au moins par quatre faciès dont deux, ceux de Kostienki 21/III/ et Kostienki 4 /II/, ressemblent au Gravettien occidental et deux autres, Kostienki-Avdeevo et Kostienki 11/II/, sont des faciès propres à l'Europe de l'Est, sans analogie à l'Ouest.

Descripteurs (termes-clés) : Europe, Kostienko, Borschevo, variation, typologie, industrie osseuse, industrie lithique, Europe centrale, Avdeevo, Paléolithique supérieur, Gravettien.

Archéologie

Etude d'un condensat acide isocyanurique-urée-formaldéhyde

La synthèse d'un condensat acide isocyanurique-urée-formaldéhyde utilisant la pyridine en tant que solvant a été effectuée par réaction sonochimique.

Descripteurs (termes-clés) : Réaction sonochimique, hétérocycle azote, cycle 6 chaînons, ether.

Chimie

Données (suite)

	Archéologie	Linguistique	Sciences de l'information	Psychologie	Chimie
Notices	718	715	706	720	782
Mots/doc.	219,1	156,7	119,7	185,7	105,2
Termes-clés/doc.	16,6	8,0	8,5	11,6	12,8
Mots/terme-clé	1,3	1,8	1,7	1,6	2,2
Diversité des termes-clés	25,5 %	23,0 %	25,0 %	17,4 %	40,6 %
Termes-clés contrôlés	79,8 %	86,9%	85,8 %	90,9%	83,0 %
Termes-clés non contrôlés	20,2 %	13,1%	14,2 %	9,1%	17,0 %
Termes-clés extractibles (Rappel max.)	62,9 %	38,8 %	32,4 %	27,1 %	23,7 %

- Peu de contenu
- Différence d'organisation du discours
- Différence de complexité des termes-clés
- Diversité plus importante en chimie
- Difficulté a priori très importante

Données (suite)

	Archéologie	Linguistique	Sciences de l'information	Psychologie	Chimie
Notices	718	715	706	720	782
Mots/doc.	219,1	156,7	119,7	185,7	105,2
Termes-clés/doc.	16,6	8,0	8,5	11,6	12,8
Mots/terme-clé	1,3	1,8	1,7	1,6	2,2
Diversité des termes-clés	25,5 %	23,0 %	25,0 %	17,4 %	40,6 %
Termes-clés contrôlés	79,8 %	86,9%	85,8 %	90,9%	83,0 %
Termes-clés non contrôlés	20,2 %	13,1%	14,2 %	9,1%	17,0 %
Termes-clés extractibles (Rappel max.)	62,9 %	38,8 %	32,4 %	27,1 %	23,7 %

- Peu de contenu
- Différence d'organisation du discours
- Différence de complexité des termes-clés
- Diversité plus importante en chimie
- Difficulté a priori très importante

Données (suite)

	Archéologie	Linguistique	Sciences de l'information	Psychologie	Chimie
Notices	718	715	706	720	782
Mots/doc.	219,1	156,7	119,7	185,7	105,2
Termes-clés/doc.	16,6	8,0	8,5	11,6	12,8
Mots/terme-clé	1,3	1,8	1,7	1,6	2,2
Diversité des termes-clés	25,5 %	23,0 %	25,0 %	17,4 %	40,6 %
Termes-clés contrôlés	79,8 %	86,9%	85,8 %	90,9%	83,0 %
Termes-clés non contrôlés	20,2 %	13,1%	14,2 %	9,1%	17,0 %
Termes-clés extractibles (Rappel max.)	62,9 %	38,8 %	32,4 %	27,1 %	23,7 %

- Peu de contenu
- Différence d'organisation du discours
- Différence de complexité des termes-clés
- Diversité plus importante en chimie
- Difficulté a priori très importante

Données (suite)

	Archéologie	Linguistique	Sciences de l'information	Psychologie	Chimie
Notices	718	715	706	720	782
Mots/doc.	219,1	156,7	119,7	185,7	105,2
Termes-clés/doc.	16,6	8,0	8,5	11,6	12,8
Mots/terme-clé	1,3	1,8	1,7	1,6	2,2
Diversité des termes-clés	25,5 %	23,0 %	25,0 %	17,4 %	40,6 %
Termes-clés contrôlés	79,8 %	86,9%	85,8 %	90,9%	83,0 %
Termes-clés non contrôlés	20,2 %	13,1%	14,2 %	9,1%	17,0 %
Termes-clés extractibles (Rappel max.)	62,9 %	38,8 %	32,4 %	27,1 %	23,7 %


- Peu de contenu
- Différence d'organisation du discours
- Différence de complexité des termes-clés
- Diversité plus importante en chimie
- Difficulté a priori très importante

Plan

- 1 Données
- 2 Extraction de termes-clés
- 3 Expérience
- 4 Conclusion et perspectives


Extraction de termes-clés

Chaîne de traitements




Extraction de termes-clés

Chaîne de traitements




Extraction de termes-clés

Chaîne de traitements




Extraction de termes-clés

Chaîne de traitements



Extraction de termes-clés



Extraction de termes-clés

Sélection des candidats

Deux approches classiques :

- Extraction des n-grammes
 - ▶ $n \subseteq \{1..3\}$
 - ▶ Filtrage avec un anti-dictionnaire
 - ▶ Sursélection des candidats \Rightarrow faible qualité
- Reconnaissance de formes
 - ▶ (NOM | ADJ)+

Une approche non explorée jusqu'alors :

- Extraction des candidats termes
 - ▶ Utilisation de TermSuite
 - ▶ Formes très précises :
 - NOM à NOM
 - NOM en NOM
 - NOM à NOM ADJ
 - etc.

Extraction de termes-clés

Sélection des candidats

Deux approches classiques :

- Extraction des n-grammes
 - ▶ $n \subseteq \{1..3\}$
 - ▶ Filtrage avec un anti-dictionnaire
 - ▶ Sursélection des candidats \Rightarrow faible qualité
- Reconnaissance de formes
 - ▶ (NOM | ADJ)+

Une approche non explorée jusqu'alors :

- Extraction des candidats termes
 - ▶ Utilisation de TermSuite
 - ▶ Formes très précises :
 - NOM à NOM
 - NOM en NOM
 - NOM à NOM ADJ
 - etc.


Extraction de termes-clés

Sélection des candidats — Exemples

« *bassin moyen du Don* »

{1..3}-grammes	(NOM ADJ)+	Candidats termes
« <i>bassin</i> »	« <i>bassin moyen</i> »	« <i>bassin moyen du Don</i> »
« <i>moyen</i> »	« <i>Don</i> »	↔ « <i>bassin</i> »
« <i>Don</i> »		↔ « <i>moyen</i> »
« <i>bassin moyen</i> »		↔ « <i>Don</i> »
« <i>moyen du Don</i> »		↔ « <i>bassin moyen</i> »

Extraction de termes-clés



Extraction de termes-clés

TF×IDF

Hypothèse

Dans une notice, un mot est d'autant plus important qu'il y est fréquent (TF) et spécifique (IDF).

$$\text{importance}(\text{candidat}) = \sum_{\text{mot} \in \text{candidat}} \text{TF} \times \text{IDF}(\text{mot})$$

Extraction de termes-clés

TopicRank

Hypothèses

- 1 Plusieurs candidats désignent le même sujet (concept)
- 2 Seul le candidat le plus représentatif du sujet doit être extrait
- 3 Les sujets qui cooccurrent se recommandent mutuellement :
 - ▶ Plus un sujet cooccure avec d'autres sujets, plus il est important
 - ▶ Plus un sujet est important, plus les sujets avec lesquels il cooccure sont important

Plan

- 1 Données
- 2 Extraction de termes-clés
- 3 Expérience
- 4 Conclusion et perspectives

Expérience

Configuration

■ Cinq disciplines :

- ▶ Archéologie
- ▶ Linguistique
- ▶ Sciences de l'information
- ▶ Psychologie
- ▶ Chimie

■ Six systèmes d'extraction de termes-clés

- ▶ {1..3}-grammes \rightarrow TF \times IDF
- ▶ (NOM | ADJ)+ \rightarrow TF \times IDF
- ▶ Candidats termes \rightarrow TF \times IDF
- ▶ {1..3}-grammes \rightarrow TopicRank
- ▶ (NOM | ADJ)+ \rightarrow TopicRank
- ▶ Candidats termes \rightarrow TopicRank

Expérience

Configuration

■ Cinq disciplines :

- ▶ Archéologie
- ▶ Linguistique
- ▶ Sciences de l'information
- ▶ Psychologie
- ▶ Chimie

■ Six systèmes d'extraction de termes-clés

- ▶ {1..3}-grammes \rightarrow TF \times IDF
- ▶ (NOM | ADJ)+ \rightarrow TF \times IDF
- ▶ Candidats termes \rightarrow TF \times IDF
- ▶ {1..3}-grammes \rightarrow TopicRank
- ▶ (NOM | ADJ)+ \rightarrow TopicRank
- ▶ Candidats termes \rightarrow TopicRank

Expérience



Mesure d'évaluation

- Évaluation de l'ordonnement des candidats
- MAP (*Mean Average Precision*) :

$$\text{MAP} = \frac{1}{\|\text{DOCUMENTS}\|} \sum_{d \in \text{DOCUMENTS}} \frac{\sum_{t \in \text{CORRECTS}_d} \text{précision@rang}_d(t)}{\|\text{REFERENCE}_d\|}$$


Expérience

Résultats et observations



{1..3}-grammes



(NOM | ADJ)+




Candidats termes

Expérience

Résultats et observations



{1..3}-grammes





Candidats termes

(NOM | ADJ)+


- Même échelle de difficulté pour TF-IDF et TopicRank
- Meilleure stabilité du TF-IDF
⇒ Spécificité IDF
- TopicRank dépend de la qualité des candidats

Expérience

Résultats et observations



{1..3}-grammes



Candidats termes

(NOM | ADJ)+

- Même échelle de difficulté pour TF-IDF et TopicRank
- Meilleure stabilité du TF-IDF
⇒ Spécificité IDF
- TopicRank dépend de la qualité des candidats

Expérience

Observations :

- 1 Même échelle de difficulté pour les deux méthodes
- 2 Meilleure stabilité du TF-IDF en fonction de la qualité des candidats
 - ⇒ Les candidats retournés sont les candidats spécifiques
- 3 Plus les candidats sont de bonne qualité, plus TopicRank est compétitif avec TF-IDF

Conclusions :

- 1 Il y a bien une influence de la discipline sur la difficulté de l'extraction de termes-clés
- 2 La présence ou non, dans les termes-clés, de mots à usage courant dans le langage de la discipline est un facteur influent
 - « réaction sonochimique », « réaction électrochimique », etc.
- 3 La cohésion au sein du texte est un facteur influent

Expérience

Observations :

- 1 Même échelle de difficulté pour les deux méthodes
- 2 Meilleure stabilité du TF-IDF en fonction de la qualité des candidats
⇒ Les candidats retournés sont les candidats spécifiques
- 3 Plus les candidats sont de bonne qualité, plus TopicRank est compétitif avec TF-IDF

Conclusions :

- 1 Il y a bien une influence de la discipline sur la difficulté de l'extraction de termes-clés
- 2 La présence ou non, dans les termes-clés, de mots à usage courant dans le langage de la discipline est un facteur influent
→ « réaction sonochimique », « réaction électrochimique », etc.
- 3 La cohésion au sein du texte est un facteur influent

Expérience

Observations :

- 1 Même échelle de difficulté pour les deux méthodes
- 2 Meilleure stabilité du TF-IDF en fonction de la qualité des candidats
 - ⇒ Les candidats retournés sont les candidats spécifiques
- 3 Plus les candidats sont de bonne qualité, plus TopicRank est compétitif avec TF-IDF

Conclusions :

- 1 Il y a bien une influence de la discipline sur la difficulté de l'extraction de termes-clés
- 2 La présence ou non, dans les termes-clés, de mots à usage courant dans le langage de la discipline est un facteur influent
 - « réaction sonochimique », « réaction électrochimique », etc.
- 3 La cohésion au sein du texte est un facteur influent

Expérience

Observations :

- 1 Même échelle de difficulté pour les deux méthodes
- 2 Meilleure stabilité du TF-IDF en fonction de la qualité des candidats
 - ⇒ Les candidats retournés sont les candidats spécifiques
- 3 Plus les candidats sont de bonne qualité, plus TopicRank est compétitif avec TF-IDF

Conclusions :

- 1 Il y a bien une influence de la discipline sur la difficulté de l'extraction de termes-clés
- 2 La présence ou non, dans les termes-clés, de mots à usage courant dans le langage de la discipline est un facteur influent
 - « réaction sonochimique », « réaction électrochimique », etc.
- 3 La cohésion au sein du texte est un facteur influent

Expérience

Variabilité du Gravettien de Kostienki (bassin moyen du Don) et des territoires associés

Dans la région de Kostienki-Borschevo, on observe l'expression, à ce jour, la plus orientale du modèle européen de l'évolution du Paléolithique supérieur. Elle est différente à la fois du modèle Sibérien et du modèle de l'Asie centrale. Comme ailleurs en Europe, le Gravettien apparaît à Kostienki vers 28 ka (Kostienki 8 /II/). Par la suite, entre 24-20 ka, les techno-complexes gravettiens sont représentés au moins par quatre faciès dont deux, ceux de Kostienki 21/III/ et Kostienki 4 /II/, ressemblent au Gravettien occidental et deux autres, Kostienki-Avdeevo et Kostienki 11/II/, sont des faciès propres à l'Europe de l'Est, sans analogie à l'Ouest.

Descripteurs (termes-clés) : Europe, Kostienko, Borschevo, variation, typologie, industrie osseuse, industrie lithique, Europe centrale, Avdeevo, Paléolithique supérieur, Gravettien.

Archéologie

Etude d'un condensat acide isocyanurique-urée-formaldéhyde

La synthèse d'un condensat acide isocyanurique-urée-formaldéhyde utilisant la pyridine en tant que solvant a été effectuée par réaction sonochimique.

Descripteurs (termes-clés) : Réaction sonochimique, hétérocycle azote, cycle 6 chaînons, ether.

Chimie

3 La cohésion au sein du texte est un facteur influent

Expérience

Observations :

- 1 Même échelle de difficulté pour les deux méthodes
- 2 Meilleure stabilité du TF-IDF en fonction de la qualité des candidats
⇒ Les candidats retournés sont les candidats spécifiques
- 3 Plus les candidats sont de bonne qualité, plus TopicRank est compétitif avec TF-IDF

Conclusions :


- 1 Il y a bien une influence de la discipline sur la difficulté de l'extraction de termes-clés
- 2 La présence ou non, dans les termes-clés, de mots à usage courant dans le langage de la discipline est un facteur influent
→ « réaction sonochimique », « réaction électrochimique », etc.
- 3 La cohésion au sein du texte est un facteur influent

Plan

- 1 Données
- 2 Extraction de termes-clés
- 3 Expérience
- 4 Conclusion et perspectives

Conclusion


- La difficulté de l'extraction de termes-clés est liée à la discipline :



- Deux facteurs observés :
 - ▶ Vocabulaire de la discipline
 - ▶ Organisation du discours dans le résumé

Conclusion

- La difficulté de l'extraction de termes-clés est liée à la discipline :



- Deux facteurs observés :
 - ▶ Vocabulaire de la discipline
 - ▶ Organisation du discours dans le résumé

Perspectives

- Élargir notre étude aux articles complets
- Vérifier l'hypothèse de départ avec plus de disciplines
- Mesurer automatiquement la difficulté a priori
- Adapter automatiquement les méthodes selon la difficulté

MERCI

Références

Rada Mihalcea et Paul Tarau : TextRank : Bringing Order Into Texts. In Dekang Lin et Dekai Wu, éditeurs : Proceedings of the 2004 Conference on Empirical Methods in Natural Language Processing, pages 404–411, Barcelona, Spain, July 2004. Association for Computational Linguistics.