



SAIMSI

Suivi Adaptatif Interlingue et Multisource des Informations

Christian Fluhr
GEOLSemantics
christian.fluhr@geolsemantics.com

Comité de pilotage

34 mois
263 p/mois
3,2 M€



labellisé par
le pôle





Le consortium



Les partenaires et leur rôle:



GEOLSemantics est le leader du projet , développe le text mining interlingue, des bases de données textuelles et du traitement de la parole



Cassidian est l'architecte du système basé sur la plate-forme **Weblab**. Il est aussi l'intégrateur des différents modules et en fournit certains



Mondeca est en charge de la construction de la base de connaissance, des raisonnements automatiques, de la gestion et de l'utilisation de la base de connaissance



Le LIP6 est en charge des technologies de reconnaissance de l'auteur ainsi que des méthodes d'évaluation



L'IREENAT est en charge des aspects juridiques et déontologiques du projet SAIMSI

Partenariat : biométrie vocale d'Agnitio, transcription de parole Vocapia research



LES OBJECTIFS DU PROJET

Suivi des activités de personnes soupçonnées d'activités illicites (terrorisme, drogue, blanchiment d'argent, ...),

- à partir de sources ouvertes sur internet : sites webs, presse, réseaux sociaux
- en plusieurs langues (français, anglais, arabe et chinois)
- en deux média texte et parole
- traitement des données en flux



SAIMSI Information workflow

Sources ouvertes sur internet

Google/Yahoo/Bing Whois facebook/myspace /linkedIn/Viadeo RSS

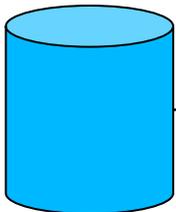
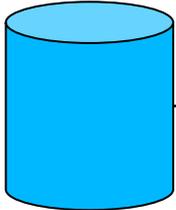
Récupération des informations,
Métamoteur de recherche, crawler, whois, RSS, réseaux sociaux

reformatage, épuration,
Transformation en texte, transcodage en UTF8, production des
métadonnées, reconnaissance de la langue

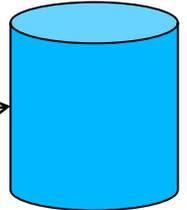
analyse morphosyntaxique
tagging, relations de dépendances, pronoms, négation
Extraction de relations sémantiques dépendant de l'application

Résolution des ambiguïtés sur les personnes, organismes, lieux
inférence de nouvelles relations par raisonnement automatique

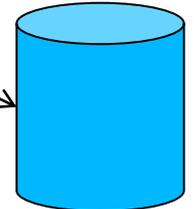
Connaissance linguistique



Base textuelle interlingue

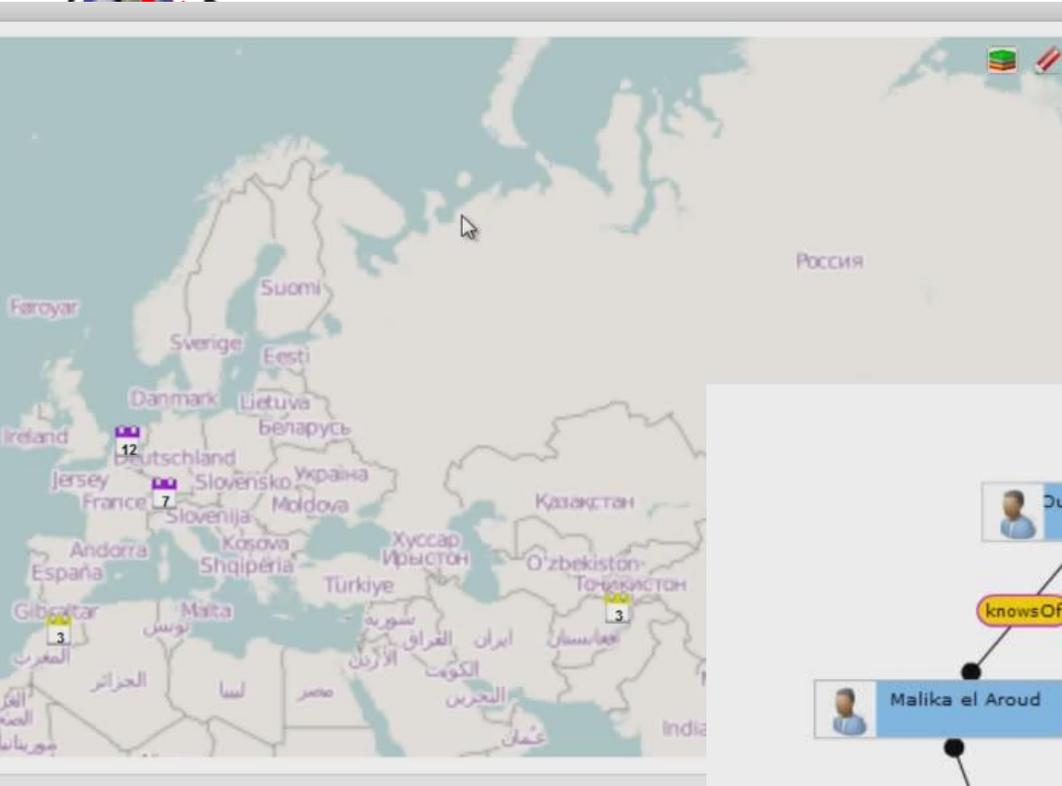


Base de connaissance





Fonctions de SAIMSI

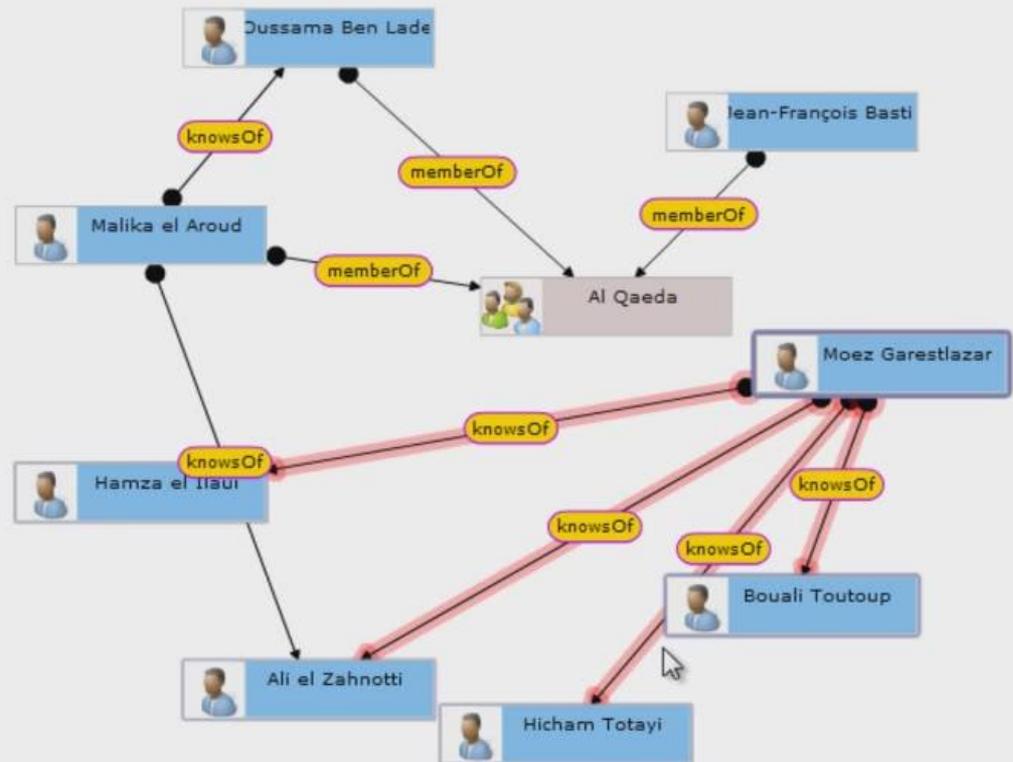
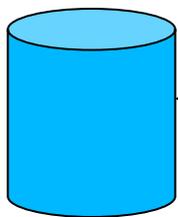


requête

Carte géographiques

timeline

interlingue



Les challenges (verrous)



- Réalisation d'une ontologie large satisfaisant à la fois les besoins des utilisateurs et les contraintes de l'extraction automatique à partir des textes
- Extraction de connaissances basée sur une analyse morphosyntaxique multilingue généraliste profonde et une extraction sémantique liée à l'ontologie de l'application
- Représentation des connaissances indépendantes de la langue source des documents
- Identification de l'auteur d'un texte
- Traitement des textes au fur et à mesure

Les deux cas d'utilisation retenus



Premier cas d'utilisation:

Prescripteur : DCRI

Sujet : les activités jihadistes

Les langues principales concernées: français, anglais, chinois et arabe

La CNIL a autorisé l'utilisation de recherches sur seulement Malika el Aroud et Oussama Ben Laden

DRM intéressée par les fiches biographiques

Deuxième cas d'utilisation:

Prescripteur: OCLCTIC

Sujet: le phishing et les malwares

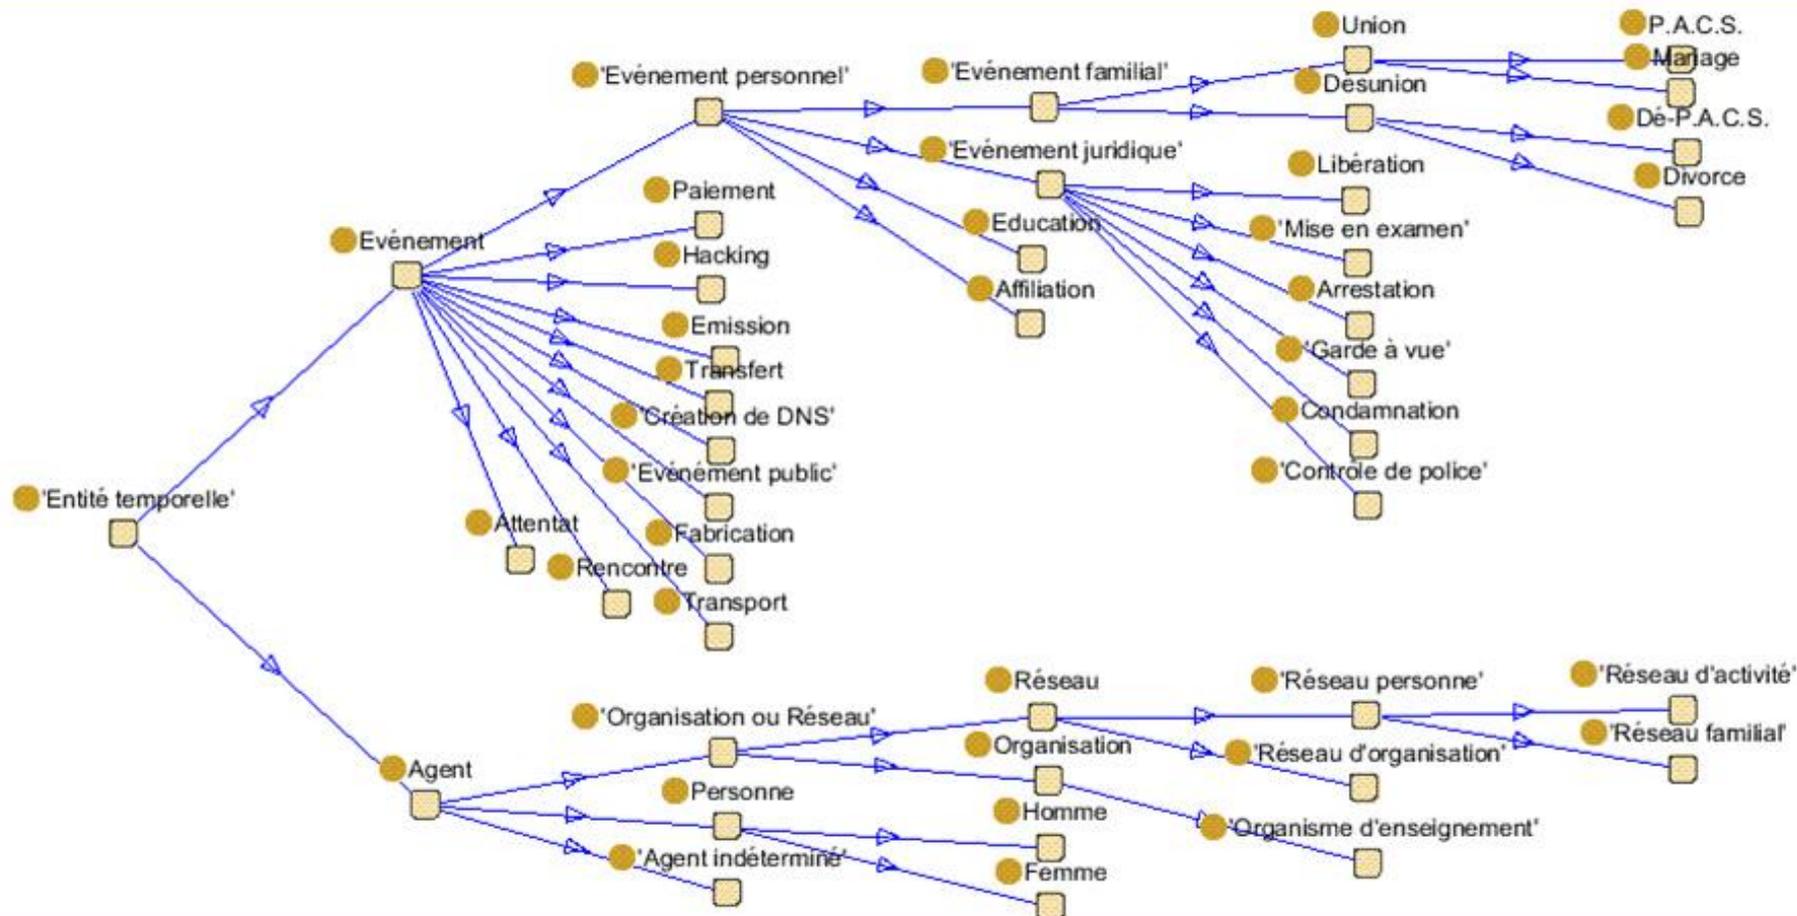
Langues: français, anglais, russe et chinois

Arrêt des développements à cause de la limitation à deux noms par la CNIL.

Une ontologie de la sécurité



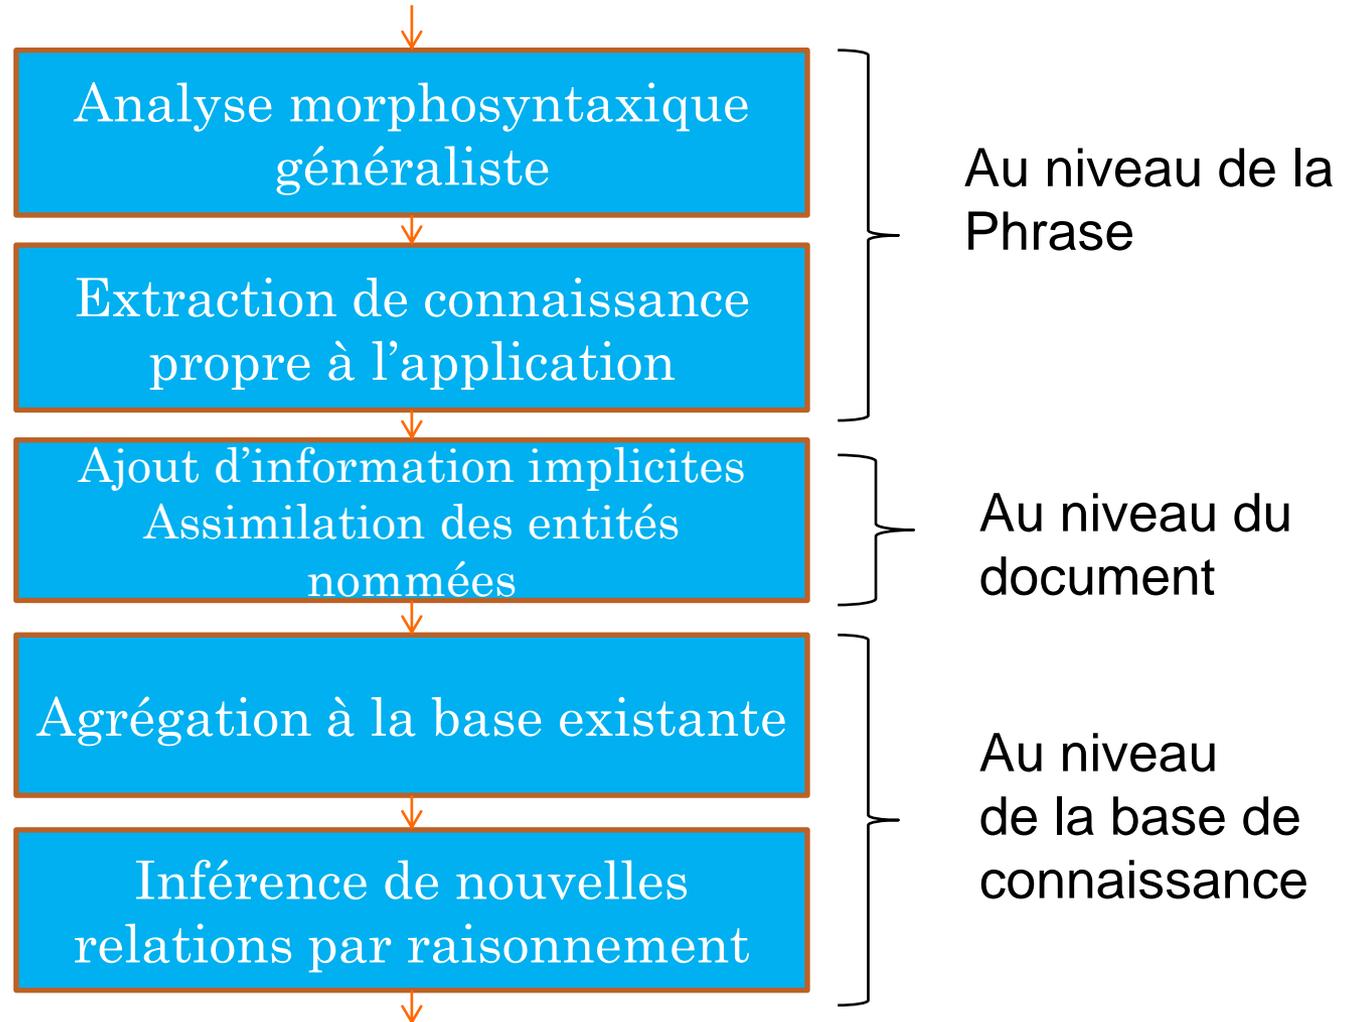
Décrit ce qui peut être cherché à propos de personnes:



rôles dans un organisme, relation comme étudiant dans un organisme d'enseignement.



Les étapes de la constitution de la base de connaissance





Choix d'une stratégie basée sur une analyse morphosyntaxique profonde généraliste

avantages:

- minimiser les résultats faux
- trouver des informations rares qui ne peuvent être rattrapées par la redondance (signaux faibles)
- permet plus facilement de passer d'une application à l'autre

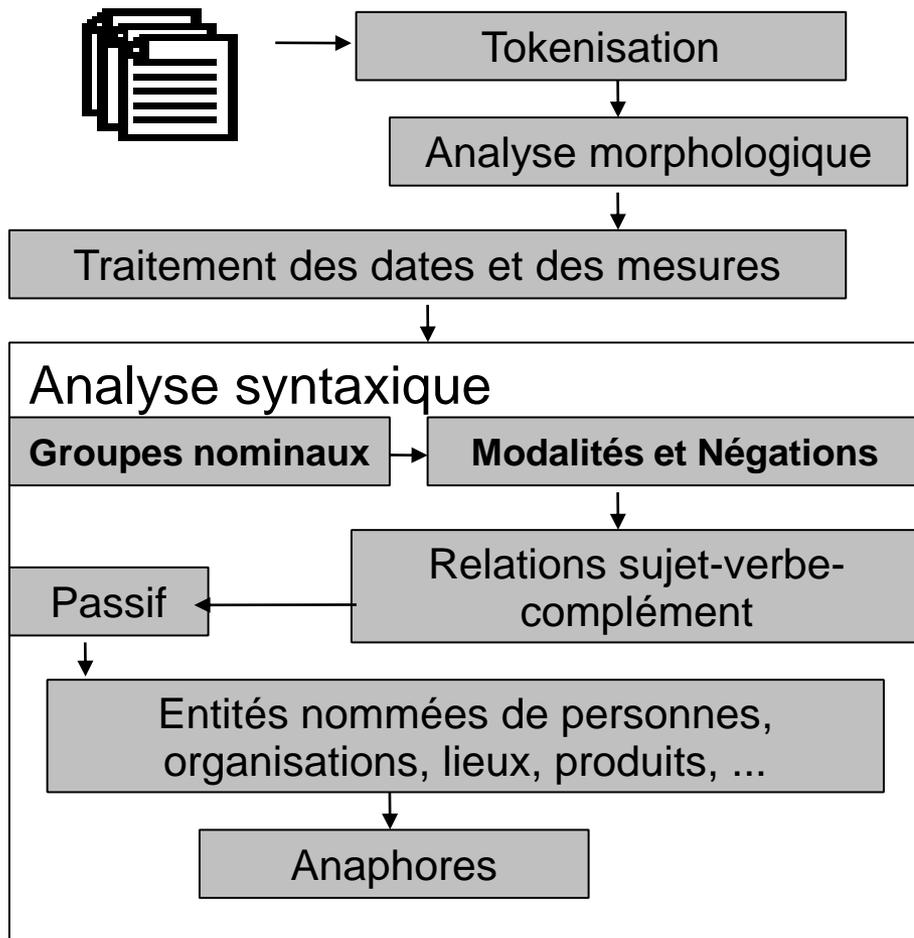
Inconvénients:

- demande plus d'effort de développement pour minimiser les informations non reconnues
- traitement plus lourds

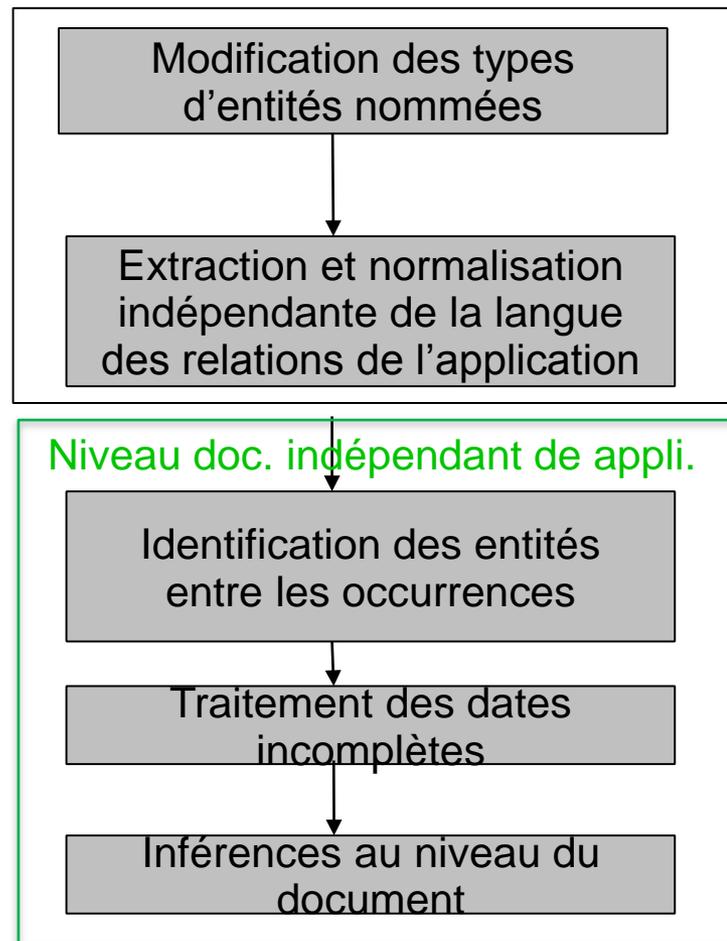
L'extraction de connaissance



Analyse morpho-syntaxique profonde
multilingue indépendante de l'application



Extraction d'information dépendant de
l'application





Extraction au niveau de la phrase

Exemple: dépêche du 13 mai 2012

« Hollande se rendra mardi à Berlin. Il rencontrera la chancelière Angela Merkel. »

L'interprétation de la première phrase est simple à partir du résultat de l'analyse morphosyntaxique

« Hollande » est l'agent de l'action « se rendre ». « mardi » est la date et « Berlin » est le lieu.

Les règles d'extraction doivent tester deux hypothèses pour l'action se rendre (aller ou se constituer prisonnier). Du fait de la présence d'une destination « Berlin » c'est la première hypothèse qui est retenue.

“Hollande” est considéré par l'analyse morphosyntaxique comme un lieu mais la règle de reconnaissance d'un déplacement ne peut avoir comme agent qu'une personne ou une organisation. En l'absence de certitude on peut le qualifier d'agent. En fait, on introduit « Hollande » aussi comme personne pour éviter l'ambiguïté.



Exemple: dépêche du 13 mai 2012

« Hollande se rendra mardi à Berlin. Il rencontrera la chancelière Angela Merkel. »

La deuxième phrase pose plus de problèmes.

On perd beaucoup d'informations dans un texte si on ne traite pas les pronoms. Il est nécessaire ici d'identifier il à Hollande. C'est ce que fait l'analyse au niveau du paragraphe et même au niveau du document par exemple dans les biographies.



Extraction au niveau du document

Exemple: dépêche du 13 mai 2012

« Hollande se rendra mardi à Berlin. Il rencontrera la chancelière Angela Merkel. »

Dans la première phrase il y a une date incomplète.

Les dates incomplètes sont traitées en fonction de la date de publication ou d'une date citée avant dans le document. Les dates incomplètes sont traduites en format ISO.

Mardi= 20120515

Toutes les dates sont données comme un intervalle d'incertitude. Par exemple *2011* sera traduit par `Datebeg=20110101 Dateend=20111231`,
La semaine prochaine si la date de publication est le 13 mai 2012:

`Datebeg=20120514 Dateend=20120520`

La deuxième phrase ne précise pas où et quand la rencontre va avoir lieu. En l'absence d'une indication contraire de l'auteur, un déplacement suivi d'une rencontre laisse penser que la date et le lieu sont communs entre les deux phrases.



Extraction au niveau du document

La même personne peut être citée à différentes occurrences dans le texte en utilisant une étiquette différente.

Exemple: [Nicolas Sarkozy](#) [Le président Sarkozy](#)[Sarkozy](#)

Les différentes actions ou attributs doivent être liés à une URI unique même si la personne est nommée de manières différentes.

En cas de types de différentes spécificités, le plus spécifique est attribué. Si Hollande dans un cas est agent et dans un autre est personne on le qualifiera de personne.

On peut bien sûr avoir dans le même texte plusieurs personnes différentes de même nom de famille. Dans ce cas l'auteur précise le prénom ou un titre discriminant.

Ex: [Abdul Aziz Bastin](#) est le fils de [Jean-François Bastin](#).

Ces considérations s'appliquent aussi aux lieux, organisations et produits.



Normalisation des informations provenant de plusieurs langues

La langue de représentation des connaissances est l'anglais.

Les valeurs des attributs doivent être transformées en anglais.

Cela pose des problèmes de listes d'autorité multilingues qui peuvent être très longues comme par exemple les noms de métiers.

Certaines valeurs ont une traduction ambiguë en anglais. Par exemple belle-fille qui peut être « daughter-in-law » ou « stepdaughter ».

Les noms propres de personnes ou de lieux exprimés dans des langues avec un autre jeu de caractères comme l'arabe et le chinois doivent être exprimés en écriture latine pour être comparables à leur forme dans des textes européens.

On utilise les dictionnaires pour les noms connus et le translittérateur pour les autres noms. Exemple 胡锦涛 → Hú Jǐntāo → Hu Jintao



EXEMPLES DE CONNAISSANCE EXTRAITE D'UN DOCUMENT

GKI - v (2012-11-07 16:55) - Windows Internet Explorer

https://www.geoldemo.com/kned3/editor?docUri=http%3A%2F%2Fgeoldemo.com%2Fdoc%2F2fc2f32952e691c4320037f1b9b7582f2be9e10bb0

Documents - Import - Export/Sauvegarde

Edition du document Doc{http://geoldemo.com/doc/c2f32952e691c4320037f1b9b7582f2be9e10bb0}

Export Analyst Notebook

Edition de connaissance

Type: *Union*

Libellé: 再婚,

début: 2007年

bénéficiaire: Malika Elaroud

Ajouter une propriété

agent

Contenu du document

基地组织“殉道者”造谣利用互联网鼓吹“圣战” <http://www.chinadaily.com.cn/>

中国日报网环球在线消息：走在街上，比利时人玛莉卡·阿鲁（Malika El Aroud）只是一名身着伊斯兰黑衣、头戴黑面罩的普通妇女，而在互联网上，她则是一名在欧洲名气不小的“圣战”战士，她通过写文章传递自己的思想，认为文字也是一种武器。虽然在妇女地位不高的伊斯兰世界里，她并不被圣战的主流力量所承认，但她一直没有放弃。

据美国《纽约时报》5月28日报道，现年48岁的阿鲁目前住在比利时，依靠政府发放的每月1100美元失业金生活，使用法语以“Oum Obeyda”的笔名在互联网上发表文章，她说自己不传播如何制造炸弹的方法，也不会亲自拿起武器去斗争，而是号召穆斯林男子参与斗争，并鼓励穆斯林女性加入这一事业。

阿鲁说：“我的角色不是去引爆炸弹——那很荒谬。我自己有一个武器，那就是写作，是表达意见。这就是我的圣战。人们可以利用语言做很多事情。写作也是一种炸弹。”

阿鲁出生于摩洛哥，18岁首次结婚，并育有一女。一本法语版的古兰经将她引向伊斯兰信仰的道路上，第二任丈夫、一名拉登的忠诚追随者让她有更多机会参与到圣战中。

2001年，她跟随丈夫参加了在阿富汗实施的恐怖袭击事件。11月11日袭击事件发生两天前，她的丈夫在本·拉登的授意下在阿富汗实施了一次炸弹袭击行动，炸死阿富汗北方联盟的领导人艾哈迈德·沙阿·马苏德（Ahmed Shah Massoud），她丈夫也在行动中身亡。从此以后，她在互联网上以一名殉道者遗孀的身份出现，这种身份在穆斯林世界里地位比较高。

2007年阿鲁再婚，她的这位丈夫后来在瑞士被认定犯有运营支持基地组织网站的罪名，她则一直对外声称受到了瑞士当局的迫害，引来不少人的同情，一家名为“受压迫者之声”（The Voice of the Oppressed Web）的网站称其为“我们21世纪的女圣战士”。

Connaissances du document

Personne (8)

- Malika Elaroud
- Malika El Aroud
- Laden
- Ben Laden
- Ahmed Shah Massoud
- husband
- i,me
- Chen Di

再婚

Type: *Union*

début: 2007年

bénéficiaire: Malika Elaroud

Emplacements de la connaissance "再婚,":

- 766:769

Ajout de connaissance

Créer la connaissance

javascript: kned.clickTextLocationFast('http://geoldemo.com/t/c2f32952e691c4320037f1b9b7582f2be9e10bb0/766/769')

15/34



AJOUT DES INFORMATIONS DANS LA BASE DE CONNAISSANCE

La principale difficulté est de déterminer si une personne identifiée dans le nouveau document est ou non une des personnes déjà répertoriée dans la base de connaissance

En cas de même nom,

certains critères permettent de dire que ce sont deux personnes différentes: **date de naissance, lieu de naissance incompatibles, différence de patronymes ou de suffixe (Jr Sr)**

certains critères permettent de dire qu'il s'agit de la même personne: **téléphone, mail, adresse**



AJOUT DES INFORMATIONS DANS LA BASE DE CONNAISSANCE

Certaines personnes de noms différents sont la même personne.

C'est en particulier le cas de variantes de latinisation de noms arabes, russes ou chinois

Pour cela on produit des hypothèses des orthographifications possibles à l'aide d'un translittérateur

Exemple: pour Oussama ben Laden

osama bin ledan, osama bin Laden, ozama ban ladin,
osama ben ladane, osama ben ladin, asama binladdan,
osama binleden, osama bin lden, osama ben ledan, ...



Les connaissances issues des textes ne donnent qu'une vision partielle de la réalité telle que peut l'appréhender un être humain

Il est possible **d'inférer de nouvelles relations ou attributs** par un raisonnement automatique

Par exemple si « **Dominique est la sœur de Jean** » On va pouvoir déduire de la relation de fratrie fournie par le traitement linguistique que **Dominique est de sexe féminin.**

D'autre part cette relation doit être complétée par Jean est le frère de Dominique si on veut connaître toutes les relations familiales de Jean



L'identification de l'auteur d'un texte est un problème difficile.

Les méthodes classiques s'appuient sur des traits assez simples de surface des textes: trigrammes de lettres, mots, succession de catégories grammaticales et sur des classifieurs simples.

La méthode évaluée par le LIP6 (feature bagging) consiste à faire un apprentissage de classifieurs sur un ensemble aléatoire d'ensemble de traits et ensuite de faire un vote

	Méthode	Accuracy
Évaluation	SVM sur 3000 traits	71,6
PAN 2012	Bagging 600 classifieurs avec chacun 100 traits	79,4

LES DÉBOUCHÉS DE SAIMSI



Aide à la productivité dans l'alimentation manuelle de bases de données structurées comme le système I2 d'IBM par exemple en traitant les procès verbaux d'enquêtes

Exemple: [graphe IBM I2 Analyst Notebook](#) des relations de Malika el Aroud

Adaptation de l'ontologie pour traiter le domaine économique: Rachats de sociétés, nominations de dirigeants, déclarations de dirigeants

Applications pour la presse qui n'a pas les mêmes contraintes juridiques pour les bases contenant des noms de personnes



ÉVOLUTIONS DES TECHNOLOGIES

Optimisation des temps de traitement pour se rapprocher des besoins du big data (en cours).

Traitement différencié par type de documents:
biographies, CV, dépêches de presse
réseaux sociaux

Extraction de relations liées à la structure du document

Développement d'un raisonneur capable de mieux prendre en compte des incertitudes de l'extraction à partir du langage naturel



Merci

Questions?