


# Alignement multilingue en corpus comparables spécialisés


Emmanuel Prochasson

Laboratoire d'Informatique de Nantes Atlantique  
Encadré par Béatrice Daille et Emmanuel Morin



17 décembre 2009

# Introduction



Reproduction de la Pierre de Rosette,


British Museum

## La *Pierre de Rosette*

- Trois textes équivalents, deux langues, trois écritures
- Aligné par Champollion (1822)
- Déchiffrage des hiéroglyphes égyptiens

Exemple de *corpus multilingue*

# Introduction




Reproduction de la Pierre de Rosette,

British Museum

## *Exploitation des corpus multilingues*

- Étude du processus de traduction

# Introduction




Reproduction de la Pierre de Rosette,

British Museum

## *Exploitation des corpus multilingues*

- Étude du processus de traduction
- Mémoire de traduction

# Introduction




Reproduction de la Pierre de Rosette,

British Museum

## *Exploitation des corpus multilingues*

- Étude du processus de traduction
- Mémoire de traduction
- Analyse contrastive multilingue

# Introduction



Reproduction de la Pierre de Rosette,

British Museum

## *Exploitation des corpus multilingues*

- Étude du processus de traduction
- Mémoire de traduction
- Analyse contrastive multilingue
- **Lexicographie/Terminologie multilingue**

- 1 Extraction lexicale bilingue
- 2 Alignement multilingue en corpus comparables spécialisés
- 3 Discussion : comparabilité des corpus comparables

- 1 Extraction lexicale bilingue
- 2 Alignement multilingue en corpus comparables spécialisés
- 3 Discussion : comparabilité des corpus comparables

# Corpus multilingues

Deux types de corpus multilingues :

- les corpus *parallèles*
  
- les corpus *comparables*

# Corpus multilingues

Deux types de corpus multilingues :

- les corpus *parallèles*
  - regroupent des documents en relation de traduction
  - coûteux, généralement réservés à certains domaines
- les corpus *comparables*

# Corpus multilingues

Deux types de corpus multilingues :

- les corpus *parallèles*
  - regroupent des documents en relation de traduction
  - coûteux, généralement réservés à certains domaines
- les corpus *comparables*
  - regroupent des documents multilingues non-traductions
  - disponibles dans de nombreuses langues
  - plus difficiles à exploiter

# Corpus comparables

Bowker & Pearson, 2002

*« Un corpus comparable est composé d'ensembles de textes, dans des langues différentes, qui ne sont pas des traductions mutuelles. »*

# Corpus comparables

## Bowker & Pearson, 2002

*« Un corpus comparable est composé d'ensembles de textes, dans des langues différentes, qui ne sont pas des traductions mutuelles. »*

## Déjean & Gaussier, 2002

*« Deux corpus de deux langues  $l_1$  et  $l_2$  sont dits comparables s'il existe une sous-partie non négligeable du vocabulaire du corpus de langue  $l_1$ , respectivement  $l_2$ , dont la traduction se trouve dans le corpus de langue  $l_2$ , respectivement  $l_1$ . »*

## Approches contextuelles

Rapp (1995) et Fung (1995) introduisent l'alignement à partir de corpus *non-parallèles*. Tous deux s'appuient sur l'idée de caractériser le *contexte* des mots à traduire, plutôt que des informations sur leurs positions.

## Approches contextuelles

Rapp (1995) et Fung (1995) introduisent l'alignement à partir de corpus *non-parallèles*. Tous deux s'appuient sur l'idée de caractériser le *contexte* des mots à traduire, plutôt que des informations sur leurs positions.

## Approches contextuelles

Rapp (1995) et Fung (1995) introduisent l'alignement à partir de corpus *non-parallèles*. Tous deux s'appuient sur l'idée de caractériser le *contexte* des mots à traduire, plutôt que des informations sur leurs positions.

- Fung (1995) s'appuie sur les bigrammes (hétérogénéité à gauche/à droite), Rapp (1995) s'appuie sur les voisins rencontrés dans une fenêtre de taille fixe autour du mot à traduire

## Approches contextuelles

Rapp (1995) et Fung (1995) introduisent l'alignement à partir de corpus *non-parallèles*. Tous deux s'appuient sur l'idée de caractériser le *contexte* des mots à traduire, plutôt que des informations sur leurs positions.

- Fung (1995) s'appuie sur les bigrammes (hétérogénéité à gauche/à droite), Rapp (1995) s'appuie sur les voisins rencontrés dans une fenêtre de taille fixe autour du mot à traduire
- **Approche par traduction directe (Fung, 1998)**

## Approches contextuelles

Rapp (1995) et Fung (1995) introduisent l'alignement à partir de corpus *non-parallèles*. Tous deux s'appuient sur l'idée de caractériser le *contexte* des mots à traduire, plutôt que des informations sur leurs positions.

- Fung (1995) s'appuie sur les bigrammes (hétérogénéité à gauche/à droite), Rapp (1995) s'appuie sur les voisins rencontrés dans une fenêtre de taille fixe autour du mot à traduire
- **Approche par traduction directe (Fung, 1998)**
- Approche par similarité interlangue (Déjean & Gaussier, 2002)

## Approches contextuelles

Rapp (1995) et Fung (1995) introduisent l'alignement à partir de corpus *non-parallèles*. Tous deux s'appuient sur l'idée de caractériser le *contexte* des mots à traduire, plutôt que des informations sur leurs positions.

- Fung (1995) s'appuie sur les bigrammes (hétérogénéité à gauche/à droite), Rapp (1995) s'appuie sur les voisins rencontrés dans une fenêtre de taille fixe autour du mot à traduire
- **Approche par traduction directe (Fung, 1998)**
- Approche par similarité interlangue (Déjean & Gaussier, 2002)

Firth, 1957

« On reconnaît un mot à ses fréquentations »

# Approche par traduction directe

## ① Construction de *vecteurs de contexte*

ients d'un authentique diabète de type 1 à l'âge adulte p  
ante du traitement du diabète traité par insuline. Les dia  
rsque l'aggravation du diabète nécessite une escalade th  
patients atteints d'un diabète de type 2 nécessitent une  
(3,4 mmol/l) lorsque le diabète est associé à 2 facteurs d  
majorité atteints d'un diabète de type 2, et leur prise en  
r faire le diagnostic de diabète sucré. Il n' est pas recom  
ormale à 3 mois [7]. Le diabète de type 2 s' inscrit habitu  
isque de développer le diabète sucré dans environ 50 %  
éduisaient le risque de diabète de 58 % lorsqu' elles sont  
surveiller l'équilibre du diabète sauf dans les situations a  
ait la mortalité liée au diabète de 42 %, la mortalité tout  
nt de la découverte du diabète (des complications peuve

# Approche par traduction directe

- 1 Construction de *vecteurs de contexte*



# Approche par traduction directe


- 1 Construction de vecteurs de *contexte*
- 2 Traduction des vecteurs sources vers la langue cible






# Approche par traduction directe

- 1 Construction de vecteurs de contexte
- 2 Traduction des vecteurs sources vers la langue cible
- 3 Calcul de la similarité entre vecteurs traduits et cibles




# Approche par traduction directe

- 1 Construction de vecteurs de contexte
- 2 Traduction des vecteurs sources vers la langue cible
- 3 Calcul de la similarité entre vecteurs traduits et cibles



# Approche par traduction directe

- 1 Construction de vecteurs de contexte
- 2 Traduction des vecteurs sources vers la langue cible
- 3 Calcul de la similarité entre vecteurs traduits et cibles
- 4 → Liste ordonnée de candidats à la traduction



## Emphase : vecteurs de contexte

Rassemble les cooccurrences *significatives* entre la tête d'un vecteur et ses éléments

**Espace vectoriel** : ensemble des mots collectés dans le corpus (monolingue, source ou cible)

**Coordonnées** : score d'association entre la tête du vecteur et les mots du corpus

## Emphase : vecteurs de contexte

Rassemble les cooccurrences *significatives* entre la tête d'un vecteur et ses éléments

**Espace vectoriel** : ensemble des mots collectés dans le corpus (monolingue, source ou cible)

**Coordonnées** : score d'association entre la tête du vecteur et les mots du corpus

**Association** : indépendance statistique entre deux événements

*Force de la relation entre deux mots : l'apparition de l'un favorise-t-elle l'apparition de l'autre ? → Sont-ils sémantiquement reliés ?*

## Emphase : vecteurs de contexte

Rassemble les cooccurrences *significatives* entre la tête d'un vecteur et ses éléments

**Espace vectoriel** : ensemble des mots collectés dans le corpus (monolingue, source ou cible)

**Coordonnées** : score d'association entre la tête du vecteur et les mots du corpus

**Association** : indépendance statistique entre deux événements

*Force de la relation entre deux mots : l'apparition de l'un favorise-t-elle l'apparition de l'autre ? → Sont-ils sémantiquement reliés ?*

Exemple : l'*Information Mutuelle* :

## Emphase : vecteurs de contexte

Rassemble les cooccurrences *significatives* entre la tête d'un vecteur et ses éléments

**Espace vectoriel** : ensemble des mots collectés dans le corpus (monolingue, source ou cible)

**Coordonnées** : score d'association entre la tête du vecteur et les mots du corpus

**Association** : indépendance statistique entre deux événements

*Force de la relation entre deux mots : l'apparition de l'un favorise-t-elle l'apparition de l'autre ? → Sont-ils sémantiquement reliés ?*

Exemple : l'*Information Mutuelle* :

$IM = \log \frac{O}{E}$  ( $O$  : observation,  $E$  : valeur attendue sous l'hypothèse nulle)

## Emphase : vecteurs de contexte

Rassemble les cooccurrences *significatives* entre la tête d'un vecteur et ses éléments

**Espace vectoriel** : ensemble des mots collectés dans le corpus (monolingue, source ou cible)

**Coordonnées** : score d'association entre la tête du vecteur et les mots du corpus

**Association** : indépendance statistique entre deux événements

*Force de la relation entre deux mots : l'apparition de l'un favorise-t-elle l'apparition de l'autre ? → Sont-ils sémantiquement reliés ?*


Exemple : l'Information Mutuelle :


$IM = \log \frac{O}{E}$  ( $O$  : observation,  $E$  : valeur attendue sous l'hypothèse nulle)

→ **Obtention d'un Motif d'Association, pour un mot et ses voisins**

Vecteur de  
contexte de  
diabète :

$$\begin{pmatrix} 0 \\ 10,04 \\ 0 \\ 0 \\ 3,13 \\ 0,4 \\ \vdots \\ 0 \\ 0,5 \\ 6,3 \\ 0 \\ 0 \\ 0 \end{pmatrix}$$





# État de l'art

Quelques exemples de travaux connexes :

- Choix des ressources multilingues pour la traduction (Chiao & Zweigenbaum, 2003 ; Déjean & Gaussier, 2002)
- Hypothèse de symétrie distributionnelle (Chiao, 2004)
- Contraintes syntaxiques et lexicales (Sadat *et al.*, 2003)
- Traduction de termes peu fréquents (Pekar *et al.*, 2006)
- Approches géométriques (Gaussier *et al.*, 2004)

# Contexte

- Corpus comparable anglais/français
  - Thème : *cancer du sein*
  - Type de discours *scientifique*
  - 530 000 mots par partie
- Corpus comparable anglais/français/japonais
  - Thème : *diabète et alimentation*
  - Type de discours *scientifique*
  - Environ 250 000 mots par partie

# Problématique

Travail sur des textes spécialisés

# Problématique

Travail sur des textes spécialisés

→ extraction *terminologique* bilingue

# Problématique

Travail sur des textes spécialisés

→ extraction *terminologique* bilingue

Travail sur des corpus de tailles modestes

# Problématique

Travail sur des textes spécialisés

→ extraction *terminologique* bilingue

Travail sur des corpus de tailles modestes

Travail sur des langues distantes

- 1 Extraction lexicale bilingue
- 2 Alignement multilingue en corpus comparables spécialisés
- 3 Discussion : comparabilité des corpus comparables

# Paramètres de l'approche directe

## Paramètres principaux :

- Taille de fenêtre contextuelle
- Mesure d'association : *information mutuelle ponctuelle* ou *taux de vraisemblance*
- Mesure de similarité : *cosinus* ou *jaccard pondéré*

# Paramètres de l'approche directe

## Paramètres principaux :

- Taille de fenêtre contextuelle
- Mesure d'association : *information mutuelle ponctuelle* ou *taux de vraisemblance*
- Mesure de similarité : *cosinus* ou *jaccard pondéré*


ients d'un authentique **diabète** de type 1 à l'âge adulte p  
ante du traitement du **diabète** traité par insuline. Les di  
rsque l'aggravation du **diabète** nécessite une escalade th  
; patients atteints d'un **diabète** de type 2 nécessitent une  
(3,4 mmol/l) lorsque le **diabète** est associé à 2 facteurs d  
majorité atteints d'un **diabète** de type 2, et leur prise er  
r faire le diagnostic de **diabète** sucré. Il n' est pas recomi  
rmale à 3 mois [7]. Le **diabète** de type 2 s' inscrit habitu  
sque de développer le **diabète** sucré dans environ 50 %  
éduisaient le risque de **diabète** de 58 % lorsqu' elles sont  
surveiller l'équilibre du **diabète** sauf dans les situations a  
iait la mortalité liée au **diabète** de 42 %, la mortalité tout  
nt de la découverte du **diabète** (des complications peuve

Définit le nombre de voisins à prendre en compte dans le vecteur d'un contexte d'un mot

# Paramètres de l'approche directe

Paramètres principaux :

- Taille de fenêtre contextuelle
- **Mesure d'association** : *information mutuelle ponctuelle* ou *taux de vraisemblance*
- Mesure de similarité : *cosinus* ou *jaccard pondéré*




Indique la force de la relation entre deux mots

## Paramètres de l'approche directe

Paramètres principaux :

- Taille de fenêtre contextuelle
- Mesure d'association : *information mutuelle ponctuelle* ou *taux de vraisemblance*
- **Mesure de similarité** : *cosinus* ou *jaccard pondéré*



Permet de comparer les vecteurs de contexte

## Paramètres de l'approche directe

### Paramètres principaux :

- Taille de fenêtre contextuelle
- Mesure d'association : *information mutuelle ponctuelle* ou *taux de vraisemblance*
- Mesure de similarité : *cosinus* ou *jaccard pondéré*
- Paramètres optimaux difficiles à connaître *a priori*

?

# Propositions

Trois propositions :

# Propositions

Trois propositions :

**Sur l'alignement anglais/français → japonais :**

- Exploitation de points d'ancrage pour l'alignement
- Alignement multisources

# Propositions

Trois propositions :

**Sur l'alignement anglais/français → japonais :**

- Exploitation de points d'ancrage pour l'alignement
- Alignement multisources

**Sur l'alignement anglais → français :**

- Exploitation de dépendances syntagmatiques et paradigmatisques en fonction d'indices de fréquence

# Propositions

- 1 Détection et exploitation de points d'ancrage
- 2 Fréquences et tailles de fenêtres
- 3 Alignement multisources

## Points d'ancrage

**Idée : compenser la faible représentativité des données en s'appuyant sur des *éléments de confiance***

# Points d'ancrage

**Idée : compenser la faible représentativité des données en s'appuyant sur des *éléments de confiance*, les points d'ancrage**

# Points d'ancrage

**Idée : compenser la faible représentativité des données en s'appuyant sur des *éléments de confiance*, les points d'ancrage**

## Propriétés

- 1 Pertinents vis-à-vis des thématiques du corpus
- 2 Détectables automatiquement
- 3 Traductions stables

# Points d'ancrage

**Idée : compenser la faible représentativité des données en s'appuyant sur des *éléments de confiance*, les points d'ancrage**

## Propriétés

- 1 Pertinents vis-à-vis des thématiques du corpus
- 2 Détectables automatiquement
- 3 Traductions stables
- 4 *Couples de traductions*

# Points d'ancrage

**Idée : compenser la faible représentativité des données en s'appuyant sur des *éléments de confiance*, les points d'ancrage**

## Propriétés

- 1 Pertinents vis-à-vis des thématiques du corpus
- 2 Détectables automatiquement
- 3 Traductions stables
- 4 *Couples de traductions*

S'appuyer sur les points d'ancrage pour :

- → rapprocher les vecteurs traductions
- → éloigner les vecteurs non-traductions

# Points d'ancrage

**Idée : compenser la faible représentativité des données en s'appuyant sur des éléments de confiance, les points d'ancrage**

## Propriétés

- 1 Pertinents vis-à-vis des thématiques du corpus
- 2 Détectables automatiquement
- 3 Traductions stables
- 4 *Couples de traductions*

S'appuyer sur les points d'ancrage pour :

- → rapprocher les vecteurs traductions
- → éloigner les vecteurs non-traductions
- *Rendre les vecteurs de contexte plus discriminants*

# Exploitation des points d'ancrage

**Idée : construire le *motif d'association* en priorité sur les points d'ancrage, puis sur les autres éléments**

# Exploitation des points d'ancrage

**Idée : construire le *motif d'association* en priorité sur les points d'ancrage, puis sur les autres éléments**

→ « Déformation » du motif d'association en faveur des points d'ancrage

# Exploitation des points d'ancrage

**Idée : construire le *motif d'association* en priorité sur les points d'ancrage, puis sur les autres éléments**

→ « Déformation » du motif d'association en faveur des points d'ancrage

Pour  $j$ , élément du vecteur  $V$  et  $PA$  l'ensemble des points d'ancrage pour une langue :

$$assoc\_pondérée_V(j) = \begin{cases} assoc_V(j) + \beta, & \text{si } j \in PA \\ assoc_V(j) - décalage_V, & \text{sinon} \end{cases}$$

# Exploitation des points d'ancrage

**Idée : construire le *motif d'association* en priorité sur les points d'ancrage, puis sur les autres éléments**

→ « Déformation » du motif d'association en faveur des points d'ancrage

Pour  $j$ , élément du vecteur  $V$  et  $PA$  l'ensemble des points d'ancrage pour une langue :

$$assoc\_pondérée_V(j) = \begin{cases} assoc_V(j) + \beta, & \text{si } j \in PA \\ assoc_V(j) - décalage_V, & \text{sinon} \end{cases}$$

$$\text{Avec } décalage_V = \frac{|V \cap PA|}{|V - PA|} \times \beta$$

## Points d'ancrage (2)

Deux types de points d'ancrage identifiés, respectant les propriétés précédentes :

- Translittération : adaptation phonétique d'un mot aux contraintes du japonais
  
  
  
  
  
  
  
  
  
  
- Composés savants : mots construits sur des racines grecques et latines (Namer, 2005)

## Points d'ancrage (2)

Deux types de points d'ancrage identifiés, respectant les propriétés précédentes :

- Translittération : adaptation phonétique d'un mot aux contraintes du japonais  
インスリン/i-n-su-ri-n (insulin/insuline)
  
- Composés savants : mots construits sur des racines grecques et latines (Namer, 2005)  
*psychologie*, construit avec le préfixe *psycho-* et le suffixe *-logie*

## Points d'ancrage (2)

Deux types de points d'ancrage identifiés, respectant les propriétés précédentes :

- Translittération : adaptation phonétique d'un mot aux contraintes du japonais  
インスリン/i-n-su-ri-n (insulin/insuline)
  - Facile à identifier automatiquement (syllabaire dédié), nombreuses recherches en alignement automatique
- Composés savants : mots construits sur des racines grecques et latines (Namer, 2005)  
*psychologie*, construit avec le préfixe *psycho-* et le suffixe *-logie*
  - Détectés à l'aide d'une liste d'affixes sur les ressources linguistiques (expression rationnelle)

## Points d'ancrage (2)

Deux types de points d'ancrage identifiés, respectant les propriétés précédentes :

- Translittération : adaptation phonétique d'un mot aux contraintes du japonais

インスリン/i-n-su-ri-n (insulin/insuline)

- Facile à identifier automatiquement (syllabaire dédié), nombreuses recherches en alignement automatique
- Couvre un vocabulaire spécifique, dans le cas des documents *scientifiques* (Ito, 2007)

- Composés savants : mots construits sur des racines grecques et latines (Namer, 2005)

*psychologie*, construit avec le préfixe *psycho-* et le suffixe *-logie*

- Détectés à l'aide d'une liste d'affixes sur les ressources linguistiques (expression rationnelle)
- Caractéristique d'un vocabulaire *scientifique*

# Protocole

Trois expériences sur le corpus *diabète et alimentation*, anglais/français/japonais

Alignements anglais → japonais, français → japonais

- 1 « *Témoin* »
- 2 Translittérations
- 3 Composés savants

# Protocole

Trois expériences sur le corpus *diabète et alimentation*, anglais/français/japonais

Alignements anglais → japonais, français → japonais

- 1 « *Témoin* »
- 2 Translittérations – 589 (en/jp) 526 (fr/jp)
- 3 Composés savants – 604 (en/jp) 819 (fr/jp)

# Protocole

Trois expériences sur le corpus *diabète et alimentation*, anglais/français/japonais

Alignements anglais → japonais, français → japonais

- 1 « *Témoin* »
- 2 Translittérations – 589 (en/jp) 526 (fr/jp)
- 3 Composés savants – 604 (en/jp) 819 (fr/jp)

Paramètres :

# Protocole

Trois expériences sur le corpus *diabète et alimentation*, anglais/français/japonais

Alignements anglais → japonais, français → japonais

- 1 « *Témoin* »
- 2 Translittérations – 589 (en/jp) 526 (fr/jp)
- 3 Composés savants – 604 (en/jp) 819 (fr/jp)

Paramètres :

- Liste de référence de 98 termes
- Taille de fenêtre : 25
- Mesure d'association/Similarité : taux de vraisemblance/cosinus

# Résultats

	<i>Témoin</i>
Anglais/Japonais ( $Top_1$ )	17,1 %
Anglais/Japonais ( $Top_{10}$ )	36,3 %
Français/Japonais ( $Top_1$ )	20,4 %
Français/Japonais ( $Top_{10}$ )	36,7 %

**Tab.:** Résultats de l'alignement anglais-japonais et français-japonais

# Résultats

	<i>Témoin</i>	<i>Translittérations</i>
Anglais/Japonais ( $Top_1$ )	17,1 %	20,2 % [+18,2 %]
Anglais/Japonais ( $Top_{10}$ )	36,3 %	39,3 % [+ 8,2 %]
Français/Japonais ( $Top_1$ )	20,4 %	20,4 % [+ 0,0 %]
Français/Japonais ( $Top_{10}$ )	36,7 %	37,8 % [+ 2,8 %]

**Tab.:** Résultats de l'alignement anglais-japonais et français-japonais

# Résultats

	<i>Témoin</i>	<i>Translittérations</i>	<i>Composés Savants</i>
Anglais/Japonais ( <i>Top</i> <sub>1</sub> )	17,1 %	20,2 % [+18,2 %]	20,2 % [+18,2 %]
Anglais/Japonais ( <i>Top</i> <sub>10</sub> )	36,3 %	39,3 % [+ 8,2 %]	40,4 % [+11,2 %]
Français/Japonais ( <i>Top</i> <sub>1</sub> )	20,4 %	20,4 % [+ 0,0 %]	22,4 % [+10,0 %]
Français/Japonais ( <i>Top</i> <sub>10</sub> )	36,7 %	37,8 % [+ 2,8 %]	38,8 % [+ 5,6 %]

**Tab.:** Résultats de l'alignement anglais-japonais et français-japonais

# Analyse

Effet des points d'ancrage sur les résultats de l'alignement :

- → léger reclassement des candidats bien classés  
( $Top < 15$ )
- → large reclassement des candidats mal classés  
( $Top > 50$ )

# Analyse

Effet des points d'ancrage sur les résultats de l'alignement :

- → léger reclassement des candidats bien classés  
( $Top < 15$ )
- → large reclassement des candidats mal classés  
( $Top > 50$ )

**Amélioration globale des résultats**

# Analyse

Effet des points d'ancrage sur les résultats de l'alignement :

- → léger reclassement des candidats bien classés  
( $Top < 15$ )
- → large reclassement des candidats mal classés  
( $Top > 50$ )

**Amélioration globale des résultats** → **même si améliorations  $Top_1$  et  $Top_{10}$  faibles**

# Analyse

Effet des points d'ancrage sur les résultats de l'alignement :

- → léger reclassement des candidats bien classés  
( $Top < 15$ )
- → large reclassement des candidats mal classés  
( $Top > 50$ )

**Amélioration globale des résultats → même si améliorations  $Top_1$  et  $Top_{10}$  faibles**

Possibilité d'extension à d'autres langues/d'autres types de vocabulaire

# Analyse

Effet des points d'ancrage sur les résultats de l'alignement :

- → léger reclassement des candidats bien classés ( $Top < 15$ )
- → large reclassement des candidats mal classés ( $Top > 50$ )

**Amélioration globale des résultats → même si améliorations  $Top_1$  et  $Top_{10}$  faibles**

Possibilité d'extension à d'autres langues/d'autres types de vocabulaire

- Phénomène de translittérations présent en Arabe, en Chinois...
- Phénomène de *cognats* entre langues (ex : gouvernement/government)

# Propositions

- 1 Détection et exploitation de points d'ancrage
- 2 **Fréquences et tailles de fenêtres**
- 3 Alignement multisources


# Observations

Observations :

- 1 Les mots très fréquents sont mieux caractérisés par de petites tailles de fenêtre contextuelle ( $<3$ )
- 2 Les mots plus rares sont mieux caractérisés par de grandes tailles de fenêtre ( $>15$ )

# Observations

## Résultats par classes de fréquences et tailles de fenêtres



# Hypothèse

Les mots fréquents peuvent être caractérisés par des dépendances *syntagmatiques* (Grefenstette, 1996)

- Ex : relations sujet-verbe, syntagme nominaux (*onde électromagnétique*)
- → Utilisation d'une information abondante mais très pertinente.

# Hypothèse

Les mots fréquents peuvent être caractérisés par des dépendances *syntagmatiques* (Grefenstette, 1996)

- Ex : relations sujet-verbe, syntagme nominaux (*onde électromagnétique*)
- → Utilisation d'une information abondante mais très pertinente.

Les mots plus rares ne peuvent supporter cette disette d'information (Zweigenbaum & Habert, 2006)

- Nécessité d'absorber un maximum d'information
- Prise en compte des dépendances *paradigmatiques*
- Ex : *diabète . . . pancréas*

# Hypothèse

Les mots fréquents peuvent être caractérisés par des dépendances *syntagmatiques* (Grefenstette, 1996)

- Ex : relations sujet-verbe, syntagme nominaux (*onde électromagnétique*)
- → Utilisation d'une information abondante mais très pertinente.

Les mots plus rares ne peuvent supporter cette disette d'information (Zweigenbaum & Habert, 2006)

- Nécessité d'absorber un maximum d'information
- Prise en compte des dépendances *paradigmatiques*
- Ex : *diabète . . . pancréas*
- → Perte de pertinence au profit de la quantité.

# Proposition

- Prendre en compte la fréquence d'un mot pour savoir comment le caractériser
- Fréquences élevées : petite fenêtre
- Fréquences faibles : grande fenêtre
- Fréquences intermédiaires : fenêtre intermédiaire

# Protocole

Deux expériences :

- ① Fenêtre taille fixe (Témoin)
- ② Fenêtre variable en fonction de la fréquence


Paramètres :

- Liste de 648 traductions français/anglais
- Mesures d'association/similarité : taux de vraisemblance/jaccard pondéré
- fenêtre taille 3 pour expérience témoin

Table de correspondances :

Fréquence	Fenêtre
[15-25]	20
]25-30]	15
]30-100]	10
]100-200]	5
]200-500]	3
]500-+∞[	2

# Résultat



# Discussion

**Intérêt de cette méthode :**

Choix *a priori* d'un paramètre...

# Discussion

## **Intérêt de cette méthode :**

Choix *a priori* d'un paramètre...

... en fonction d'un indice absolu et facile à obtenir : la fréquence

# Discussion

## **Intérêt de cette méthode :**

Choix *a priori* d'un paramètre...

... en fonction d'un indice absolu et facile à obtenir : la fréquence

Mais inefficace dans le cas du japonais

# Discussion

## **Intérêt de cette méthode :**

Choix *a priori* d'un paramètre...

... en fonction d'un indice absolu et facile à obtenir : la fréquence

Mais inefficace dans le cas du japonais

→ Meilleurs résultats toujours obtenus avec une grande taille de fenêtre

# Discussion

## **Intérêt de cette méthode :**

Choix *a priori* d'un paramètre...

... en fonction d'un indice absolu et facile à obtenir : la fréquence

Mais inefficace dans le cas du japonais

→ Meilleurs résultats toujours obtenus avec une grande taille de fenêtre

Spécificités de la langue japonaise ?

# Propositions

- 1 Détection et exploitation de points d'ancrage
- 2 Fréquences et tailles de fenêtres
- 3 **Alignement multisources**


## Contexte :


Corpus comparable français-anglais-japonais → 3 langues disponibles


Alignement français-anglais correct + ressources lexicales plus complètes

Alignements français-japonais ; anglais-japonais délicat

Idée : exploitation des connaissances en français-anglais pour aligner vers le japonais







# Proposition

Utilisation de la moyenne harmonique pour reclasser les candidats à la traduction

# Proposition

Utilisation de la moyenne harmonique pour reclasser les candidats à la traduction

- $r_{candidat} = MH(r_{en, jp}, r_{fr, jp}) = \frac{2r_{en, jp}r_{fr, jp}}{r_{en, jp} + r_{fr, jp}}$
- Note : les candidats qui n'apparaissent pas dans les **deux** alignements sont éliminés

# Proposition

Utilisation de la moyenne harmonique pour reclasser les candidats à la traduction

- $r_{candidat} = MH(r_{en,jp}, r_{fr,jp}) = \frac{2r_{en,jp}r_{fr,jp}}{r_{en,jp} + r_{fr,jp}}$
- Note : les candidats qui n'apparaissent pas dans les **deux** alignements sont éliminés

Ex : recherche de la traduction d'insuline/insulin

# Proposition

Utilisation de la moyenne harmonique pour reclasser les candidats à la traduction

- $r_{candidat} = MH(r_{en, jp}, r_{fr, jp}) = \frac{2r_{en, jp}r_{fr, jp}}{r_{en, jp} + r_{fr, jp}}$
- Note : les candidats qui n'apparaissent pas dans les **deux** alignements sont éliminés

Ex : recherche de la traduction d'insuline/insulin

Rang :	1	2	3	4	5	6	7	8
<i>insulin</i>	インスリン	自律	膵臓	改善	障害	シンケイ	代償	促進
<i>insuline</i>	促進	代償	インスリン	分泌	注射	改善	膵臓	末梢

# Proposition

Utilisation de la moyenne harmonique pour reclasser les candidats à la traduction

- $r_{candidat} = MH(r_{en,jp}, r_{fr,jp}) = \frac{2r_{en,jp}r_{fr,jp}}{r_{en,jp} + r_{fr,jp}}$
- Note : les candidats qui n'apparaissent pas dans les **deux** alignements sont éliminés

Ex : recherche de la traduction d'insuline/insulin

Rang :	1	2	3	4	5	6	7	8
insulin	インスリン	自律	膵臓	改善	障害	シンケイ	代償	促進
insuline	促進	代償	インスリン	分泌	注射	改善	膵臓	末梢

Combinaison des résultats :

{insuline, insulin} → インスリン; 促進; 代償; 膵臓; 改善

# Expérience


Trois expériences :

- 1 Témoin français/japonais
- 2 Témoin anglais/japonais
- 3 Alignement multisources

Paramètres :

- Intersection de listes de termes français/japonais et anglais/japonais
- Liste de 89 termes en traduction, français/anglais/japonais
- Fenêtre taille 15
- Mesure d'association/similarité : taux de vraisemblance/cosinus

# Résultats



# Discussion

**Intérêt** : fort gain en précision

**Conséquence principale** : facilite l'accès à l'information :

# Discussion

**Intérêt** : fort gain en précision

**Conséquence principale** : facilite l'accès à l'information :

- Difficulté à construire de *gros* corpus fortement comparables

# Discussion

**Intérêt** : fort gain en précision

**Conséquence principale** : facilite l'accès à l'information :

- Difficulté à construire de *gros* corpus fortement comparables
- Facilité à construire des corpus comparables modestes dans de nombreuses langues, sur de nombreux sujets

# Discussion

**Intérêt** : fort gain en précision

**Conséquence principale** : facilite l'accès à l'information :

- Difficulté à construire de *gros* corpus fortement comparables
- Facilité à construire des corpus comparables modestes dans de nombreuses langues, sur de nombreux sujets
- Bonne connaissance de certaines langues

# Discussion

**Intérêt** : fort gain en précision

**Conséquence principale** : facilite l'accès à l'information :

- Difficulté à construire de *gros* corpus fortement comparables
- Facilité à construire des corpus comparables modestes dans de nombreuses langues, sur de nombreux sujets
- Bonne connaissance de certaines langues

Exploitation de langues connues pour des alignements plus délicats

# Discussion

**Intérêt** : fort gain en précision

**Conséquence principale** : facilite l'accès à l'information :

- Difficulté à construire de *gros* corpus fortement comparables
- Facilité à construire des corpus comparables modestes dans de nombreuses langues, sur de nombreux sujets
- Bonne connaissance de certaines langues

Exploitation de langues connues pour des alignements plus délicats

Ouverture : *gros c'est beau vs. contraint c'est bien* (Morin et al. 2009) → *qualité dans la variété!*

- 1 Extraction lexicale bilingue
- 2 Alignement multilingue en corpus comparables spécialisés
- 3 Discussion : comparabilité des corpus comparables

# Comparabilité des corpus comparables

**Comparabilité** : intuitivement, qualité d'un corpus comparable pour une tâche donnée

→ Notion d'homogénéité multilingue (Kilgarriff, 2001)

Dans la littérature, comparabilité évaluée sur :

- Critères qualitatifs/externes : choix des documents composant le corpus (thème, type de discours, date de publication, origine linguistique. . . – Bowker & Pearson, 2002)
- Critères quantitatifs/internes : quantité de vocabulaire commun entre les différentes parties du corpus (Déjean & Gaussier, 2002 ; Saralegi & Alegria, 2007)

# Comparabilité

## Cas de l'extraction lexicale bilingue

- Critère quantitatif prépondérant → vocabulaire commun
- Généralement, le respect des critères qualitatifs tend à maximiser les critères quantitatifs

**Comparabilité** : intuitivement, l'idée que les parties du corpus se ressemblent, ont des caractéristiques similaires

- Corpus *équilibrés*, pour favoriser une même représentativité du vocabulaire commun

# Comparabilité

## Cas de l'extraction lexicale bilingue

- Critère quantitatif prépondérant → vocabulaire commun
- Généralement, le respect des critères qualitatifs tend à maximiser les critères quantitatifs

**Comparabilité** : intuitivement, l'idée que les parties du corpus se ressemblent, ont des caractéristiques similaires

- Corpus *équilibrés*, pour favoriser une même représentativité du vocabulaire commun
  - (Morin, 2009) montre qu'il est possible d'exploiter des corpus massivement déséquilibrés

# Comparabilité

## Cas de l'extraction lexicale bilingue

- Critère quantitatif prépondérant → vocabulaire commun
- Généralement, le respect des critères qualitatifs tend à maximiser les critères quantitatifs

**Comparabilité** : intuitivement, l'idée que les parties du corpus se ressemblent, ont des caractéristiques similaires

- Corpus *équilibrés*, pour favoriser une même représentativité du vocabulaire commun
  - (Morin, 2009) montre qu'il est possible d'exploiter des corpus massivement déséquilibrés à *condition de choisir soigneusement les paramètres de l'alignement*

# Comparabilité

## Cas de l'extraction lexicale bilingue

- Critère quantitatif prépondérant → vocabulaire commun
- Généralement, le respect des critères qualitatifs tend à maximiser les critères quantitatifs

**Comparabilité** : intuitivement, l'idée que les parties du corpus se ressemblent, ont des caractéristiques similaires

- Corpus *équilibrés*, pour favoriser une même représentativité du vocabulaire commun
  - (Morin, 2009) montre qu'il est possible d'exploiter des corpus massivement déséquilibrés à *condition de choisir soigneusement les paramètres de l'alignement*
- Corpus *propres, homogènes*, pour limiter le bruit
  - Vraiment ?

# Corpus bruité

## Hypothèse

Vues les méthodes utilisées pour l'extraction lexicale bilingue à partir de vecteurs de contexte, le bruit ne devrait pas avoir d'incidence sur les résultats de l'extraction, à condition que ce bruit n'interfère pas avec le vocabulaire à aligner.

Expérience : alignement français-anglais (corpus *cancer du sein*)

- partie française complétée par une partie du corpus issu du journal *Le Monde*
- partie anglaise complétée par un extrait du corpus *EUROPARL*

**Le volume de *bruit* est supérieur au volume initial du corpus**

# Résultats

Observations :

- ① Différence de qualité de l'alignement peu significative
- ② **L'évolution du rang des traductions trouvées entre l'expérience témoin (corpus équilibré) et l'expérience bruitée est moins significative que celle obtenue en changeant simplement les mesures d'association utilisées pour l'expérience témoin**

# Résultats

Observations :

- ① Différence de qualité de l'alignement peu significative
- ② **L'évolution du rang des traductions trouvées entre l'expérience témoin (corpus équilibré) et l'expérience bruitée est moins significative que celle obtenue en changeant simplement les mesures d'association utilisées pour l'expérience témoin**

## Hypothèse confirmée

Le bruit dans les corpus n'influence pas significativement l'alignement

# Résultats

Observations :

- ① Différence de qualité de l'alignement peu significative
- ② **L'évolution du rang des traductions trouvées entre l'expérience témoin (corpus équilibré) et l'expérience bruitée est moins significative que celle obtenue en changeant simplement les mesures d'association utilisées pour l'expérience témoin**

## Hypothèse confirmée

Le bruit dans les corpus n'influence pas significativement l'alignement à *condition que le bruit n'interfère pas avec le lexique à aligner*

# Notion d'incomparabilité

Deux contraintes disparaissent :

- la contrainte d'équilibre des corpus
- la contrainte d'*homogénéité des corpus*

# Notion d'incomparabilité

Deux contraintes disparaissent :

- la contrainte d'équilibre des corpus
- la contrainte d'*homogénéité des corpus* à condition que le bruit ne couvre pas le vocabulaire à extraire

# Notion d'incomparabilité

Deux contraintes disparaissent :

- la contrainte d'équilibre des corpus
- la contrainte d'*homogénéité des corpus* à condition que le bruit ne couvre pas le vocabulaire à extraire
- Exemple : *history*
  - Sens 1 : *antécédent*
  - Sens 2 : *historique, histoire*

# Notion d'incomparabilité

Deux contraintes disparaissent :

- la contrainte d'équilibre des corpus
- la contrainte d'*homogénéité des corpus* à condition que le bruit ne couvre pas le vocabulaire à extraire
  
- Exemple : *history*
  - Sens 1 : *antécédent*
  - Sens 2 : *historique, histoire*

## Définition : incomparabilité

Élément lexical utilisé avec des sens différents au sein d'un même corpus

# Comparabilité

- Dépistage et traitement des incomparabilités
- Exemple : distinguer les différents usages de *drug*
  - Drogue, contexte : *addiction, désintoxication, répression...*
  - Médicament, contexte : *traitement, prescription, posologie...*
- Construire un vecteur de contexte par usage

Connexion avec l'*acquisition sémantique* (Grefenstette, 1994)

La comparabilité repose sur :

- + La quantité de vocabulaire commun
- La quantité d'*incomparabilité*

# Conséquences

- Moins de contraintes sur la construction des corpus
- Meilleures approches pour l'exploitation des corpus dans le cas de l'extraction lexicale bilingue
  - cas des corpus homogènes et équilibrés : approches classiques
  - cas des corpus hétérogènes et/ou déséquilibrés : approches classiques, avec choix pertinent des mesures d'association
  - cas des corpus *incomparables* : partitionnement sémantique puis approches classiques

# Conclusion

Enjeux : **Amélioration de la caractérisation terminologique multilingue et de l'alignement de lexique bilingue à partir de corpus comparables**

- Trois améliorations de l'approche directe
  - Utilisation de points d'ancrage
  - Corrélation fréquence d'un mot/taille de fenêtre optimale
  - Alignement multisource
- Discussion sur la notion de comparabilité : cadre, évaluation et conséquences
  - Conséquences sur la façon d'exploiter les corpus
  - Conséquences sur la façon de construire les corpus
- Choix de certains paramètres *a priori* pour l'approche directe
  - Taille de fenêtre (en fonction de la fréquence)
  - Mesure d'association (en fonction de la *comparabilité* du corpus)

# Perspectives

Possibilités d'améliorations de l'extraction de lexique bilingue à partir de corpus comparables spécialisés :

- par combinaison de méthodes, peu exploitées ici
- par une meilleure caractérisation *a priori* des corpus comparables

Exploitation de corpus comparables *différents* :

- corpus variés, pour couvrir plus précisément des domaines plus larges
- problème des incomparabilités : approches plus complexes et plus subtiles

Domaine d'étude en pleine expansion

- atelier sur les corpus comparables (Fung & Zweigenbaum, 2008)
- construction de corpus comparables (Goeuriot, 2008 ; Sharoff, 2006)

Merci !

Merci !

Merci !

Merci !

Merci !

