

Introduction à la traduction automatique (statistique)

felipe@iro.umontreal.ca

RALI

Dept. Informatique et Recherche Opérationnelle
Université de **Montréal**



février 2015



Plan

Introduction

Traduction statistique

Autres modèles

Systran

Appariement de textes

Évaluer la traduction

Sujets Chauds



Crédits

- ▶ Chapitre 13 dans [?]
- ▶ Chapitre 21 dans [*Jurafsky and Martin, 2000*]

- ▶ certaines acétates prises à :
 - ▶ F. Yvon,
 - ▶ D. Déchelotte,
 - ▶ K. Knight & P. Koehn (tutoriel SMT),
 - ▶ H. Schwenk

(Hutchins, 2005)

1949 Warren Weaver's (Rockefeller Foundation), théorie de l'information

(Hutchins, 2005)

- 1949 Warren Weaver's (Rockefeller Foundation), théorie de l'information
- 1960 Russe/Anglais, textes scientifiques et techniques
Initialement plutôt approches "classiques", IA + TAL : utilisation de Parseurs, de règles développées par des humains, . . .

(Hutchins, 2005)

- 1949 Warren Weaver's (Rockefeller Foundation), théorie de l'information
- 1960 Russe/Anglais, textes scientifiques et techniques
Initialement plutôt approches "classiques", IA + TAL : utilisation de Parseurs, de règles développées par des humains, . . .
- 1966 Rapport ALPAC (Automatic Language Processing Advisory Committee)

(Hutchins, 2005)

- 1949 Warren Weaver's (Rockefeller Foundation), théorie de l'information
- 1960 Russe/Anglais, textes scientifiques et techniques
Initialement plutôt approches "classiques", IA + TAL : utilisation de Parseurs, de règles développées par des humains, . . .
- 1966 Rapport ALPAC (Automatic Language Processing Advisory Committee)
- 70s Systran, système Meteo

(Hutchins, 2005)

- 1949 Warren Weaver's (Rockefeller Foundation), théorie de l'information
- 1960 Russe/Anglais, textes scientifiques et techniques
Initialement plutôt approches "classiques", IA + TAL : utilisation de Parseurs, de règles développées par des humains, . . .
- 1966 Rapport ALPAC (Automatic Language Processing Advisory Committee)
- 70s Systran, système Meteo
- 90s Traduction Statistique (IBM) + Traduction par l'exemple
⇒ Exploitation de **mémoires de traductions**

Quelques faits

En vrac :

- ▶ fin 80 : traduction sur ordinateur personnel

Quelques faits

En vrac :

- ▶ fin 80 : traduction sur ordinateur personnel
- ▶ fin 90 : traduction sur la toile :
 - ▶ [Alta Vista](#) – Babel Fish – (Systran)
 - ▶ [Google](#) (initialement avec Systran)
 - ▶ [Microsoft](#) (Systran + TS à l'interne)
 - ▶ [Language Weaver](#)

Quelques faits

En vrac :

- ▶ fin 80 : traduction sur ordinateur personnel
- ▶ fin 90 : traduction sur la toile :
 - ▶ [Alta Vista](#) – Babel Fish – (Systran)
 - ▶ [Google](#) (initialement avec Systran)
 - ▶ [Microsoft](#) (Systran + TS à l'interne)
 - ▶ [Language Weaver](#)
- ▶ \$\$
 - ▶ 30% du budget du parlement européen
 - ▶ En 2004 : 1650 traducteurs professionnels employés à la Commission Européenne
 - ▶ 75% des pages internet sont monolingues
 - ▶ 3% des japonais parlent une langue seconde

*A recent UNESCO report on multilingualism states that languages are an **essential medium** for the enjoyment of **fundamental rights**, such as political expression, education and participation in society. From the very beginning, Europe had decided to keep its cultural and linguistic richness and diversity alive during the process of becoming an economic and political union. For maintaining the policy of multilingualism, the EU's institutions spend about one **billion Euros a year on translating texts** and interpreting spoken communication. For all European economies the translation costs for compliance with the laws and regulations are much higher.*

*Strategic Research Agenda for Multilingual Europe
2020, Springer 2013*



*English, Mandarin, Punjabi, Vietnamese, French : These are, in **descending** order, the five most common languages spoken in **Vancouver**. The West Coast metropolis ranks as one of the most multilingual cities in the country. **Multilingualism is increasingly widespread in major cities—especially in Europe**, where high population density is conducive to interaction among cultural communities.*

The challenges of multilingualism in cities : An international research project, Gazette 5 oct. 2011

*Many **less resourced languages** (LRL) that are thriving to get a place in the digital space and that could profit of the new opportunities offered by the Internet and digital devices will seriously face **digital extinction** if they are not supported by Language Technologies.*

CFP LTC Workshop on "Less Resourced Languages, new technologies, new challenges and opportunities", 2013



Multilinguisme

- ▶ enjeux sociétaires :
 - ▶ *e-governance*
 - ▶ éducation
 - ▶ égalité sociale
 - ▶ etc.
- ▶ enjeu économique
- ▶ traduction automatique = technologies émergentes
 - ▶ domaine scientifique complexe faisant intervenir tous les aspects du traitement du langage naturel
 - ▶ pas de pratique encore cimentée : **We need you !**

Traduction Statistique

- ▶ la TS a fait une percée incroyable
- ▶ il est dit *ad libitum* que la TS s'améliore

*However, the overall user experience of **automated translation services tends to be very poor**, often including apparently nonsensical and obvious errors. Swapping common terms for non- equivalent terms in other languages as well as inverting sentence meaning are also common. Piron estimates that, at most, such machine translation will cater for about 25% of a translator's needs with the remaining 75% requiring human intervention to produce publishable quality translation.*

Lost in Translation – the challenges of multilingualism, Martin Flynn, 2011

- ▶ de très bons outils (Moses, Joshua, Gizapp, etc.)



L'ordre des mots varie entre les langues

Exemples :

- ▶ Anglais :
 - ▶ IBM bought Lotus
 - ▶ Reporters said IBM bought Lotus
- ▶ Japonais :
 - ▶ IBM Lotus bought
 - ▶ Reporters IBM Lotus bought said
- ▶ Français :
 - ▶ une nouvelle voiture
 - ▶ une voiture nouvelle

Résolution des références

Il l'aime

systran : it likes it

google : he likes

Julie demande à Paul de ne plus la regarder

systran : Julie asks Paul more to look at it

google : Julie asks Paul no longer look

Julie demande à Paul de lui raconter une blague

systran : Julie asks Paul to tell him a joke

google : Julie asks Paul to tell a joke

Quelques problèmes de sémantique

Ambiguïté sémantique : multiplicité des sens d'un mot

- ▶ Anglais : **plant** (arbre ou entreprise) ; **bank** (banque ou bord d'une rivière)
 - ▶ Français : **allumer** (une cigarette ou le moteur)
couper (les cheveux (en 4) ou le moteur)
- ⇒ Souvent les sens différents correspondent à des traductions différentes

Idiomes

- ▶ Expressions poly-léxématiques qu'on ne peut traduire mot par mot (= non-compositionnelles)
- ▶ être au pied du mur → To be at the foot of the wall ?
- ▶ tenir sa langue → keep ones tongue ?
- ▶ ne pas mâcher ses mots → not to chew ones words ?

Problèmes de morpho-syntaxe

Utilisation des pronoms

- ▶ Certaines langues autorisent l'omission des pronoms (eg. espagnol, italien)
- ▶ Souvent la forme verbale détermine le bon pronom
- ▶ Mais ne on peut savoir s'il faut utiliser **he**, **she** ou **it**
Atraversó_v el río_n flotando_{pp} ↔ it_{pr} floated_v across_p the river

Problèmes de morpho-syntaxe

Utilisation des pronoms

- ▶ Certaines langues autorisent l'omission des pronoms (eg. espagnol, italien)
- ▶ Souvent la forme verbale détermine le bon pronom
- ▶ Mais ne on peut savoir s'il faut utiliser **he**, **she** ou **it**

Atraversó_v el río_n flotando_{pp} ↔ **it**_{pr} floated_v **across**_p the river

Problèmes de morpho-syntaxe

Utilisation des pronoms

- ▶ Certaines langues autorisent l'omission des pronoms (eg. espagnol, italien)
 - ▶ Souvent la forme verbale détermine le bon pronom
 - ▶ Mais ne on peut savoir s'il faut utiliser **he**, **she** ou **it**
- Atravers_v el río_n flotando_{pp} ↔ **it**_{pr} floated_v across_p the river

Marques flexionnelles

- ▶ **He is nice** → **Il est beau** vs **She is nice** → **Elle est belle** : accord d'un côté mais pas de l'autre

⇒ En général, la traduction est plus difficile quand la cible est morphologiquement plus riche que la source

Quelques approches à la traduction Automatique

Approches :

- ▶ Traduction mot par mot
- ▶ Transfert syntaxique
- ▶ Utilisation d'une "langue" pivot (Interlingua)
- ▶ Approches utilisant des textes déjà traduits
 - ▶ Utiliser "l'expertise" contenue dans des traductions effectuées par des humains
 - Minimiser le problème d'acquisition de connaissances
 - ▶ *Example-based machine translation* (EBMT)
 - ▶ [Approche statistique](#)
- ▶ Systèmes hybrides

Le modèle du canal bruité

Canal bruité

- ▶ f une phrase du langage source (french),
- ▶ e une phrase du langage cible (english),
- ▶ traduire \Leftrightarrow résoudre :

$$\operatorname{argmax}_e P(e|f) = \operatorname{argmax}_e P(f|e)P(e)$$

Deux modèles

- ▶ $p(f|e)$ définit le *modèle de transfert*
- ▶ $p(e)$ définit le *modèle de langue*

Un décodeur

- ▶ problème NP-complet (Knight, 2001)



Point de départ : un corpus parallèle

► Un corpus parallèle

- The Legislative Assembly convened at 3.30 pm.
- Mr. Quirke (Clerk-Designate) :
- THURSDAY, APRIL 1, 1999

- sitamiq, ipuru 1, 1999
- maligaliurvik matuiqtaulauqtuq 3 :30mi unnusakkut
- mista kuak (titiraqti - tikkuaqtausimajuq) :

Point de départ : un corpus parallèle

- ▶ Un corpus parallèle + *Aligneur* = **bitexte**

- The Legislative Assembly convened at 3.30 pm.

- Mr. Quirke (Clerk-Designate) :

- THURSDAY, APRIL 1, 1999

- sitamiq, ipuru 1, 1999

- maligaliurvik matuiqtaulauqtuq 3 :30mi unnusakkut

- mista kuak (titiraqti - tikkuaqtausimajuq) :

Point de départ : un corpus parallèle

- ▶ Un corpus parallèle + *Aligneur* = **bitexte**

<ul style="list-style-type: none">● The Legislative Assembly convened at 3.30 pm.● Mr. Quirke (Clerk-Designate) :● THURSDAY, APRIL 1, 1999	<ul style="list-style-type: none">● sitamiq, ipuru 1, 1999● maligaliurvik matuiqtaulauqtuq 3 :30mi unnusakkut● mista kuak (titiraqti - tikkuaqtausimajuq) :
--	---

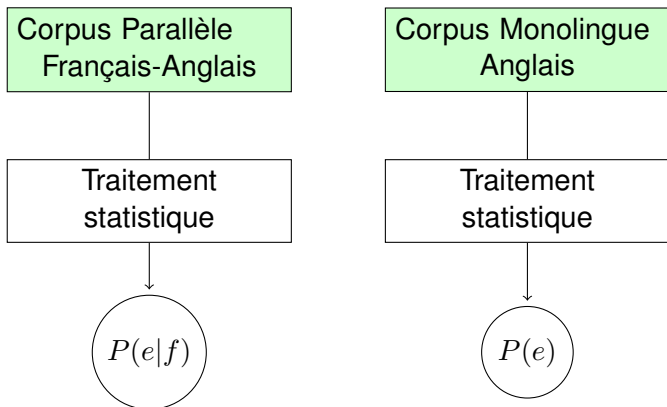
- ▶ Des aligneurs disponibles ([Gale and Church, 1993](#) ; [Moore, 2001](#))

Des ressources, des modèles, des algorithmes

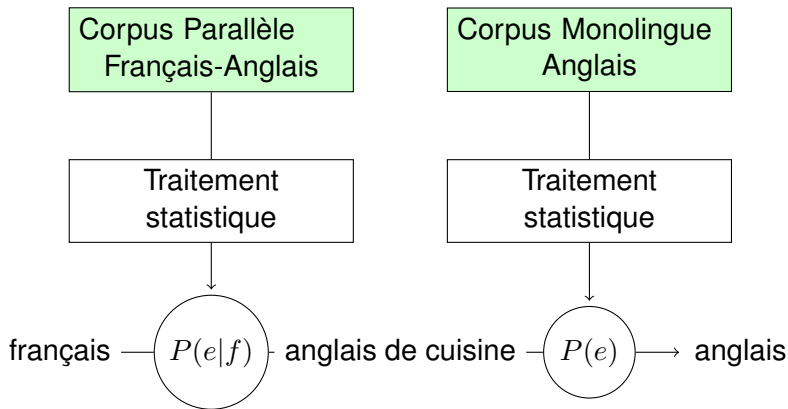
Corpus Parallèle
Français-Anglais

Corpus Monolingue
Anglais


Des ressources, des modèles, des algorithmes



Des ressources, des modèles, des algorithmes



Des ressources, des modèles, des algorithmes



Corpus alignés : le nerf de la guerre

- ▶ textes institutionnels :
 - ▶ débats parlementaires canadiens (anglais-français, anglais-inuktitut)
 - ▶ débats parlementaires européens (français, italien, espagnol, portugais, anglais, allemand, hollandais, danois, suédois, grec, finnois)
 - ▶ hong-kong (anglais-chinois)
 - ▶ santé-canada (anglais-français), Pan Health Organization (anglais-espagnol)
 - ▶ ...
- ▶ textes techniques
- ▶ *best sellers* :
 - ▶ Bible (2212), Coran (≥ 40), Catalogue IKEA (~ 30), Harry Potter (~ 30), ...
- ▶ internet



Modèle de langue n-gramme

$$p(w = w_1, \dots, w_N) \approx \prod_{i=1}^N p(w_i | w_{i-n+1}^{i-1})$$

Cas du modèle trigramme (n=2)

$p(15 \text{ années de traduction en } 15 \text{ minutes}) = p(15) \times p(\text{années} | 15) \times p(\text{de} | 15 \text{ années}) \times p(\text{traduction} | \text{années de}) \times p(\text{en} | \text{de traduction}) \times p(15 | \text{traduction en}) \times p(\text{minutes} | \text{en } 15)$

Lire (Goodman, 2001), (Bengio et al., 2001)



Introduction des alignements

- ▶ estimation directe de $P(f|e)$?
- ▶ décomposition à la HMM $P(f|e) = \prod_i P(f_i|e_i)$ simpliste
- ▶ \Rightarrow décomposition via des alignements :

$$P(f|e) = \sum_a P(a, f|e)$$

où a est un **alignement** entre e et f




Alignement de mots


Mary₁ n'₂ est₃ pas₄ d'accord₅ avec₆ les₇ amis₈ de₉ John₁₀

Mary₁ does₂ not₃ agree₄ with₅ John's₆ friends₇

Alignement de mots



Alignement de mots



- ▶ un alignement = relation sur $I \times J$.

$$a = \{(1, 1), (2, 3), (3, 4), (4, 3), (5, 4) \dots\}$$


$2^{I \times J}$ relations possibles

- ▶ un alignement = application partielle de I vers J :


$$a = [1, 3, 4, 3, 4, 5, 7, 7, 6, 6]$$

« seulement » I^{J+1} applications possibles


Problèmes des alignements de mots



Problèmes des alignements de mots




Mais :




Modèles d'alignement non symétriques

Problèmes des alignements de mots




Les alignements "à la IBM" ne sont pas toujours possibles

Problèmes des alignements de mots



Les alignements "à la IBM" ne sont pas toujours possibles



Présence de bruit dans les corpus

Modélisation avec alignements cachés

Notations

- ▶ $f_1^J = f_1 \dots f_J$ la phrase source (J mots)
- ▶ $e_1^I = e_1 \dots e_I$ la phrase cible (I mots)
- ▶ problème : décomposer $P(a, f|e)$

Modélisation avec alignements cachés

Notations

- ▶ $f_1^J = f_1 \dots f_J$ la phrase source (J mots)
- ▶ $e_1^I = e_1 \dots e_I$ la phrase cible (I mots)
- ▶ problème : décomposer $P(a, f|e)$

Structure du modèle génératif (IBM1,2 & HMM)

- ▶ choisir J sachant e_1^I
- ▶ pour chaque position $j \in [1 : J]$
 - ▶ choisir a_j sachant $J, a_1^{j-1}, f_1^{j-1}, e_1^I$
 - ▶ choisir f_j sachant $J, a_1^j, f_1^{j-1}, e_1^I$

$$P(a_1^J, f_1^J | e_1^I) = P(J | e_1^I) \prod_j P(a_j | a_1^{j-1}, f_1^{j-1}, e_1^I) P(f_j | a_1^j, f_1^{j-1}, e_1^I)$$

Processus Génératif

- NULL
- vendredi
- ,
- c'
- est
- badminton


$$P(f, a|e) = P(J|I) \prod_{j=1}^J P(a_j|a_1^{j-1}, f_1^{j-1}, J, I) P(f_j|a_1^j, f_1^{j-1}, J, I)$$

Processus Génératif

-
-
-
-
-
-
- NULL
- vendredi
- ,
- c'
- est
- badminton


$$P(f, a|e) = P(J|I) \prod_{j=1}^J P(a_j | a_1^{j-1}, f_1^{j-1}, J, I) P(f_j | a_1^j, f_1^{j-1}, J, I)$$

Processus Génératif




$$P(f, a|e) = P(J|I) \prod_{j=1}^J P(a_j | a_1^{j-1}, f_1^{j-1}, J, I) P(f_j | a_1^j, f_1^{j-1}, J, I)$$

Processus Génératif



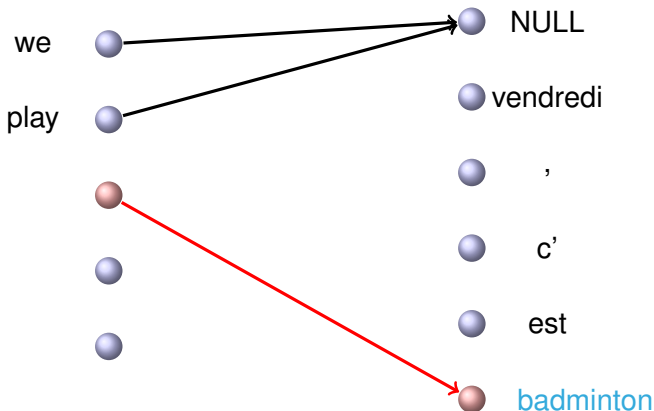
$$P(f, a|e) = P(J|I) \prod_{j=1}^J P(a_j | a_1^{j-1}, f_1^{j-1}, J, I) P(f_j | a_1^j, f_1^{j-1}, J, I)$$

Processus Génératif




$$P(f, a|e) = P(J|I) \prod_{j=1}^J P(a_j | a_1^{j-1}, f_1^{j-1}, J, I) P(f_j | a_1^j, f_1^{j-1}, J, I)$$

Processus Génératif




$$P(f, a|e) = P(J|I) \prod_{j=1}^J P(a_j | a_1^{j-1}, f_1^{j-1}, J, I) P(f_j | a_1^j, f_1^{j-1}, J, I)$$

Processus Génératif




$$P(f, a|e) = P(J|I) \prod_{j=1}^J P(a_j | a_1^{j-1}, f_1^{j-1}, J, I) P(f_j | a_1^j, f_1^{j-1}, J, I)$$

Processus Génératif




$$P(f, a|e) = P(J|I) \prod_{j=1}^J P(a_j | a_1^{j-1}, f_1^{j-1}, J, I) P(f_j | a_1^j, f_1^{j-1}, J, I)$$

Processus Génératif



$$P(f, a|e) = P(J|I) \prod_{j=1}^J p_a(a_j|a_{j-1}, J) P(f_j|a_1^j, f_1^{j-1}, J, I)$$

Processus Génératif



$$P(f, a|e) = P(J|I) \prod_{j=1}^J p_a(a_j|a_{j-1}, J) p_t(f_j|e_{a_j})$$

Deux finesses

Les mots “vides”

Traiter des mots source non alignables : ai et l' dans :
j' ai eu l' occasion / I had occasion

- ▶ état fictif dans la cible (d'indice 0) atteint avec
 $P_0 = P(a_i = 0 | a_{i-1}, J)$
- ▶ une distribution associée à cet état $P = P(f|\epsilon)$

Deux finesses

Les mots “vides”

Traiter des mots source non alignables : ai et l' dans :
j' ai eu l' occasion / I had occasion


- ▶ état fictif dans la cible (d'indice 0) atteint avec
 $P_0 = P(a_i = 0 | a_{i-1}, J)$
- ▶ une distribution associée à cet état $P = P(f|\epsilon)$

Modéliser les sauts

Rendre le modèle d'alignement indépendant des indices absolus : \Rightarrow remplacer $P(a_i | a_{i-1})$ par $P(a_i - a_{i-1} | a_{i-1} - a_{i-2})$

Émergence des alignements

... la maison ... la maison blue ... la fleur ...




... the house ... the blue house ... the flower ...

Tous les alignements sont également probables émergent...
se renforcent s'imposent (principe du « pigeonhole »)

Émergence des alignements

... la maison ... la maison blue ... la fleur ...



... the house ... the blue house ... the flower ...

Tous les alignements sont également probables [la/the](#),
[maison/house](#) émergent... se renforcent s'imposent (principe
du « pigeonhole »)

Émergence des alignements

... la maison ... la maison bleu ... la fleur ...



... the house ... the blue house ... the flower ...

Tous les alignements sont également probables émergent...
 la/the, maison/house se renforcent s'imposent (principe du
 « pigeonhole »)

Émergence des alignements

... la maison ... la maison bleu ... la fleur ...
/ | | X | |
... the house ... the blue house ... the flower ...

Tous les alignements sont également probables émergent...
se renforcent **bleue/blue**, **fleur/flower** s'imposent (principe du
« pigeonhole »)

Estimation supervisée du modèle

- ▶ à alignements connus...
- ▶ ... les paramètres se déduisent par décompte :

$$\forall I \in [1 \dots I_{max}], J \in [1 \dots J_{max}], P(J|I) = \frac{n(I, J)}{n(I)}$$

$$\forall i, i' \in [1 \dots I_{max}], P(i'|i, J, I) = \frac{n(i, i')}{n(i)}$$

$$\forall e \in V_e, f \in V_f, P(f|e) = \frac{n(e, f)}{n(e)}$$

Estimation par EM

Étape E(xpectation)

à paramètres connus (étape précédente) :

$$P(a_1^J | e_1^I, f_1^J) = \frac{P(a_1^J, f_1^J | e_1^I)}{\sum_a P(a_1^J, f_1^J | e_1^I)}$$

Le dénominateur se calcule par programmation dynamique.

Estimation par EM

Étape E(xpectation)

à paramètres connus (étape précédente) :

$$P(a_1^J | e_1^I, f_1^J) = \frac{P(a_1^J, f_1^J | e_1^I)}{\sum_a P(a_1^J, f_1^J | e_1^I)}$$

Le dénominateur se calcule par programmation dynamique.

Étape M(aximisation)

$$\forall I \in [1 \dots I_{max}], J \in [1 \dots J_{max}], P(J|I) = \frac{n(I, J)}{n(I)}$$

$$\forall i, i' \in [1 \dots I], P(i' | i, J, I) = \frac{\sum_k P(a^{(k)} | e^{(k)}, f^{(k)}) n^{(k)}(i, i')}{\sum_{i'} \sum_k P(a^{(k)} | e^{(k)}, f^{(k)}) n^{(k)}(i, i')}$$

$$\forall e, f, P(f|e) = \frac{\sum_{(k)} P(a^{(k)} | e^{(k)}, f^{(k)}) n^{(k)}(e, f)}{\sum_f \sum_{(k)} P(a^{(k)} | e^{(k)}, f^{(k)}) n^{(k)}(e, f)}$$

Les deux derniers termes se calculent par programmation dynamique (algorithme *Forward-Backward*)

Distributions lexicales

the	(3/149)	(le,0.18) (la,0.15) (de,0.12)
minister	(2/27)	(ministre,0.8) (le,0.12)
people	(3/66)	(gens,0.25) (les,0.16) (personnes,0.1)
years	(3/24)	(ans,0.38) (années,0.31) (depuis,0.12)

$$\forall e, \sum_f p(f|e) = 1$$

Calculer les alignements (à modèle connu)

- ▶ $P(.|I)$ connu ; $P(.|a, I, J)$ connu ; $P(f|e)$ connu
- ▶ e_1^I et f_1^J sont observés
- ▶ trouver :


$$\begin{aligned}
 a^* &= \operatorname{argmax}_{a_1 \dots a_J} P(a_1^J | f_1^J, e_1^I) \\
 &= \operatorname{argmax}_{a_1 \dots a_J} P(f_1^J, a_1^J | e_1^I) \\
 &= \operatorname{argmax}_{a_1 \dots a_J} P(J|I) \prod_j P(a_j | a_{j-1}) P(f_j | e_{a_j})
 \end{aligned}$$

- ▶ Résolution par programmation dynamique (Viterbi)

$$\begin{cases}
 \delta(i, 1) = P(a_1 = i), \forall i \in [1 \dots I] \\
 \delta(i, j) = \max_{i' \in I} \delta(i', j-1) P(a_j = i | a_{j-1} = i') P(f_j | e_i) \forall i, j > 1
 \end{cases}$$



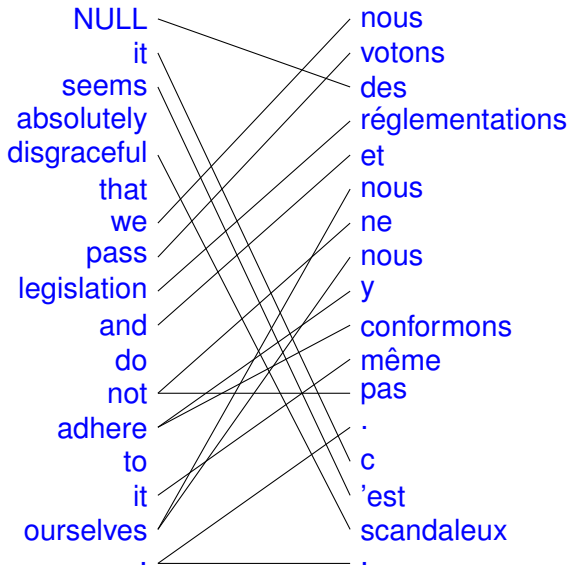
Des alignements... plus ou moins heureux



Des alignements... plus ou moins heureux



Des alignements... plus ou moins heureux



Pour en savoir plus...

- ▶ The mathematics of statistical machine translation (Brown & al, 1993) : publication de référence sur la traduction mot-à-mot et les modèles d'alignement
- ▶ A Statistical MT tutorial workbook [*Knight, 1999b*] : très pédagogique (disponible ici <http://www.statmt.org>)
- ▶ Giza, Giza++, Giza-pp : logiciel *open-source* pour la construction d'alignements
- ▶ <http://www.statmt.org>

Vers les modèles de segment

- ▶ Les alignements mot-à-mot sont problématiques
 - ▶ Le modèle lexical $t(f|e)$ n'utilise pas de contexte :
ex : Les poules du couvent couvent
 - ▶ Prise en compte des formes figées (vue à l'entraînement)
ex : ... ont renoncé de guerre lasse à ... — has finally given up trying
 - ▶ Un modèle lexical $t(f_j|e_{i-2}e_{i-1}e_i)$ est trop complexe
- ⇒ nouveau modèle de traduction, alignement de “blocs de mots” (segments).
- : Apprentissage du modèle
- ▶ acquisition des segments
 - ▶ modèle probabiliste à base de segments



Extraction de segments

english to spanish

	bofetada	bruja					
English	no	daba	una	a	la	verde	
Mary	■						
did				■			
not	■						
slap		■	■	■			
the					■		
green						■	■
witch						■	

spanish to english

	bofetada	bruja					
Spanish	no	daba	una	a	la	verde	
Mary	■						
did		■	■				
not							
slap				■			
the					■		
green						■	■
witch						■	

intersection

	bofetada	bruja					
English	no	daba	una	a	la	verde	
Mary	■						
did							
not	■						
slap		■					
the					■		
green						■	■
witch						■	

Extraction de segments




Extraction des segments



Les alignements symétrisés

Extraction des segments



Les contraintes de cohérence

$$\forall e_i \in \tilde{e}, (e_i, f_j) \in A \Rightarrow f_j \in \tilde{f}$$

$$\forall f_j \in \tilde{f}, (e_i, f_j) \in A \Rightarrow e_i \in \tilde{e}$$

Extraction des segments

	bofetada				bruja			
	Maria	no	daba	una	a	la	verde	
Mary	■							
did		■						
not								
slap			■	■	■			
the					■	■		
green							■	
witch							■	


(Mary,Maria), (did not, no), (slap, daba una bofetada)...

Extraction des segments



(Mary did not, Maria no), (did not slap, no daba una bofetada)...

Extraction des segments



(Mary did not slap, Maria no daba una bofetada)...

Les scores d'un fragment

- ▶ Au maximum de vraisemblance :

- ▶ $P(\tilde{f}|\tilde{e}) = \frac{c(\tilde{f},\tilde{e})}{c(\tilde{e})}$

- ▶ $P(\tilde{e}|\tilde{f}) = \frac{c(\tilde{e},\tilde{f})}{c(\tilde{f})}$

⇒ estimateurs très optimistes pour les longs segments

- ▶ Autres options :

- ▶ $P(\tilde{f}|\tilde{e}) = P_{IBM}(\tilde{f}|\tilde{e})$

- ▶ $P(\tilde{e}|\tilde{f}) = P_{IBM}(\tilde{e}|\tilde{f})$

- ▶ Pourquoi choisir ? ⇒ combinaison des scores

Combinaison des scores et tuning

- ▶ Nouveau modèle de traduction (indépendance entre segments) :

$$P(e|f) = \sum_{a=s_1 \dots s_k} \prod_{i=1}^k P(\tilde{f}_i | \tilde{e}_i)$$

$$\approx \max_{a=s_1 \dots s_k} \prod_{i=1}^k P(\tilde{f}_i | \tilde{e}_i)$$

- ▶ Modèles probabilistes individuellement imprécis

⇒ Pondération de leur influence :

$$e^* = \operatorname{argmax}_e \prod_k P_k(f, e)^{\lambda_k}$$

$$e^* = \operatorname{argmax}_e \sum_k \lambda_k \log P_k(f, e)$$

- ▶ Comment déterminer les coefficients λ_i ?

Optimisation du système : calcul des λ

- ▶ À la main ?
- ▶ Boucle exploratoire :
 - 1 Choisir λ_k initiaux
 - 2 Faire un décodage avec ces valeurs
 - 3 Obtenir une solution et calculer son score
 - 4 Modifier les λ_k et recommencer à l'étape 2
 - 5 Terminer si le score ne s'améliore plus

⇒ Algorithmes itératifs de recherche

Les ingrédients d'un modèle de segment

► Modèle de traduction :

$P(\tilde{f}|\tilde{e})$ traduction segments $e \rightarrow f$

$P(f|e)$ traduction de mots $e \rightarrow f$ (modèle lexical type IBM1)

$P(\tilde{e}|\tilde{f})$ traduction segments $f \rightarrow e$

$P(e|f)$ traduction de mots $e \rightarrow f$ (modèle lexical type IBM1)

e constante \rightarrow pénalité sur le nombre de segments

► + modèles de distortions (une autre fois)

► Modèle de langage : $P(e)$

► constante 1 \rightarrow pénalité de longueur

La table des segments

Scores : $P(\tilde{f}|\tilde{e})$, $P(e|f)$, $P(\tilde{e}|\tilde{f})$, $P(f|e)$ et e

quelques traductions de “A big”

```
A big ||| Le grand ||| 0.0106383 0.000152962 0.166667 0.00405915 2.718
A big ||| Un des principaux ||| 0.0434783 0.0005689 0.166667 1.56536e-05 2.718
A big ||| Un grand ||| 0.00961538 0.00957428 0.166667 0.0300893 2.718
A big ||| Une grande ||| 0.0108696 0.00360665 0.166667 0.0208976 2.718
A big ||| ont une grande ||| 0.0217391 1.12938e-05 0.166667 3.79597e-06 2.718
A big ||| une grande ||| 0.000256345 1.12938e-05 0.166667 0.00211983 2.718
```

La table des segments (suite)

467 traductions de “European Commission”

European Commission		Commission européenne		0.752696	0.812097	0.749849	0.455413	2.718
European Commission		Commission		0.00265859	0.00194196	0.0511501	0.952132	2.718
European Commission		la Commission européenne		0.0426116	0.812097	0.0352603	0.0174883	2.718
European Commission		Commission européenne ,		0.17041	0.812097	0.0195218	0.0364258	2.718
European Commission		de la Commission européenne		0.0625	0.812097	0.0160412	0.00229579	2.718

38 traductions inverses de “Commission européenne”

European Commission		Commission européenne		0.752696	0.812097	0.749849	0.455413	2.718
Commission		Commission européenne		0.116208	0.490344	0.00548883	0.00587199	2.718
the European Commission		Commission européenne		0.0095701	0.0437849	0.0119704	0.455413	2.718
Commission 's		Commission européenne		0.00592435	0.00389219	0.0137227	0.00378834	2.718
Commission is		Commission européenne		0.00303813	0.000335368	0.0036914	4.97013e-05	2.718

La table des segments (suite et fin)

672 traductions de '!'!!!

```

! ||| ! ! ! ||| 0.375 0.588351 0.000338181 0.462852 2.718
! ||| ! ! ||| 0.153846 0.588351 0.000225454 0.598358 2.718
! ||| ! ||| 0.534388 0.588351 0.731372 0.773536 2.718
! ||| : non ! ||| 0.5 0.588351 0.000112727 2.60435e-07 2.718
...
! ||| , dit-on partout ! ||| 1 0.588351 0.000112727 4.76404e-12 2.718
! ||| , exigez que ||| 0.5 5.69e-05 0.000112727 1.92463e-10 2.718
! ||| , exigez ||| 0.333333 5.69e-05 0.000112727 1.20609e-08 2.718
! ||| , il est primordial que la ||| 0.333333 5.69e-05 0.000112727 3.20037e-15 2.718
! ||| , il est primordial que ||| 0.0277778 5.69e-05 0.000112727 8.33407e-14 2.718
...
! ||| Messieurs , il est primordial que la ||| 1 5.69e-05 0.000112727 4.92856e-19 2.718
! ||| Messieurs , il est primordial ||| 1 5.69e-05 0.000112727 8.04285e-16 2.718
...

```

Note : 1 million de paires de phrases ~ 40 millions de paramètres ...

Modèles de traduction IBM

In : un *bitexte*, cad un corpus constitué de deux textes alignés au niveau des phrases. Le découpage en “mots” est également connu.

Out :

- modèle de transfert :

the	(3/149)	(le,0.18)	(la,0.15)	(de,0.12)
minister	(2/27)	(ministre,0.8)	(le,0.12)	
people	(3/66)	(gens,0.25)	(les,0.16)	(personnes,0.1)
years	(3/24)	(ans,0.38)	(années,0.31)	(depuis,0.12)

$$\forall s, \sum_t p(t|s) = 1$$

- autres distributions selon le modèle utilisé

How ? Entraînement par EM de modèles génératifs

$$P(F = f | E = e) = \sum_{a \in \mathcal{A}(e,f)} P(F = f, A = a | E = e)$$

$$a = (a_1, \dots, a_m) \text{ avec } a_i \in [0, l] \forall i \in [1, m]$$



IBM 1 & 2

- ▶ jointe ($e \equiv e_1 \dots e_l$) :

$$P(f, a|e) = l(m|e) \prod_{j=1}^m a(a_j|j, m, e)t(f_j|e_{a_j})$$

avec $a(a_j|j, m, e) = 1/(l + 1)$ dans le cas d'IBM1

- ▶ histoire générative :

- 1 Choisir m la longueur de la traduction f (selon l)
- 2 Générer indépendamment chaque mot f_j de f :
 - 1 choisir a_j une position ($\in [0, l]$) dans e associée à f_j (selon la distribution a). e_{a_j} est le mot qui est "responsable" de la génération de f_j
 - 2 choisir f_j sachant e_{a_j} (selon t)

Entraînement d'un modèle IBM1

[Brown et al., 1993]

- Soit un corpus $(f^s, e^s) \forall s \in [1, S]$,

$$c(\mathbf{f}|\mathbf{e}; e, f) = \frac{t(\mathbf{f}|\mathbf{e})}{\sum_{i=0}^l t(\mathbf{f}|e_i)} \quad \overbrace{\sum_{j=1}^m \delta(f_j, \mathbf{f})}^{\text{nb de f dans } f} \quad \overbrace{\sum_{i=0}^l \delta(\mathbf{e}, e_i)}^{\text{nb de e dans } e}$$

$$\text{avec } t(\mathbf{f}|\mathbf{e}) = \lambda_{\mathbf{e}} \sum_{s=1}^S c(\mathbf{f}|\mathbf{e}; f^{(s)}, e^{(s)})$$


- où $\delta(a, b)$ est la fonction de Kroneker qui vaut 1 lorsque $a = b$ et 0 sinon
- $\lambda_{\mathbf{e}}$ coefficient de Lagrange
- **Note** : converge vers un maximum global



IBM2

- ▶ $a(i|j, l, m)$ probabilité qu'un mot source en position i soit associé à un mot cible en position j , sachant la longueur respective (comptée en mot) des deux phrases considérées.

une **aiguille** dans une botte de foin



- ▶ $\forall j, l, m \sum_{i=0}^l a(i|j, l, m) = 1$

Entraînement d'un modèle IBM2

$$c(\mathbf{f}|\mathbf{e}; e, f) = \sum_{j=1}^m \sum_{i=0}^l \frac{t(\mathbf{f}|\mathbf{e})a(i|j,l,m)}{\sum_{k=0}^l t(\mathbf{f}|e_k)a(k|j,l,m)}$$

$$c(i|j, l, m; f, e) = \frac{t(f_j|e_i)a(i|j,l,m)}{\sum_{k=0}^l t(f_j|e_k)a(k|j,l,m)}$$

$$t(\mathbf{f}|\mathbf{e}) = \lambda_{\mathbf{e}} \sum_1^S c(\mathbf{f}|\mathbf{e}; e^s, f^s)$$

$$a(i|j, l, m) = \mu_{j,l,m} \sum_1^S c(i|j, l, m; f^s, e^s)$$

Modèle HMM [Vogel et al., 1996]

- $p(a_j|a_{j-1}, l)$ permet de capturer le fait que les alignements sont (souvent) localement dépendants

Eve							x
avec						x	
pomme					x		
une				x			
mange		x	x				
Adam	x						
	Adam	is	eating	an	apple	with	Eve

- modélise la probabilité d'un saut : $p(a_j|a_{j-1}, l) = \frac{s(i-i')}{\sum_{k=1}^l s(k-i')}$

IBM3, 4 & 5 : intégration de la fertilité

- ▶ **the** est souvent traduit par un mot (**le, la, l'**), mais peut également ne pas être traduit.
- ▶ **only** est très souvent traduit par un seul mot (**seulement**), mais de temps en temps par deux mots (**ne ... que**)
- ▶ **bill** est presque systématiquement traduit par 3 mots (**projet de loi**)

⇒ La **fertilité** modélise cette information : distribution du nombre de mots cibles générés par un mot source particulier :

$$\forall \mathbf{e}, \sum_n \phi(n|\mathbf{e}) = 1.$$



IBM3, 4 & 5 : une autre histoire générative

L'histoire est simple, mais sa formulation mathématique et les problèmes calculatoires le sont moins ...

- 1 Choisir la fertilité de chaque mot source e_i selon la distribution $\phi(n|e_i) = \phi_i$.
- 2 Pour chaque mot source e_i , choisir ϕ_i mots cibles selon les distributions $t(f|e)$. **[Brown et al., 1993]** appellent la liste des ϕ_i mots générés par e_i la *tablet* de e_i ; notée τ_i . L'ensemble des *tablets* est appelé le tableau de e .
- 3 Permuter les mots cibles selon une distribution Π afin d'obtenir la traduction.

IBM3, 4 & 5 : une autre histoire générative

- ▶ On peut voir cette histoire comme une suite de réécritures [*Knigh*t, 1999a] :

Mary did not slap the green witch	input
Mary not slap slap slap the the green witch	fertilité = (1, 0, 1, 3, 2, 1)
Mary no daba una botefada a la verde bruja	cible
Mary no daba una botefada a la bruja verde	permutation
Mary no daba una botefada a la bruja verde	output

- ▶ l'histoire se complique un peu (au niveau des notations) avec ce que [*Brown et al.*, 1993] appellent les *spurious-words* : les mots cibles non associés à un mot source particulier.

IBM3, 4 & 5 : une autre histoire générative

$$P(\tau, \pi | e) =$$

$$\text{(step 1)} \quad \prod_{i=1}^l P(\phi_i | \phi_1^{i-1}) \times P(\phi_0 | \phi_1^l, e)$$

$$\text{(step 2)} \quad \times \prod_{i=0}^l \prod_{k=1}^{\phi_i} P(\tau_{i,k} | \tau_{i,1}^{k-1}, \tau_0^{i-1}, \phi_0^l, e)$$

$$\text{(step 3)} \quad \times \prod_{i=1}^l \prod_{k=1}^{\phi_i} P(\pi_{i,k} | \pi_{i,1}^{k-1}, \pi_1^{i-1}, \tau_0^{i-1}, \phi_0^l, e) \times \prod_{k=1}^{\phi_0} P(\pi_{0,k} | \pi_{0,1}^{k-1}, \pi_1^l, \tau_0^l, \phi_0^l, e)$$

où $\tau_{i,1}^k = \tau_{i,1}, \tau_{i,2}, \dots, \tau_{i,k}$ et $\pi_{i,1}^k = \pi_{i,1}, \dots, \pi_{i,k}$.

$$P(f, a | e) = \sum_{(\tau, \pi) \in \langle f, a \rangle} P(\tau, \pi | e)$$

$\langle f, a \rangle$ désigne l'ensemble de toutes les paires (τ, π) consistantes avec la paire (f, a) .

IBM3, 4 & 5 : une autre histoire générative

- ▶ τ et π nous donnent f et l'alignement sous-jacent.
- ▶ En général, différentes paires (τ, π) amènent à la même paire (f, a)

$$\begin{aligned}\tau_{cheap} &= \{\text{bon, marché}\} & \pi_{cheap} &= \{1, 2\} \\ \tau_{cheap} &= \{\text{marché, bon}\} & \pi_{cheap} &= \{2, 1\}\end{aligned}$$

- ▶ Il y a $\phi_i!$ arrangements possibles des ϕ_i mots cibles de chaque ensemble τ_i , donc

$$|\langle f, a \rangle| = \prod_{i=0}^l \phi_i!$$

IBM3

$P(\phi_i | \phi_1^{i-1}, e)$ (pour $i \in [1, l]$) ne dépend que de $e_i \rightarrow n(\phi|e)$, les probabilités de fertilité d'un mot source e .

$P(\tau_{i,k} | \tau_{i,1}^{k-1}, \tau_0^{i-1}, \phi_0^l, e)$ (pour $i \in [0, l]$) ne dépend que de $e_i \rightarrow t(f|e)$, les probabilités de transfert.

$P(\pi_{i,k} | \pi_{i,1}^{k-1}, \pi_1^{i-1}, \tau_0^{i-1}, \phi_0^l, e)$ (pour $i \in [1, l]$) ne dépend que de i, m et $l \rightarrow d(j|i, m, l)$ les probabilités de distorsion.

- ▶ Les probabilités de distorsion et de fertilité pour e_0 sont traitées à part.
 - ▶ le nombre de mots cibles associés à e_0 (les *spurious words*) est choisi après avoir choisi les autres fertilités ($P(\phi_0 | \phi_1^l, e)$)
 - ▶ le positionnement de ces mots est fait après avoir positionné les autres mots ($\prod_{k=1}^{\phi_0} P(\pi_{0,k} | \pi_{0,1}^{k-1}, \pi_1^l, \tau_0^l, \phi_0^l, e)$)



IBM3

- ▶ les mots spurious sont placés de manière uniforme dans les espaces vacants, donc $p(\pi_{0,k} = j | \pi_{0,1}^{k-1}, \pi_1^l, \tau_0^l, \phi_0^l, e)$ vaut 0 si j n'est pas une place vacante et $(\phi_0 - k + 1)^{-1}$ sinon.

$$\text{▶ } \prod_{k=1}^{\phi_0} P(\pi_{0,k} | \pi_{0,1}^{k-1}, \pi_1^l, \tau_0^l, \phi_0^l, e) = \prod_{k=1}^{\phi_0} \frac{1}{\phi_0 - k + 1} = \frac{1}{\phi_0!}$$

- ▶ modélisé par une binomiale dépendant de p_1 :

$$P(\phi_0 | \phi_1^l, e) = \binom{\phi = \phi_1 + \dots + \phi_l}{\phi_0} (1 - p_1)^{\phi - \phi_0} (p_1)^{\phi_0}$$

où p_1 représente la probabilité que chaque mot des τ_1^l entraîne l'apparition d'un mot spurious

IBM3 : retour à l'histoire générative

- 1 pour chaque mot e de la phrase source, on choisit une fertilité ϕ avec une probabilité $n(\phi|e)$
- 2 m' est la somme de ces fertilités (n'incluant pas celle de e_0)
- 3 créer une nouvelle phrase source en retirant les mots de fertilité 0, en copiant les mots de fertilité 1, en dupliquant les mots de fertilité 2, etc.
- 4 après chacun de ces m' mots, décider si l'on insère un mot spurious (avec une probabilité p_1), ou pas.
- 5 Soit ϕ_0 le nombre de mots spurious finalement ajoutés. Alors $m = m' + \phi_0$ est la longueur de la traduction.
- 6 remplace chaque mot de cette phrase source par un mot cible selon les probabilités de transfert.
- 7 détermine la position de chaque mot cible non généré par e_0 selon les probabilités de distorsion.
- 8 si une position cible contient plus d'un mot, alors ERREUR
- 9 détermine les positions cibles des ϕ_0 mots générés par NULL parmi les positions restées vacantes dans f_1^m ; chaque choix étant équiprobable ($1/\phi_0$).
- 10 lire la chaîne ainsi créée.

IBM3 en un seul morceau

$$\begin{aligned}
 p(f|e) &= \sum_a p(f, a|e) \\
 &= \sum_a \sum_{(\tau, \pi) \in \langle f, a \rangle} \\
 &\quad \prod_{i=1}^l n(\phi_i | e_i) \times \binom{\phi = \phi_1 + \dots + \phi_l}{\phi_0} (1 - p_1)^{\phi - \phi_0} p_1^{\phi_0} \times \\
 &\quad \prod_{i=0}^l \prod_{k=1}^{\phi_i} t(\tau_{i,k} | e_i) \times \\
 &\quad \prod_{i=1}^l \prod_{k=1}^{\phi_i} d(\pi_{i,k} | i, m, l) \times \frac{1}{\phi_0!} \\
 &= \sum_a \binom{m - \phi_0}{\phi_0} (1 - p_1)^{m - 2\phi_0} p_1^{\phi_0} \prod_{i=1}^l \phi_i! n(\phi_i | e_i) \times \\
 &\quad \prod_{j=1}^m t(f_j | e_{a_j}) \prod_{j: a_j \neq 0}^m d(j | a_j, m, l)
 \end{aligned}$$

Note : lorsque (τ, π) est consistant avec (f, a) :

$$\begin{aligned}
 p(\tau | \phi, e) &= \prod_{i=0}^l \prod_{k=1}^{\phi_i} t(\tau_{i,k} | e_i) &= \prod_{j=1}^m t(f_j | e_{a_j}) \\
 p(\pi | \tau, \phi, e) &= \frac{1}{\phi_0!} \prod_{i=1}^l \prod_{k=1}^{\phi_i} d(\pi_{i,k} | i, l, m) &= \frac{1}{\phi_0!} \prod_{j: a_j \neq 0}^m d(j | a_j, l, m)
 \end{aligned}$$

IBM3

Formules de réestimation (merci [*Brown et al., 1993*]) :

$$c(\mathbf{f}|\mathbf{e}; f, e) = \sum_a p(a|e, f) \sum_{j=1}^m \delta(\mathbf{f}, f_j) \delta(\mathbf{e}, e_{a_j})$$

$$c(j|i, m, l; f, e) = \sum_a p(a|e, f) \delta(i, a_j)$$

$$c(\phi|\mathbf{e}; f, e) = \sum_a p(a|e, f) \sum_{i=1}^l \delta(\phi, \phi_i) \delta(e, e_i)$$

$$c(0; f, e) = \sum_a p(a|e, f) (m - 2\phi_0)$$

$$c(1; f, e) = \sum_a p(a|e, f) \phi_0$$

$$t(\mathbf{f}|\mathbf{e}) \propto \sum_{s=1}^S c(\mathbf{f}|\mathbf{e}; f^s, e^s)$$

$$d(j|i, m, l) \propto \sum_{s=1}^S c(j|i, m, l; f^s, e^s)$$

$$n(\phi|\mathbf{e}) \propto \sum_{s=1}^S c(\phi|\mathbf{e}; f^s, e^s)$$

$$p_k \propto \sum_{s=1}^S c(k; f^s, e^s)$$

IBM3

- ▶ **Problème** : On ne peut pas calculer efficacement la sommation sur l'ensemble des alignements ni l'alignement optimal selon le modèle IBM3
- ▶ *[Brown et al., 1993]* calculent cette somme sur un ensemble d'alignement “prometteurs” :
 - ▶ alignement le plus probable selon un modèle calculable (IBM2)
 - ▶ amélioration selon IBM3 sur les alignements obtenus par un ensemble restreint de modifications de ce “meilleur” alignement (approche *greedy*)
 - ▶ deux opérations élémentaires : *move* et *swap*.

IBM3 : La magie des nombres (pris de *[Brown et al., 1993]*)

Probabilités de transfert et de fertilité pour le mot e = `nodding`.

f	$t(f e)$	f	$t(f e)$	ϕ	$n(\phi e)$
signe	0.164	hocher	0.048	4	0.342
la	0.123	faire	0.030	3	0.293
tête	0.097	me	0.024	2	0.167
oui	0.086	approuve	0.019	1	0.163
fait	0.073	qui	0.019	0	0.023
que	0.073	un	0.012		
hoche	0.054	faites	0.011		

IBM3 : La magie des nombres (pris de *[Brown et al., 1993]*)

Probabilités de transfert et de fertilité pour le mot e =farmers.

f	$t(f e)$	ϕ	$n(\phi e)$
agriculteurs	0.442	2	0.731
les	0.418	1	0.228
cultivateurs	0.046	0	0.039
producteurs	0.021		

Une propriété de IBM3

- ▶ Le fait que les probabilités de distorsion (la probabilité d'une position cible) ne dépendent pas des positions décidées auparavant fait que le modèle est **déficient**.
- ▶ En clair, cela signifie qu'il se peut très bien que plusieurs mots soient attribués indépendamment à la même position cible (ce que les modèles IBM interdisent par essence). Donc une partie de la masse de probabilité du modèle 3 est employée à modéliser des séquences sans intérêt.

$$\sum_f p(f|e) + p(\textit{failure}|e) = 1$$

- ▶ Un modèle est déficient si $p(\textit{failure}|e) > 0$

IBM4

- ▶ tendance à préserver localement l'ordre des mots
- ⇒ changement de l'histoire générative
- ▶ chaque mot source e_i génère toujours ϕ_i mots cibles (fertilité), mais on commence (**étape 1**) par générer la **tête** de la *tablet* (le premier mot) en tenant compte de la *tablet* précédente selon la distribution :

$$(\pi_{i,1} = j | \pi_1^{i-1}, \tau_0^{i-1}, \phi_0^l, e) = d_1(j - c_{\rho_i} | \mathcal{A}(e_{\rho_i}), \mathcal{B}(f_j))$$


avec :

$$\begin{aligned} \rho_i &= \max_{i' < i} \{i' : \phi_{i'} > 0\} \\ c_{\rho} &= \phi_{\rho}^{-1} \sum_{k=1}^{\phi_{\rho}} \pi_{\rho,k} \end{aligned}$$

et \mathcal{A} et \mathcal{B} deux fonctions prenant respectivement en entrée le mot source “précédent” et le mot de tête (cible) de la i -ème *tablet* $\tau_{i,1}$.



IBM4 : Illustration de l'étape 1




IBM4

- ▶ L'idée est de modéliser les mouvements de groupes par ces déplacements de têtes (qui peuvent être positifs ou négatifs).
- ▶ permet de capturer des régularités positionnelles entre les deux langues comme par exemple la tendance à l'inversion (entre le français et l'anglais) de la séquence nom/adjectif (ex : The blue montain / la montagne bleue).

- ▶ **[Brown et al., 1993]** rapportent que :

$$d_1(-1|\mathcal{A}(\text{government's})\mathcal{B}(\text{développement})) = 0.7986 \text{ et}$$

$$d_1(+1|\mathcal{A}(\text{government's})\mathcal{B}(\text{développement})) = 0.0168.$$



IBM4

- ▶ Une fois la tête du *tablet* positionnée, on positionne les autres mots (**étape 2**) en imposant que chaque mot positionné se trouve à droite du mot précédemment positionné :

$$p(\pi_{i,k} = j | \pi_{i,1}^{k-1}, \pi_1^{i-1}, \tau_0^{i-1}, \phi_0^l, e) = d_{>1}(j - \pi_{i,k-1} | \mathcal{B}(f_j))$$

- ▶ **[Brown et al., 1993]** rapportent par exemple que $d_{>1}(2 | \mathcal{B}(\text{pas})) = 0.6847$ (ex : [not/ne... pas](#)) alors que $d_{>1}(2 | \mathcal{B}(\text{en})) = 0.15$ (ex : [implemented/mis en application](#))
- ▶ IBM4 est déficient.

IBM5

- ▶ IBM3 est déficient en raison de l'indépendance du choix d'une position cible pour un mot donné d'une *tablet*.
- ▶ IBM4 possède (d'une manière moindre) les mêmes travers, plus celui de modéliser des déplacements de tête de tablet en dehors de la phrase source (avant le début ou après la fin).
- ▶ IBM5 remédie à cela en forçant les positionnements à tomber sur des places vacantes. Pour plus de détails, voir [\[Brown et al., 1993\]](#). Le modèle 5 contient plus de paramètres, mais ne donne pas nécessairement de meilleurs résultats que IBM4.



Inversion Transduction Grammar (ITG)

► [Wu, 1997, Wu, 2000]

- grammaire hors contexte qui génère un bitexte

- règles de la forme :

$$A \rightarrow (x/y \vee B)^+$$

où x/y est une paire de mots (ex : *apple/pomme*), A et B des non-terminaux.

- Les paires lexicales peuvent contenir le mot vide ϵ pour rendre compte des insertions de mots sources et cibles.

Ex : $A \rightarrow B x/y C z/\epsilon$ signifie que x (source) se réécrit par y (cible) et z se réécrit en ϵ (insertion d'un mot source).

ITG


$S \rightarrow SP \text{ Stop}$ $STOP \rightarrow ./.$
 $SP \rightarrow ART \text{ NG}$ $ART \rightarrow \text{the/la}$
 $NG \rightarrow N \text{ ADJ}$ $ADJ \rightarrow \text{blue/bleue}$
 $NG \rightarrow ADJ \text{ N}$ $N \rightarrow \text{montain/montagne}$

- ▶ Cette grammaire ne peut pas produire un alignement (correct) de la paire de phrases (*the blue montain . / la montagne bleue .*).
- ▶ *[Wu, 2000]* introduit deux types de lecture d'une règle :

$\boxed{}$ indique une lecture habituelle (gauche-droite)
 $\langle \rangle$ indique un lecture inversée.

$NG \rightarrow [ADJ \text{ N}]$
 $NG \rightarrow \langle ADJ \text{ N} \rangle$

ITG



- Les fils directs des nœuds étiquetés <> sont lus de la gauche vers la droite dans la langue source et de la droite vers la gauche dans la langue cible.

ITG

- ▶ *[Wu, 2000]* montre qu'une ITG peut-être représentée sous forme normale :


$$\begin{array}{l}
 S \rightarrow \epsilon / \epsilon \quad A \rightarrow x / \epsilon \quad A \rightarrow [B C] \\
 A \rightarrow x / y \quad A \rightarrow \epsilon / y \quad A \rightarrow \langle B C \rangle
 \end{array}$$

- ▶ Tous les alignements ne sont pas représentables avec une ITG. *[Wu, 2000]* fait l'hypothèse que ces alignements non représentables ne sont pas linguistiquement motivés.
- ▶ Si tel est le cas, alors une ITG possède l'intéressante propriété d'autoriser une fraction de plus en plus restreinte des alignements potentiels entre des constituants de longueur l , plus l augmente.

ITG

l	ITG	align	l	ITG	align
0	1	1	6	394	720
1	1	1	7	1806	5040
2	2	2	8	8558	40320
3	6	6	9	41586	362880
4	22	24	10	206098	3628800
5	90	120

- ▶ 2 alignements de séquences de 4 mots non représentables par une ITG (parmi 24 alignements potentiels) et 2 alignements représentables :



ITG

- ▶ version stochastique des ITG en ajoutant une probabilité à chaque règle sous la contrainte, pour tout non terminal A :

$$\sum_{B,C \in \mathcal{N}} (a_{A \rightarrow [B C]} + a_{A \rightarrow \langle B C \rangle}) + \sum_{x,y \in T} b_A(x,y) = 1$$

où les a -probabilités sont celles associées aux nœuds qui ne sont pas des feuilles, et les b -probabilités sont les probabilités lexicales.

- ▶ un algorithme d'analyse proche de CYK est décrit, ainsi que différents usages des ITGs comme le parenthésage bilingue à l'aide d'une ITG simple comme :

$$\begin{array}{ll} A \rightarrow [A A] [a] & A \rightarrow u_i/v_j [b_{i,j}] \\ A \rightarrow \langle A A \rangle [a] & A \rightarrow u_i/\epsilon [b_{i,\epsilon}] \\ & A \rightarrow \epsilon/v_j [b_{\epsilon,j}] \end{array}$$

Traduction guidée par la syntaxe


Canal bruité dans *[Yamada and Knight, 2001]* :

- ▶ Un arbre syntaxique entre dans un canal qui le transmet sous la forme d'une chaîne cible traduction de la chaîne source associée à l'arbre "entrant".
- ▶ Le canal applique pour cela trois opérations :
 - 1 réordonnement des nœuds de l'arbre,
 - 2 insertion de mots dans les nœuds de l'arbre réordonné et,
 - 3 traduction des feuilles de l'arbre précédent.
- ▶ traduction = la chaîne résultant de la lecture en profondeur d'abord de l'arbre "traduit".




[Yamada and Knight, 2001] : entrée

- ▶ arbre obtenu par l'analyseur probabiliste de [Collins, 1999]




[Yamada and Knight, 2001] :

Réordonnement



original	réordonnant	prob	original	réord.	prob
	PRP VB2 VB1	0.723	VB TO	TO VB	0.749
PRP VB1 VB2	VB2 PRP VB1	0.083		VB TO	0.251
	PRP VB1 VB2	0.074	TO NN	NN TO	0.893
	⋮	⋮		TO NN	0.107


[Yamada and Knight, 2001] : Insertion



parent	TOP	VB	VB	...
node	VB	VB	PRP	...
p(none)	0.735	0.687	0.344	...
p(left)	0.004	0.061	0.004	...
p(right)	0.260	0.252	0.652	...

w	$p_{ins}(w)$
ha	0.219
ta	0.131
⋮	⋮

[Yamada and Knight, 2001] : Transfert



E	adores	he	...
J	daisuki 1.0	kare 0.952	...
		NULL 0.016	...
		nani 0.005	...
		da 0.003	...
		⋮	⋮
		⋮	⋮

Les systèmes hiérarchiques

Jean donne une balle à Marie		John gives Mary a ball
une balle		a ball
Jean		John
Marie		Mary

Les systèmes hiérarchiques

Jean donne une balle à Marie		John gives Mary a ball
une balle		a ball
Jean		John
Marie		Mary



Jean donne X_1 à Marie		John gives Mary X_1
X_1 donne une balle à Marie		X_1 gives Mary a ball
Jean donne une balle à X_1		John gives X_1 a ball
X_1 donne une balle à X_2		X_1 gives X_2 a ball
X_1 donne X_2 à X_3		X_1 gives X_2 X_3

Les systèmes hiérarchiques

$$\begin{aligned}
 G &: \{N \equiv \{S, X\}, V, S, R, P\} \\
 R &: \left\{ \begin{array}{l} \{X \rightarrow \langle \delta, \gamma, \sim \rangle : \delta, \gamma \in (N \cup V)^*\} \\ S \rightarrow \langle SX, SX, 1 - 2 \rangle \\ S \rightarrow \langle X, X, 1 \rangle \end{array} \right\} \\
 P &: p(r \equiv X \rightarrow \langle \delta, \gamma, \sim \rangle) = \prod_i \phi_i(r)^{\lambda_i}
 \end{aligned}$$

Décodage : $trad(f) \approx \operatorname{argmax}_{D: yield(D) \equiv f} w(D)$ où :

$$w(D) = \prod_{r \in D} p(r)$$

Traduction = analyse

Les systèmes hiérarchiques


 $S \rightarrow \langle SX, SX \rangle$
 $S \rightarrow \langle X, X \rangle$
 $X \rightarrow \langle \text{John, Jean} \rangle$
 $X \rightarrow \langle \text{saw } X_1 \text{ with } X_2, \text{ à vu } X_1 \text{ avec } X_2 \rangle$
 $X \rightarrow \langle \text{the man, l'homme} \rangle$
 $X \rightarrow \langle \text{saw } X_1, \text{ a vu } X_1 \rangle$
 $X \rightarrow \langle \text{with a } X_1, \text{ avec un } X_1 \rangle$
 $X \rightarrow \langle \text{telescop, télescope} \rangle$

Les systèmes hiérarchiques

$S \rightarrow \langle SX, SX \rangle$	$S \rightarrow \langle X, X \rangle$
$X \rightarrow \langle \text{John}, \text{Jean} \rangle$	$X \rightarrow \langle \text{saw } X_1 \text{ with } X_2, \text{à vu } X_1 \text{ avec } X_2 \rangle$
$X \rightarrow \langle \text{the man}, \text{l'homme} \rangle$	$X \rightarrow \langle \text{saw } X_1, \text{a vu } X_1 \rangle$
$X \rightarrow \langle \text{with a } X_1, \text{avec un } X_1 \rangle$	$X \rightarrow \langle \text{telescop}, \text{téléscope} \rangle$

$S \Rightarrow \langle \text{SX}, \text{SX} \rangle$
 $\Rightarrow \langle \text{SX}_1 X_2, \text{SX}_1 X_2 \rangle$
 $\Rightarrow \langle \text{X}_1 X_2 X_3, \text{X}_1 X_2 X_3 \rangle$
 $\Rightarrow \langle \text{John } X_1 X_2, \text{Jean } X_1 X_2 \rangle$
 $\Rightarrow \langle \text{John saw } X_1 X_2, \text{Jean a vu } X_1 X_2 \rangle$
 $\Rightarrow \langle \text{John saw the man } X_1, \text{Jean a vu l'homme } X_1 \rangle$
 $\Rightarrow \langle \text{John saw the man with a } X_1, \text{Jean a vu l'homme with a } X_1 \rangle$
 $\Rightarrow \langle \text{John saw the man with a telescope},$
 $\quad \text{Jean a vu l'homme avec un télescope} \rangle$

Les systèmes hiérarchiques

 $S \rightarrow \langle SX, SX \rangle$
 $S \rightarrow \langle X, X \rangle$
 $X \rightarrow \langle \text{John, Jean} \rangle$
 $X \rightarrow \langle \text{saw } X_1 \text{ with } X_2, \text{à vu } X_1 \text{ avec } X_2 \rangle$
 $X \rightarrow \langle \text{the man, l'homme} \rangle$
 $X \rightarrow \langle \text{saw } X_1, \text{a vu } X_1 \rangle$
 $X \rightarrow \langle \text{with a } X_1, \text{avec un } X_1 \rangle$
 $X \rightarrow \langle \text{telescop, télescope} \rangle$


Désambiguïisation lexicale

- ▶ (Schwenk,2007 ; Stroppa et al, 2007 ; Carpuat et Wu, 2007)

En : You must make the first move.

En : You must first move the car.

Désambiguïisation lexicale

- ▶ (Schwenk,2007 ; Stroppa et al, 2007 ; Carpuat et Wu, 2007)

En : You must make the **first move**.

Fr : Tu dois faire le **premier pas**.

En : You must **first move** the car.

Fr : Tu dois **d'abord déplacer** la voiture.

Désambiguïisation lexicale

- ▶ (Schwenk,2007 ; Stroppa et al, 2007 ; Carpuat et Wu, 2007)

En : You must make the **first move**.

Fr : Tu dois faire le **premier pas**.

En : You must **first move** the car.

Fr : Tu dois **d'abord déplacer** la voiture.

Traduction de *first move* ? $\left\langle \begin{array}{l} \text{premier pas} \\ \text{d'abord déplacer} \end{array} \right.$

Désambiguïisation lexicale

- ▶ (Schwenk,2007 ; Stroppa et al, 2007 ; Carpuat et Wu, 2007)

En : You must make the first **move**.
PP MD VV DT JJ NN

Fr : Tu dois faire le premier **pas**.

En : You must first **move** the car.
PP MD RB VV DT NN

Fr : Tu dois d'abord **déplacer** la voiture.

Les catégories lexicales permettent de désambiguïser

Désambiguïisation lexicale

- ▶ (Schwenk,2007 ; Stroppa et al, 2007 ; Carpuat et Wu, 2007)

En : You must make the first **move**.
PP MD VV DT JJ NN

Fr : Tu dois faire le premier **pas**.

En : You must first **move** the car.
PP MD RB VV DT NN

Fr : Tu dois d'abord **déplacer** la voiture.

Traductions : $\text{move}_{NN} \rightarrow \text{pas}$
 $\text{move}_{VV} \rightarrow \text{déplacer}$

Utilisation de morpho-syntaxe

Principe

- ▶ Étiqueter les textes parallèles avec des informations morpho-syntaxiques
- ▶ Enrichir les mots avec les catégories lexicales :

You_P must_V make_V the_D first_{Adj} mov_{EN}.

Tu_P dois_V faire_V le_D premier_{Adj} pas_N.

- ▶ Construire un **système statistique** complet sur ce vocabulaire enrichi
- ▶ En sortie :
 - ▶ Suppression des étiquettes
 - ▶ Réutilisation des étiquettes (ML morpho-syntaxique)

Modèle de Traduction Factorisé

Motivation

- ▶ Seuls sont disponibles les segments du corpus parallèle d'apprentissage
- ▶ Pas de généralisation lexicale

Modèle de Traduction Factorisé

Motivation

- ▶ Seuls sont disponibles les segments du corpus parallèle d'apprentissage
- ▶ Pas de généralisation lexicale

Exemple


- ▶ *La voiture rouge est belle*
→ *The red car is nice*
- ▶ *Les vélos rouges sont beaux*
→ *The red bikes are nice*
- ▶ *Les voitures rouges sont belles*
Traduction de cette phrase sachant les deux autres ?

Modèle de Traduction Factorisé

Principe

- ▶ L'approche actuelle de traduction par syntagmes traite un mot comme unité
 - ▶ Savoir traduire un mot, ne permet pas de traduire son pluriel, sa conjugaison, ...
- ⇒ Décomposer les mots en lemme, genre, nombre, ...
- ▶ Traduire ces **facteurs** séparément
 - ▶ Recomposer le mot dans la langue cible à partir de la traductions des facteurs
 - ▶ **Processus de génération**

Modèle de Traduction Factorisé : Mise en œuvre



Le système Systran

In **1962**, there were 48 working groups deeply involved in the research and development of MT.

The US National Academy of Sciences published the **ALPAC report** in **1966**. This report stated that MT had a limited future, and then put an end to all US Government research and development projects and financing for MT.

Peter Toma, Ph.D., a linguist researcher for MT, began his work in **1957** at the California Institute of Technology. Later, Dr. Toma became involved in the pioneering work in **Russian to English** MT at Georgetown University, the largest MT project in the US of that time. In **1968**, Dr. Toma established a company in La Jolla, California, USA, with a product called **SYSTRAN**; an acronym for **System Translation**. Soon thereafter, the company was contracted to develop Russian to English MT for the US Air Force.

The first SYSTRAN system was tested in early **1969** at Wright-Patterson Air Force Base in Dayton, Ohio, USA. Since **1970**, the system has continued to provide translations for the **US Air Force's** Foreign Technology Division.

During the period **1974-1975**, SYSTRAN was used by **NASA** for the joint US-USSR Apollo-Soyouz space project.

texte consulté en 2002 depuis : <http://www.translation.net/systrans.html>



Systran

In **1975**, Dr. Toma demonstrated a prototype of **English to French** MT to representatives of the **Commission of the European Communities (CEC)**, which resulted in a contract to develop MT systems for various European language pairs. The CEC uses more than 12 SYSTRAN MT systems for the translation of its internal documents.

Xerox Corporation began using SYSTRAN in **1978**, the same period during which the SYSTRAN MT systems were transformed into multitarget (English to several non-English languages). Xerox continues to use the systems for translation of thousands of pages per year. This process allows Xerox to launch multilingual products to the global marketplace.

In **1981**, SYSTRAN initiated the development of the **Japanese to English and English to Japanese** MT systems. Under newly European influence, the first World SYSTRAN Conference, organized by the CEC, was held in Luxembourg, shortly thereafter. This conference, the first dedicated to one single MT system, brought together all the principal SYSTRAN users from around the world.

SYSTRAN introduced the utility "**Customer Specific Dictionaries**", (referred to as CSDs), in **1989**. CSDs are dictionaries created by users with their own specific terminology.

The company developed integrated MT for Xerox in **1990**. This new system provided the option to preserve the original text format during the translation process. This option has

Systran

In **1992**, SYSTRAN began the "C" conversion project, bringing its powerful, patented MT technology to the PC.

In **1995**, SYSTRAN PROfessional for Windows in standalone and client/server versions were launched.

SYSTRAN received a contract from the [US National Air Intelligence Center](#) to develop several Eastern European MT language pairs in **1996**. This included the first-ever [Serbo-Croatian to English](#) MT system, already delivered to the US Government. Also in 1996, SYSTRAN signed a licensing agreement with [Seiko Instruments, Inc.](#), through which SYSTRAN would provide linguistic data and software for Seiko's hand-held translation products.

In early **1997**, [Ford Motor Company](#) acquired multiple custom software licenses of SYSTRAN's MT software, to be embedded directly into Ford's systems.

Today, **14 SYSTRAN MT language pairs** are commercially available*

*52 paires de langues en février 2015



Systran de l'intérieur

(*[Hutchins and Somers, 1992]*)

- ▶ Consultation de **dictionnaires** bilingues à grande couverture.
 - ▶ dictionnaire principal dont les entrées sont des mots seuls
 - ▶ différents dictionnaires spécialisés (ou contextuels) dont les entrées sont des unités spécialisées.
- ▶ Une entrée dans le dictionnaire principal contient de nombreuses informations morphologiques, grammaticales et sémantiques.
 - ▶ valence d'un verbe,
 - ▶ type de nom (animé, énumérable, abstrait, etc.), etc.
- ▶ Le dictionnaire principal est lemmatisé (sauf pour l'anglais).
 - ▶ à chaque entrée lemmatisée correspond une association privilégiée dans la langue cible, elle même étiquetée avec des informations nécessaires à l'étape de génération.



Systran de l'intérieur

Les dictionnaires contextuels contiennent entre-autre :

- ▶ **formes idiomatiques** : de plus en plus, par dessus tout, toute chose égale par ailleurs, etc. dont la traduction est fixe.
- ▶ **formes sémantiques limitées** : identifiant des unités comme *hydraulic break* pour éviter par exemple d'interpréter de manière erronée *hydraulic break fluide* ; ou encore des formes composées comme *pomme de terre/potato*
- ▶ **informations homographiques** : dressant le contexte syntaxique nécessaire à la résolution de formes homographes.
- ▶ **exception aux règles syntaxiques** : comme par exemple *nor* en anglais qui fait exception à la règle des autres conjonctions en permettant l'inversion du groupe verbal qui suit : ... *nor could he see the difficulties*
- ▶ **informations sémantiques contextuelles** : pour le choix lexical. Ex. *grow* → *grandir* (dictionnaire principal), mais peut être traduit par *élever* si le complément est "animé", ou encore *cultiver* si le complément est une plante.

Systran de l'intérieur

(pipeline)

Étapes de pré-traitement :

- 1 Identification de formatage (titres, paragraphes, indentation, etc)
- 2 Repérage des formes idiomatiques
- 3 Consultation du dictionnaire principal
- 4 Analyse morphologique (sauf si la langue source est l'anglais).
Inférence éventuelle dans le cas de mots inconnus
- 5 Identification des noms composés (par consultation des dictionnaires sémantiques limités).

Prise de décision dans des cas comme : **Il parla à la femme de ménage (charlady ?)**.



Systran de l'intérieur

Étapes d'analyse :

- 6 Résolution d'homographes (par analyse du contexte). Ex : **states** peut être un verbe ou un nom, mais pas lorsque précédé de **many**.
- 7 Segmentation des phrases en clauses (marqueurs = ponctuations, conjonctions de coordination, pronoms, etc).
- 8 Identification de relations syntaxiques simples (entre noms et adjectifs, temps de la phrase, son mode, etc.)
- 9 Désambiguïsation des énumérations :
Smog and pollution control are important factors
Smog and pollution control is under consideration
- 10 Identification sujet/prédicats (traitement simpliste)
- 11 Identification de relations syntaxiques "profondes"

Systran de l'intérieur

Étapes de Transfert :

- 12 Transfert des idiomes conditionnels. Ex : **agree** sera traduit par **convenir** s'il est à la forme passive et par **être d'accord** sinon.
- 13 Traduction des prépositions
- 14 Transfert structurel (par consultation de règles spécifiques) :
Ex : **He expects to come** / **Il s'attend à ce qu'il vienne**

Étapes de génération :

- 15 Affectation de la traduction par défaut aux mots encore à traduire
- 16 Génération morphologique
- 17 Arrangements finaux : perturbation de l'ordre des mots, élisions (**le homme** → **l'homme**).

Appariement automatique de textes

Définition : tâche consistant à mettre en correspondance dans un corpus bilingue les phrases qui sont en relation de traduction.

Intérêt : mémoires de traduction, extraction de lexiques bilingues et de dictionnaires terminologiques, désambiguïsation sémantique, etc.

- ▶ aligner des mots \Rightarrow aligner des phrases \Rightarrow aligner des mots
- ▶ des indices plutôt simples permettent d'aligner de manière "satisfaisante" des corpus au niveau de la phrase.
- ▶ en utilisant de l'information **métrique** et de l'information à caractère "**linguistique**".

[Brown et al., 1991, Debilli, 1992, Gale and Church, 1993a, Simard et al., 1992, Kay and Röscheisen, 1993, Fung and Church, 1994, Wu, 1994, Langé and Gaussier, 1995, Simard and Plamondon, 1996, Melamed, 1997, Chang and Chen, 1997, Moore, 2002, Li et al., 2010]

Appariement automatique de textes

Débat

L'intelligence artificielle

Depuis 35 ans, les spécialistes d'intelligence artificielle cherchent à construire des machines pensantes.

Leurs avancées et leurs succès alternent curieusement.

Les symboles et les programmes sont des notions purement abstraites.

Artificial intelligence

A Debat



Attempts to produce thinking machines have met during the past 35 years with a curious mix of progress and failure.

Two further points are important.

First, symbols and programs are purely abstract notions.

Indices métriques (longueurs)

- ▶ Le processus de traduction tend à préserver la longueur (comptée en mots ou en caractères) des phrases : il est assez probable qu'une phrase courte soit traduite par une phrase courte, et qu'à l'inverse une phrase longue soit traduite par une phrase longue.
- ▶ Cette idée simple a été exploitée en premier lieu par *[Brown et al., 1991, Gale and Church, 1993a]*.



Corpus ilo - 7124 paires de phrases

Indices métriques (patterns)

- ▶ En général, à une phrase source est alignée une phrase cible. De manière moins fréquente, n phrases sources sont alignées avec m phrases cibles.

Corpus ilo : 7124 paires de phrases					
pattern	nb	pattern	nb	pattern	nb
1/1	6744 (94.5%)	4/1	15	1/3	3
2/1	203 (2.85%)	1/0	13	5/1	3
1/2	48 (0.6%)	0/1	6	0/9	1
3/1	37 (0.5%)	0/2	5	1/4	1
2/2	26 (0.3%)	2/0	5	1/14	1

- ▶ **[Gale and Church, 1993a]** proposent de considérer uniquement les six schémas (patterns) suivants : 1/1 ($p = 0.89$), 1/2 et 2/1 ($p = 0.089$), 0/1 et 1/0 ($p = 0.011$) et 2/2 ($p = 0.010$).

Indices métriques

- ▶ **[Gale and Church, 1993a]** proposent de mesurer la qualité d'un appariement de l_1 caractères sources avec l_2 caractères cibles par une estimée de $p(match|\delta)$:

$$S_{gc} = -\log(p(\delta|match) \times p(match))$$


$$p(\delta|match) = 2 \times (1 - p(|\delta|))$$

où δ suit une loi normale centrée réduite : $\delta = \frac{(l_2 - l_1 c)}{\sqrt{l_1 s^2}}$ qui dépend de deux paramètres c (la moyenne) et s^2 (la variance) déterminés expérimentalement (resp. 1 et 6.8).

- ▶ $p(match)$ est donnée par les comptes du transparent précédent ($p(1/1)$, $(1/2)$, etc).

Indices métriques

- **Hypothèse** : Chaque caractère de L_1 donne lieu à un nombre aléatoire de caractères dans L_2 . Le nombre de caractères dans L_2 “généralisé” par un caractère de L_1 est une variable aléatoire d’espérance c et de variance s^2 :



En pointillé : distribution empirique des δ . En trait plein, une normale centrée réduite.

Indices à caractère linguistique

- ▶ **[Simard et al., 1992]** proposent d'aligner des corpus bilingues en exploitant le fait que deux phrases en relation de traduction partagent souvent des mots communs ou proches (chiffres, noms propres, etc).
- ▶ Deux mots sont dits **cognates** s'ils partagent des propriétés communes à un quelconque niveau (sémantique, orthographique, etc.).

accès/access, activité/activity, parlement/parliament
librairie/library

- ▶ **Définition [Simard et al., 1992]** : deux mots sont cognates s'ils ont en commun un **préfixe de 4 caractères** au moins. Si l'un des mots contient un chiffre au moins, alors les deux mots sont cognates s'ils sont égaux.
- ▶ Consulter **[Ribeiro et al., 2001]** pour un algorithme permettant de déterminer plus de cognates (ex : [gouvernement/government](#)).



Indices à caractère linguistique

- ▶ **[Simard et al., 1992]** qualité d'un appariement :

$$S_{cog} = \frac{P_T(c|n)}{P_R(c|n)} \times p(\text{match})$$
 où $P_T(c|n)$ et $P_R(c|n)$ dénotent la probabilité que deux segments de longueur moyenne n (en mots) possèdent c cognates sous les hypothèses respectives que les segments sont en relation de traduction, ou au contraire qu'ils ont été sélectionnés aléatoirement.
- ▶ Les auteurs observent sur une partie étiquetée du Hansard, que ces deux probabilités suivent approximativement des **lois binomiales** où p_T (resp. p_R) désigne la probabilité qu'un mot d'un segment ait un cognate dans un segment de l'autre langue lorsque ces deux segments sont (resp. ne sont pas) traduction l'un de l'autre (p_T et p_R ont été expérimentalement fixés à 0.3 et 0.09).

$$\begin{aligned}
 p_T(c|n) &= \binom{n}{c} \times p_T^c \times (1 - p_T)^{n-c} \\
 p_R(c|n) &= \binom{n}{c} \times p_R^c \times (1 - p_R)^{n-c}
 \end{aligned}$$

Algorithme d'alignement


- ▶ Par programmation dynamique ; soit, $D(i, j)$ le (score du) meilleur alignement des phrases sources s_1, \dots, s_i avec les phrases cibles t_1, \dots, t_j .
 - ▶ À l'initiale, $D(i, j)$ est nul pour tout i et j
 - ▶ Récurrence, sur les **schémas d'appariement** : 0/1, 1/0, 1/1, 1/2, 2/1 et 2/2 :

$$D(i, j) = \min \begin{cases} D(i, j-1) & + & d_1 \\ D(i-1, j) & + & d_2 \\ D(i-1, j-1) & + & d_3 \\ D(i-1, j-2) & + & d_4 \\ D(i-2, j-1) & + & d_5 \\ D(i-2, j-2) & + & d_6 \end{cases}$$

où $d_{i \in [1,6]}$ sont les coûts respectifs de chaque schéma selon un score donné (par exemple S_{gc} ou S_{cog}).

Algorithme d'alignement

Comme dans viterbi, on garde un pointeur de retour arrière sur la meilleure case de laquelle on vient.



Algorithme d'alignement : codage

- ▶ Nous avons besoin de deux tables consignnant les informations de chaque phrase des textes source et cible.

```
INFO Source[nbPhraseSource];  
INFO Cible[nbPhraseCible];
```

où `INFO` contient toutes les informations nécessaires au calcul du score d'un appariement.

Ex :

```
INFO = [ int carLength; //longueur de la phrase en caractères  
        int wordLength; //longueur de la phrase en mots  
        string texte; //la phrase elle-même (pas nécessaire)
```



Algorithme d'alignement : codage

- ▶ Nous avons également besoin d'une représentation de l'espace de recherche (une matrice) :

```
DTW Space[nbPhraseSource] [nbPhraseCible]
```

```
DTW = [ float score ; //le (meilleur) score  
        pair<int, int> back ; //le "pointeur" de retour (un entier suffit)
```

- ▶ **Note** : Aligner un corpus bilingue de 1000 phrases sources avec 1000 phrases cibles requiert :
 - ▶ $1000 \times 1000 \times (8 + 2 \times 4)$ soit 16 000 000 octets (16 Meg !).
 - réduction de l'espace de recherche + matrice creuse



Algorithme d'alignement : codage

- ▶ Le score de l'alignement des d_i phrases sources ($S[i] \dots S[i - d_i + 1]$) avec les d_j phrases cibles ($T[j] \dots T[j - d_j + 1]$) est donnée par :

```
float score(int i, int j, int di, int dj, ...)
```

- ▶ le score d'un alignement est additif (somme des scores des appariements = score de l'alignement).
- ▶ Lorsque possible, il est souhaitable de précalculer des informations (ex : les mots cognates)

Algorithme d'alignement : codage

```

Space[i][j].score ← 0 ∀i ∈ [1, nbPhSource], j ∈ [1, nbPhCible]
for (int i=0 ; i<nbPhSource ; i++) do
  path ← false
  for (int j=0 ; i<nbPhCible ; j++) do
    if (inSpace(i,j)) then
      // alignment 1/1
      if (inSpace(i-1,j-1)) then
        score ←= Score(i, j, 1, 1)
        if (score > Space[i][j].score) then
          Space[i][j].score = score ;
          Space[i][j].back = make_pair(1,1) ; path ← true
      // alignment 2/1
      if (inSpace(i-2,j-1)) then
        score ←= Score(i, j, 2, 1)
        if (score > Space[i][j].score) then
          Space[i][j].score = score ;
          Space[i][j].back = make_pair(2,1) ; path ← true
      // on passe de même tous les alignements possibles
    if (path == false) then
      // Alignement impossible (impasse sur la phrase i)

```

Algorithme d'alignement : retour du meilleur chemin

- ▶ Le meilleur alignement a pour score :
`Space[nbPhSource][nbPhCible].score`
- ▶ et l'alignement est obtenu en retournant
`Space[nbPhSource][nbPhCible].back`
`i ← nbPhSource`
`j ← nbPhCible`
while (i && j) **do**
 PRINT Alignement en (i,j) avec un schéma :
 `Space[i][j].back.first/Space[i][j].back.second`
 `i -= Space[i][j].back.first`
 `j -= Space[i][j].back.second`

Réduction de l'espace de recherche

- ▶ Réduire les temps de calculs de manière significative (possiblement avec perte en robustesse)
 - ▶ **Idée** : l'alignement grossier au niveau des mots permet de réduire l'espace de recherche.
 - ▶ **hypothèse** : les cognates peu fréquents sont probablement de bons indicateurs de synchronisation des deux textes.
- ▶ Soit $M(i, j)$ une matrice qui vaut 1 si le i -ème mot source et le j -ième mot cible sont cognates, et 0 sinon.
 - ▶ on cherche à minimiser la déviation à la diagonale que l'on devrait observer si notre hypothèse est vérifiée.

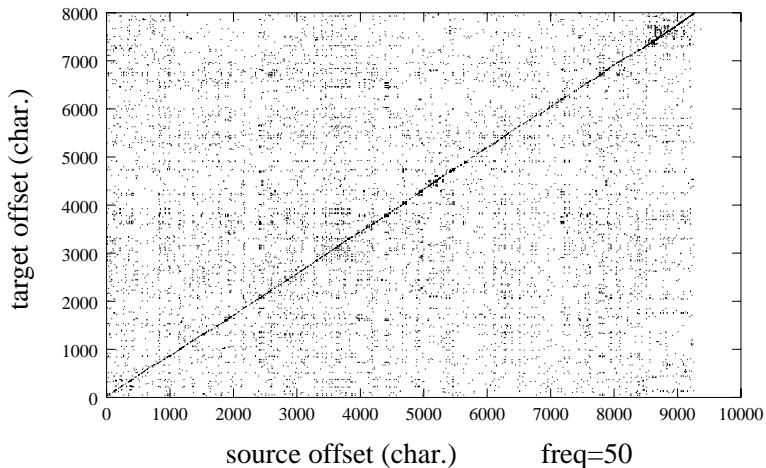
$$S(I, J) = \min_{i=I-R}^{I-1} \min_{j/M_{i,j}=1} (S(i, j) + F(i, j, I, J))$$

$$\text{with } F(i, j, I, J) = \frac{J-j}{I-i} + (I-i-1) \times C$$

C et R constantes déterminées empiriquement.




Réduction de l'espace de recherche




Un point correspond à deux mots qui sont cognates dans un bitexte.

Réduction de l'espace de recherche



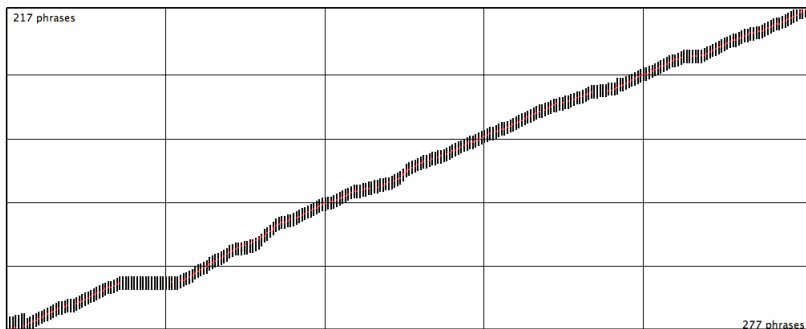
Un point correspond à deux mots qui sont cognates dans un bitexte.

Réduction de l'espace de recherche



- en rouge : le résultat de l'alignement basé sur les cognates

Réduction de l'espace de recherche



- ▶ cet alignement permet de définir un faisceau étroit sur lequel appliquer la prog. dynamique

Alignement de phrases : Évaluation

L'AUPELF-UREF finance ARCADE une action de recherche sur l'évaluation d'algorithmes d'alignement bilingues

[Langlais et al., 1998].

- ▶ Une première campagne (95-96) avait pour but de collecter des corpus de référence (des bitextes alignés manuellement au niveau des phrases) et de mettre au point une méthodologie d'évaluation de la performance des algorithmes d'alignement. Cinq équipes participent aux tests :
 - ▶ RALI (Montréal), LORIA (Nancy), IRMC(Paris), ISSCO (Genève), LIA (Avignon).
- ▶ Une seconde campagne (97-98) réunit 9 équipes et étend les tests à l'alignement de mots *[Véronis and Langlais, 2000]* :
 - + LILLA (Nice), UPenn (Pennsylvanie), CEA (Paris), XEROX (Grenoble)



Arcade : corpus de référence

BAF : 400 000 mots par langue (anglais/français). Quatre types de textes :

- ▶ **INST** (300 000 mots par langue de textes institutionnels, ex : Hansard),
- ▶ **SCIENCE** (50 000 mots par langue d'articles scientifiques),
- ▶ **ITECH** (documentation technique de Xerox, 39 328 mots anglais, 46 828 mots français),
- ▶ **IVERNE** ("De la terre à la lune" de Jules Verne, 40161 mots anglais, 53 181 mots français).

JOC : 200 000 mots par langue du journal officiel de la communauté européenne (français/anglais). Série de questions/réponses sur différents problèmes concernant la communauté européenne. Année 93.

Note : *D'autres corpus sont bien sûr disponibles, notamment, la bible et le coran qui sont traduits dans de nombreuses langues. Pas nécessairement de référence annotée à la main*

Arcade : Métriques d'évaluation

- ▶ Taux de **précision** et **rappel**, mais à différents degrés de granularité.
- ▶ Soit $S = \{s_1, s_2, \dots, s_n\}$ et $T = \{t_1, t_2, \dots, t_m\}$ sa traduction. Un alignement A entre S et T est un sous-ensemble du produit cartésien $\wp(S) \times \wp(T)$, où $\wp(S)$ et $\wp(T)$ sont respectivement l'ensemble de tous les sous-ensembles de S et T . On appelle le triplet $\langle S, T, A \rangle$ un *bitexte*.
- ▶ Voici un bitexte de référence que nous utilisons par la suite :

s_1 Ceci est la phrase numéro un.	t_1 This is the first sentence.
s_2 Ceci est la phrase numéro deux qui ressemble à la première	t_2 This is the second sentence. t_3 It looks like the first.

- ▶ La représentation de cet alignement est :

$$A_r = \{(\{s_1\}, \{t_1\}), (\{s_2\}, \{t_2, t_3\})\}$$

Arcade : Métriques d'évaluation

- Soit le bitexte de référence $\langle S, T, A_r \rangle$ et un alignement candidat A .

$$\text{rappel} = |A \cap A_r| / |A_r| \quad \text{précision} = |A \cap A_r| / |A|$$

s_1 Ceci est la phrase numéro un.	t_1 This is the first sentence.
	t_2 This is the second sentence.
s_2 Ceci est la phrase numéro deux, qui ressemble à la première.	t_3 It looks like the first.

$$A = \{(\{s_1\}, \{t_1\}), (\{\}, \{t_2\}), (\{s_2\}, \{t_3\})\}$$

$$A_r = \{(\{s_1\}, \{t_1\}), (\{s_2\}, \{t_2, t_3\})\}$$

- $A \cap A_r = \{(\{s_1\}, \{t_1\})\} \Rightarrow \text{rappel}=1/2, \text{précision}=1/3$ et
 $F\text{-mesure} = 2 \times \frac{p \times r}{p+r} = 0.4$ (*métriques MA dans la table*)



Arcade : Métriques d'évaluation

- ▶ Les taux de précision et rappel tels que calculés précédemment sont sévères car des *bisegments* (éléments de l'alignement) sont peut-être partiellement corrects.
 - ▶ Dans l'exemple précédent, $(\{s_2\}, \{t_3\})$ n'appartient pas à A_r mais t_3 est bel et bien associé à s_2 dans la référence.
- donner du crédit à des alignements partiellement corrects en considérant le produit cartésien des alignements dans chaque bisegment
 - ▶ Posons $A = \{a_1, a_2, \dots, a_m\}$ et $A_r = \{ar_1, ar_2, \dots, ar_n\}$ avec $a_i = (as_i, at_i)$ et $ar_j = (ars_j, art_j)$, alors :

$$A' = \bigcup_i (as_i \times at_i) = \{(s1, t1), (s2, t3)\}$$

$$A'_r = \bigcup_j (ars_j \times art_j) = \{(s1, t1), (s2, t2), (s2, t3)\}$$
 - ▶ précision=1 et rappel=2/3, F-mesure=0.8 (au lieu de 0.4)
(métriques MP dans la table)

Arcade : Métriques d'évaluation

Problèmes avec ces métriques calculées au niveau de la phrase :

- 1 Nécessite une segmentation au niveau de la phrase
- 2 Tous les algorithmes n'en font pas usage
- 3 Ne donne pas d'information sur la gravité d'un alignement (une erreur sur une petite phrase est peut-être moins pénalisant dans une application, qu'une erreur commise sur un long passage).

⇒ *mesures des taux de précision et rappel au niveau des caractères (ou des mots)*

Arcade : Métriques d'évaluation

- ▶ Sur notre exemple, au niveau des mots :

$$|Ar'| = 5*6 + 11*10 = 140$$

$$|A'| = 5*6 + 0*5 + 11*6 = 96$$

$$|Ar' \hat{=} A'| = 96$$

$$\text{recall} = 96/140 = 0.69$$

$$\text{precision} = 1$$

$$F = 0.82$$

- ▶ Sur notre exemple, au niveau des caractères (incluant les espaces) \hookrightarrow *métriques MC dans la table*

$$|Ar| = 29*27 + 60*52 = 3903$$

$$|A| = 29*27 + 0*28 + 60*24 = 2223$$

$$|Ar' \hat{=} A'| = 2223$$

$$\text{recall} = 2223/3903 = 0.57$$

$$\text{precision} = 1$$

$$F = 0.73$$



Arcade : Performances

(Corpus BAF)

	MP			MC			MA		
	Pr	Rc	F	Pr	Rc	F	Pr	Rc	F
APA	97.01	81.24	88.43	98.19	88.92	93.33	87.95	91.72	89.80
GSA+	95.24	81.57	87.88	97.18	88.97	92.89	88.78	90.59	89.68
GSA	94.98	81.08	87.48	97.38	88.65	92.81	88.33	90.36	89.34
SFI	94.19	81.66	87.48	95.96	88.55	92.11	88.40	89.23	88.81
LILLA	92.97	78.79	85.29	96.06	86.26	90.90	84.45	86.59	85.51
JACAL	91.66	79.73	85.28	94.06	87.15	90.47	82.26	86.63	84.39
SALIGN	85.42	82.98	84.18	93.12	89.26	91.15	88.85	85.35	87.06
GC	90.60	77.39	83.47	92.82	84.65	88.55	83.96	85.29	84.62
ISSCO	88.95	76.33	82.16	91.00	82.25	86.41	83.31	84.19	83.75
CEA	92.56	71.08	80.41	98.10	83.16	90.01	77.91	82.50	80.14
LORIA	86.41	72.65	78.94	90.80	80.88	85.56	80.26	82.27	81.25
IRMC	81.22	65.74	72.67	83.38	73.38	78.06	70.86	76.85	73.74

Arcade : Performances

(Corpus JOC)

	MP			MC			MA		
	Pr	Rc	F	Pr	Rc	F	Pr	Rc	F
GSA+	99.08	98.83	98.95	99.58	99.41	99.49	98.14	98.40	98.27
APA	99.23	98.64	98.93	99.63	98.93	99.28	97.82	98.41	98.11
LORIA	98.89	98.82	98.86	99.50	99.01	99.26	98.41	98.37	98.39
GSA	98.86	98.71	98.78	99.51	99.34	99.42	97.96	98.14	98.05
SFI	98.33	99.02	98.67	99.03	99.26	99.14	98.41	98.20	98.31
JACAL	97.93	98.67	98.30	98.78	99.36	99.07	97.91	97.54	97.72
GC	96.94	97.17	97.06	98.10	97.97	98.03	96.52	96.33	96.43
LILLA	97.19	96.93	97.06	98.39	96.85	97.61	95.51	95.66	95.59
IRMC	97.10	96.92	97.01	98.37	98.31	98.34	93.84	94.90	94.37
SALIGN	94.73	99.20	96.92	97.82	99.51	98.66	96.99	95.04	96.01
ISSCO	95.02	95.80	95.41	96.82	96.67	96.74	95.74	95.06	95.40
CEA	96.58	91.05	93.74	98.38	93.18	95.71	88.43	90.45	89.43

À propos des aligneurs de phrases

- ▶ Il en existe plusieurs en code ouvert :

G&C *[Gale and Church, 1993b]* (le code est dans l'article !)
BMA *[Moore, 2002]*
HUNALIGN *[Varga et al., 2005]*
YASA <http://rali.iro.umontreal.ca/rali/?q=en/yasa>

- ▶ plusieurs études montrent qu'on peut itérativement sélectionner des alignements de phrases fiables de manière à :
 - ▶ entraîner un classificateur à reconnaître des paires de phrases parallèles *[Yu et al., 2012]*
 - ▶ entraîner un système de traduction pour traduire les phrases et faire une comparaison monolingue *[Sennrich and Volk, 2011]* ou pour regrouper des alignements 1-n ou n-1 *[Braune and Fraser, 2010]*
- ▶ d'autres s'affranchissent partiellement ou en totalité de l'hypothèse de monotonie *[Bisson and Fluhr, 2000, Deng et al., 2007, Quan et al., 2013]*



BMA, YASA et HUNALIGN sont dans un bateau

bitext	YASA		BMA		HUNALIGN	
	F_A	F_S	F_A	F_S	F_A	F_S
INST	94.9	96.4	93.3	91.4	91.0	93.4
SCIENCE	89.4	91.7	88.9	86.4	84.8	86.5
VERNE	69.2	86.9	72.3	74.6	66.0	74.6
TECH	90.4	10.9	94.2	10.3	89.6	10.7


- Résultats sur BAF (F_A : niveau alignement, F_S : niveau phrase)

BMA, YASA et HUNALIGN sont dans un bateau

%	INST	SCIENCE	VERNE	TECH
0	94.9 (+1.6)	89.4 (+0.5)	69.2 (-3.1)	90.4 (-3.8)
10	85.9 (+1.1)	78.8 (-1.9)	56.1 (-2.5)	72.2 (-7.1)
20	81.7 (+2.2)	75.2 (+2.9)	54.5 (-3.8)	74.7 (-6.5)
30	77.8 (+7.0)	70.5 (+8.3)	36.7 (-7.6)	69.1 (-3.8)
40	76.0 (+16.6)	69.1 (+30.5)	40.6 (+3.3)	65.0 (+1.8)
50	69.0 (+23.0)	67.2 (+41.8)	44.7 (+28.8)	64.3 (+14.9)
60	69.5 (+44.8)	67.8 (†)	49.9 (+41.9)	65.8 (†)

- ▶ Introduction artificielle de bruit (en supprimant des phrases dans la source)
- ▶ Entre parenthèse : gain absolu par rapport à BMA

BMA, YASA et HUNALIGN sont dans un bateau



YASA & Traduction — en-fr

► EUROPARL version pré-alignée :

<http://www.statmt.org/europarl/>

<CHAPTER ID=1>

<SPEAKER ID=1 NAME="La présidente">

Reprise de la session

<P>

Je déclare reprise de la session du parlement européen qui avant été interrompue le Vendredi 17 Décembre...

<P>

<CHAPTER ID=1>

<SPEAKER ID=1 NAME="President">

Resumption of the session

<P>

I declare resumed the session of the European Parliament adjourned on Friday 17 December 1999 ...


<P>

► `sentence-align-corpus.perl`

- 1 **CHAPTER** supposés synchronisés (**ID** est ignoré)
- 2 **SPEAKER** supposés synchronisés (ceux en trop sont ignorés)
- 3 les tours de paroles où le nombre de **P** est identique sont alignés à l'aide de G&C.



YASA & Traduction — en-fr



Qualité d'un bitexte versus performance en traduction

	NEWS09	NEWS10	NEWS11	HANS
DAILY	20.02	20.46	21.16	23.64
PK	19.43	20.14	20.77	23.46
YASA	19.81	20.47	20.93	23.60
PK++	19.49	20.27	20.62	23.25
YASA++	19.96	20.61	21.05	23.95

- ▶ Performance (BLEU) sur différents test sets (fr→en)
- ▶ gains également sur d'autres paires de langues (*[Lamraoui and Langlais, 2013]*)
- ▶ voir aussi *[Goutte et al., 2012]* qui montre (au contraire) que du bruit dans les bitextes affectent peu les performances BLEU



Quelques perles

1/3

Extraites de <http://www.languagetranslation.com/resources/humorous-examples.html>


- ▶ Cocktail lounge, Norway :
Ladies are Requested Not to have Children in the Bar
- ▶ At a Budapest zoo :
PLEASE DO NOT FEED THE ANIMALS. If you have any suitable food, give it to the guard on duty
- ▶ Hotel, Acapulco :
The Manager has Personally Passed All the Water Served Here
- ▶ Tokyo hotel's rules and regulations :
Guests are requested NOT to smoke or do other disgusting behaviors in bed.
- ▶ On the menu of a Swiss restaurant :
Our wines leave you nothing to hope for.
- ▶ Hotel elevator, Paris :
Please leave your values at the front desk.
- ▶ Hotel, Japan :
You are invited to take advantage of the chambermaid.



Quelques perles

2/3

pv.ca/HEIN?



AU FOUR / FOUR GRILLE-PAIN
OVEN / TOASTER OVEN

<ol style="list-style-type: none">1. Préchauffer le four à 218°C / 425°F.2. Étendre les morceaux de pommes de terre surgelés en une seule couche sur une plaque de cuisson ou dans un plat peu profond allant au four.3. Cuire 20-25 minutes jusqu'à l'obtention de la couleur et de la texture désirée en retournant une à deux fois les morceaux de pommes de terre.4. Servir immédiatement après cuisson.	<ol style="list-style-type: none">1. Preheat oven to 218°C/425°F.2. Spread frozen potato wedges in a single layer on a flat baking sheet or pan.3. Bake 25-30 minutes, or until wedges are crisp and a light golden color. Turn halfway through cooking time.4. Serve immediately after cooking.
--	--

Quelques perles

3/3



pv.ca/HEIN?

SPECIAL
QUEBEC

自然精制

Période de conservation: 24 mois.

Date de production: Se référer au phoque.

純綠紅豆
Pure Mung Bean Vermicelli
Vermicellis Pura De Fèves De Mung

BABELFISH, GOOGLE et SYSTRAN sont dans un bateau

1/3

b : <http://www.babelfish.fr/>

s : <http://www.systran.fr/lp/traduction-en-ligne/>

g : <https://translate.google.ca/?hl=fr>

He likes her

b Il aime lui

s,g Il l'aime

She likes him

b Elle aime lui

s,g Elle l'aime

Il l'aime

b He loves her

s He likes it

g He loves

Elle l'aime

b She loves him

s She likes it

g She loves

BABELFISH, GOOGLE et SYSTRAN sont dans un bateau

2/3

He took french leave

- g il a pris un congé Français
- b Il a pris un congé de Français
- s Il a pris le congé de Français

elle donne du fil à retordre à ses parents

- b It gives of trouble to his parents
- s it gives wire to be twisted with her parents
- g it gives a headache to his parents

BABELFISH, GOOGLE et SYSTRAN sont dans un bateau

3/3

you should never trust machine translations

- g vous ne devriez jamais faire confiance traductions automatiques
- b vous ne devriez jamais confiance traductions automatiques
- s vous devriez ne jamais faire confiance à des traductions automatiques

Paul aime virginie qui ne le regarde même pas

- b Paul loves Virginia which doesn't even look not
- s Paul likes Virginia which does not even look at it
- g Paul looks like Virginia that not even

Fluency (fluidité) / Adequation (fidélité)

- ▶ Grille d'évaluation :

Fluency	
5	Flawless English
4	Good English
3	Non-Native English
2	Disfluent English
1	Incomprehensible

Adequacy	
5	All Information
4	Most Information
3	Much Information
2	Little Information
1	None

- ▶ jugements bruités : l'humain s'habitue !
- ▶ tâche difficile et longue (coûteuse)

Classement de systèmes

1/4

SRC	A good idea, provided that it will, prove realistic this time.
REF	Une bonne idée, à condition de se montrer réaliste, cette fois.
S1	Une bonne idée, à condition qu'il se montre réaliste, ceci chronomètre.
S2	Une bonne idée, à condition qu'il sera cette fois réaliste.
S3	Une bonne idée, pourvu qu'elle va s'avérer réaliste cette fois-ci.
S4	Une bonne idée, pourvu qu'il va s'avérer réaliste cette fois.
S5	Une bonne idée, à condition qu'il aille, s'avère réaliste cette fois.
S6	Une bonne idée, à condition qu'elle s'avèrera, réaliste cette fois.
S7	Une bonne idée, à condition qu'elle va se montrer réaliste, cette fois.
S8	A fourni une bonne idée, qu'il va, s'avérer réalistes pour l'instant.
S9	Une bonne idée, à condition que ce sera, cette fois prouver réaliste.
S10	Une bonne idée, pourvu que lui will, se révéler réaliste cette fois-ci.
S11	Une bonne idée, à condition qu'il aille, s'avère réaliste cette fois.
S12	Une bonne idée, fournie qu'il fait, prouve réaliste cette fois.
S13	Une bonne idée, à condition que elle, s'avérer réaliste cette fois.
S14	Une bonne idée, à condition qu'il faudra prouver réaliste cette fois.
S15	Une bonne idée, à condition qu'il soit réaliste de prouver cette fois.

Quelle traduction préférez vous ?

Classement de systèmes

2/4

- SRC Whilst Portugal dominated the match for over one hour, it was not able to reach this precious target, which would have consoled it.
- REF Le Portugal a dominé la partie pendant plus d'une heure, certes, mais il a été incapable de marquer ce but si précieux, qui l'aurait soulagé.
-
- S1 Pendant que le Portugal a dominé le match pendant plus d'une heures, il n'était pas capable d'atteindre cette cible précieuse, qui aurait le consolé.
- S2 Alors que le Portugal dominé le match pendant plus d'une heure, il n'a pas été en mesure d'atteindre cet objectif précieux, dont il aurait fait taire.
- S3 Alors que le Portugal a dominé le match pendant plus d'une heure, il n'a pas été en mesure d'atteindre cet objectif précieux, qu'il aurait réconforté.
- S4 Alors que le Portugal a dominé le match pendant plus d'une heure, il n'était pas en mesure d'atteindre cet objectif précieux, qui aurait réconforté.
- S5 Alors que le Portugal a dominé le match depuis plus d'une heure, il n'était pas capable d'atteindre cette cible précieuse, qui l'aurait consolé.
- S6 Alors que le Portugal a dominé le match pendant plus d'une heure, il n'était pas en mesure d'atteindre cet objectif précieux, qui n'auraient pas consolé.
- S7 Si le Portugal a dominé le match pendant plus d'une heure, il n'a pas été en mesure d'atteindre cet objectif, ce qui aurait consoled précieux.
- S8 Tandis que le Portugal a dominé le match pendant plus d'une heure, il n'était pas capable d'atteindre cet objectif précieux, qui serait consolé.
- S14 Alors que le Portugal a dominé le match pendant plus d'une heure, il n'a pas été en mesure d'atteindre cet objectif précieux, qui aurait consolés.
- S15 Si le Portugal a dominé le match pendant plus d'une heure, il n'a pas été en mesure d'atteindre cet objectif précieux. qui aurait consolons-il.

Classement de systèmes

3/4

SRC Unless the followers of the Sharia law put a stop to that.

REF Pour peu que nous en empêchent ces adeptes de la charia.

S1 À moins que les adeptes de la loi de la charia mettent un arrêt à cela.

S2 Si les partisans de la charia, la loi de mettre un terme.

S3 À moins que les partisans de la charia mettent un terme à cela.

S4 Si les partisans de la loi de la charia mettre un terme.

S5 À moins que les adeptes de la loi de Charia n'y mettent un arrêt.

S6 À moins que les partisans de la Sharia mettre un terme.

S7 À moins que les partisans de la charia loi mettre un terme à tout cela.

S8 À moins que les partisans de la charia que mettre un terme.

S14 À moins que les partisans de la sharia, mettre un terme à cela.

S15 Si les partisans de la charia mettre un terme à tout cela.

Quelle traduction préférez vous ?

Classement de systèmes

4/4

S1	Its-LATL	S8	onlineA
S2	KIT-Phrase-Based-SMT-System	S9	onlineB
S3	LIMSI-Ncode-Constrained-Primary	S10	onlineC
S4	LIUM-EN-FR-12	S11	onlineD
S5	PROMT-DeepHybrid	S12	onlineE
S6	RWTH-Jane2-HPBT-constrained	S13	onlineF
S7	jhu-hiero	S14	uedin-wmt12
		S15	uk-dan-moses

Les données viennent de la compétition organisée dans le cadre de WMT2012

(<http://www.statmt.org/wmt12/results.html>)



WER (Word Error Rate)

- ▶ distance d'édition normalisée (par la taille source / la taille cible / le nombre total d'opérations d'édition)

SRC	She does not think that the issue of British Gas' structure will be a long-term problem .
REF	Elle ne croit pas que le problème structurel de la British perdure .
SMT	Elle ne croit que la question de British Gas' structures sera un problème .

```

REF : Elle ne croit pas que le problème structurel de la Briti
CAN : Elle ne croit que la question de
ALI : <=> <=> <=> DEL <=> SUB SUB DEL <=> I

```

- ▶ $ED = 10, 17 \text{ opérations} \Rightarrow WER = 100 \times 10/17 = 58.8\%$



mWER (Minimum Word Error Rate)

- WER avec la plus proche des références

SRC	She does not think that the issue of British Gas' structure will be a long-term problem .
REF	Elle ne croit pas que le problème structurel de la British perdure .
REF	Elle ne croit pas que la question structurelle de la British Gas sera un problème à long term .
SMT	Elle ne croit que la question de British Gas' structures sera un problème .

Elle ne croit pas que la question structurelle de la British
 Elle ne croit que la question de
 <=> <=> <=> DEL <=> <=> <=> DEL <=> DEL <=>

- $ED = 8, 20 \text{ opérations} \Rightarrow mWER = 100 \times 8/20 = 40\%$



PER (Position Independant Rate)

- ▶ toute permutation d'une référence a un taux d'erreur null.

SRC	She does not think that the issue of British Gas' structure will be a long-term problem .
REF	Elle ne croit pas que le problème structurel de la British perdure .
SMT1	Elle ne croit que la question de British Gas' structures sera un problème .
SMT2	Gas' structures Elle ne croit sera un que la question de British problème .

- ▶ $PER = 100 \times 8/14 = 57.14\%$

- ▶ SER (Sentence Error Rate) = $100 \times \frac{I - \sum_i \delta(Trad_i, Ref_i)}{I} = 100\%$



BLEU

[Papineni et al., 2002]

Ref	Can you give me some medicine for headache ?
SMT1	Can I have some medicine for headache ?
SMT2	Can you give me prescribe some medicine ?
SMT3	Can I have some medicine for headache ?

très bon

bon

ok

nul


BLEU

- ▶ Comparaison de n-grams entre une traduction et une ou plusieurs références
- ▶ 1g jusqu'à 4g (typiquement)
- ▶ $BLEU = BP \times \exp\left(\sum_{n=1}^N w_n \frac{|n\text{-grams}_{trad} \cap n\text{-grams}_{ref}|}{|n\text{-grams}_{trad}|}\right)$
moyenne pondérée des précisions n-gram (entre 0 et 1, 1 = parfait)
- ▶ BP (Brevity Penalty) = $\min(1, \exp(|trad|/|ref|))$
pénaliser les phrases trop courtes par rapport à la référence
- ▶ $w_n = 1/N$




BLEU

- ▶ valable au niveau d'un texte (500 phrases ou plus)
- ▶ la présence d'un n-gram (n grand) est très bien payée
- ▶ semble corrélérer avec les jugements humains (note globale entre 1 et 5)
- ▶ les n-grams les plus fréquents sont souvent les moins informatifs (fluency plus qu'adequacy)
- ▶ lire [Doddington, 2002] pour une variante biaisée davantage vers la fidélité (adequacy) : [NIST](#)



[Bengio et al., 2001]



Embeddings de *[Collobert et al., 2011]*

chalkboard	sofa washroom hallway bathroom darkroom skit ...
charlene	cynthia cathy benji angie ronnie julie caitlin cheryl ...
delighted	amazed thrilled dismayed ridiculed astonished ...
deregulate	liberalise reallocate unsettle penalise unnerve ...
memorizing	deciphering interpreting embodying unlocking ...
parrots	wasps cormorants beetles lizards newts ...
planet	earth universe portal basestar mothership galaxy ...
visible	confusing common hidden standing peculiar ...

plus proches voisins (cosine) de mots pris au hasard.



Deep Learning SMT

- ▶ Des gains en utilisant un modèle de langue neuronal “à la Bengio” en traduction, en RAP
[Schwenk et al., 2006, Le et al., 2012b, Le et al., 2012a]
- ▶ Des packages pour entraîner de tels modèles
 - ▶ *[Schwenk et al., 2012]*
 - ▶ RNNLM <http://www.fit.vutbr.cz/~imikolov/rnnlm/>
- ▶ Des choses simples à faire pour améliorer la traduction à l'aide de ces modèles
 - ▶ ex : modèle global $p(\text{trg word}|\text{src sentence})$ à la
[Patry and Langlais, 2011a]



[Koehn et al., 2009]

	Target Language																					
	en	bg	de	cs	da	el	es	et	fi	fr	hu	it	lt	lv	mt	nl	pl	pt	ro	sk	sl	sv
en	-	40.5	46.8	52.6	50.0	41.0	55.2	34.8	38.6	50.1	37.2	50.4	39.6	43.4	39.8	52.3	49.2	55.0	49.0	44.7	50.7	52.0
bg	61.3	-	38.7	39.4	39.6	34.5	46.9	25.5	26.7	42.4	22.0	43.5	29.3	29.1	25.9	44.9	35.1	45.9	36.8	34.1	34.1	39.9
de	53.6	26.3	-	35.4	43.1	32.8	47.1	26.7	29.5	39.4	27.6	42.7	27.6	30.3	19.8	50.2	30.2	44.1	30.7	29.4	31.4	41.2
cs	58.4	32.0	42.6	-	43.6	34.6	48.9	30.7	30.5	41.6	27.4	44.3	34.5	35.8	26.3	46.5	39.2	45.7	36.5	43.6	41.3	42.9
da	57.6	28.7	44.1	35.7	-	34.3	47.5	27.8	31.6	41.3	24.2	43.8	29.7	32.9	21.1	48.5	34.3	45.4	33.9	33.0	36.2	47.2
el	59.5	32.4	43.1	37.7	44.5	-	54.0	26.5	29.0	48.3	23.7	49.6	29.0	32.6	23.8	48.9	34.2	52.5	37.2	33.1	36.3	43.3
es	60.0	31.1	42.7	37.5	44.4	39.4	-	25.4	28.5	51.3	24.0	51.7	26.8	30.5	24.6	48.8	33.9	57.3	38.1	31.7	33.9	43.7
et	52.0	24.6	37.3	35.2	37.8	28.2	40.4	-	37.7	33.4	30.9	37.0	35.0	36.9	20.5	41.3	32.0	37.8	28.0	30.6	32.9	37.3
fi	49.3	23.2	36.0	32.0	37.9	27.2	39.7	34.9	-	29.5	27.2	36.6	30.5	32.5	19.4	40.6	28.8	37.5	26.5	27.3	28.2	37.6
fr	64.0	34.5	45.1	39.5	47.4	42.8	60.9	26.7	30.0	-	25.5	56.1	28.3	31.9	25.3	51.6	35.7	61.0	43.8	33.1	35.6	45.8
hu	48.0	24.7	34.3	30.0	33.0	25.5	34.1	29.6	29.4	30.7	-	33.5	29.6	31.9	18.1	36.1	29.8	34.2	25.7	25.6	28.2	30.5
it	61.0	32.1	44.3	38.9	45.8	40.6	57.2	25.0	29.7	52.7	24.2	-	29.4	32.6	24.6	50.5	35.2	56.5	39.3	32.5	34.7	44.3
lt	51.8	27.6	33.9	37.0	36.8	26.5	41.0	34.2	32.0	34.4	28.5	36.8	-	40.1	22.2	38.1	31.6	31.6	29.3	31.8	35.3	35.3
lv	54.0	29.1	35.0	37.8	38.5	29.7	42.7	34.2	32.4	35.6	29.3	38.9	38.4	-	23.3	41.5	34.4	39.6	31.0	33.3	37.1	38.0
mt	72.1	32.2	37.2	37.9	38.9	33.7	48.7	26.9	25.8	42.4	22.4	43.7	30.2	33.2	-	44.0	37.1	45.9	38.9	35.8	40.0	41.6
nl	56.9	29.3	46.9	37.0	45.4	35.3	49.7	27.5	29.8	43.4	25.3	44.5	28.6	31.7	22.0	-	32.0	47.7	33.0	30.1	34.6	43.6
pl	60.8	31.5	40.2	44.2	42.1	34.2	46.2	29.2	29.0	40.0	24.5	43.2	33.2	35.6	27.9	44.8	-	44.1	38.2	38.2	39.8	42.1
pt	60.7	31.4	42.9	38.4	42.8	40.2	60.7	26.4	29.2	53.2	23.8	52.8	28.0	31.5	24.8	49.3	34.5	-	39.4	32.1	34.4	43.9
ro	60.8	33.1	38.5	37.8	40.3	35.6	50.4	24.6	26.2	46.5	25.0	44.8	28.4	29.9	28.7	43.0	35.8	48.5	-	31.5	35.1	39.4
sk	60.8	32.6	39.4	48.1	41.0	33.3	46.2	29.8	28.4	39.4	27.4	41.8	33.8	36.7	28.5	44.4	39.0	43.3	35.3	-	42.6	41.8
sl	61.0	33.1	37.9	43.5	42.6	34.0	47.0	31.1	28.8	38.2	25.7	42.3	34.6	37.3	30.0	45.9	38.2	44.1	35.8	38.9	-	42.7
sv	58.5	26.9	41.0	35.6	46.6	33.3	46.6	27.4	30.9	38.9	22.7	42.0	28.2	31.0	23.7	45.6	32.2	44.2	32.7	31.3	33.5	-

Le problème

- ▶ Exemple pris de *[Luong et al., 2010]* :

SRC = the_{STM} new_{STM}, un_{PRE+} democratic_{STM} immigration_{STM} policy_{STM}
TGT = uusi_{STM}, epä_{PRE+} demokraat_{STM+} t_{SUF+} i_{SUF+} s_{SUF+} en_{SUF} maahanmuutto_{PRE+} poli
 (*uusi=new* , *epädemokraattisen=undemocratic* *maahanmuuttopolitiikan=immigration poli*)

- ▶ grands vocabulaires
- ▶ beaucoup de mots hors-vocabulaire
- ▶ De bons outils pour la segmentation (p.ex. Morfessor *[Creutz and Lagus, 2005]*)
- ▶ La segmentation n'est pas le seul problème (voir p.ex. les langues templatiques).

Solutions

- ▶ annoter une langue à morphologie simple (ex. anglais) avec l'information nécessaire à la génération d'une traduction dans une langue à morphologie riche (ex. inuktitut).
 - ▶ souvent à l'aide d'outils complexes (analyseurs morphologique et syntaxique, etc.)
 - ▶ des gains pour certaines langues
 - ▶ ex : *[Avramidis and Koehn, 2008]*
- ▶ segmenter les mots de la langue à morphologie riche à l'aide d'un outil comme Morfessor, puis entraîner un système de TS sur les unités résultantes
 - ▶ des gains pour des petits corpus d'entraînement
 - ▶ des pertes sinon
 - ▶ lire *[Luong et al., 2010]* pour une explication et des solutions



Solutions

- ▶ Segmenter de manière non supervisée la langue à morphologie riche de manière à augmenter la vraisemblance du bitexte d'entraînement
 - ▶ exemple canonique : *[Chung and Gildea, 2009]*
 - modèle génératif sous-jacent : IBM1
 - espace de recherche : les segmentations
 - des gains ... parfois
 - ▶ voir aussi *[Nguyen et al., 2010]*

[Trabelsi, 2012]

tieotokoneongelma ?

tieotokone	computer	0.23
	NULL	0.15
	a	0.15
	computers	0.08
	typewrite	0.04

ongelma	problem	0.27
	the	0.15
	NULL	0.13
	a	0.06
	is	0.04

- ▶ on peut traduire ces mots (et donc segmenter) si suffisamment de morphes ont été vus à l'entraînement
- ▶ une version approchée de cela a été testée
- ▶ aussi "bon" en traduction que d'utiliser Morfessor *[Creutz and Lagus, 2005]* pour segmenter le Finnois





Handrail Intersect

Handrail

Cut String

Winder

Newel Post

Cut string on Wall

Square Nosing

Tread

Closed String

Double Bullnose



Constat

La terminologie est au cœur de l'activité de traduction, mais représente une infime partie des travaux publiés en traduction.

- ▶ Des travaux théoriques menés en linguistique (ex : OLST)
- ▶ Des travaux sur l'extraction :
 - ▶ *[Daille and Morin, 2005]*
 - ▶ TermoStat
http://olst.ling.umontreal.ca/?page_id=91
 - ▶ *[Patry and Langlais, 2005]*
- ▶ Des travaux sur l'alignement de termes dans des ressources comparables (voir les travaux du LINA)
- ▶ Pas d'arrimage systématique à la TS

Constat

- ▶ Pas de protocole d'évaluation reproductible
 - ▶ comparer des extracteurs terminologiques est compliqué *[Gojun et al., 2012]*, CESTA (*[El Hadi et al., 2004]*), etc.
- ▶ Pas de volonté de maintenir une base multilingue et multi-domaines **ouverte** de :
 - ▶ termes structurés (variantes, définitions, etc.)
 - ▶ MWE (*multiword expression*) *[Sag et al., 2001]*
 - ▶ formes idiomatiques
 - ▶ collocations
- ▶ Pourtant cela serait utile...



Enjeux

- ▶ tirer meilleur profit des ressources existantes
 - ▶ meilleur alignement de phrases dans les corpus parallèles
 - ▶ meilleure exploitation des ressources comparables
 - ▶ nettoyage, bonnes pratiques
- ▶ forage systématique des données
 - ▶ *[Smith et al., 2013]*
 - ▶ *[Uszkoreit et al., 2010]*
- ▶ organisation en **domaines**

Ressources comparables

- ▶ On sait extraire des **phrases parallèles**
 - ▶ *[Munteanu and Marcu, 2005]*
 - ▶ *[Smith et al., 2010]*
- ▶ On essaye d'extraire des **segments parallèles**
 - ▶ de données parallèles bruitées *[Riesa and Marcu, 2012]*
 - ▶ de données comparables *[Quirk et al., 2007]* et *[Kumano and Tokunaga, 2007]*
- ▶ On sait aligner des termes avec une précision “décente”
 - ▶ voir *[Hazem, 2013]* !!!
 - ▶ *[Bouamor et al., 2013]* (désambiguïsation des contextes)



[Munteanu and Marcu, 2005]

Recette :

- ▶ Classificateur entraîné à reconnaître des phrases parallèles
 - ▶ traits en grande partie extraits de modèles IBM
- ▶ Considérer les files de presse émises dans deux langues à des dates proches
- ▶ Classifier les paires de phrases de ces files (parallèles ou pas)

Cons :

- ▶ adapté aux documents qui sont datés (sinon très couteux)
- ▶ requiert une annotation de phrases parallèles
- ▶ présuppose un modèle (dictionnaire) adapté
- ▶ processus ad hoc et bruité (qui mène à des gains en traduction)

[Smith et al., 2010]

- ▶ identifier des phrases parallèles dans les articles de Wikipedia liés par la langue.
- ▶ classificateurs versus *rankers*
- ▶ ingénierie fine des *features* (IBM, Wikipedia, etc.)
- ▶ 1.9M de paires de phrases identifiées comme parallèles pour sp-en (1.6M pour la paire de-en)
- ▶ des gains en traduction (pour des corpus d'intérêt "général") lorsqu'ajouté à Europarl.

Ce qu'on l'on fait moins bien

- ▶ identifier les documents d'intérêt sur lesquels appliquer ces techniques
 - ▶ voir l'approche force brute *[Tillmann and Xu, 2009]*
- ▶ classer les documents selon leur degré de parallélisme
 - ▶ les approches "à la Munteanu et Marcu" sont-elles efficaces sur des corpus parallèles ?
- ▶ dépendance à un modèle lexical existant
 - ▶ pour calculer les traits du classificateur
- ▶ pas de modèle génératif décent d'un corpus comparable
 - ▶ mais voir *[Quirk et al., 2007]* et *[Kumano and Tokunaga, 2007]*



Paradocs *[Patry and Langlais, 2011b]*

- ▶ un système qui identifie les textes parallèles dans une collection
- ▶ basé sur un classificateur utilisant des traits simples :
 - ▶ les séquences de nombres
 - ▶ les séquences de mots hapax (d'au moins 4 lettres)
 - ▶ les séquences de ponctuations
- ▶ couplé à un système de RI permettant d'identifier les paires de documents à classifier
- ▶ meilleur que l'état de l'art *[Enright and Kondrak, 2007]*
- ▶ appliqué à la découverte de documents parallèles dans Wikipedia

Wikipedia : Cook, South Australia | Cook (Australie méridionale)

[1] Cook is a railway station and crossing loop on the standard gauge Trans-Australian Railway from Adelaide to Perth, with no inhabited places around.

[2] The town was created in 1917 when the railway was built and is named after former Prime Minister Joseph Cook.

[3] The town depended on the Tea and Sugar Train for the delivery of supplies, and is on the longest stretch of straight railway in the world, at 479 km which stretches from Ooldea to beyond Loongana.

[7] The town was effectively closed in 1997 when the railways were privatised and the new owners did not need a support town there, although the diesel re fuelling facilities remain, and there is overnight accommodation for train drivers.

[9] The bush hospital is closed, and the shop is only opened while the Indian Pacific is in town.

[10] It has a few houses and fuel tanks for the locomotives.

[11] The crossing loop can cross trains up to 1800m long.

[1] Cook est une gare ferroviaire et surtout un point de croisement sur la voie de chemin de fer à écartement standard, la Trans-Australian Railway qui permet à l'Indian Pacific de relier Adelaide à Perth, sans aucun habitant aux alentours.

[2] Il y a quelques maisons abandonnées et quelques réservoirs de gas-oil pour les trains.

[3] Ce point de croisement permet le croisement de trains jusqu'à 1800 mètres de long.

[4] La ville fut créée en 1917 lors de la construction de la voie de chemin de fer.

[5] Elle doit son nom au premier ministre australien de l'époque Joseph Cook.

[6] La ville fut abandonnée en 1997 quand les chemins de fer furent privatisés et que les nouveaux propriétaires estimèrent qu'ils n'avaient pas besoin de personnel à cet endroit, gardant simplement des réserves de gas-oil en cas de nécessité, des logements pour permettre au personnel du train de se reposer la nuit et un magasin qui ouvre lorsque le train est en gare.

[10] Cook est sur la plus longue ligne droite de chemin de fer au monde avec une ligne droite de 479 km.

Articles traduits dans Wikipedia ?

- ▶ Nous avons identifié grâce à `Paradocs` 69 834 paires d'articles parallèles dans `Wikipedia EN-FR 2009` dont 56 801 paires d'articles liés par un lien interlangue
- ▶ 50 de ces paires (prises aléatoirement) ont été analysées ainsi que 50 paires aléatoires liées par un lien interlangue :

	Wikipedia	PARADOCS
Parallèle	4	20
En majorité parallèle	9	9
Partiellement parallèle	11	6
Non parallèle	26	15

- ▶ ~ 33k paires parallèles dans `Wikipedia`

[Rebout, 2012] : documents parallèles

- ▶ 80 documents annotés (phrases alignées) : 17 parallèles ou en partie
- ▶ classificateurs avec *features* basés sur le *markup* de Wikipedia
- ▶ tâche : identifier les paires de documents parallèles
- ▶ validation croisée à 3 plis :

	Recall	Precision	F ₁ -score
neural network	82.4%	87.5%	84.8%
decision tree	70.6%	75.0%	72.7%



[Rebut, 2012] : phrases parallèles

- ▶ 20 *features* (nombre de mots, d'hapax, etc.)
- ▶ différents modes de post-traitement des sorties de classification (*hung*, *greedy* and *extend*)
- ▶ validation croisée à 17 plis (2057 paires de phrases parallèles sur 17 documents parallèles ou presque) :

		Rec.	Prec.	F ₁
(nn)	neural network	57.5	55.2	56.3
(dt)	decision tree	53.9	56.9	55.4
	dt + <i>hung</i> + <i>extend</i>	53.9	69.6	60.8
	nn + <i>greedy</i>	60.5	72.5	66.0
	nn + <i>hung</i>	58.3	73.1	64.9
(◇)	nn + <i>hung</i> + <i>extend</i>	62.7	74.4	67.6
	◇ + bootstrapping	72.0	80.2	75.9

[Rebout, 2012]

- ▶ WIKITITLE : les titres des articles liés par un lien interlangue
- ▶ WIKILUCENE : RI trans-linguistique (dictionnaire)
- ▶ WIKICLASS : classer les documents parallèles + classer les phrases parallèles dans ces documents

	WIKITITLE		WIKICLASS		WIKILUCENE	
sentences	580 288		560 694		1 453 565	
words	1.52M	1.47M	11.17M	10.7M	29.4M	27.3M
≠ words	346K	337K	399K	382K	665K	612K

[Rebut, 2012] :

- ▶ 200 paires de phrases choisies aléatoirement par bitexte extrait :

	WIKICLASS		WIKILUCENE	
parallel	70%	140	18.5%	37
semi-parallel	6%	12	4%	8
non-parallel	24%	48	77.5%	155

- ▶ Préférable de trouver les documents prometteurs
- ▶ Le plus n'est pas forcément l'ami du bien (cf. *[Morin et al., 2007]*)

[Reboot, 2012] : *play it again Sam*

training	WIKITEST	NEWSTEST	EUROTEST
(E)UROPARL	10.44	21.54	27.51
(W)IKICLASS	12.04	20.10	20.43
E+W-T	11.56	21.85	27.71
E+W	12.20	22.46	27.71
E+W-T+W	12.11	22.19	27.38
E+W-T+W-B	12.38	22.56	27.65



À quand la TS parfaite ?

Une technologie imparfaite peut être serviable à qui veut l'utiliser intelligemment.

- ▶ Prédire quand la traduction est serviable à un besoin donné (pour le moment, plutôt fait à l'échelle des phrases)
- ▶ Détecter des erreurs (humaines ou machine)
- ▶ Combiner différentes solutions (mémoires, etc.)
- ▶ Interfaces intelligentes pour le traducteur



Outils d'aide à la traduction

Le traducteur réalise un nombre impressionnant d'opérations (ex : requêtes à Google) sans aucune assistance

- ▶ vers une plateforme intégrée (terminologie, dictionnaire, mémoires, suggestions, correcteurs)
- ▶ quelques réalisations “timides”
 - ▶ TSRali.com [Bourdaillet et al., 2010]
 - ▶ TransType [Langlais et al., 2002]
 - ▶ Web-based tool : [Caitra](#) [Koehn, 2009]

La communauté TALN n'accueille pas favorablement les travaux de terrain : l'humain est dans la boucle, ce qui ne permet pas une évaluation simple.

TSRali.com *[Bourdaillet et al., 2010]*

A translation finder :

- ▶ initialement développé par Michel Simard (TransSearch)
- ▶ produit commercialisé par Terminotix
- ▶ embarque des modèles d'alignement de mots et un bitexte de plus de 8M de paires de phrases
- ▶ bitexte mis à jour régulièrement

- ▶ clients typiques : bureaux de traduction



TransSearch

TransSearch

administrateur Log out Home Queries My Account Preferences Users Subscriptions Collections Parameters Help Français

Expression

Collections

213 translations of *in keeping with* in 909 occurrences

conforme à	203	conforme à	203
conformément à	139	Fourth, the judge must be convinced that a conditional sentence is in keeping with the general principles of proportionality of the sentence.	Quatrièmement, le juge doit être convaincu que l'emprisonnement avec sursis est conforme aux principes généraux de la proportionnalité de la peine.
respecte	68	It is a bill that is in keeping with the campaign and election commitments made by the Conservative Party of Canada to Canadians.	Ce dernier est conforme aux engagements pris par le Parti conservateur pendant la campagne électorale.
correspond à	32	All this is in keeping with our Canadian values of compassion and generosity in times of need, a quality displayed across every community in Canada.	Voilà qui est conforme à nos valeurs canadiennes de compassion et de générosité qui s'expriment dans des cas comme celui-là, une qualité commune à toutes les collectivités du Canada.
fidèle à	21	The reserve was in keeping with the established budgetary practice of setting aside policy reserves for specific contingent purposes.	La réserve était conforme à la pratique budgétaire établie qui consistait à mettre de l'argent de côté pour certaines éventualités.
en conformité avec	21		
dans le sens de	19		
dans le respect de	14		
dans le cadre de	13		
compatible avec	12		
compte tenu	12		
inscrit dans	12		

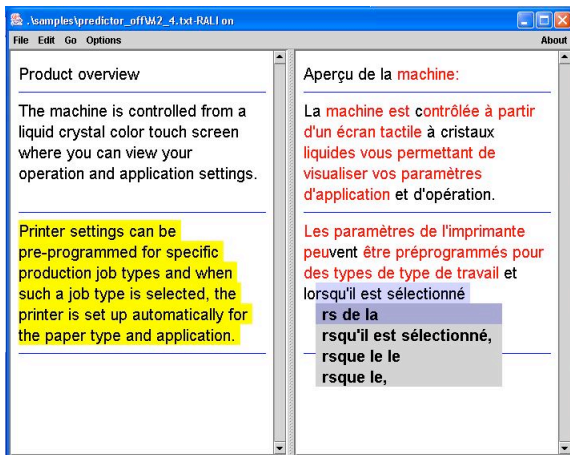
query

TransType *[Langlais et al., 2002]*

- ▶ éditeur pour le traducteur offrant la complétion
- ▶ à l'intérieur :
 - ▶ un moteur de traduction statistique
 - ▶ un modèle de l'utilisateur ($p(\text{utilité} \mid \text{complétion}, \text{contexte})$)
- ▶ énormes gains potentiels (voir *[Macklovitch, 2004]*)

- ▶ un outil idéal pour intégrer d'autres technologies
- ▶ voir *[González-Rubio et al., 2013]*


TransType



Voir les travaux de Alabau

- ▶ qui intègrent différentes modalités dans une même interface

- ▶ efficiency



May 9, 2014

Multimodal IMT

Vicent Alabau

- ▶ Voir le projet **Casmacat** (post-édition)

<http://www.casmacat.eu>



Caitra *[Koehn, 2009]*

- ▶ un système de complétion basé sur la TS
- ▶ possibilité de cliquer sur des segments

Paul	Newman	le magnifique
Paul	Newman	the wonderful
Mr	Newman ,	the magnificent
Mr Paul	Newman here	the wonderful
as Paul	Committee	beautiful
another	Newman , who speaks	magnificent
with Paul		the splendid
, Paul		the excellent
of Paul		the beautiful
work of Paul		it
the words of Paul		great

[1] Paul Newman le magnifique >>

Paul

enter Newman ☒

- ▶ application Web (ruby on rails) <http://www.caitra.org/>

**ACL-35 (1997).**

Proceedings of the 35th Annual Meeting of the Association for Computational Linguistics (ACL), Madrid, Spain.

**Avramidis, E. and Koehn, P. (2008).**

Enriching morphologically poor languages for statistical machine translation.

In *Proceedings of ACL-08 : HLT*, pages 763–770, Columbus, Ohio.

**Bengio, Y., Ducharme, R., and Vincent, P. (2001).**

A neural probabilistic language model.

In *Advances in Neural Information Processing Systems*.

**Bisson, F. and Fluhr, C. (2000).**

Sentence alignment in bilingual corpora based on crosslingual querying.

In *Computer-Assisted Information Retrieval*, RIAO 2000, pages 529–542.

**Bouamor, D., Semmar, N., and Zweigenbaum, P. (2013).**

Context vector disambiguation for bilingual lexicon extraction from comparable corpora.

In Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics (Volume 2 : Short Papers), pages 759–764, Sofia, Bulgaria.

**Bourdaillet, J., Huet, S., Langlais, P., and Lapalme, G. (2010).**

TransSearch : from a bilingual concordancer to a translation finder.

Mach. Transl., 24(3-4) :241–271.

**Braune, F. and Fraser, A. (2010).**

Improved unsupervised sentence alignment for symmetrical and asymmetrical parallel corpora.

In 23rd COLING, pages 81–89.

**Brown, P., Lai, J., and Mercer, R. (1991).**

Aligning Sentences in Parallel Corpora.

In *Proceedings of the 29th Annual Meeting of the Association for Computational Linguistics (ACL)*, pages 169–176, Berkeley, California.



Brown, P. F., Pietra, S. A. D., Pietra, V. J. D., and Mercer, R. L. (1993).

The mathematics of statistical machine translation : Parameter estimation.

Computational Linguistics, 19(2) :263–311.



Chang, J. and Chen, M. (1997).

An alignment method for noisy parallel corpora based on image processing techniques.

In [ACL-35, 1997], pages 297–304.



Chung, T. and Gildea, D. (2009).

Unsupervised tokenization for machine translation.

In *EMNLP*, pages 718–726.



Collins, M. (1999).

Head-Driven Statistical Models for Natural Language Parsing.

PhD thesis, University of Pennsylvania.



Collobert, R., Weston, J., Bottou, L., Karlen, M., Kavukcuoglu, K., and Kuksa, P. (2011).

Natural language processing (almost) from scratch.

Journal of Machine Learning Research, 12 :2493–2537.



Creutz, M. and Lagus, K. (2005).

Unsupervised Morpheme Segmentation and Morphology Induction from Text Corpora Using Morfessor 1.0.

Technical report.



Daille, B. and Morin, E. (2005).

French-english terminology extraction from comparable corpora.

Natural Language Processing–IJCNLP 2005, page 707–718.



Debili, F. (1992).

Aligning sentences in bilingual texts french-english and french-arabic.

In Proceedings of the International Conference on Computational Linguistics (COLING) 1992, pages 517–525, Nantes, France.

**Deng, Y., Kumar, S., and Byrne, W. (2007).**

Segmentation and alignment of parallel text for statistical machine translation.

Natural Language Engineering, 13 :235–260.

**Doddington, G. (2002).**

Automatic evaluation of machine translation quality using n-gram cooccurrence statistics.

In *Proceedings of the HLT*, pages 257–258, San Diego, USA.

**El Hadi, W., Dabbadie, M., Timimi, I., Rajman, M., Langlais, P., and A., H. (2004).**

Work-in-Progress project Report : CESTA Translation Evaluation Campaign.

In *2nd International Workshop on Language Resources for Translation Work, Research and Training, satellite workshop of COLING 2004*, pages 8–17, Geneva, Switzerland.

**Enright, J. and Kondrak, G. (2007).**

A Fast Method for Parallel Document Identification.

In *NAACL HLT 2007, Companion Volume*, pages 29–32, Rochester, NY.



Fung, P. and Church, K. (1994).

K-vec : A new approach for aligning sentences in bilingual corpora.

In *Proceedings of the International Conference on Computational Linguistics (COLING) 1994*, pages 1096–1102, Kyoto, Japan.



Gale, W. A. and Church, K. W. (1993a).

A program for aligning sentences in bilingual corpora.

In *Computational Linguistics*, volume 19, pages 75–102.



Gale, W. A. and Church, K. W. (1993b).

A program for aligning sentences in bilingual corpora.

Comput. Linguist., 19(1) :75–102.



Gojun, A., Heid, U., Weißbach, B., Loth, C., and Mingers, I. (2012).

Adapting and evaluating a generic term extraction tool.

In *8th LREC*, Istanbul, Turkey.



González-Rubio, J., Ortíz-Martínez, D., José-Miguel, B., and Casacuberta, F. (2013).

Interactive machine translation using hierarchical translation models.

In *EMNLP 2013*.



Goutte, C., Carpuat, M., and Foster, G. (2012).

The impact of sentence alignment errors on phrase-based machine translation performance.

In *10th AMTA*.



Hazem, A. (2013).

Extraction de lexiques bilingues à partir de corpus comparables.

PhD thesis, Université de Nantes, oct.



Hutchins, W. J. and Somers, H. L. (1992).

An Introduction to Machine Translation.

Academic Press.



Jurafsky, D. and Martin, J. H. (2000).

Speech and Language Processing.

Prentice Hall.

**Kay, M. and Röscheisen, M. (1993).**

Text-translation alignment.

Computational Linguistics, 19(1) :121–142.

**Knight, K. (1999a).**

Decoding complexity in word-replacement translation models.

Computational Linguistics, 25(4).

**Knight, K. (1999b).**

A statistical mt tutorial workbook.

<http://www.isi.edu/natural-language/people/knight.html>.

**Koehn, P. (2009).**

A web-based interactive computer aided translation tool.

In *Proceedings of the ACL-IJCNLP 2009 Software Demonstrations*, ACLDemos '09, pages 17–20.

**Koehn, P., Birch, A., and Steinberger, R. (2009).**

462 Machine Translation Systems for Europe.

In *Machine Translation Summit XII*.

**Kumano, T. and Tokunaga, H. T. T. (2007).**

Extracting phrasal alignments from comparable corpora by using joint probability smt model.



Lamraoui, F. and Langlais, P. (2013).

Yet another fast, robust and open source sentence aligner. time to reconsider sentence alignment ?

In XIV Machine Translation Summit, pages 77–84, Nice, France.



Langé, J.-M. and Gaussier, E. (1995).

Alignement de corpus multilingues au niveau des phrases.

T.A.L., 36(1-2) :67–80.



Langlais, P., Lapalme, G., and Loranger, M. (2002).

Transtype : Development-Evaluation Cycles to Boost Translators' Productivity.

Machine Translation, Kluwer Academic Publishers., 17 :77–98.
Special issue on Embedded Machine Translation Systems.



Langlais, P., Simard, M., and Véronis, J. (1998).

Methods and practical issues in evaluating alignment techniques.

In *Proceedings of the 36th Annual Meeting of the Association for Computational Linguistics (ACL)*, Montréal, Canada.



Le, H.-S., Allauzen, A., and Yvon, F. (2012a).

Continuous space translation models with neural networks.

In *Proceedings of the 2012 Conference of the North American Chapter of the Association for Computational Linguistics : Human Language Technologies*, pages 39–48, Montréal, Canada. Association for Computational Linguistics.



Le, H.-S., Allauzen, A., and Yvon, F. (2012b).

Measuring the influence of long range dependencies with neural network language models.

In *Proceedings of the NAACL-HLT 2012 Workshop : Will We Ever Really Replace the N-gram Model ? On the Future of Language Modeling for HLT*, pages 1–10, Montréal, Canada.



Li, P., Sun, M., and Xue, P. (2010).

Fast-champollion : a fast and robust sentence alignment algorithm.

In *Proceedings of the 23rd International Conference on Computational Linguistics : Posters*, COLING '10, pages 710–718.



Luong, M.-T., Nakov, P., and Kan, M.-Y. (2010).

A hybrid morpheme-word representation for machine translation of morphologically rich languages.

In *EMNLP*, pages 148–157.



Macklovitch, E. (2004).

The contribution of end-users to the transtype2 project.

In Frederking, R. E. and Taylor, K., editors, *AMTA*, volume 3265 of *Lecture Notes in Computer Science*, pages 197–207.

Springer.



Melamed, I. D. (1997).

A portable algorithm for mapping bitext correspondence.

In [ACL-35, 1997], pages xx–yyy.



Moore, R. C. (2002).

Fast and accurate sentence alignment of bilingual corpora.

In *Proceedings of the 5th Conference of the Association for Machine Translation in the Americas on Machine Translation : From Research to Real Users*, AMTA '02, pages 135–144.



Morin, E., Daille, B., Takeuchi, K., and Kageura, K. (2007).

Bilingual terminology mining - using brain, not brawn comparable corpora.

In *45th ACL*, pages 664–671, Prague, Czech Republic.



Munteanu, D. and Marcu, D. (2005).

Improving machine translation performance by exploiting non-parallel corpora.

Computational Linguistics, 31(4) :477–504.



Nguyen, T., Vogel, S., and Smith, N. A. (2010).

Nonparametric word segmentation for machine translation.

In *23rd COLING*, pages 815–823.



Papineni, K., Roukos, S., Ward, T., and Zhu, W.-J. (2002).

Bleu : a method for automatic evaluation of machine translation.

In *Proceedings of the 40th Annual Meeting of the Association for Computational Linguistics (ACL)*, pages 311–318, Philadelphia, Pennsylvania, USA.



Patry, A. and Langlais, P. (2005).

Corpus-based terminology extraction.

In *7th International Conference on Terminology and Knowledge Engineering (TKE 2005)*, Copenhagen, Denmark.



Patry, A. and Langlais, P. (2011a).

Going beyond word cooccurrences in global lexical selection for statistical machine translation using a multilayer perceptron.

In *5th International Joint Conference on Natural Language Processing (IJCNLP'11)*, pages 658–666, Chiang Mai, Thailand.



Patry, A. and Langlais, P. (2011b).

Identifying parallel documents from a large bilingual collection of texts : application to parallel article extraction in wikipedia.

In *Proceedings of the 4th Workshop on Building and Using Comparable Corpora : Comparable Corpora and the Web*, pages 87–95.

**Quan, X., Kit, C., and Song, Y. (2013).**

Non-monotonic sentence alignment via semisupervised learning.

In *ACL*, pages 622–630.

**Quirk, C., Udupa, R., and Menezes, A. (2007).**

Generative models of noisy translations with applications to parallel fragment extraction.

In *In Proceedings of MT Summit XI, European Association for Machine Translation*.

**Rebout, L. (2012).**

L'extraction de phrases en relation de traduction dans wikipédia.
Master's thesis, Université de Montréal.

**Ribeiro, A., Dias, G., Lopes, G., and Mexia, J. (2001).**

Cognates alignment.

In *Machine Translation Summit VIII, Machine Translation in The Information Age*, pages 287–292, Santiago de Compostela, Galicia, Spain.

**Riesa, J. and Marcu, D. (2012).**

Automatic Parallel Fragment Extraction from Noisy Data.

In Proceedings of the 2012 Conference of the North American Chapter of the Association for Computational Linguistics : Human Language Technologies, pages 538–542, Montréal, Canada.

**Sag, I. A., Baldwin, T., Bond, F., Copestake, A., and Flickinger, D. (2001).**

Multiword expressions : A pain in the neck for nlp.

In 3rd CICLing-2002, pages 1–15.

**Schwenk, H., Dechelotte, D., and Gauvain, J.-L. (2006).**

Continuous space language models for statistical machine translation.

In Proceedings of the COLING/ACL on Main conference poster sessions, COLING-ACL '06, pages 723–730, Stroudsburg, PA, USA. Association for Computational Linguistics.

**Schwenk, H., Rousseau, A., and Attik, M. (2012).**

Large, pruned or continuous space language models on a gpu for statistical machine translation.

NAACL-HLT 2012, page 11.



Sennrich, R. and Volk, M. (2011).

Iterative, mt-based sentence alignment of parallel texts.

In 18th Nordic Conference of Computational Linguistics.



Simard, M., Foster, G., and Isabelle, P. (1992).

Using cognates to align sentences in bilingual corpora.

In Proceedings of the 4th Conference on Theoretical and Methodological Issues in Machine Translation (TMI), pages 67–81, Montréal, Québec.



Simard, M. and Plamondon, P. (1996).

Bilingual sentence alignment : Balancing robustness and accuracy.

In Proceedings of the Second Conference of the Association for Machine Translation in the Americas (AMTA), Montréal, Québec.



Smith, J., Quirk, C., and Toutanova, K. (2010).

Extracting parallel sentences from comparable corpora using document level alignment.

In *Human Language Technologies : The 2010 Annual Conference of the North American Chapter of the Association for Computational Linguistics*, page 403–411.



Smith, J. R., Saint-amand, H., Koehn, P., Callison-burch, C., Plamada, M., and Lopez, A. (2013).

Dirt cheap web-scale parallel text from the common crawl.
In *51st ACL*, pages 1374–1383, Sofia, Bulgaria.



Tillmann, C. and Xu, J. (2009).

A simple sentence-level extraction algorithm for comparable data.

In *Proceedings of Human Language Technologies : The 2009 Annual Conference of the North American Chapter of the Association for Computational Linguistics, Companion Volume : Short Papers*, page 93–96.



Trabelsi, C. (2012).

Traduction statistique vers une langue à morphologie riche :
Combinaison d'algorithmes de segmentation morphologique et
de modèles statistiques de traduction automatique.

Master's thesis, Université de Montréal.



Uszkoreit, J., Ponte, J. M., Papat, A. C., and Dubiner, M. (2010).

An empirical study on web mining of parallel data.

In *23rd COLING*, pages 1101–1109, Beijing, China.



Varga, D., Németh, L., Halácsy, P., Kornai, A., Trón, V., and Nagy, V. (2005).

Parallel corpora for medium density languages.

In *Recent Advances in Natural Language Processing (RANLP 2005)*, pages 590–596.



Véronis, J. and Langlais, P. (2000).

Evaluation of parallel text alignment systems : The ARCADE project, volume 13, chapter 19, pages 369–388.

Parallel Text Processing, Kluwer.



Vogel, S., Ney, H., and Tillmann, C. (1996).

Hmm-based word alignment in statistical translation.

In Proceedings of the International Conference on Computational Linguistics (COLING) 1996, pages 836–841, Copenhagen, Denmark.



Wu, D. (1994).

Aligning a parallel english-chinese corpus statistically with lexical criteria.

In Proceedings of the 32nd Annual Meeting of the Association for Computational Linguistics (ACL), pages 80–87, Las Cruces, New Mexico.



Wu, D. (1997).

Stochastic inversion transduction grammars and bilingual parsing of parallel corpora.

Computational Linguistics, 23(3) :377–404.



Wu, D. (2000).

Bracketing and aligning words and constituents in parallel text using Stochastic Inversion Transduction Grammars, volume 13, chapter 19, pages 139–168.

Parallel Text Processing, Kluwer.



Yamada, K. and Knight, K. (2001).

A syntax-based statistical translation model.

In *Proceedings of the 39th Annual Meeting of the Association for Computational Linguistics (ACL)*, pages 523–530, Toulouse, France.



Yu, Q., Max, A., and Yvon, F. (2012).

Revisiting sentence alignment algorithms for alignment visualization and evaluation.

In *5th workshop BUCC*, pages 10–16.