

# Une alternative aux modèles de traduction statistique d'IBM : Les triggers inter-langues

Caroline Lavecchia, Kamel Smaïli, David Langlois

► **To cite this version:**

Caroline Lavecchia, Kamel Smaïli, David Langlois. Une alternative aux modèles de traduction statistique d'IBM : Les triggers inter-langues. 15eme conférence sur le Traitement Automatique des Langues Naturelles - TALN'08, Jun 2008, Avignon, France. 2008. <inria-00285275>

**HAL Id: inria-00285275**

**<https://hal.inria.fr/inria-00285275>**

Submitted on 5 Jun 2008

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

## Une alternative aux modèles de traduction statistique d'IBM : Les triggers inter-langues

Caroline Lavecchia<sup>1,2</sup> Kamel Smaïli<sup>1,2</sup> David Langlois<sup>1,3</sup>

(1) LORIA/Speech Group, Campus scientifique, BP 239, 54506 Vandoeuvre  
lès Nancy Cedex, France

(2) Université Nancy2

(3) IUFM de Lorraine

**Résumé.** Dans cet article, nous présentons une nouvelle approche pour la traduction automatique fondée sur les triggers inter-langues. Dans un premier temps, nous expliquons le concept de triggers inter-langues ainsi que la façon dont ils sont déterminés. Nous présentons ensuite les différentes expérimentations qui ont été menées à partir de ces triggers afin de les intégrer au mieux dans un processus complet de traduction automatique. Pour cela, nous construisons à partir des triggers inter-langues des tables de traduction suivant différentes méthodes. Nous comparons par la suite notre système de traduction fondé sur les triggers inter-langues à un système état de l'art reposant sur le modèle 3 d'IBM (Brown & al., 1993). Les tests menés ont montré que les traductions automatiques générées par notre système améliorent le score BLEU (Papineni & al., 2001) de 2,4% comparé à celles produites par le système état de l'art.

**Abstract.** In this paper, we present an original approach for machine translation based on inter-lingual triggers. First, we describe the idea of inter-lingual triggers and how to determine them. Then, we present the way to make good use of them in order to integrate them in an entire translation process. We used inter-lingual triggers to estimate different translation tables. Then we compared our translation system based on triggers to a state-of-the-art system based on IBM model 3 (Brown & al., 1993). The experiments showed that automatic translations generated by our system outperform model 3 of IBM by 2.4% in terms of BLEU (Papineni & al., 2001).

**Mots-clés :** Traduction Automatique Statistique, Triggers Inter-Langues, Information Mutuelle, Corpus parallèle, Décodage.

**Keywords:** Statistical Machine Translation, Inter-Lingual Triggers, Mutual Information, Parallel corpus, Decoding process.

## 1 Introduction

L'objectif de la traduction automatique est de transformer une phrase donnée dans une langue source en une phrase dans une langue cible. Pour résoudre ce problème très complexe, il est possible d'intégrer le savoir faire de traducteurs humains, mais cela demande une modélisation de ce savoir qui est en soi un sujet de recherche. Il faut utiliser des modèles formels des langues source et cible issus du Traitement Automatique des Langues, et un modèle de traduction à base de règles, comme par exemple ce qui est fait dans le système de Systran (Jean Senellart, 2001). Cet effort de conception doit être répété pour chaque couple de langues (même si le savoir faire peut être en partie transféré). L'approche statistique, quant à elle, utilise une voie différente. En effet, elle n'utilise pas de connaissances *a priori*, mais s'appuie sur des corpus bilingues. Ces corpus sont alignés, c'est-à-dire que le lien entre chaque partie du texte de la langue source est fait avec la partie correspondante dans la langue cible. Le lien est généralement fait au niveau de la phrase. Partant de ces corpus, une analyse statistique utilise les redondances existantes afin d'estimer les paramètres du processus de traduction. La traduction statistique est possible car les modèles *ad hoc* sont couplés avec des algorithmes de programmation dynamique qui maximisent une fonction de traduction d'une phrase source vers une phrase cible. IBM a utilisé avec succès cette approche (Brown & al., 1993). La plupart des systèmes statistiques actuels sont fondés sur les modèles d'IBM.

L'approche statistique nécessite de définir un modèle de traduction qui va permettre de calculer les probabilités de traduction entre les mots, les suites de mots et les autres constituants de la phrase. IBM propose pour cela une méthode itérative engendrant 5 modèles de traduction différents, du plus simple au plus complexe. Cela aboutit à des modèles performants, mais longs et complexes à estimer. Cette complexité croît très vite au fur et à mesure des paramètres supplémentaires pris en compte lors du processus de traduction.

Dans cet article, nous proposons une nouvelle approche permettant de construire un modèle de traduction fondé sur les triggers inter-langues (extension des triggers classiques) pour construire notre système de traduction statistique. Le concept de triggers est bien connu de la communauté de la modélisation statistique du langage. Facile à mettre en oeuvre, il possède une certaine souplesse qui permet de l'appliquer à différents niveaux de lecture de la phrase (mots, genre, nombre, constituants syntaxiques). Nous montrerons que les triggers inter-langues permettent de construire un modèle de traduction efficace. Nous comparerons ses résultats à ceux fondés sur les modèles d'IBM.

Nous présentons dans la partie 2 la notion générale des triggers. La partie 3 définit le concept de triggers inter-langues qui associe à chaque mot de la langue source une liste de traductions possibles. Dans la partie 4, nous présentons la manière dont les triggers inter-langues ont été intégrés à un processus complet de traduction automatique. Nous terminons enfin par une conclusion qui met en avant les points forts de notre méthode et donne quelques perspectives futures des travaux de notre groupe de recherche.

## 2 Rappel sur les triggers

Le concept de triggers est très souvent cité en modélisation statistique du langage et plus particulièrement en reconnaissance de la parole. Les triggers permettent entre autre d'améliorer et de généraliser le modèle Cache (Kuhn & DeMori, 1990). Le modèle Cache favorise la probabilité

d'un mot  $w_i$  récemment apparu dans le contexte gauche. Un modèle de triggers va plus loin et accorde une probabilité plus importante à une liste de mots corrélés au mot  $w_i$  (Tillmann & Ney, 1996). Les triggers sont sélectionnés selon la valeur de l'Information Mutuelle (IM) donnée par la formule suivante :

$$IM(x, y) = P(x, y) \log \frac{P(x, y)}{P(x)P(y)} \quad (1)$$

Chaque mot appartenant au vocabulaire est alors associé à  $n$  mots qui lui sont le plus fortement corrélés d'après la valeur de l'IM. Un trigger est un ensemble composé d'un mot appelé *déclencheur* et d'une liste de mots qu'il déclenche appelés *déclenchés*. La figure 1 illustre un exemple de triggers anglais.

Les triggers ont beaucoup été utilisés en reconnaissance de la Parole où ils sont combinés avec un modèle n-gramme classique (Tillmann & Ney, 1997).




FIG. 1 – Exemples de triggers classiques

### 3 Les triggers inter-langues

Nous proposons dans ce qui suit d'étendre ce concept pour l'utiliser avec des corpus bilingues alignés. Nous appelons ce concept triggers inter-langues. Un trigger inter-langue est défini comme étant un ensemble composé d'un mot déclencheur d'une langue source et des mots déclenchés d'une langue cible qui lui sont fortement corrélés. Ainsi, chaque mot  $f$  du vocabulaire français  $V_F$  est associé à  $n$  mots anglais ou triggers inter-langues qui lui sont le plus fortement corrélés au sens de l'IM. Plus formellement,

$$\forall f_i \in V_F, Trig_n(f_i) \text{ est l'ensemble des } n \text{ triggers inter-langues de } f_i$$

De la même façon, chaque mot  $e$  du vocabulaire anglais  $V_E$  est associé à  $n$  mots français :

$$\forall e_i \in V_E, Trig_n(e_i) \text{ est l'ensemble des } n \text{ triggers inter-langues de } e_i.$$

Les triggers inter-langues sont déterminés suivant la valeur de l'Information Mutuelle calculée sur un corpus aligné au niveau de la phrase. Ce corpus est constitué de paires  $(E, F)$  où  $F$  est la traduction de  $E$ . Les triggers permettent de repérer les éléments en relation d'une langue à l'autre. Les triggers sont estimés en utilisant la formule (2).

$$IM(f, e) = P(f, e) * \log \left( \frac{P(f, e)}{P(f) * P(e)} \right) \quad (2)$$

$$P(X) = \frac{N(X)}{|Corpus|} \quad P(f, e) = \frac{N(f, e)}{|Corpus|} \quad (3)$$

–  $e$  et  $f$  sont des éléments de la paire de phrases  $(E, F)$

- $N(X)$  est le nombre de phrases dans lesquelles le mot  $X$  apparaît
  - $N(e, f)$  est le nombre de paires  $(E, F)$  de phrases du corpus aligné dans lesquelles les mots  $e$  et  $f$  co-occurrent.
  - $|Corpus|$  est le nombre de paires de phrases constituant le corpus aligné.
- La figure 2 montre un exemple de triggers inter-langues de l’Anglais vers le Français. Ce qui




FIG. 2 – Exemples de triggers inter-langues

motive l’utilisation de cette notion est le fait que l’on espère trouver la traduction du mot déclencheur dans la liste des mots déclenchés.

Notons que ce principe de triggers inter-langues est utilisé en modélisation du langage pour enrichir des langues faiblement dotées à partir d’autres langues très riches en termes de corpus (Kim & Khudanpur, 2004).

## 4 La traduction automatique avec les triggers inter-langues

La première étape pour la mise en place de notre système de traduction est l’apprentissage des triggers inter-langues. Pour ce faire, nous les déterminons sur un corpus parallèle extrait des actes du Parlement Européen dont les statistiques sont résumées dans le tableau 1.

TAB. 1 – Corpus d’apprentissage

	<b>Français</b>	<b>Anglais</b>
Paires de phrases	596K	
Taille (en mots)	17.3M	15.8M
Vocabulaire (en mots)	77.5K	60.3K

Nous appliquons les formules (2) pour détecter les couples  $(e, f)$  les plus corrélés et qui constitueront les triggers inter-langues.

Quelques exemples de triggers Anglais-Français sont présentés dans le tableau 2, de même des exemples de triggers Français-Anglais sont présentés dans le tableau 3. La troisième colonne des tableaux indique pour chaque couple de mots déclencheur-déclenché la valeur de

l'Information Mutuelle qui lui est associée. Une analyse qualitative de nos triggers montre que les mots déclenchés peuvent souvent être apparentés à de possibles traductions du mot déclencheur ou à des mots vraiment très proches du point de vue du sens. Par ailleurs, comme le montrent les exemples des tableaux, les triggers détectent également les différents sens des homographes (ainsi, deux sens de 'porte' sont détectés avec de forts taux d'Information Mutuelle). Ces constats sont valables dans les deux sens de traduction.

TAB. 2 – Exemples de mots français déclenchés par des mots anglais

Déclencheur anglais	Déclenchés français	IM (10 <sup>4</sup> )	Déclencheur anglais	Déclenchés français	IM (10 <sup>4</sup> )
chess	pion	0,33	champion	champion	2,38
	échiquier	0,29		championne	1,00
	échecs	0,26		homme	0,28
door	porte	20,96	sense	sens	69,06
	ouverte	5,15		bon	8,91
	portes	2,73		sentiment	7,23
translation	traduction	34,16	plant	usine	7,54
	erreur	2,73		installation	3,92
	version	1,49		plantes	3,59

TAB. 3 – Exemples de mots anglais déclenchés par des mots français

Déclencheur français	Déclenchés anglais	IM (10 <sup>4</sup> )	Déclencheur français	Déclenchés anglais	IM (10 <sup>4</sup> )
échecs	failures	5,88	champion	champion	2,38
	failure	0,88		expert	0,25
	chess	0,26		champions	0,24
porte	door	20,96	sens	sense	69,06
	relates	5,21		direction	28,68
	concerns	4,23		meaning	11,61
traduction	translation	34,16	plantes	plants	19,20
	error	2,51		plant	3,59
	version	1,49		crops	1,98

Nous proposons dans ce qui suit, d'utiliser l'ensemble des triggers inter-langues pour mettre en place notre système de traduction. Nous le comparons ensuite à un système état de l'art reposant sur le modèle 3 d'IBM (Brown & al., 1993). Pour ce faire, nous avons utilisé le décodeur Pharaoh<sup>1</sup>(Koehn, 2004), afin de traduire automatiquement un corpus de test de 1444 phrases anglaises. Les traductions produites sont ensuite comparées à l'aide de la mesure Bleu, une mesure automatique couramment employée en traduction automatique (Papineni & al., 2001). Dans les sections suivantes, nous présentons trois façons d'identifier les traductions potentielles

<sup>1</sup>Le modèle de langage de la langue cible est un modèle trigram (méthode de lissage de Good-Turing. Les poids des différents modèles sont les suivants : 1 pour le modèle de langage, 1 pour le modèle de traduction, 1 pour le modèle de ré-ordonnancement et enfin une pénalité de mot de 0. Le décodage est fait avec ré-ordonnancement.

d'un mot au sein de notre système à partir des triggers inter-langues déterminés auparavant. Elles donnent lieu à l'estimation de trois tables de traduction.

#### 4.1 Les tables de traduction *Trig-n*

Dans un premier temps, nous estimons que tous les triggers inter-langues peuvent être assimilés à des traductions possibles. Par conséquent, nous les ajoutons tous dans la table de traduction. Ainsi, un mot anglais  $e_i$  est une traduction probable du mot français  $f_j$  s'il fait partie de ses triggers inter-langues. La probabilité associée à cette traduction est la valeur de l'Information Mutuelle normalisée du couple  $(e_i, f_j)$ .

$$\forall f_j \in V_F, \forall e_i, e_k \in Trig_n(f_j) \quad P(e_i|f_j) = \frac{IM(f_j, e_i)}{\sum_{k=1}^n IM(f_j, e_k)} \quad (4)$$

Par la suite, nous appellerons les tables de traduction ainsi construites *Trig-n* avec  $n$  le nombre de triggers inter-langues retenus pour chaque mot français du vocabulaire.

L'évaluation de notre système mis en place avec les tables de traduction *Trig-n*,  $n$  variant de 10 à 200, est décrite par la série *Trig-n* de l'histogramme de la figure 3. Dans un premier temps, nous remarquons une amélioration du score Bleu de plus de 2 points entre *Trig-10* et *Trig-20*. Ceci montre que, globalement, les traductions correctes d'un mot déclencheur sont dans les 20 meilleurs déclenchés. Toutefois, lorsque  $n$  prend des valeurs au delà de 20, l'impact est beaucoup plus faible. Il faut préciser que, dans la configuration utilisée, Pharaoh, dans un souci de rapidité de recherche, ne prend en compte que les 20 meilleures traductions d'un mot donné. Donc, il est inutile d'aller au delà de 20. Toutefois l'impact montré n'est pas nul car le fait de normaliser les probabilités sur 20, 50 ou 100 triggers modifie l'échelle des valeurs de la table de traduction et donc le poids de cette table dans le processus de recherche. Notons que nous avons modifié cette configuration afin de permettre à Pharaoh de tenir compte de plus de 20 traductions, mais que cela n'a pas eu d'impact positif sur les performances.

#### 4.2 Les tables de traduction *Sym-n*

La deuxième méthode de construction d'une table de traduction consiste à considérer comme traductions possibles les couples  $(f_j, e_i)$  qui respectent la contrainte de symétrie suivante :

$$\text{Si } e_i \in Trig_n(f_j) \text{ et } f_j \in Trig_n(e_i) \text{ Alors } e_i \in Sym_n(f_j) \quad (5)$$

$e_i$  appartient aux traductions possibles de  $f_j$  ( $Sym_n(f_j)$ ), si  $e_i$  fait partie des triggers inter-langues de  $f_j$  et inversement si  $f_j$  est un trigger inter-langue de  $e_i$  comme l'illustre la figure 4.

Cette contrainte de symétrie nous permet d'affiner la liste des triggers inter-langues de  $f_j$  pour ne retenir que les plus pertinents. Nous supposons que si  $e_i$  est un des  $n$  mots les plus corrélés avec  $f_j$  et que  $f_j$  est également dans les  $n$  mots les plus déclenchés par  $e_i$ , alors il y a de fortes chances que  $e_i$  soit une traduction de  $f_j$ . La probabilité associée à ce couple est calculée de la manière suivante :

$$\forall f_j \in V_F, \forall e_i, e_k \in Sym_n(f_j) \quad P_{sym}(e_i|f_j) = \frac{IM(f_j, e_i)}{\sum_{k=1}^n IM(f_j, e_k)} \quad (6)$$




FIG. 3 – Évaluation des traductions produites à l’aide des tables de traduction *Trig-n*, *Sym-n* et *Smooth-n* en fonction de *n*

Triggers anglais–français Triggers français–anglais

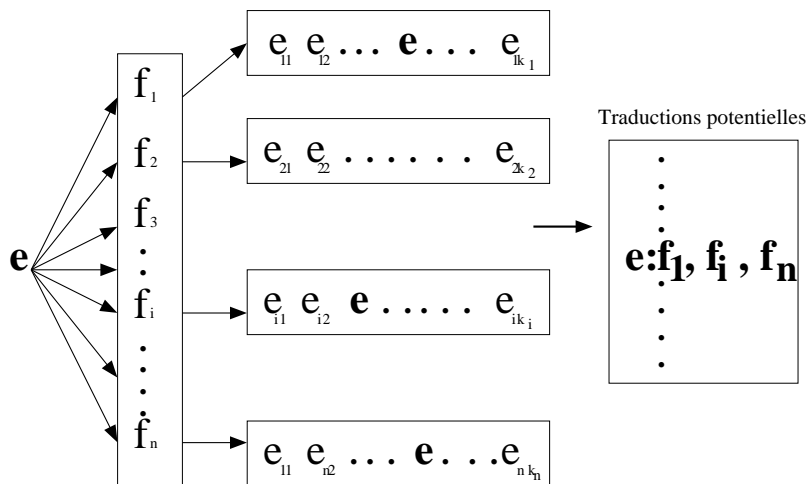


FIG. 4 – Identification des traductions potentielles d’un mot par symétrie

La contrainte de symétrie réduit considérablement le nombre de couples retenus parmi les triggers inter-langues. En moyenne, seuls 21% des triggers inter-langues respectent la contrainte de symétrie (5). Ainsi, nous espérons n’avoir retenu que les triggers les plus pertinents.

La série *Sym-n* de l’histogramme de la figure 3 présente l’évaluation de notre système fondé sur les tables de traduction *Sym-n*. Nous observons à nouveau une nette amélioration du score Bleu lorsque l’on utilise *Sym-20* au lieu de la table *Sym-10*. Nous notons, également, une légère amélioration du score Bleu qui passe de 25, 84 pour *Trig-10* à 25, 91 pour *Sym-10*. La contrainte de symétrie nous permet donc, dans ce cas, d’écarter des triggers inter-langues qui ne seraient



pas de réelles traductions. Malheureusement, cette observation ne s'étend pas aux autres tables *Sym-n* (avec  $n > 10$ ) puisque leur score Bleu reste inférieur à ceux obtenus avec les tables *Trig-n*. Même si cette intuition semble naturelle, la contrainte de symétrie semble donc être trop restrictive pour améliorer les performances de notre système.

Nous proposons donc une troisième façon d'identifier et d'estimer les traductions potentielles pour assouplir cette contrainte de symétrie. Pour cela, nous décidons d'utiliser une technique de lissage des probabilités (*smoothing*).

### 4.3 Les tables de traduction *Smooth-n*

Afin de ne pas affecter une probabilité nulle aux couples  $(f, e)$  qui ne satisfont pas la contrainte de symétrie "*e déclenche f et f déclenche e*", nous proposons d'utiliser une technique de lissage pour estimer une troisième table de traduction que nous appelons par conséquent *Smooth-n*. En modélisation du langage, ces techniques dites de *smoothing* permettent de lisser les probabilités de manière à ce que chaque événement, même impossible, se voit affecter une probabilité (Ney *et al.*, 1994). Nous proposons d'employer le même type de technique. Pour ce faire, nous réduisons la probabilité des triggers symétriques des tables *Sym-n*. La masse ainsi récupérée est répartie uniformément sur les triggers non symétriques. Cette nouvelle estimation est calculée de la manière suivante :

$$\forall e_i \in Trig_n(f_j) \quad P_{smooth}(e_i|f_j) = \begin{cases} P_{sym}(e_i|f_j) - \epsilon & \text{si } e_i \in Sym_n(f_j) \\ \gamma & \text{sinon} \end{cases} \quad (7)$$

Pour un mot français, nous retirons une quantité  $\epsilon$  à chaque probabilité de traduction assignée à ses triggers inter-langues symétriques et nous redistribuons la masse récoltée uniformément sur ses autres triggers inter-langues non symétriques.

La dernière série de l'histogramme de la figure 3 indique les performances de notre système reposant sur les tables *Smooth-n*. Rappelons que  $n$  est le nombre de triggers inter-langues retenus pour chaque mot du vocabulaire français. L'allure de la série est la même que pour les expériences précédentes. Toutefois, nous pouvons constater que notre système est plus performant avec les tables *Smooth-n* qu'avec les tables *Sym-n*. Par conséquent, nous pouvons dire que la contrainte de symétrie est en effet trop restrictive, et que le fait de conserver les triggers non-symétriques permet bien d'améliorer les performances. En revanche, malgré ces efforts de lissage, notre système reste le plus performant lorsque chaque trigger inter-langue est considéré comme une traduction potentielle qu'il respecte la contrainte de symétrie ou non (série *Trig-n*).

### 4.4 Comparaison avec le modèle 3 de traduction d'IBM

Afin d'évaluer la pertinence de notre système fondé sur les triggers inter-langues, nous avons comparé ses performances avec celles d'un système état de l'art reposant sur le modèle 3 d'IBM et que nous appelons *M3*. Ce dernier a été entraîné, à l'aide de l'outil Giza++ (Och & Ney, 2000), sur le même corpus parallèle d'apprentissage que les triggers inter-langues et testé avec le même décodeur sur les mêmes 1444 phrases. Les performances du système *M3* sont inférieures à celle de notre système. En effet, nous obtenons un score BLEU de 28,07 (cf. courbe *M3* de la figure 3) par rapport à un score de 28,49 pour *Trig-100*.

Toutefois, comme nous l'avons dit précédemment, le décodeur Pharaoh ne prend en compte

pour chaque mot français que les 20 meilleures traductions dans le but de réduire son espace de recherche. Afin d'optimiser les performances de notre système, nous avons paramétré le décodeur de telle sorte de lui laisser la possibilité de prendre en compte plus de 20 traductions par mot français. Pour cela, nous faisons varier le paramètre *ttable-limit*. Nous optimisons également le paramètre *ttable-threshold* qui permet d'écarter de l'espace de recherche les couples de traductions dont la probabilité est inférieure à un certain seuil. L'optimisation est réalisée indépendamment pour les deux systèmes. Les résultats en terme de score Bleu sont présentés dans le tableau 4. Les performances de notre système sont optimales lorsque

TAB. 4 – Optimisation des paramètres *ttable-limit* et *ttable-threshold*

Modèle	<i>ttable-limit</i>	<i>ttable-threshold</i>	Bleu
<i>Trig-100</i>	22	0,04	<b>28,95</b>
<i>M3</i>	53	0,00	28,27

le décodeur restreint son espace de recherche aux 22 meilleures traductions par mot français dont la probabilité est supérieure ou égale à 0,04. Celles du système *M3* le sont lorsque le décodeur réduit son espace de recherche aux 53 meilleures traductions pour un mot français sans contrainte sur la valeur des probabilités. Notre système fondé sur les triggers inter-langues apporte une amélioration de 2,4% en termes de score BLEU par rapport au système état de l'art.

## 5 Conclusion et perspectives

Nous avons présenté dans cet article une alternative aux modèles d'IBM pour la traduction statistique. La méthode est fondée sur les triggers inter-langues. Ces triggers ont été sélectionnés à partir d'un corpus parallèle aligné au niveau de la phrase extrait des actes du Parlement Européen. Ils permettent de définir pour chaque mot (français ou anglais) une liste des mots (français ou anglais) qui lui sont fortement corrélés. Ainsi un mot français est associé à une liste de mots anglais et vice versa.

Dans le but d'évaluer la pertinence des triggers inter-langues en tant que traductions potentielles, nous avons mis en place un système de traduction de mots basé uniquement sur les triggers inter-langues. Nous avons ensuite comparé ses performances à celles d'un système de référence état de l'art reposant sur les modèles d'IBM. Après optimisation des deux systèmes, les tests menés ont montré qu'en ne retenant que 22 traductions potentielles pour chaque mot français, les performances de notre système apportent une amélioration de 2,4% du score BLEU par rapport au système de référence.

Ces premiers résultats révèlent la faisabilité de l'utilisation des triggers inter-langues en traduction automatique statistique. Par ailleurs, le concept de triggers inter-langues est un formalisme souple et nous nous sommes concentrés ici que sur des triggers d'ordre 1-1, c'est-à-dire qu'un mot est traduit par un seul mot. La prochaine étape de nos travaux consiste à mettre en place un système de traduction fondé sur les triggers d'ordre n-m, où plusieurs mots peuvent être traduits par plusieurs mots. Ainsi, notre système sera un système de traduction de séquences de mots et non plus de mots.

A plus long terme, nous pouvons envisager beaucoup d'autres manières d'utiliser les triggers inter-langues en traduction statistique, comme par exemple en tant que mesure de confiance. De

plus, nous venons de voir qu'ils permettent de prendre en compte des séquences de mots, mais nous pouvons également imaginer déterminer des triggers inter-langues d'autre nature que le mot comme par exemple des triggers de traits syntaxiques.

Plusieurs autres applications des triggers inter-langues ont été envisagées et sont en cours de développement dans notre groupe de recherche.

## Remerciements

Ce travail est subventionné par la fondation d'entreprises EADS (European Aeronautic Defence and Space Company) dans le cadre d'une thèse sur la traduction Parole-Parole

## Références

- BROWN P. F. & AL. (1993). The mathematics of statistical machine translation : parameter estimation. *Computational Linguistics*, **19**, 263–311.
- JEAN SENELLART, PÉTER DIENES T. V. (2001). New generation systran translation system. In *MT Summit VIII*, Santiago de Compostela, Spain.
- KIM W. & KHUDANPUR S. (2004). Lexical triggers and latent semantic analysis for cross-lingual language model adaptation. *ACM Transactions on Asian Language Information Processing (TALIP)*, **3**(2), 94–112.
- KOEHN P. (2004). Pharaoh : A beam search decoder for phrase-based statistical machine translation models. In *6th Conference Of The Association For Machine Translation In The Americas*, p. 115–224, Washington, DC, USA.
- KUHN R. & DEMORI R. (1990). A cache-based natural language model for speech recognition. *IEEE Trans. PAMI*, **12**(6), 570–582.
- NEY H., ESSEN U. & KNESER R. (1994). On structuring probabilistic dependences in stochastic language modelling. *Computer Speech and Language*, **8**, 1–38.
- OCH F. J. & NEY H. (2000). Improved statistical alignment models. In *ACL '00 : Proceedings of the 38th Annual Meeting on Association for Computational Linguistics*, p. 440–447, Morristown, NJ, USA : Association for Computational Linguistics.
- PAPINENI K. & AL. (2001). Bleu : a method for automatic evaluation of machine translation. In *Proceedings of the 40th Annual of the Association for Computational linguistics*, p. 311–318, Philadelphia, USA.
- TILLMANN C. & NEY H. (1996). *Selection criteria for word trigger pairs in language modeling*, In L. M. ET C. DE LA HIGUERA, Ed., *Grammatical Inference : Learning Syntax from Sentences*, p. 98–106. Lecture Notes in Artificial Intelligence 1147, Springer Verlag.
- TILLMANN C. & NEY H. (1997). Word trigger and the EM algorithm. In *Proceedings of the Conference on Computational Natural Language Learning*, p. 117–124, Madrid, Spain.