



European Language  
Resource Coordination  
Connecting Europe Faculty

---

# “Les principes de la traduction automatique statistique”

Auteur: François Yvon (LIMSI, CNRS)



Atelier Traduction Automatique CEF.AT, 11 mai 2016

1



European Language  
Resource Coordination  
Connecting Europe Faculty

## Traduction humaine / Bio-traduction

---

- Haute qualité
- Coûteuse
  - Expertise rare
  - Formation longue
  - Délais



Atelier Traduction Automatique CEF.AT, 11 mai 2016

2


**Traduction humaine **ouillée** (CAT)**


---

- Réutilise **au mieux** les traductions passées
  - Recopie des « matchs » exacts
  - Adaptation des « matchs » partiels
  - Traduction humaine en cas de besoin
- Qualité des mémoires de traduction (TM)
- Idéal: une TM par type de document
- TM évolutives, collaboratives, etc

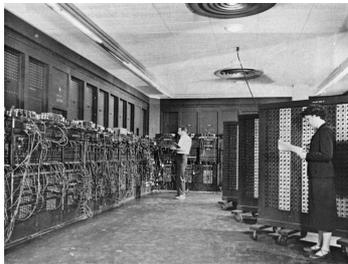



 Atelier Traduction Automatique CEF.AT, 11 mai 2016
 3


**La traduction « automatique » (TA)**


---

- Instantanée
- Disponible 24h/24
- Traite du texte tout venant
- Coût dérisoire  
(voire gratuit)
- Qualité imprévisible & incontrôlable  
(du médiocre, du grotesque, du très bon)




 Atelier Traduction Automatique CEF.AT, 11 mai 2016
 4

European Language Resource Coordination  
Connecting Europe Facility

## Le meilleur des deux mondes ?

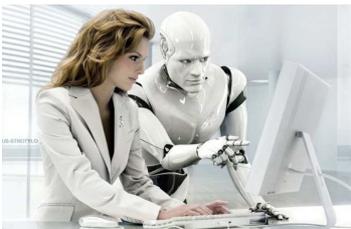



---

- Tâches répétitives, non solvables: TA  
(faible valeur ajoutée)

**La traduction statistique amplifie l'utilisation des TM:**

- décompose les segments
- multiplie les « matches »



- Tâches créatives : HT, CAT  
(haute valeur ajoutée)

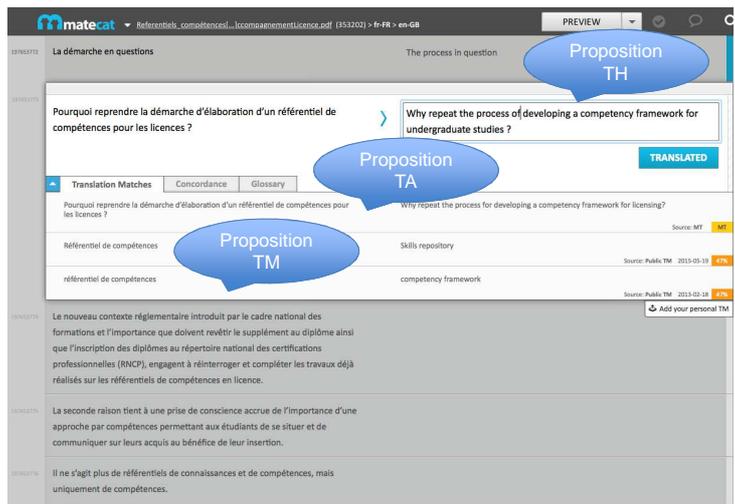
 Atelier Traduction Automatique CEF.AT, 11 mai 2016 5

European Language Resource Coordination  
Connecting Europe Facility

## Une hybridation possible




---



**Proposition TH**

**Proposition TA**

**Proposition TM**

 Atelier Traduction Automatique CEF.AT, 11 mai 2016 6

European Language Resource Coordination  
Connecting Europe Facility

## Un long chemin vers la TA statistique




---

- TA 1960-1990
  - Formulation de règles, systèmes experts
  - « *Logiciellisation* » du problème (sous-tâches, modules, tests)
- Constat: La TA est « *AI – complete* »
- TA Statistique 1990-
  - Construit des modèles (**approximations**)
  - A partir de **données**
  - Solution imparfaite:
    - Intégration dans les WF de traduction
    - Pré / post-édition





CNRS

Atelier Traduction Automatique CEF.AT, 11 mai 2016

7

European Language Resource Coordination  
Connecting Europe Facility

## Principes de la TA statistique




---

Output

↑

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

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

Decoding Algorithm

Translation Model

Language Model

Input

↓

« La meilleure traduction ( $e_{best}$ ) est celle qui est la plus probable parmi toutes les traductions ( $e$ ) possibles de la phrase d'entrée ( $f$ ). »

La qualité de  $e$  dépend de deux termes:

- $P(f|e)$  :  $f$  et  $e$  sont bien appariés
- $P(e)$  :  $e$  est une phrase bien formée

En TAS ces termes sont appris à partir de données

CNRS

Atelier Traduction Automatique CEF.AT, 11 mai 2016

8



## Deux sources de connaissance



### Les données pour la TAS:

- Traductions humaines (bitextes)
- Textes en langue cible
- De grande qualité
- En grande qualité

GERMAN	ENGLISH	FRENCH
<p>Einleitung</p> <p><i>I. Von dem Unterschiede der reinen und empirischen Erkenntnis</i></p> <p>Daß alle unsere Erkenntnis mit der Erfahrung anfangt, daran ist gar kein Zweifel; denn wodurch sollte das Erkenntnisvermögen sonst zur Ausübung erweckt werden, geschähe es nicht durch Gegenstände, die unsere Sinne rühren und teils von selbst Vorstellungen bewirken, teils unsere Verstandstätigkeit in Bewegung bringen, diese zu vergleichen, sie zu verknüpfen oder zu trennen, und so den rohen Stoff sinnlicher Eindrücke zu einer Erkenntnis der Gegenstände zu verarbeiten, die Erfahrung heißt? Der Zeit nach geht also keine Erkenntnis in uns vor der Erfahrung vorher, und mit dieser fängt alle an.</p>	<p>Introduction</p> <p><i>I. Of the difference between Pure and Empirical Knowledge</i></p> <p>That all our knowledge begins with experience there can be no doubt. For how is it possible that the faculty of cognition should be awakened into exercise otherwise than by means of objects which affect our senses, and partly of themselves produce representations, partly rouse our powers of understanding into activity, to compare to connect, or to separate these, and so to convert the raw material of our sensuous impressions into a knowledge of objects, which is called experience? In respect of time, therefore, no knowledge of ours is antecedent to experience, but begins with it.</p>	<p>Introduction</p> <p><i>I. De la différence de la connaissance pure et de la connaissance empirique.</i></p> <p>Que toute notre connaissance commence avec l'expérience, cela ne soulève aucun doute. En effet, par quoi notre pouvoir de connaître pourrait-il être éveillé et mis en action, si ce n'est par des objets qui frappent nos sens et qui, d'une part, produisent par eux-mêmes des représentations, et d'autre part, mettent en mouvement notre faculté intellectuelle, afin qu'elle compare, lie ou sépare ces représentations, et travaille ainsi la matière brute des impressions sensibles pour en tirer une connaissance des objets, celle qu'on nomme l'expérience? Ainsi, chronologiquement, aucune connaissance ne précède en nous l'expérience et c'est avec elle que toutes commencent.</p>



Atelier Traduction Automatique CEF,AT, 11 mai 2016

9



## Exploitation des bitextes



- Identification des phrases « parallèles » par **alignement**
- Identification d'équivalences lexicales: **alignement de mots + probabilités de traduction**
- Régularités syntaxiques de surface: **modèles de langue**

GERMAN	ENGLISH	FRENCH
<p>Einleitung</p> <p><i>I. Von dem Unterschiede der reinen und empirischen Erkenntnis</i></p> <p>Daß alle unsere Erkenntnis mit der Erfahrung anfangt, daran ist gar kein Zweifel; denn wodurch sollte das Erkenntnisvermögen sonst zur Ausübung erweckt werden, geschähe es nicht durch Gegenstände, die unsere Sinne rühren und teils von selbst Vorstellungen bewirken, teils unsere Verstandstätigkeit in Bewegung bringen, diese zu vergleichen, sie zu verknüpfen oder zu trennen, und so den rohen Stoff sinnlicher Eindrücke zu einer Erkenntnis der Gegenstände zu verarbeiten, die Erfahrung heißt? Der Zeit nach geht also keine Erkenntnis in uns vor der Erfahrung vorher, und mit dieser fängt alle an.</p>	<p>Introduction</p> <p><i>I. Of the difference between Pure and Empirical Knowledge</i></p> <p>That all our knowledge begins with experience there can be no doubt. For how is it possible that the faculty of cognition should be awakened into exercise otherwise than by means of objects which affect our senses, and partly of themselves produce representations, partly rouse our powers of understanding into activity, to compare to connect, or to separate these, and so to convert the raw material of our sensuous impressions into a knowledge of objects, which is called experience? In respect of time, therefore, no knowledge of ours is antecedent to experience, but begins with it.</p>	<p>Introduction</p> <p><i>I. De la différence de la connaissance pure et de la connaissance empirique.</i></p> <p>Que toute notre connaissance commence avec l'expérience, cela ne soulève aucun doute. En effet, par quoi notre pouvoir de connaître pourrait-il être éveillé et mis en action, si ce n'est par des objets qui frappent nos sens et qui, d'une part, produisent par eux-mêmes des représentations, et d'autre part, mettent en mouvement notre faculté intellectuelle, afin qu'elle compare, lie ou sépare ces représentations, et travaille ainsi la matière brute des impressions sensibles pour en tirer une connaissance des objets, celle qu'on nomme l'expérience? Ainsi, chronologiquement, aucune connaissance ne précède en nous l'expérience et c'est avec elle que toutes commencent.</p>



Atelier Traduction Automatique CEF,AT, 11 mai 2016

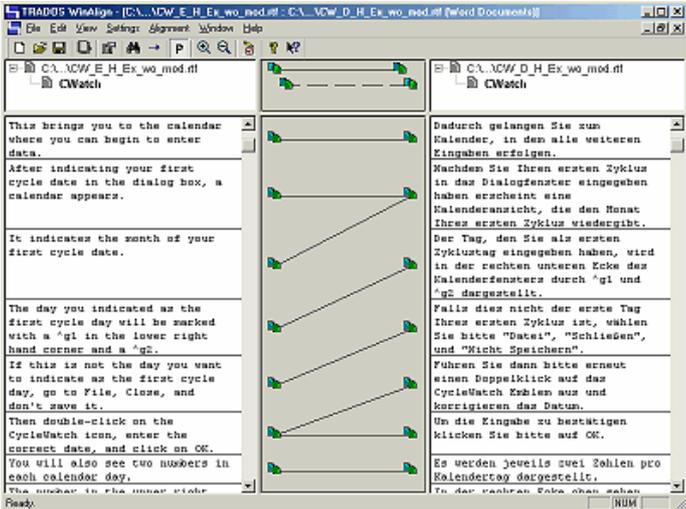
10



European Language  
Resource Coordination  
Connecting Europe Facility

## Alignement des phrases







Atelier Traduction Automatique CEF.AT, 11 mai 2016

11



European Language  
Resource Coordination  
Connecting Europe Facility

## Alignement des mots







Atelier Traduction Automatique CEF.AT, 11 mai 2016

12



## Alignement des mots



---

### CLASSIC SOUPS

		Sm.	Lg.
清 燉 雞 湯 57.	House Chicken Soup (Chicken, Celery, Potato, Onion, Carrot) .....	1.50	2.75
雞 飯 湯 58.	Chicken Rice Soup .....	1.85	3.25
雞 麵 湯 59.	Chicken Noodle Soup .....	1.85	3.25
廣 東 雲 吞 60.	Cantonese Wonton Soup .....	1.50	2.75
蕃 茄 湯 61.	Tomato Clear Egg Drop Soup .....	1.65	2.95
雲 吞 湯 62.	Regular Wonton Soup .....	1.10	2.10
酸 辣 湯 63.	Hot & Sour Soup .....	1.10	2.10
蛋 花 湯 64.	Egg Drop Soup .....	1.10	2.10
雲 吞 湯 65.	Egg Drop Wonton Mix .....	1.10	2.10
豆 腐 菜 湯 66.	Tofu Vegetable Soup .....	NA	3.50
雞 玉 米 湯 67.	Chicken Corn Cream Soup .....	NA	3.50
蟹 肉 玉 米 湯 68.	Crab Meat Corn Cream Soup .....	NA	3.50
海 鮮 湯 69.	Seafood Soup .....	NA	3.50



Atelier Traduction Automatique CEF.AT, 11 mai 2016

13



## Alignement des mots



---

- Principes sous-jacents
  - Cooccurrences lexicales bilingues
  - Contraintes de localité (proximité source => proximité cible)
  - Contraintes de fertilité (chaque mot cible ne traduit que peu de mots source – et réciproquement)
- Ne connaît que les mots du corpus
- Problème difficile pour l'humain, mal posé pour la machine
- Résultat souvent imparfait



Atelier Traduction Automatique CEF.AT, 11 mai 2016

14

European Language Resource Coordination  
Connecting Europe Facility

## Traduction statistique




---

I love the boy.  
J'aime le garçon.  
I love the dog.  
J'aime le chien.  
They love the dog.  
Ils aiment le chien.  
They talk to the girl.  
Ils parlent à la fille.  
They talk to the dog.  
Ils parlent au chien.  
I talk to the mother.  
Je parle à la mère.

Aligned Data

Atelier Traduction Automatique CEF.AT, 11 mai 2016

15

European Language Resource Coordination  
Connecting Europe Facility

## Traduction statistique




---

I love the boy.  
J'aime le garçon.  
I love the dog.  
J'aime le chien.  
They love the dog.  
Ils aiment le chien.  
They talk to the girl.  
Ils parlent à la fille.  
They talk to the dog.  
Ils parlent au chien.  
I talk to the mother.  
Je parle à la mère.

Aligned Data

I	J'		mother	mère	
	Je		dog	chiene	
love	aime		they	ils	
	aiment		talk	parlent	
the	le			parle	
	la		to	à	
boy	garçon			au/_the	
girl	fille				

Collated Statistics

Atelier Traduction Automatique CEF.AT, 11 mai 2016

16



## Traduction statistique



---

I love the boy.  
J'aime le garçon.  
I love the dog.  
J'aime le chien.  
They love the dog.  
Ils aiment le chien.  
They talk to the girl.  
Ils parlent à la fille.  
They talk to the dog.  
Ils parlent au chien.  
I talk to the mother.  
Je parle à la mère.

Aligned Data

→

Input I talk to the girl.

I	J'		mother	mère	
	Je		dog	chiene	
love	aime		they	ils	
	aiment		talk	parlent	
the	le			parle	
	la		to	à	
boy	garçon			au/_the	
girl	fille				

Collated Statistics



Atelier Traduction Automatique CEF.AT, 11 mai 2016

17



## Traduction statistique



---

I love the boy.  
J'aime le garçon.  
I love the dog.  
J'aime le chien.  
They love the dog.  
Ils aiment le chien.  
They talk to the girl.  
Ils parlent à la fille.  
They talk to the dog.  
Ils parlent au chien.  
I talk to the mother.  
Je parle à la mère.

Aligned Data

→

Input I talk to the girl.

I	J'		mother	mère	
	Je		dog	chiene	
love	aime		they	ils	
	aiment		talk	parlent	
the	le			parle	
	la		to	à	
boy	garçon			au/_the	
girl	fille				

Collated Statistics

↓

J'parlent à la fille.

Output



Atelier Traduction Automatique CEF.AT, 11 mai 2016

18

European Language Resource Coordination  
Connecting Europe Facility

## Traduction statistique



I love the boy.  
J'aime le garçon.  
I love the dog.  
J'aime le chien.  
They love the dog.  
Ils aiment le chien.  
They talk to the girl.  
Ils parlent à la fille.  
They talk to the dog.  
Ils parlent au chien.  
I talk to the mother.  
Je parle à la mère.

Aligned Data

I talk to the girl  
J' parlent au le fille  
2/3 2/3 1/3 2/5 1/1  
Je parle à la fille  
1/3 1/3 2/3 2/5 1/1

Comment choisir la meilleure?

Atelier Traduction Automatique CEF.AT, 11 mai 2016

19

European Language Resource Coordination  
Connecting Europe Facility

## Traduction statistique



I love the boy.  
J'aime le garçon.  
I love the dog.  
J'aime le chien.  
They love the dog.  
Ils aiment le chien.  
They talk to the girl.  
Ils parlent à la fille.  
They talk to the dog.  
Ils parlent au chien.  
I talk to the mother.  
Je parle à la mère.

Aligned Data

### Le modèle de langue

- Contraintes de surface en cible
- Suites de mots possibles + leurs probabilités
- Appris sur des corpus monolingues
  - Je parle : OK
  - J' parlent : KO
  - la fille : OK
  - le fille : KO
- Je parle à la fille >> J' parlent à le fille

Atelier Traduction Automatique CEF.AT, 11 mai 2016

20

European Language Resource Coordination  
Connecting Europe Facility

## Traduction statistique

Input: *I talk to the girl.*

Aligned Data:

I love the boy.  
J'aime le garçon.  
I love the dog.  
J'aime le chien.  
They love the dog.  
Ils aiment le chien.  
They talk to the girl.  
Ils parlent à la fille.  
They talk to the dog.  
Ils parlent au chien.  
I talk to the mother.  
Je parle à la mère.

Collated Statistics:

I	J'		mother	mère	
	Je		dog	chiene	
love	aime		they	ils	
	aiment		talk	parlent	
the	le			parle	
	la		to	à	
boy	garçon			au/_the	
girl	fille				

Language Model

Output: *Je parle à la fille.*

Atelier Traduction Automatique CEF.AT, 11 mai 2016

European Language Resource Coordination  
Connecting Europe Facility

## Traduire : des mots aux segments

- Traduire des mots isolés est risqué
  - perte du contexte source;
  - erreurs d'accord (*le fille ...*),
  - idiomes, mots-composés, termes, etc.
- La « fluidité » repose sur le modèle de langue
- Bien meilleur
  - Préférer des segments longs
  - En dernier ressort : mots isolés

*the girl : la fille*  
*to the girl : à la fille*  
*I talk : Je parle*

Atelier Traduction Automatique CEF.AT, 11 mai 2016



European Language  
Resource Coordination  
Connecting Europe Facility

## TAS « à base de mots »



---

I love the boy.  
J'aime le garçon.  
I love the dog.  
J'aime le chien.  
They love the dog.  
Ils aiment le chien.  
They talk to the girl.  
Ils parlent à la fille.  
They talk to the dog.  
Ils parlent au chien.  
I talk to the mother.  
Je parle à la mère.

➔

Input

I talk to the girl.

I	J		mother mère	
	Je		dog chiene	
love	aime		they ils	
	aiment		talk	parlent
the	le			parle
	la		to	à
boy	garçon			au/_the
girl	fille			

Collated Statistics

J'parlent à la fille.

Output



Atelier Traduction Automatique CEF.AT, 11 mai 2016

23



European Language  
Resource Coordination  
Connecting Europe Facility

## TAS « à base de segments »



---

I love the boy.  
J'aime le garçon.  
I love the dog.  
J'aime le chien.  
They love the dog.  
Ils aiment le chien.  
They talk to the girl.  
Ils parlent à la fille.  
They talk to the dog.  
Ils parlent au chien.  
I talk to the mother.  
Je parle à la mère.

➔

Input

I talk to the girl.

I love	J'aime	
They love	Ils aiment	
They talk	Ils parlent	
I talk	Je parle	
To the dog	au chien	
the boy	le garçon	
the dog	le chien	
to the girl	à la fille	
to the boy	au garçon	
to the mother	à la mère	



Atelier Traduction Automatique CEF.AT, 11 mai 2016

24

European Language Resource Coordination  
Connecting Europe Facility

TAS « à base de segments »

Aligned Data

Input

I talk to the girl.

I love	J'aime	
They love	Ils aiment	
They talk	Ils parlent	
I talk	Je parle	
To the dog	au chien	
the boy	le garçon	
the dog	le chien	
to the girl	à la fille	
to the boy	au garçon	
to the mother	à la mère	

Output

Je parle à la fille.

Atelier Traduction Automatique CEF.AT, 11 mai 2016

25

European Language Resource Coordination  
Connecting Europe Facility

TAS « à base de segments »

- Traductions visiblement meilleures
- Technologie mature & efficace: Google, Microsoft, Baidu, Logiciels professionnels (CAT, TA)
- Implémentation publique: **Moses**
- Système le plus utilisé
- Développé par des projets européens (2007-)
- Utilisé dans MT@EC (DGT)

MOSES  CORE

Atelier Traduction Automatique CEF.AT, 11 mai 2016

26



## Dépasser l'état de l'art




---

- Meilleures analyses linguistiques
  - Syntaxe en langue cible
  - Prise en compte de la morphologie
  - Traduction « sémantique »
  - Modélisation du discours
- Meilleurs modèles statistiques
  - Multiplication des modèles
  - Réseaux neuronaux profonds
- Meilleure utilisation des données
  - Pivot, transfert entre langues
  - Sélection des corpus
- Progression régulière ... mais trop lente
- **Amélioration garantie: plus de données, de meilleure qualité !**



Atelier Traduction Automatique CEF.AT, 11 mai 2016

27



## La place des données en TAS




---

- La TAS est **exclusivement à base de données**
- Connaissance extraite de grands corpus
  - Correspondances bilingues (données parallèles)
  - Régularités de surface (textes cibles)
  - Peut inclure: dictionnaire, terminologies bilingues, etc.
- Limitations majeure:
  - Qualité de la TA dépend de la « qualité » des données
  - Pas de données : pas de TA



Atelier Traduction Automatique CEF.AT, 11 mai 2016

28



## Qualité des bitextes



---

**Plus de résultats**

<p>But always remember: garbage in, garbage out! No conversion will make a bad picture good.</p>	<p>Mais souvenez -vous, mauvaises données à l'entrée, mauvais résultats à la sortie. Aucune conversion ne rendra belle une image de mauvaise qualité.</p>
<p>Like they say, garbage in, garbage out.</p>	<p>C'est un marché en pleine expansion.</p>
<p>"Garbage in, garbage out."</p>	<p>"A données inexactes, résultats erronés".</p>
<p>If you put in garbage, you get garbage out.</p>	<p>Les résultats obtenus à partir de données fausses sont eux aussi faux.</p>
<p>If you put in garbage, you get garbage out.</p>	<p>Les résultats obtenus à partir de données fausses sont eux aussi faux.</p>
<p>However, the data provided to these bodies is not always of the highest quality and "if you punch in garbage you get out garbage".</p>	<p>Toutefois, les données communiquées à ces organismes ne sont pas toujours de la plus haute qualité, "ce qui est préjudiciable à la valeur du produit final".</p>
<p>I want this garbage out of here.</p>	<p>Je veux que ces détritüs soient sortis d'ici.</p>

Des segments vraiment parallèles



Atelier Traduction Automatique CEF.AT, 11 mai 2016

29



## Qualité des bitextes



---

<p>Je voudrais encore soulever brièvement deux problèmes concernant la déclaration.</p>	<p>I should like to conclude by dealing briefly with two problems relating to the declaration.</p>
<p>Nous publions ici la déclaration finale.</p>	<p>We reproduce here the Declaration adopted at that meeting.</p>
<p>Je condamne également la déclaration du ministre polonais.</p>	<p>I also condemn the statement made by the Polish Minister.</p>
<p>Mme Sriswasdi appuie la déclaration du Brésil.</p>	<p>Ms. Sriswasdi said that she supported the statement by Brazil.</p>
<p>Assigner un numéro à la déclaration de conformité est optionnel.</p>	<p>It is optional to assign a number to the declaration of conformity.</p>
<p>Une copie de la déclaration d'immatriculation.</p>	<p>A copy of the declaration of registration, if applicable.</p>

Des exemples adaptés, représentant les « bons » sens



Atelier Traduction Automatique CEF.AT, 11 mai 2016

30



## Qualité des bitextes



the tax return

▼

<p>L'évaluation finale par les autorités peut prendre jusqu'à trois ans à compter de la présentation de la <b>déclaration d'impôts</b>.</p>	<p>The final assessment by the authorities can take up to three years following the submission of <b>the tax return</b>.</p>
<p>L'évaluation finale par les autorités peut prendre jusqu'à trois ans à compter de la présentation de la <b>déclaration d'impôts</b>.</p>	<p>The final assessment by the authorities can take up to three years after submitting <b>the tax return</b>.</p>
<p>L'année fiscale court du 1er avril au 31 mars et la <b>déclaration d'impôts</b> doit être présentée avant le 30 novembre de l'année suivante.</p>	<p>The tax year runs from 1 April to 31 March and <b>the tax return</b> must be submitted by 30 November of the following year.</p>
<p>L'avantage procuré par ce régime devrait être calculé sur la base du montant déduit une deuxième fois du bénéfice net tel qu'enregistré dans la colonne spéciale de la <b>déclaration d'impôts</b> réservée aux activités éligibles.</p>	<p>The benefit of this scheme should be calculated on the basis of the amount deducted a second time from the net profit as recorded on <b>the tax return</b> in the special column for promoted activities.</p>
<p>Il ne figure pas sur la <b>déclaration d'impôts</b> du père.</p>	<p>He's not listed as a dependant on <b>his father's tax returns</b>.</p>

**Des exemples adaptés, fournissant des longs « matches »**



Atelier Traduction Automatique CEF.AT, 11 mai 2016

31



## Les données pour CEF.AT



- Pour délivrer des services multilingues **de qualité** pour tous les citoyens et les administrations publiques...
- CEF.AT demande des données **de qualité**:
  - DGT, Agences européennes, ONU, etc.
  - **Administration centrale, agences et établissements publics, ONG, etc.**
- En grande quantité



Atelier Traduction Automatique CEF.AT, 11 mai 2016

32



European Language  
Resource Coordination  
*Connecting Europe's Faculty*



Merci de votre attention



Atelier Traduction Automatique CEF.AT, 11 mai 2016

33