



Patent Machine Translation (Handling large data with Moses)

Bruno Pouliquen (Bruno.Pouliquen@wipo.int)
with the help of Marcin Junczys-Dowmunt

What this talk is about?

- Introduction
- Patent translation, what is specific about it?
- Our tool: Tapta
- Big model management with Moses
- Language specificities
- Our tool installed in various places
- User interfaces
- Quality / user acceptance
- Conclusion

Introduction: Basic facts about WIPO

World Intellectual Property Organization



Mission : promote the protection of intellectual property rights worldwide and extend the benefits of the international intellectual property system to all member states

Status : a specialized agency of the UN


Member states : 184

Observers : 250+

Staff : 950 from 101 countries

Translation of Patents:

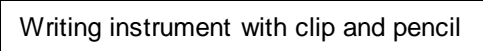
PCT : translation of titles/abstracts and International Search reports (40 million words/year to EN and FR, 90% outsourced)




Patentscope: patent search engine


The screenshot displays the WIPO Patentscope website. At the top left is the WIPO logo. To its right is the text "PATENTSCOPE" and a navigation menu with links for "Mobile", "Deutsch", "Español", "Français", "日本語", "한국어", "Português", "Русский", and "中文". Below this is the tagline "Search International and National Patent Collections". A secondary navigation bar includes "Search", "Browse", "Translate", "Options", "News", and "Help". A breadcrumb trail shows "Home > IP Services > PATENTSCOPE" and a highlighted button for "Translation Assistant for Patent Titles and Abstracts". The main section is titled "Advanced Search" and features a "Search For:" input field. Below the search field are filters for "Language:" (set to English), "Stem:" (checked), and "Office:" (set to All). A dropdown menu is open, showing a list of countries and regions with checkboxes and language codes (en, fr, de, zh, ja, ko, pt, ru). The countries listed are: Africa (ARIPO, Egypt, Kenya, Morocco, South Africa), Americas (United States of America, Canada, LATIPAT, Argentina, Brazil, Chile, Colombia, Costa Rica, Cuba, Dominican Rep., Ecuador, El Salvador, Guatemala, Honduras, Mexico, Nicaragua, Panama, Peru, Uruguay), and Asia-Europe (Bahrain, China, Eurasian Patent Office, Estonia, European Patent Office, Israel, Japan, Jordan, Russian Federation, Russian Federation (USSR data), Singapore, Spain, Republic of Korea, Viet Nam, United Arab Emirates).

Patent translation, what is specific about it?

- A patent application is made up of a title, an abstract, a description and claims
 - Title: 8 words  Writing instrument with clip and pencil
 - Abstract: 114 words
 - Description: 6'428 words!
 - Claims: 726 words
- Meta information: office, classification (IPC), original language, filing date, publication date, inventor etc...
- Specific language, scientific terms, almost no repetitive text (Unknown phrase: “I am”, almost no proper names...)
- Usually only the title and the abstract are translated



The clipboard pencil holder is a device that can be easily attached to the clip of a conventional clipboard for the purpose of providing easy and convenient storage and retrieval of a pencil or other similarly-sized writing instrument. The holder holds the pencil horizontally against, and parallel to the clipboard clip while substantially avoiding interference with the clipboard clip's ability to grip a paper pad which, for example, is positioned between the clip and the board of the clipboard.



Claim 1: A writing instrument, which consists of a pencil and clip for holding the apparatus in a product, said clip being attached to said pencil.
Claim 2: The writing instrument of claim 1 wherein said clip may be fixed to said pencil
...

WIPO SMT tool: TAPTA

Requirements

- Fully automatic
 - preparation of data
 - training
 - evaluating/mert/binarization/etc.
- Domain aware
- Fast translations (on the fly)
- Free to use (open source + in-house development)
- Confidentiality
- Various User interfaces
- First goal: assimilation, online translation of patent applications on our search engine
- Additional goal: dissemination, integration in CAT tool, “translation accelerator”

TAPTA: First version - 2011

- Patent SMT: title+abstracts
- 180 M words (en-fr), 8M words
- Called TAPTA (“Translation Assistant for Patent Title and Abstract”)
- Domain-aware: 32 domains encoded as factors in Moses
- Pouliquen et al. EAMT 2011


COPPA: Corpus Of Parallel Patent Applications

All English-French PCT application title and abstract (1990-2010)

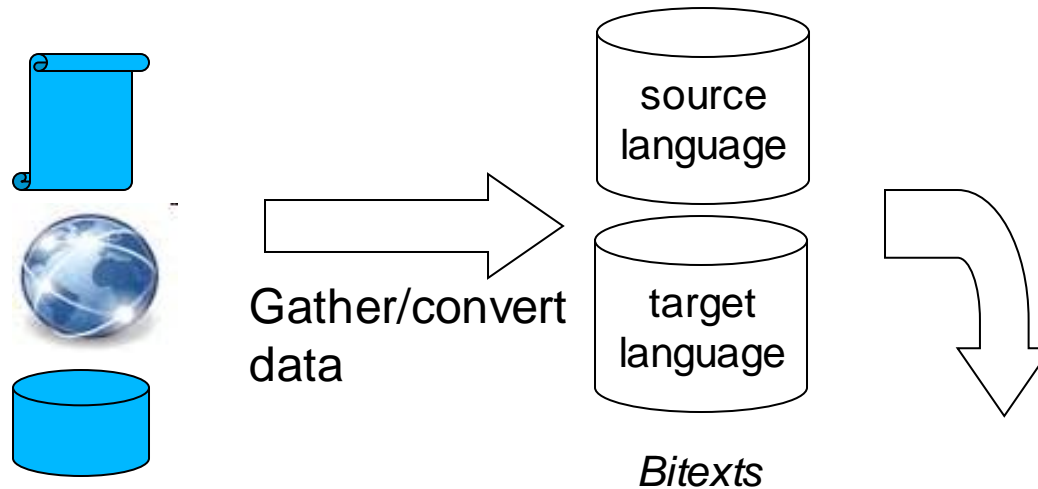
Free for research

180 Million words in TMX format (8.7 Million translation units)


<http://www.wipo.int/patentscope/en/data/products.html#coppa>



Tapta framework



Our system prepares the data for Moses, applies some post-processing (filter, pruning, binarization, optimization...) and offers various interfaces to translate



TAPTA:



Translate

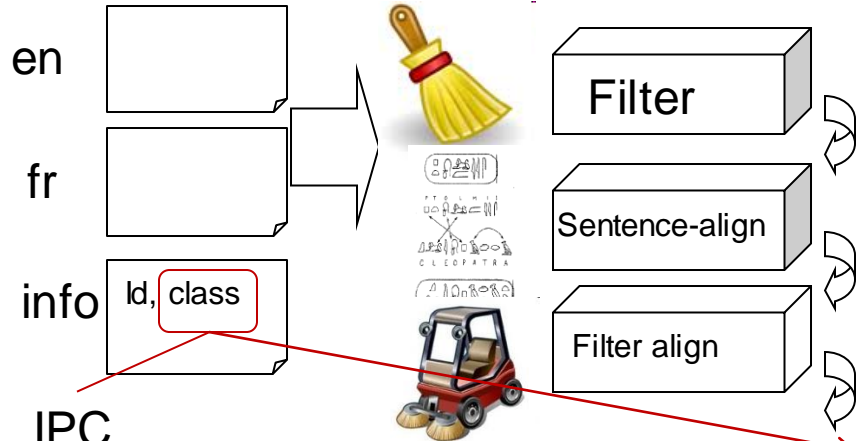
This tool is based on statistics and trained only on patent titles and abstracts. You can cut and paste titles/abstracts from any patent application.

Source text: automatic translation movement

Language pair: English->French

Domain: [automatic detection]

Translate



en	fr	domain
antimicrobial coatings	enrobages antimicrobiens	CHEM
electronic transaction	transaction électronique	SPOR
ternary mixed ethers	éthers mixtes ternaires	CHEM
submarine	sous - marin	MARI
automatic translation	traduction automatique	DATA
automatic translation	translation automatique	BLDG

- IPC
- A0.1
 - A01.2
 - A01.2.3
 - A02
 - B01
 - B01.1.2






Moses' train model



post-filter



prune



Domain: [automatic detection]

- [automatic detection]
- Aeronautics & Aerospace Engineering
- Agriculture, Fisheries & Forestry
- Audio, Audiovisual, Image & Video Tech
- Civil Engineering & Building Construction
- Chemical & Materials Technology
- Computer Sci, Telecom & Broadcasting
- Electrical Engineering & Electronics
- Energy, Fuels & Heat Transfer Eng
- Environmental & Safety Engineering
- Foods & Food Technology
- Generalities, Language, Media & Info Sci
- Home Contents & Household Maintenance
- Precision Mechanics, Jewelry & Horology
- Manufacturing & Materials Handling Tech
- Marine Engineering
- Standards, Units, Metrology & Testing
- Mechanical Engineering
- Medical Technology
- Metallurgy

TAPTA: more than titles & abstracts

- Many offices, many languages (en, ja, fr, zh, de, ru, ko, es, pt...)
- Usually only the title and abstract are translated...
- But:
 - European Patent Office: translations of claims in English, French and German
 - One invention can be patented in more than one country (in various languages)...
 - Huge amount of data ~ Millions of patent applications

Description alignment

Challenges with getting parallel sentences

Applicants: DOERING VITURIN
Inventors: Doering, Viturin
Agents: Webb Ziesenheim Logsdon Orkin & Hanson, P.C.
Priority Data: 19939612 20.08.1999 DE
Title: (EN) Sound carrier for

[0009] Zur Lösung dieses Problems sieht die Erfindung vor, dass bei dem eingangs genannten Tonträger wenigstens eine der Durchbrechungen auf der Oberseite des Tonträgers von einem nach oben aus der Oberseite vorstehenden Wulstring, der z.

To meet this object, the invention provides that in the sound carrier at least one of the adjustment perforations on the surface of the sound carrier is surrounded by an annular bead which protrudes in upward direction and has been impressed or deep-drawn, for example. Said annular bead is located immediately at the perforation or surround it a small distance of about 1.0 to 1.5 mm, especially 1.2 mm, thus forming a flat shoulder which contributes to defining the perforation.

It is advisable to provide the two perforations in the lower edge of the sound carrier with such an annular bead. Such an annular bead does not only make the perforations better visible, they also render the alignment of the feet of the sound reproducing device easier because they practically fall into the larger annular bead and slip into the precise adjustment perforations automatically.

It is also possible to provide the two perforations in the lower edge of the sound carrier with such an annular bead. Such an annular bead does not only make the perforations better visible, they also render the alignment of the feet of the sound reproducing device easier because they practically fall into the larger annular bead and slip into the precise adjustment perforations automatically. Such a perforation surrounded by an annular bead can actually be compared to a funnel.

Of course, all the perforations in a sound carrier can be provided with beads. In this case, of course, all the perforations in a sound carrier can be provided with beads. In this case, of course, all the perforations in a sound carrier can be provided with beads. In this case, of course, all the perforations in a sound carrier can be provided with beads.

As an alternative to this solution, the two lower adjustment perforations may be widened and elongated in the direction away from the other adjustment perforations toward the outside or in the direction of the same toward the inside. In this case, the adjusting foot is inserted into them with large clearance by means of the wide region created in this manner, so that said adjusting foot is movable to abut the narrow region and the other adjusting foot is in a position to engage the other adjustment perforation/perforations in this position.

As a result, when centered, the feet are in each case in the exactly defined position. This is achieved in that the walls of the enlarged adjustment perforations should have the same configuration on the side facing toward or away from the other adjustment perforations as the aligning feet to be inserted.

As a result, when centered, the feet are in each case in the exactly defined position. This is achieved in that the walls of the enlarged adjustment perforations should have the same configuration on the side facing toward or away from the other adjustment perforations as the aligning feet to be inserted.

1-1	99.28%	surround it a small distance of about 1.0 to 1.5 mm, especially 1.2 mm, thus forming a flat shoulder which contributes to defining the perforation
1-2	48.85%	the annular bead should have a height of 0.2 to 0.3 mm, especially of 0.2 mm, and a width of about 1-1.5 mm, especially 1.2 mm. It is advisable to provide the two perforations in the lower edge of the sound carrier with such an annular bead
1-1	90.33%	such an annular bead does not only make the perforations better visible, they also render the alignment of the feet of the sound reproducing device easier because they practically fall into the larger annular bead and slip into the precise adjustment perforations automatically
1-1	21.93%	such a perforation surrounded by an annular bead can actually be compared to a funnel
1-1	30.73%	of course, all the perforations in a sound carrier can be provided with beads
1-2	50.66%	they also prevent an unintentional dislocation of the sound reproducing device during possibly desired interruptions of a reproduction while studying educational information. This is important as the sound reproducing device has to be actuated frequently also during reproduction, for example for interruptions or for a repeated reproduction which naturally involves the danger of dislocation
1-1	100%	as an alternative to this solution, the two lower adjustment perforations may be widened and elongated in the direction away from the other adjustment perforations toward the outside or in the direction of the same toward the inside and surround the respective aligning foot to be inserted into them with large clearance by means of the wide region created in this manner, so that said aligning foot is movable to abut the narrow region and the other aligning foot is in a position to engage the other adjustment perforation/perforations in this position
1-1	99.86%	a plane guiding funnel is formed in this manner which passes the sound reproducing device placed in position into the round perforations of the sound carrier
0-1		
0-1		
0-1		
1-1	57.12%	the walls of the enlarged adjustment perforations should have the same configuration on the side facing toward or away from the other adjustment perforations as the aligning feet to be inserted
		as a result, when centered, the feet are in each case in the exactly defined

1-1	99.28%	einen geringen Abstand von etwa 1,0 bis 1,5 mm, insbesondere 1,2 mm, und bildet so einen flachen Absatz, was zur Präzisierung der Durchbrechung beiträgt
1-2	48.85%	Der Wulstring sollte eine Höhe von 0,2 bis 0,3 mm, insbesondere von 0,2 mm, und eine Breite von ca. 1 - 1,5 mm, insbesondere 1,2 mm haben. Zweckmäßigerweise werden zwei Durchbrüche am unteren Rand des Tonträgers mit diesem Wulstring ausgestattet
1-1	90.33%	Durch diesen Wulstring sind die Durchbrüche nicht nur besser sichtbar, sie erleichtern auch das Justieren der Füße des Tonwiedergabegerätes, da die Justierfüsse in dem grösseren Wulstring praktisch hineinfallen und zwangsweise in die präzisen Justierdurchbrechungen schlüpfen
1-1	21.93%	Man kann diese von einem Wulstring umgebenen Durchbrüche praktisch mit einem Trichter vergleichen.
1-1	30.73%	Selbstverständlich können auch alle Durchbrechungen eines Tonträgers mit Wulsten versehen werden
1-2	50.66%	Diese Wulste verhindern auch das unbeabsichtigte Verrücken des Tonwiedergabegerätes bei evtl. gezielten Unterbrechungen der Wiedergabe beim Studium von Lernmaterial. Das ist wichtig, weil das Tonwiedergabegerät auch während der Wiedergabe häufig, beispielsweise für Unterbrechungen oder Wiedergabewiederholungen zu betätigen ist und dabei an sich die Gefahr des Verrückens besteht.
1-1	100%	Alternativ zu dieser Lösung kann auch ein Teil der Justierdurchbrechungen, z. B. zwei untere Justierdurchbrechungen, in Richtung von den anderen Justierdurchbrechungen nach aussen weg oder zu diesen nach innen hin verbreitert und verlängert ausgebildet sein und in sie einzuführenden Justierfüsse mit dem so geschaffenen breiten Bereich mit grossem Spiel so umschliessen, dass dieser Justierfuss zur Anlage an den engen Bereich verschieblich ist und die anderen Justierfüsse in dieser Lage in die anderen Justierdurchbrechungen, die die Justierfüsse im engsten Bereich mit geringem Spiel umschliessen, einzugreifen vermögen
1-1	99.86%	So ist ein ebener Führungstrichter gebildet, der das aufgesetzte Tonwiedergabegerät in die runden Durchbrechungen des Tonträgers leitet
0-1		Zusammen mit den dann zum Eingriff kommenden anderen Justierfüssen ist das Tonwiedergabegerät dann lagestabil gehalten.
0-1		Ein älterer bekannter Vorschlag (US Patentschrift 4,298,967) ist von der Praxis als ungeeignet verworfen worden, der im Mittelpunkt der Tonrille eines folienartigen, dünnen Tonträgers eine schuhartige zur Mitte und nach unten sich verengende Vertiefung vorsah, in die ein zentraler Justierstift des Tonwiedergabegerätes bis zum Grund in die Justierstellung geführt wird, in diese aber wegen Fehlen der Arretierungsmöglichkeit nicht lagestabil festgehalten ist
0-1		Ausserdem verdeckt das Tonwiedergabegerät jegliche Sicht zur schuhartigen Vertiefung.
1-1	57.12%	Die Wände der vergrösserten Justierdurchbrechungen sollten auf der den anderen Justierdurchbrechungen zugewandten oder abgewandten Seite die gleiche Gestalt haben wie die einzusetzenden Justierfüsse
		Dadurch befinden sich die Füsse lagestabil in der zentrierten Lage jeweils an den genau

ist. Dieser Wulstring kann sich unmittelbar über den Wulstring auf der Oberseite des Tonträgers von einem nach oben aus der Oberseite vorstehenden Wulstring, der z. B. einen geringen Abstand von etwa 1,0 bis 1,5 mm, insbesondere 1,2 mm, und bildet so einen flachen Absatz, was zur Präzisierung der Durchbrechung beiträgt.

Durch diesen Wulstring sind die Durchbrüche nicht nur besser sichtbar, sie erleichtern auch das Justieren der Füße des Tonwiedergabegerätes, da die Justierfüsse in dem grösseren Wulstring praktisch hineinfallen und zwangsweise in die präzisen Justierdurchbrechungen schlüpfen. Man kann diese von einem Wulstring umgebenen Durchbrüche praktisch mit einem Trichter vergleichen.

Selbstverständlich können auch alle Durchbrechungen eines Tonträgers mit Wulsten versehen werden. In diesem Fall können auch alle Durchbrechungen eines Tonträgers mit Wulsten versehen werden. In diesem Fall können auch alle Durchbrechungen eines Tonträgers mit Wulsten versehen werden.

Diese Wulste verhindern auch das unbeabsichtigte Verrücken des Tonwiedergabegerätes bei evtl. gezielten Unterbrechungen der Wiedergabe beim Studium von Lernmaterial. Das ist wichtig, weil das Tonwiedergabegerät auch während der Wiedergabe häufig, beispielsweise für Unterbrechungen oder Wiedergabewiederholungen zu betätigen ist und dabei an sich die Gefahr des Verrückens besteht.

Alternativ zu dieser Lösung kann auch ein Teil der Justierdurchbrechungen, z. B. zwei untere Justierdurchbrechungen, in Richtung von den anderen Justierdurchbrechungen nach aussen hin verbreitert und verlängert ausgebildet sein und in sie einzuführenden Justierfüsse mit dem so geschaffenen breiten Bereich mit grossem Spiel so umschliessen, dass dieser Justierfuss zur Anlage an den engen Bereich verschieblich ist und die anderen Justierfüsse in dieser Lage in die anderen Justierdurchbrechungen, die die Justierfüsse im engsten Bereich mit geringem Spiel umschliessen, einzugreifen vermögen. So ist ein ebener Führungstrichter gebildet, der das aufgesetzte Tonwiedergabegerät in die runden Durchbrechungen des Tonträgers leitet.

Zusammen mit den dann zum Eingriff kommenden anderen Justierfüssen ist das Tonwiedergabegerät dann lagestabil gehalten.

Ein älterer bekannter Vorschlag (US Patentschrift 4,298,967) ist von der Praxis als ungeeignet verworfen worden, der im Mittelpunkt der Tonrille eines folienartigen, dünnen Tonträgers eine schuhartige zur Mitte und nach unten sich verengende Vertiefung vorsah, in die ein zentraler Justierstift des Tonwiedergabegerätes bis zum Grund in die Justierstellung geführt wird, in diese aber wegen Fehlen der Arretierungsmöglichkeit nicht lagestabil festgehalten ist.

Ausserdem verdeckt das Tonwiedergabegerät jegliche Sicht zur schuhartigen Vertiefung.

Die Wände der vergrösserten Justierdurchbrechungen sollten auf der den anderen Justierdurchbrechungen zugewandten oder abgewandten Seite die gleiche Gestalt haben wie die einzusetzenden Justierfüsse. Dadurch befinden sich die Füsse lagestabil in der zentrierten Lage jeweils an den genau definierten Positionen, an denen die Justierfüsse einzugreifen vermögen. So ist ein ebener Führungstrichter gebildet, der das aufgesetzte Tonwiedergabegerät in die runden Durchbrechungen des Tonträgers leitet.

Claims alignment

Challenges with getting parallel sentences from claims

Applicants: DOERING VITURIN
Inventors: Doering, Viturin
Agents: Webb Ziesenheim Logsdon Orkin & Hanson, P.C.
Priority Data: 19939612 20.08.1999 DE
Title: (EN) Sound carrier for a sound illustrated book

1. A sheet-shaped sound carrier, especially for a sound illustrated book, which is to be associated with selected pages and has on its front side at least one spiral shaped sound groove and at least two adjustment perforations which are arranged outside of the sound groove and around the same symmetrically with respect to a center axis thereof, and are dimensioned such that the at least two adjustment perforations each receive an aligning foot of a sound reproducing device placed in a pre-aligned position upon the sound carrier, the reproducing device having a pickup means rotatable about an axis of rotation in an aligned position in which the center axis of the sound groove and the axis of rotation of the sound pickup means coincide, wherein at least one of the adjustment perforations is surrounded by a shoulder on the surface of the sound carrier.

2. The sound carrier according to claim 1, wherein the adjustment perforation is at a distance of about 1-1.5 mm from the bead.

3. The sound carrier according to claim 2, wherein the adjustment perforation is at a distance of about 1-1.5 mm from the bead.

4. The sound carrier according to claim 1, wherein the adjustment perforation is at a distance of about 0.2 to 0.3 mm and a width of about 1-1.5 mm.

5. The sound carrier according to claim 1, wherein the adjustment perforations are spaced apart by a distance of about 1-1.5 mm.

6. The sound carrier according to claim 1, wherein the sound carrier is made of clear and translucent plastics material, and is provided with a partially transparent coating.

7. The sound carrier according to claim 6, wherein the coating is a color coating.

8. The sound carrier according to claim 1, wherein the adjustment perforations are spaced apart by a distance of about 1-1.5 mm.

9. The sound carrier according to claim 1, wherein the adjustment perforations are spaced apart by a distance of about 1-1.5 mm and the sound carrier is made of aluminum film.

10. The sound carrier according to claim 1, wherein the adjustment perforations are spaced apart by a distance of about 1-1.5 mm and the sound carrier is provided with an adhesive.

11. A sheet-shaped sound carrier especially for a sound illustrated book, which is to be associated with selected pages and has on its front side at least one spiral shaped sound groove and at least two adjustment perforations which are arranged outside of the sound groove area and around the same symmetrically with respect to a center axis thereof, and are dimensioned such that the at least two adjustment perforations each receive an aligned foot of a sound reproducing device placed in a pre-aligned position upon the sound carrier, the reproducing device having a pickup means rotatable about an axis of rotation in an aligned position in which the center axis of the sound groove and the axis of rotation of the sound pickup means coincide, wherein at least one of the adjustment perforations is surrounded by a shoulder on the surface of the sound carrier.

21 claims

16 claims

2. The sound carrier according to claim 1, wherein each annular bead surrounds the adjustment perforation at a distance of about 1-1.5 mm leaving a shoulder between the perforation and the bead.

7. The sound carrier according to claim 6, wherein the coating is a color coating.

1. Blattförmiger Tonträger, insbesondere mit einer Dicke von etwa 0,2 bis 0,35 mm und für ein tonillustriertes Buch, der ausgewählten Seiten zuzuordnen ist und der auf seiner Oberseite jeweils wenigstens eine spiralförmige Tonrille (5) aufweist und mindestens zwei außerhalb der Tonrille um diese herum, insbesondere symmetrisch zu deren Mittelachse angeordnete Justierdurchbrechungen (6, 8) hat, die so groß sind, daß sie je einen Justierfuß eines aufsetzbaren Tonwiedergabegeräts mit einem um eine Drehachse rotierbaren Tonabnehmer in einer Justierstellung lagestabil aufnehmen, in der die Mittelachse der Tonrille und die Drehachse des Tonabnehmers zusammenfallen, dadurch gekennzeichnet, daß wenigstens eine der Justierdurchbrechungen (8) auf der Oberseite des Tonträgers (4) von einem nach oben vorstehenden Wulstring (10) umgeben ist.

2. Tonträger nach Anspruch 1, dadurch gekennzeichnet, daß jeder Wulstring (10) die Justierdurchbrechung mit geringem Abstand von etwa 1-1,5 mm, insb. 1,2 mm, einen Absatz belassend, umgibt.

3. Blattförmiger Tonträger, insbesondere mit einer Dicke von etwa 0,2 bis 0,35 mm und für ein tonillustriertes Buch, der ausgewählten Seiten zuzuordnen ist und der auf seiner Oberseite jeweils wenigstens eine spiralförmige Tonrille (5) aufweist und mindestens zwei außerhalb der Tonrille um diese herum, insbesondere symmetrisch zu deren Mittelachse angeordnete Justierdurchbrechungen (6, 8) hat, die so groß sind, daß sie je einen Justierfuß eines aufsetzbaren Tonwiedergabegeräts mit einem um eine Drehachse rotierbaren Tonabnehmer in einer Justierstellung lagestabil aufnehmen, in der die Mittelachse der Tonrille und die Drehachse des Tonabnehmers zusammenfallen, dadurch gekennzeichnet, daß wenigstens eine der Justierdurchbrechungen (8) auf der Oberseite des Tonträgers (4) von einem nach oben vorstehenden Wulstring (10) umgeben ist.

2. Tonträger nach Anspruch 1, dadurch gekennzeichnet, daß jeder Wulstring (10) die Justierdurchbrechung mit geringem Abstand von etwa 1-1,5 mm, insb. 1,2 mm, einen Absatz belassend, umgibt.

mm und für ein tonillustriertes Buch, der ausgewählten Seiten zuzuordnen ist und der auf seiner Oberseite jeweils wenigstens eine spiralförmige Tonrille (5) aufweist und mindestens zwei außerhalb der Tonrille um diese herum, insbesondere symmetrisch zu deren Mittelachse angeordnete Justierdurchbrechungen (6, 8) hat, die so groß sind, daß sie je einen Justierfuß eines aufsetzbaren Tonwiedergabegeräts mit einem um eine Drehachse rotierbaren Tonabnehmer in einer Justierstellung lagestabil aufnehmen, in der die Mittelachse der Tonrille und die Drehachse des Tonabnehmers zusammenfallen, dadurch gekennzeichnet, daß wenigstens eine der Justierdurchbrechungen (8) auf der Oberseite des Tonträgers (4) von einem nach oben vorstehenden Wulstring (10) umgeben ist.

7. Tonträger nach Anspruch 6, dadurch gekennzeichnet, daß sich jede verbreiterte und verlängerte Justierdurchbrechung (8) vom breiten Bereich (13) zum engeren Bereich (12) hin

zuzuordnen ist und der auf seiner Oberseite jeweils wenigstens eine spiralförmige Tonrille (5) aufweist und mindestens zwei außerhalb der Tonrille um diese herum, insbesondere symmetrisch zu deren Mittelachse angeordnete Justierdurchbrechungen (6, 8) hat, die so groß sind, daß sie je einen Justierfuß eines aufsetzbaren Tonwiedergabegeräts mit einem um eine Drehachse rotierbaren Tonabnehmer in einer Justierstellung lagestabil aufnehmen, in der die Mittelachse der Tonrille und die Drehachse des Tonabnehmers zusammenfallen, dadurch gekennzeichnet, daß wenigstens eine der Justierdurchbrechungen (8) auf der Oberseite des Tonträgers (4) von einem nach oben vorstehenden Wulstring (10) umgeben ist.

2. Tonträger nach Anspruch 1, dadurch gekennzeichnet, daß jeder Wulstring (10) die Justierdurchbrechung mit geringem Abstand von etwa 1-1,5 mm, insb. 1,2 mm, einen Absatz belassend, umgibt.

3. Blattförmiger Tonträger, insbesondere mit einer Dicke von etwa 0,2 bis 0,35 mm und für ein tonillustriertes Buch, der ausgewählten Seiten zuzuordnen ist und der auf seiner Oberseite jeweils wenigstens eine spiralförmige Tonrille (5) aufweist und mindestens zwei außerhalb der Tonrille um diese herum, insbesondere symmetrisch zu deren Mittelachse angeordnete Justierdurchbrechungen (6, 8) hat, die so groß sind, daß sie je einen Justierfuß eines aufsetzbaren Tonwiedergabegeräts mit einem um eine Drehachse rotierbaren Tonabnehmer in einer Justierstellung lagestabil aufnehmen, in der die Mittelachse der Tonrille und die Drehachse des Tonabnehmers zusammenfallen, dadurch gekennzeichnet, daß wenigstens eine der Justierdurchbrechungen (8) auf der Oberseite des Tonträgers (4) von einem nach oben vorstehenden Wulstring (10) umgeben ist.

2. Tonträger nach Anspruch 1, dadurch gekennzeichnet, daß jeder Wulstring (10) die Justierdurchbrechung mit geringem Abstand von etwa 1-1,5 mm, insb. 1,2 mm, einen Absatz belassend, umgibt.

3. Blattförmiger Tonträger, insbesondere mit einer Dicke von etwa 0,2 bis 0,35 mm und für ein tonillustriertes Buch, der ausgewählten Seiten zuzuordnen ist und der auf seiner Oberseite jeweils wenigstens eine spiralförmige Tonrille (5) aufweist und mindestens zwei außerhalb der Tonrille um diese herum, insbesondere symmetrisch zu deren Mittelachse angeordnete Justierdurchbrechungen (6, 8) hat, die so groß sind, daß sie je einen Justierfuß eines aufsetzbaren Tonwiedergabegeräts mit einem um eine Drehachse rotierbaren Tonabnehmer in einer Justierstellung lagestabil aufnehmen, in der die Mittelachse der Tonrille und die Drehachse des Tonabnehmers zusammenfallen, dadurch gekennzeichnet, daß wenigstens eine der Justierdurchbrechungen (8) auf der Oberseite des Tonträgers (4) von einem nach oben vorstehenden Wulstring (10) umgeben ist.

7. Tonträger nach Anspruch 6, dadurch gekennzeichnet, daß sich jede verbreiterte und verlängerte Justierdurchbrechung (8) vom breiten Bereich (13) zum engeren Bereich (12) hin

2. Tonträger nach Anspruch 1, dadurch gekennzeichnet, daß jeder Wulstring (10) die Justierdurchbrechung mit geringem Abstand von etwa 1-1,5 mm, insb. 1,2 mm, einen Absatz belassend, umgibt.

Big models: bitexts

Matching Chinese description/claims with US

~ 64 Million segments (en zh)

English size: 2'000 Million words, 10Gb

(more careful alignment/cleaning to be done in the future)

Big models: language models

English texts only ~ 1Tb (US+EPO+PCT
descriptions/claims/titles/abstracts)

...all English Wikipedia is 44Gb

Currently we stick to 10Gb for the language model

Tapta and big models

Parallelization:

- Use mgiza
- For big models: split corpus in 4 parts, launch mgiza on each quarter
- For big models: stop at HMM iteration

Heavy compression


- Pruning
- Binarization (compact phrase table, kenlm)
- (without much loss in quality)

Training and scalability

Size reduction zh-en

	Phrasetable 0-0		Phrasetable 0,1-0		Reordering model		Language model	
	M rows	Gb	M rows	Gb	M rows	Gb	M ngrams	Gb
Basic	806	100	974	130	806	89	584	23
Pruned	551	69	623	83	551	61	388	16
Binarized		6.4		7.4		4.2		4.6

342Gb



**22.6Gb
(6.6%)**

Language specificities

Tokenizer: Based on Lucene framework

- zh: adapted “SmartCn”
- ja: “kuromoji”
- de: decomposer (Junczys & Poulouen, Eamt2014)
- ar: prefix splitting, removes short vowels
- ko: decomposer
- Normalizes greek letters
- Groups references to figures (eg. “(1)” not “_(1)_”)

Reordering

- de: pre-reordering (Junczys & Poulouen, Eamt2014)
- ja: Simple naïve pre-reordering (more to be done)

Tapta: our tool installed in different places



And some projects going on to install Tapta prototype in other International institutions...

Our tool in different situations

- Adapted our code so that it can easily install and run
- Under version control, regression tests, Installation/administration documentation (100 pages)
- With installation instructions: ½ day to configure a new Linux server
- Runs on Linux:
 - Hardware: Amazon cloud, virtual machine, desktop PC, server
 - OS: Ubuntu/Suse/Centos/RedHat


Training and scalability: UN data

- All United Nation texts ~ 212 Million words, 10 M segments

	Phrase table		Reordering model		Language model	
	M rows	Gb	M rows	Gb	M rows	Gb
Basic	82	9.70	82	8.70	49	1.70
Pruned	19	2.20	19	1.90	31	1.00
Binarized		0.27		0.15		0.70

UN data

20Gb



**1.12Gb
(6%)**

Our tool in production


- Install/publish/update/train/evaluate (robust) scripts
- Monitor tool
- Dashboard interface
- Anti robot policy (captcha)
- Statistics
- ...



Hardware & OS



- Virtual, 4 Gb Ram, Suse SLES11, 4 cores, 250Gb
- Virtual, 16 Gb Ram, RedHat ent R6.2, 16 cores, 200Gb
- PC, 8Gb ram, Ubuntu 12.4, 8 cores, 350Gb
- Server, 16Gb, Centos R6.4, 16 cores, 400Gb
- Server, 11Gb Ram, RedHat ent. R6.5, 8 cores, 100Gb disk
- ...
- Amazon cloud, 64 Gb Ram, Suse ent. 11, 8 cores, 400Gb
- ...
- Server, 500Gb ram, RedHat ent. R6.5, 48 cores, 4T



Various user interfaces

- Java Swing
- Web interface
 - Gist translation
 - Interactive translation
- Hotkey
- Plugin (SDL studio, Worldserver, eLuna etc.)
- Tapta widget

Web interface

Home > IP Services > PATENTSCOPE > Database Search > Translation Assistant

Translate

[\[help/user guide\]](#)

This tool is based on statistics and trained only on patent titles and abstracts.
You can cut and paste titles/abstracts from any published patent application.

(THIS TOOL SHOULD NOT BE USED FOR THE PURPOSE OF TRANSLATING CONFIDENTIAL OR SENSITIVE DATA, IN PARTICULAR UNDISCLOSED PATENT DATA, BECAUSE DATA TRANSMITTED VIA THIS TOOL IS NOT ENCRYPTED)

Source text:

本发明公开了一种移动通讯网络中的接入认证的方法,该方法包括移动通讯网络中身份位置寄存器对用户终端的接入认证过程.本发明还公开了相应系统,该系统包括用户终端,接入服务器和身份位置寄存器.本发明还公开了相应装置.本发明有效地避免了经由不可靠网络而导致的中间人攻击,通过将接入点路由信息和认证结果绑定,来保证接入点就是用户真实的接入点。

Language pair:

...

Domain:

[automatic detection]

Translate

- ...
- English->French
- French->English
- Korean->English[not yet]
- Japanese->English[not yet]
- English->Chinese
- Chinese->English

User can specify the language pair (or let the system choose)
The system can “guess” the domain from the text, or the user can specify

- [automatic detection]
- Aeronautics & Aerospace Engineering
- Agriculture, Fisheries & Forestry
- Audio, Audiovisual, Image & Video Tech
- Civil Engineering & Building Construction
- Chemical & Materials Technology
- Computer Sci, Telecom & Broadcasting
- Electrical Engineering & Electronics
- Energy, Fuels & Heat Transfer Eng
- Environmental & Safety Engineering
- Foods & Food Technology
- Generalities, Language, Media & Info Sci
- Home Contents & Household Maintenance
- Precision Mechanics, Jewelry & Horology
- Manufacturing & Materials Handling Tech
- Marine Engineering
- Standards, Units, Metrology & Testing
- Mechanical Engineering
- Medical Technology
- Metallurgy

TAPTA web interactive

This automatic translation is provided for information only, it may contain discrepancies or mistakes and does not have any juridical value.

- *Please select segments in source text (with mouse or use "shift" and arrow keys)*
- *You can then select among the proposals*
- *Special keys: <escape> to undo (or press "[undo]" button) use CTRL to select non-contiguous segments*

Segment: [Translation-type:]

Proposals: *pour dispositifs électroniques organiques et des cellules photovoltaïques .*

>>refresh>>

<<[undo]<<

Source text:

Polymers which can be used in p-type materials for organic electronic devices and photovoltaic cells. Compounds, monomers, dimers, trimers, and polymers comprising formula (I) and/or formula (VIII) are prepared

Translated text:

Polymères qui peuvent être utilisés dans des matériaux de type p pour dispositifs électroniques organiques et des cellules photovoltaïques .

[options](#)


Tapta hotkey



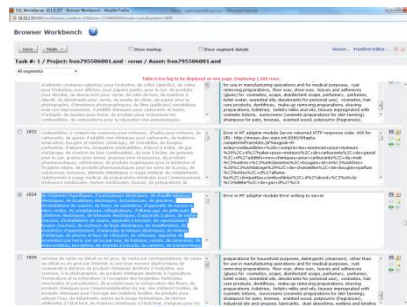
- Access the translation server using the "F3" key: Select text, press F3, translation goes to clipboard
- Work only on PC (opensource AutoHotKey), but is a solution to integrate MT in any application

Plugins

SDL/Studio



Worldserver




Eluna (United Nation internal CAT tool)



Multitrans?



Tapta widget



A script to be inserted at the beginning of any HTML page, translates inline text on the fly

1. (WO2014131214) TRAVEL SUITCASE/BAG HAVING REMOVABLE MODULARIZED STORAGE DEVICE

PCT Biblio. Data	Description	Claims	National Phase	Notices	Drawings	Documents
------------------	-------------	--------	----------------	---------	----------	-----------

Note: Text based on automatic Optical Character Recognition processes. Please use the PDF version for legal matters

[Wipo translate]

Alternative machine translation: (google)

权利要求书

1. 一种旅行箱/包, 其包括箱体/包体, 所述箱体/包体具有一容置空间, 其特征在于, 所述容置空间内可拆卸式地设置有若干模块化收纳装置。
2. 如权利要求 1 所述的旅行箱/包, 其特征在于, 所述模块化收纳装置通过一连接装置可拆卸式地设置在所述容置空间内, 或者通过连接设置在所述模块化收纳装置上的第一连接部件和连接设置在所述容置空间内的第二连接部件可拆卸式地设置在所述容置空间内。
3. 如权利要求 2 所述的旅行箱/包, 其特征在于, 所述连接装置或一端可拆卸式连接在所述箱体内侧而使所述模块化收纳装置可拆卸式地设置在所述容置空间内。

1. (WO2014131214) TRAVEL SUITCASE/BAG HAVING REMOVABLE MODULARIZED STORAGE DEVICE

PCT Biblio. Data	Description	Claims	National Phase	Notices	Drawings	Documents
------------------	-------------	--------	----------------	---------	----------	-----------

Note: Text based on automatic Optical Character Recognition processes. Please use the PDF version for legal matters

[Wipo translate]

Alternative machine translation: (google)

CLAIMS

如权利要求 1 所述的旅行箱/包, 其特征在于, 所述模块化收纳装置通过一连接装置可拆卸式地设置在所述容置空间内, 或者通过连接设置在所述模块化收纳装置上的第一连接部件和连接设置在所述容置空间内的第二连接部件可拆卸式地设置在所述容置空间内。

1. a travel housing/package, comprising a housing/body, wherein the housing/body has a receiving space, characterized in that, the receiving space is detachably provided with a plurality of modularized storage devices.
2. as claimed in claim 1, wherein the travel housing/packages, wherein, the modular receiving device through a connection device may be releasably disposed in the receiving space., or by connection settings in the modular receiving the first coupling member and the connection settings in the receiving space of a second connection component may be releasably disposed in the receiving space.
3. apparatus according to claim 2 wherein the trip tank/packet, wherein the connection device is a strip connection device, the ribbon connecting device is fixed in the modular receiving device and or one end, of two ends of the removable the inside of the housing such that the modular receiving device may be releasably disposed in the receiving space.
4. 如权利要求 3 所述的旅行箱/包, 其特征在于, 所述带状连接装置穿设在所述模块化收纳装置上, 相应地, 所述模块化收纳装置在其内部边缘或者外部设有可供所述带状连接装置穿设的孔。

[Continue translation]

Tapta: translation quality

- Competitive!
- Better than Google and Microsoft translate
 - Working with our data
 - Based on good open source “Moses”
- Small team...
but working with others...

Also the United Nations

BLEU scores

Language pair	Tapta	Google	Bing
ar-en	55.25	n/a ^[1]	51.17
en-ar	44.10	33.74	28.94
en-es	61.81	53.39	46.86
en-fr	51.23	45.58	42.19
en-ru	50.85	39.67	38.96
en-zh	43.17	34.16	32.77
es-en	60.32	52.54	49.18
fr-en	53.36	46.46	43.39
ru-en	58.56	47.71	47.09
zh-en	42.31	36.55	30.60

UN PROTOTYPE: Translation accelerator (Tapta4Un) [\[help/user guide \(On Patentscope\)\]](#)

[Note that the English into Spanish/Chinese/Arabic server available at <http://184.73.153.185:8080/Mapta/>]
 This tool is based on statistics and trained exclusively on UN documents (2000-2012)

Source text:

Language pair:

Show concordances:

This automatic translation is provided for information only, it may contain discrepancies or mistakes and does not have any juridical value.

تُعرب الخدمات الاستشارية التابعة للجنة الدولية للصليب الأحمر عن امتنانها لجميع الأشخاص الذين ساهموا مع المنظمات في صياغة هذا الدليل، الذي هو نتاج عمل جماعي مكثف.

The advisory services of the international committee of the red cross expressed its gratitude to all those who have contributed with organizations in drafting the manual, which was the product of intensive teamwork.

Bruno Pouliquen, Cecilia Elizalde, Marcin Junczys-Dowmunt, Christophe Mazenc, José García-Verdugo, **Large-scale multiple language translation accelerator at the United Nations** , MT Summit, Nice, France, September 2013

User acceptance

How Tapta is perceived among translators:

- When seen as a “translation accelerator”: very useful
- When seen as “replacement for translator”: useless
- When proposed as a copy-paste tool: not used
- When integrated in translator’s environment: used

Frustration: User has little impact on the MT output

Blacklist that we apply on the phrase table

Collect post-edition segments:

- quality estimation
- improving the MT

•

Conclusion/discussion

- MT contributes to information dissemination
- Moses easily supports huge models
- Tapta MT quality competitive
- Language dependent tools should be avoided in our context
- “User acceptance landscape is changing”
- Integration!

Future work on transliteration

Application Number: 2006551087 **Application Date:** 20.12.2004

Publication Number: 2007520013 **Publication Date:** 19.07.2007

Publication Kind : A5

IPC: G07F 9/10

Applicants: ザ コカコーラ カンパニー

Inventors: ラディック アーサー ジョー,
アンタオ,

Agents: 山本 秀策
安村 高明
森下 夏樹

Priority Data: 10/708,093 02.03.2004

Title: (JA) 温冷両用自動販売機

Abstract: (JA)

Coca Cola Co

Radic Arthur G

Atao Leonard F

Shusaku Yamamoto

Yasumura Takaaki

Natsuki Morishita

温冷両用自動販売機。この自動販売機は、製品用区画(141)、冷蔵システム(305)、ならびにこの冷蔵システムおよびこの製品用区画と連通する通風システム(180)を備え得る。通風システムは、この製品用区画と連通するように配置されたバルブ(240)を備え得る。ヒーター(270)が、この製品用区画のまわりに配置され得る。このバルブおよびこのヒーターは、この製品用区画が暖められるかまたは冷却され得るように、選択的に活性化される。

Future work

- Continue improving quality/speed/costs
 - OSM
 - Word cluster LM
 - Additional usage of meta data
- Interactive translation (autosuggest?)
- Incremental training
- Translation through pivot language

Future work

User feedbacks

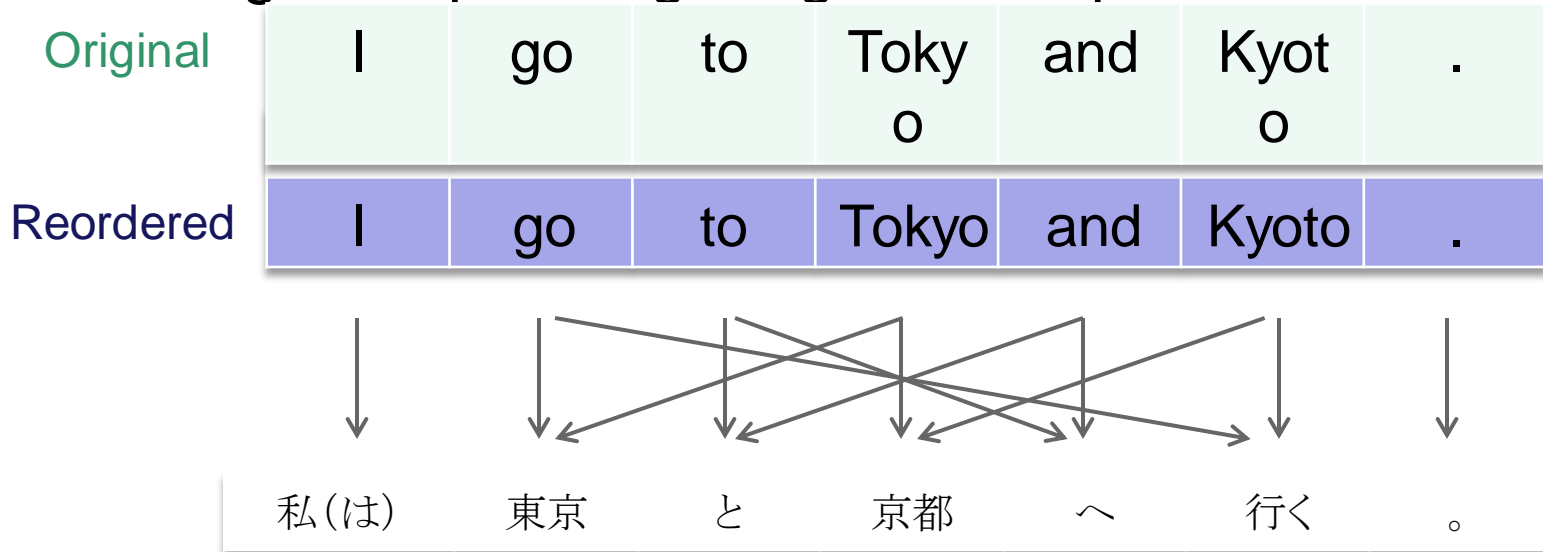
- Take into account new translations
- Blacklist of phrases
- Collect post-editions
- ...

Pre-reordering



Dan Han
Native Chinese
PhD Tokyo Graduate University for Advanced Studies

Order differences complicate phrase extraction.
Reordering is helpful. E.g. English-to-Japanese



Thank you for your attention

شكرا لكم على اهتمامكم

Merci pour votre attention!

感谢您的关注

Grazie per la vostra attenzione!

i Gracias por su atención !

Vielen Dank für Ihre Aufmerksamkeit!

Obrigado pela vossa atenção!

Dziękuję bardzo za Państwa uwagę!

Děkujeme za Vaši pozornost!

Ďakujem ti veľmi pekne za tvoju pozornosť!

Tänaan tähelepanu eest!

Благодарим за Вашето внимание!

Tak for Jeres opmærksomhed!

आप अपना ध्यान के लिए धन्यवाद

Bibliography

Try it! Google: wipo translate

- (2014) Marcin Junczys-Dowmunt and Bruno Pouliquen: SMT of German Patents at WIPO: Decompounding and Verb Structure Pre-reordering. (*EAMT2014*), 16-18 June 2014, Dubrovnik
- (2013) Bruno Pouliquen, Christophe Mazenc & Paul Halfpenny: Latest developments in machine translation at WIPO, *EPO- East meets West*, 18-19 April 2013, Vienna, Austria
- (2011) Bruno Pouliquen & Christophe Mazenc: Automatic translation tools at WIPO. *Aslib, Translating and the Computer 33*, 17-18 Nov 2011, London
- (2012) Marcin Junczys-Dowmunt : A Phrase Table without Phrases: Rank Encoding for Better Phrase Table Compression. *EAMT2012*
- (2011) Bruno Pouliquen & Christophe Mazenc: COPPA, CLIR and TAPTA: three tools to assist in overcoming the patent barrier at WIPO. *MT Summit XIII*.
- (2011) Bruno Pouliquen, Christophe Mazenc & Aldo Iorio: Tapta: a user-driven translation system for patent documents based on domain-aware statistical machine translation. [*EAMT2011*]

Tapta4UN:

- (2013) B. Pouliquen, C. Elizalde, M. Junczys-Dowmunt, C. Mazenc & J. Garcia-Verdugo: Large-scale multiple language translation accelerator at the United Nations. [MT Summit 2013]
- (2012) C. Elizalde, B. Pouliquen, C. Mazenc & J. García-Verdugo: TAPTA4UN: collaboration on machine translation between the World Intellectual Property Organization and the United Nations. [Aslib 2012] *Translating and the Computer 34*, 29-30 November 2012]
- (2012) Bruno Pouliquen, Christophe Mazenc, Cecilia Elizalde, & Jose Garcia-Verdugo: Statistical machine translation prototype using UN parallel documents. *EAMT2012*