

Contextual Distribution for Textual Alignment

Yuri Bizzoni, Marianne Reboul

Abstract—Our program compares French and Italian translations of Homer's *Odyssey*, from the XVIth to the XXth century. We focus on the third point, showing how distributional semantics systems can be used both to improve alignment between different French translations as well as between the Greek text and a French translation. Although we focus on French examples, the techniques we display are completely language independent.

Keywords—Translation studies, machine translation, computational linguistics, distributional semantics.

I. INTRODUCTION

WE compare French and Italian translations of Homer's *Odyssey*, from the XVIth to the XXth century. Open data algorithms are still either too dependent on language specifications and databases or unreliable. We hope to overcome these aporias. The Greek text is first cut on anchor points (proper nouns), and so is its corresponding translation; the corpus is then aligned with our algorithm and divided in fixed chunks. Each Greek chunk is given a fixed ID, allowing us to give its translations the corresponding IDs. Each translation is therefore aligned one to another according to their identification.

The alignment of the source to the target is done in three steps (preprocessing, alignment and postprocessing). To align textual chunks we use three main systems: 1, an automatically generated bilingual dictionary of Greek-French proper nouns; 2, length and frequency measures; 3, a dictionary of distributionally related terms.

II. DISTRIBUTIONAL SEMANTICS

The third point allowed us to consider a token not just as one data unit but as a contextual vector.

A problem in aligning different monolingual translations is that different translators could use different words to express the same meaning, and it would be necessary to find a way to detect the semantic similarity between their different choices. A way to model the semantic similarity of two elements is to study the problem from a distributional point of view, which is done through the construction of contextual vectors.

A contextual vector represents the distributional behaviour of a word in a corpus. The distribution of a word is the list of contexts in which such word appears [1], and it gives a representation of how that word is used [2].

It is argued by several linguists [2], [3] that one of the best ways to define the meaning of a word is to look at that word in relation to others.

The way two words are used can be considered as an indication of their difference in meaning [4]: thus, words with similar distributions should have similar meanings. Words having similar contextual vectors will probably share a similarity in meaning: they could be synonyms, since they are used in the same contexts.

III. MONOLINGUAL DISTRIBUTIONAL SIMILARITIES

Comparing vectors in both source and target allowed us to determine a distributional dictionary of potential synonyms.

We saw, in fact, that contextual features could still be useful in different translations to determine synonymy.

Some contexts tend to remain similar from the source to the target, and therefore may be most useful for chunk-to-chunk or even word-to-word alignment. Just to make an example, we can look at the following lines taken respectively from Dacier's and Sommer's translations:

une hécatombe de taureaux et d'*agneaux*
(Dacier, *Odyssée*, I)

une hécatombe de taureaux et de *brebis*
(Sommer, *Odyssée*, I)

In this example, *agneaux* and *brebis* have exactly the same context, thus it is possible to hypothesize a semantic similarity between the two words.

Although stylistic differences between translators involve large changes also in lexicon, it is often the case that two different synonyms, or pseudo-synonyms, are used in similar contexts, allowing us to distributionally detect similar variations. To do so, we give each word of each text (stored in a non repetitive map) a modifiable immediate context.

The choice of the context has a central role in this model, since it strongly conditions the results. For example, a 4-word contextual window will take into account the two words preceding and the two words following every occurrence of the given term:

la ville **sacrée** de Troie (Dacier, *Odyssée*, I)

les murs **sacrés** de Troie (Sommer, *Odyssée*, I)

Yuri Bizzoni is graduated in Computational Linguistics at the University of Pisa (e-mail is yuri.bizzoni@gmail.com).

Marianne Reboul is a PhD student at the University La Sorbonne of Paris (e-mail: odyseuspolymetis2010@gmail.com).

This way, it is possible to represent the semantic similarity of two words as the similarity between their vectors. Co-occurrence vectors are set into a co-occurrence matrix. Such matrix normally has a set of words in rows and a set of words in columns while cells contain the frequency of co-occurrence of each word in rows with each word in columns:

	la	ville	les	murs	de	Troie	...
<i>sacrés</i>	0	0	1	1	1	1	
<i>sacrée</i>	1	1	0	0	1	1	

$$\text{sim cos}(\vec{x}, \vec{y}) = \frac{x \cdot y}{|x||y|} = \frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2} \sqrt{\sum_{i=1}^n y_i^2}}$$

NW sans traitement	
chunk 1 Muse, contez-moi les aventures de cet homme prudent qui, après avoir ruiné la ville sacrée de Troie, fut errant plusieurs	chunk 1 Muse, dis-moi ce sage héros qui erra de longues années après qu'il eut renversé les murs sacrés de Troie, qui vis
chunk 2 Jupiter, daigne nous apprendre, à nous aussi, une partie des aventures de ce héros. Tous ceux qui avaient été la mo	chunk 2 Soleil, et le dieu leu ravit le jour du retor. Déesse, fille de Jupiter, redis-nous du moins une partie de ces malheurs
chunk 3 Calypso, qui désirait passionnément de l'avoir pour époux. Mais après plusieurs années révolues, quand celle que les di	chunk 3 Calypso, belle entre les déesses, le retenait dans ses grottes profondes, et brûlait d'en faire son époux. Mais lor
chunk 4 Ithaque fut arrivée, ce prince se trouva encore exposé à de nouveaux travaux, quoiqu'il fût au milieu de ses amis. Enfin	chunk 4 Ithaque, alors même il devait soutenir encore des luttes jusqu'au milieu de ses amis. Tous les dieux avaient pitié d
chunk 5 Jupiter. Là, le père des dieux et des hommes s' étant souvenu du fameux	chunk 5 Egisthe, que venait de tuer le fils d' Agamemnon, le fameux
chunk 6 Egisthe, qu' Oreste avait tué pour venger la mort de son père, leur parla ainsi : Quo ! les mortels osent accuser les die	chunk 6 Oreste ; il se souvenait, et il adressa ces paroles aux immortels : `` Hélas ! combien les hommes n'accusent - ils pa
chunk 7 Agamemnon, après avoir assassiné ce prince ; il l'ignorait pourtant pas fa terrible punition qui suivrait son crime. Nous s	chunk 7 Mercure, le vigilant meurtrier d'
chunk 8 Mercure, qui lui défendait de notre part d'attenter à la vie du fils d'Attrée et de s'em parer de son lit ; lui déclara qu'	chunk 8 Argus, nous l'avions averti de ne point le tuer et de ne point rechercher son épouse, car
chunk 9 Oreste vengerait cette mort et le punirait de ses forfaits dès qu'il serait en âge et qu'il sentirait le désir de voir sa patrie,	chunk 9 Oreste le punirait un jour, quand il aurait grandi et qu'il désirerait revoir sa patrie. Ainsi parla
chunk 10 Egisthe n'écouta point des avis si salutaires ; aussi vient-il de payer à la fois tous ses crimes. La déesse	chunk 10 Mercure ; mais ses conseils bienveillants ne persuadèrent point le cœur d'Egisthe ; et maintenant il a expié tout à
chunk 11 Minerve, prenant la parole, répondit : - Fils du grand Saturne, qui êtes notre père et qui régné sur tous les rois, ce m	chunk 11 Minerve, lui répondit ensuite : `` Fils de Saturne, notre père, le plus grand des rois, il est tombé sous de justes

chunk 1 Muse, contez-moi les aventures de cet homme prudent qui, après avoir ruiné la ville sacrée de Troie, fut errant plusieurs années en divers lieux. chunk 2 Soleil, et ce dieu irrité le punit de ce sacrilège. Déesse, fille de chunk 3 Jupiter, daignez nous apprendre, à nous aussi, une partie des aventures de ce héros. Tous ceux qui avaient évité la mort devant les renaissances de ce héros. chunk 4 Ithaque fut arrivée. ce prince se trouva encore exposé à de nouveaux travaux, quoiqu'il fût au milieu de ses amis. Enfin les dieux eurent pitié de lui. chunk 5 Jupiter. Là, le père des dieux et des hommes s'étant souvenu du fameux Égisthe, qu'Oreste avait tué pour venger la mort de son père Agamemnon, après avoir assassiné ce prince: il n'ignorait pourtant pas la terrible punition qui suivrait son crime. Nous avons eu soin de vous en avertir. chunk 6 Mercure, qui lui défendait de notre part d'attenter à la vie du fils d'Atreïde et de s'en parer de son lit: il lui déclara qu'il le punirait de ses forfaits dès qu'il serait en âge et qu'il sentirait le désir de voir sa patrie. Mercure l'avertit de ne point desobéir à ces avis si salutaires; aussi vient-il de payer à la fois tous ses crimes. La déesse Minerve, prenant la parole, répondit: - Fils du grand Saturne, qui êtes notre père et qui régniez sur tous les rois, ce malheureux ne méritait pas d'être puni de mort. chunk 7 Ulysse, qui depuis longtemps est accablé d'une infinité de maux, loin de ses amis, dans une île éloignée, toute couverte de bois, au milieu de la forêt. chunk 8 Ithaque, Ulysse résiste à tous ses charmes; il ne demande qu'à voir seulement la fumée de son palais, et, pour acheter ce plaisir, il offre de sacrifier à tous les dieux. chunk 9 Ulysse qui vous a offert tant de sacrifices sous les murs de Troie? Pourquoi êtes-vous si fort irrité contre lui? - Ma fille, lui répondit le malin dieu, que vous savez. chunk 10 Ulysse, qui surpasse tous les hommes en prudence et qui a offert plus de sacrifices que nul autres aux dieux immortels qui habitent l'Olympe.	chunk 1 Muse, dis-moi ce sage héros qui erra de longues années après qu'il eut renversé les murs sacrés de Troie, qui visita les cîtes et apprit les événements de son pays. chunk 2 Soleil, et le dieu lui racontant le jour du retour. Déesse, fille de chunk 3 Jupiter, reds-nous du moins une partie de ces malheurs. Déjà tous ceux qui avaient échappé à une fin terrible avaient leur patrie: ils ne demandaient qu'à retourner. chunk 4 Ithaque, alors même il devait soutenir encore des luttres jusqu'au milieu de ses amis. Tous les dieux avaient pitié de lui; Ulysse, jusque-là, ne demandait qu'à retourner. chunk 5 Égisthe, que venait de tuer le fils d'Agamemnon, le fameux Oreste; il se souvenait, et il adressa ces paroles aux immortels: " Hé! que de malheurs!" chunk 6 Égisthe, malgré le destin, s'est uni à l'épouse du fils d'Atreïde, il a égorgé le héros à son retour, bien qu'il vît une fin terrible; nous l'avons vu. chunk 7 Argus, nous l'avions averti de ne point le tuer et de ne point rechercher son épouse, car il était le fils de son père. chunk 8 Oreste le punirait un jour, quand il aurait grandi et qu'il désirerait revoir sa patrie. Ainsi parla le dieu. chunk 9 Mercure; mais ses conseils bienveillants ne persuadèrent point le cœur d'Égisthe; et maintenant il a expié tout à la fois. " La déesse Minerve, prenant la parole, répondit: " chunk 10 Minerve, lui répondit ensuite: " Fils de Saturne, notre père, le plus grand des rois, il est tombé sous de justes coups. Pénisse à la mort, il ne demandait qu'à retourner. chunk 11 Ulysse, l'infortuné, qui depuis longtemps, loin de ses amis, souffre dans une île qu'enferment les flots et qui est le center de la mort, ne demandait qu'à retourner. chunk 12 Ithaque, mais Ulysse, qui voudrait voir au moins la fumée s'élever de la terre natale, souhaite de mourir. Ton cœur n'est donc point assés dur. chunk 13 Troie? Pourquoi tant de courroux contre lui, à offering 2" Jupiter qui assemble les nuées lui répondit: " Ma fille, quelle parole est-ce que tu me dis?" chunk 14 Ulysse, le plus sage des mortels, celui qui a offert le plus de sacrifices aux dieux qui habitent le vaste ciel? Mais il n'est pas mort.
--	---

2079

If the cosine similarity result is high, we store each word and its potential proximity tokens in a distributional dictionary that will impact on the final similarity score.

Referring to the preceding example, a chunk with *agneaux* and a chunk with *brebis* will have a slightly higher probability to be aligned - thus, to contain the same information - than two chunks with words distributionally unrelated.

The immediate results show that distributionally near words tend to be either semantically related or linked by similar expressions, and in general that this technique allows us to improve the alignment of translational segments.

In Fig. 1, we can see that, although some chunks have been correctly aligned, many mistakes remain. For 17 chunks, 7 are faulty. In Fig. 2 however, when context is taken into account, only 3 mistakes remain (which could be reduced to one, as two of these problematic alignments are to be considered in reverse).

The theoretical interest of these results in our line of work is also to be considered: the changing in the use and the meaning of words is of primary interest in translation studies. The same words could have very different distributional neighbours in different translations. The fact that contextual information can be successfully used to infer semantic similarities between translations of different eras can be fascinating to consider.

This method being entirely language independent, it may be adaptable to any monolingual set of translation.

Once the preprocessing is done, an adaptation of Needleman-Wunsch's algorithm (initially created to align protein sequences) [6] associates each chunk in a potentially final aligned corpus.

This algorithm works building up a grid from any two sequences. For each element in the first sequence (for example, for each letter, or for each segment) it assigns a value of matching probability to every element of the second sequence, based on a given similarity score and on the already made matches.

The similarity score is calculated through a specific function that uses some pre-defined metric to determine how much two elements are similar between them. This is somehow the most sensitive part of the system, since it is the function that decides whether two elements have a good probability of matching. The function that attributes a similarity score determines the success of the rest of the operation. In our case, since we are using non-annotated corpora, we maintained very simple parameters: the similarity is calculated through the automatically generated dictionary and some other heuristics.

We use the distributional similarity between words to improve the precision of the similarity score.

IV. CROSS-LINGUAL DISTRIBUTIONAL SIMILARITIES

Naturally, a context-based similarity is very helpful between monolingual translations.

Vectorial representations are widely used in linguistics to model the distance between words, concepts [7], expressions [8], etc., but semantic distance is normally computed between two words of the same language and only recently some studies have been made about vectors in bilingual parallel corpora.

Corpus-based approaches to parallel corpora have been exploited mainly in the field of Machine Translation. Cohn and Lapata [9] try to improve poor-resource languages translation through a triangulation method, using a rich language as pivot between two texts. Banea [10] uses multilingual corpus-based approach to improve sentiment analysis annotation. In general, standard context-based distributional analysis is bound to work only on monolingual texts.

Thus, to embetter Greek-French alignment we used a slightly different technique, that can be applied in a second-round alignment to refine results.

In this case, two aligned parts of a bilingual text can be considered as a unique cooccurrence window, or, better, as a unique "word area" that can, or cannot, contain some given words in both languages.

In this perspective, the vector of each word of the parallel corpus (thus, the vector of every word independently from the language it belongs to) is determined by the presence or absence of that word in each bilingually aligned block. Being the blocks composed of a segment of text in a language and its equivalent in the other language, we could expect from an absolutely literal translation to return perfectly similar vectors for each word and its translation.

So, from a first alignment we obtain Greek-French coupled chunks and we build our words' vectors looking at whether each word appears or not in a determined Greek-French couple. Ancient Greek and French equivalent words will happen to have similar vectors, since they will appear in the same aligned chunks.

The principle is simple: we create a semantic space of the word-to-document kind, so that in rows are words and in columns are textual blocks in which those words can appear. Each textual block is composed by two parallel segments already aligned. One word's vector is given by its presence or absence in textual blocks. Consequently, both Greek and French words can appear in every block - can have a non-zero value in every position of their vector.

A Greek word and its French rendition will tendentially have very similar vectors and thus will appear very near, as in the following toy-example:

Ulysse sur les vaisseaux recourbés vers Ilion
Ὀδυσσεύς Ἰλίον εἰς εὐπωλον ἔβη κοῦλησ' ἐνὶ νηυσίν

Cyclope tua dans sa caverne profonde
Κύκλωψ ἐν σπητὶ γλαφυρῷ

le fils chéri d'**Ulysse**
Ὀδυσσεύς φίλος υἱός

Ὀδυσσεύς vector: **1 0 1**

Ulysse vector: **1 0 1**

Cyclope vector: 0 1 0

This system, a form of cross-lingual term-by-document matrix, is already known in information retrieval although it is mainly used to retrieve documents, and not single terms, in

different languages. Basically, a query in a language is used to find relevant documents in another language.

This technique can both allow a word-to-word research on text and give better alignment results when connected to the aligner, since it gives a quick way to find new anchor words for the text. Starting from a broad block-to-block alignment with the heuristics we described, it is possible to reach a more refined

matching through the extraction of single word translations, that can be used in a second round alignment as additional anchor words.

From this basic idea an improved dictionary of anchor words can be created, with values of probability assigned to each Greek-French translation, and a second-round alignment can be run to obtain more accurate results.

chunk 1 "ἄνδρα μοι ἔννεπε, χυμ 1 Muse, dis-moi ce sage héros qui erra de longues années après qu'il eut renversé les murs sacrés de Troie, qui visita les cités et app	chunk 1 Muse, dis-moi ce sage héros qui erra de longues années après qu'il eut renversé les murs sacrés de Troie, qui visita les cités et app
chunk 2 μοῦσα, πολύτροπον, ἔς μοι πολλὰ πόλιν ἔειπ' ἔπειτα χυμ 2 Soleil, et le dieu leu ravit le jour du retour, Déesse, fille de Jupiter, redis-nous du moins une partie de ces malheurs. Déjà tous ceux	chunk 2 Soleil, et le dieu leu ravit le jour du retour, Déesse, fille de Jupiter, redis-nous du moins une partie de ces malheurs. Déjà tous ceux
chunk 3 ἀνδρῶν ἡρώων ἡρώων: αὐτὰρ ὁ τοῖσιν ἀνέειπε νόστον ἦμαρ, τῶν ἄλλων γε, θεῶ, θύγατερ χυμ 3 Agamemnon, le fameux Oreste; il se souvenait, et il adressa ces paroles aux immortels: " Hélas! combien les hommes n'accusent	chunk 3 Agamemnon, le fameux Oreste; il se souvenait, et il adressa ces paroles aux immortels: " Hélas! combien les hommes n'accusent
chunk 4 οὐδ', εἰπέ μοι ἦμιν, ἔνθ' ἄλλοι μὲν πάντες, ὅσοι φύγον αἰὲν ἄλκιρον, οἷοι ἴσων, πάλῃ μὲν τε περὶ γόγγυον ἦδ' ἔθλασσον: τὸν δ' οὖν νόστος χυμ 4 Egisthe, malgré le destin, s' est uni à l'épouse du fils d'Atrée, il a égorgé le héros à son retour, bien qu'il vît une fin terrible: nous r	chunk 4 Egisthe, malgré le destin, s' est uni à l'épouse du fils d'Atrée, il a égorgé le héros à son retour, bien qu'il vît une fin terrible: nous r
chunk 5 ἴδμεν, οὐδ' ἔνθα περὶ γόγγυον ἦν ἔδμεν καὶ μετὰ οἷα φίλοι. θεοὶ δ' ἔλκετον ἴππωνες νόστοι ποσειδάωνος: ὁ δ' ἀσπερ εἰς μενέαιον χυμ 5 Oreste le punirait un jour, quand il aurait grandi et qu'il désirerait revoir sa patrie. Ainsi parla Mercure: mais ses conseils bienveillan	chunk 5 Oreste le punirait un jour, quand il aurait grandi et qu'il désirerait revoir sa patrie. Ainsi parla Mercure: mais ses conseils bienveillan
chunk 6 ὁ δὲ πᾶσι πᾶσι τοῖσιν ἔειπεν, ἄλλ' ὁ μὲν αἰθήρας μετεκίεθε τῆλ' ἄλκιρος, χυμ 6 Minerve, lui répondit ensuite: " Fils de Saturne, notre père, le plus grand des rois, il est tombé sous de justes coups. Périsse ain	chunk 6 Minerve, lui répondit ensuite: " Fils de Saturne, notre père, le plus grand des rois, il est tombé sous de justes coups. Périsse ain
chunk 7 αἰθήρας τοὶ δὲ θεοὶ δαίμονες, ἔσχατοι ἄνδρων, οἳ μὲν δυσσέμνον ὑπερίονος οἳ δ' ἀνάντες, ἀντίων τούρων τε καὶ ἀρνεῖν κατασφίγγει χυμ 7 Ulysse, mais il le fait errer loin de sa patrie. Mais voyons, nous tous qui sommes ici, songeons à assurer son retour; Neptune dépos	chunk 7 Ulysse, mais il le fait errer loin de sa patrie. Mais voyons, nous tous qui sommes ici, songeons à assurer son retour; Neptune depos
chunk 8 ἔνθα δὲ μὲν ἔειπεν, αὐτὰρ ὁ μὲν ἔπειτα πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 8 Saturne, notre père, le plus grand des rois, s' il plaît aujourd' hui aux dieux bienheureux que le prudent	chunk 8 Saturne, notre père, le plus grand des rois, s' il plaît aujourd' hui aux dieux bienheureux que le prudent
chunk 9 ἀμύμονος ὁ δὲ μὲν ἔπειτα πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 9 Ulysse rentre dans sa demeure, envoyons aussitôt	chunk 9 Ulysse rentre dans sa demeure, envoyons aussitôt
chunk 10 αἰθήρας, τὸν δ' ἔπειτα πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 10 Mercure, notre messager, le meurtrier d'Argus, dans l'île d'Ogyge, pour déclarer à la nymphe aux beaux cheveux notre résolution	chunk 10 Mercure, notre messager, le meurtrier d'Argus, dans l'île d'Ogyge, pour déclarer à la nymphe aux beaux cheveux notre résolution
chunk 11 Ὀδυσσεύς: τοῦ δ' ἔπειτα πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 11 Ulysse. Moi, j'irai à l'île d'Argos animer son fils, et je mettrai la force dans son cœur, pour qu'il convoque en assemblée les	chunk 11 Ulysse. Moi, j'irai à l'île d'Argos animer son fils, et je mettrai la force dans son cœur, pour qu'il convoque en assemblée les
chunk 12 Ἀτρεΐδαν, ὅπως ἂν ἴδμεν τε καὶ ἴς ἡμῶν αἰῶν, ὡς ἔφαθ' ἔρμης, ἄλλ' οὐ φέρονος χυμ 12 Grecs à la longue chevelure et interdise sa maison aux prétendants, qui chaque jour égorgent en foule ses brebis et ses bœufs au	chunk 12 Grecs à la longue chevelure et interdise sa maison aux prétendants, qui chaque jour égorgent en foule ses brebis et ses bœufs au
chunk 13 αἰθήρας πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 13 Athènes, elle s' irrite, elle, fille d'un père puissant. Elle s' élance des cimes de l'	chunk 13 Athènes, elle s' irrite, elle, fille d'un père puissant. Elle s' élance des cimes de l'
chunk 14 Ἀθήνη: " ὡς πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 14 Athènes, elle s' irrite, elle, fille d'un père puissant. Elle s' élance des cimes de l'	chunk 14 Athènes, elle s' irrite, elle, fille d'un père puissant. Elle s' élance des cimes de l'
chunk 15 Ὀδυσσεύς, ὅπως ἂν ἴδμεν τε καὶ ἴς ἡμῶν αἰῶν, ὡς ἔφαθ' ἔρμης, ἄλλ' οὐ φέρονος χυμ 15 Ulysse, près du vestibule d'Ulysse, sur le seuil de la cour, semblable à un étranger, à	chunk 15 Ulysse, près du vestibule d'Ulysse, sur le seuil de la cour, semblable à un étranger, à
chunk 16 Ὀδυσσεύς, ὅπως ἂν ἴδμεν τε καὶ ἴς ἡμῶν αἰῶν, ὡς ἔφαθ' ἔρμης, ἄλλ' οὐ φέρονος χυμ 16 Minerve. Elle trouva d'abord les prétendants superbes; ils se divertissaient avec des jetons devant la porte, ar	chunk 16 Minerve. Elle trouva d'abord les prétendants superbes; ils se divertissaient avec des jetons devant la porte, ar
chunk 17 Ὀδυσσεύς, ὅπως ἂν ἴδμεν τε καὶ ἴς ἡμῶν αἰῶν, ὡς ἔφαθ' ἔρμης, ἄλλ' οὐ φέρονος χυμ 17 Pallas Athénè le suivit. Lorsqu'ils furent entrés dans la haute demeure, il alla poser la lance contre une colonne élevée, dans une	chunk 17 Pallas Athénè le suivit. Lorsqu'ils furent entrés dans la haute demeure, il alla poser la lance contre une colonne élevée, dans une

Fig. 3 Needleman-Wunsch Greek alignment without distributional semantics

chunk 1 "ἄνδρα μοι ἔννεπε, χυμ 1 Muse, dis-moi ce sage héros qui erra de longues années après qu'il eut renversé les murs sacrés de	chunk 1 Muse, dis-moi ce sage héros qui erra de longues années après qu'il eut renversé les murs sacrés de
chunk 2 μοῦσα, πολύτροπον, ἔς μοι πολλὰ πόλιν ἔειπ' ἔπειτα χυμ 2 Troie, qui visita les cités et apprit les mœurs de tant de peuples; sur mer, son cœur endura mille souffrances, tandis qu'il lutait	chunk 2 Troie, qui visita les cités et apprit les mœurs de tant de peuples; sur mer, son cœur endura mille souffrances, tandis qu'il lutait
chunk 3 ἀνδρῶν ἡρώων ἡρώων: αὐτὰρ ὁ τοῖσιν ἀνέειπε νόστον ἦμαρ, τῶν ἄλλων γε, θεῶ, θύγατερ χυμ 3 Agamemnon, le fameux Oreste; il se souvenait, et il adressa ces paroles aux immortels: " Hélas! combien les hommes n'accu	chunk 3 Agamemnon, le fameux Oreste; il se souvenait, et il adressa ces paroles aux immortels: " Hélas! combien les hommes n'accu
chunk 4 οὐδ', εἰπέ μοι ἦμιν, ἔνθ' ἄλλοι μὲν πάντες, ὅσοι φύγον αἰὲν ἄλκιρον, οἷοι ἴσων, πάλῃ μὲν τε περὶ γόγγυον ἦδ' ἔθλασσον: τὸν δ' οὖν νόστος χυμ 4 Soleil, et le dieu leu ravit le jour du retour, Déesse, fille de Jupiter, redis-nous du moins une partie de ces malheurs. Déjà tous ce	chunk 4 Soleil, et le dieu leu ravit le jour du retour, Déesse, fille de Jupiter, redis-nous du moins une partie de ces malheurs. Déjà tous ce
chunk 5 ἴδμεν, οὐδ' ἔνθα περὶ γόγγυον ἦν ἔδμεν καὶ μετὰ οἷα φίλοι. θεοὶ δ' ἔλκετον ἴππωνες νόστοι ποσειδάωνος: ὁ δ' ἀσπερ εἰς μενέαιον χυμ 5 Calypso, belle entre les déesses, le retenait dans ses grottes profondes, et brûlait d'en faire son époux. Mais lorsque enfin les	chunk 5 Calypso, belle entre les déesses, le retenait dans ses grottes profondes, et brûlait d'en faire son époux. Mais lorsque enfin les
chunk 6 αἰθήρας μετεκίεθε τῆλ' ἄλκιρος, αἰθήρας τοὶ δὲ θεοὶ δαίμονες, ἔσχατοι ἄνδρων, οἳ μὲν δυσσέμνον ὑπερίονος οἳ δ' ἀνάντες, ἀντίων τούρων τε καὶ ἀρνεῖν κατασφίγγει χυμ 6 Athènes, alors même il devait soutenir encore des luttes jusqu'au milieu de ses amis. Tous les dieux avaient pitié de lui: Ulysse, j	chunk 6 Athènes, alors même il devait soutenir encore des luttes jusqu'au milieu de ses amis. Tous les dieux avaient pitié de lui: Ulysse, j
chunk 7 ἔνθα δὲ μὲν ἔειπεν, αὐτὰρ ὁ μὲν ἔπειτα πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 7 Olympien. Le père des dieux et des hommes prit le premier la parole: il se souvenait en son cœur du noble	chunk 7 Olympien. Le père des dieux et des hommes prit le premier la parole: il se souvenait en son cœur du noble
chunk 8 Ἀμύμονος ὁ δὲ μὲν ἔπειτα πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 8 Egisthe, que venait de tuer le fils d'	chunk 8 Egisthe, que venait de tuer le fils d'
chunk 9 ἀμύμονος ὁ δὲ μὲν ἔπειτα πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 9 Agamemnon, le fameux Oreste; il se souvenait, et il adressa ces paroles aux immortels: " Hélas! combien les hommes n'accu	chunk 9 Agamemnon, le fameux Oreste; il se souvenait, et il adressa ces paroles aux immortels: " Hélas! combien les hommes n'accu
chunk 10 αἰθήρας πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 10 Egisthe, malgré le destin, s' est uni à l'épouse du fils d'Atrée, il a égorgé le héros à son retour, bien qu'il vît une fin terrible: nc	chunk 10 Egisthe, malgré le destin, s' est uni à l'épouse du fils d'Atrée, il a égorgé le héros à son retour, bien qu'il vît une fin terrible: nc
chunk 11 Ὀδυσσεύς: τοῦ δ' ἔπειτα πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 11 Oreste le punirait un jour, quand il aurait grandi et qu'il désirerait revoir sa patrie. Ainsi parla Mercure: mais ses conseils bienve	chunk 11 Oreste le punirait un jour, quand il aurait grandi et qu'il désirerait revoir sa patrie. Ainsi parla Mercure: mais ses conseils bienve
chunk 12 Ἀτρεΐδαν, ὅπως ἂν ἴδμεν τε καὶ ἴς ἡμῶν αἰῶν, ὡς ἔφαθ' ἔρμης, ἄλλ' οὐ φέρονος χυμ 12 Saturne, notre père, le plus grand des rois, il est tombé sous de justes coups. Périsse ainsi quiconque ferait de lui: Ulysse, j	chunk 12 Saturne, notre père, le plus grand des rois, il est tombé sous de justes coups. Périsse ainsi quiconque ferait de lui: Ulysse, j
chunk 13 αἰθήρας πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 13 Atlas, qui connaît les abîmes de la mer entière et soutient les hautes colonnes qui séparent la terre et les cieux. Sa fille retent	chunk 13 Atlas, qui connaît les abîmes de la mer entière et soutient les hautes colonnes qui séparent la terre et les cieux. Sa fille retent
chunk 14 Ἀθήνη: " ὡς πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 14 Ulysse, près des vaisseaux des Troie? Pourquoi tant de courroux contre lui, ô Jupiter? "	chunk 14 Ulysse, près des vaisseaux des Troie? Pourquoi tant de courroux contre lui, ô Jupiter? "
chunk 15 Ὀδυσσεύς, ὅπως ἂν ἴδμεν τε καὶ ἴς ἡμῶν αἰῶν, ὡς ἔφαθ' ἔρμης, ἄλλ' οὐ φέρονος χυμ 15 Ulysse, près des vaisseaux des Troie? Pourquoi tant de courroux contre lui, ô Jupiter? "	chunk 15 Ulysse, près des vaisseaux des Troie? Pourquoi tant de courroux contre lui, ô Jupiter? "
chunk 16 Ἀτρεΐδαν γῆμ' ἔλκετον νοστήσαντα, εἰδὼς αἰὲν ἄλκιρον, ἔπειτα πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 16 Ulysse, près des vaisseaux des Troie? Pourquoi tant de courroux contre lui, ô Jupiter? "	chunk 16 Ulysse, près des vaisseaux des Troie? Pourquoi tant de courroux contre lui, ô Jupiter? "
chunk 17 ἔρμης πᾶσι τῶν ἄλλων τῶν τε θεῶν τε: μνηστον γὰρ κατὰ θυμὸν ἀμύμονος χυμ 17 Jupiter qui rassemble les nuées lui répondit: " Ma fille, quelle parole est sortie de ta bouche! Comment pourrais-je oublier le d	chunk 17 Jupiter qui rassemble les nuées lui répondit: " Ma fille, quelle parole est sortie de ta bouche! Comment pourrais-je oublier le d

Fig. 4 Needleman-Wunsch Greek alignment with distributional semantics

In Fig. 3 we can see that many chunks are not correctly aligned. At least 9 of the 17 chunks have not found their correct match. However, in Fig. 4, considering the post-processing of pre-segmented distributional semantics, the result is almost perfect: 3 out of 17 chunks have found their correct match. It is therefore visible that this ultimate step, based on realigning preceding chunks and applying distributional semantics methods for a last alignment, is most effective.

V.CONCLUSION

As a language may be defined as a system based on grammatical principles (which may be flexible or not), any language may not be organized totally arbitrarily. Words and

their multiple meanings are defined and clarified by their context. Therefore, understanding the logic behind a simple multi-character token implies a deep consideration of not only the word examined, but also of the whole group of words that surrounds it. This theoretical principle may also be applied on a statistical point of view: even in texts made to be impossible to understand, language has its logic, and words cannot be considered independently. Thus, in a statistical approach, if we may not strictly speaking infer the meaning of words on the sole consideration that they may be similar, we can at least conclude that each word cannot be considered as a nucleus, but as a particle of a much more complex cell. As a result, we have shown that alignment procedures need not only to consider a word through its internal similarity with others, but also as a

necessary part of a larger statistical system. Studying context for alignment is an image of the way the human brain works: understanding a language means understanding its systematic principles.

REFERENCES

- [1] Miller, G. A. (1967), *Empirical methods in the study of semantics*, in *Journeys in Science: Small Steps – Great Strides*, University of New Mexico Press, Albuquerque: 51–7.
- [2] Miller G. and Charles W. (1991), *Contextual correlates of semantic similarity*. In: *Language and Cognitive Processes* 6(1):1–28.
- [3] Firth J. R. (1951), *Modes of meaning*, In: *Essays and Studies*, The English Association, Oxford.
- [4] Harris, Z., (1954), *Distributional structure*. *Word*, X/2-3, pp. 146-62.
- [5] Sahlgren, M., (2006). *The Word Space Model*. PhD Dissertation, Stockholm University.
- [6] Needleman, S. and Wunsch, C., (1970), *A general method applicable to the search for similarities in the amino acid sequence of two proteins*. In: *Molecular Biology*, n.48, pp.443-453.
- [7] Alfonseca, E. and Manandhar, S., (2002), *Extending a Lexical Ontology by a Combination of Distributional Semantics Signatures*. Berlin: Springer-Verlag.
- [8] Baroni, M., Bernardi, R., Do, N., Shan, C., (2012), *Entailment above the word level in distributional semantics*. *Proceedings of the 13th Conference of the European Chapter of the Association for Computational Linguistics*, pp.23-32.
- [9] Pado S. and Lapata M. (2007). *Dependency-based Construction of Semantic Space Models*. *Computational Linguistics*, 33:2, 161-199.
- [10] Banea C., Mihalcea J. R., and Wiebe J., (2010). *Multilingual subjectivity: Are more languages better?* In: *Proceedings of COLING'10*.