



# Quelques bases de Traitement Automatique des Langues (TAL)

Karën Fort

karen.fort@univ-lorraine.fr / <https://members.loria.fr/KFort/>

## Quelques sources d'inspiration

- ▶ Cours d'Alain Couillault, Gestion sémantique des contenus, Master ICONE, La Rochelle.
- ▶ [http://faculty.washington.edu/ebender/2012\\_472/0404.pdf](http://faculty.washington.edu/ebender/2012_472/0404.pdf)
- ▶ <http://www.cis.upenn.edu/~cis639/docs/fsexamples.html>

## Sources

### Introduction

- Le TAL en 2 minutes
- Le TAL et ses applications
- Le TAL et ses acteurs
- Le TAL : définitions

Ambiguïté à tous les étages

Des solutions

Rappel sur l'analyse syntaxique

Pour finir

## De quoi ça parle ?

Reoiajr oj earoij reoa o eo ao aeoi oj aeroij aoeir eoaj.

# De quoi ça parle ?

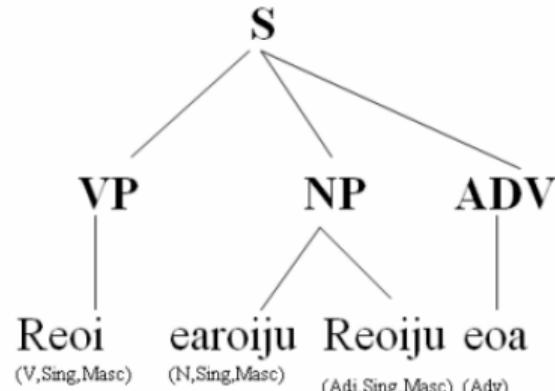
Reoiajr oj earoij reoa o eo ao aeoi oj aeroij aoeir eoaj.

## De quoi ça parle ?

Reoi      earoiju    Reoiju    eoa  
(V,Sing,Masc)    (N,Sing,Masc)    (Adj,Sing,Masc)    (Adv)

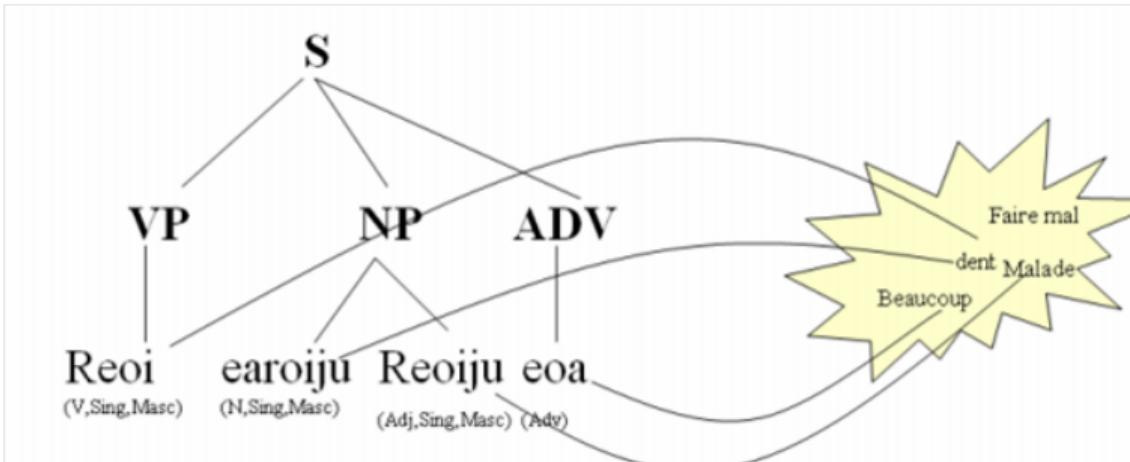
Reoiajr oj earoij reoa o eo ao aeoij aeroij aoeir eoaj.

# De quoi ça parle ?



Reoiajr oj | earoij | reoa | o eo ao | aeoi oj aeroij | aoeir | eoaj.

# De quoi ça parle ?



Reoiajr oj earoij reoa o eo ao aeoij oj aeroij aoeir eoaj.

## Pour quoi faire ?

- ▶ traduction automatique
- ▶ recherche d'informations
- ▶ indexation
- ▶ traitement de courriels
- ▶ veille
- ▶ agents conversationnels
- ▶ ...

# Associations savantes



## Acteurs majeurs



Google

amazon



Microsoft

## (quelques) Entreprises de TAL en France



## Marché (tel que vu il y a quelques années)

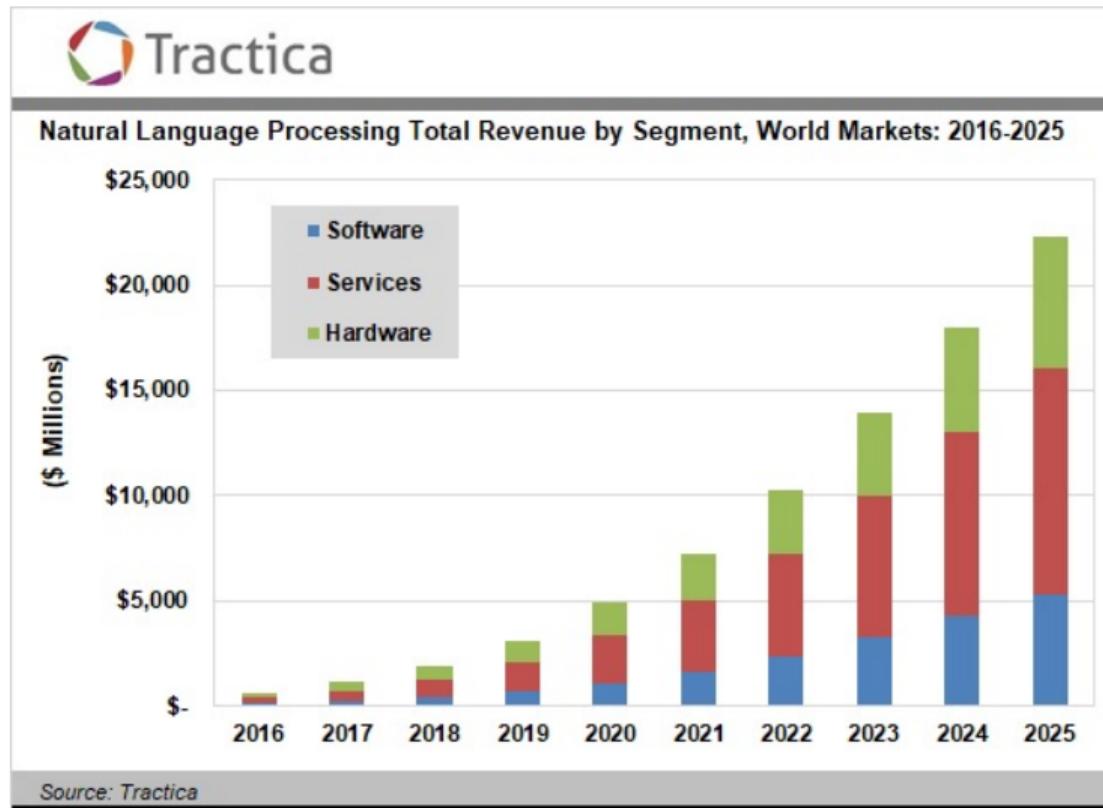
*"The NLP market size, which is about \$7.5B today, is estimated to grow to \$16B by 2021."*

<https://www.techemergence.com/natural-language-processing-business-applications/>

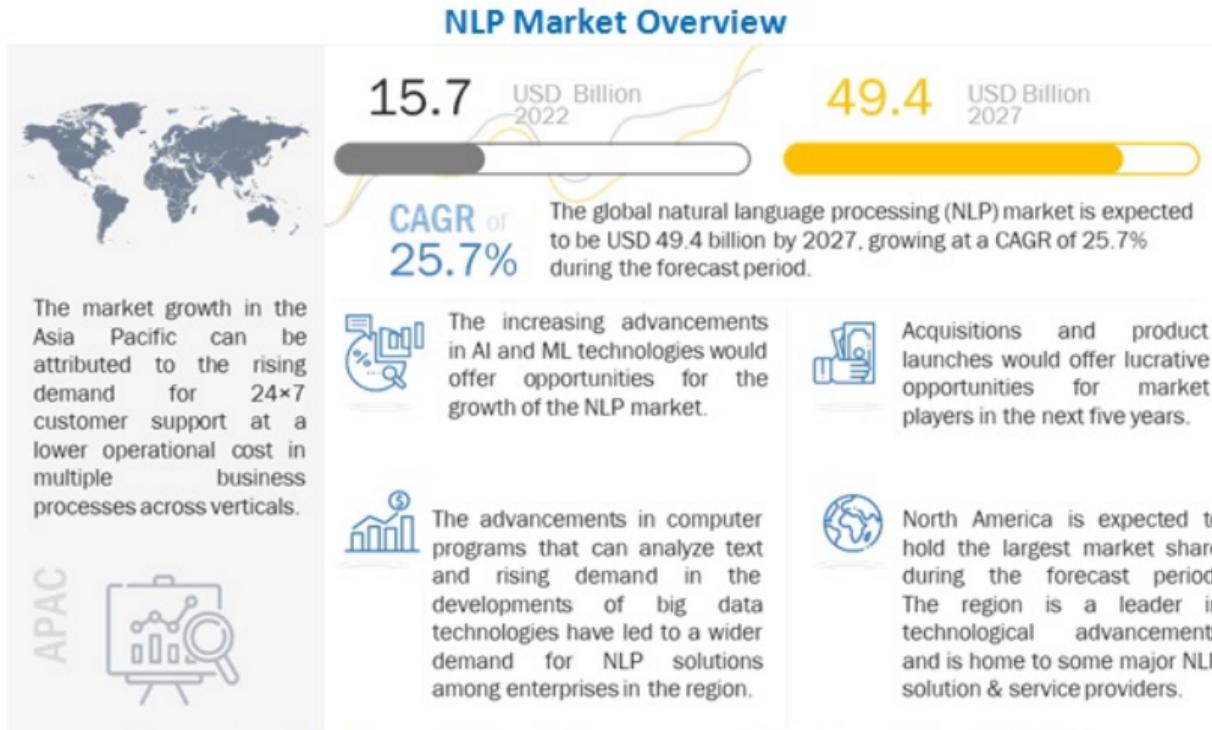
*"The next few years should see AI technology increase even more, with the global AI market expected to push \$60 billion by 2025"*

<https://www.forbes.com/sites/forbestechcouncil/2018/07/02/what-is-natural-language-processing-and-what-is-it-used-for/#7ef6bf675d71>

# Prévisions de chiffre d'affaire (il y a quelques années)

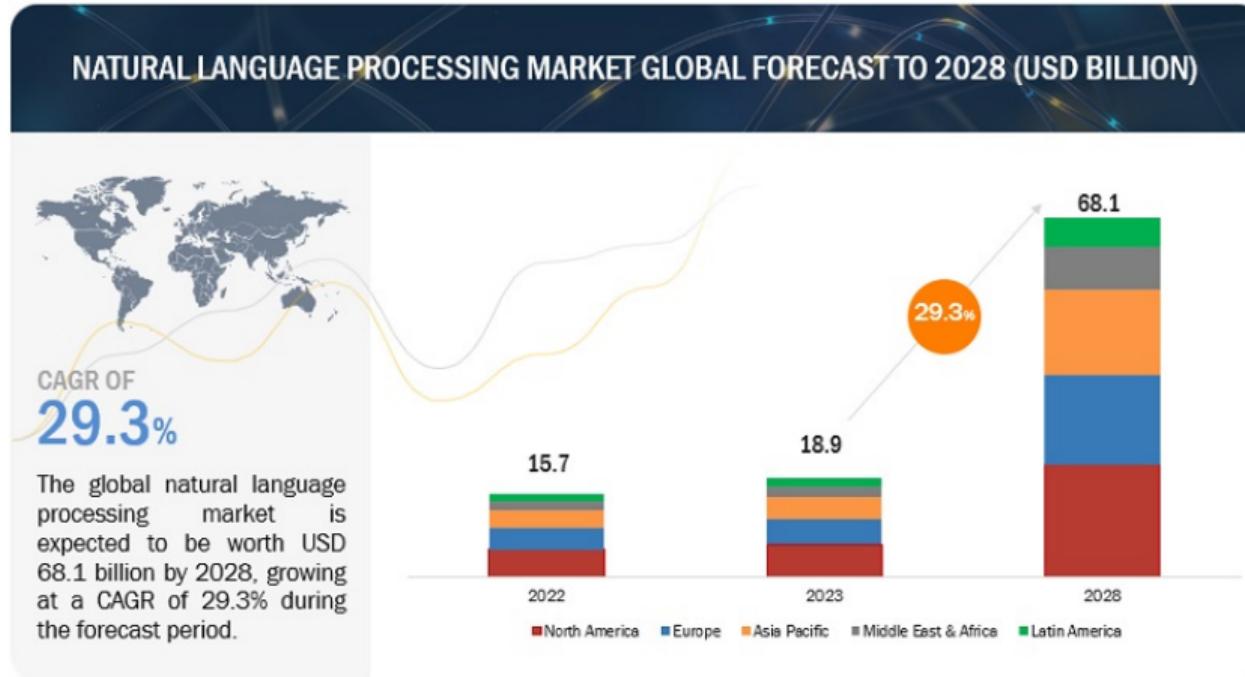


# Prévisions (il y a 2 ans)



Source: Secondary Research, Expert Interviews, and MarketsandMarkets Analysis

# Prévisions aujourd'hui (2024)



<https://www.marketsandmarkets.com/Market-Reports/natural-language-processing-nlp-825.html>

# TAL et linguistique computationnelle

Linguistique computationnelle :

- ▶ modéliser une activité langagière pour comprendre comment fonctionne la langue

vs

Traitement automatique des langues :

- ▶ reproduire l'activité langagière humaine pour optimiser les performances des systèmes

Sources

Introduction

Ambiguïté à tous les étages

Exemples

Les grandes étapes du TAL *old school*

Des solutions

Rappel sur l'analyse syntaxique

Pour finir

## Le TAL : pas si simple...

- ▶ *La mousse aux fraises est sur la table de l'avocat.*

## Le TAL : pas si simple...

- ▶ *La mousse aux fraises est sur la table de l'avocat.*
- ▶ *L'omelette au lard est parti sans payer !*

## Le TAL : pas si simple...

- ▶ *La mousse aux fraises est sur la table de l'avocat.*
- ▶ *L'omelette au lard est parti sans payer !*
- ▶ *Le bus a renversé un passant...*

## Le TAL : pas si simple...

- ▶ *La mousse aux fraises est sur la table de l'avocat.*
- ▶ *L'omelette au lard est parti sans payer !*
- ▶ *Le bus a renversé un passant...  
▶ ... je l'ai entendu freiner.*

## Le TAL : pas si simple...

- ▶ *La mousse aux fraises est sur la table de l'avocat.*
- ▶ *L'omelette au lard est parti sans payer !*
- ▶ *Le bus a renversé un passant...
  - ▶ ... je l'ai entendu freiner.
  - ▶ ... je l'ai entendu crier.*

## Le TAL : pas si simple...

- ▶ *La mousse aux fraises est sur la table de l'avocat.*
- ▶ *L'omelette au lard est parti sans payer !*
- ▶ *Le bus a renversé un passant...
  - ▶ ... je l'ai entendu freiner.
  - ▶ ... je l'ai entendu crier.*
- ▶ *Le professeur a envoyé l'élève chez le proviseur...*

## Le TAL : pas si simple...

- ▶ *La mousse aux fraises est sur la table de l'avocat.*
- ▶ *L'omelette au lard est parti sans payer !*
- ▶ *Le bus a renversé un passant...
  - ▶ ... je l'ai entendu freiner.
  - ▶ ... je l'ai entendu crier.*
- ▶ *Le professeur a envoyé l'élève chez le proviseur...
  - ▶ ... il faisait trop de bruit.*

## Le TAL : pas si simple...

- ▶ *La mousse aux fraises est sur la table de l'avocat.*
- ▶ *L'omelette au lard est parti sans payer !*
- ▶ *Le bus a renversé un passant...*
  - ▶ ... je l'ai entendu freiner.
  - ▶ ... je l'ai entendu crier.
- ▶ *Le professeur a envoyé l'élève chez le proviseur...*
  - ▶ ... il faisait trop de bruit.
  - ▶ ... il était excédé.

## Le TAL : pas si simple...

- ▶ *La mousse aux fraises est sur la table de l'avocat.*
- ▶ *L'omelette au lard est parti sans payer !*
- ▶ *Le bus a renversé un passant...*
  - ▶ ... je l'ai entendu freiner.
  - ▶ ... je l'ai entendu crier.
- ▶ *Le professeur a envoyé l'élève chez le proviseur...*
  - ▶ ... il faisait trop de bruit.
  - ▶ ... il était excédé.
  - ▶ ... il l'avait convoqué.

## Le TAL : pas si simple...

- ▶ *La mousse aux fraises est sur la table de l'avocat.*
- ▶ *L'omelette au lard est parti sans payer !*
- ▶ *Le bus a renversé un passant...
  - ▶ ... je l'ai entendu freiner.
  - ▶ ... je l'ai entendu crier.*
- ▶ *Le professeur a envoyé l'élève chez le proviseur...
  - ▶ ... il faisait trop de bruit.
  - ▶ ... il était excédé.
  - ▶ ... il l'avait convoqué.*

→ **ambiguités** pour les systèmes et/ou pour les humains

## Le découpage en « mots » ou *tokenization*

- ▶ *l'arbre*

## Le découpage en « mots » ou *tokenization*

- ▶ *l'arbre*
- ▶ *aujourd'hui*

## L'analyse morphologique

la *porte*

- *porte* +Nf + Sg

# L'analyse morphologique

la *porte*

- ▶ *porte* +Nf + Sg
- ▶ *porte* +VT + 1/3P + Sg

## L'analyse syntaxique

*Jean regarde un homme sur la colline avec un télescope.*

- ▶ **Qui** est sur la colline ?
- ▶ **Qui** a un télescope ?

## L'analyse sémantique

*Tous les hommes aiment une femme.*

→ **Chaque** homme aime une femme ou **tous** les hommes aiment la même femme ?

## Sources

### Introduction

#### Ambiguïté à tous les étages

### Des solutions

Techniques utilisées

Identification de la langue

Segmentations

Analyse morphologique

Désambiguïsation

Petite parenthèse sur le tagging

### Rappel sur l'analyse syntaxique

### Pour finir

# Des techniques variées

- ▶ systèmes à base de règles
  - ▶ définies par l'humain (linguistes/info-linguistes)
  - ▶ entrées manuellement
- ▶ systèmes basés sur les données
  - ▶ apprentissage supervisé ou non supervisé
  - ▶ à partir d'exemples (rédigés et/ou annotés par des humains)
  - ▶ algorithmes (pensés par des humains)

# Quelles techniques dans l'industrie ?



1

Allez sur [wooclap.com](https://wooclap.com)

2

Entrez le code d'événement dans le bandeau supérieur

Activer les réponses par SMS

Code d'événement  
**MUEFXM**

# Sources

## Introduction

Ambiguïté à tous les étages

## Des solutions

Techniques utilisées

**Identification de la langue**

Segmentations

Analyse morphologique

Désambiguïsation

Petite parenthèse sur le tagging

## Rappel sur l'analyse syntaxique

## Pour finir

## Exercice : identifier la langue d'un texte

Groupes de 3

### Exercice

Trouver au moins **2** algorithmes permettant d'identifier la langue d'un texte

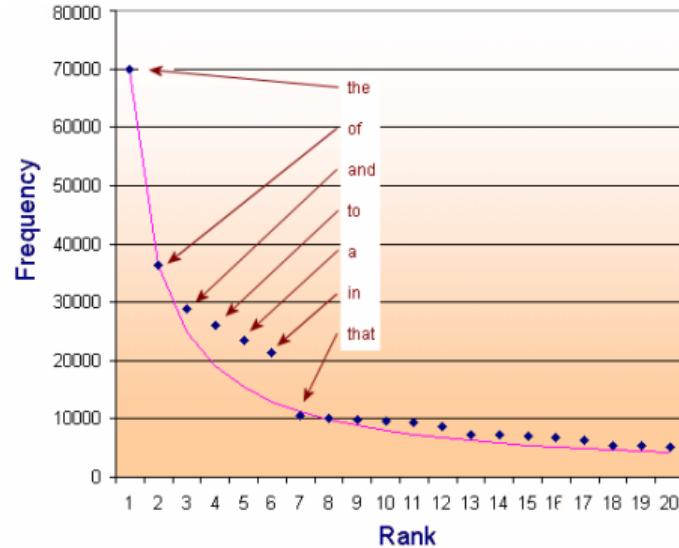
# Conseil : connaître les langues et leurs caractéristiques

## Loi de Zipf :

- étant donné un corpus d'énoncés en langue naturelle, la fréquence d'un mot est **inversement proportionnelle** à son rang dans la table de fréquence.
- ex. : “the” représente près de 7 % du *Brown Corpus* alors que près de la moitié du vocabulaire total du corpus sont des **hapax**.
- Seuls 135 éléments de vocabulaire sont nécessaires pour couvrir la moitié du *Brown Corpus*

Rang	Mot	Fréquence
1	<i>the</i>	69 970
2	<i>of</i>	36 410
3	<i>and</i>	28 854
20	<i>I</i>	5 180

## Loi de Zipf sur le *Brown corpus*



## Identifier la langue : solution 1

Méthode des *shortwords* :

- ▶ BD de « mots outils » (mots grammaticaux, « petits » mots)
- ▶ Compter les occurrences de ces mots outils dans le texte
- ▶ Comparer avec les BD

## Identifier la langue : solution 2

Méthode des *trigrammes* :

- ▶ Rechercher la probabilité qu'un caractère  $C_i$  apparaisse après les deux précédents dans la langue  $I$  :

$$P(C_i | C_{i-1} : C_{i-2}, I)$$

- ▶ Calculer la probabilité résultante pour chaque langue, pour l'ensemble du texte :

$$\prod_{i=1}^{i=n} P(C_i | C_{i-1} : C_{i-2}, I)$$

# Limitations

- ▶ Longueur du texte (5 mots mini.)
- ▶ textes multilingues :

## Natural Language Processing at hand

Many software applications use, create or transform textual data, be them word processors, online reservation applications, electronic messaging, document processing, on-line or off-line watch....

With GramLab, these applications can be enhanced with NLP functions: spell checking, automatic recognition of dates or places, automatic update of email contact, enhance full text search...

Aproxed : Nouvelle avancée dans l'analyse de contenus et la valorisation de l'information...

L'Aproxed et le Consortium

- ▶ et aussi :
  - ▶ Barack Obama → français
  - ▶ Barack Obama and Nicolas Sarkozy → anglais
  - ▶ camping caravaning, trekking

## Identifier la langue : solutions 3 et 4

- ▶ Essayer d'identifier l'encodage
- ▶ Regarder les méta-données

## Google language identifier

<https://translate.google.com/?sl=auto>

## Parenthèse : à propos des mots outils (*stopwords*)

À quoi servent-ils ? Qu'en faire ?

Python3

```
import nltk  
from nltk.corpus import stopwords  
  
nltk.download('stopwords')  
print(stopwords.words('english'))
```

<https://www.geeksforgeeks.org/removing-stop-words-nltk-python/>

## Ce que vous enlevez quand vous enlevez les mots outils

108	some
109	such
110	no
111	nor
112	not
113	only
114	own
115	same
116	so
117	than
118	too

# Sources

## Introduction

Ambiguïté à tous les étages

## Des solutions

Techniques utilisées

Identification de la langue

### Segmentations

Analyse morphologique

Désambiguisation

Petite parenthèse sur le tagging

## Rappel sur l'analyse syntaxique

## Pour finir

## Segmentations : exercice

*Marchepied à plate forme sécurisée 2.41m hauteur travail max. 3.16m 5 marches et garde corps fixe PROFORT TUBESCA*

### Exercice

Segmenter (manuellement) la phrase en mots

# Segmentations : approche simpl(ist)e

## 1. Segmentation en phrases (texte brut) :

- ▶ Se termine par une ponctuation de fin de phrase (. ; ? !)
- ▶ La phrase suivante commence par une espace ou un retour à la ligne suivi d'une majuscule
- ▶ Les ... forment une ponctuation unique

## 2. Segmentation en mots (tokenization) :

- ▶ Séparateurs de mots : espace, CR, tab, apostrophes (avec le mot), ponctuations (considérés comme des mots), les . ne sont pas des séparateurs
- ▶ Les tirets sont des séparateurs s'ils sont suivis d'un pronom (vient-il), et la séquence -t doit être effacée dans certains cas (*envoie-t-elle*, césure de fin de phrase)
- ▶ Appliquer des transformations locales : Au, du, cet, qu', l', m'....

## Segmentation en phrases : plus loin

- ▶ en allemand ?
- ▶ en thaï ?

## Tokenization : plus loin

*Je veux bien que tu viennes*

→ Conserver l'ambiguïté

## Tokenization : encore plus loin

- ▶ en allemand ?
- ▶ en chinois ?

# Segmentations : les questions

Définition théorique du segment :

- ▶ Qu'est-ce qu'un **mot** ?
  - ▶ Plate forme, marche-pied marche pied marchepied
  - ▶ Les marchands du temple : du → de le ?
- ▶ Qu'est-ce qu'une **phrase** ?
  - ▶ Ah ?
  - ▶ - ?

Ambiguïté des séparateurs :

- ▶ Microsoft.com, 23.5, ..., C.G.T.
- ▶ Aujourd'hui, 9'8, jusqu'à
- ▶ C&A, R&D
- ▶ Sépara-
- ▶ teur

# Parenthèse sur la tokenization dans les grands modèles de langues

Ici sur l'interface de test du tokenizer d'OpenAI (H. de Mazancourt)

Many English words map to one token, but some don't, as *indivisible*.

Mais en français, il y a beaucoup plus de tokens pour un mot.

Auch im Deutsch gibt es viel mehr Tokens für einen Wort.

<https://www.linkedin.com/in/mazancourt/>

# Sources

## Introduction

### Ambiguïté à tous les étages

## Des solutions

Techniques utilisées

Identification de la langue

Segmentations

**Analyse morphologique**

Désambiguïsation

Petite parenthèse sur le tagging

## Rappel sur l'analyse syntaxique

## Pour finir

## Morphologie : exercice

*Orange, au cours du matin, a permis la prise de bénéfices. Nous avions fait des paris audacieux sur cette valeur qui est montée dès l'ouverture du CO*

Article, Nom, Adverbe, Verbe, Adjectif, Pronom, Nom propre, Ppassé, Préposition, Interjection

### Exercice

Utiliser les étiquettes proposées pour réaliser une analyse morpho-syntaxique du texte

## Morphologie : étiquettes

- ▶ Orange [Nom propre, Adjectif, Nom]
- ▶ au [Préposition, Article]
- ▶ cours [Nom]
- ▶ au cours du [Préposition]
- ▶ du [Ppassé, Nom]
- ▶ matin [interjection, Adverbe, Nom]
- ▶ a [Préposition, Nom]
- ▶ permis [Ppassé, Nom, Adjectif]
- ▶ la [Article, Pronom, Nom]
- ▶ prise [Nom, Ppassé]
- ▶ de [Préposition]
- ▶ bénéfices [Nom]

## Morphologie : lemmatisation

- ▶ Orange → orange — Orange
- ▶ au → à + le
- ▶ cours → cours
- ▶ du → de + le
- ▶ matin → matin
- ▶ a → avoir
- ▶ permis → permis — permettre
- ▶ la → le
- ▶ prise → prise — prendre
- ▶ de → de
- ▶ bénéfices → bénéfice

# Morphologie : solutions en extension

```
<lexicalEntry id="championne_1">
    <feminineVariantOf target="champion_1">champion</feminineVariantOf>
    <formSet>
        <lemmatizedForm>
            <orthography>championne</orthography>
            <grammaticalCategory>commonNoun</grammaticalCategory>
            <grammaticalGender>feminine</grammaticalGender>
        </lemmatizedForm>
        <inflectedForm>
            <orthography>championne</orthography>
            <grammaticalNumber>singular</grammaticalNumber>
        </inflectedForm>
        <inflectedForm>
            <orthography>championnes</orthography>
            <grammaticalNumber>plural</grammaticalNumber>
        </inflectedForm>
    </formSet>
    <originatingEntry target="TLF">CHAMPION, ONNE, subst.</originatingEntry>
</lexicalEntry>
```

## Morphologie : solutions ( ?) en extension

Stockage ?

Morphalou 2 = **160 Mo**

## Morphologie : solutions ( ?) en extension

Temps d'accès ?

# Morphologie : la composition



<https://www.youtube.com/watch?v=gG62zay3kck>

# Morphologie : l'agglutination

Exemples en finnois :

- ▶ *Järjestelmällinen* : organisé

## Morphologie : l'agglutination

Exemples en finnois :

- ▶ *Järjestelmällinen* : organisé
- ▶ *järjestelmällistetty* : conçu pour être organisé

## Morphologie : l'agglutination

Exemples en finnois :

- ▶ *Järjestelmällinen* : organisé
- ▶ *järjestelmällistetty* : conçu pour être organisé
- ▶ *epäjärjestelmällistetty* : désorganisé ou pas conçu pour être organisé

# Morphologie : l'agglutination

Exemples en finnois :

- ▶ *Järjestelmällinen* : organisé
- ▶ *järjestelmällistetty* : conçu pour être organisé
- ▶ *epäjärjestelmällistetty* : désorganisé ou pas conçu pour être organisé
- ▶ *Epäjärjestelmällistämättömyy* : négation et substantivation

# Morphologie : l'agglutination

Exemples en finnois :

- ▶ *Järjestelmällinen* : organisé
- ▶ *järjestelmällistetty* : conçu pour être organisé
- ▶ *epäjärjestelmällistetty* : désorganisé ou pas conçu pour être organisé
- ▶ *Epäjärjestelmällistämättömyy* : négation et substantivation
- ▶ *Epäjärjestelmällistytämättömyydellänsä* : l'objet dénoté par le substantif appartient à quelqu'un (génitif)

# Morphologie : l'agglutination

Exemples en finnois :

- ▶ *Järjestelmällinen* : organisé
- ▶ *järjestelmällistetty* : conçu pour être organisé
- ▶ *epäjärjestelmällistetty* : désorganisé ou pas conçu pour être organisé
- ▶ *Epäjärjestelmällistämättömyy* : négation et substantivation
- ▶ *Epäjärjestelmällistyttämättömyydyllänsä* : l'objet dénoté par le substantif appartient à quelqu'un (génitif)
- ▶ *Epäjärjestelmällistyttämättömyydyllänsäkään* : nouvelle négation

# Morphologie : l'agglutination

Exemples en finnois :

- ▶ *Järjestelmällinen* : organisé
- ▶ *järjestelmällistetty* : conçu pour être organisé
- ▶ *epäjärjestelmällistetty* : désorganisé ou pas conçu pour être organisé
- ▶ *Epäjärjestelmällistämättömyy* : négation et substantivation
- ▶ *Epäjärjestelmällistyttämättömyy dellänsä* : l'objet dénoté par le substantif appartient à quelqu'un (génitif)
- ▶ *Epäjärjestelmällistyttämättömyy dellänsäkään* : nouvelle négation
- ▶ *epäjärjestelmällistyttämättömyy dellänsäkäänkö* : ajout d'un suffixe dénotant l'interrogation

# Morphologie : l'agglutination

Exemples en finnois :

- ▶ *Järjestelmällinen* : organisé
- ▶ *järjestelmällistetty* : conçu pour être organisé
- ▶ *epäjärjestelmällistetty* : désorganisé ou pas conçu pour être organisé
- ▶ *Epäjärjestelmällistämättömyy* : négation et substantivation
- ▶ *Epäjärjestelmällistyttämättömyydyllänsä* : l'objet dénoté par le substantif appartient à quelqu'un (génitif)
- ▶ *Epäjärjestelmällistyttämättömyydyllänsäkään* : nouvelle négation
- ▶ *epäjärjestelmällistyttämättömyydyllänsäkäänkö* : ajout d'un suffixe dénotant l'interrogation
- ▶ *epäjärjestelmällistyttämättömyydyllänsäkäänköhän* : ajout d'une emphase (c'est moi qui ...)

# Morphologie : l'agglutination

Exemples en finnois :

- ▶ *Järjestelmällinen* : organisé
- ▶ *järjestelmällistetty* : conçu pour être organisé
- ▶ *epäjärjestelmällistetty* : désorganisé ou pas conçu pour être organisé
- ▶ *Epäjärjestelmällistämättömyy* : négation et substantivation
- ▶ *Epäjärjestelmällistyttämättömyydyllänsä* : l'objet dénoté par le substantif appartient à quelqu'un (génitif)
- ▶ *Epäjärjestelmällistyttämättömyydyllänsäkään* : nouvelle négation
- ▶ *epäjärjestelmällistyttämättömyydyllänsäkäänkö* : ajout d'un suffixe dénotant l'interrogation
- ▶ *epäjärjestelmällistyttämättömyydyllänsäkäänköhän* : ajout d'une emphase (c'est moi qui ...)
- ▶ *epäjärjestelmällistyttämättömyydylläänsäkäänköhän* :

# Morphologie : l'agglutination

Exemples en finnois :

- ▶ *Järjestelmällinen* : organisé
- ▶ *järjestelmällistetty* : conçu pour être organisé
- ▶ *epäjärjestelmällistetty* : désorganisé ou pas conçu pour être organisé
- ▶ *Epäjärjestelmällistämättömyy* : négation et substantivation
- ▶ *Epäjärjestelmällistyttämättömyydyllänsä* : l'objet dénoté par le substantif appartient à quelqu'un (génitif)
- ▶ *Epäjärjestelmällistyttämättömyydyllänsäkään* : nouvelle négation
- ▶ *epäjärjestelmällistyttämättömyydyllänsäkäänkö* : ajout d'un suffixe dénotant l'interrogation
- ▶ *epäjärjestelmällistyttämättömyydyllänsäkäänköhän* : ajout d'une emphase (c'est moi qui ...)
- ▶ *epäjärjestelmällistyttämättömyydylläänsäkäänköhän* :

*The reverse of the reverse of something abstract that is made to be unorganised, which is owned by someone, and is one of the two or more (possibly similar) attributes that have a negative atmosphere or lack of something, and we doubt if it is it at the same time that we ensure that it truly is.*

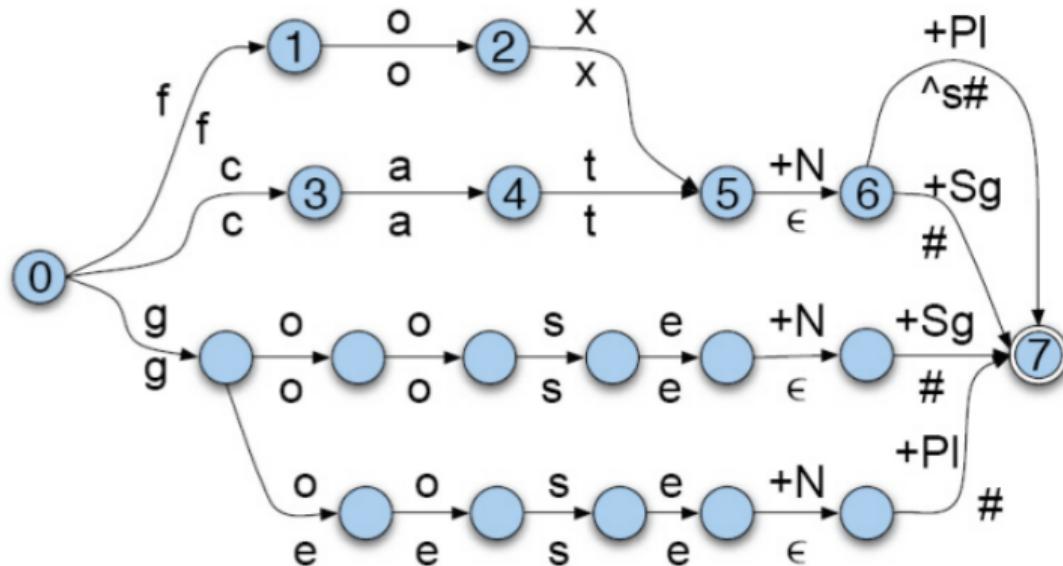
# Morphologie : solutions en intension

Quelle solution pour :

- ▶ optimiser le stockage
- ▶ permettre un accès rapide
- ▶ dans les deux sens :
  - ▶ leave+NNS → leaves
  - ▶ leaves → leave+NNS

Structure de données **et** accès ?

# Morphologie : solutions en intension



## Morphologie : transducteurs à états finis (FST)

XFST (Xerox FST) :

```
[ [l e a v e %+VBZ .x. l e a v e s] |
[l e a v e %+VB .x. l e a v e] |
[l e a v e %+VBG .x. l e a v i n g] |
[l e a v e %+VBD .x. l e f t] |
[l e a v e %+NN .x. l e a v e] |
[l e a v e %+NNS .x. l e a v e s] |
[l e a f %+NNS .x. l e a v e s ] |
[l e f t %+JJ .x. l e f t] ]
```

APPLY DOWN> leave+VBD

left

APPLY UP> leaves

leave+NNS

leave+VBZ

leaf+NNS

# Morphologie : transducteurs à états finis (FST)

Lexique du français en FST :

- ▶ taille une fois compilé : **800 Ko** (français), 500 Ko (anglais)
  - ▶ *lookup* immédiat
  - ▶ gestion des langues agglutinantes, des cycles, ...
- importance des **ressources langagières**

# Sources

## Introduction

### Ambiguïté à tous les étages

## Des solutions

Techniques utilisées

Identification de la langue

Segmentations

Analyse morphologique

Désambiguïsation

Petite parenthèse sur le tagging

## Rappel sur l'analyse syntaxique

## Pour finir

## Désambiguïsation : le problème

permis → permettre+V — permis+N :

- ▶ un mot = plusieurs analyses
- ▶ mots inconnus

→ Comment faire ? Qu'utilise l'humain ?

## Désambiguïsation : le problème

permis → permettre+V — permis+N :

- ▶ un mot = plusieurs analyses
- ▶ mots inconnus

→ Comment faire ? Qu'utilise l'humain ?

*Il m'a permis d'habiter chez lui.*

Solutions ?

## Désambiguïsation : modèles de Markov

Chaîne de Markov [1913] :

- ▶ une variable ne dépend que du présent
- ▶ la probabilité d'une variable ne dépend que de celle la précédent
  - ▶ pas de mémoire
  - ▶ homogène (ne dépend pas de la place dans la chaîne)

## Désambiguïsation : HMM

- ▶ Etant donnée une suite de symboles :
  - ▶ Orange [Nom propre, Adjectif, Nom], au cours du [Préposition], matin [interjection, Adverbe, Nom], a [Préposition, Nom], permis [Ppassé, Nom, Adjectif], la [Article, Pronom, Nom], prise [Nom, Ppassé], de [Préposition], bénéfices [Nom]
- ▶ On considère la probabilité qu'un symbole se trouve après deux autres symboles
- ▶ On prend la plus grande

# Sources

## Introduction

### Ambiguïté à tous les étages

## Des solutions

Techniques utilisées

Identification de la langue

Segmentations

Analyse morphologique

Désambiguïsation

Petite parenthèse sur le tagging

## Rappel sur l'analyse syntaxique

## Pour finir

## *Tagging* : étiquettagement morpho-syntaxique

tokenization

+

analyse morphologique + lemmatisation

+

désambiguïsation

## *Tagging : exemple*

### **Exercice**

Montrez les différentes étapes et possibilités de tagging de :  
*Le chef d'orchestre donne le la.*

## Lemmatisation vs stemming

Le *stemming* c'est la racinisation :

imaginait → imagin

La lemmatisation c'est retrouver l'entrée de dictionnaire :

imaginait → imaginer

# Qualité de l'étiquetage morpho-syntaxique

ou *POS tagging*

Exactitude (*accuracy* en anglais, à ne pas confondre avec la précision) :

- ▶ TreeTagger (1994) : 95,7 % [Allauzen and Bonneau-Maynard, 2008]
- ▶ MElt (2010) : près de 98 % [Denis and Sagot, 2010]



Quelle différence concrète ?

# Qualité de l'étiquetage morpho-syntaxique

ou *POS tagging*

Exactitude (*accuracy* en anglais, à ne pas confondre avec la précision) :

- ▶ TreeTagger (1994) : 95,7 % [Allauzen and Bonneau-Maynard, 2008]
- ▶ MELT (2010) : près de 98 % [Denis and Sagot, 2010]



Quelle différence concrète ?

96 % d'exactitude, environ 10 mots par phrase  
→ sur 10 phrases, un mot mal étiqueté dans 4 phrases

98 % d'exactitude → **deux fois moins** d'erreurs

Sources

Introduction

Ambiguïté à tous les étages

Des solutions

## Rappel sur l'analyse syntaxique

L'analyse syntaxique en constituants

L'analyse syntaxique en dépendances

Pour finir

## Analyse syntaxique : le problème

Un énoncé est une suite ordonnée de mots :

- ▶ quels mots ?
- ▶ **dans quel(s) ordre(s) ?**
- ▶ pour quel sens ?
- ▶ dans quelles langues ?

## Analyse syntaxique : les approches

Deux types d'approches en TAL :

- ▶ analyse en constituants
- ▶ analyse en dépendances

Sources

Introduction

Ambiguïté à tous les étages

Des solutions

Rappel sur l'analyse syntaxique

L'analyse syntaxique en constituants

L'analyse syntaxique en dépendances

Pour finir

## La constituance (Antoine Gautier)

Une phrase n'est pas une simple concaténation d'unités minimales du type  $A + B + C + D$ , qui serait équivalente à  $B + A + D + C$

Observez :

- (1) a. Virginie mange une salade.  
≠ Une salade mange Virginie.
- b. Joey est (stupide et gentil) → Joey est beau.
- c. (((Paul) mange) (une salade))

→ La phrase est une **hiérarchie** et non une **concaténation** d'éléments.

## Justifier la notion de constituant (Antoine Gautier)

On observe cependant que certaines suites de mots fonctionnent comme des mots uniques. Autrement dit :

**Ils ont la même distribution qu'un mot unique.**

- (2) a. **Le frère de Marie** dormait profondément.  
b. **Paul** dormait profondément.

**Ils sont déplaçables en bloc, mais pas séparément :**

- (3) Il dormait profondément, **le frère de Marie**.  
a. \***Il de Marie** dormait profondément, **le frère**.  
b. \***Le frère** dormait profondément **de Marie**.

**Ils peuvent constituer des énoncés autonomes :**

- Qui dormait profondément ?  
— Le frère de Marie.

**Ils peuvent être conjoints :**

Joey est (bête) → Joey est (bête et gentil)

## Têtes et catégories (Antoine Gautier)

La plupart des syntagmes (ou groupes) s'organisent autour d'un mot central qui détermine le reste de sa constitution, la **tête du syntagme**. La catégorie du syntagme se déduit alors de la catégorie de sa tête.

Nom	SN	[Le <b>frère</b> de Marie] dort profondément.
Préposition	SPrep	J'ai discuté [ <b>avec</b> le frère de Marie].
Verbe	SV	Je [ <b>connais</b> le frère de Marie].
Adjectif	SAdj	Je suis [très <b>mécontent</b> de mon travail].
Adverbe	SAdv	[ <b>Malheureusement</b> pour vous], il va pleuvoir.

## Analyse syntaxique : les constituants

Vous connaissez sans doute les catégories suivantes :

- ▶ GN, GV, GP (équivalentes à SN, SV, SP)

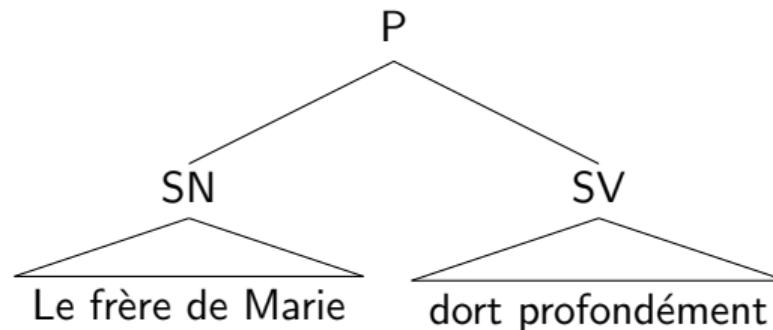
Si je vous demande d'analyser grammaticalement la phrase suivante, vous savez le faire :

*Jean aime la belle Marie.*

# La représentation des constituants (Antoine Gautier)

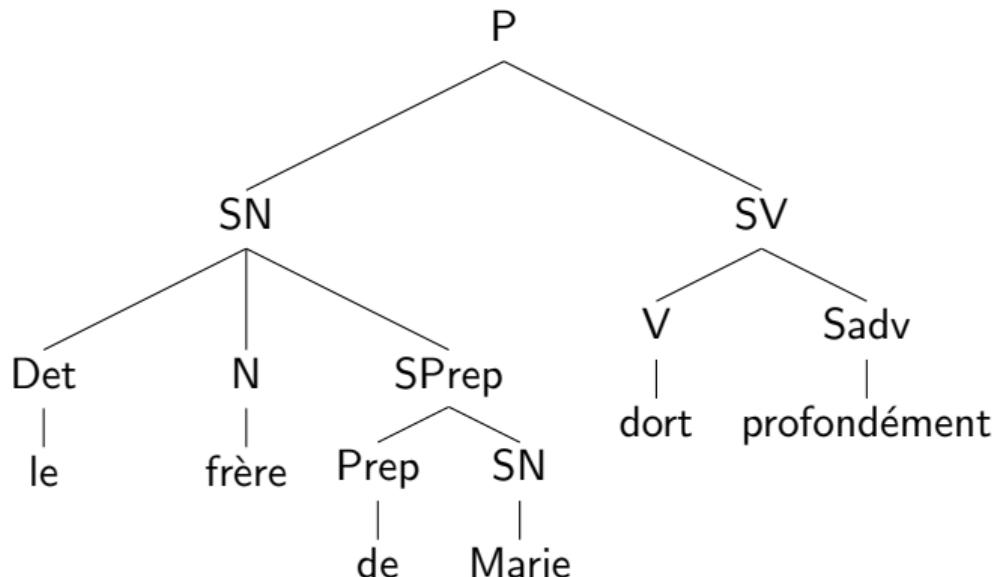
Deux représentations équivalentes :

- ▶ Crochets : [SN le frère de Marie] [SV dort profondément].
- ▶ Arbre :

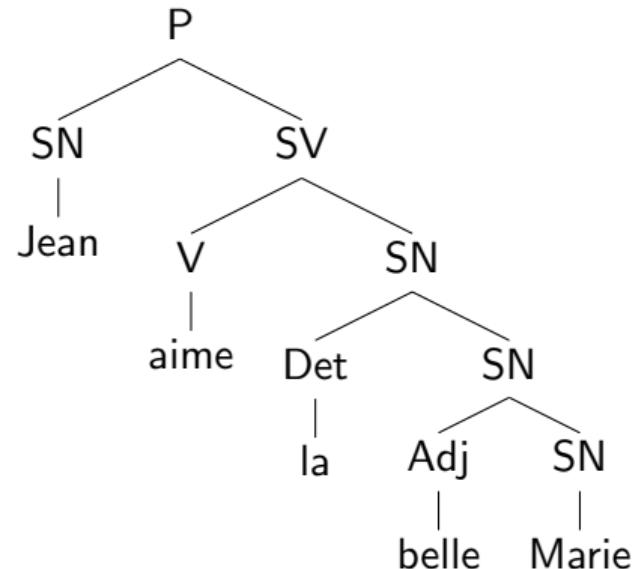


# Analyse en Constituants Immédiats (Antoine Gautier)

Faire un découpage systématique de l'énoncé en syntagmes et en mots, jusqu'à ce qu'il ne reste plus que des mots.

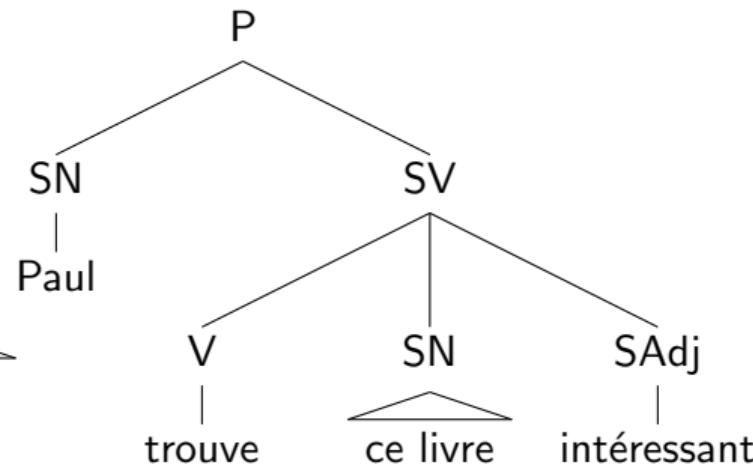
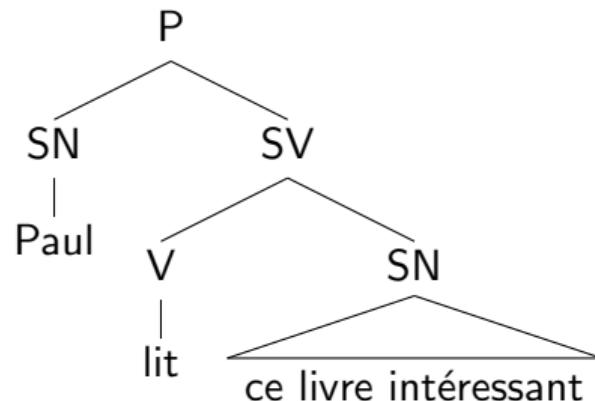


Dans notre cas : *Jean aime la belle Marie*



# L'ambiguïté structurale (Antoine Gautier)

La même séquence de mots peut être un syntagme dans une phrase, mais pas dans une autre.



Sources

Introduction

Ambiguïté à tous les étages

Des solutions

## Rappel sur l'analyse syntaxique

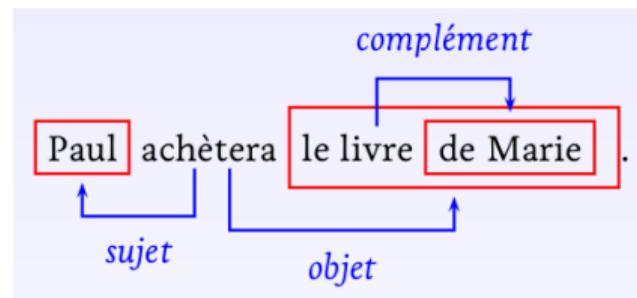
L'analyse syntaxique en constituants

L'analyse syntaxique en dépendances

Pour finir

# Les fonctions syntaxiques

Les fonctions syntaxiques sont des **relations** entre un mot et un constituant qui dépend syntaxiquement de ce mot.



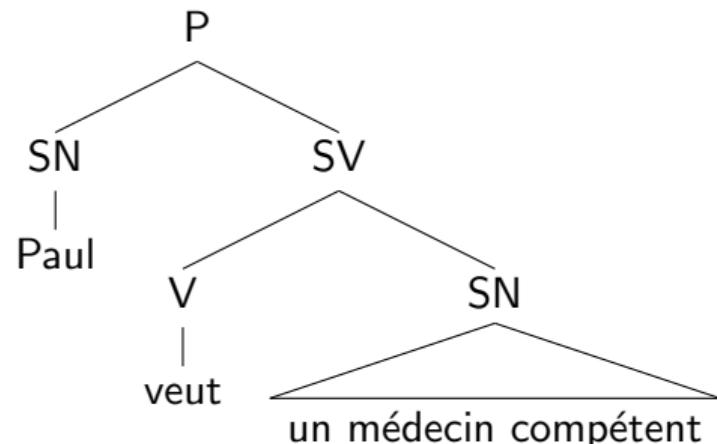
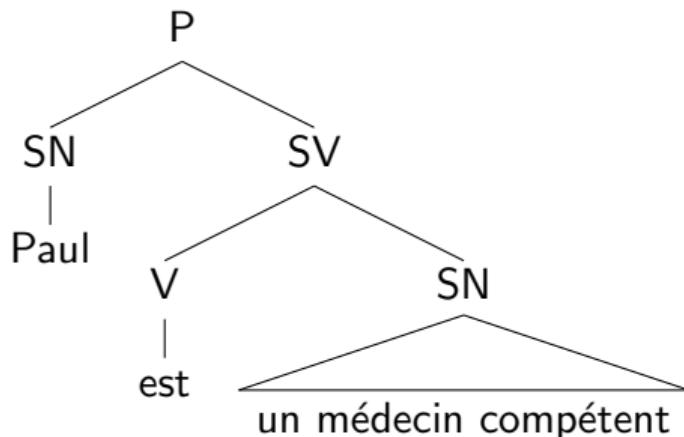
Les différentes fonctions se caractérisent par des propriétés syntaxiques :

- ▶ En français, seul le **sujet** s'accorde en nombre et en personne avec le verbe.
- ▶ En français, seul l'**objet direct** d'une phrase active peut être transformé en **sujet** au passif.

## Fonctions vs. Positions

### (4) Même position, différentes fonctions

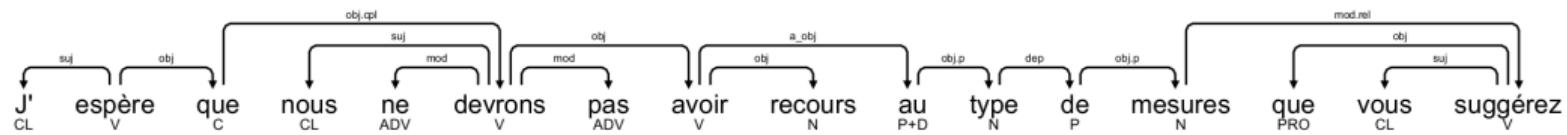
- a. Paul veut un **médecin compétent**..... *Objet*
- b. Paul est **un médecin compétent**..... *Attribut*



### (5) Même fonction, différentes positions

- a. Je veux **un gâteau au chocolat**..... *Objet*
- b. **Que** voulez-vous ? ..... *Objet*

# Analyse syntaxique en dépendances : un exemple



Sources

Introduction

Ambiguïté à tous les étages

Des solutions

Rappel sur l'analyse syntaxique

Pour finir

CQFR : Ce Qu'il Faut Retenir

Bibliographie



- ▶ l'ambiguïté est partout, parfois même pour l'humain
- ▶ les principales étapes du TAL
- ▶ les solutions trouvées (les principes)
- ▶ la loi de Zipf
- ▶ les rappels de syntaxe

- 
- Allauzen, A. and Bonneau-Maynard, H. (2008).  
Training and evaluation of pos taggers on the french multitag corpus.  
In Nicoletta Calzolari (Conference Chair), Khalid Choukri, B. M. J. M. J. O. S. P. D. T., editor, Proceedings of the Sixth International Conference on Language Resources and Evaluation (LREC'08), Marrakech, Morocco. European Language Resources Association (ELRA).  
[http ://www.lrec-conf.org/proceedings/lrec2008/](http://www.lrec-conf.org/proceedings/lrec2008/).
- 
- Denis, P. and Sagot, B. (2010).  
Exploitation d'une ressource lexicale pour la construction d'un étiqueteur morphosyntaxique état-de-l'art du français.  
In Traitement Automatique des Langues Naturelles : TALN 2010, Montréal, Canada.