

# ***Cours de Traitement Automatique du Langage***

***DI5 – 2021-22***

# Au programme

---



- **Séances de cours puis TP**

- CM : 6 x 2h (JYR + Thomas Bourquard)
- Travaux pratiques : 6 x 2h (D Maurel + JYR)
  - ➔ TP classiques au début puis mise en oeuvre d'un système TAL + rapport
- Avec UniTex d'abord (D. Maurel)
- Avec Python (jupyter Notebook ou autre) ➔ **installation préalable requise**
- Celene incrémentalement...

- **Evaluation**

- CR des Travaux Pratiques (seul ou en binome)

- **Contenu**

- Introduction : Organisation et objectifs (pédagogiques) + définitions
- Pré-traitements et traitements basique
- Modèles de langages
- Etiquetage (syntaxique) de séquences et Word embedding
- Analyses sémantiques : sens des mots, coréférences, sentiment analysis, ...

# Les sources - Quelques cours similaires

---

## Les cours suivants ont largement servi pour la création de ce support

- Cours de TAL. 2021. JY Antoine, Agata Savary. Master BDMA de Blois; Université de Tours.
- Cours de TAL. 2021, ARIES A., Ecole nationale Supérieure d'Informatique d'Alger
- Cours Speech and Language Processing. de Jurafsky, D. and Martin, J. H; 2020.  
<https://web.stanford.edu/~jurafsky/slp3/>
- CS224n: Natural Language Processing with Deep Learning. Stanford university (2020).  
<https://web.stanford.edu/class/cs224n/>

## Plus légèrement :

- Livre Deep Learning for Natural Language Processing - Creating Neural Networks with Python, Palash Goyal, Sumit Pandey, Karan Jain, Apress
- CS388: Natural Language Processing (2018). University of Texas.  
<https://www.cs.utexas.edu/~mooney/cs388/>
- Natural Language Processing S21 (2020). Carnegie Mellon University.  
<http://demo.clab.cs.cmu.edu/NLP/>
- CSE 517: Natural Language Processing (2020). University of Washington.  
<https://courses.cs.washington.edu/courses/cse517/>
- CS 294-5: Statistical Natural Language Processing (2005). University of Berkely.  
<https://people.eecs.berkeley.edu/~klein/cs294-5/index.html>
- CS 5340/6340: Natural Language Processing (2020). University of Utah.  
<https://my.eng.utah.edu/~cs5340/schedule.html>

# Si besoin...

---

- Si vous avez des difficultés :
  - Internet est vaste : soyez autonomes (et critique) ...
  - Références à des ouvrages / travaux tout au long du cours
- N'hésitez pas à demander, venir discuter :
  - [ramel@univ-tours.fr](mailto:ramel@univ-tours.fr) - Bureau 2° étage
- Quelques conseils
  - Ne surtout pas commencer à travailler à la dernière minute
  - Travaillez en plusieurs fois - Se laisser du temps pour réfléchir aux problèmes
  - Du temps est disponible durant les cours et TP - Profitez en !
  - Evitez de trop surfer le web, réfléchissez avant ...

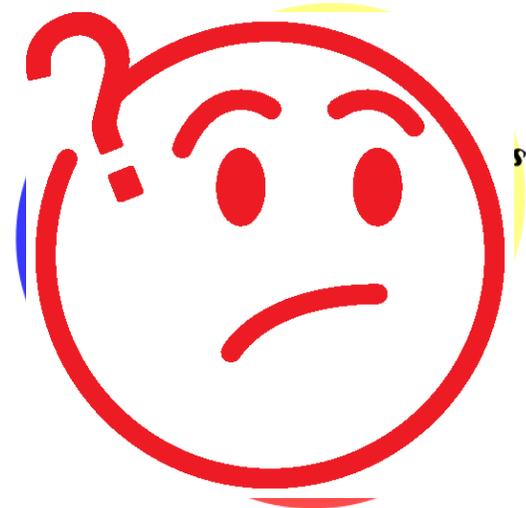
---

# **Introduction**

# Introduction - Définition

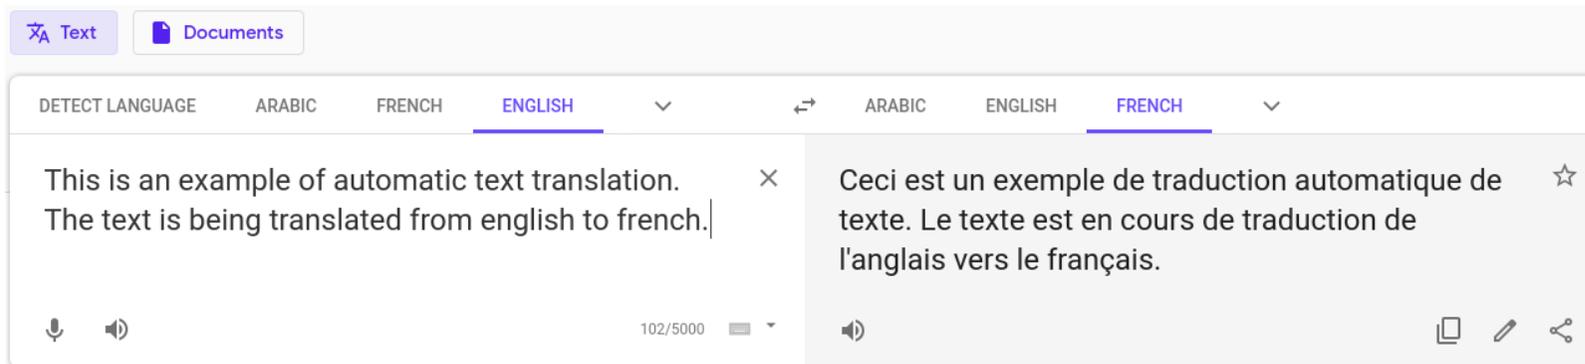
---

- TALN: Traitement automatique du langage naturel (NLP)
- TAL: Traitement automatique des langues
  
- Définition : l'ensemble des méthodes permettant de rendre le langage humain accessible aux ordinateurs.
- Un domaine multidisciplinaire
  - Linguistique: Etude du langage
  - Informatique: Traitement automatique de l'information
  - Intelligence artificielle: Ensemble de théories et de techniques mises en œuvre en vue de réaliser des machines capables de simuler l'intelligence humaine



# Introduction – Applications du TAL

- Traduction automatique → Google Translate, DeepL



- Résumé automatique → Esummarizer

There are broadly two types of extractive summarization tasks depending on what the summarization program focuses on. The first is generic summarization, which focuses on obtaining a generic summary or abstract of the collection (whether documents, or sets of images, or videos, news stories etc.). The second is query relevant summarization, sometimes called query-based summarization, which summarizes objects specific to a query. Summarization systems are able to create both query relevant text summaries and generic machine-generated summaries depending on what the user needs.

An example of a summarization problem is document summarization, which attempts to automatically produce an abstract from a given document. Sometimes one might be interested in generating a summary from a single source document, while others can use multiple source documents (for example, a cluster of articles on the same topic). This problem is called multi-document summarization. A related application is summarizing news articles. Imagine a system, which automatically pulls together news articles on a given topic (from the web), and concisely represents the latest news as a summary.

## Summary

The first is generic summarization, which focuses on obtaining a generic summary or abstract of the collection (whether documents, or sets of images, or videos, news stories etc.).

The second is query relevant summarization, sometimes called query-based summarization, which summarizes objects specific to a query.

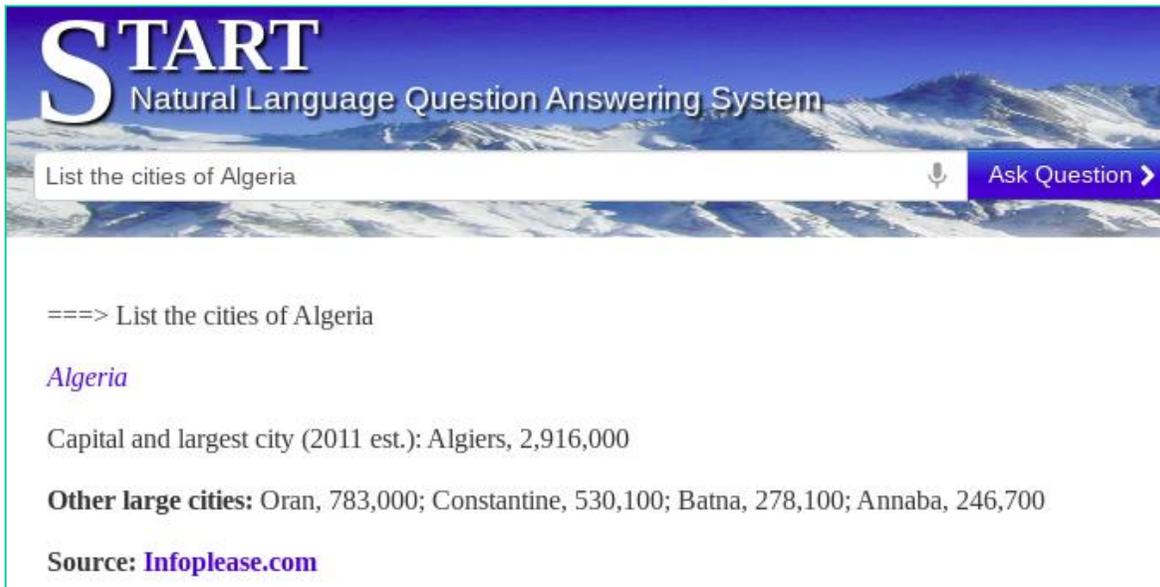
An example of a summarization problem is document summarization, which attempts to automatically produce an abstract from a given document.

It consists in selecting a representative set of images from a larger set of images.[4] A summary in this context is useful to show the most representative images of results in an image collection exploration system.

Save

# Introduction – Applications du TAL

- ChatBot, Question/Réponse → système Start



**START**  
Natural Language Question Answering System

List the cities of Algeria   [Ask Question >](#)


====> List the cities of Algeria

*Algeria*

Capital and largest city (2011 est.): Algiers, 2,916,000

**Other large cities:** Oran, 783,000; Constantine, 530,100; Batna, 278,100; Annaba, 246,700

Source: [Infoplease.com](http://Infoplease.com)



**cleverbot**

34142 people talking

Are you human?

*Yes of course.*

Are you sure?

*Think so.*

Where are you from?

*United States.* [share!](#)

say to cleverbot.. 

# Introduction – Applications du TAL

---

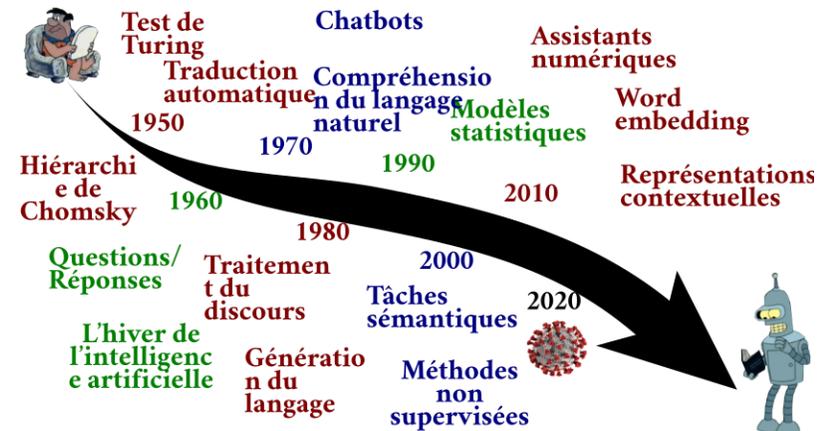
## Et toutes les autres....

- Recherche d'informations, fouille de texte, recommandations,...
  - Connaissance du marché (Market intelligence) : surveiller les concurrents afin de se tenir au courant des événements liés à l'industrie.
  - Marketing (pub,...),
  - Veille de marché / d'opinion (fake news, ...),
  - Santé (analyse de CR, génération de rapports, ...),
  - RH (CV, ...), éducation (correction auto, ...)
- Analyse de sentiments (réseaux sociaux)
  - Surveillance de la réputation : on utilise l'analyse des sentiments pour savoir si les clients sont heureux avec des produits ou non.

# Introduction - Histoire

## Naissance de l'IA : Les années 1950

- 1951 : Shannon a exploité les modèles probabilistes des langages naturels [Shannon, 1951].
- 1954 : Expérimentation IBM pour traduire automatiquement 60 phrases du russe vers l'anglais.
- 1956 : Chomsky a développé les modèles formels de syntaxe.
- 1958 : Luhn (IBM) a expérimenté sur le résumé automatique de texte [Luhn, 1958]



## L'Age d'or de l'IA : Les années 1960

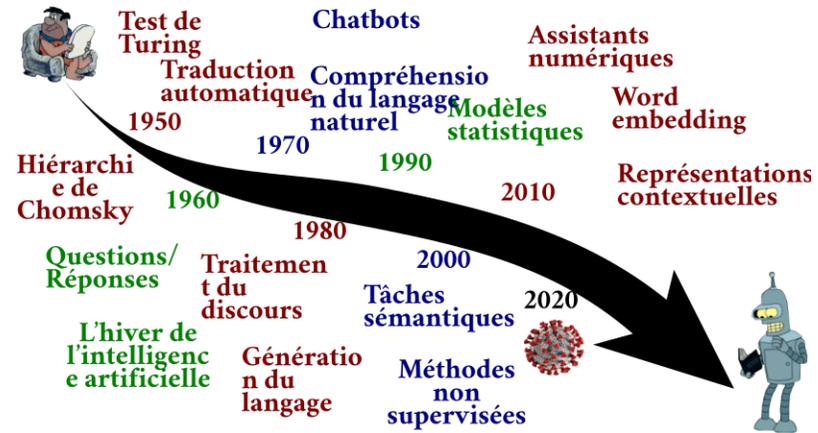
- 1961 : Développement du premier analyseur syntaxique automatique à U.Penn. [Joshi, 1961, Harris, 1962]
- 1964 : Weizenbaum a mis au point ELIZA, une simulation d'un psychothérapeute au sein du laboratoire MIT AI.
- 1964 : Bobrow a mis au point STUDENT, conçu pour lire et résoudre des problèmes d'algèbre de lycée à partir d'analyse de texte [Bobrow, 1964]
- 1967 : Brown corpus, le premier corpus électronique

→ Analyse probabiliste et syntaxique de texte

# Introduction - Histoire

## Hiver de l'IA : Les années 1970 / 80

- 1971 Le MIT développe SHRDLU, un programme de compréhension du langage naturel [Winograd71]
- 1972 Colby (Stanford) crée PARRY un chatbot qui simule une personne avec la schizophrénie
- 1975 MARGIE un système qui fait des inférences et des paraphrases à partir des phrases en utilisant la représentation conceptuelle du langage.
- 1975 DRAGON, un système pour la reconnaissance de la parole en utilisant les HMM [Baker, 1975].
- 1980 KL-One, représentation de connaissance pour le traitement de la syntaxe et la sémantique [Bobrow and Webber, 1980]
- 1986 TRUMP, analyseur de langage en utilisant une base lexicale [Jacobs, 1986]
- 1987 MU, Conférence sur l'extraction des données financée par DARPA
- 1988 Utilisation des HMM dans l'étiquetage morpho-syntaxique [Church, 1988]



→ Solutions symboliques sur le traitement du discours et génération de phrases

# Introduction - Histoire

## Printemps de l'IA : Les années 1990-2000

- 1990 Une approche statistique pour la traduction automatique [Brown et al., 1990]
- 1993 Pen Tree-bank, un corpus annoté de l'anglais [Marcus et al., 1993]
- 1995 Wordnet, une base lexicale pour l'anglais [Miller, 1995]
- 1996 SPATTER, un analyseur lexical statistique basé sur les arbres de décision [Magerman, 1996]

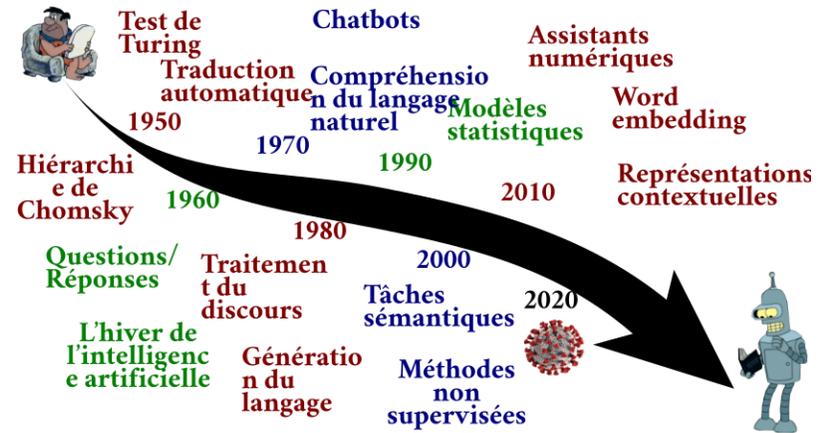
### → Popularité des méthodes statistiques, génération de corpus

- 2003 Les modèles probabilistes de langues en utilisant les RN [Bengio et al., 2003]
- 2006 Watson : un système de question/réponse IBM

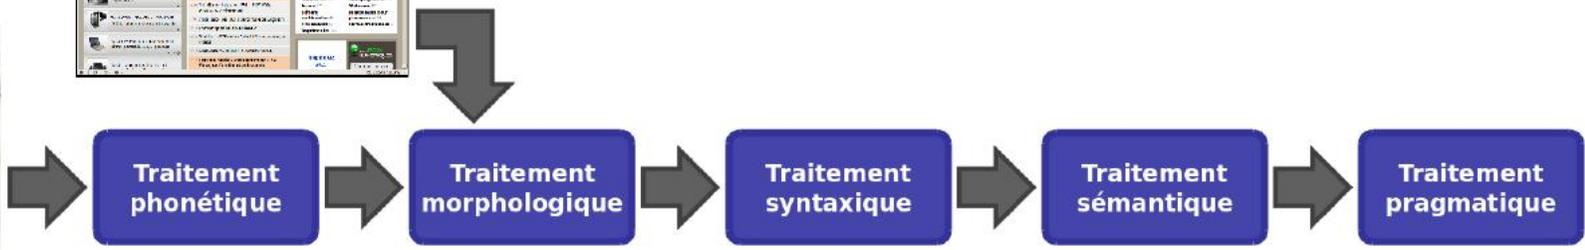
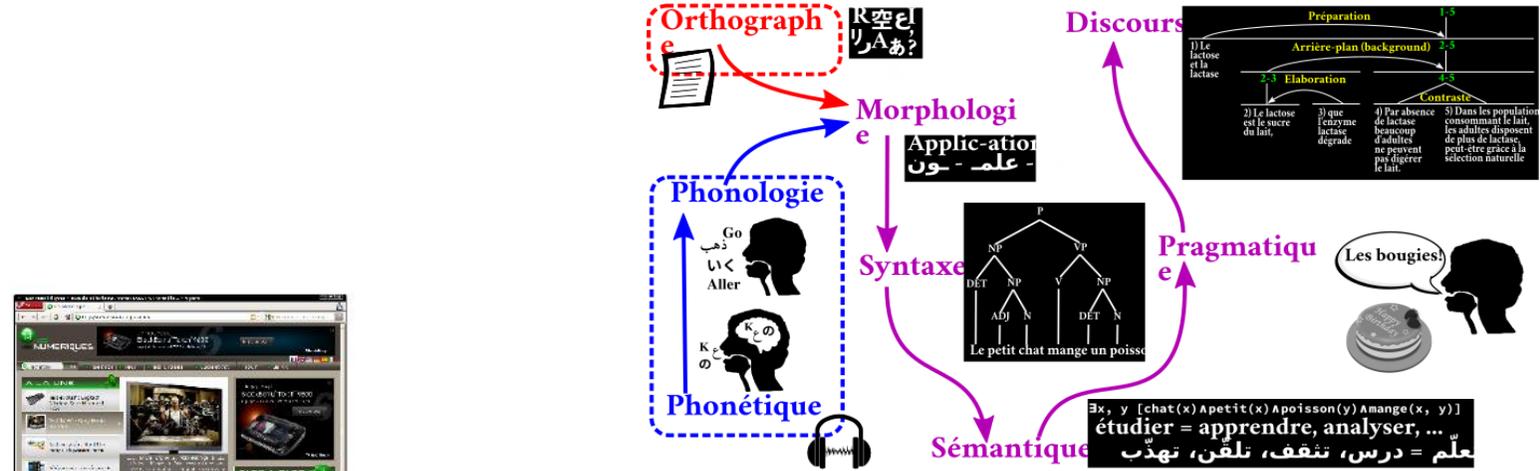
### → Utilisation de l'apprentissage non supervisé et semi-supervisé comme alternatives à l'apprentissage purement supervisé

- 2011 Sortie de Siri (Apple), suivi par Alexa (Amazon, 2014) et Google Assistant (2016)
- 2014 Word embedding [Lebret and Collobert, 2014]
- 2018 Apparition des représentations contextuelles (des modèles de langue pré-entraînés) : ULMfit (fast.ai) [Howard and Ruder, 2018], ELMO (AllenNLP) [Peters et al., 2018], GPT (OpenAI) [Radford et al., 2018], BERT (Google) [Devlin et al., 2018], XLM (Facebook) [Lample and Conneau, 2019]

### → Déplacement du focus sur les tâches sémantiques



# Introduction - Niveaux de traitement d'une langue



# Introduction - Niveaux de traitement

## Phonétique, phonologie et orthographe : Phonologie

- Etude des sons ou phonemes d'une langue donnée
- s'intéresse aux sons en tant qu'éléments d'un système

### Exemple : le phonème /r/

- En français, le *r* peut se prononcer (en phonétique) : roulé [r], grasseyé [ʀ], ou normal (parisien) [ʁ]
- Il est transcrit toujours de la même façon, exemple *rat* /rat/
- En arabe, on trouve les consonnes ر [r] et غ [ɣ] qui ont deux phonèmes différents : /r/ et /ɣ/ respectivement. Exemple, غريب /ɣæri:b/ (étranger)

# Introduction - Niveaux de traitement

## Phonétique, phonologie et orthographe : Orthographe

Etude des types et de la forme des lemmes / système d'écriture (selon le graphème)

- Logo-graphique: logo-grammes, chacun est un graphème unique notant un lemme (mot).
  - Exemple : Kanji (Japonais) : 日, 本, 語
- Syllabique : symboles, chacun représente un syllabe (son vocalisé).
  - Exemple, Hiragana (Japonais) : る, た, め, の;
  - Katakana (Japonais) : セ, ク;
- Alphabétique : lettres, chacune d'elles représente un phonème.
  - Exemple, Le latin : A, B, C, etc.
  - L'arabe : ه, ت, ب
- Ponctuation
- Règles d'écriture

THE INTERNATIONAL PHONETIC ALPHABET (revised to 2018)

CONSONANTS (PULMONIC)

© 2018 IPA

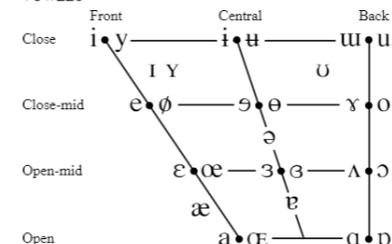
	Bilabial	Labiodental	Dental	Alveolar	Postalveolar	Retroflex	Palatal	Velar	Uvular	Pharyngeal	Glottal
Plosive	p b			t d		ʈ ɖ	c ɟ	k ɡ	q ɢ		ʔ
Nasal	m	ɱ		n		ɳ	ɲ	ŋ	ɴ		
Trill				r					ʀ		
Tap or Flap				ɾ		ɽ					
Fricative	ɸ β	f v	θ ð	s z	ʃ ʒ	ʂ ʐ	ç ʝ	x ɣ	χ ʁ	ħ ʕ	h ɦ
Lateral fricative				ɬ ɮ							
Approximant		ʋ		ɹ		ɻ	j	ɰ			
Lateral approximant				l		ɭ	ʎ	ʟ			

Symbols to the right in a cell are voiced, to the left are voiceless. Shaded areas denote articulations judged impossible.

CONSONANTS (NON-PULMONIC)

Clicks	Voiced implosives	Ejectives
◌ ɸ Bilabial	ɓ Bilabial	◌ ʼ Examples:
◌ ɱ Dental	ɗ Dental/alveolar	◌ ɸ Bilabial
◌ ʄ (Post)alveolar	ɟ Palatal	◌ ɖ Dental/alveolar
◌ ɟ Palatoalveolar	ɠ Velar	◌ ɟ Velar
◌ ɠ Alveolar lateral	ɢ Uvular	◌ ɠ Alveolar fricative

VOWELS



# Introduction - Niveaux de traitement

## Morphologie et syntaxe : Morphologie

- Etude de la formation des mots, y compris la façon dont les nouveaux mots sont inventés dans les différentes langues
- Etude de la façon dont les formes des mots varient en fonction de leurs utilisations dans les phrases.
- **Morphème**: la plus petite unité de langage qui a sa propre signification.
  - Exemple, les noms propres, les suffixes, etc.
- **Lexème**: un ensemble de toutes les formes grammaticales qui ont le même sens.
- **Lemme**: un mot choisi parmi ces formes pour représenter le **lexème**.
- Les **catégories grammaticales** : classe ouverte (adjectif, nom, verbe) et classe fermée (adverbe, article, conjonction, interjection, préposition, pronom)



# Introduction - Niveaux de traitement

---

## Typologie morphologique des langues

- Langues isolantes/analytiques: chaque mot est constitué d'un et d'un seul morphème
  - Les modifications morphologiques sont peu nombreuses, voire absentes.
  - Parmi ces langues : mandarin, vietnamien, thai, khmer, etc..
  - Exemple : 四个男孩 → “quatre garçons” (lit.“quatre [entité de] masculin enfant”)
- Les langues flexionnelles/synthétiques: les mots sont formés d'une racine en plus de morphèmes supplémentaires
- Langues agglutinantes: les morphèmes sont toujours clairement différenciables phonétiquement l'un de l'autre.
  - Parmi ces langues : finnois, turc, japonais, langues berbères, etc..
  - Exemple → 行く,行きます
- Langues fusionnelles: il n'est pas toujours aisé de distinguer les morphèmes de la racine, ou les morphèmes les uns des autres.
  - Parmi ces langues : anglais, français, arabe, etc.
  - Exemple: foot, feet

# Introduction - Niveaux de traitement

---

## Morphologie flexionnelle

- Formation de mots sans changer de catégorie ou créer de nouveaux lexèmes
- Modification de la forme des lexèmes afin qu'ils s'adaptent à différents contextes grammaticaux
- Flexion: déclinaison ou conjugaison
- Affixation : préfixe, infixe, suffixe → étudiant (masculin-singulier),étudiantes (feminin-pluriel)
- Nombre: singulier, pluriel
- Personne: première, deuxième, troisième, etc.
- Genre: masculin, féminin, neutre, commun
- Temps: passé, présent, futur
  
- Voix: active, moyenne, passive, etc.
- Polarité: affirmative, négative
- Politesse: informelle, formelle, etc.



# Introduction - Niveaux de traitement

---

## Morphologie dérivationnelle

- Formation de mots en changeant de catégorie (jouer, joueur) ou en créant de nouveaux lexèmes (connecter, déconnecter)
- Affixation : en utilisant des préfixes, infixes et/ou suffixes.
  - Exemple : happy (ADJ), unhappy (ADJ), unhappiness (N)
- Composition : en fusionnant des mots dans un seul
  - Exemple : porter(V) + manteau (N) = porte-manteau (N); wind (N), mill (N), windmill (N)
- Conversion : en changeant la catégorie grammaticale d'un mot sans aucune modification
  - Exemple : orange (fruit, N), orange (couleur, ADJ); visiter (V), visite (N); fish (N), to fish (V)
- Troncation :
  - Exemple : bibliographie, biblio, information, info



# Introduction - Niveaux de traitement

## Syntaxe

- Structure des phrases : comment les mots se combinent pour former des phrases
- Catégories grammaticales ou parties du discours (verbe, Nom, Adjectif, etc) des mots de la phrase (étiquetage morpho-syntaxique).
- Ordre des mots selon le sujet (S), le Verbe (V) et l'Objet (O)
- Fonctions grammaticales : Sujet, COD, COI, etc.

### Exemple SOV [japonais]

カリムさんは日本語を勉強します。

### Exemple SVO [français]

Karim apprend le français.

### Exemple VSO [arabe]

يتعلم كريم العربية .

Ordre	Proportion	Exemples
SOV	44.78%	japonais, latin, tamoul, basque, ourdou, grec ancien, bengali, hindi, sanskrit, persan, coréen
SVO	41.79%	français, mandarin, russe, anglais, haoussa, italien, malais (langue), espagnol, thaï
VSO	9.20%	irlandais, arabe, hébreu biblique, philippin, langues touarègues, gallois
VOS	2.99%	malgache, baure, car (langue)
OVS	1.24 %	apalai, hixkaryana, klingon (langue)

# Introduction - Niveaux de traitement

---

## Syntaxe – grammaire de constituants

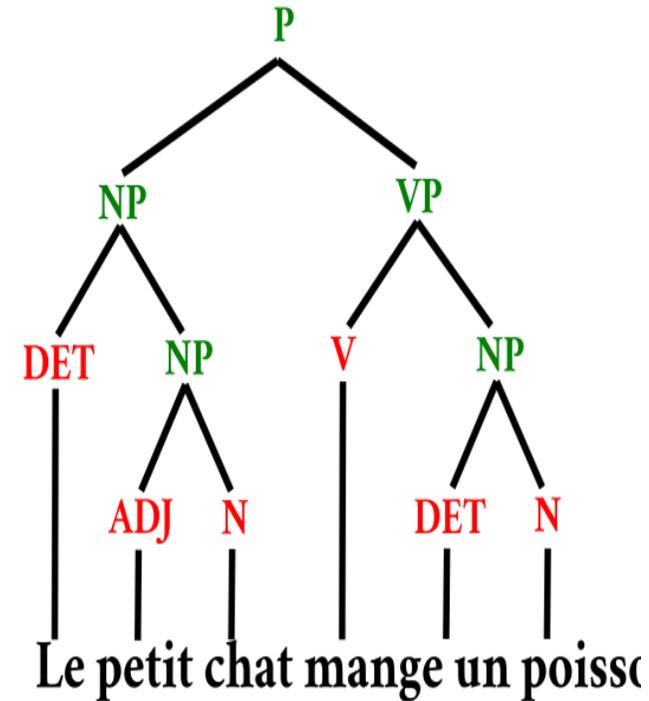
- Une phrase est constituée de plusieurs syntagmes qui sont constitués des mots et d'autres syntagmes.
- Un **syntagme contient un noyau qui est l'élément central**
- Selon le noyau, le syntagme peut être : nominal (NP), adjectival (AP), verbal (VP) ou prépositionnel (PP)
- Le système formel le plus utilisé pour modéliser la structure des constituants d'une phrase est la **grammaire hors-contexte**

# Introduction - Niveaux de traitement

## Syntaxe – grammaire de constituants

- La grammaire qui a généré cet arbre syntaxique peut être écrite :
  - $P \rightarrow NP VP$
  - $NP \rightarrow DET NP'$
  - $NP \rightarrow DET N$
  - $NP' \rightarrow ADJ N$
  - $VP \rightarrow V NP$

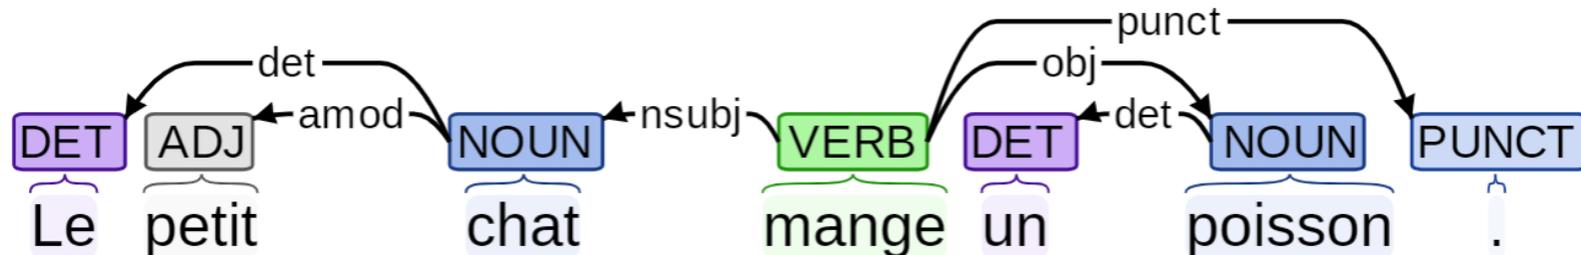
*Rem : La deuxième règle n'ai pas écrite ( $NP \rightarrow DET NP$ ) sinon on peut avoir plusieurs déterminants pour un nom*



# Introduction - Niveaux de traitement

## Syntaxe – grammaire de dépendances

- Grammaire de dépendances: un ensemble des relations binaires entre les mots de la phrase
- La structure syntaxique est décrite en terme de mots et pas des syntagmes
- Les relations peuvent être : un sujet nominal (nsubj), un objet (obj), un modificateur d'adjectif (amod), déterminant (det), etc



Un exemple de dépendances générée par <https://corenlp.run/>

# Introduction - Niveaux de traitement

---

## Sémantique

- Etude du sens dans les langages
  - Sémantique lexicale: sens des mots
  - Sémantique propositionnelle: sens des phrases

### Un exemple de différents sens

Le terme **poulet** a plusieurs sens selon la phrase  
(<https://fr.wiktionary.org/wiki/poulet>)

- J'écoute les piaulements des **poulets**. *“Petit du coq et de la poule, plus âgé que le poussin, avant d'être adulte.”*
- Je mange du **poulet**. *“Viande de jeune poule ou jeune coq.”*
- Mon petit **poulet**. *“Terme d'affection, que l'on adresse généralement aux enfants.”*

# Introduction - Niveaux de traitement

## Sémantique : Le sens des mots

- Dans les systèmes logographiques, un graphème représente un ou plusieurs sens (en général, avec plusieurs prononciations)

川 (rivière), 山(montagne),  
音(son, bruit) + 樂(musique, confort, facilité) =音樂(musique)

- Un mot peut avoir plusieurs sens (Polysémie)
  - Le sens d'un mot est construit d'un ensemble de “primitives sémantiques”
  - a l'aide de relations entre morphèmes (un réseau de sens)
- Sème : une unité minimale de signification (trait sémantique minimal)
- Sémème : un faisceau de sèmes correspondant a une unité lexicale

### Un exemple de l'analyse sémique

Mot/Sème	animé	domestique	félin
Chat	+	+	+
Lion	+	-	+
Chien	+	+	-

# Introduction - Niveaux de traitement

---

## Sémantique : Le sens des mots

- Synonyme : si on substitue un mot par un autre dans une phrase sans changer le sens, donc les mots sont des synonymes
- Antonyme : le sens opposé. Les deux mots doivent exprimer deux valeurs d'une même propriété.
  - Exemple, grand et petit expriment la propriété taille
- Hyponyme : un mot ayant un sens plus spécifique qu'un autre.
  - Exemple, chat est l'hyponyme de félin.
- Hyperonyme : un mot avec un sens plus générique.
  - Exemple, félin est l'hyperonyme de chat

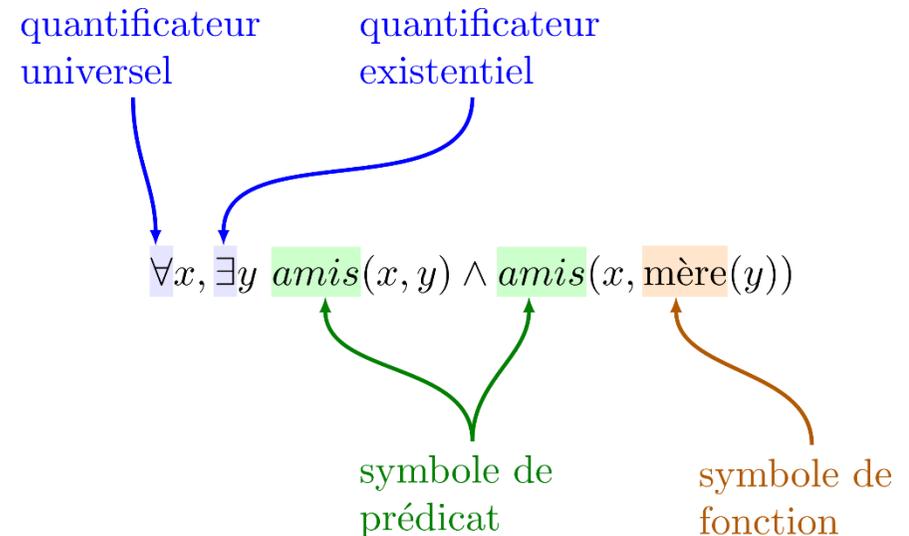
# Introduction - Niveaux de traitement

## Sémantique : Le sens des propositions

- Souvent représentée par une formule de logique du premier ordre (calcul de prédicat)

### Logique des prédicats:

- Constante : une entité spécifique du monde (Pierre, Polytech)
- Variable : réfère a une entité anonyme :  $x, y$ .
- Fonction : résulte d'une entité spécifique sans avoir besoin de créer une nouvelle constante  
Ex.  $\text{locationOf}(\text{Polytech})$
- Prédicat : une relation entre des entités  
Ex.  $\text{Posséder}(x,y)$
- Connecteurs logiques ( $\neg, \wedge, \vee, \Rightarrow, =, \dots$ ) et quantificateurs ( $\forall, \exists$ )



# Introduction - Niveaux de traitement

## Sémantique : Le sens des propositions

### Un exemple de la représentation sémantique d'une phrase

- Quelques étudiants possèdent deux ordinateurs
- Deux ordinateurs sont possédés par quelques étudiants
- $E = Etudiant, O = Ordinateur, P = Possede$
- $\exists x(E(x) \wedge \forall y(O(y) \Rightarrow P(x, y)))$  ❌
- $\exists x(E(x) \wedge \exists y, z(((O(y) \wedge P(x, y)) \wedge (O(z) \wedge P(x, z))))$  ❌
- $\exists x(E(x) \wedge \exists y, z(\neg y = z \wedge ((O(y) \wedge P(x, y)) \wedge (O(z) \wedge P(x, z))))$  ✔️
- $\exists x(E(x) \wedge \exists y((O(y) \wedge P(x, twoOf(y))))$  ✔️



### Un exemple d'inférence

Chaque homme est mortel.	Socrate est un homme.
$\forall x(Homme(x) \Rightarrow Motel(x))$	$Homme(Socrate)$
$Motel(Socrate)$	

# Introduction - Niveaux de traitement

## Sémantique : Pragmatique et discours

- Imaginer qu'on est dans un anniversaire
- Une personne crie : "Les bougies!"
- On peut directement comprendre qu'il n'y a pas des bougies sur la tarte
- Question: comment peut-on déduire ça ?
- Réponse: **Savoir prendre en compte le contexte**



Sémantique	Pragmatique
une personne <b>A</b> est arrivée tard à un rendez-vous.	
<b>B</b> : "A votre avis, quelle heure est-il ?"	
<b>A</b> annonce l'heure	<b>A</b> explique les raisons du retard

# Introduction - Niveaux de traitement

---

## Sémantique : Pragmatique et raisonnement

- Implication conversationnelle: réfère a ce que le locuteur veut dire d'une **façon implicite**.
- D'après [Grice, 1979], les interlocuteurs doivent respecter certaines normes (maximes) conversationnelles : quantité, qualité, pertinence et manière.
- Présupposition: réfère aux suppositions faites par les interlocuteurs lors de la communication.
- Acte de langage: réfère a l'interaction linguistique du locuteur afin d'agir sur son environnement.
- Une liste des actes de langage est fournie par [Austin, 1962] : déclaration, ordre, question, interdiction, salutation, invitation, félicitations, excuses, ...

# Introduction - Niveaux de traitement

---

## Sémantique : Discours et coréférences

### Un exemple de coréférence

- **The cat** doesn't fit in the box because **it** is too big.
- The cat doesn't fit in **the box** because **it** is too small.

- Exemples
  - Pronoms: le chat a chassé une souris et **il** joue avec elle.
  - Syntagmes nominaux: Apple est un fabricant d'ordinateur. **La firme** est mondialement connue.
  - Noms: Comme Apple, **IBM** fabrique des ordinateurs.
  - Zero Anaphora: dans des langues comme le japonais, parfois, la référence est omise.

# Introduction - Niveaux de traitement

## Sémantique : Discours et cohérences

- Relation entre les énoncés d'un discours
- Rhetorical Structure Theory (RST): le modèle du discours le plus utilisé
- Deux types d'énoncé : Noyau et satellite
- L'étudiant s'est absenté hier. Il a été malade.
  - Première phrase est un noyau puisqu'elle décrit l'événement principal
  - Deuxième phrase est un satellite puisqu'elle dépend de la première
- Il y a plusieurs relations de cohérence : raison, élaboration, évidence, attribution, narration, etc

### Un exemple de la raison

[NOY L'étudiant s'est absenté hier.] [SAT Il a été malade.]

### Un exemple de l'élaboration

[NOY L'examen est facile.] [SAT Il ne prend qu'une heure.]

### Un exemple de l'évidence

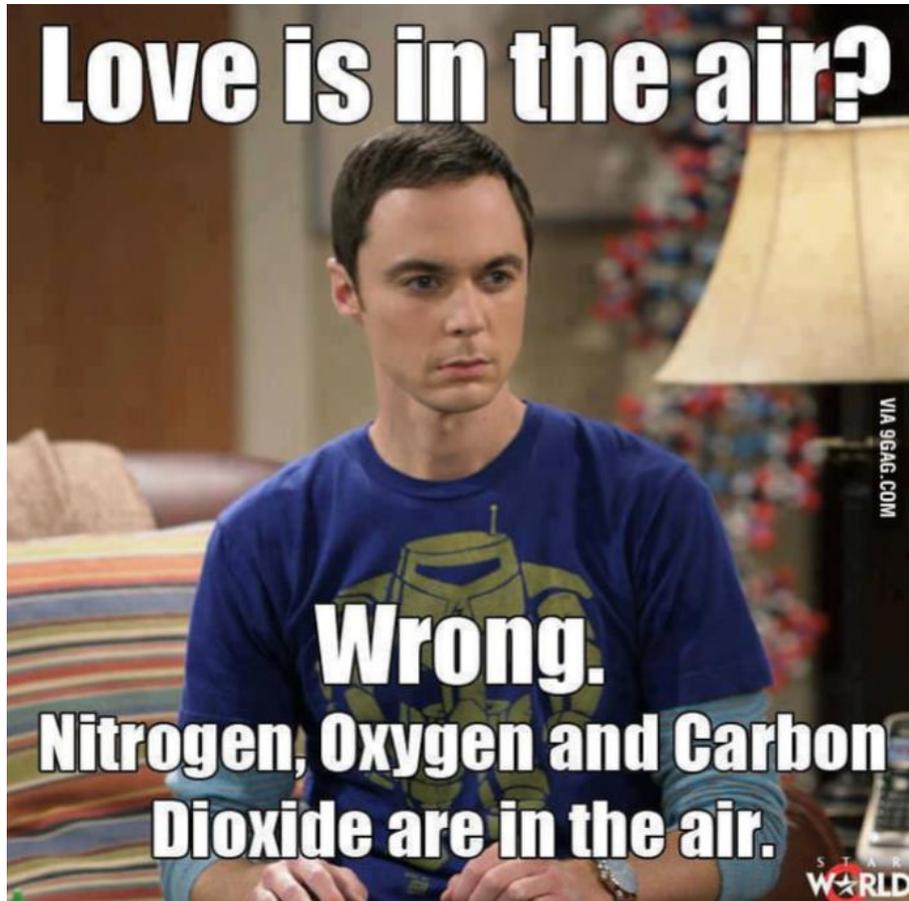
[NOY Kevin doit être ici.] [SAT Sa voiture est garée à l'extérieur.]

# Introduction – Retour sur les applications

---

- Niveau 1 : Tache morpho-syntaxique
  - Délimitation de la phrase et séparation des mots
  - Lemmatisation et racinisation: transformer les mots en une forme standard (token)
  - Etiquetage morpho-syntaxique: trouver les catégories grammaticales des mots d'une phrase
  - Analyse syntaxique: trouver la structure syntaxique d'une phrase (comment elle est formée)
  - Extraction terminologique: rechercher des terminologies spécifiques dans un texte (E.R.)
- Niveau 2 : Tache Sémantique
  - Etiquetage des rôles sémantiques: chercher le rôle sémantique des mots et syntagmes
  - Reconnaissance d'entités nommées
  - Analyse sémantique: trouver la représentation sémantique du texte
  - Paraphrase: formuler un texte différemment → résumé automatique
  - Génération automatique de texte
- Niveau 3 : Analyse de discours
  - Résolution de coréférence: trouver les différentes références à un meme objet dans le texte
  - Analyse du discours: chercher les relations entre les phrases
  - Résolution d'ellipse: trouver les éléments omis du texte.  
Exemple d'ellipse : "Pierre mange des cerises, Paul des fraises"

# Pour conclure l'introduction...



## Les défis restent nombreux...

- Manque de ressources et d'évaluations
  - Selon les langues
  - Annotation manuelle des corpus d'entraînement et de test
  - Évaluation manuelle
- Prise en compte d'un contexte étendu
- Ambiguïtés et coréférences
  - polysémie: un mot ayant plusieurs sens
  - Métaphore, expression polylexicale ("It's raining cats and dogs")
  - Variations (français, sms,...), personnalité, émotions,
- Aspects éthiques
  - Vie privée et utilisation
  - Biais dans les corpus