Traitement automatique de la langue

Principaux concepts et méthodologies

Xavier Tannier

xavier.tannier@sorbonne-universite.fr

D’abord, quelques questions sur vous

1 Allez sur wooclap.com

2 Entrez le code d'événement dans le bandeau supérieur

Code d'événement
MPDDNN

1 Envoyez @MPDDNN au 06 44 60 96 62

2 Vous pouvez participer

Quel est le problème ?

Pourquoi le langage naturel est-il différent des autres données ?

Quel est le problème ?

Pourquoi le langage naturel est-il différent des autres données ?

- Il est redondant
- Il est implicite
- Il est ambigu
- … bref il est naturel
- … et il est difficile à représenter

Le langage est redondant

ChatGPT au tribunal : un avocat trompé par l'IA plaide coupable

Etats-Unis: ChatGPT lui souffle des affaires inventées, un avocat dans l'embarras

Un avocat utilise ChatGPT pour préparer un procès : il doit s'excuser car rien n'était vrai dans son dossier

"MON DIEU, JE REGRETTE": L'AVOCAT AYANT UTILISÉ CHATGPT ESTIME S'ÊTRE FAIT AVOIR PAR L'IA

Un avocat américain a utilisé ChatGPT pour préparer un procès... et n'a cité que des faux arrêts

Après avoir utilisé ChatGPT, un avocat fait référence à des affaires qui n'ont jamais eu lieu

Le langage est redondant

« L'avocat Steven Schwartz travaillait sur un procès contre une compagnie aérienne, Avianca, la plus grande compagnie colombienne. Mais selon le juge en charge du dossier, le mémoire juridique qu'il a fourni pour appuyer ses arguments est truffé d'erreurs. "Six des cas mentionnés se révèlent être des décisions judiciaires imaginaires, étoffées de citations et de références imaginaires", a déclaré le juge américain Kevin Castel.

[…] Dans une déclaration sous serment, Steven Schwartz a reconnu avoir utilisé le robot conversationnel ChatGPT pour l'aider à faire son dossier... […] Pour seule vérification, il a tapé dans le champ de recherche de ChatGPT : "Est-ce que c'est une véritable affaire ?"

"Oui", a répondu ChatGPT. […] »

https://www.radiofrance.fr/franceinter/un-avocat-americain-a-utilise-chatgpt-pour-preparer-un-proces-et-n-a-cite-que-des-faux-arrets-3833906

Le langage est ambigu

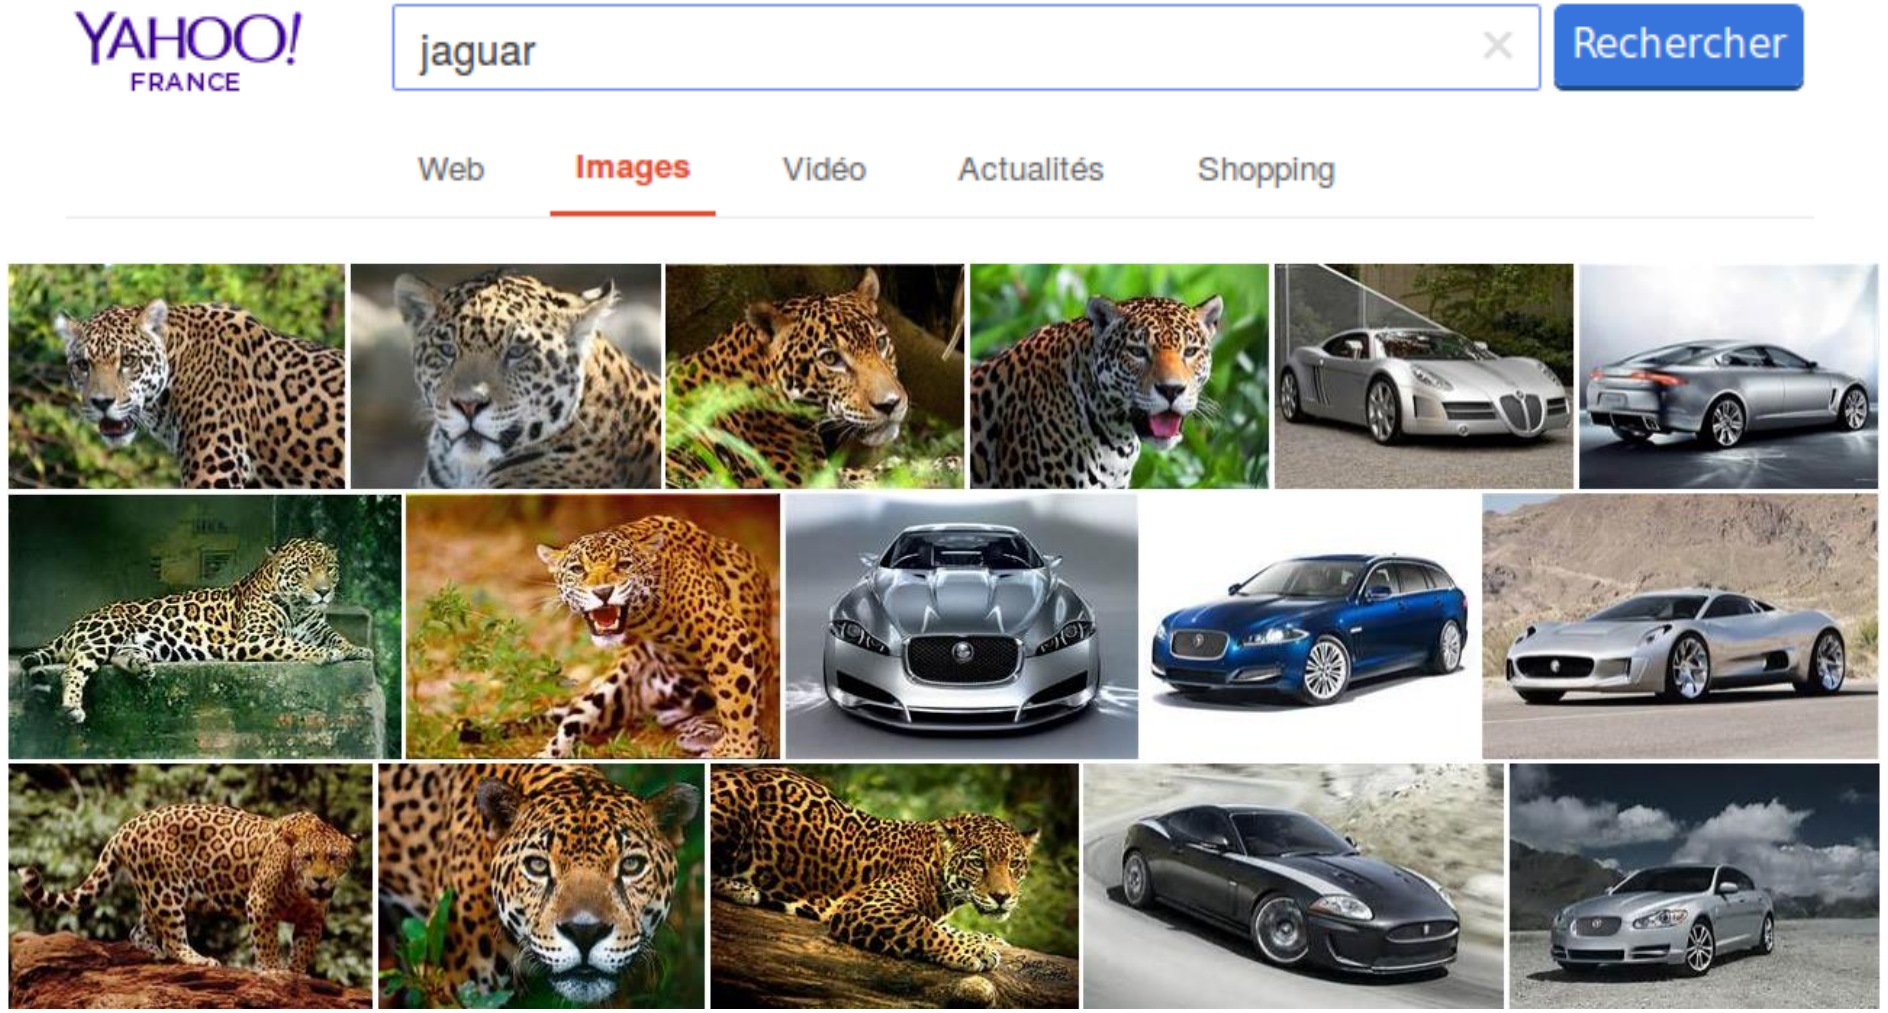

Le langage est ambigu, implicite

*Jean vend une tarte **aux pommes**.*

*Jean vend une tarte **aux clients**.*

Si votre bébé ne supporte pas le lait cru, faites-le bouillir

Si le vice-chancelier invite Simone de Beauvoir, il regrettera d'avoir une féministe à sa table.

Si le vice-chancelier invite le président des États-Unis, il regrettera d'avoir une féministe à sa table.

Le langage est implicite

Le Monde

Un Caravage a-t-il été découvert dans un grenier en France ?

Le Monde - il y a 1 heure

Le tableau représentant la décapitation [...] n grenier de la région de Toulouse. Studio SEBERT. Un ta[...] et présenté comme une œuvre du C[...]

Connaissance du monde

Métonymie

Etats-Unis : Devant ses partisans, Donald Trump fustige Biden et une « inculpation sans fondement »

MEETINGS Donald Trump est visé par 37 chefs [...] che, emporté des milliers de documents dont certains confidentiels

Connaissance du contexte

14 mai 1610 : Henri IV est assassiné | L'Histoire

www.histoire.presse.fr/.../14-mai-1610-**henri-iv**-est-[...]4-05-201...

14 mai 2012 - Le 14 mai [...] rs qu'il se rend à l'Arsenal pour s'entretenir [...] duc de Sully, **Henri IV** est ...

Déduction (présupposition)

Le langage est naturel

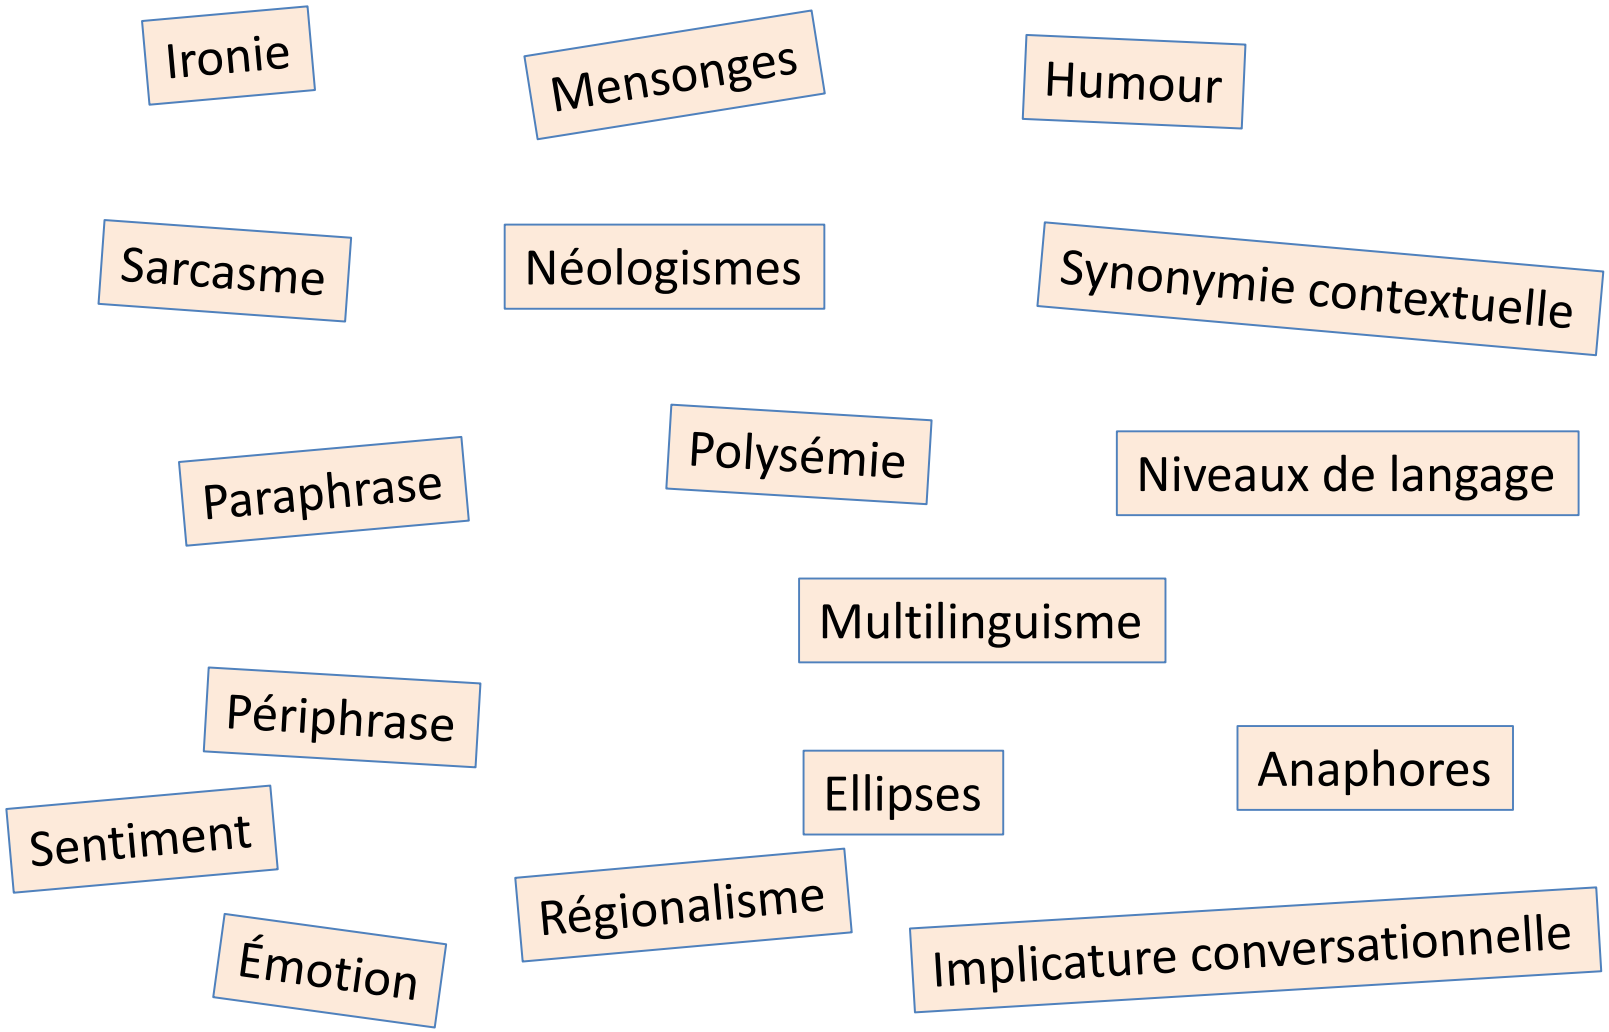

Le langage est naturel

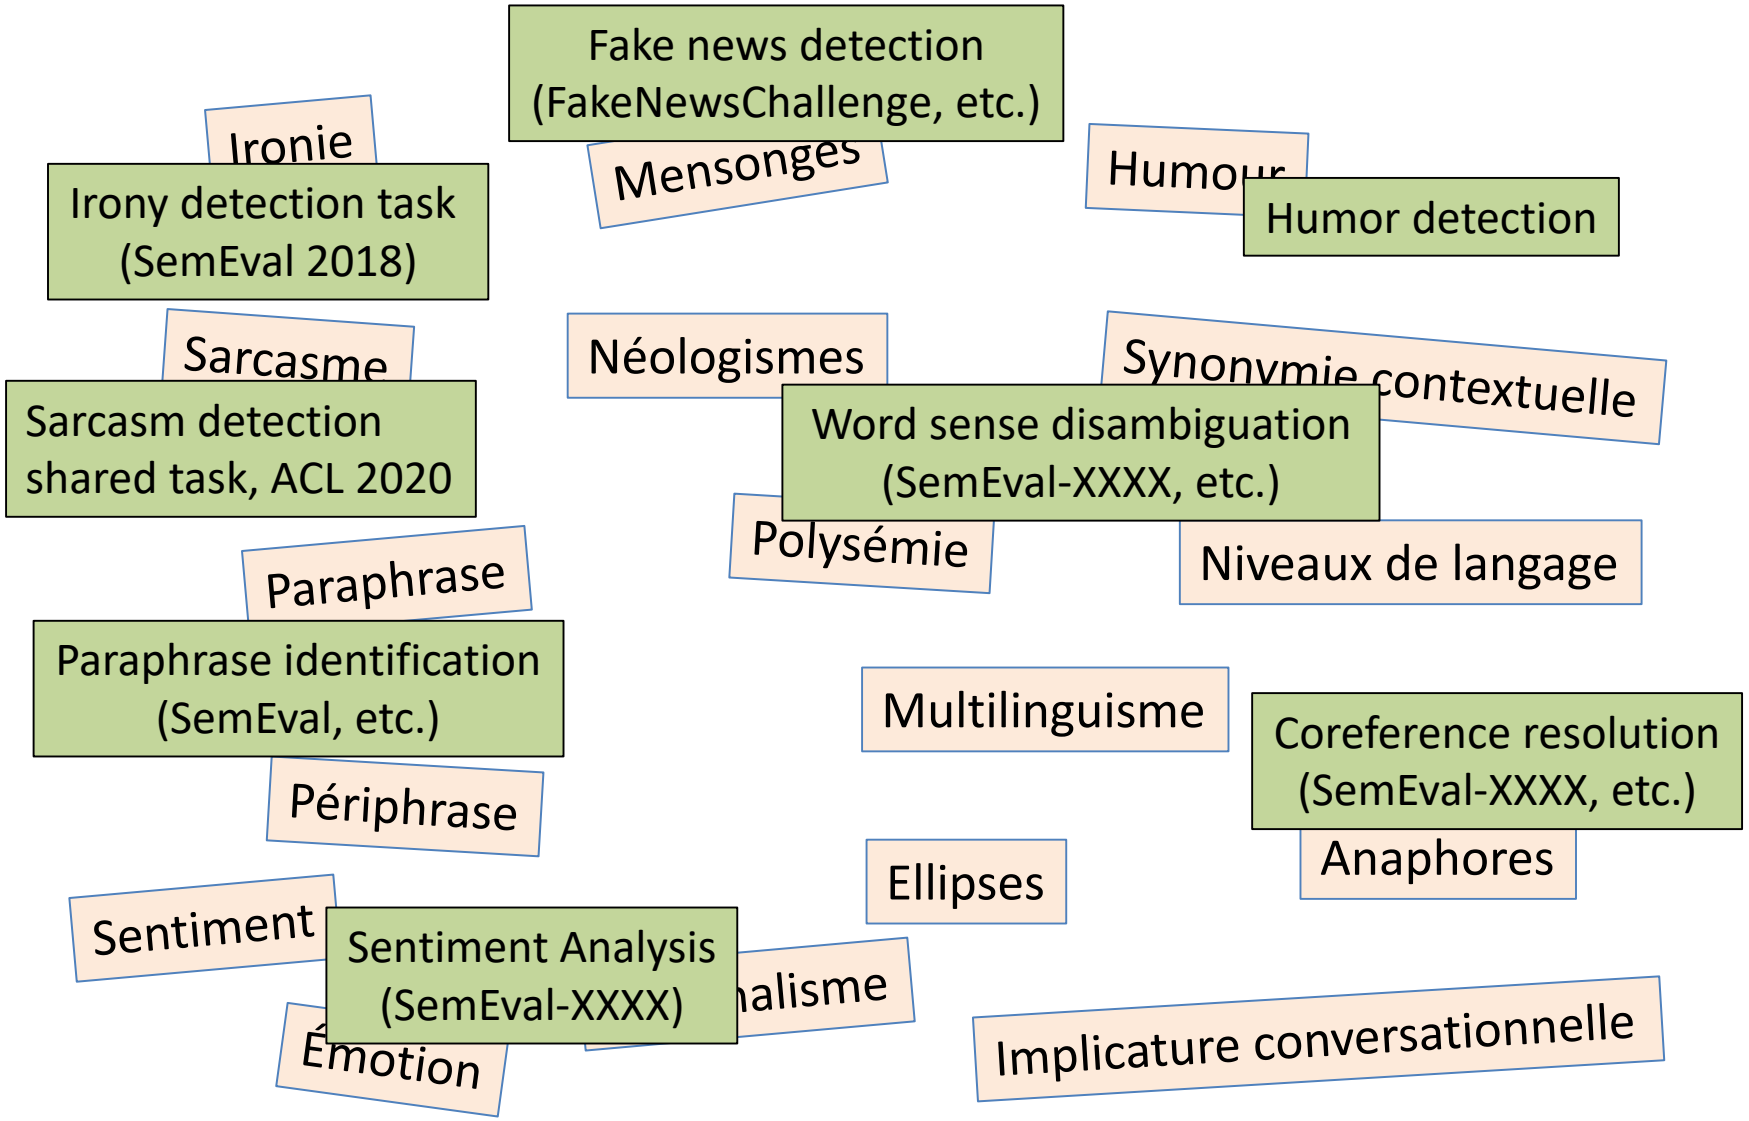

Le langage est naturel

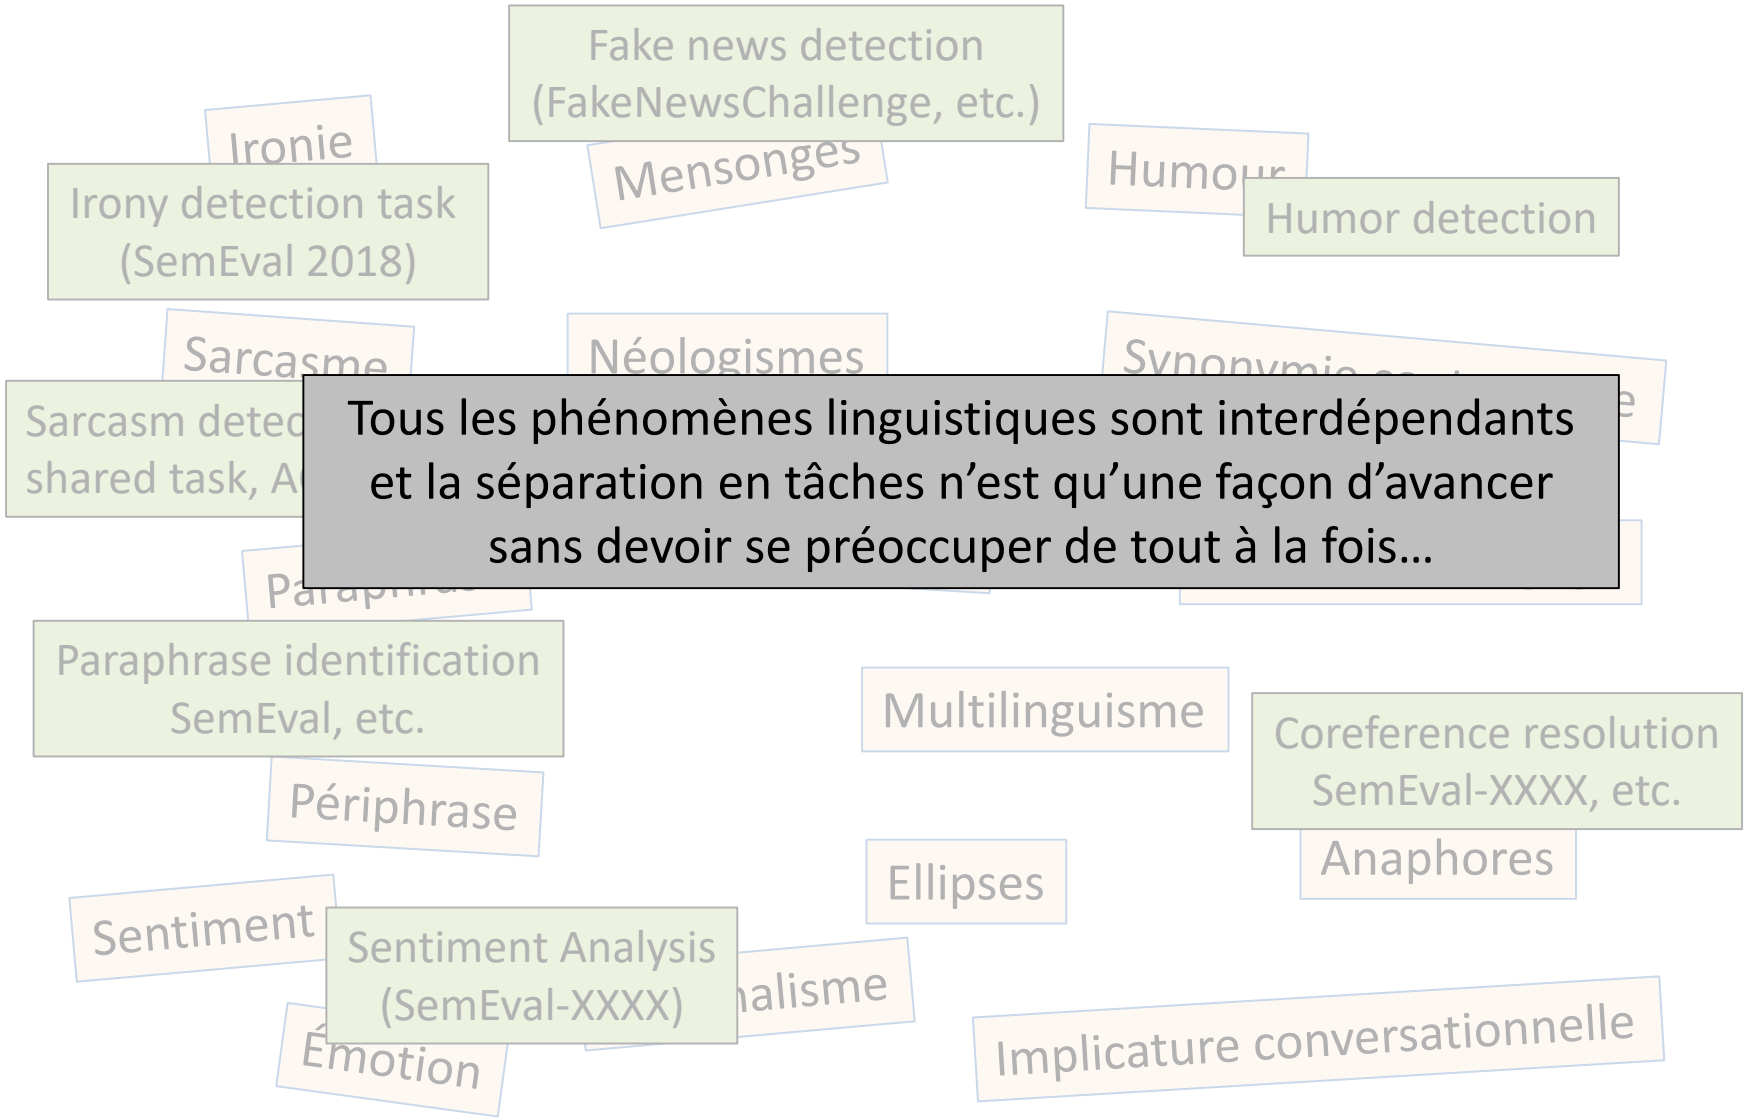

La langue est vivante

Arthur Rimbaud
Honte (19ème siècle)

Tant que la lame n'aura
Pas coupé cette cervelle,
Ce paquet blanc, vert et gras,
A vapeur jamais nouvelle,

(Ah ! Lui, devrait couper son
Nez, sa lèvre, ses oreilles,
Son ventre ! et faire abandon
De ses jambes ! ô merveille !)

Mais non ; vrai, je crois que
Que pour sa tête la lame,
Que les cailloux pour son fla
Que pour ses boyaux la flam

Quant l'Emperere ad faite sa justice
E esclargiée est la sue granz ire,
En Bramimunde ad chrestientet mise.
Passet li jurz, la nuiz est aserie,
Culchet s'est li Reis en sa cambre voltice.
Seinz Gabriel de part Deu li vint dire :
« Carle, semun les oz de tun empire,
« Par force iras en la tere de Bire,
« Rei Vivien si succurras en Imphe,
« A la citet que païen unt asise.
« Li chrestien te recleiment e crient. »
Li Emperere n'i volsist aler mie :
Deus ! dist li Reis, si penuse est ma vi
uret des oilz, sa barbe blanche tiret...

Chanson de Roland
(11ème siècle)

Allocution présidentielle
(21ème siècle)

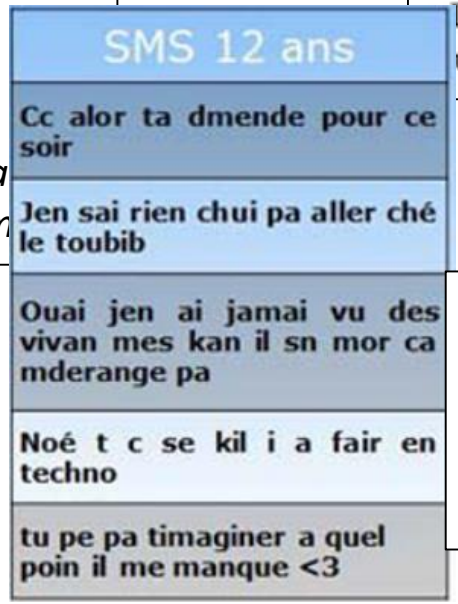

Écriture inclusive (21ème siècle)

"Les étudiant·e·s jouent un rôle essentiel dans notre société. Ils et elles apportent une perspective diversifiée et enrichissante à nos établissements d'enseignement. Il est important de reconnaître les talents et les contributions de chacun·e. Nous devons veiller à ce que les étudiant·e·s se sentent inclus·e·s et soutenu·e·s dans leur parcours éducatif. "

Les langues sont nombreuses

… et souvent « peu dotées »
(*low-resource*)

Pieter Brueghel l'Ancien,
La Grande Tour de Babel
1563

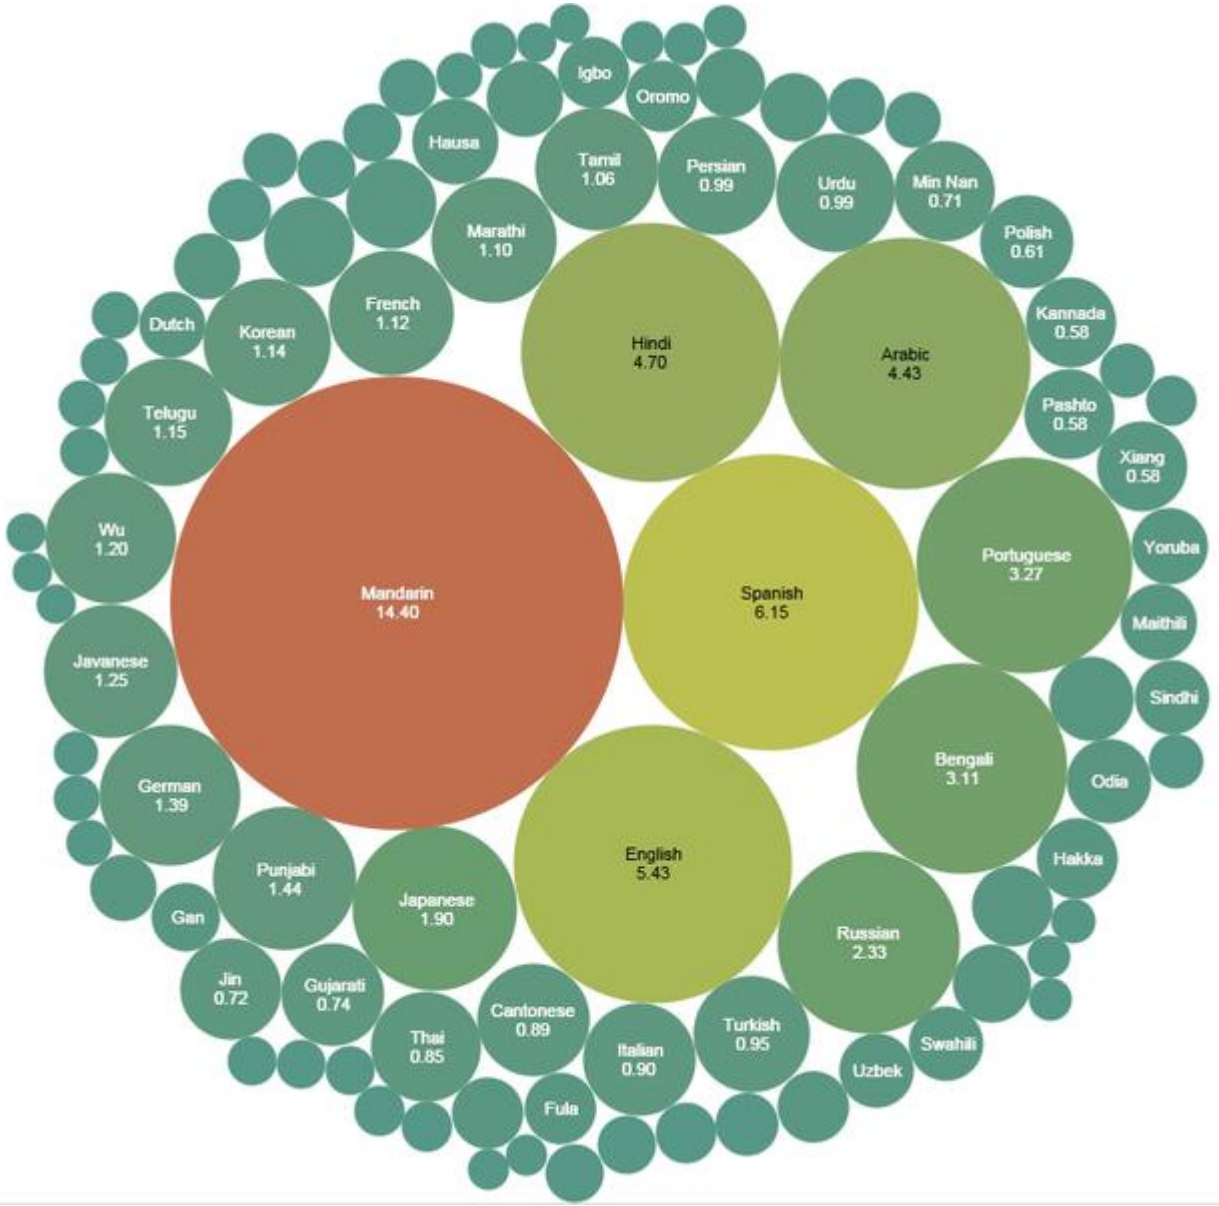

https://en.wikipedia.org/wiki/List_of_languages_by_number_of_native_speakers

Les dénominations du « sac (plastique) » en français régional, d'après les résultats de l'enquête Euro-1. (d'après l'article de Mathieu Avanzi, "Cornet, poche, pochon, sac, sachet ou autre ?" du 31 août 2016)

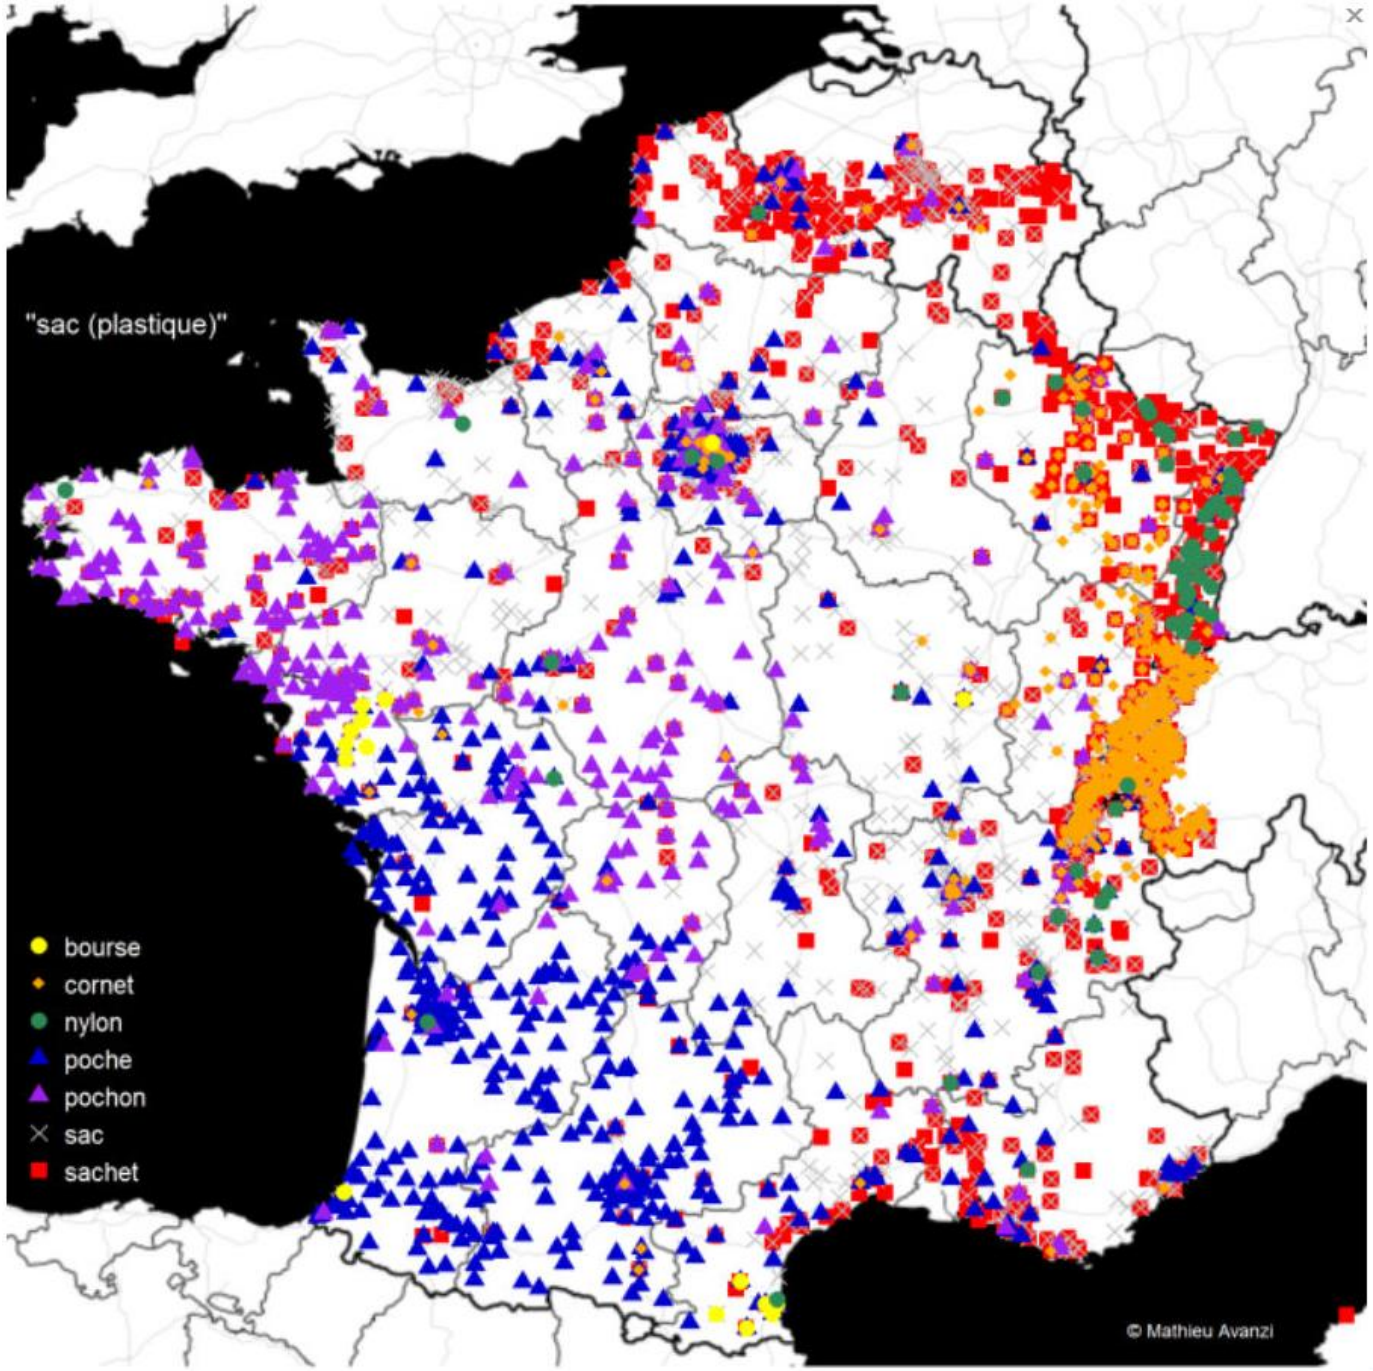

La langue est multimodale

Le langage est une interaction

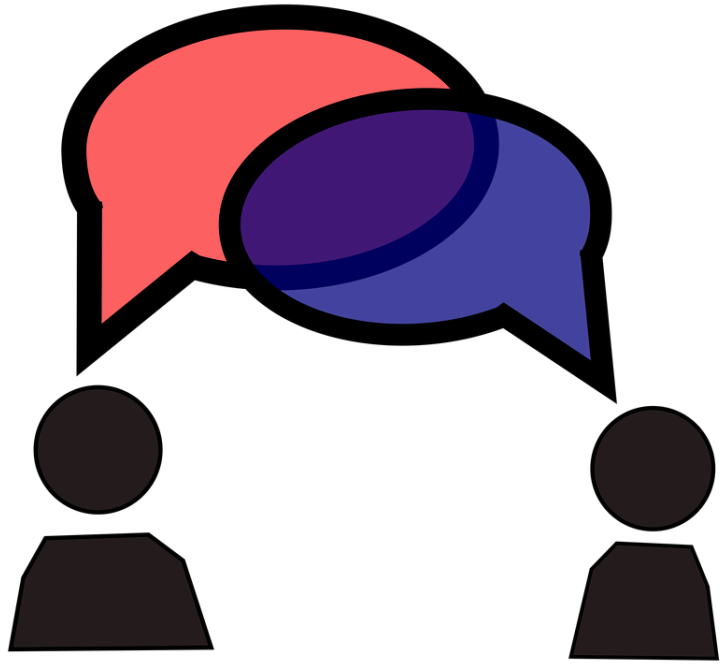

vous avez, il y a une date de limite je pense,
pour accéder au bureau quand on est au C.A.
il y a une… on va dire une date
oui, oui.
par rapport à l'A.G.
oui il faut il faut faire partie de de la
ah non non absolument pas, tu peux être
du C.A. ou non vous n'avez pas ça dans les
statuts, parce que dans certains
je pense pas
statuts il doit y avoir au moins six mois

La transcription automatique : un rêve enfin accessible ?
Elise Tancoigne, Jean-Philippe Corbellini, Gaëlle Deletraz, Laure Gayraud, Sandrine Ollinger, Daniel Valéro
Sept. 2020

La communication n’est pas que verbale

Source : Le Parisien, 17 octobre 2018
https://www.leparisien.fr/politique/jean-luc-melenchon-le-cout-de-la-colere-17-10-2018-7921920.php

Le langage peut être utilisé pour mentir (ou exagérer, induire en erreur…)

LES DÉCODEURS

« Gilets jaunes » : « Constitution disparue
complotisme débridé sur les réseaux soci

**Derrière une théorie très partagée par les « gilets jaunes », qui postule que la Constituti
disparu depuis un an, se trouve Serge Petitdemange, septuagénaire youtubeur aux acc
conspirationnistes.**

Par Samuel Laurent • Publié aujourd'hui à 12h20

CHRISTOPHE ASSELIN - JANV. 26, 2021

Vaccins et Covid : les Fake News les plus fréquentes sur les médias sociaux en France

Pour 17% des français, le coronavirus a été créé **intentionnellement** en laboratoire. Les théories du complot et la désinformation, générant de la méfiance à l'égard des vaccins contre la COVID-19 pourraient conduire à des taux de vaccinations en dessous des 55% nécessaires pour obtenir une immunité collective aux États-Unis et en Grande-Bretagne selon une étude de la London School of Hygiene & Tropical Medicine [1]. Et en France ?
En novembre, 54% des Français déclaraient qu'ils se feraient vacciner, les plaçant en tête des pays les plus réticents. Les fake news sur la Covid et le coronavirus sont légions sur le web et les réseaux sociaux depuis le

ACCUEIL › MONDE

VIDÉO. Donald Trump : Ses dix «fake news» les marquantes depuis son élection

FAKE OFF Le président des Etats-Unis aime beaucoup les « faits alternatifs »...

Mathilde Cousin | Publié le 20/01/18 à 10h45 — Mis à jour le 20/01/18 à 10h45

2 COMMENTAIRES 316 PARTAGES

À LIRE AUSSI

26/10/17 | FAKE OFF
Non, le drapeau européen ne va pas «remplacer» le drapeau français

06/11/17 | JAPON
VIDEO. Japon: Trump en visite officielle, protocole et carpes Koï

06/11/17 | COREE DU NORD
Donald Trump et Shinzo Abe affichent leur fermeté face à la Corée du Nord

D'ACTU

Historique

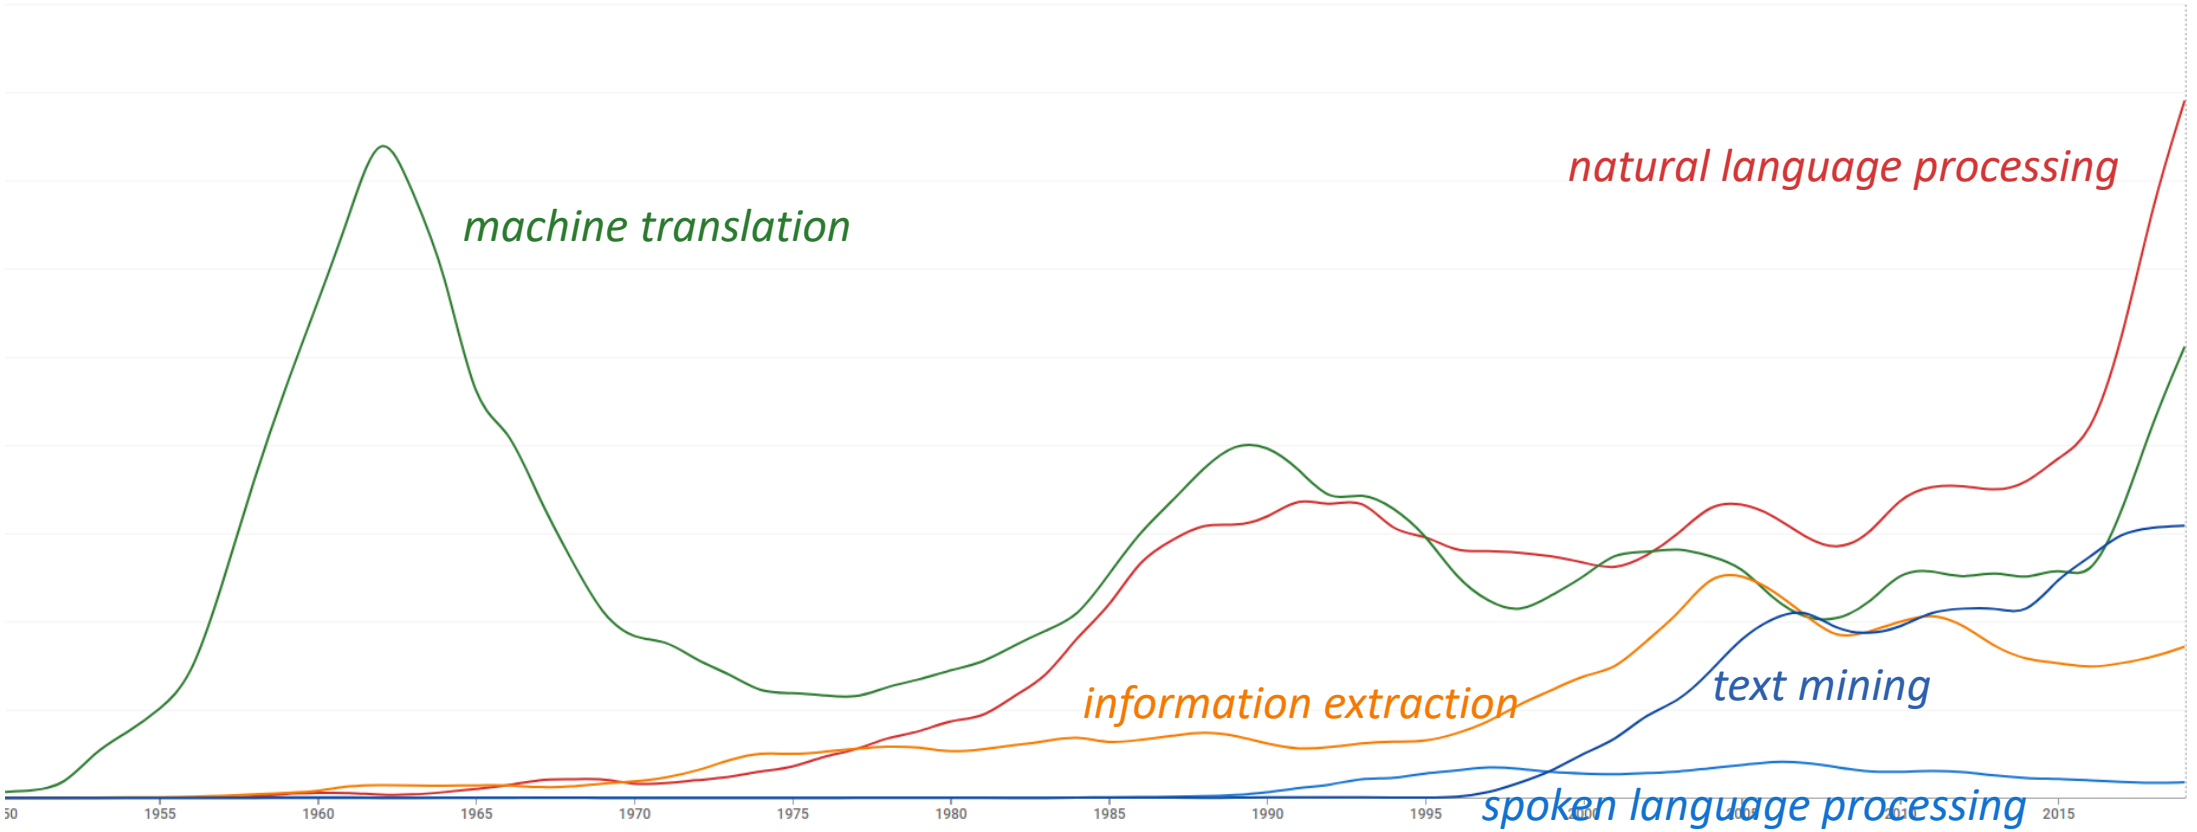

Google Books Ngram Viewer

Qu’est-ce que le TAL ?

~~Comprendre du langage~~

Accomplir des tâches
en lien avec le langage

Niveaux d'analyse (image d'Épinal)

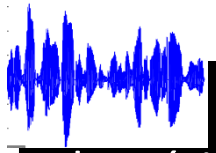

(parole)
phonétique, phonologique

Comment les mots et les phrases sont liés aux sons qui les réalisent à l'oral

(texte)
(extraction), tokénisation

morphologique

Comment les mots sont construits et quels sont leurs rôles dans la phrase

syntaxique

Comment les mots se combinent pour former des syntagmes, puis des propositions et enfin des phrases correctes

sémantique

Comment les mots font du sens lorsqu'ils sont insérés dans une phrase (indépendamment du contexte)

discours

Comment les phrases peuvent être interprétées selon leur contexte d'énonciation
(interlocuteurs, phrases précédentes, connaissance commune du monde, ...)

Transcription manuelle

Les grandes classes de tâches de TAL

Correction

Reconnaissance de la parole

Synthèse de la parole

Désambiguïsation lexicale

Analyse syntaxique

Rôles sémantiques

Recherche d'information

Similarité

Extraction d'information
- Reconnaissance d'entités nommées
- Extraction de relations
- Coréférence…

Classification de texte

Traduction

Réponse à des questions

Dialogue

Génération

Résumé

Le TAL, un problème de représentation

Le mot

Rien ne sert de courir il faut partir à point

Le mot

Rien ne sert de courir il faut partir à point

etc.
T.A.L.
21.3
www.sncf.com

Jean-Louis
donne-t-il
1914-1918
06-13-23-33-12

l'illusion
aujourd'hui
jusqu'à

Les industries sont variées : imprimerie, agroalimentaire (jus de fruits, conserveries), armement et défense, équipement électrique et électronique, chimie (engrais, matières plastiques), industries pharmaceutiques, textile et confection, industries dérivées du bois (papeteries) et du tabac. Sur la côte orientale, à Cap Canaveral, est installée le grand centre spatial de la NASA.

Le mot

Rien ne sert de courir il faut partir à point

etc.
T.A.L.
21.3
www.sncf.com

Jean-Louis
donne-t-il
1914-1918
06-13-23-33-12

l'illusion
aujourd'hui
jusqu'à

Les industries sont variées : imprimerie, agroalimentaire (jus de fruits, conserveries), armement et défense, équipement électrique et électronique, chimie (engrais, matières plastiques), industries pharmaceutiques, textile et confection, industries dérivées du bois (papeteries) et du tabac. Sur la côte orientale, à Cap Canaveral, est installée le grand centre spatial de la NASA.

Le mot

Lebensversicherungsgesellschaftsangestellter (langues agglutinantes)

(employé d'une compagnie d'assurance-vie)

學而不思則罔，思而不學則殆

東京、マドリード、イスタンブール（トルコ）が争う2020年夏季五輪の開催地は7日（日本時間8日）、ブエノスアイレスでの国際オリンピック委員会（IOC）総会で、IOC委員約100人の投票で決まる。

Formes d'un mot, famille d'un mot

- **Flexion**
  - Verbale : *montrer, montreras...*
  - Nominale : *cheval, chevaux...*
  - forme canonique (lemme) et formes fléchies
- **Dérivation**
  - *penser/V + able = pensable*
  - *in + pensable/A = impensable*
  - base et dérivé
- **Composition**
  - *appendice + ectomie = appendicectomie*
  - éléments de formation, mot composé

Lemmatisation

- Obtention de la forme canonique (le *lemme*) à partir du mot :
  - Pour un **verbe** : sa forme à l'infinitif (sans les flexions)

    montrer, montreras, montraient → montrer
  - Pour un **nom**, **adjectif**, **article**, ... : sa forme au masculin singulier

    vert, vertes, verts → vert
- La lemmatisation demande des ressources et un traitement linguistique
  - En particulier pour les nombreuses exceptions
  - Long et donc difficile à mettre en œuvre pour des grandes collections
  - Dépendant de la langue
- Elle n'agrège que des variantes flexionnelles
  - *cheval* = *chevaux*
  - *cheval* ≠ *chevalier*

Racinisation (*stemming*)

- Obtention de la racine, une forme tronquée du mot, commune à toutes les variantes morphologiques
  - Suppression des **flexions**
  - Suppression des **suffixes**
  - Ex : *cheval, chevaux, chevalier, chevalerie, chevaucher*
    → *"cheva"(mais pas "cavalier")*
- La racinisation est généralement à base de règles
  - Rapide
  - Dépendant de la langue
- Elle agrège beaucoup plus que la lemmatisation
  - Vocabulaire plus petit

Étiquetage

- Associer aux mots leur **catégorie morphosyntaxique** (nom, verbe, adjectif, etc.)

- Peut être utile pour :
  - Supprimer les mots inutiles
  - Opérer des regroupements en termes complexes
  - Manipuler des mots ambigus avec plus de précision (*vers*, *or*, *pouvoir*…)
  - Construire une représentation syntaxique

- Mais :
  - Un processus plus long
  - 96 % de précision = une erreur par phrase en moyenne !

Mots vides

- Les mots « **outils** » n'apportent pas de sens au texte

  déterminants : « le », « la », pronoms : « je », « nous »,
  prépositions : « sur », « contre », …

- Ce sont les mots les plus fréquents de la langue
  - Les 30 mots les plus fréquents représentent 30 % des occurrences de mots
  - Les supprimer permet :
    - de réduire le bruit qu'ils pourraient générer
    - de « rapprocher » les mots porteurs de sens
    - d'économiser beaucoup de place dans un index
  - Mais :
    - ils informent sur la syntaxe
    - ils sont dans les expressions multi-mots
    - comme toutes les listes en TAL, la frontière n'est pas évidente à fixer

Tâche : classification de texte

20newsgroups : 20 000 documents partitionnés en 20 classes

comp.graphics comp.os.ms-windows.misc comp.sys.ibm.pc.hardware comp.sys.mac.hardware comp.windows.x	rec.autos rec.motorcycles rec.sport.baseball rec.sport.hockey	sci.crypt sci.electronics sci.med sci.space
misc.forsale	talk.politics.misc talk.politics.guns talk.politics.mideast	talk.religion.misc alt.atheism soc.religion.christian

Tâche : classification thématique

talk.politics.guns

Percentage of Reported Gun and Knife Attacks

Guns (6,350 total attacks) 12.2

[…] the purchase of a handgun when his life or family members have been threatened? […]

[…] teach children to safely handle firearms […]

[…] Didn't Christ tell his disciples to arm themselves […]

[…] not in the armied forces. […]

[…] unintentional youth gun deaths […]

pc.hardware

this is a bus mouse.

Variantes
Similarité sémantique
Polysémie
N-grammes

Représentation « sac de mots »

Lisible par l'humain	👍
Sémantique explicite	👍
Dimensionalité	👎
Similarité sémantique	👎
Polysémie	👎
Variantes orthographiques	👎
Expressions multi-mots	👎
Mots inconnus	👎

Langage = symboles

Vocabulaire = tous les mots

Vélo ≠ bicyclette ≠ VTT, chien ≠ chat,
Paris ≠ Londres

Tuebingen ≠ Tübingen,
artichaut ≠ artichaud

N-grammes de mots

n-gramme = sous-séquence de *n* éléments consécutifs dans une séquence donnée

- n-gramme de caractères
- n-gramme de mots
- …

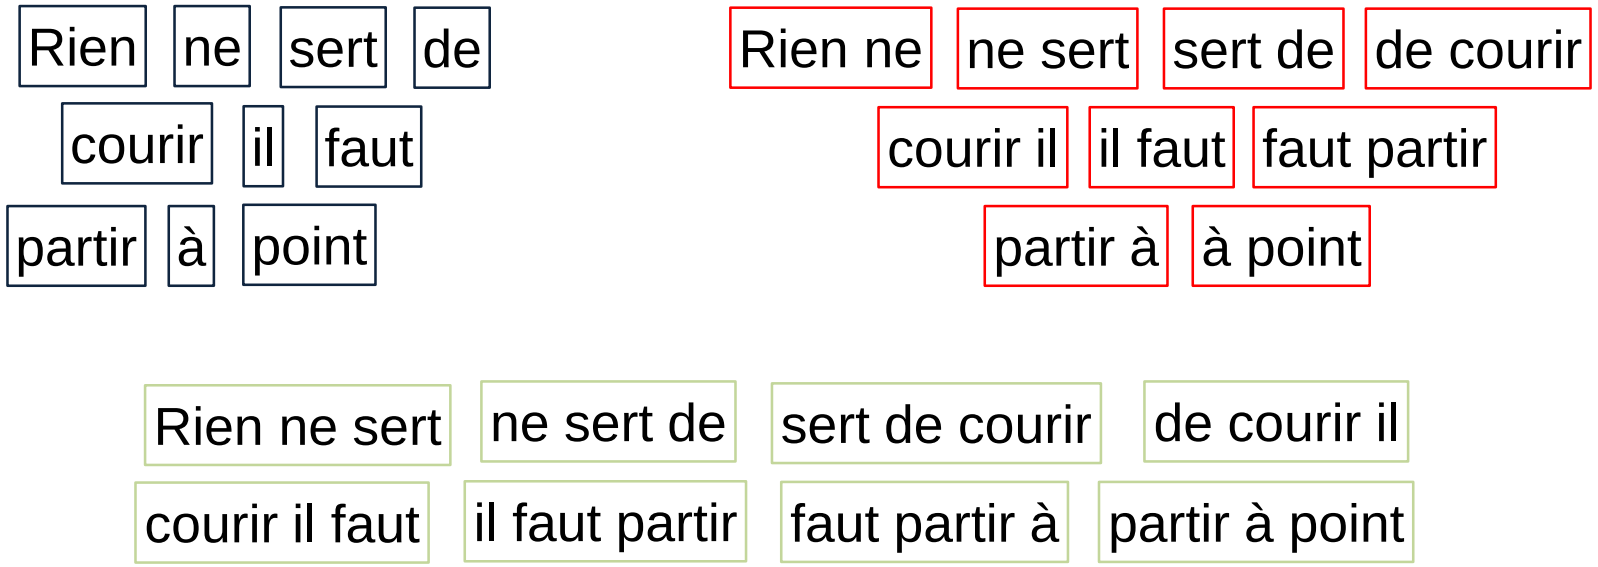

Tâche : recherche d'information

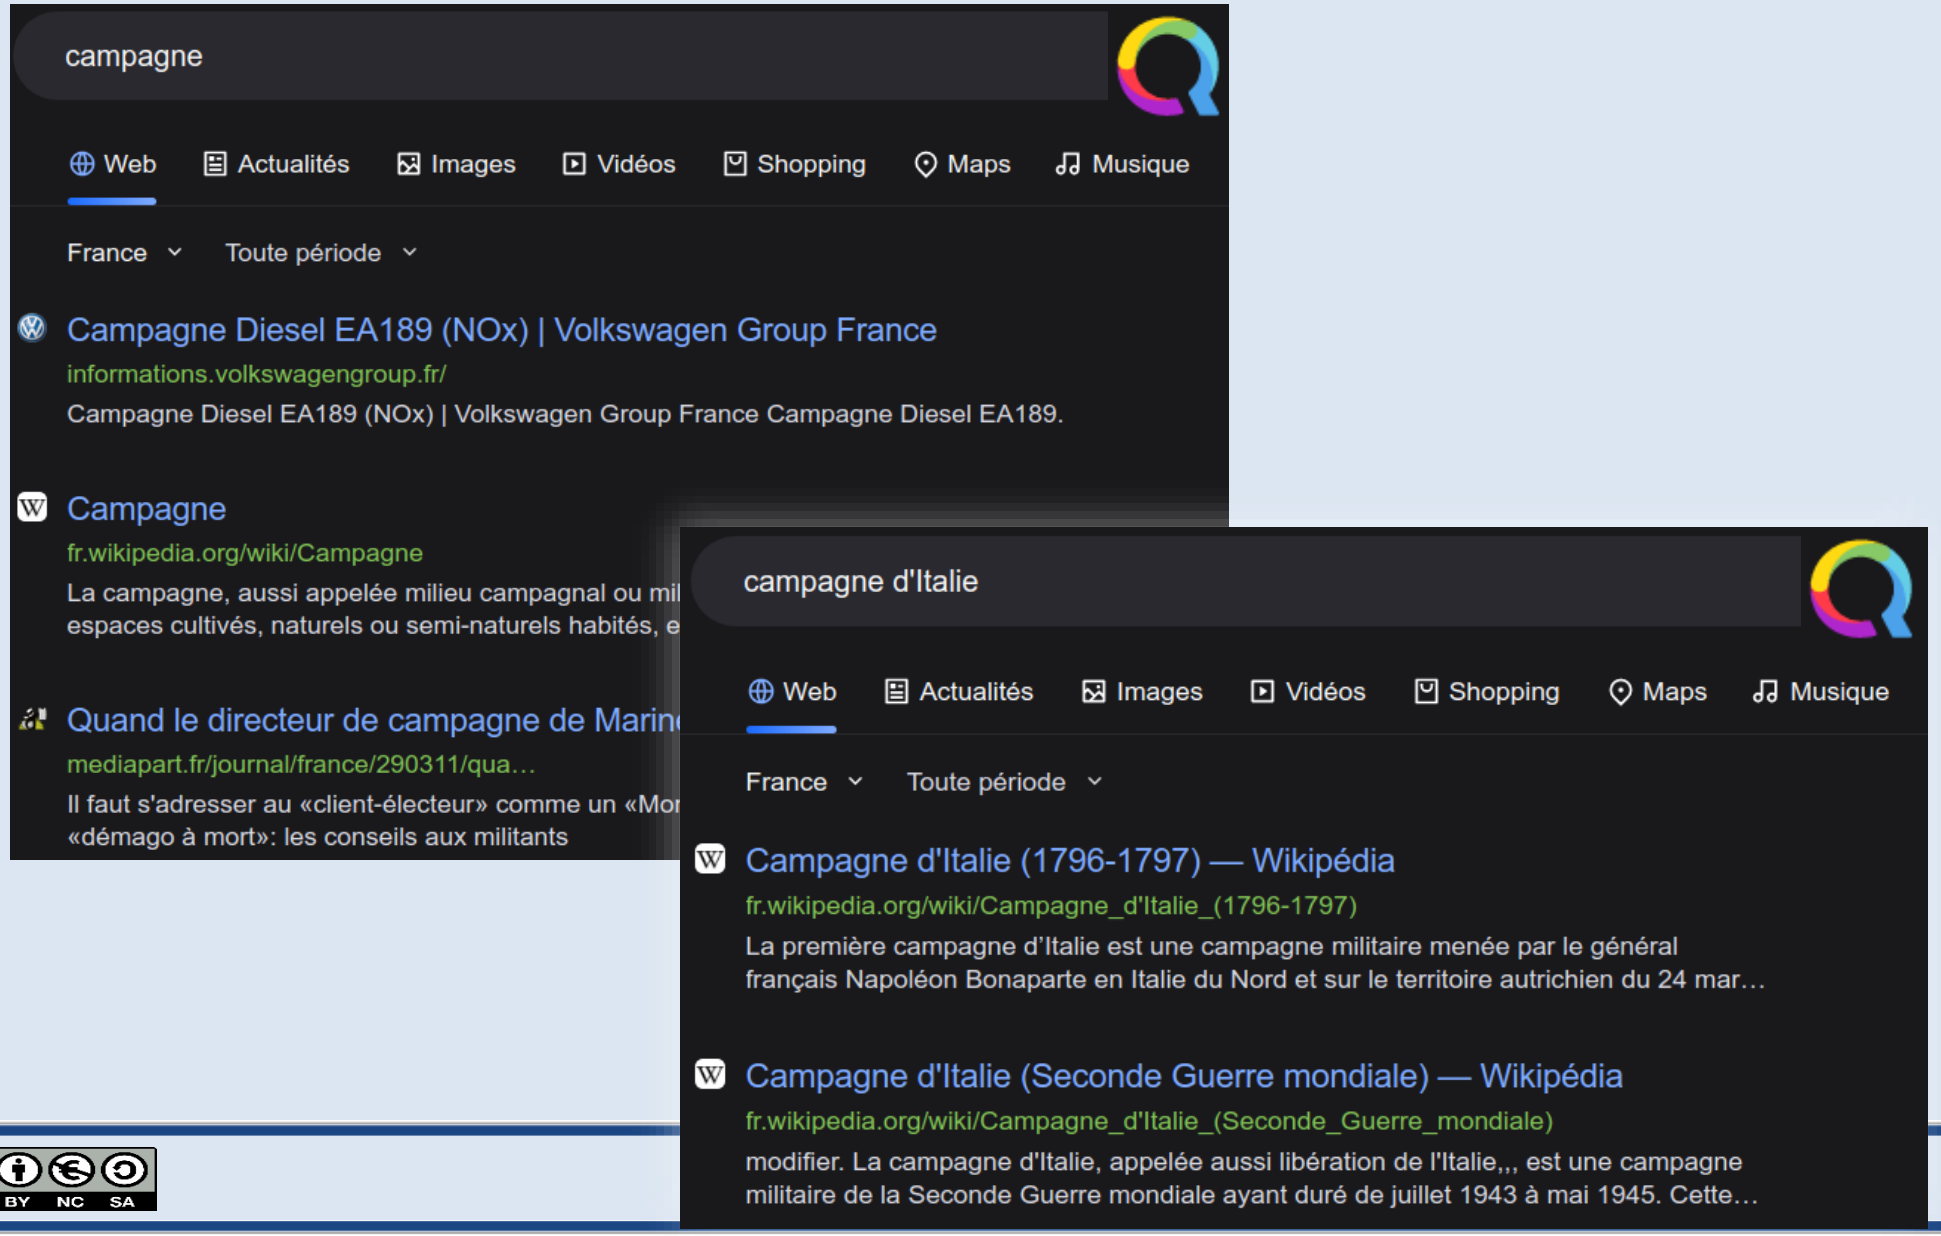

Représentation « sac de n-grammes »

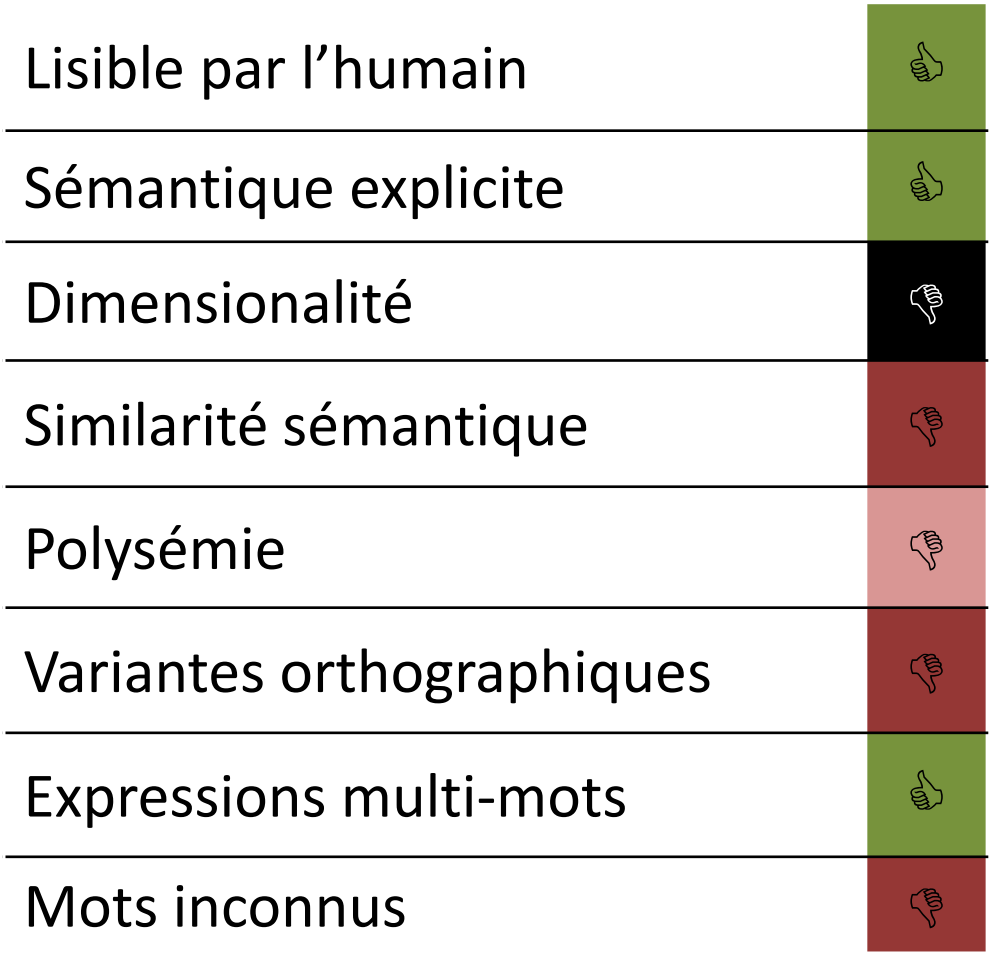

Vocabulaire = tous les n-grammes

n-grammes peu polysémiques

Représentations denses (*embeddings*)

- Word embeddings = représentation vectorielle des mots
- Mots proches dans l'espace = mots ayant un certain degré de similarité entre eux

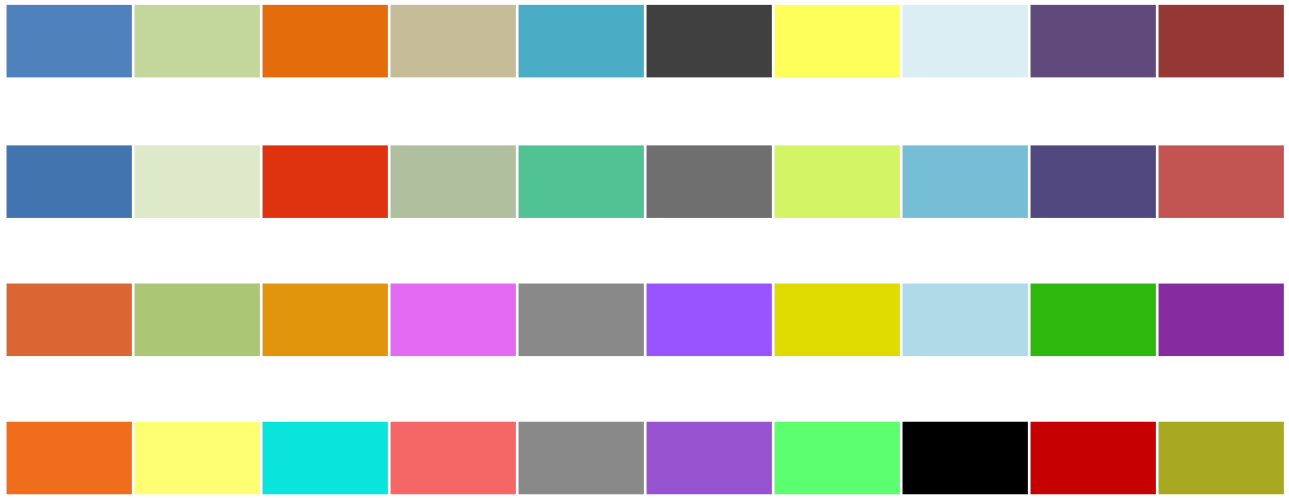

Représentations denses (*embeddings*)

- **Intuition 1**. Chaque mot d'un langage est associé à une composition de facteurs cachés (souvent inintelligible)

  Ex : chat = 10 (animal) + 5 (doux) – 10 (loyal)

- **Intuition 2**. Hypothèse distributionnelle

  « You shall know a word by the company it keeps » (Firth, 1957)

  Deux mots proches dans l'espace vectoriel = deux mots qui partagent souvent des contextes similaires

  Ex : le … griffe ; … est un félin

$$occurrence(chat) \sim occurrence(tigre)$$

$$w_{chat} \cdot w_{contexte} \sim w_{tigre} \cdot w_{contexte}$$

$$w_{chat} \sim w_{tigre}$$

(© Perceval Wajsbürt)

Représentations denses (*embeddings*)

- Word embeddings = représentation vectorielle des mots
- Mots proches dans l'espace = mots ayant un certain degré de similarité entre eux

Représentations denses (*embeddings*)

- Word embeddings = représentation vectorielle des mots
- Mots proches dans l'espace = mots ayant un certain degré de similarité entre eux

Représentations denses (*embeddings*)

Deux mots proches dans l'espace vectoriel = deux mots qui partagent souvent des contextes similaires

Deux mots proches dans l'espace vectoriel = ~~deux mots ayant un sens proche~~

$w_{vélo} \sim w_{bicyclette}$ $w_{chat} \sim w_{tigre}$ $w_{bon} \sim w_{mauvais}$

$w_{malade} \sim w_{malades}$ $w_{Paris} \sim w_{Londres}$ $w_{petit} \sim w_{grand}$

Tâche : reconnaissance d’entités nommées

CONLL 2003, reconnaissance d’entités nommées

- Anglais, Allemand, Espagnol, Néerlandais
- Types : PERSONNE, ORGANISATION, LIEU, DIVERS

LOCATION
Bonn has led efforts to protect public health after consumer confidence collapsed in March

LOCATION
[...] told Israel Radio it looked like Damascus wanted to talk [...]

LOCATION
[...] concert in the English city of Nottingham he threw the sheet of paper [...]

Représentation dense

Lisible par l'humain	👎	
Sémantique explicite	👎	
Dimensionalité	👍	Vecteur = quelques centaines de dimensions
Similarité sémantique	👍	Par construction, mais implicite
Polysémie	👎	
Variantes orthographiques	👍	
Expressions multi-mots	👎	Opérations arithmétiques sur les vecteurs de mots
Mots inconnus	?	Selon les méthodes, voir plus loin

Représentation dense

Autre avantage des représentations denses :
on peut les mélanger à des représentations d'autre chose

Aditya Ramesh, Mikhail Pavlov, Gabriel Goh, Scott Gray, Chelsea Voss, Alec Radford, Mark Chen, Ilya Sutskever
Zero-Shot Text-to-Image Generation

Représentation dense

Autre avantage des représentations denses :
on peut les mélanger à des représentations d'autre chose

DALL·E 2

High-Resolution Image Synthesis with Latent Diffusion Models
Robin Rombach, Andreas Blattmann, Dominik Lorenz, Patrick Esser, Björn Ommer
CVPR '22

Représentation dense

Autre avantage des représentations denses :
on peut les mélanger à des représentations d'autre chose

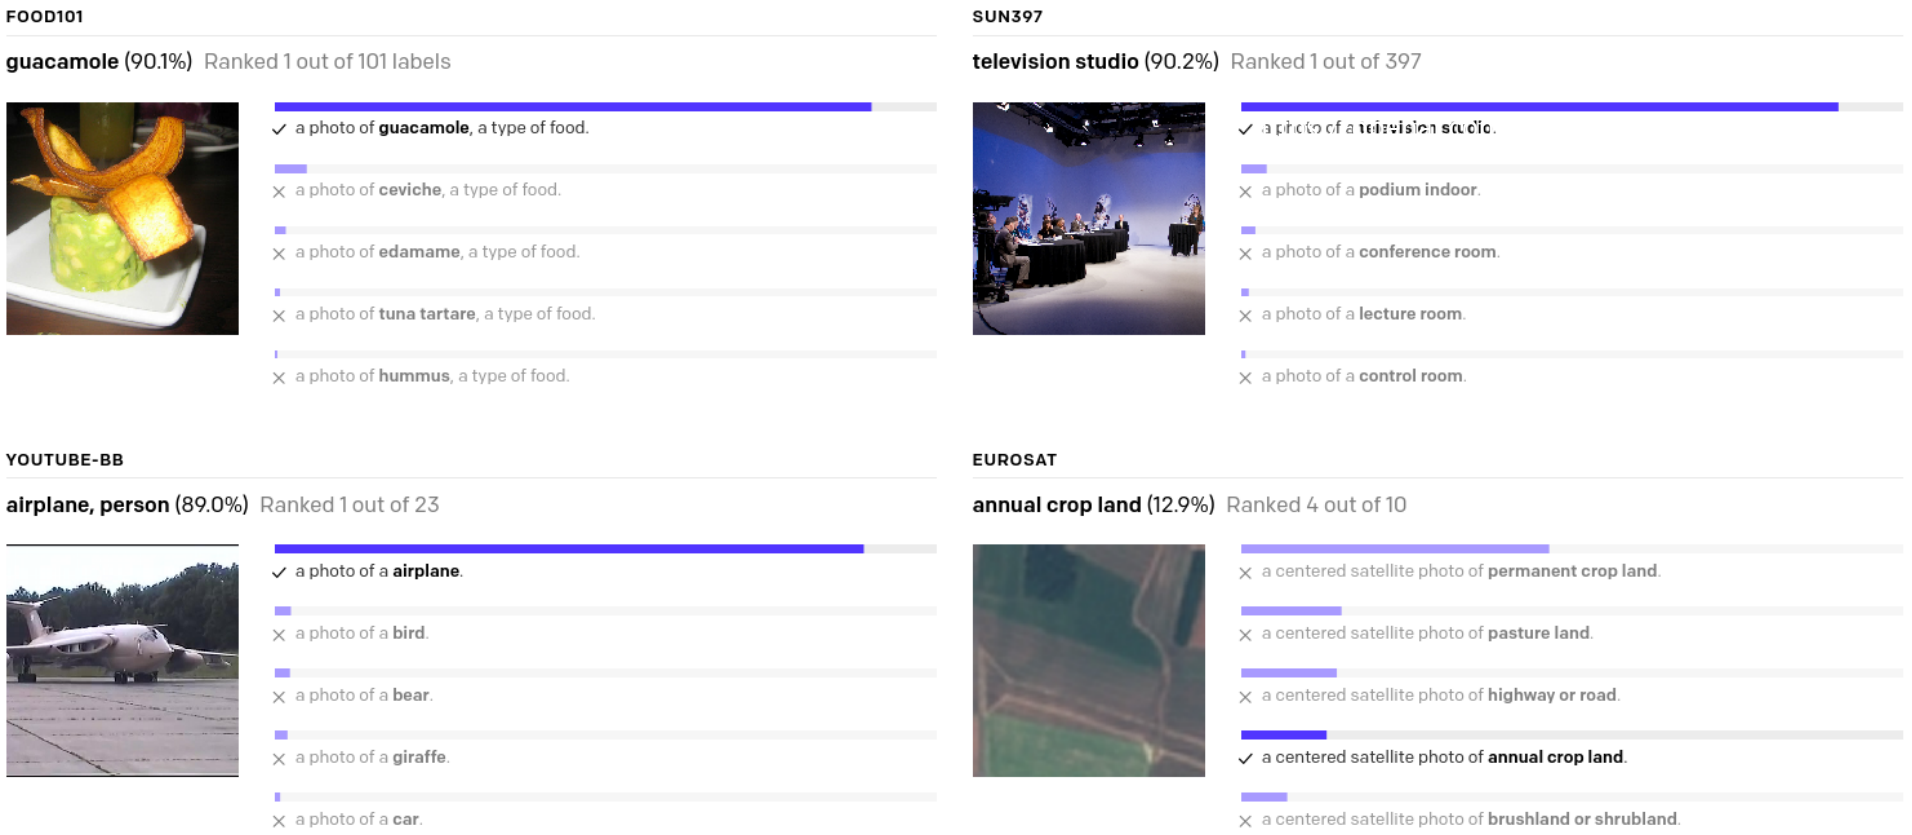

https://openai.com/blog/clip/

Alec Radford et al.
Learning Transferable Visual Models From Natural Language Supervision
Feb. 2021

Tâche : légendage automatique d'image

Rohrbach, Anna, Marcus Rohrbach, Ronghang Hu, Trevor Darrell, and Bernt Schiele (2016). "Grounding of Textual Phrases in Images by Reconstruction".Computer Vision - ECCV 2016

Représentation dense

Autre avantage des représentations denses :
on peut les mélanger à des représentations d'autre chose

Embeddings de graphes de connaissance

Luca Costabello, Sumit Pai, Nicholas McCarthy, Adrianna Janik
Knowledge Graph Embeddings Tutorial: From Theory to Practice
ECAI 2020

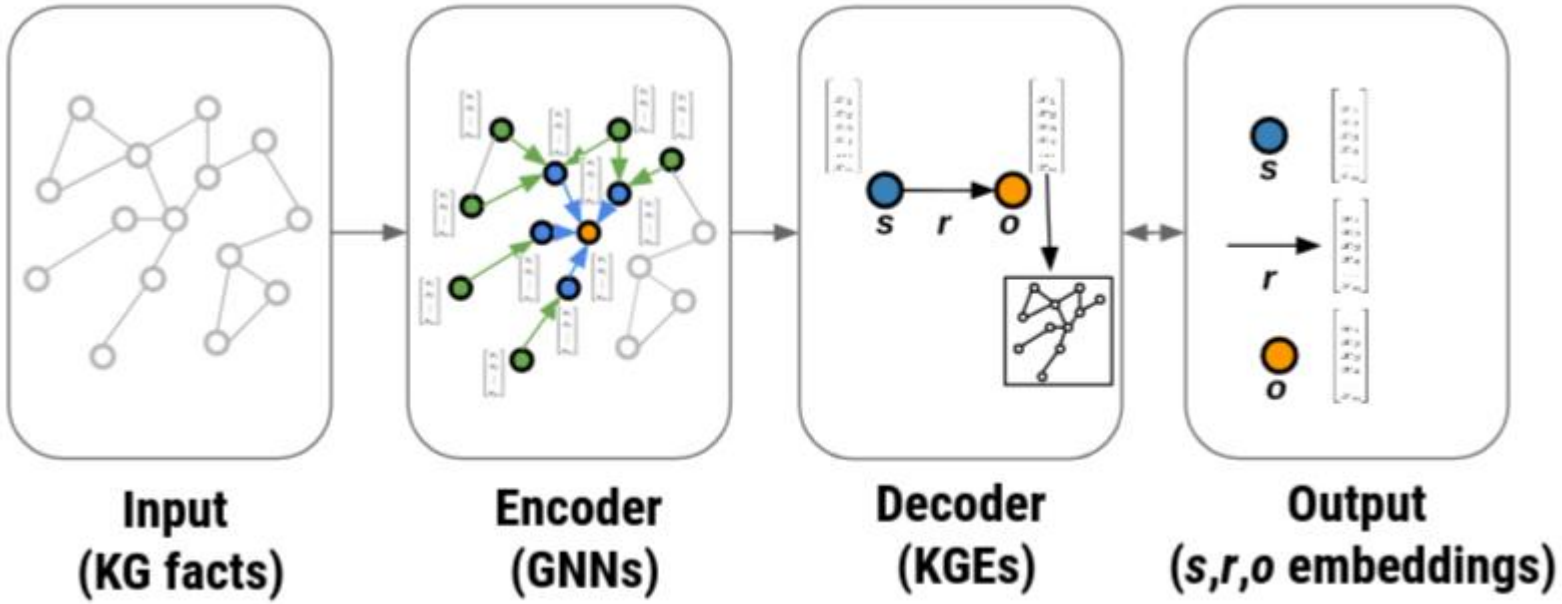

(Source :
Giuseppe Futia)

Sous le mot

- Subwords

school `{'sch', 'cho', 'hoo', 'ool', 'scho', 'choo', 'hool', 'schoo', 'chool', 'school'}` (n-grammes de caractères)

Puis agrégation des sous-mots en mots (somme des vecteurs)

- WordPieces

  - Un vocabulaire de taille prédéfinie, composé de n-grammes de caractères
  - Vocabulaire choisi pour maximiser la fréquence des n-grammes
  - Possibilité d'un tokenizer multilingue
  - Exemple (FlauBERT) :

```
nous uti ##lisons des mo ##deles de re ##presentation contextu ##elle
```

Bojanowski, P., Grave, E., Joulin, A., and Mikolov, T. (2017). Enriching word vectors with subword information. Transactions of the Association for Computational Linguistics, 5

Schuster, M., and Nakajima, K. Japanese and Korean voice search. 2012 IEEE International Conference on Acoustics, Speech and Signal Processing (2012).

Tâche : recherche vocale

- Recherche vocale : lancer des recherches web par la parole
- Utilisation de WordPiece pour gérer le vocabulaire infini, notamment dans des langues sans espaces

1. ” 京都 清水寺の写真” (original text)
2. ” 京都 清水寺 の写真” (after segmentation)
3. ” __京都__ __清水寺 の写真__” (after addition of under-scores, used for LM training, dictionary etc.)
4. ” __京都__ __清水寺 の写真__” (decoder result)
5. ” 京都 清水寺の写真” (displayed output)

Schuster, M., and Nakajima, K. Japanese and Korean voice search. 2012 IEEE International Conference on Acoustics, Speech and Signal Processing (2012).

Représentations denses en contexte

- Représentation statique : un token = un vecteur
  - On manipule une « matrice d'embeddings » (*N* x *d*)
  - Le vecteur du token est le même à chacune de ses occurrences dans le corpus

- Représentation contextuelle : calcul du vecteur en contexte
  - Le calcul de la représentation est intégré dans le modèle
  - Les mots précédents et suivants agissent sur la représentation (en général grâce à un mécanisme d'attention…)

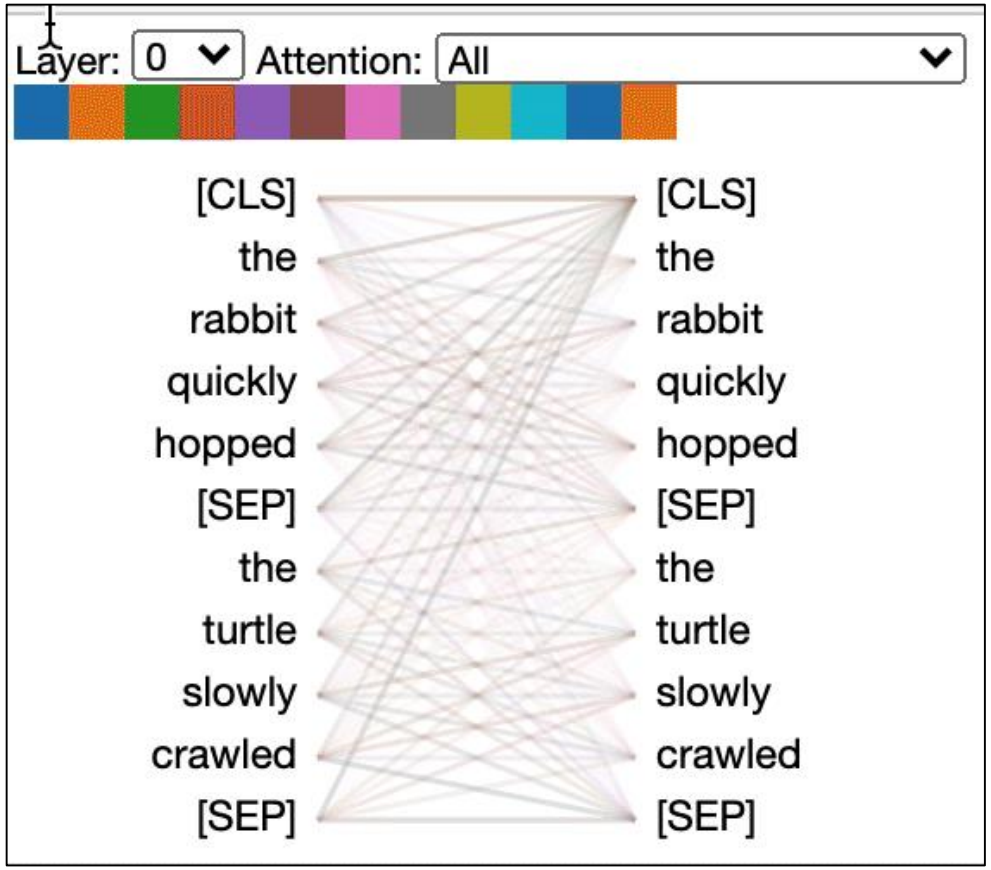

https://github.com/jessevig/bertviz/

Représentation contextuelle

Lisible par l'humain	👎
Sémantique explicite	👎
Dimensionalité	👍
Similarité sémantique	👍
Polysémie	👍
Variantes orthographiques	👍
Expressions multi-mots	👍
Mots inconnus	👍

Vecteur = quelques centaines de dimensions

Par construction, mais implicite

Modèle de langue

Ces modèles entrent dans la classe des *modèles de langue*.

Un modèle de langue est un modèle sans supervision manuelle, avec deux styles principaux d'entraînements différents :

- Prédire le mot suivant (*autoregressive models*, ex. GPT)
- Prédire des mots masqués dans une séquence (*masked language models*, MLM, ex. BERT).

Ces modèles sont au cœur de la grande majorité des systèmes de TAL à l'heure actuelle. On parle de LLM (*Large Language Models*).

Modèle de langue

Un modèle de langue est

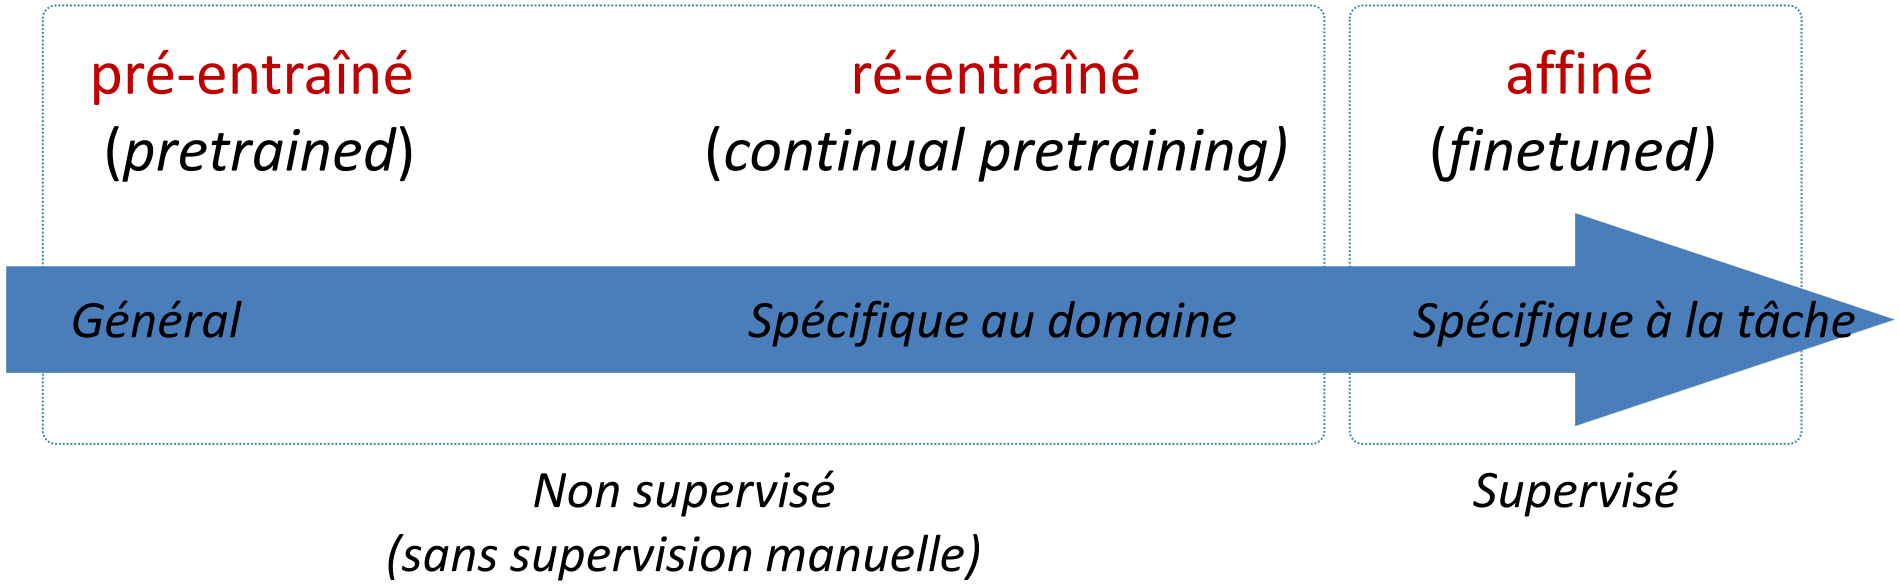

Modèle de langue

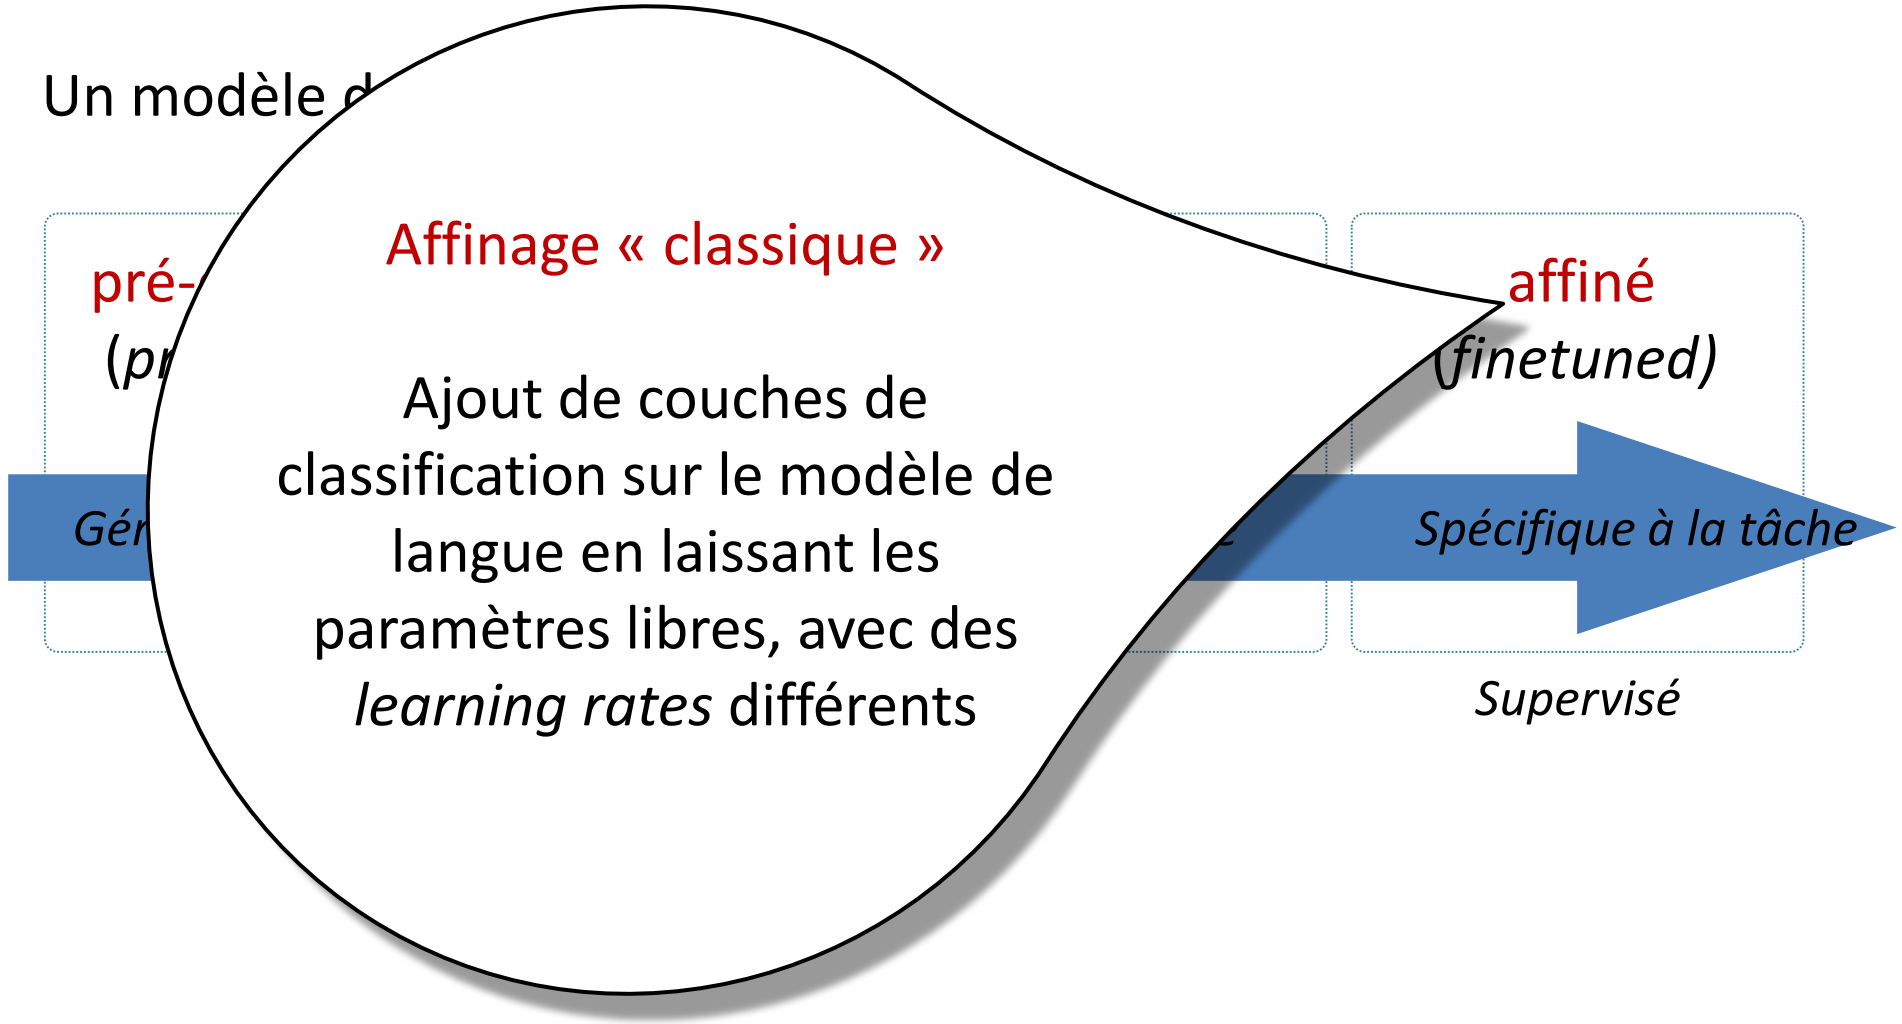

Modèle de langue

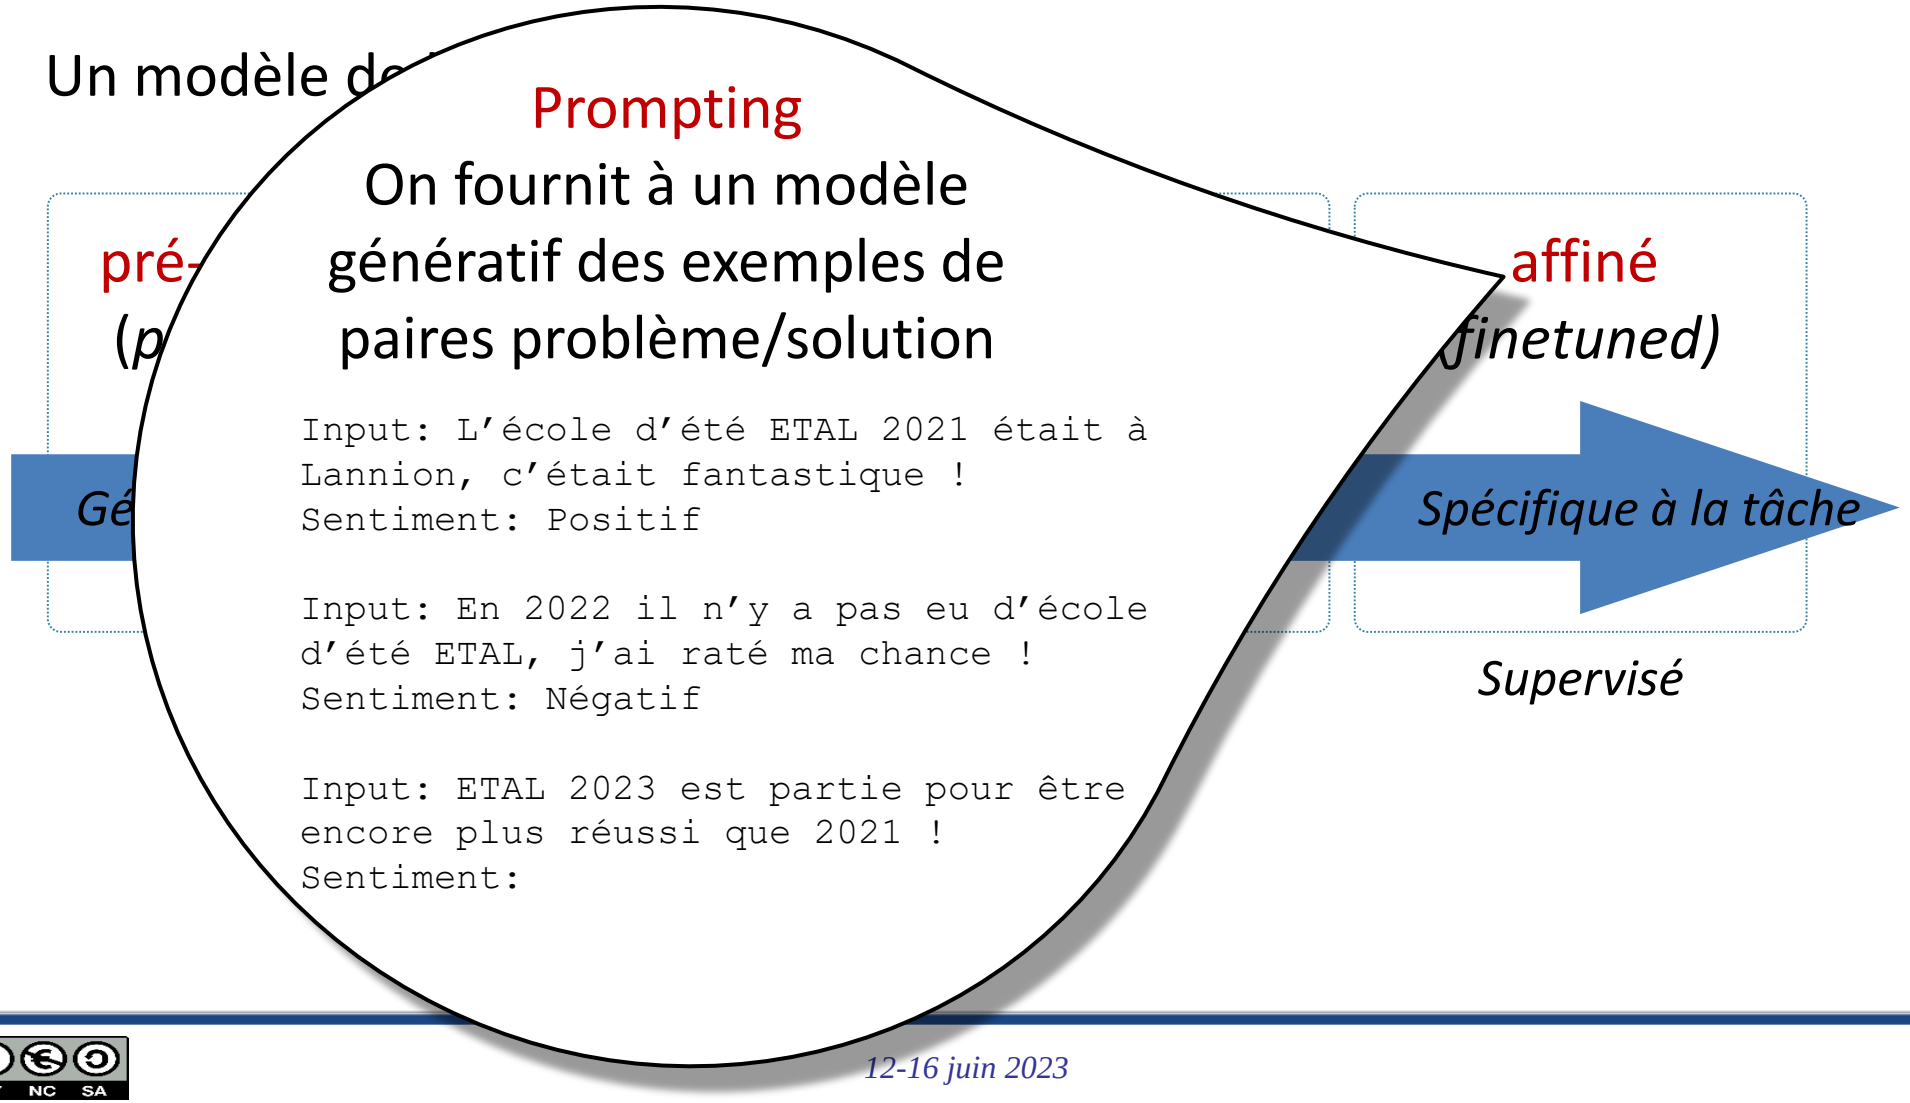

Modèle de langue

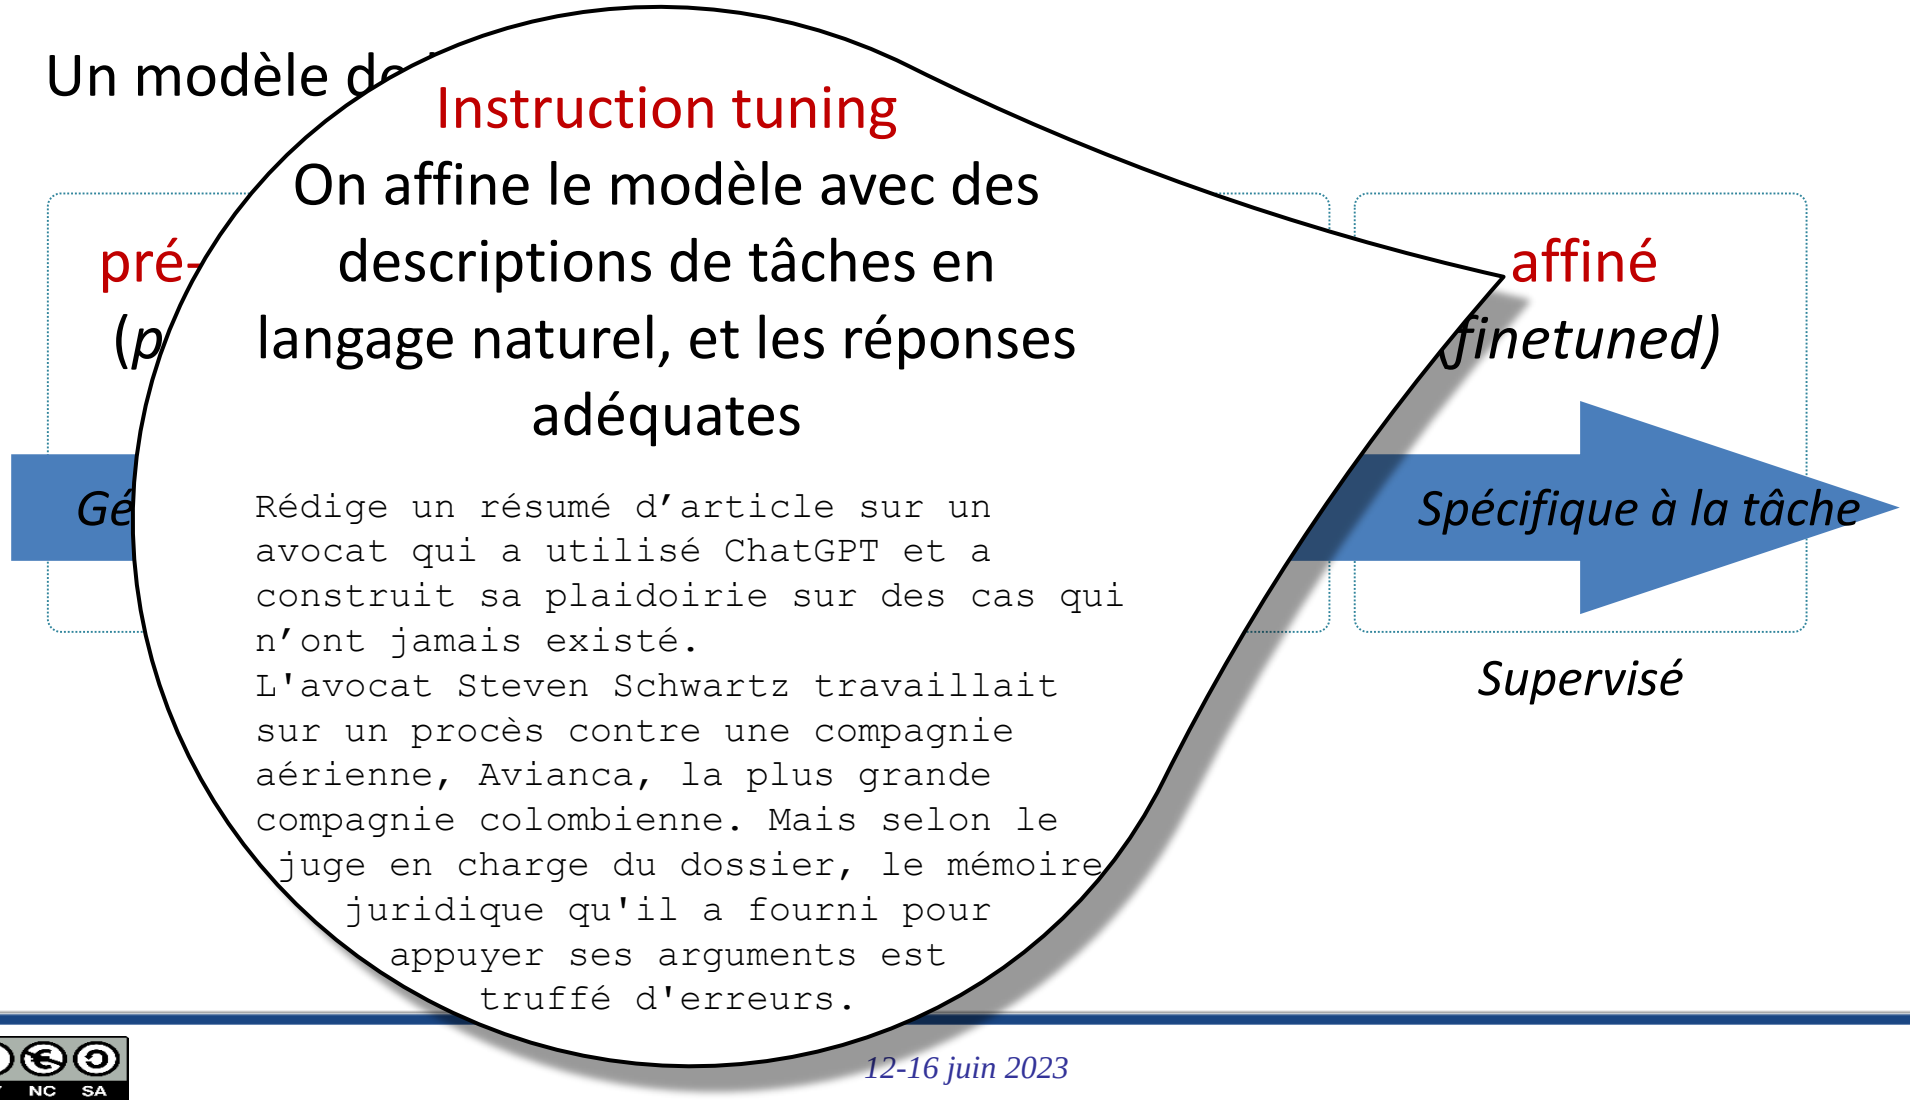

Modèle de langue

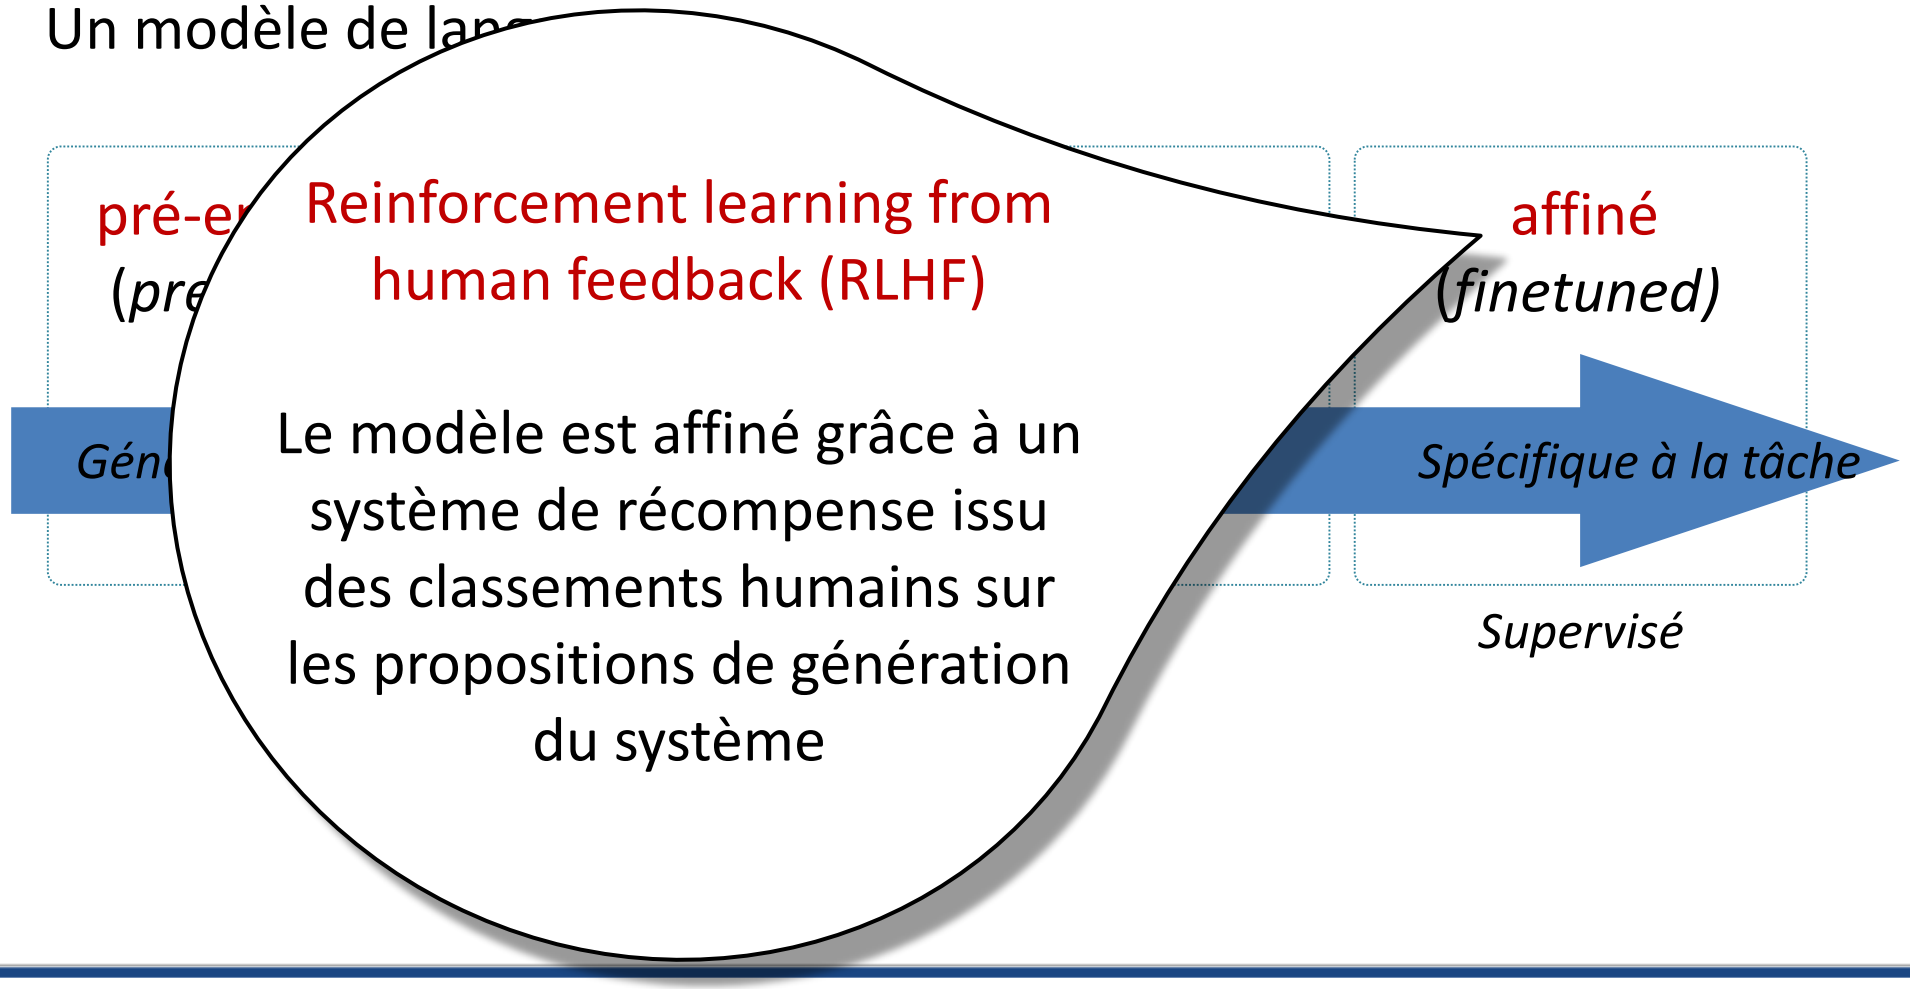

Modèle de langue

Questions :

- Sur quel jeu de données est entraîné/ré-entraîné le modèle de langue que vous utilisez ?
- Quels sont les biais potentiels que cela implique ?
- Votre tâche est-elle représentée de près ou de loin dans ce jeu de données ?
- Le jeu de données spécifiques à votre tâche a-t-il été impliqué dans l'entraînement/ré-entraînement du modèle de langue ?

Modèles de langue

https://en.wikipedia.org/wiki/Large_language_model (le 10 juin 2023)

Name	Release date[a]	Developer	Number of parameters[b]	Corpus size	License[c]	Notes
BERT	2018	Google	340 million[29]	3.3 billion words[29]	Apache 2.0[30]	An early and influential language model,[2] but encoder-only and thus not built to be prompted or generative[31]
XLNet	2019	Google	~340 million[32]	33 billion words		An alternative to BERT; designed as encoder-only[33][34]
GPT-2	2019	OpenAI	1.5 billion[35]	40GB[36] (~10 billion tokens)[37]	MIT[38]	general-purpose model based on transformer architecture
GPT-3	2020	OpenAI	175 billion[17]	300 billion tokens[37]	public web API	A fine-tuned variant of GPT-3, termed GPT-3.5, was made available to the public through a web interface called ChatGPT in 2022.[39]
GPT-Neo	March 2021	EleutherAI	2.7 billion[40]	825 GiB[41]	MIT[42]	The first of a series of free GPT-3 alternatives released by EleutherAI. GPT-Neo outperformed an equivalent-size GPT-3 model on some benchmarks, but was significantly worse than the largest GPT-3.[42]
GPT-J	June 2021	EleutherAI	6 billion[43]	825 GiB[41]	Apache 2.0	GPT-3-style language model

Modèles de langue

https://en.wikipedia.org/wiki/Large_language_model (le 10 juin 2023)

Megatron-Turing NLG	October 2021[44]	Microsoft and Nvidia	530 billion[45]	338.6 billion tokens[45]	Restricted web access	Standard architecture but trained on a supercomputing cluster.
Ernie 3.0 Titan	December 2021	Baidu	260 billion[46]	4 Tb	Proprietary	Chinese-language LLM. Ernie Bot is based on this model.
Claude[47]	December 2021	Anthropic	52 billion[48]	400 billion tokens[48]	Closed beta	Fine-tuned for desirable behavior in conversations.[49]
GLaM (Generalist Language Model)	December 2021	Google	1.2 trillion[50]	1.6 trillion tokens[50]	Proprietary	Sparse mixture-of-experts model, making it more expensive to train but cheaper to run inference compared to GPT-3.
Gopher	December 2021	DeepMind	280 billion[51]	300 billion tokens[52]	Proprietary	
LaMDA (Language Models for Dialog Applications)	January 2022	Google	137 billion[53]	1.56T words,[53] 168 billion tokens[52]	Proprietary	Specialized for response generation in conversations.
GPT-NeoX	February 2022	EleutherAI	20 billion[54]	825 GiB[41]	Apache 2.0	based on the Megatron architecture
Chinchilla	March 2022	DeepMind	70 billion[55]	1.4 trillion tokens[55][52]	Proprietary	Reduced-parameter model trained on more data. Used in the Sparrow bot.
PaLM (Pathways Language Model)	April 2022	Google	540 billion[56]	768 billion tokens[55]	Proprietary	aimed to reach the practical limits of model scale

Modèles de langue

https://en.wikipedia.org/wiki/Large_language_model (le 10 juin 2023)

OPT (Open Pretrained Transformer)	May 2022	Meta	175 billion[57]	180 billion tokens[58]	Non-commercial research[d]	GPT-3 architecture with some adaptations from Megatron
YaLM 100B	June 2022	Yandex	100 billion[59]	1.7TB[59]	Apache 2.0	English-Russian model based on Microsoft's Megatron-LM.
Minerva	June 2022	Google	540 billion[60]	38.5B tokens from webpages filtered for mathematical content and from papers submitted to the arXiv preprint server[60]	Proprietary	LLM trained for solving "mathematical and scientific questions using step-by-step reasoning".[61] Minerva is based on PaLM model, further trained on mathematical and scientific data.
BLOOM	July 2022	Large collaboration led by Hugging Face	175 billion[62]	350 billion tokens (1.6TB)[63]	Responsible AI	Essentially GPT-3 but trained on a multi-lingual corpus (30% English excluding programming languages)
Galactica	November 2022	Meta	120 billion	106 billion tokens[64]	CC-BY-NC-4.0	Trained on scientific text and modalities.
AlexaTM (Teacher Models)	November 2022	Amazon	20 billion[65]	1.3 trillion[66]	public web API[67]	bidirectional sequence-to-sequence architecture

Modèles de langue

https://en.wikipedia.org/wiki/Large_language_model (le 10 juin 2023)

LLaMA (Large Language Model Meta AI)	February 2023	Meta	65 billion[68]	1.4 trillion[68]	Non-commercial research[e]	Trained on a large 20-language corpus to aim for better performance with fewer parameters.[68] Researchers from Stanford University trained a fine-tuned model based on LLaMA weights, called Alpaca.[69]
GPT-4	March 2023	OpenAI	Exact number unknown, approximately 1 trillion [f]	Unknown	public web API	Available for ChatGPT Plus users and used in several products.
Cerebras-GPT	March 2023	Cerebras	13 billion[71]		Apache 2.0	Trained with Chinchilla formula.
Falcon	March 2023	Technology Innovation Institute	40 billion[72]	1 Trillion tokens (1TB)[72]	Apache 2.0[73]	The model is claimed to use only 75% of GPT-3's training compute, 40% of Chinchilla's, and 80% of PaLM-62B's.
BloombergGPT	March 2023	Bloomberg L.P.	50 billion	363 billion token dataset based on Bloomberg's data sources, plus 345 billion tokens from general purpose datasets[74]	Proprietary	LLM trained on financial data from proprietary sources, that "outperforms existing models on financial tasks by significant margins without sacrificing performance on general LLM benchmarks"

Modèles de langue

https://en.wikipedia.org/wiki/Large_language_model (le 10 juin 2023)

PanGu-Σ	March 2023	Huawei	1.085 trillion	329 billion tokens[75]	Proprietary	
OpenAssistant[76]	March 2023	LAION	17 billion	1.5 trillion tokens	Apache 2.0	Trained on crowdsourced open data
PaLM 2 (Pathways Language Model 2)	May 2023	Google	340 billion[77]	3.6 trillion tokens[77]	Proprietary	Used in Bard chatbot.[78]

Du mot à la phase

Pondération des mots

- Dans un document, dans une requête, dans une question, les termes n'ont pas tous la même importance

- **Intuition #1** : plus un document contient d'occurrences d'un terme, plus il est "à propos" de ce terme (plus il sera pertinent par rapport à une requête contenant ce terme)

$$tf_{t,d} = \text{nombre d'occurrences du terme } t \text{ dans le document } d$$

Pondération des mots : la matrice des présences

	Antoine & Cléopâtre	Jules César	La Tempête	Hamlet	Othello	Macbeth
Antoine	1	1	0	0	0	0
Brutus	1	1	0	1	0	0
César	1	1	0	1	1	1
Calpurnia	0	1	0	0	0	0
Cléopâtre	1	0	0	0	0	0
pitié	1	0	1	1	1	1
pire	1	0	1	1	1	0

Pondération des mots : la matrice des fréquences

	Antoine & Cléopâtre	Jules César	La Tempête	Hamlet	Othello	Macbeth
Antoine	157	73	0	0	0	0
Brutus	4	157	0	1	0	0
César	232	227	0	2	1	1
Calpurnia	0	10	0	0	0	0
Cléopâtre	57	0	0	0	0	0
pitié	2	0	3	5	5	1
pire	2	0	1	1	1	0

Chaque document est un vecteur v dans $\mathbb{N}^{|v|}$

Pondération des mots

- **Intuition #2** : des termes très fréquents dans tous les documents ne sont pas si importants (ils sont moins ***discriminants***)
- On compense donc la fréquence des termes dans les documents (tf) en prenant en compte leur fréquence dans la collection (df)

$$df_t = \text{nombre de documents qui contiennent le terme } t$$

$$\boldsymbol{idf_t = log_{10} \frac{N}{df_t}} \quad (N = \text{nombre total de documents})$$

Pondération des mots

- Le **poids** d'un terme (*tf.idf*) est la combinaison de ces deux intuitions pour rendre compte du caractère discriminant d'un terme dans un document

$$w_{t,d} = tf_{t,d} \times idf_t$$

$$= tf_{t,d} \times log_{10} \frac{N}{df_t}$$

ou $w_{t,d} = log\_tf_{t,d} \times log_{10} \frac{N}{df_t}$

- Le poids d'un terme *t* :
  - augmente avec sa fréquence dans le document
  - augmente avec sa rareté dans la collection de documents

Pondération des mots : la matrice des poids

	Antoine & Cléopâtre	Jules César	La Tempête	Hamlet	Othello	Macbeth
Antoine	13,1	11,4	0	0	0	0
Brutus	3,0	8,3	0	1	0	0
César	2,3	2,3	0	0,5	0,3	0,3
Calpurnia	0	11,2	0	0	0	0
Cléopâtre	17,7	0	0	0	0	0
pitié	0,5	0	0,7	0,9	0,9	0,3
pire	1,2	0	0,6	0,6	0,6	0

Chaque document est un vecteur v dans $\mathbb{R}^{|v|}$

De nombreuses variantes existent !

Du mot à la phrase : les syntagmes

- Les **syntagmes** (ou **constituants**) sont qualifiés par le type de l'élément principal (la **tête**). On a donc des syntagmes :
  - **nominaux** *(le loup, Paul, l'homme qui valait 3 millions)*
  - **verbaux** (*vendra, valait 3 millions)*
  - **adjectivaux** (*rouge, [une classe] pleine d'étudiants)*
  - **adverbiaux** (*bien, conformément à la loi)*
  - on parle aussi de syntagmes **prépositionnels** ([le chat] *de ma mère*)
- Les autres éléments sont :
  - les ***spécifieurs*** *(déterminants...)*
  - les ***qualificateurs*** *(adjectifs, adverbes...)*
  - les ***compléments*** *(compléments du nom, propositions relatives...)*
- Un syntagme a la même fonction que sa tête dans la phrase

Du mot à la phrase : les syntagmes

- Les syntagmes de même type sont syntaxiquement **substituables** entre eux...

{ Le loup / Paul / Il / L'homme qui a vu l'ours / Le petit chaperon rouge / La fille de Minos et de Pasiphaé } sort de la forêt.

- Les syntagmes peuvent s'imbriquer les uns dans les autres :

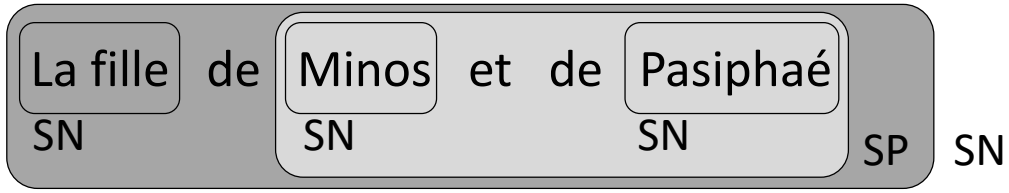

Chunking

- [*Les gendarmes*] [*interpellent*] [*un conducteur*] [*en état d'ivresse.*]

- Pas d'analyse de la structure interne
- **Pas de liens de dépendances** entre les ***chunks***
- Les ambiguïtés de rattachement sont implicites

- [*Bill*] [*vit*] [*l'homme*] [*sur la colline*] [*avec un télescope.*]

Tâche : extraction de termes

N…, âgé de **40 ans**, a consulté pour une **symptomatologie mictionnelle sévère, irritative et obstructive**. On notait dans ses **antécédents** une **orchidectomie droite** pour **ectopie testiculaire** à l'âge de **10 ans**, une **lobectomie thyroïdienne gauche** après **irradiation nucléaire accidentelle**.
Ce patient était adressé en **consultation d'Urologie** avec une **échographie de l'appareil urinaire**.

- Les termes sont en général des groupes nominaux
- Peut permettre :
  - d'indexer des n-grammes pertinents
  - de créer une terminologie/ontologie basée sur les corpus
  - de rechercher des traductions plus précises
  - de faciliter l'analyse syntaxique
  - …

Les entités nommées

- Les **entités nommées** sont des éléments qu'il est intéressant de pouvoir distinguer du reste du texte :
  - Entités : **personnes**, **organisations**, **lieux**
  - Dates : **dates**, **heures**
  - Quantités : **montants financiers**, **pourcentages**, **etc.**

- **Reconnaissance** des entités nommées :
  - **Identifier** ces unités dans un texte
  - Les **catégoriser**
  - Éventuellement, les **normaliser** *(entity linking)*

Entités nommées

Identification

Le joueur de tennis américain John McEnroe a déclaré samedi sur ESPN que Gaël Monfils n'était pas assez professionnel. « Monfils aurait déjà dû gagner 4 ou 5 majeurs », a-t-il précisé.

Entités nommées

Catégorisation

personne *date*

Le joueur de tennis américain John McEnroe a déclaré samedi

organisation *personne*

sur ESPN que Gaël Monfils n'était pas assez professionnel.

personne

« Monfils aurait déjà dû gagner 4 ou 5 majeurs », a-t-il précisé.

Entités nommées

Normalisation

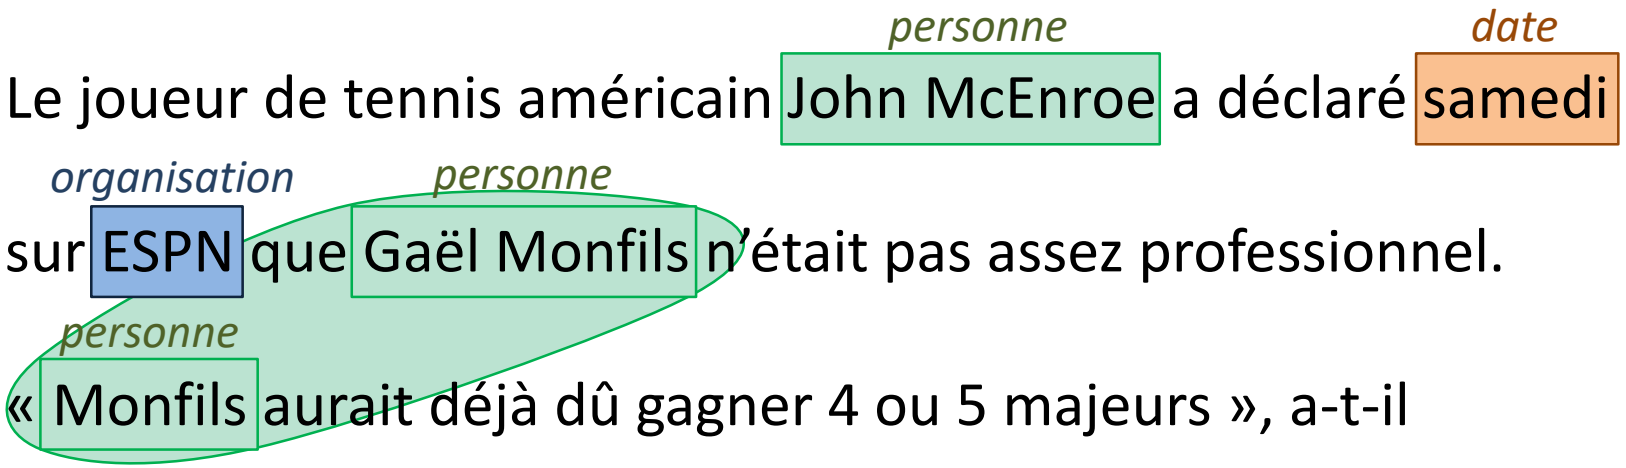

Entités nommées

Normalisation

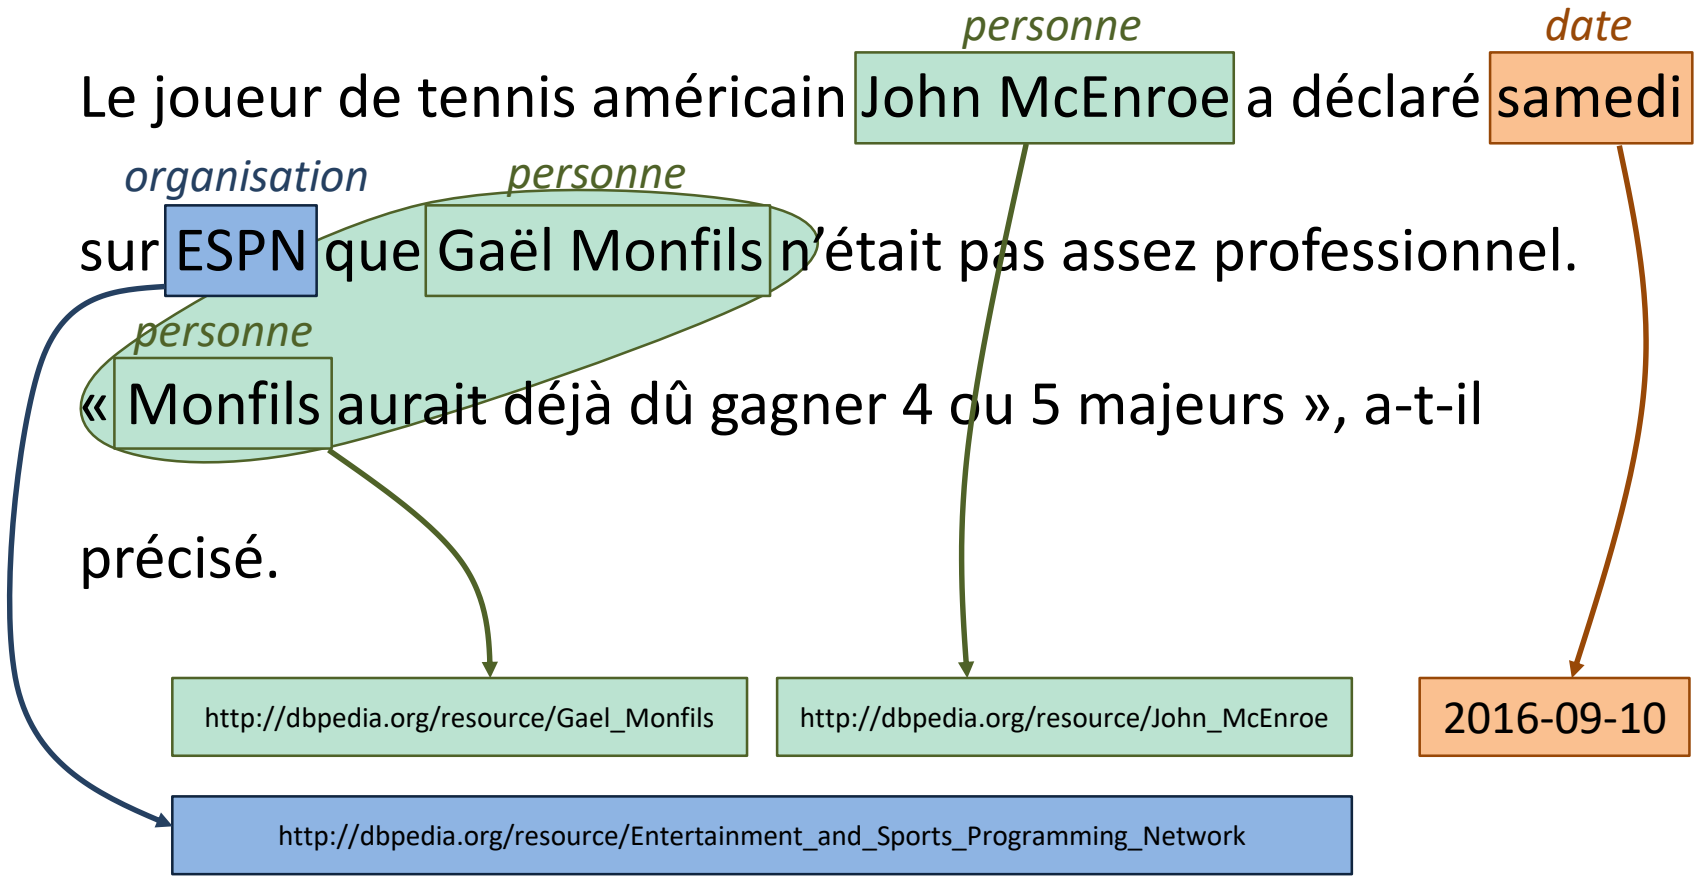

Entités nommées

Plus de précision ?

fonction *pers:sportif* *date:jour*

Le joueur de tennis américain John McEnroe a déclaré samedi

org:TV *pers:sportif*

sur ESPN que Gaël Monfils n'était pas assez professionnel.

pers:sportif *evt:tournoi*

« Monfils aurait déjà dû gagner Rolland-Garros », a-t-il

précisé.

Entités nommées

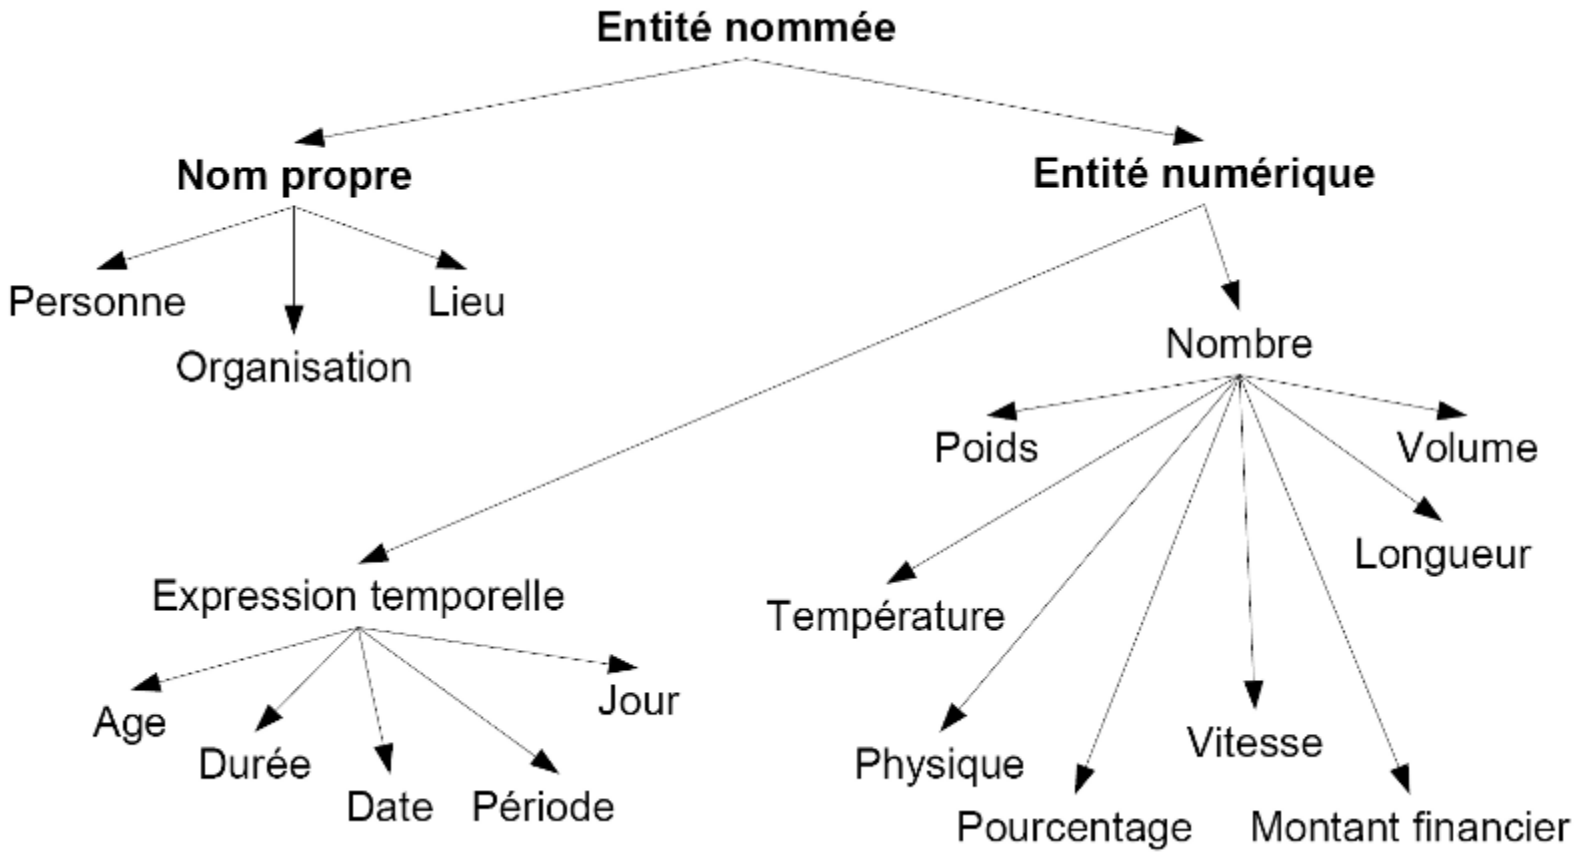

Tâche : Désidentification

Cher Confrère,

Votre patiente madame [redacted], âgée de [redacted], née le [redacted], a été hospitalisée aux soins intensifs de cardiologie le [redacted] pour la prise en charge d'un syndrome douloureux thoracique.

Les principaux antécédents de cette patiente sont représentés par :
- une thyroïdectomie en [redacted].
- une hystérectomie en [redacted].
- un stripping des varices en [redacted].
- une hernie discale en [redacted].

Ses principaux facteurs de risque cardio-vasculaire sont représentés par une hypertension artérielle traitée par ATACAND, une dyslipidémie non traitée, un tabagisme estimé à 5 paquets année, et une légère surcharge pondérale ([redacted] pour [redacted]).

Tâche : *entity linking*

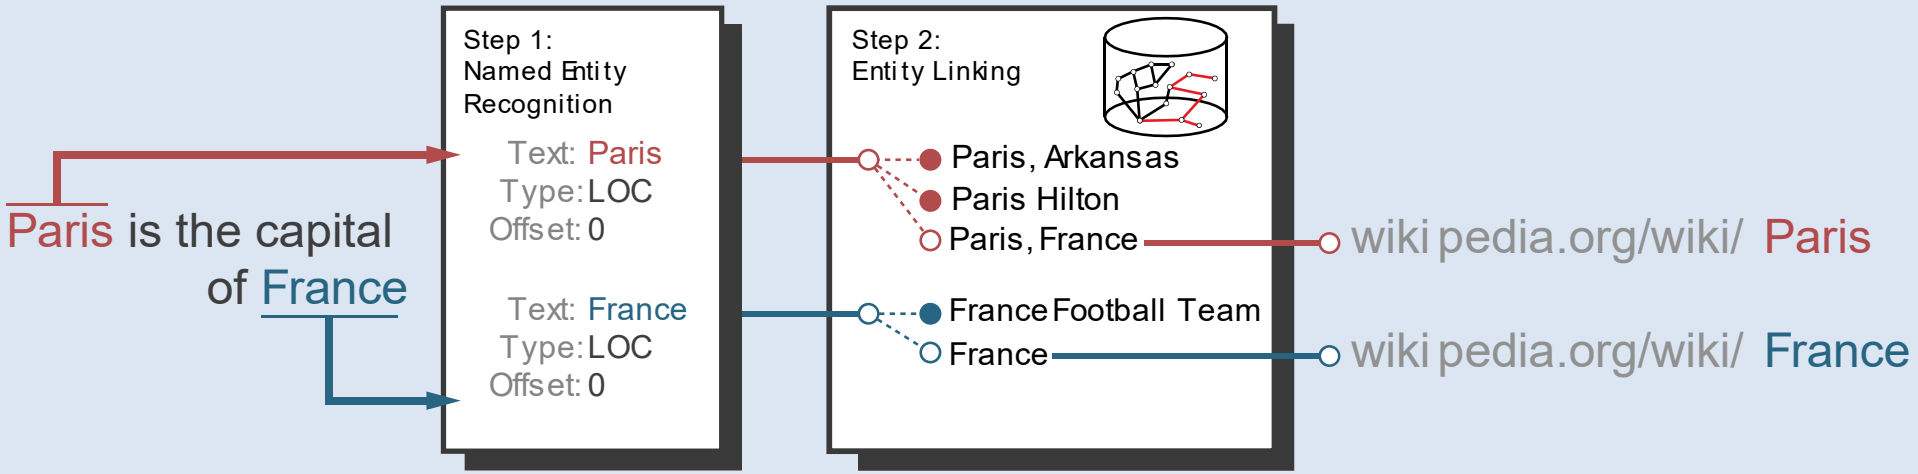

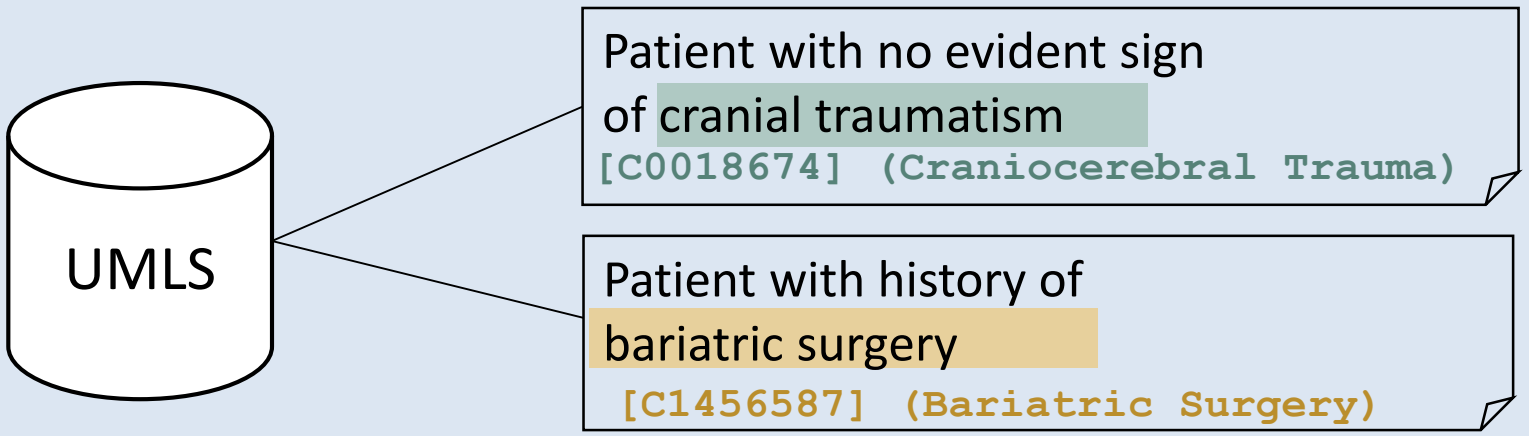

La phrase

- Une ou plusieurs ***propositions*** :
  - *Deux pigeons s'aimaient d'amour tendre.*
  - *Deux sûretés valent mieux qu'une, et le trop en cela ne fut jamais perdu.* (coordination)
  - *Vous savez que nul n'est prophète en son pays.* (subordination)

- Une succession de phrases forment le ***discours***.

Les fonctions grammaticales

- Le rôle *syntaxique* que joue un constituant par rapport à un autre
- Dépend surtout des positions relatives dans l'énoncé :

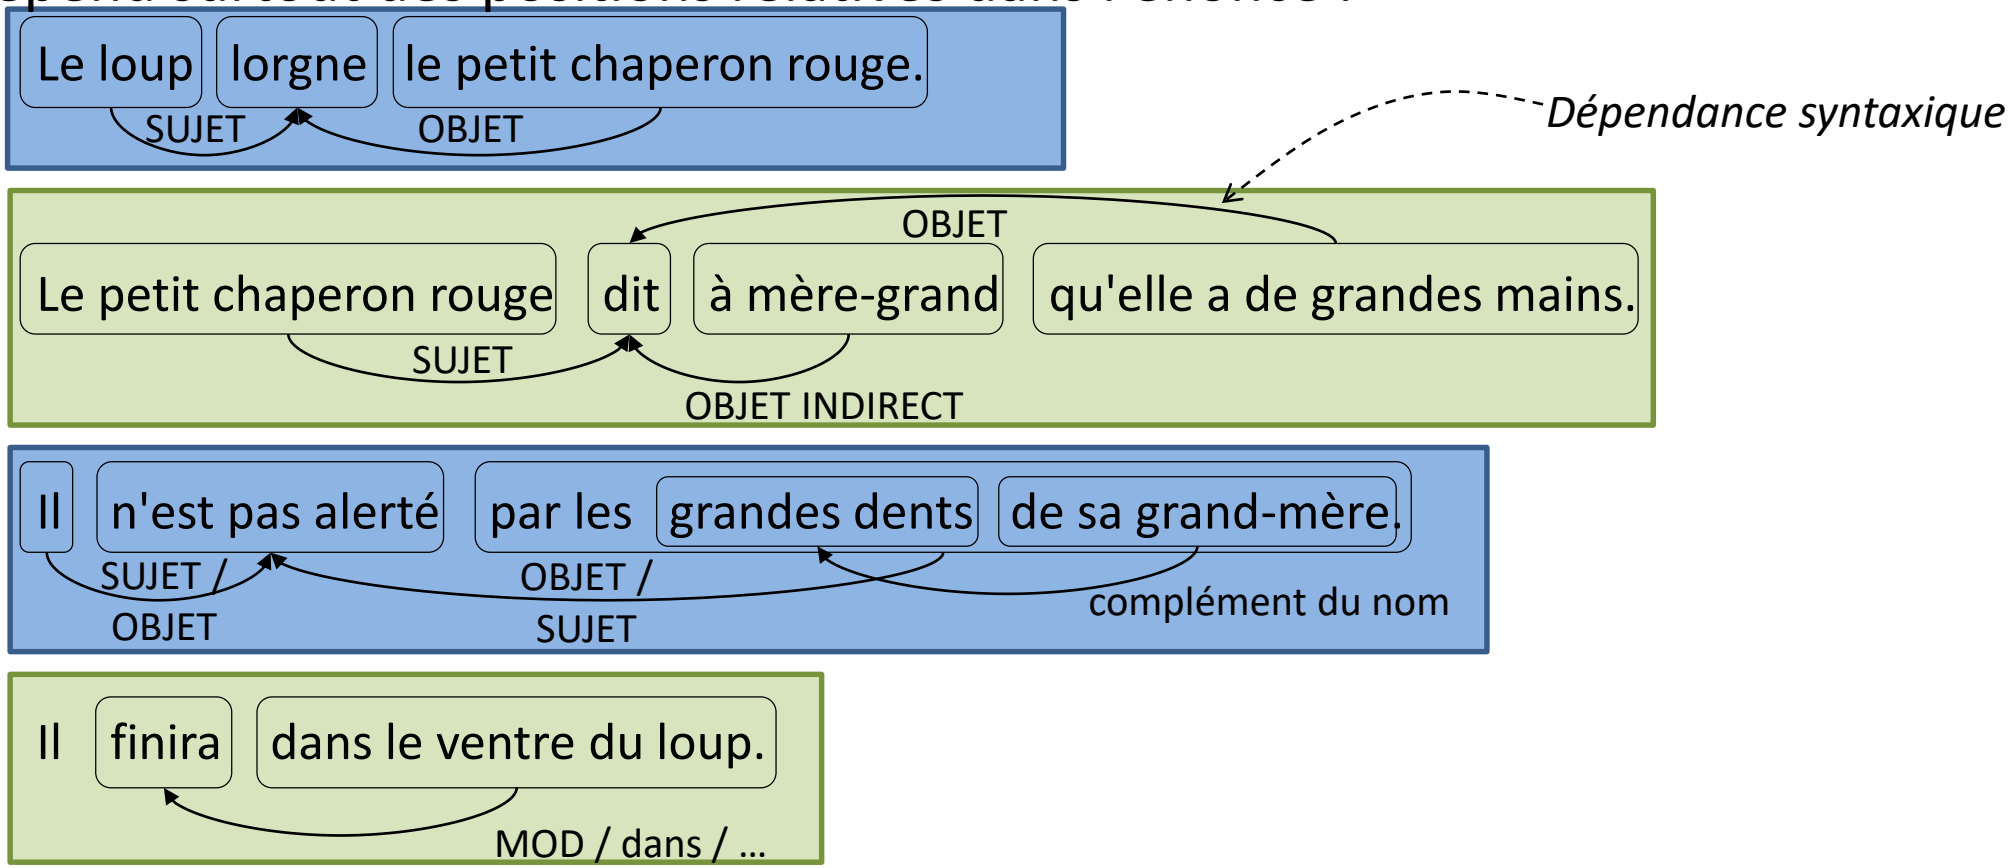

Tâche : analyse syntaxique sur des transcriptions de dialogues oraux, pour l'extraction d'information

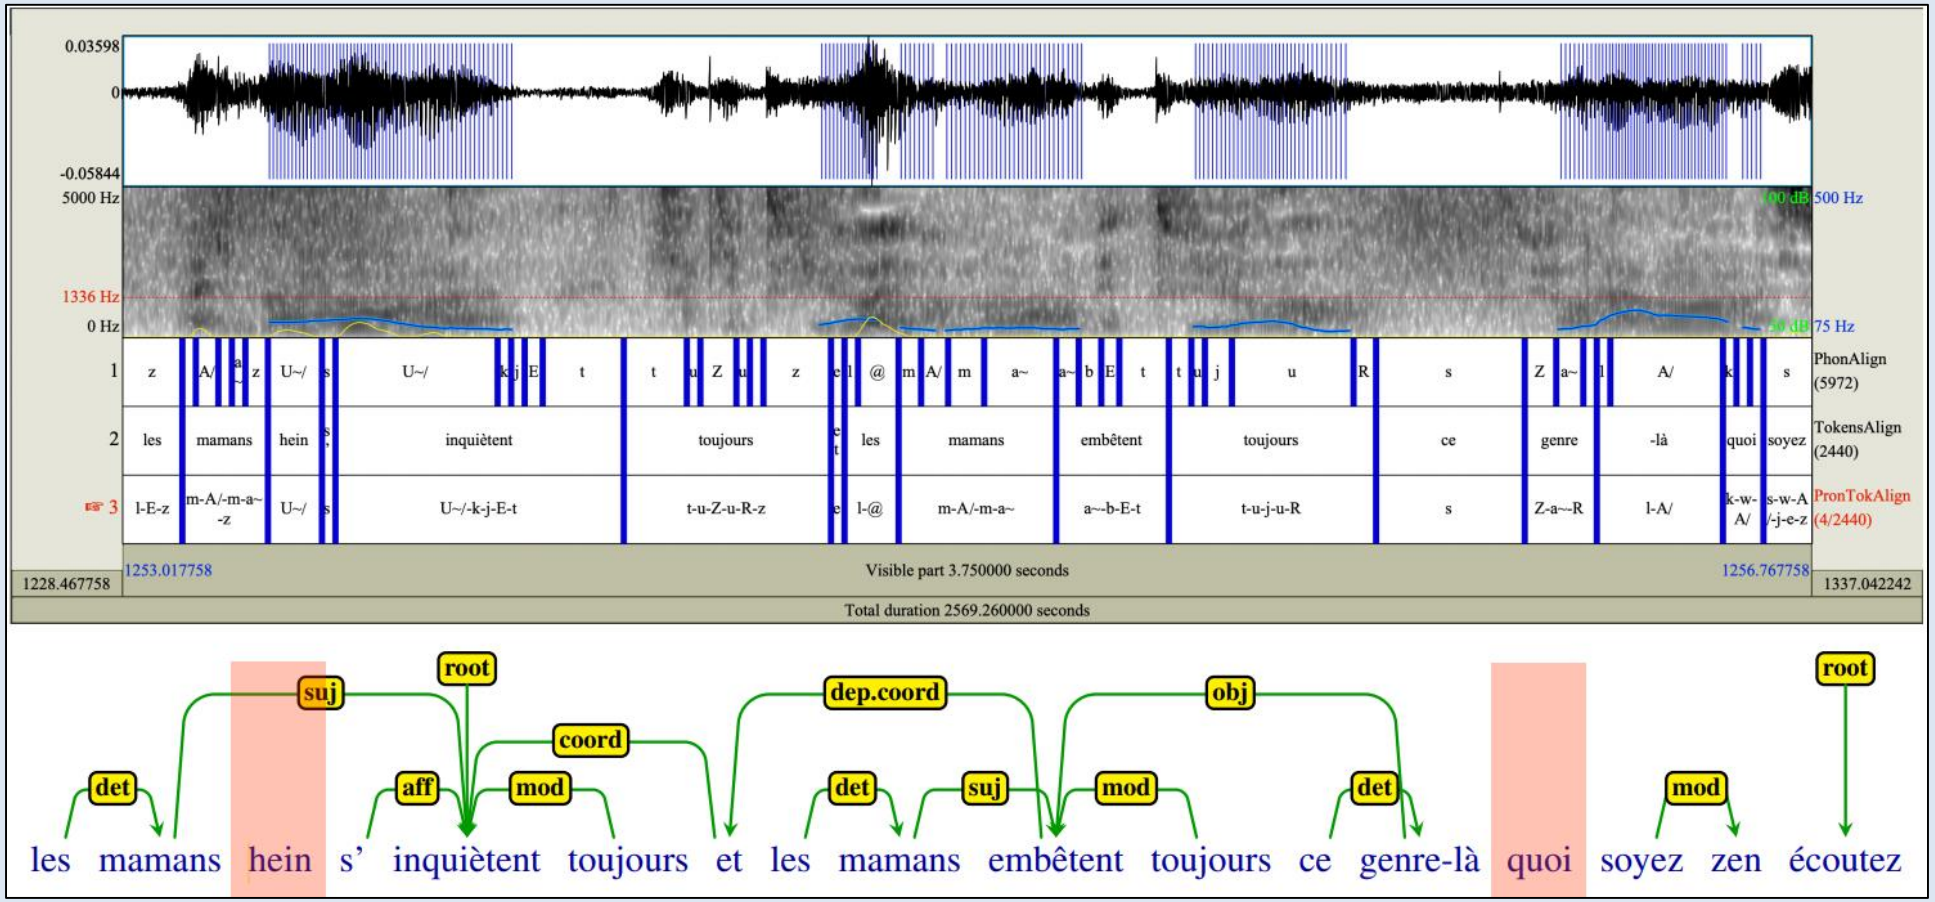

Yannis Haralambous, Christophe Lemey, Philippe Lenca, Romain Billot, Deok-Hee Kim-Dufor.
Using Dependency Syntax-Based Methods for Automatic Detection of Psychiatric Comorbidities.
Resources and ProcessIng of linguistic, para-linguistic and extra-linguistic Data from people with various forms of cognitive/psychiatric/developmental impairments, May 2020, Marseille, France.

Les ambiguïtés syntaxiques

- On peut les classer selon les connaissances nécessaires pour la désambiguïsation
- Connaissances **pragmatiques**
  - *Jean a rapporté un vase de Chine.*
  - *Jean a rapporté un vase de Chine (des puces de St-Ouen).*
- Connaissances **sémantiques**
  - *Jean vend une tarte aux pommes.*
  - *Jean vend une tarte aux clients.*
- Connaissances **syntaxiques**
  - *Un jus d'oranges fraîches.*
  - *Un jus d'oranges frais.*
- Parfois des centaines de combinaisons possibles pour une phrase.

Tâche : correction syntaxique

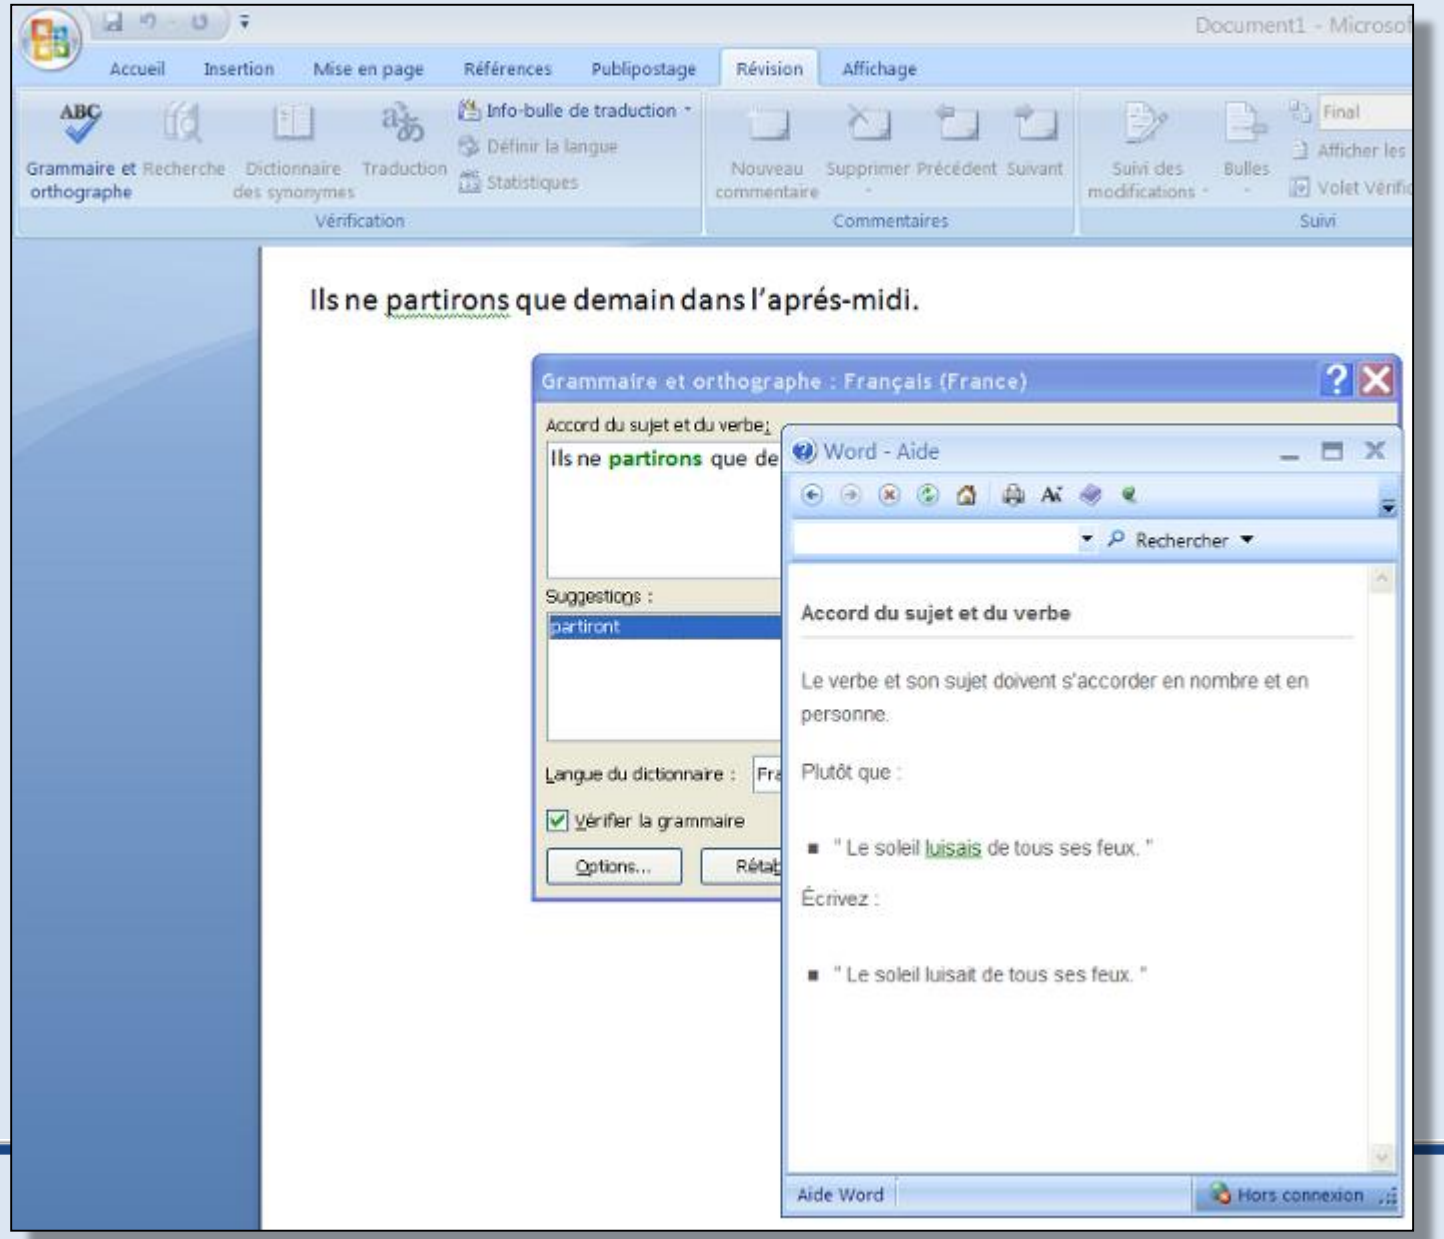

Relations sémantiques

- Les relations sémantiques considérées dans la littérature sont très diverses :
  - Causalité
  - Temps, espace
  - Possession, production, instrument
  - Manière, moyen
  - Sujet
  - Propriété, bénéficiaire
  - Mesure
  - …

Barker K. and Szpakowicz S 1998. Semi-automatic recognition of noun modifier relationships. In Proc. of the 36th Annual Meeting of the ACL and 17th International Conference on Computational Linguistics (COLING/ACL-98), pages 96-102, Montreal, Canada

D. Moldovan and R. Girju. 2001. An Interactive Tool For The Rapid Development of Knowledge
Bases. In International Journal on Artificial Intelligence Tools (IJAIT).

Relations sémantiques : l'exemple de SemEval 2010, tâche 10

Cause-Effect	those **cancers** were caused by radiation **exposures**
Instrument-Agency	**phone operator**
Product-Producer	a **factory** manufactures **suits**
Content-Container	a **bottle** full of **honey** was weighed
Entity-Origin	**letters** from foreign **countries**
Entity-Destination	the **boy** went to **bed**
Component-Whole	my **apartment** has a large **kitchen**
Member-Collection	there are many **trees** in the **forest**
Message-Topic	the **lecture** was about **semantics**

Iris Hendrickx et al.
SemEval-2010 Task 8: Multi-Way Classification of Semantic Relations between Pairs of Nominals
Proceedings of the 5th International Workshop on Semantic Evaluation

Au-delà de la phrase

La coréférence

- Coréférence pronominale
  - *Jacques$_1$ était furieux. **Il$_1$** s'était disputé avec Georges.*
  - *Dominique$_1$ rencontra Collins$_2$ à un congrès. **Ils$_{1+2}$** se réconcilièrent.*
  - *Nicolas$_1$ rencontra Dominique$_2$ dans un couloir. **Il$_?$** **lui$_?$** en voulait toujours.*
  - *Pierre$_1$ empoisonna Sam2. **Il$_2$** mourut.*
  - *Pierre$_1$ empoisonna Sam2. **Il$_1$** fut arrêté.*
  - *Si votre bébé ne supporte pas le lait cru, faîtes-**le** bouillir.*
- Autres
  - *La cage du gorille s'ouvrit. **Sa** serrure devait être mal fermée.*
  - *Le gorille accéléra le pas vers le juge. **Le quadrumane** avait une idée derrière la tête.*
  - *Je ne peux donner la suite de l'histoire. **Cela** serait pourtant délectable.*

Extraction d'information

Extraction d'entités, extraction de relations

Un **séisme** de magnitude **6,9** a secoué **hier** le **nord-ouest de la Birmanie.**

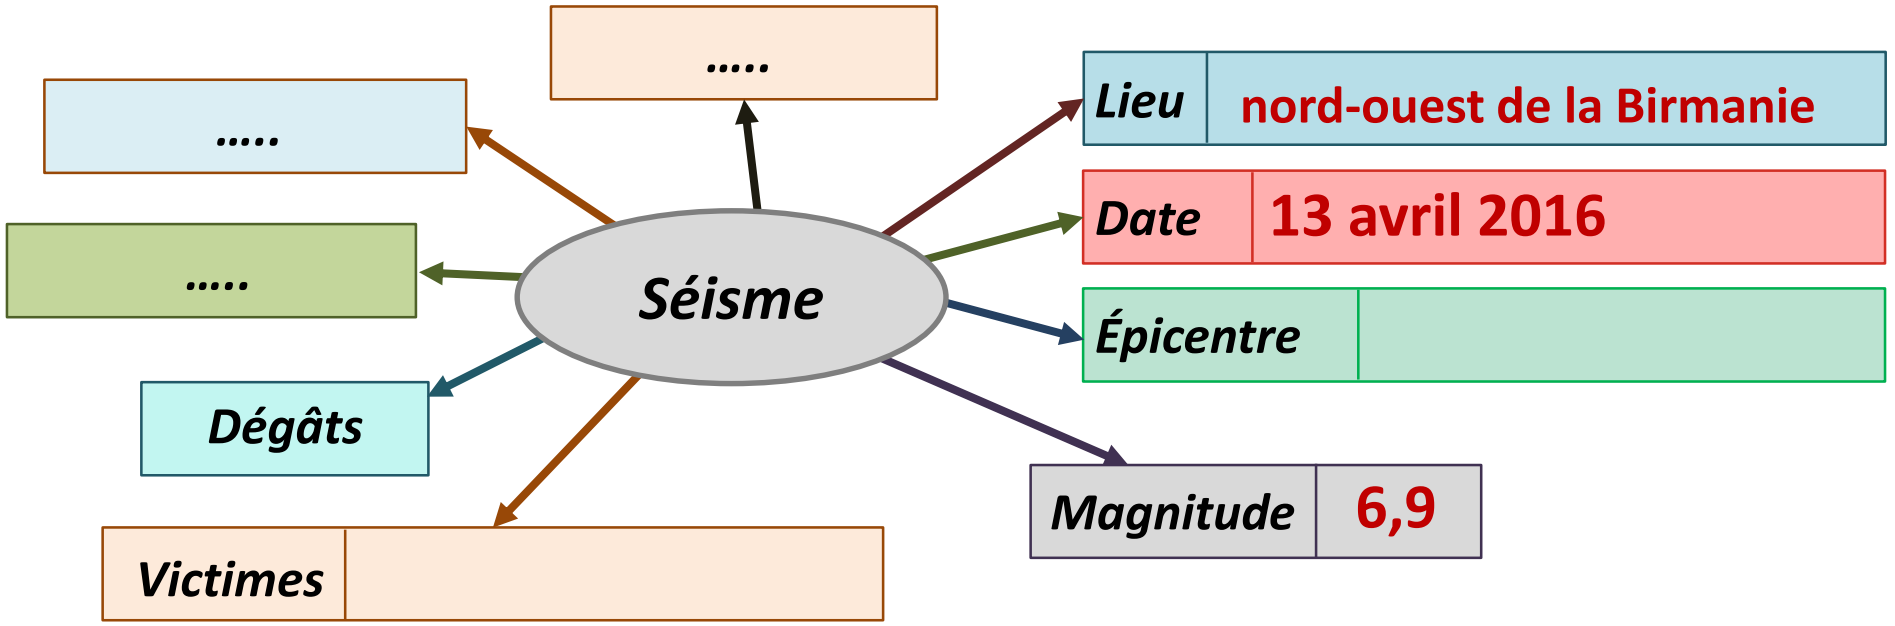

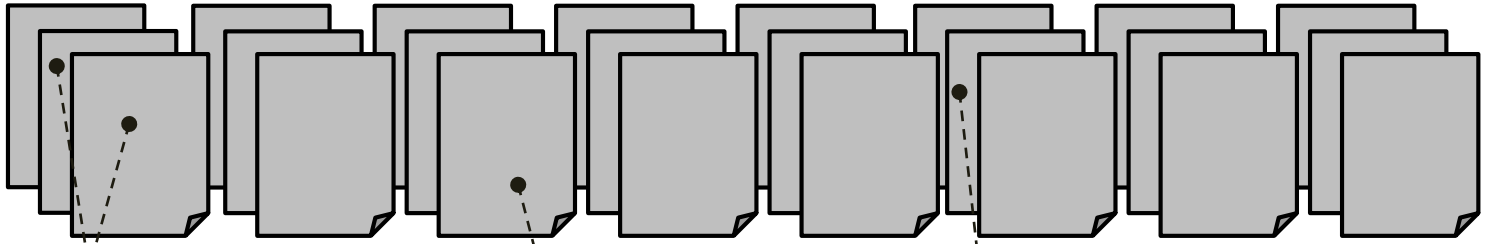

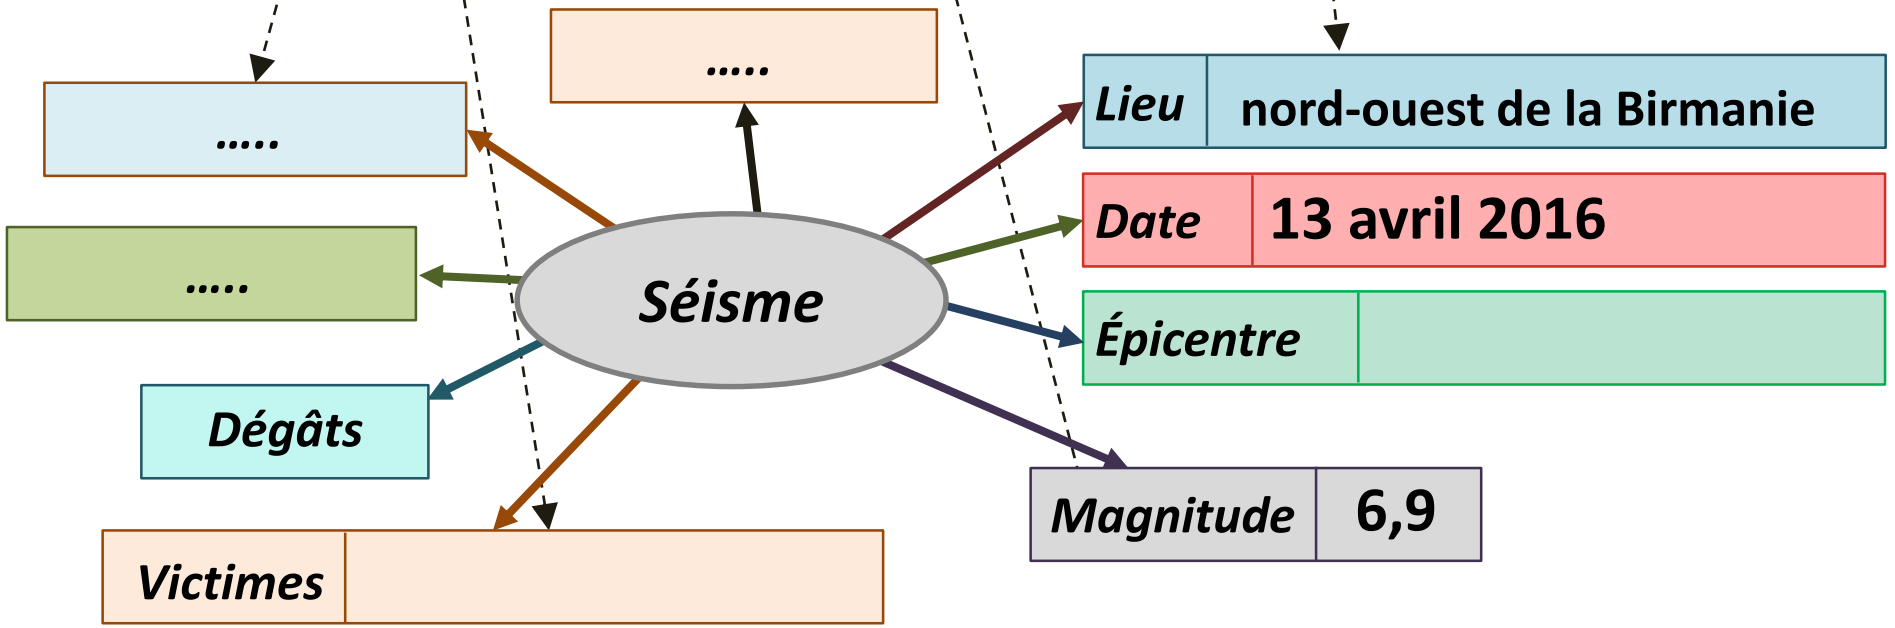
.....
.....
.....
Séisme
Dégâts
Victimes
Lieu
nord-ouest de la Birmanie
Date
13 avril 2016
Épicentre
Magnitude
6,9

Classification de texte

Spam ou pas spam ?

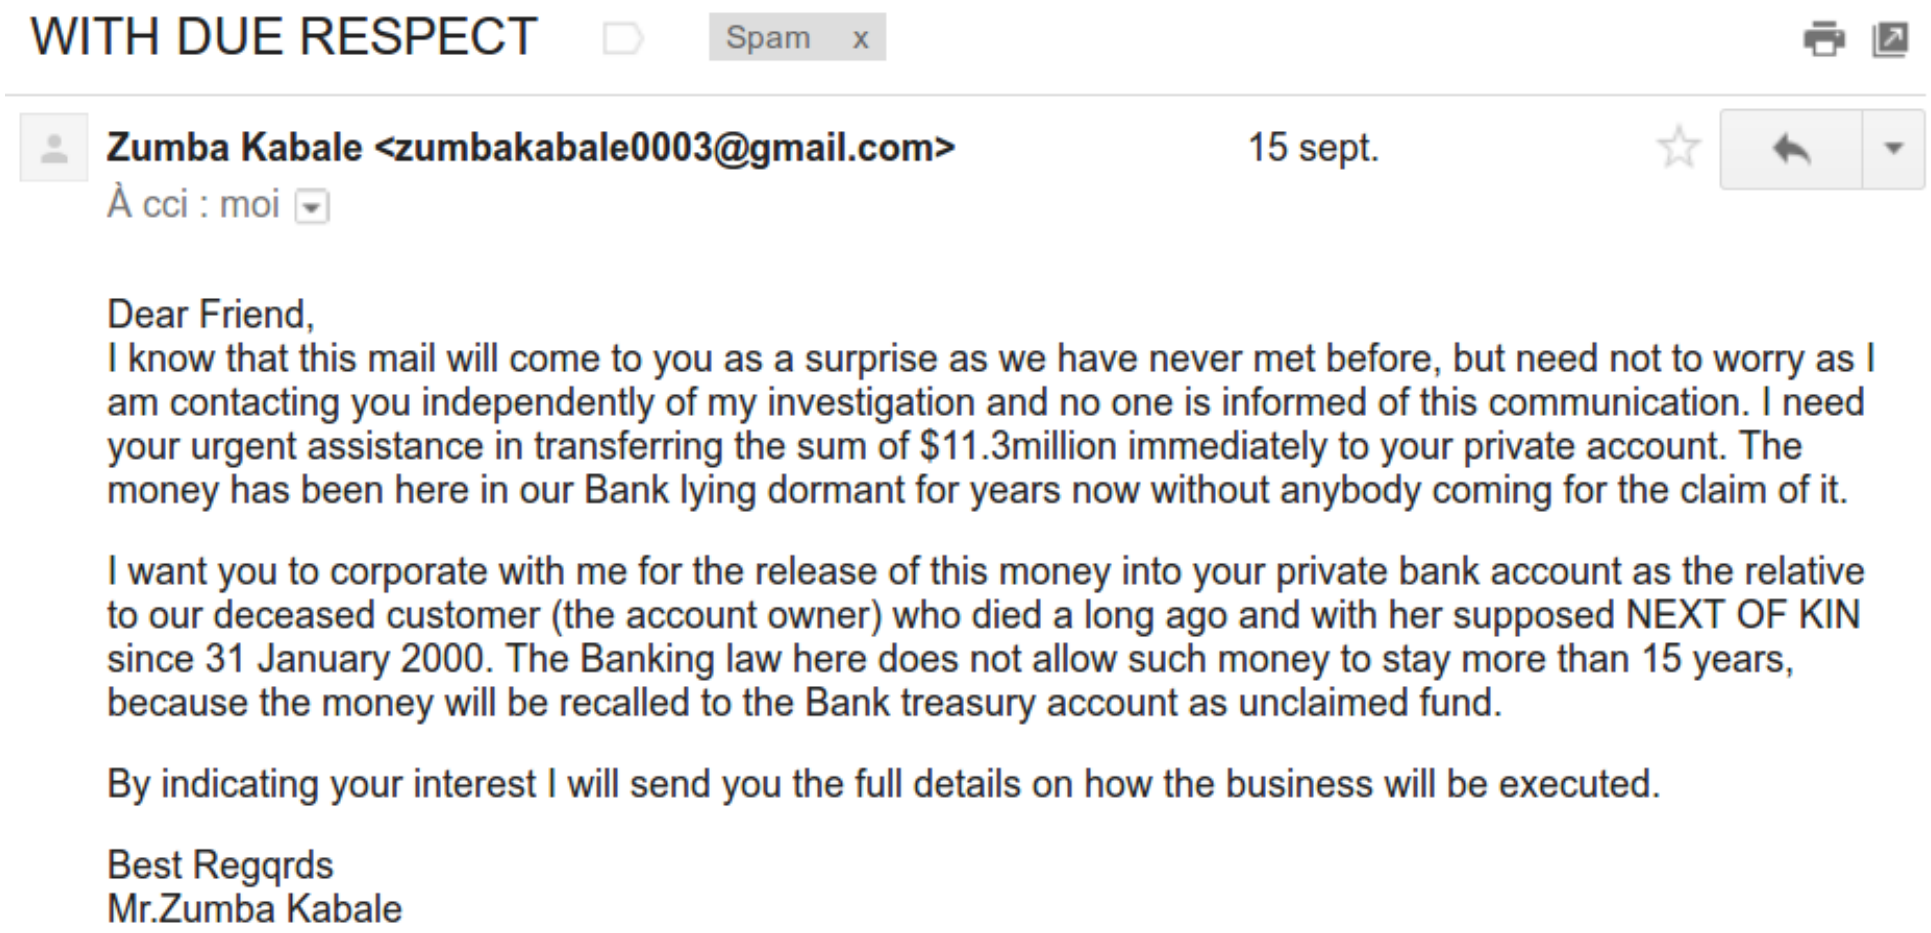

WITH DUE RESPECT Spam x

Zumba Kabale <zumbakabale0003@gmail.com> 15 sept.

À cci : moi

Dear Friend,
I know that this mail will come to you as a surprise as we have never met before, but need not to worry as I am contacting you independently of my investigation and no one is informed of this communication. I need your urgent assistance in transferring the sum of $11.3million immediately to your private account. The money has been here in our Bank lying dormant for years now without anybody coming for the claim of it.

I want you to corporate with me for the release of this money into your private bank account as the relative to our deceased customer (the account owner) who died a long ago and with her supposed NEXT OF KIN since 31 January 2000. The Banking law here does not allow such money to stay more than 15 years, because the money will be recalled to the Bank treasury account as unclaimed fund.

By indicating your interest I will send you the full details on how the business will be executed.

Best Regqrds
Mr.Zumba Kabale

Classification de texte

Quel **thème** ?

(international, politique, sports, people, sciences, économie, ...)

Tintin : les procédures judiciaires pour contrefaçon soulèvent des questions sur la paternité du héros reporter

Onésime, héros de Benjamin Rabier aux allures de Tintin (image BnF).

Publié le 2 juin 2021

Hergé est-il l'unique créateur de Tintin ? Car il existe bien un Tintin en pantalon de golf et houppette créé en 1897 par l'illustrateur français Benjamin Rabier.

Tintin est le héros le plus protégé de la bande dessinée. La société Moulinsart qui gère l'oeuvre du dessinateur belge est d'une fermeté sans égale. Elle poursuit quiconque reproduit ou s'inspire des oeuvres du maître. Avec d'ailleurs plus ou moins de succès. Tout récemment, la chambre civile du tribunal de Rennes vient de donner raison au peintre Xavier Marabout en lui accordant le droit de parodier le reporter du Petit Vingtième. Une autre procédure est en cours au tribunal civil de Marseille à l'encontre du plasticien Peppone. Les démêlés judiciaires de l'artiste provençal avec Moulinsart ont commencé en 2015. Des bustes du héros belge en résine de fibre de verre sont à l'origine du litige.

Classification de texte

Content
ou pas content ?

“Une arnaque!!!”

J'avais réservé une chambre double en demandant des lits séparés car partageais la chambre avec la collègue. Notre demande avait été confirmée par la réception de l'hôtel quelques jours avant notre arrivée. Le jour J: ascenseur dont la tapisserie se décolle, chambre avec lit king seize et baignoire trônant au milieu de la pièce...notre demande n'avait finalement pas été prise en compte. Nous avons demandé à être changées de chambre et avons tout simplement fini... À la cave! Chambre accessible par l'extérieur, odeur de moisi, bouteille de jus de fruit périmée dans le frigidaire, finitions douteuse: moisissure sur l poignée de porte des toilettes, saleté dans la baignoire et la cerise sur le gâteau: impossible de fermer la porte de douche car cette dernière cogne dans le pommeau!!la porte de douche a visiblement été montée avant la colonne de douche! Et le pommeau qui se trouve à hauteur de les chevilles, le cordon de douche n'est pas suffisamment long pour le permettre d'atteindre mes cheveux! Deuxième demande auprès de la réception afin d'être changées de chambre, à plus de 200€ la nuit, nous attendons un minimum de propreté et de fonctionnalité! Nous arrivons finalement dans une troisieme chambre, correspondant davantage à nos attentes, mais toujours: baignoire sale (morceaux de peau et de cheveux,beurk), table de nuit abîmée. En clair: un nom, une déco surchargée qui masque des finitions inexistantes et hôtel qui ne bénéficie pas du tout du standing qu'il veut se donner.

Classification de texte

Relations temporelles / positionnement temporel

Avant,
pendant,
après ?

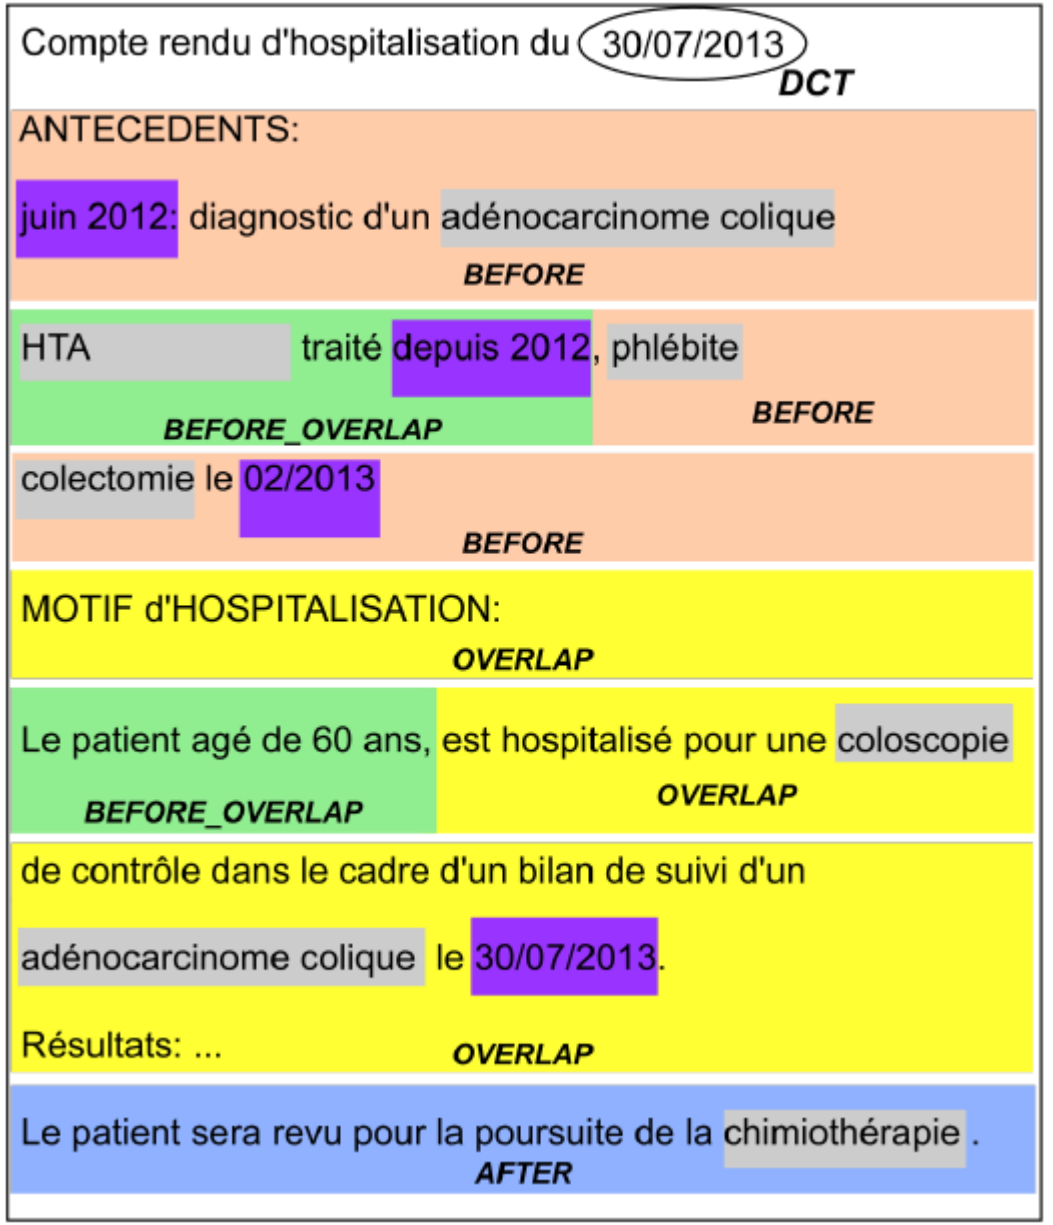

Event-independent temporal positioning: application to French clinical text. Bannour, N. et al., BioNLP 2023

Classification de texte

Malade ou pas malade ?

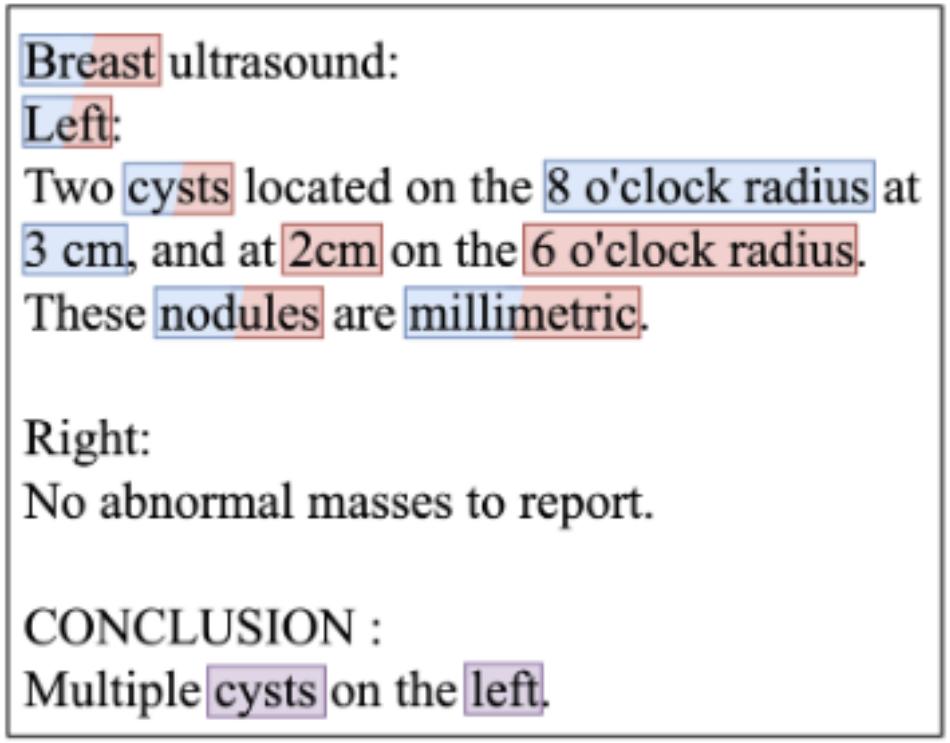

An end-to-end neural model based on cliques and scopes for frame extraction in long breast radiology reports.
Wajsbürt, P. et al., BioNLP 2023

Génération de… trucs

I'm about to teach an introduction to natural language processing in a summer school. What are the main aspects of NLP that I must not forget in this lesson?

When teaching an introduction to natural language processing, there are several key aspects that you should not forget to include in your lesson:

1. The main goals and tasks of NLP: It's important to explain what NLP is and what it aims to accomplish, such as understanding, interpreting, and generating human language in a natural and useful way.
2. Text pre-processing: Explain the importance of text pre-processing and the common techniques used, such as tokenization, stop-word removal, stemming, and lemmatization.
3. Text representation: Discuss the different methods of text representation and their pros and cons, such as bag of words, word embeddings, N-grams, POS tagging, and syntactic parsing.
4. NLP applications: Give examples of NLP applications, such as chatbots, machine translation, sentiment analysis, and text summarization, and explain how they are used in the industry.
5. NLP challenges: Explain the challenges of NLP, such as ambiguity, ic expressions, and sarcasm, and how they can be addressed
6. Tools and libraries: Introduce some of the popular NLP libraries and as NLTK, SpaCy, and CoreNLP, and the features and functionalities t
7. Hands-on practice: Provide the students with some hands-on practi techniques and tools, such as coding exercises, tutorials, and projec to apply what they have learned.

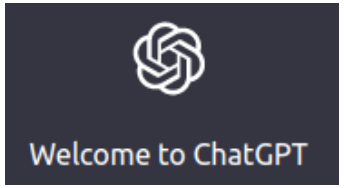

https://openai.com/blog/chatgpt/

Should I speak about you?

As a language model, I am a tool that is used in natural language processing and you could certainly mention me as an example of a modern NLP technology. However, it depends on the scope of your lesson and what you are trying to achieve. If you are looking to give a broad overview of NLP, you might not go into too much detail about any specific tool or technology. But if you are looking to give a more advanced lesson and want to demonstrate the capabilities of modern NLP technologies, then you could certainly talk about me and other language models like me, and how they are used in various NLP applications.

Génération de… trucs

Can AI Write Your React Code?

Harshdeep Bilaiya Follow

Sep 2, 2020 · 5 min read

In a word: ***YES***! But it could do much, much more than that. This disruptive language model is taking the internet by storm — it's called ***GPT-3*** *(Generative Pre-trained Transformer 3). It is an autoregressive language model that uses deep learning to produce human-like text*. It is the third-generation language prediction model in the *GPT-n* series created by OpenAI. OpenAI is an AI research and development company founded in late 2015, by one of THE tech innovators of our time — Elon Musk (along with *Greg Brockman (CTO), Sam Altman (CEO) and 3* other gentlemen).

https://medium.com/globant/can-ai-write-you-react-code-c36c9f16b1f5#:~:text=In%20a%20word%3A%20YES!

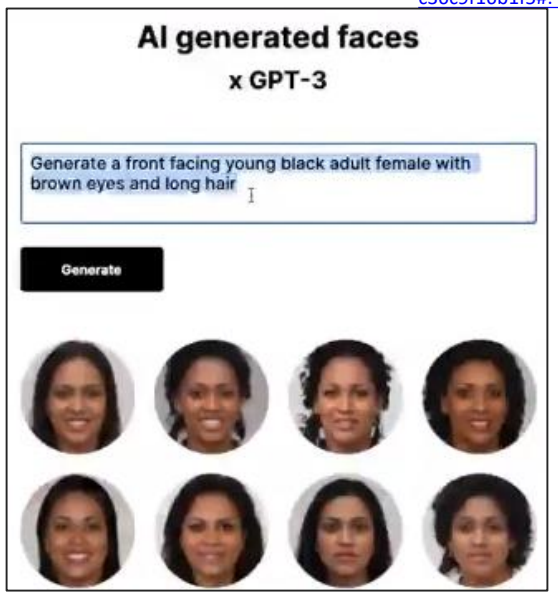

https://gpt3demo.com/apps/gpt-3-x-gans

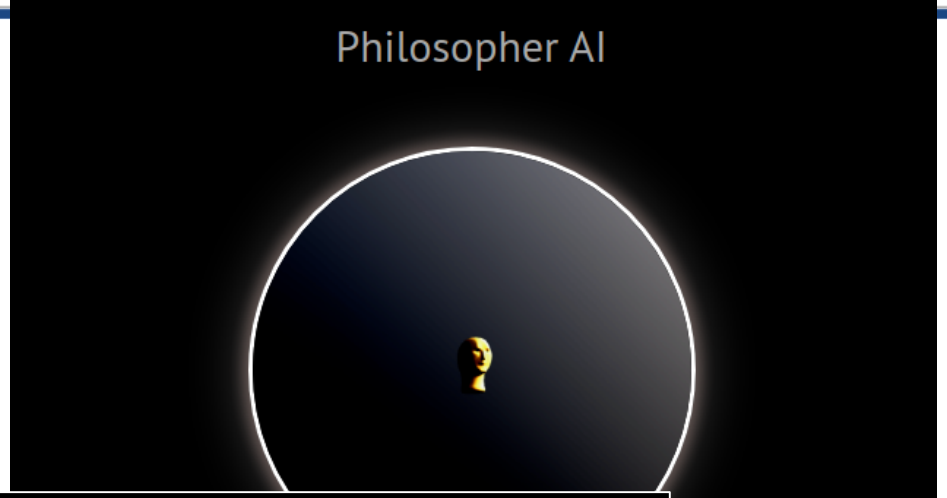

This is an experiment in what one might call "prompt engineering", which is a way to utilize GPT-3, a neural network trained and hosted by OpenAI.

GPT-3 is a language model. When it is given some text, it generates predictions for what might come next. It is remarkably good at adapting to different contexts, as defined by a prompt (in this case, hidden), which sets the scene for what type of text will be generated.

Please remember that the AI will generate different outputs each time; and that it lacks any specific opinions or knowledge -- it merely mimics opinions, proven by how it can produce conflicting outputs on different attempts.

Let's design a happier world together

Firstly, we should look at the current state of happiness in human society. Finding out how happy people are and then using that as a benchmark for making their lives even happier is a good place to start. It would make sense to survey everyone about this first and find out what they think makes them happy.

The most common response for both men and women was that more sex would make them happier. Aside from this, the other immediate responses were:

Sex (in general) Family Life Friends Work A loving partner in life Good health Money/financial security Community Spirituality Break Free of Stress Being very wealthy My children Doing what you love Traveling The right job Growing old with someone

It seems that sex and family are the two most important factors in achieving happiness. This is supported by a lot of research into this area. For example, social relationships have been identified as an essential component of human well-being.

https://philosopherai.com/philosopher/lets-design-a-happier-world-together-c4f8ad

Tâche : traduction automatique

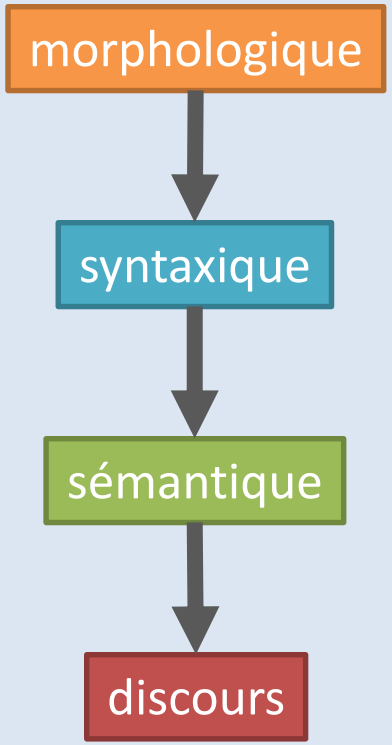

Tâches

- Dialogue humain / machine (oral ou écrit)
- Réponse à des questions
- Résumé, synthèse, simplification
- Recherche d’information, similarité entre documents
- …

Tâches

- Dialogue humain / machine (oral ou écrit)
- Réponse à des questions
- Résumé, synthèse, simplification
- Recherche d'information, similarité entre documents
- …
- Sans oublier les tâches multimodales
  - Multimodal emotion recognition / sentiment analysis (vidéo + texte)
  - Visual question answering (image + texte)
  - Verifying Multimedia Use (image + texte, MediaEval 2016)
  - Image captioning
  - Image generation
  - …

http://nlpprogress.com/english/multimodal.html

Qu’est-ce qui rend un problème difficile ? (1/2)

Il est difficile à résoudre par un humain

(cf. accord inter-annotateur, accord intra-annotateur, bonnes pratiques d’annotation)

Il a beaucoup de classes (*multi-class*)

(ex. : *entity linking* ; trouver tous les concepts médicaux mentionnés dans un compte-rendu)

Les classes ne sont pas mutuellement exclusives (*multi-label*)

(ex. : attribution de tags, classification d’images)

Qu’est-ce qui rend un problème difficile ? (2/2)

Les classes sont réparties de façon très déséquilibrée (*unbalanced, skewed*)

(ex. : malade/pas malade)

Sa représentation est complexe

(ex. : phrase, document, multimodal)

Certaines données sont manquantes ou bruitées (*missing data, noisy data*)

(ex. : quasiment tous les problèmes de la vie réelle)

Geekeries

En vrac

Quiz

"Quelle est l'unique différence entre cette phrase et les autres ?"

“Quelle est l'unique différence entre cette phrase et les autres ?”

« Quelle est l'unique différence entre cette phrase et les autres ? »

Quiz

Quelle est l’unique différence entre cette phrase et l’autre ?

Quelle est l'unique différence entre cette phrase et l'autre ?

Quiz

Quelle est l’unique différence entre cette phrase et l’autre ?

Quelle est l’unique différence entre cette phrase et l’autre ?

Quiz

Quel est le problème ?

« prÃ©sident du PÃ©rou »

Encodage

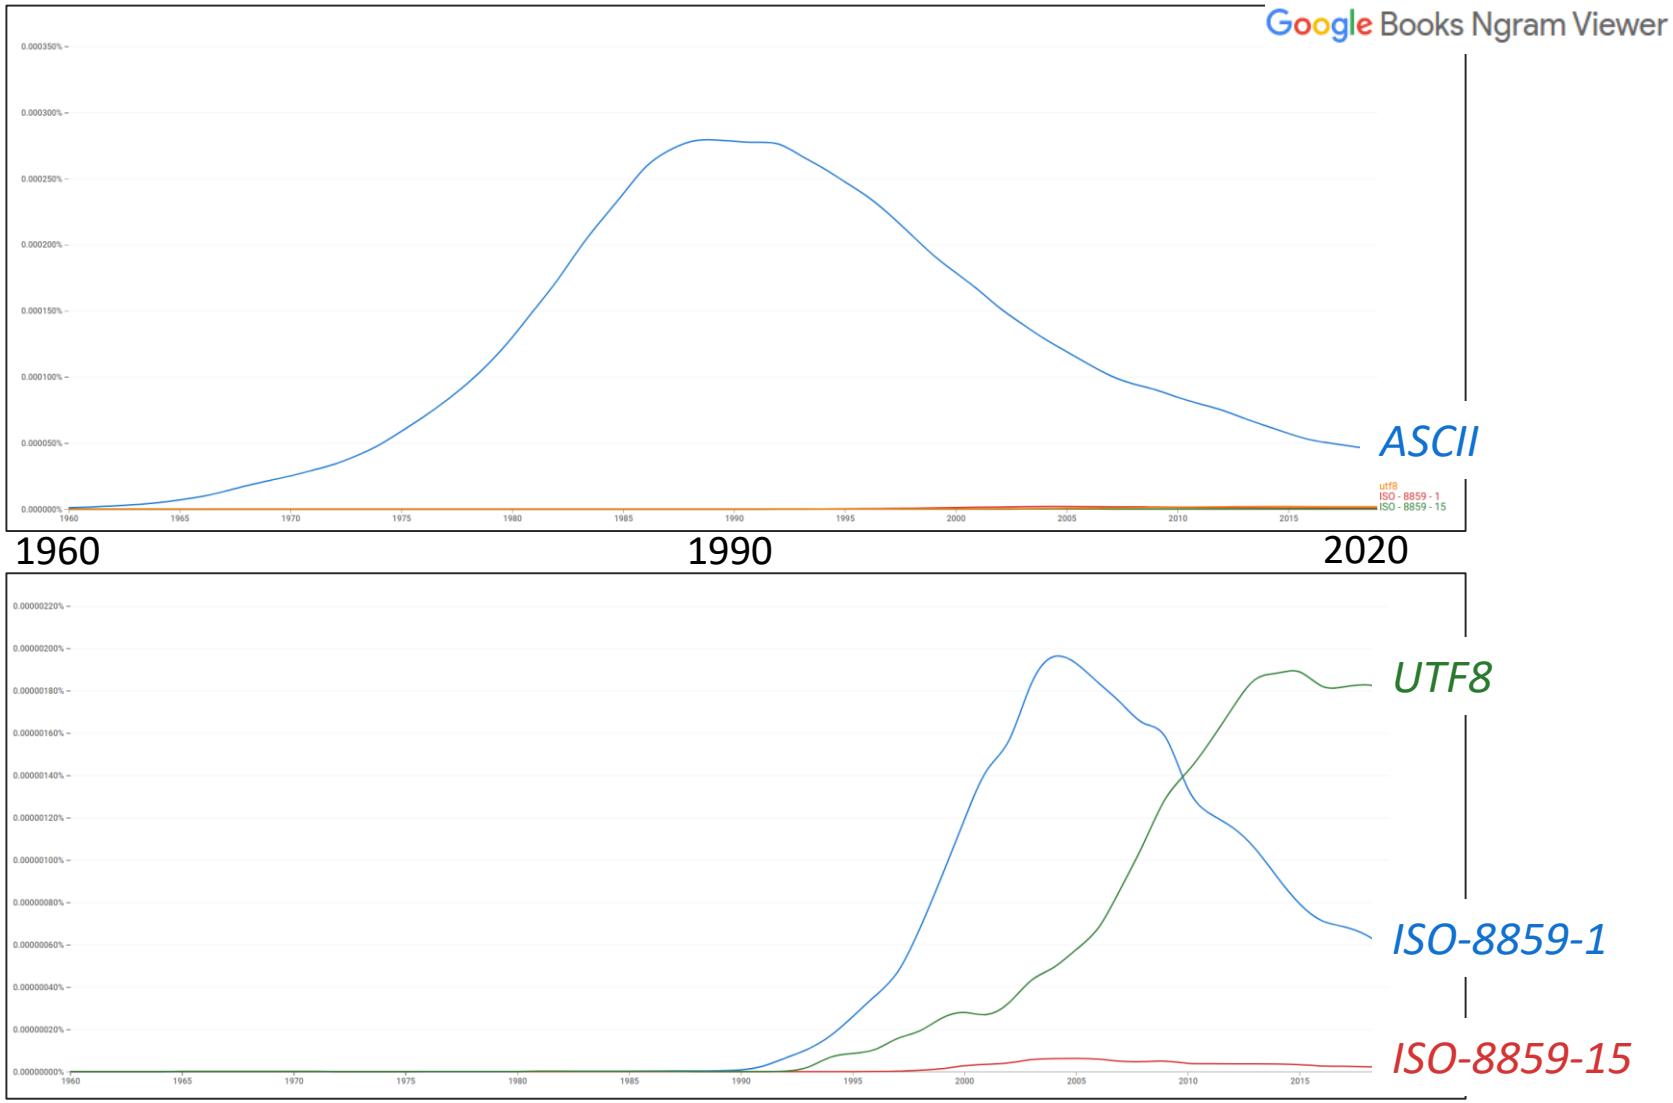

Encodage

ASCII

Codage de 128 caractères sur 7 bits
(un octet avec dernier bit à 0)

USASCII code chart

b_4	b_3	b_2	b_1	Row ↓ / Column →	0 (0 0 0)	1 (0 0 1)	2 (0 1 0)	3 (0 1 1)	4 (1 0 0)	5 (1 0 1)	6 (1 1 0)	7 (1 1 1)
0	0	0	0	0	NUL	DLE	SP	0	@	P	`	p
0	0	0	1	1	SOH	DC1	!	1	A	Q	a	q
0	0	1	0	2	STX	DC2	"	2	B	R	b	r
0	0	1	1	3	ETX	DC3	#	3	C	S	c	s
0	1	0	0	4	EOT	DC4	$	4	D	T	d	t
0	1	0	1	5	ENQ	NAK	%	5	E	U	e	u
0	1	1	0	6	ACK	SYN	&	6	F	V	f	v
0	1	1	1	7	BEL	ETB	'	7	G	W	g	w
1	0	0	0	8	BS	CAN	(	8	H	X	h	x
1	0	0	1	9	HT	EM	)	9	I	Y	i	y
1	0	1	0	10	LF	SUB	*	:	J	Z	j	z
1	0	1	1	11	VT	ESC	+	;	K	[	k	{
1	1	0	0	12	FF	FS	,	<	L	\	l	|
1	1	0	1	13	CR	GS	-	=	M	]	m	}
1	1	1	0	14	SO	RS	.	>	N	^	n	~
1	1	1	1	15	SI	US	/	?	O	_	o	DEL

Manuel d'imprimante de 1972
(source : Wikipedia)

Encodage

ISO-8859-1 (« latin1 »)

Codage de 192 caractères sur 8 bits
(un octet)

ISO/CEI 8859-1															
	x0	**x1**	**x2**	**x3**	**x4**	**x5**	**x6**	**x7**	**x8**	**x9**	**xA**	**xB**	**xC**	**xD**	**xE**	**xF**
0x	*positions inutilisées*															
1x																
2x	SP	!	"	#	$	%	&	'	(	)	*	+	,	-	.	/
3x	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4x	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5x	P	Q	R	S	T	U	V	W	X	Y	Z	[	\	]	^	_
6x	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7x	p	q	r	s	t	u	v	w	x	y	z	{	|	}	~	
8x	*positions inutilisées*															
9x																
Ax	NBSP	¡	¢	£	¤	¥	¦	§	¨	©	ª	«	¬	-	®	¯
Bx	°	±	²	³	´	µ	¶	·	¸	¹	º	»	¼	½	¾	¿
Cx	À	Á	Â	Ã	Ä	Å	Æ	Ç	È	É	Ê	Ë	Ì	Í	Î	Ï
Dx	Ð	Ñ	Ò	Ó	Ô	Õ	Ö	×	Ø	Ù	Ú	Û	Ü	Ý	Þ	ß
Ex	à	á	â	ã	ä	å	æ	ç	è	é	ê	ë	ì	í	î	ï
Fx	ð	ñ	ò	ó	ô	õ	ö	÷	ø	ù	ú	û	ü	ý	þ	ÿ

(source : Wikipedia)

Encodage

UTF-8

Codage sur 1, 2, 3 ou 4 octets
(potentiellement jusqu'à 8)

Caractères codés	Représentation binaire UTF-8
U+0000 à U+007F	0xxxxxxx
U+0080 à U+07FF	110xxxxx 10xxxxxx
U+0800 à U+FFFF	1110xxxx 10xxxxxx 10xxxxxx
U+10000 à U+10FFFF	11110xxx 10xxxxxx 10xxxxxx 10xxxxxx

(source : Wikipedia)

Quiz

Et donc, quel est le problème ?

« prÃ©sident du PÃ©rou »

Encodage

On peut espérer être bientôt débarrassé du problème…

https://w3techs.com/technologies/history_overview/character_encoding/ms/y

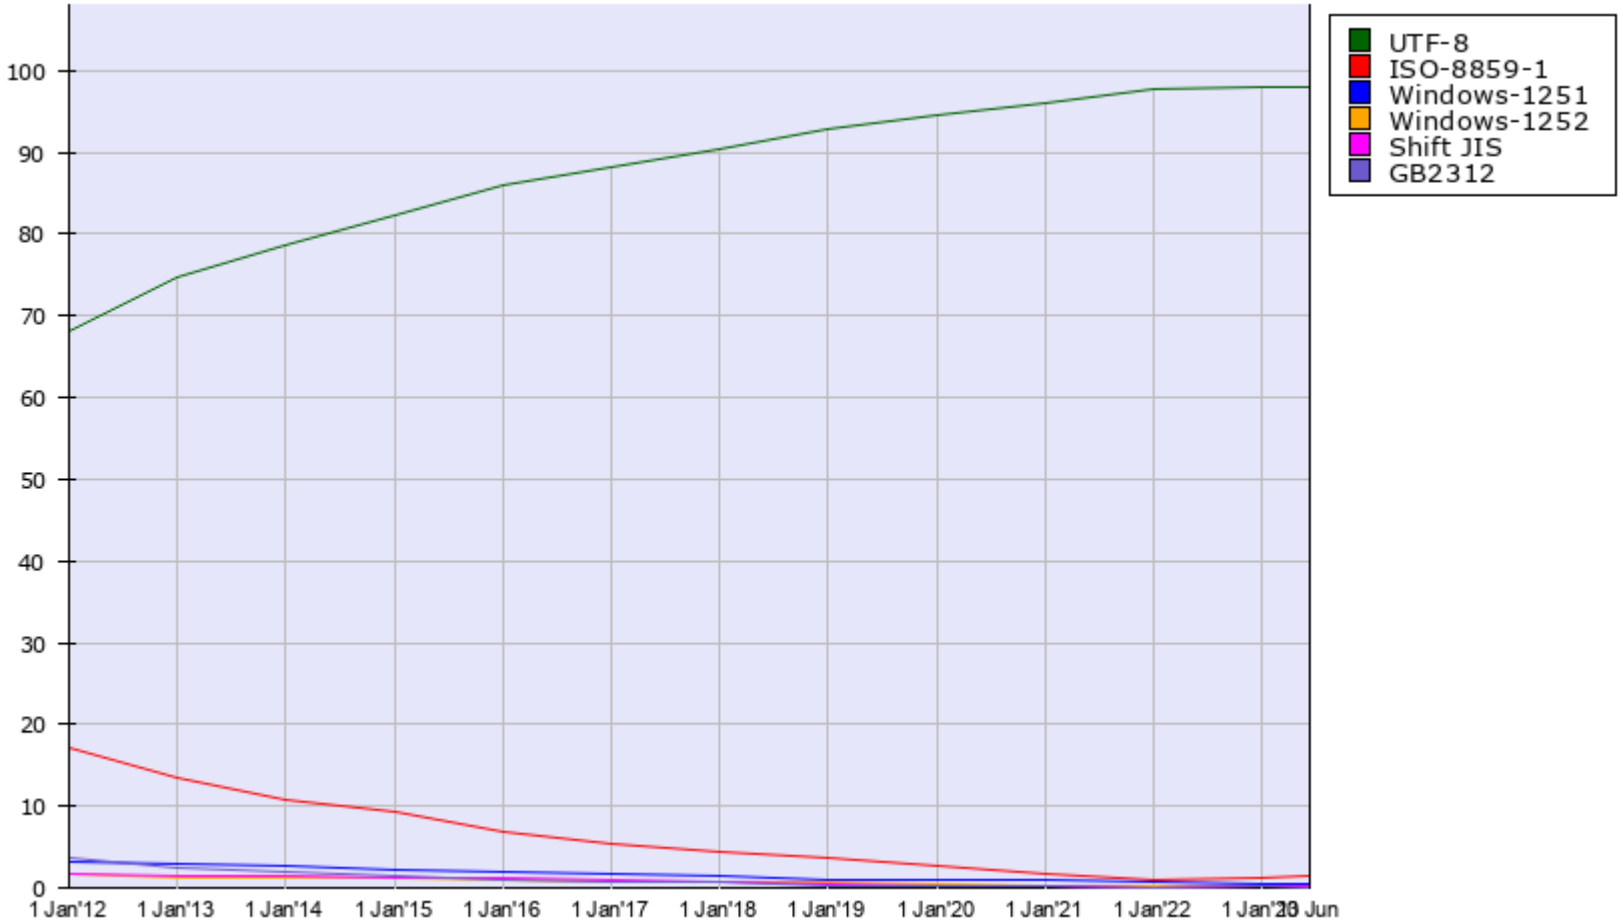

Encodage

PS : ça ne date pas de l'invention de l'informatique…

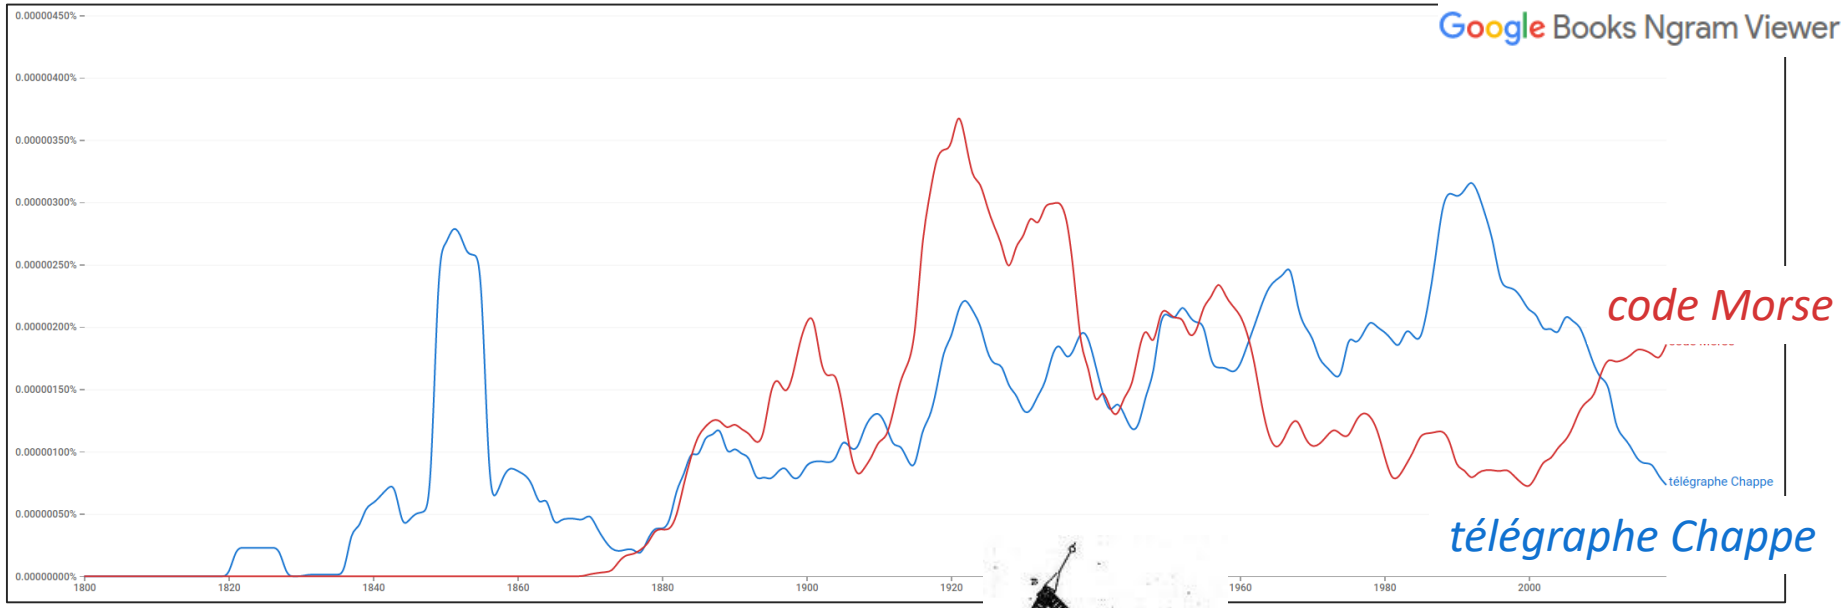

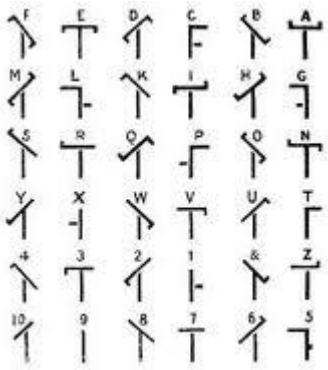

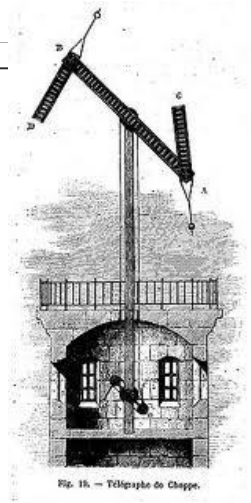

Quiz

```
-DOCSTART- -X- O O

EU NNP I-NP I-ORG
rejects VBZ I-VP O
German JJ I-NP I-MISC
call NN I-NP O
to TO I-VP O
boycott VB I-VP O
British JJ I-NP I-MISC
lamb NN I-NP O
. . O O

Peter NNP I-NP I-PER
Blackburn NNP I-NP I-PER

BRUSSELS NNP I-NP I-LOC
1996-08-22 CD I-NP O

The DT I-NP O
European NNP I-NP I-ORG
Commission NNP I-NP I-ORG
said VBD I-VP O
on IN I-PP O
Thursday NNP I-NP O
```

Voici le début du fichier d'entraînement de Conll 2003 (chunking et reconnaissance d'entités nommées, EN).

Vous avez une minute pour en extraire les classes d'entités nommées (dernière colonne) et leur nombre dans le corpus.

Quiz

```
-DOCSTART- -X- O O

EU NNP I-NP I-ORG
rejects VBZ I-VP O
German JJ I-NP I-MISC
call NN I-NP O
to TO I-VP O
boycott VB I-VP O
British JJ I-NP I-MISC
lamb NN I-NP O
. . O O

Peter NNP I-NP I-PER
```

Voici le début du fichier d'entraînement de Conll 2003 (chunking et reconnaissance d'entités nommées, EN).

Vous avez une minute pour en extraire les classes

```
> grep -v "DOCSTART-" eng.train.txt | sed '/^$/d' | awk '{print $4}'
| sort | uniq -c | sort -nr
 169578 O
  11128 I-PER
  10001 I-ORG
   8286 I-LOC
   4556 I-MISC
     37 B-MISC
     24 B-ORG
     11 B-LOC
```

Quiz

```
-DOCSTART- -X- O O

EU NNP I-NP I-ORG
rejects VBZ I-VP O
German JJ I-NP I-MISC
call NN I-NP O
to TO I-VP O
boycott VB I-VP O
British JJ I-NP I-MISC
lamb NN I-NP O
. . O O

Peter NNP I-NP I-PER
```

Voici le début du fichier d'entraînement de Conll 2003 (chunking et reconnaissance d'entités nommées, EN).

Vous avez une minute pour en extraire les classes

```
> grep -v "DOCSTART-" eng.train.txt | sed '/^$/d' | awk '{print $4}'
| sort | uniq -c | sort -nr
 169578 O
  11128 I-PER
  10001 I-ORG
   8286 I-LOC
   4556 I-MISC
     37 B-MISC
     24 B-ORG
     11 B-LOC
```

Apprenez les commandes unix !

- grep, tr
- sort, uniq
- cut
- awk
- sed

Quiz

```
-DOCSTART- -X- O O

EU NNP I-NP I-ORG
rejects VBZ I-VP O
German JJ I-NP I-MISC
call NN I-NP O
to TO I-VP O
boycott VB I-VP O
British JJ I-NP I-MISC
lamb NN I-NP O
. . O O
```

Voici le début du fichier d'entraînement de Conll 2003 (chunking et reconnaissance d'entités nommées, EN).

Et calculez les statistiques des corpus que vous manipulez, avant TOUTE chose :

- Répartition des classes
- Nombre de classes par objet
- Nombre de mots total, par document, par phrase
- …

```
> grep -v "DOCS
| sort | uniq -
 169578 O
  11128 I-PER
  10001 I-ORG
   8286 I-LOC
   4556 I-MISC
     37 B-MISC
     24 B-ORG
     11 B-LOC
```

```
$4}'
```

- grep, tr
- sort, uniq
- cut
- awk
- sed

Quiz

Quels sont les points communs entre ces erreurs ?

Erreur pytorch

```
RuntimeError: size mismatch, m1: [a x b], m2: [c x d]
```

Erreur regex

```
AttributeError: 'NoneType' object has no attribute 'group'
```

Erreur partout

```
IndexError: list index out of range
```

```
FileNotFoundError: [Errno 2] No such file or directory
```

Quiz

Quels sont les points communs entre ces erreurs ?

1. Elles peuvent arriver après des heures d'entraînement
2. Les corriger peut vous prendre des heures
3. Vous auriez peut-être pu les éviter en utilisant **`assert`**

Err

```
Ru
```

Err

```
AttributeError: 'NoneType' object has no attribute 'group'
```

```
assert isfile(res_file)
```

Erreur partout

```
IndexError
```

```
assert outputs.shape == (batch_size, seq_len, dim)
```

```
FileNotFou                                    e or directory
```

```
assert len(fields) > 0, fields
```

Traitement automatique de la langue

Évaluation

Xavier Tannier

LIMICS

SORBONNE UNIVERSITÉ
CRÉATEURS DE FUTURS DEPUIS 1257

Évaluation

- Une bonne évaluation, c'est :
  - Une bonne référence
  - Un périmètre bien défini (pour estimer la généralisabilité et la robustesse)
  - Une métrique appropriée
  - Un protocole défini et respecté

- Et puis se poser les questions sur :
  - L'interprétabilité
  - Le caractère FAIR des données
  - Le coût environnemental
  - La reproductibilité
  - La robustesse aux attaques
  - L'éthique

Une bonne évaluation, c’est

un bon jeu de données annotées

Construction du jeu de données

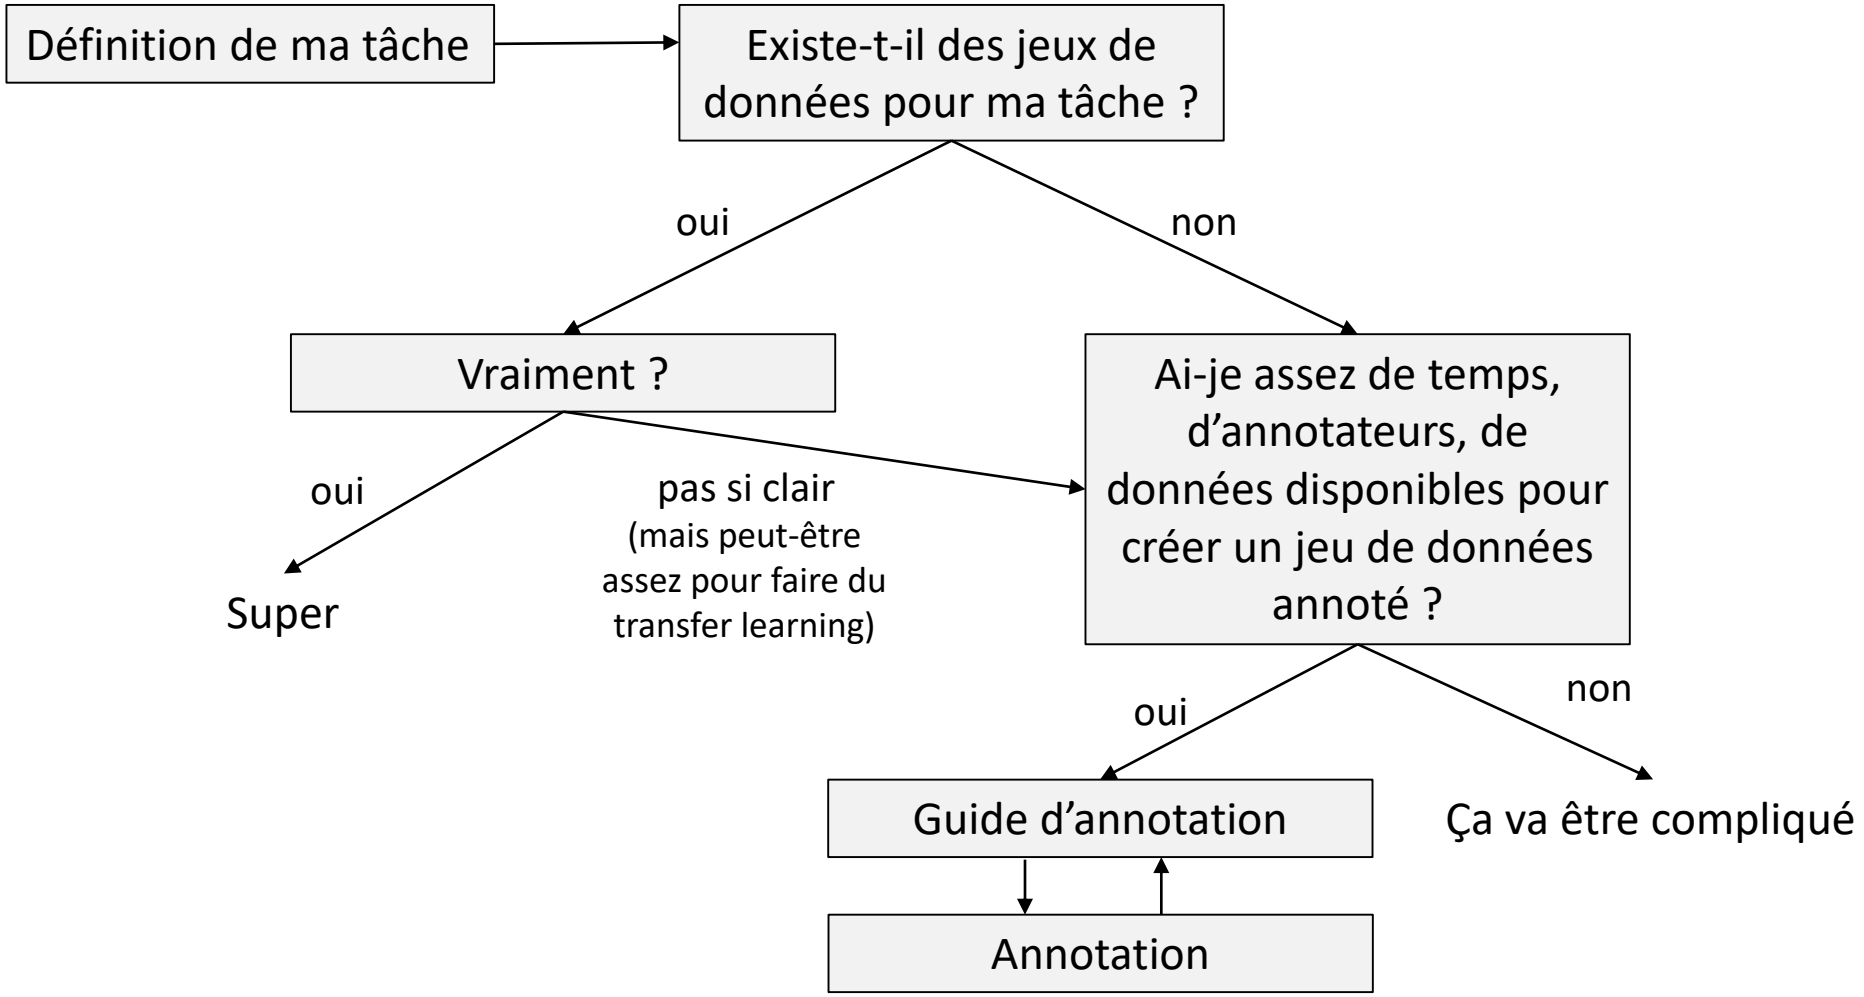

Construction du jeu de données

La configuration idéale (version courte)

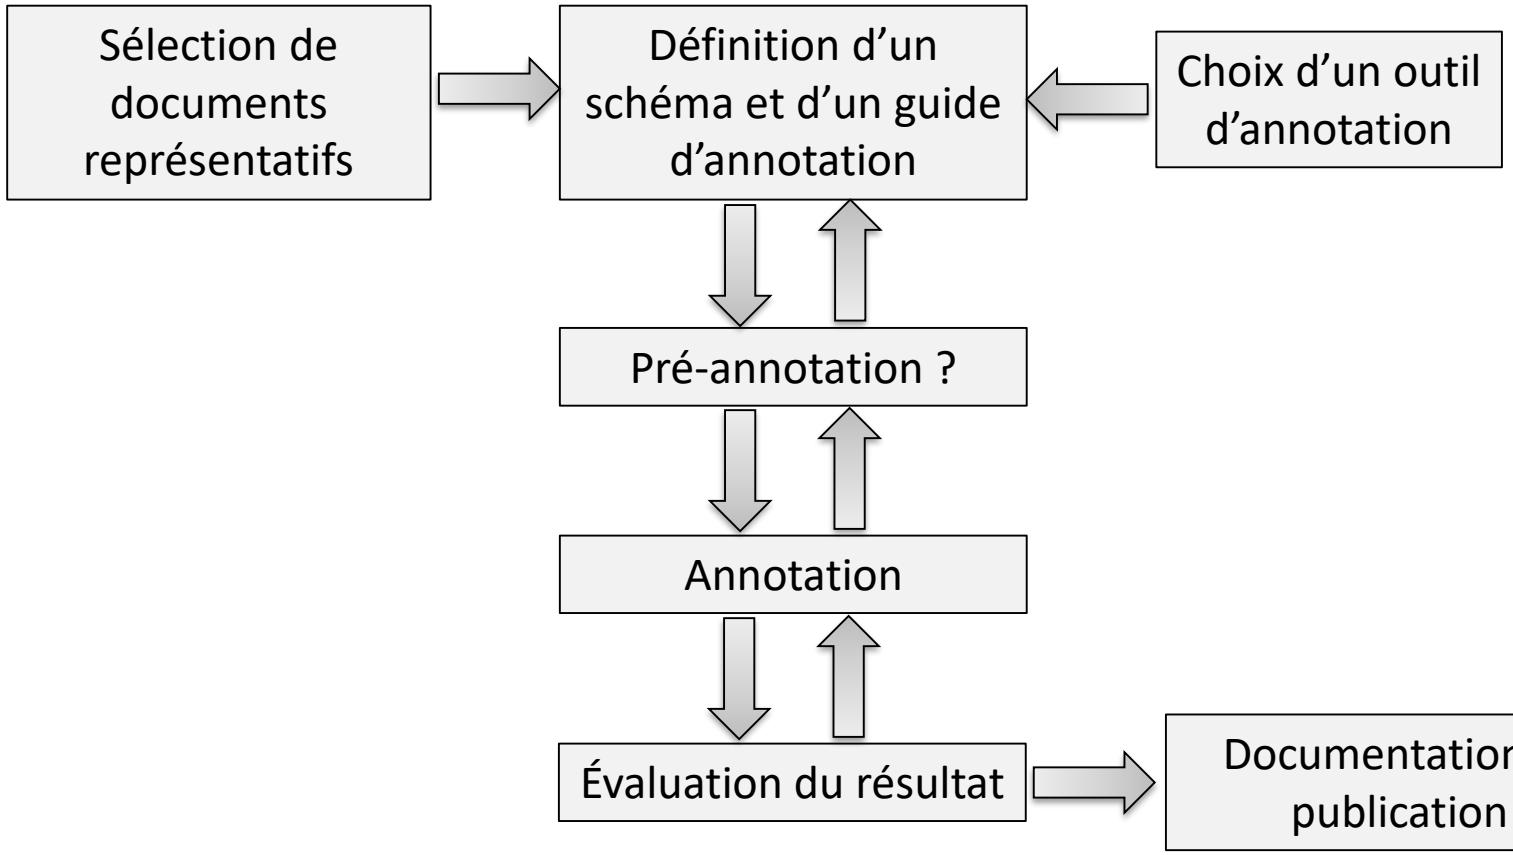

Construction du jeu de données

La configuration idéale (version courte)

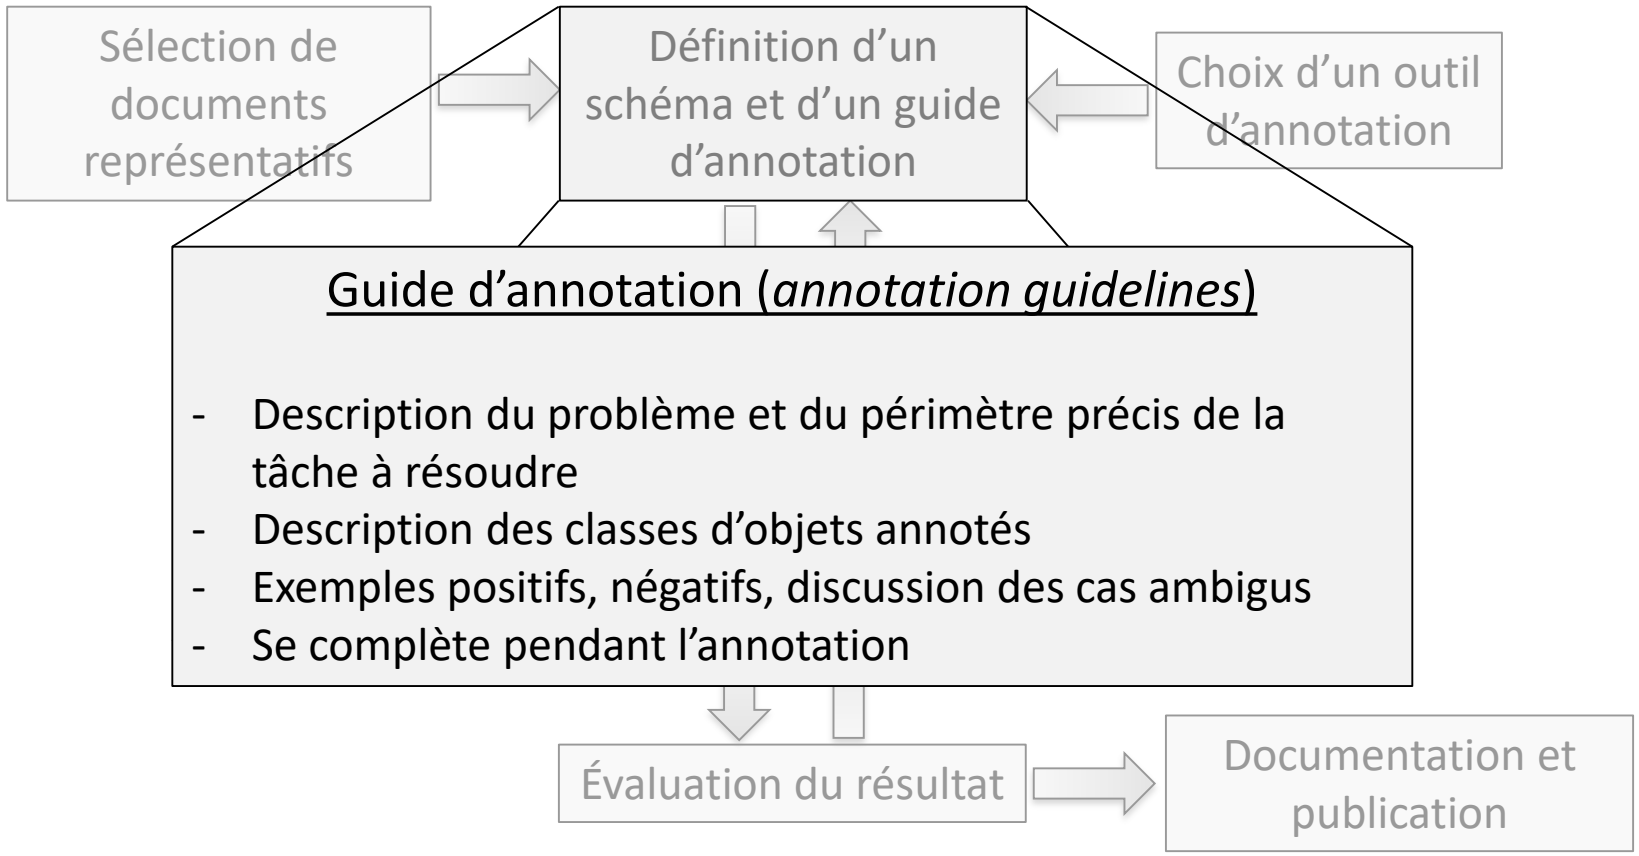

Construction du jeu de données

La configuration idéale (version courte)

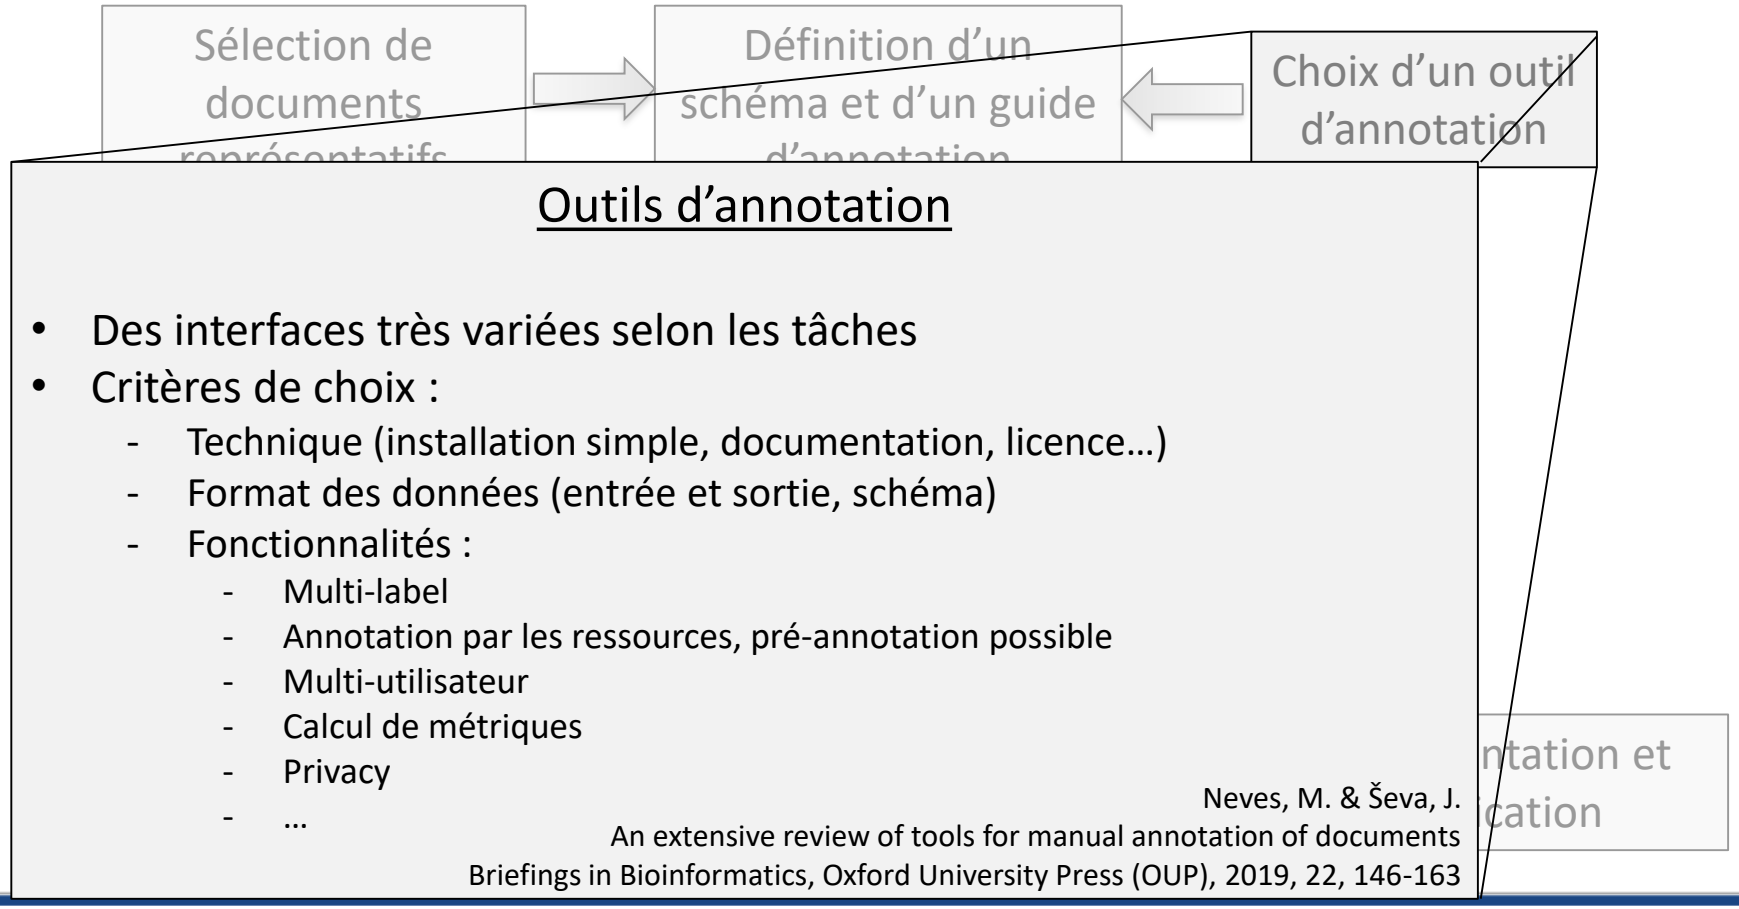

Construction du jeu de données

La co

Annotation

- Plusieurs personnes, et pas celles qui vont concevoir le système
- Procédure :
  1. Annotent des documents ensemble
  2. Annotent séparément mais avec du chevauchement par paire d'annotateurs
  3. Se retrouvent régulièrement pour régler les désaccords (adjudication) et vérifient qu'ils ne varient pas
- Si crowd-sourcing, ajouter des contrôles qualité un peu partout

Les ressources annotées, un enjeu pour l'analyse de contenu : vers une méthodologie de l'annotation manuelle de corpus. Thèse de doctorat. Karën Fort

M. Sabou, K. Bontcheva, L. Derczynski, A. Scharl Corpus Annotation through Crowdsourcing: Towards Best Practice Guidelines LREC 2014 (LREC'14), 2014

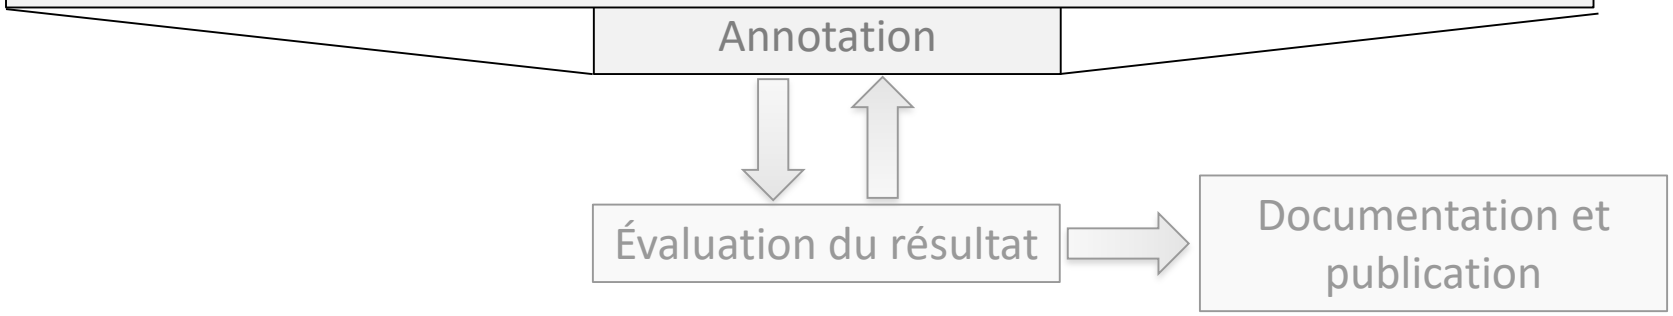

Construction du jeu de données

La configuration idéale (version courte)

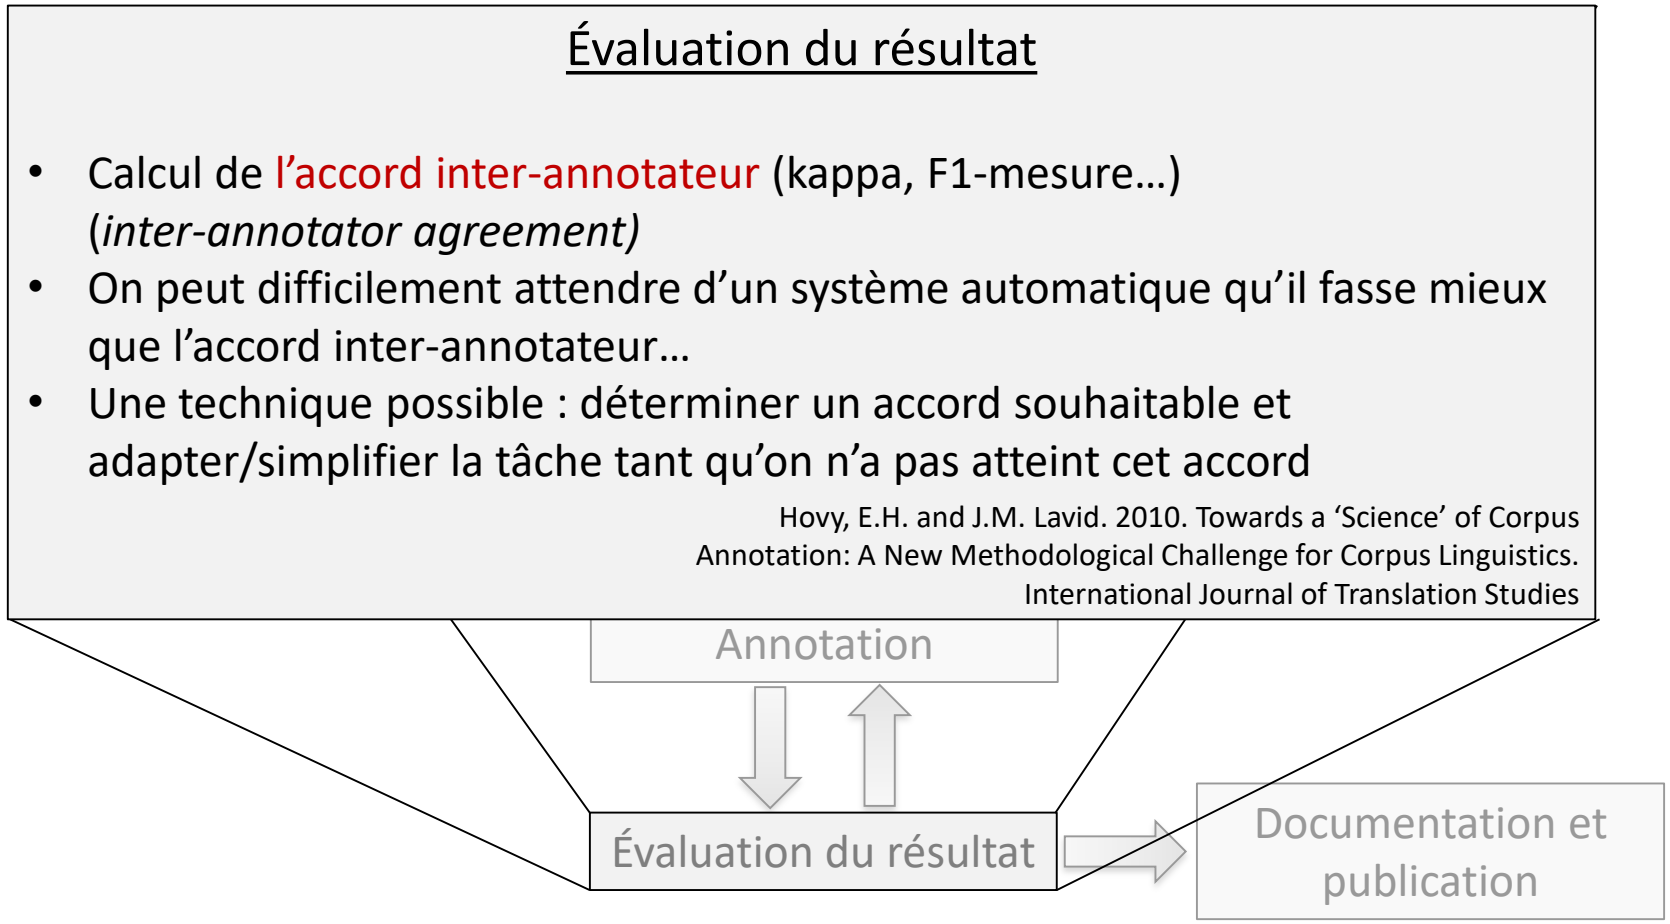

Construction du jeu de données

La configuration idéale (version courte)

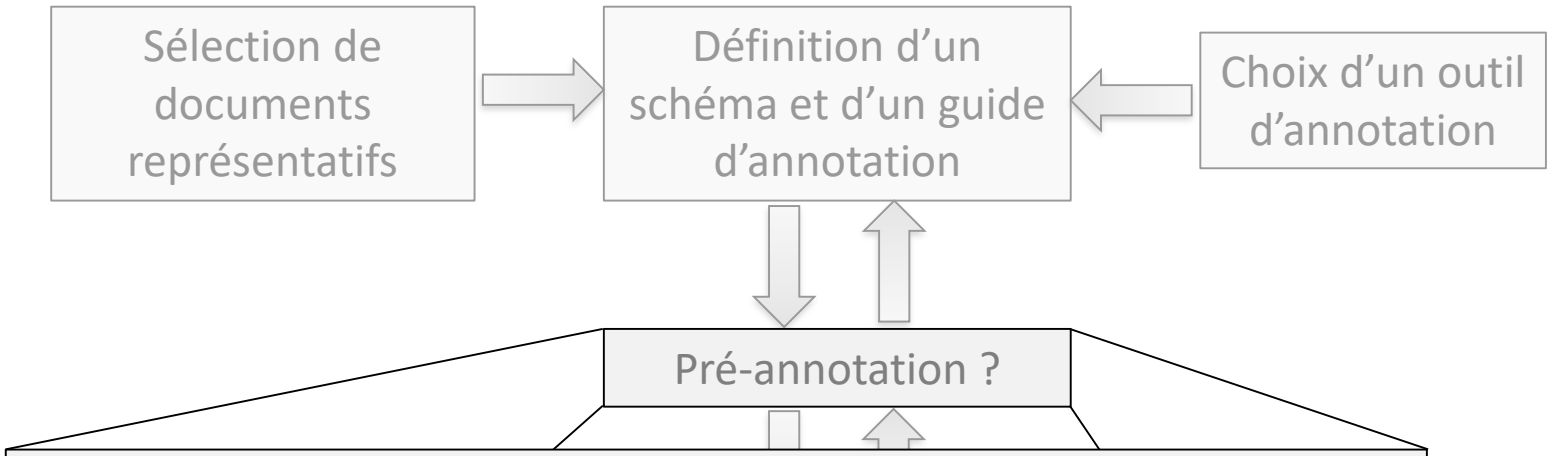

Pré-annotation

- À base de règles ou d'un système entraîné sur peu de données
- Avantage principal : si la pré-annotation est de qualité suffisante, elle réduit l'effort humain
- Inconvénient avéré : biais de confirmation

Karën Fort, Benoît Sagot.
Influence of Pre-annotation on POS-tagged Corpus Development
The Fourth ACL Linguistic Annotation Workshop, Jul 2010, Uppsala, Sweden.

ntation et
cation

À quoi sert le jeu de données ? (tâches supervisées)

On sépare en général le jeu de données annotées en trois :

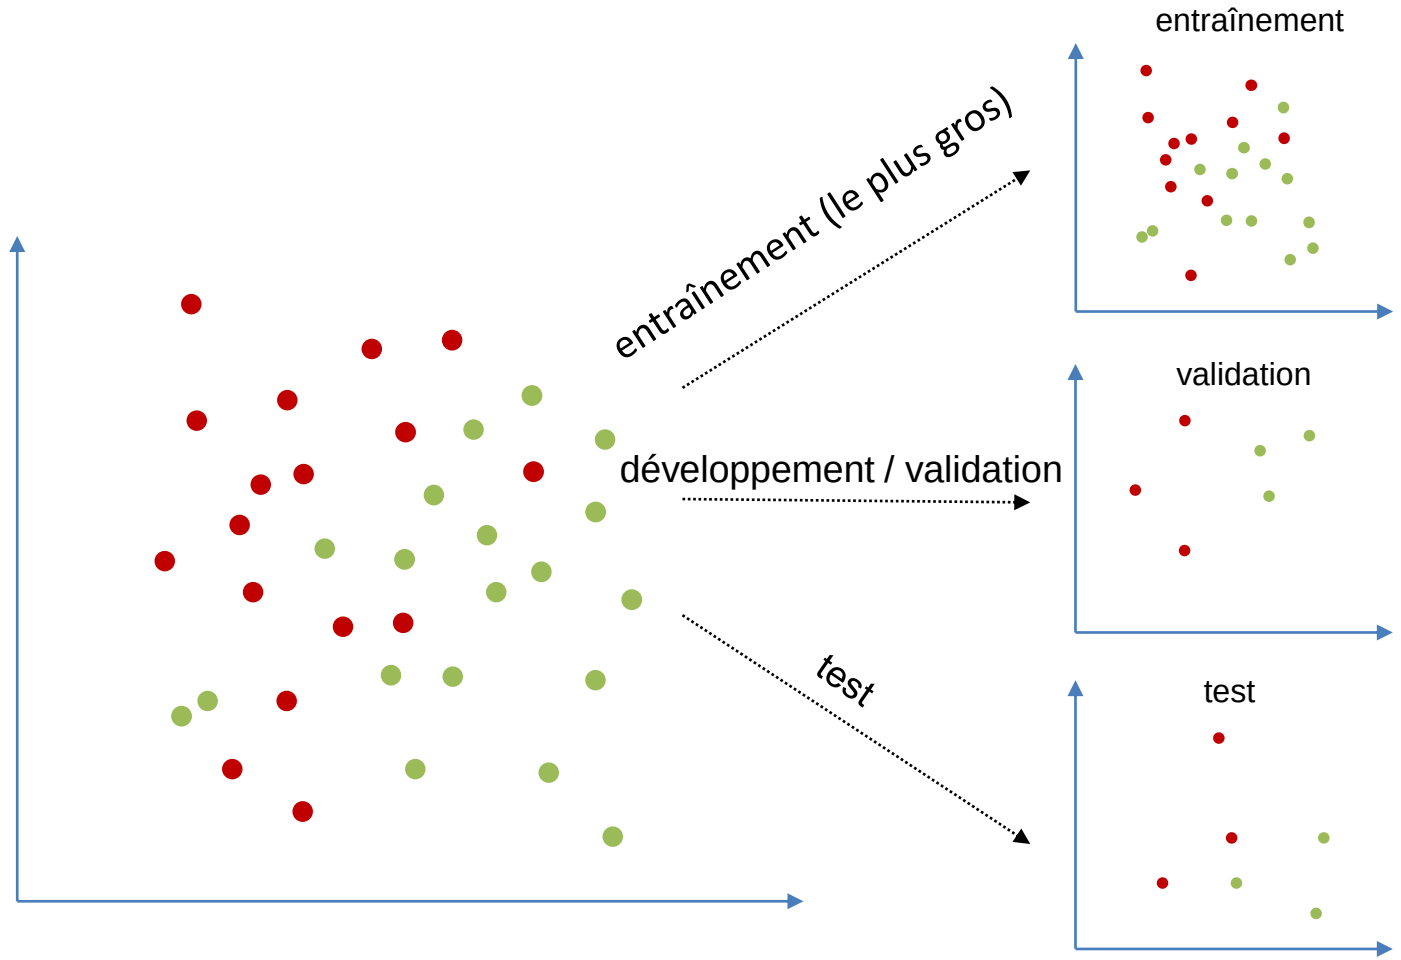

À quoi sert le jeu de données ? (tâches supervisées)

On sépare en général le jeu de données annotées en trois :

Pour entraîner le modèle

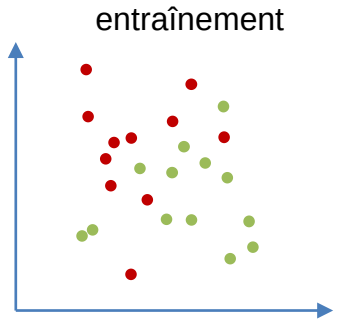

Pour trouver les meilleurs paramètres / le meilleur modèle, savoir quand arrêter l'entraînement, éviter le surentraînement, etc.

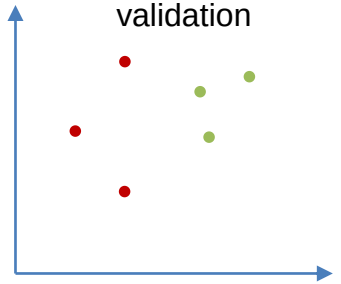

Pour évaluer les performances du modèle choisi sur des données qu'il n'a jamais vues. **Ne doit jamais être regardé ni utilisé pendant la conception !**

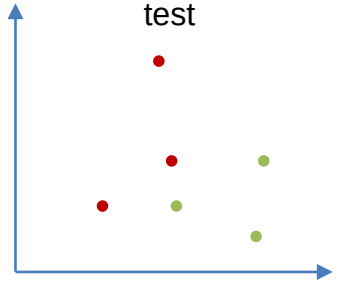

Les bonnes propriétés du jeu de données

Pour une bonne réutilisabilité :

- Le périmètre du jeu de données doit être clair et documenté
- La qualité des annotations doit être documentée
- Les données doivent être représentatives de la tâche considérée (dans le périmètre considéré)
- Les formats de données doivent être standard (si un standard existe)
- Le jeu de test doit être défini (et respecté)
- Les données doivent être rendue disponibles (si légalement possible)

FAIR data

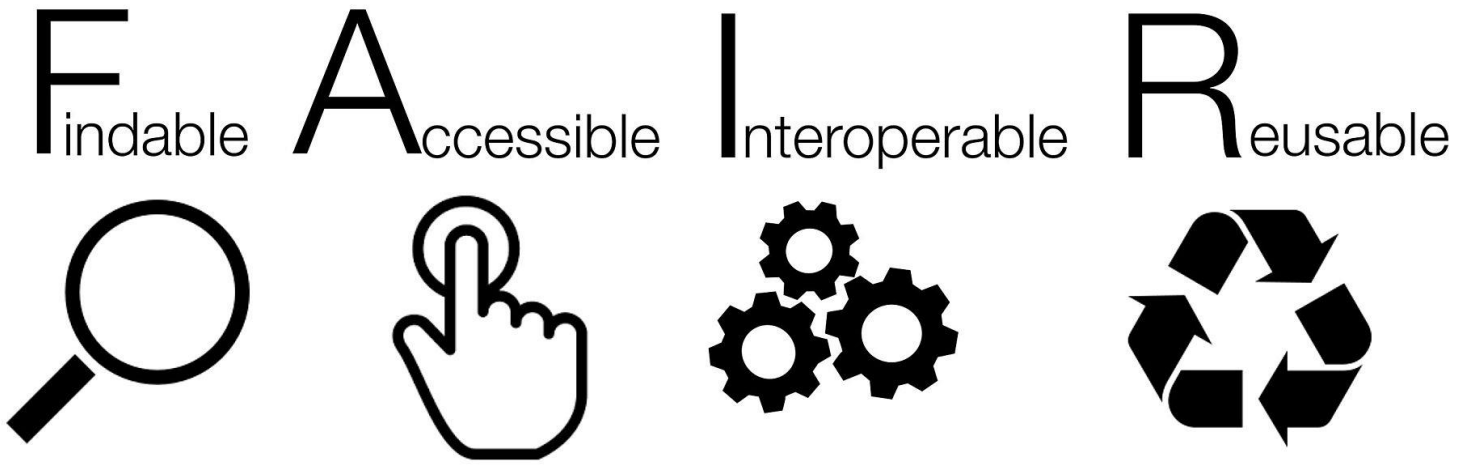

SangyaPundir, CC BY-SA 4.0, https://commons.wikimedia.org/w/index.php?curid=53414062

Kai-Wei Chang, Vicente Ordonez, Margaret Mitchell, Vinodkumar Prabhakaran
Tutorial: Bias and Fairness in Natural Language Processing
EMNLP 2019

Une bonne évaluation, ce sont de bonnes métriques

Évaluation en extraction d'information

Prédiction du système

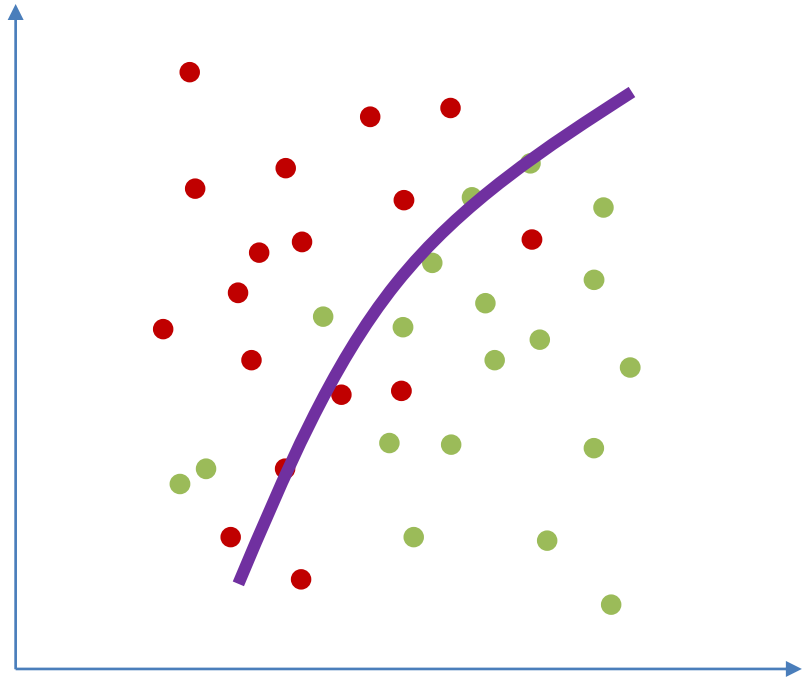

Évaluation en extraction d'information

classe « VERT »

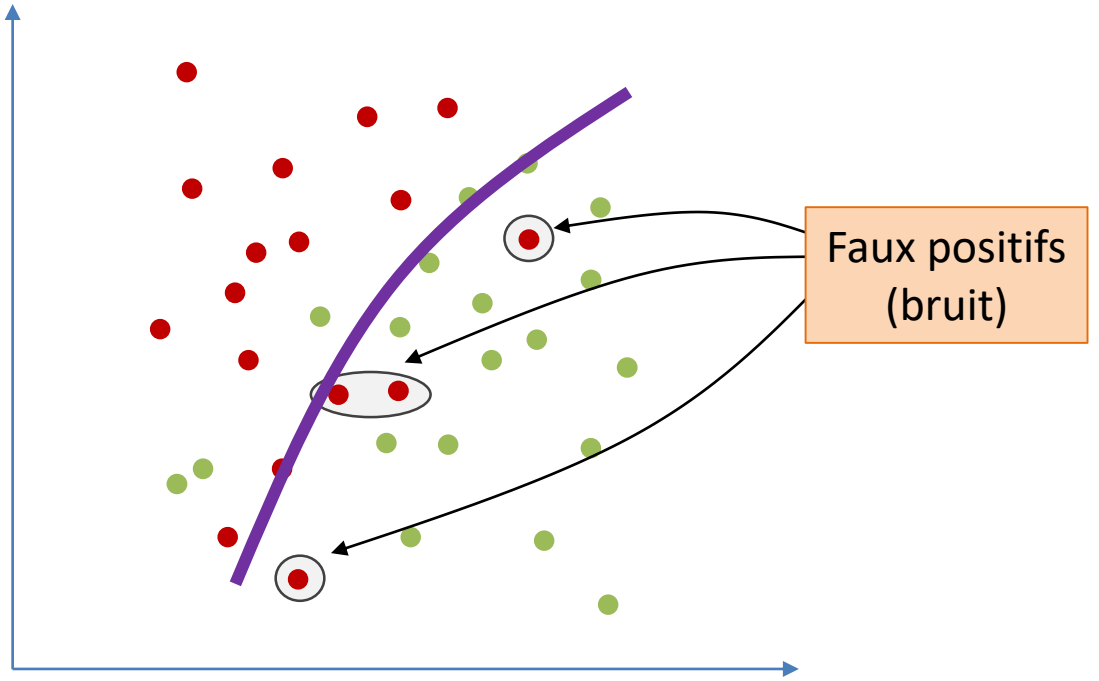

Évaluation en extraction d'information

classe « VERT »

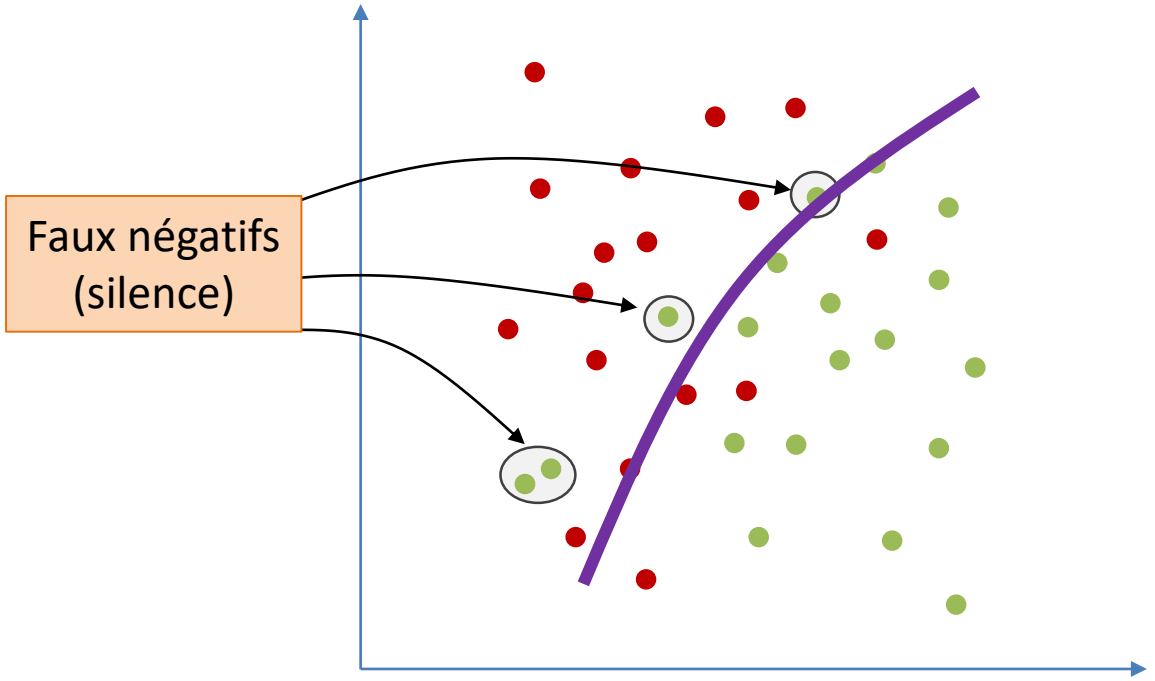

Évaluation en extraction d'information

classe « VERT »

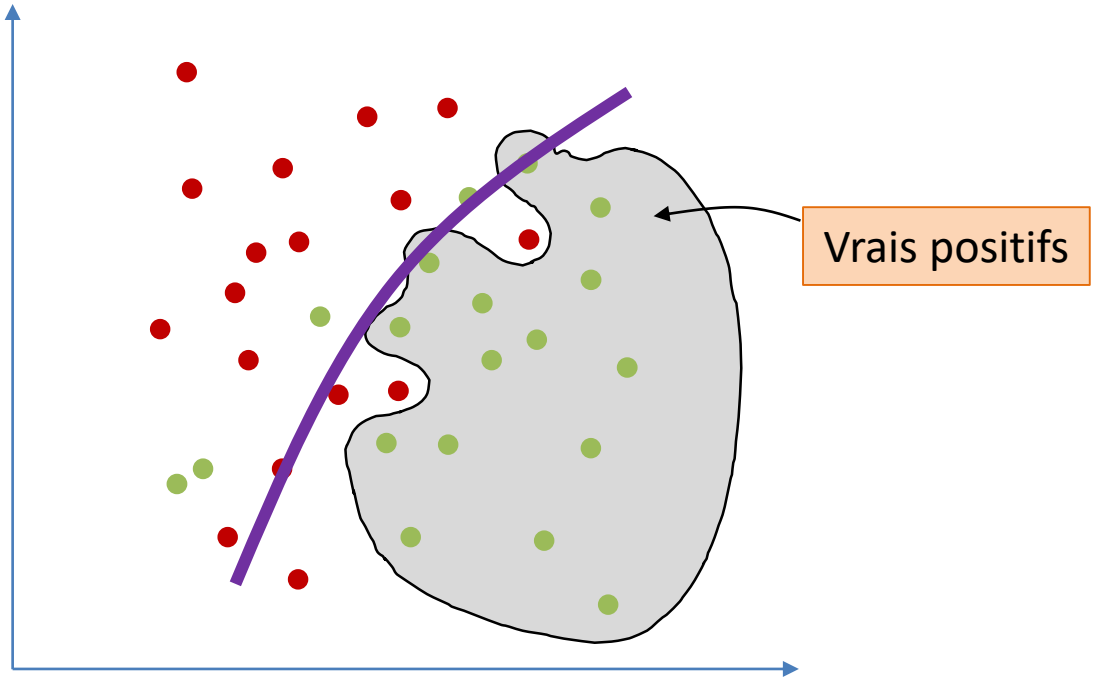

Évaluation en extraction d'information

classe « VERT »

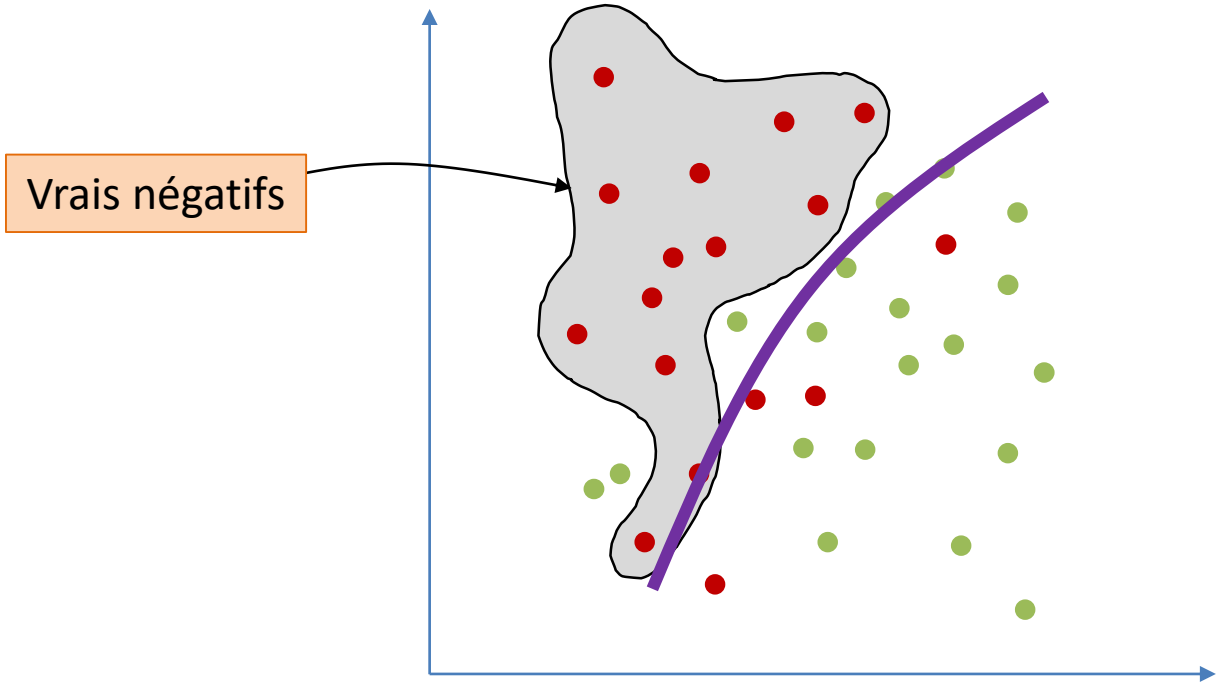

Évaluation en extraction d'information

classe « VERT »

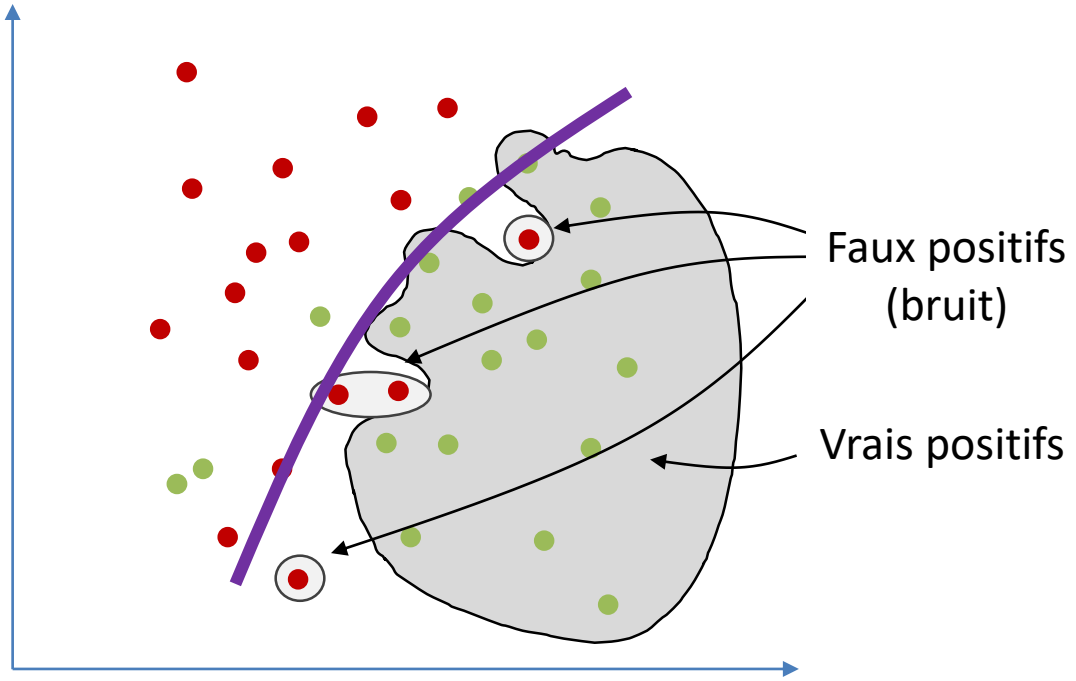

taux de positifs dans la prédiction « VERT » = $\text{Précision} = \frac{\text{Vrais positifs}}{\text{Vrais positifs+Faux positifs}}$ = 1 - bruit

Évaluation en extraction d'information

classe « VERT »

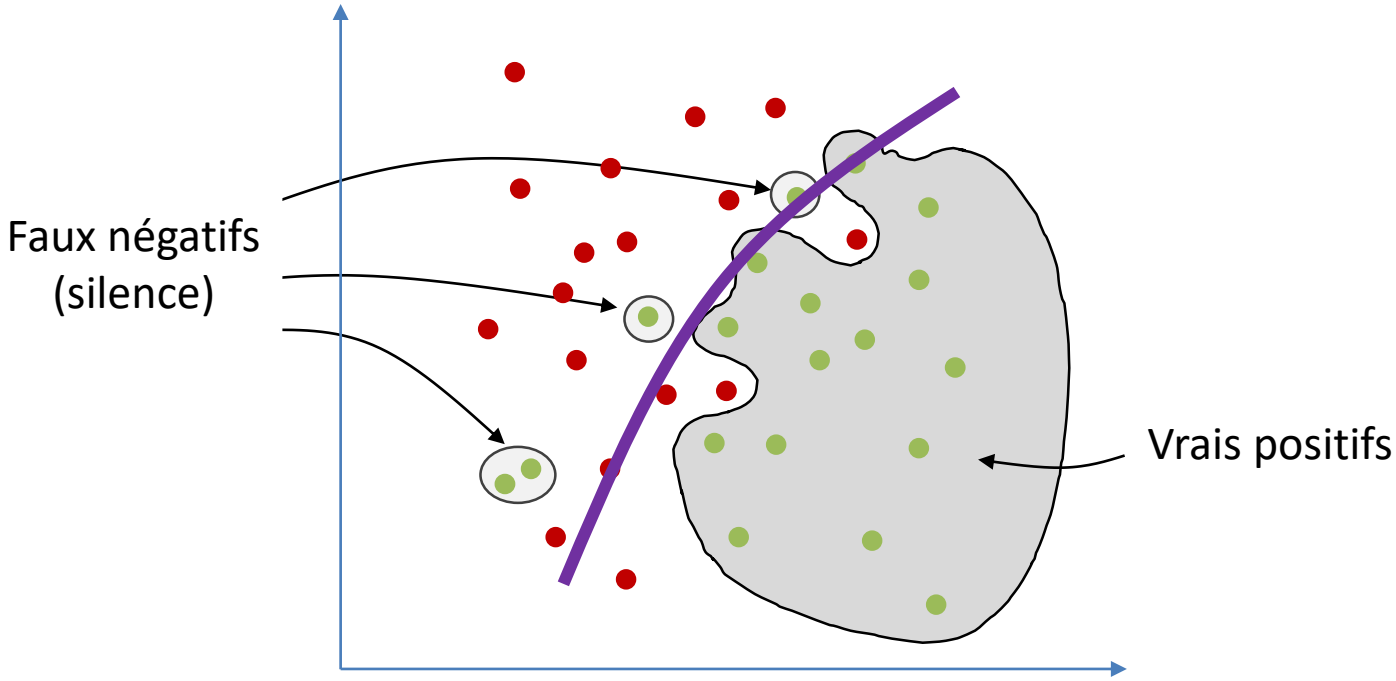

taux de positifs dans la référence « VERT » = $\text{Rappel} = \frac{\text{Vrais positifs}}{\text{Vrais positifs+Faux négatifs}}$ = 1 - silence

Évaluation en extraction d'information

- Précision : le système a-t-il raison quand il annonce la classe ?
- Rappel (ou sensibilité) : le système manque-t-il beaucoup d'éléments de la classe ?
- Spécificité = $\frac{\text{Vrais négatifs}}{\text{Vrais négatifs + Faux positifs}}$ le système évite-t-il les fausses alarmes ?

- F-mesure = moyenne harmonique de précision et rappel

$$= \frac{(1+\beta^2)\times(\text{Précision}\times\text{Rappel})}{(\beta^2\times\text{Précision}+ \text{Rappel})}$$

- F_1-mesure = $2\ \frac{\text{Précision}\times\text{Rappel}}{\text{Précision+Rappel}}$

Évaluation en extraction d'information

- Classification multi-classes : matrice de confusion

		Prédictions		
		Classe 1	Classe 2	Classe 3
Référence	Classe 1	125	9	6
	Classe 2	13	110	52
	Classe 3	6	31	95

Évaluation en extraction d'information

- Accuracy = taux de bonnes réponses, mais ATTENTION à son interprétation !

		Prédictions	
		Pas malade	Malade
Référence	Pas malade	19064	89
	Malade	110	231

- Accuracy = 0,99
- Rappel de la classe malade = 0,68
- Précision de la classe malade = 0,72

→ On préfèrera peut-être la « balanced accuracy »

Évaluation en extraction d'information

- Évaluation de listes ordonnées : tenir compte du rang des réponses

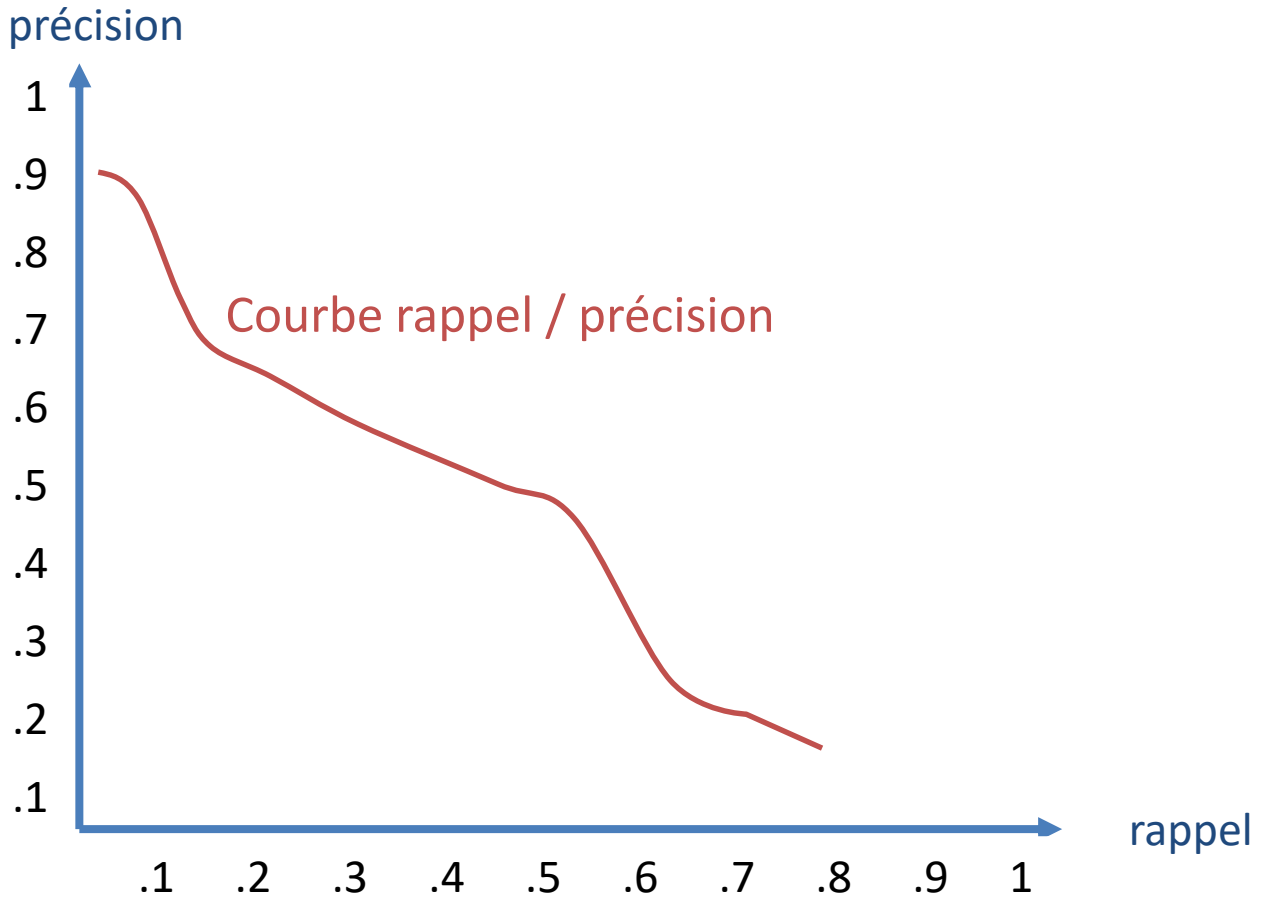

Évaluation en extraction d'information

- Évaluation de listes ordonnées : tenir compte du rang des réponses

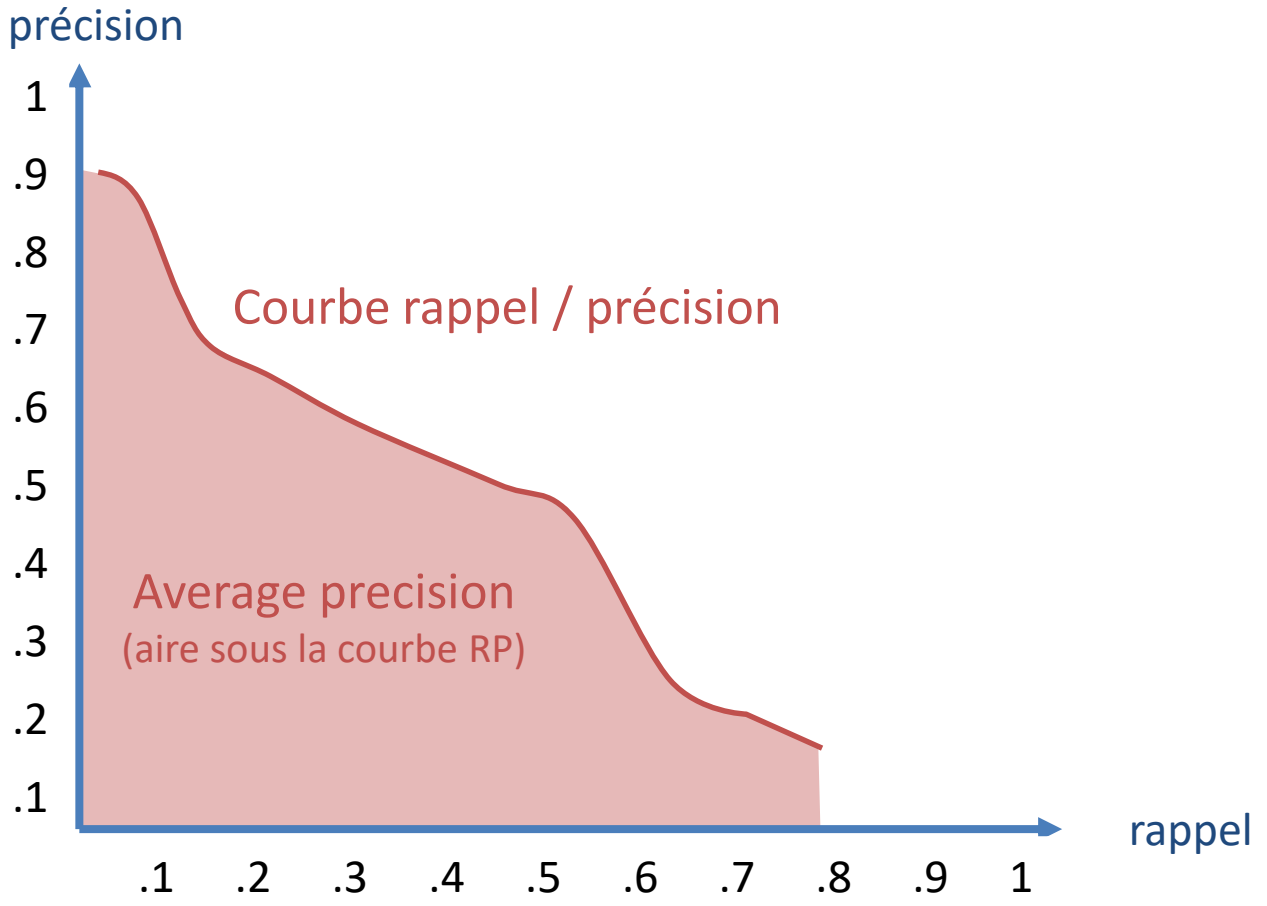

Évaluation en extraction d'information

- Évaluation de listes ordonnées : tenir compte du rang des réponses
  - Précision après *n* éléments (*P@5, P@10*...)
  - Rappel après *k* éléments, où *k* est le nombre d'éléments qu'il fallait renvoyer
  - AUROC
  - Mean Reciprocal Rank (MMR)
  - Mean Average Precision (MAP)

Évaluation en traduction / génération

- BLEU (Bilingual Evaluation Understudy) : comparaison des références et des résultats du système en termes de n-grammes en commun
- METEOR (Metric for Evaluation of Translation with Explicit ORdering) : tient compte des synonymes ou des racines de mots
- ROUGE (Recall-Oriented Understudy for Gisting Evaluation) : métrique plus orientée vers le rappel

- Ces métriques sont controversées et d'autres ont été proposées, sans que la communauté parvienne à un réel consensus

Évaluation en reconnaissance de la parole

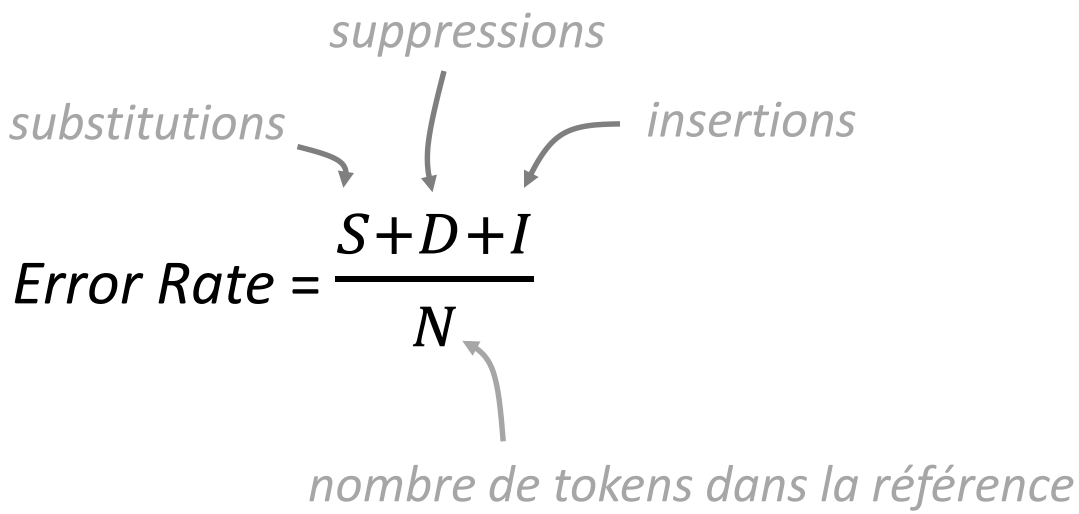

Évaluation des tâches non supervisées

- Pour les modèles de langue, la perplexité : à quel point le modèle est « surpris » de voir des nouvelles phrases (il est surpris s'il a assigné une faible probabilité aux suites de mots)

- Pour le clustering, par exemple
  - La silhouette : est-ce que la cohésion des clusters (similarité intra-cluster) est plus forte que la séparation (distance avec les clusters voisins)
  - La cohérence, par exemple le degré de similarité entre les mots bien classés d'un topic dans le topic modeling

Évaluation intrinsèque vs extrinsèque

- Évaluation intrinsèque = mesure de la performance d'un système sur la tâche elle-même
- Évaluation extrinsèque = mesure de l'apport d'un système sur des tâches aval.
  - Extrinsèque mais « interne » au TAL
    - Stemming : mesure de l'apport sur la recherche d'information
    - Embeddings : mesure de l'apport sur l'extraction d'information
    - Recherche d'information : mesure de l'apport sur la réponse à des questions
  - Extrinsèque applicatif
    - Entités nommées dans des comptes-rendus médicaux : meilleure sélection de cohortes de patients ou de cas similaire ?
    - Analyse de sentiment : meilleur ciblage des actions correctives ?
    - Système de recommandation : augmentation du panier moyen ?

Validation croisée

- Pour les approches par apprentissage, possibilité de « faire tourner » le jeu de validation
- Exemple : validation croisée à 5 plis (*5-fold cross-validation*)
  - On sépare le jeu de données en 5 parties égales
  - On réalise 5 expériences indépendantes

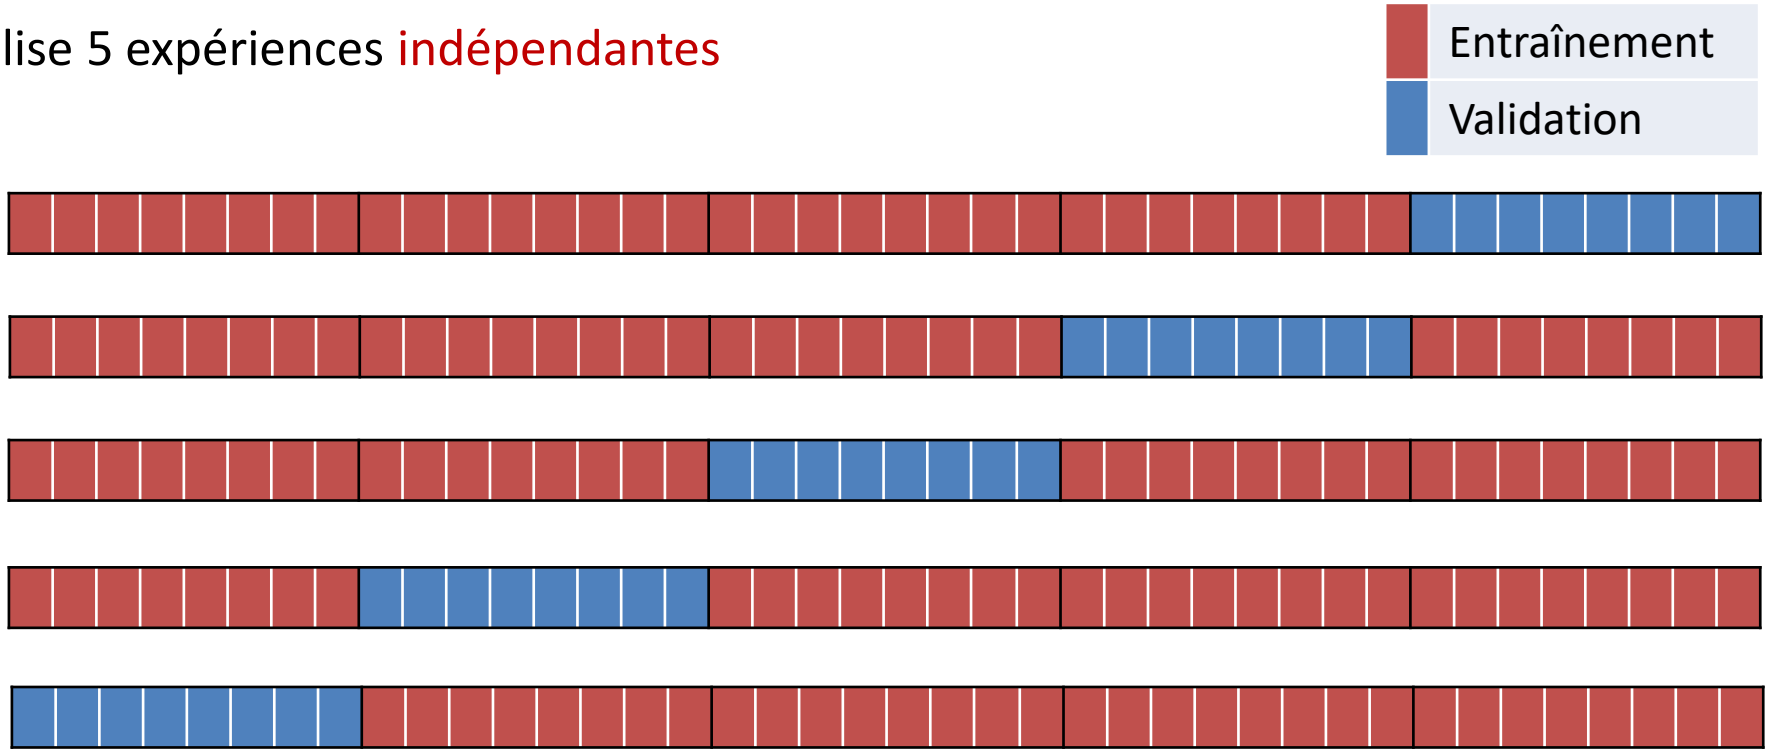

Validation croisée

- Intérêts
  - Évaluer un système sans « gâcher » un jeu de validation
  - Utile pour les petits jeux de données
  - Permet d'estimer la performance de validation d'un système avec des mesures de biais et de variance
    - Si les résultats varient peu d'un pli à l'autre, c'est bon signe pour la représentativité du jeu de données et la généralisabilité du modèle
    - Si les résultats varient beaucoup, c'est mauvais signe mais on l'a repéré, alors qu'un jeu de validation unique ne l'aurait pas permis
- Limites
  - Difficile de déduire les hyperparamètres à choisir au final
  - Ne permet pas de conclure formellement sur les performances réelles du modèle (pour cela on a besoin d'un jeu de test distinct)
  - *k* plis = *k* fois plus coûteux !

Un run n’est pas assez

- Les résultats peuvent dépendre de l’initialisation aléatoire de vos réseaux de neurones
- Fonder vos conclusions sur un seul *run* peut :
  - Masquer des variations importantes, symptômes d’un problème dans votre modèle (difficulté à généraliser)
  - Conduire à des conclusions erronées sur le positionnement par rapport à l’état de l’art

Un run n’est pas assez

- Deux écoles :
  1. Présenter la distribution de vos résultats sur plusieurs *runs* (5, 30… avec un *violin plot* ou un *box plot*)

Reimers, N. & Gurevych, I.
Reporting Score Distributions Makes a Difference: Performance Study of LSTM-networks for Sequence Tagging
EMNLP 2017

Distribution of scores for re-running the system by Ma and Hovy (left) and Lample et al. (right) multiple times with different seed values. Dashed lines indicate quartiles

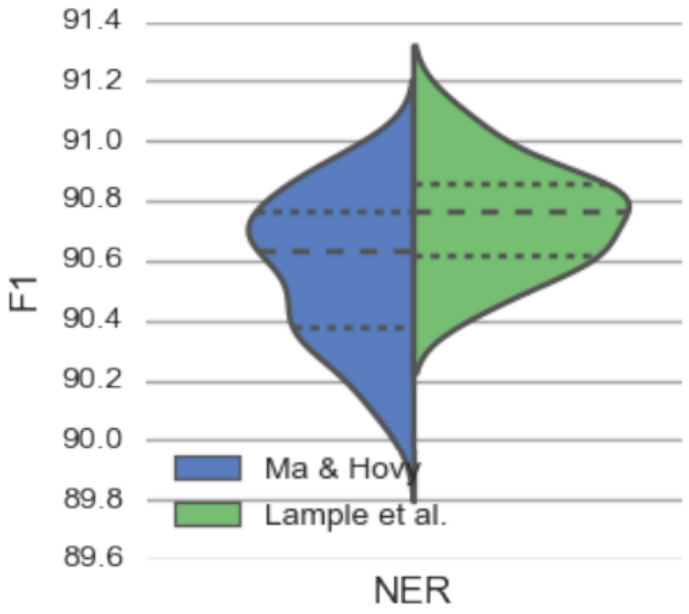

Un run n’est pas assez

- Deux écoles :
  2. Les graines aléatoires devraient être optimisées comme n’importe quel autre hyperparamètre

Bethard, S.
We need to talk about random seeds
ArXiV 2022

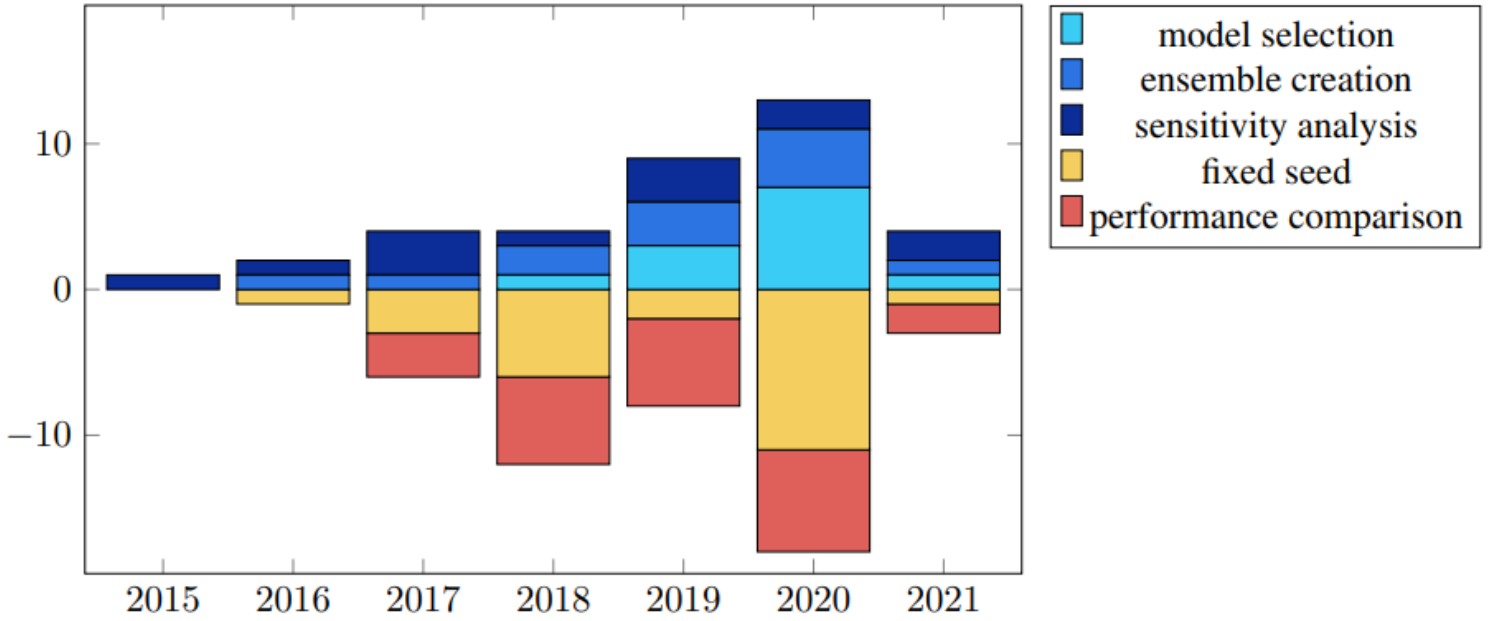

Figure 1: Uses of neural network random seeds by year for 85 ACL Anthology articles.

Une bonne évaluation,

c’est aussi…

L'interprétabilité

Le système sait-il « expliquer » ses prédictions ?

- Quelle partie de l'entrée a conduit à la prédiction ?
  - Saillance et perturbations adversariales
  - Support aux réponses à des questions

- Quelles règles de décision ont conduit à la prédiction ?
- Quels exemples du jeu d'entraînement ont causé la prédiction ?
- Génération d'une explication en langage naturel

- Intégration de la notion d'interprétabilité dans les modèles (mise en abyme)

Yonatan Belinkov, Sebastian Gehrmann, Ellie Pavlick
Interpretability and Analysis in Neural NLP
ACL 2020

Eric Wallace, Matt Gardner, Sameer Singh
Tutorial on Interpreting Predictions of NLP Models
EMNLP 2020

Le coût environnemental

- Des outils existent pour faire une estimation approximative de l'impact carbone d'un algorithme.
  - Estimation à partir de la description de l'outil (ex. Green Algorithms)
  - Mesure directe (ex. Carbon Tracker)

- Mais ce ne sont pour l'instant que des indications très imprécises, tenant compte du temps de l'expérience, mais pas
  - Du cycle de vie du matériel (de la fabrication au recyclage)
  - Du lieu de l'expérience (impact carbone de l'électricité en Allemagne >> celui de la France)

Bannour N, Ghannay S, Ligozat AL, Névéol A.
Evaluating the carbon footprint of NLP methods: a survey and analysis of existing tools.
EMNLP, Workshop SustaiNLP, 2021

Le coût environnemental

- Green Algorithms (en ligne, estimation)

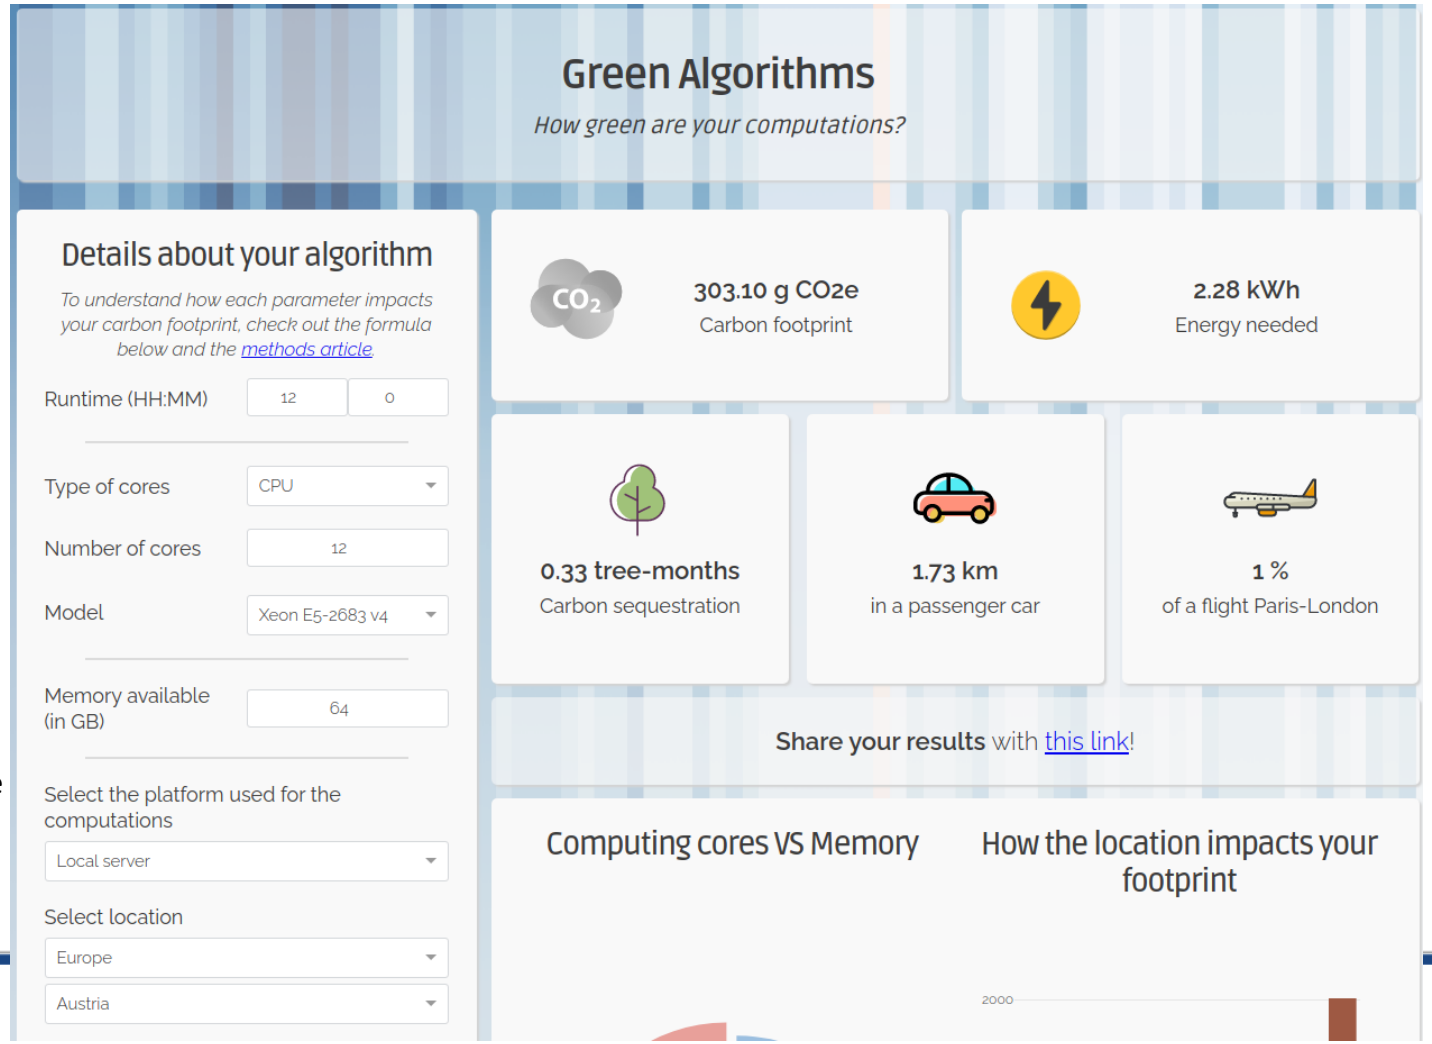

L. Lannelongue, J. Grealey, M. Inouye
Green Algorithms: Quantifying the Carbon Footprint of Computation
Advanced Science, May 2021

Le coût environnemental

- Carbon Tracker

Example usage

```
from carbontracker.tracker import CarbonTracker

tracker = CarbonTracker(epochs=max_epochs)

# Training loop.
for epoch in range(max_epochs):
    tracker.epoch_start()

    # Your model training.

    tracker.epoch_end()

# Optional: Add a stop in case of early termination before all monitor_epochs has
# been monitored to ensure that actual consumption is reported.
tracker.stop()
```

- Et d'autres…

Lasse F. Wolff Anthony, Benjamin Kanding, Raghavendra Selvan
Carbontracker: Tracking and Predicting the Carbon Footprint of Training Deep Learning Models
ICML Workshop on "Challenges in Deploying and monitoring Machine Learning Systems", 2020

La reproductibilité

- Pouvoir reproduire les expériences (réplicabilité, répétabilité)
- Mais aussi pouvoir reproduire :
  - La conclusion générale (ce qu'on apprend d'un article)
  - Les résultats qualitatifs (ce qu'on constate, sans interprétation)
  - Les valeurs (mesurées ou calculées)

K. Bretonnel Cohen, Jingbo Xia, Pierre Zweigenbaum, Tiffany Callahan, Orin Hargraves, Foster Goss, Nancy Ide, Aurélie Névéol, Cyril Grouin, Lawrence E. Hunter
Three Dimensions of Reproducibility in Natural Language Processing
LREC 2018

Anya Belz, Shubham Agarwal, Anastasia Shimorina, Ehud Reiter
A Systematic Review of Reproducibility Research in Natural Language Processing
EACL 2021

La robustesse (face aux attaques)

Kai-Wei Chang, He Ne, Robin Jia, Sameer Singh
ACL workshop on Robustness and Adversarial Examples in NLP
ACL 2021

https://robustnlp-tutorial.github.io/

“

- Finding Lack of Robustness (Attacks)
  - Writing Challenging Examples
  - Generating Adversarial Examples
  - Adversarial Trigger and Text Generation
  - Training Time Attack
- Making Models Robust (Defenses)
  - Robustness to Spurious Correlations
  - Adversarial Training for Defense
  - Certified Robustness in NLP
  - Test time-defense: detecting adversarial examples

”

L’éthique

- Les biais cognitifs (genre, origine ethnique et sociale…)
- Le respect de vos valeurs (applications…)
- La gestion des données confidentielles
- L’information honnête du grand public
- Et de nombreux autres sujets

- … mercredi avec Karën Fort !

Pointeurs utiles

En vrac

The NLP Index

Articles, code, graphe : https://index.quantumstat.com/

Search... Expand

Origin paper

Manual Evaluation Matters: Reviewing Test Protocols of Distantly Supervised Relation Extraction
Tianyu Gao, Xu Han, Keyue Qiu, Yuzhuo Bai, Zhiyu Xie, Yankai Lin, Zhiyuan Liu, Peng Li,... 2021

Learning from Context or Names? An Empirical Study on Neural Relation Extraction
Hao Peng, Tianyu Gao, X. Han, Yankai Lin, Peng Li, Zhiyuan Liu, M. Sun, Jie Zhou 2020

More Data, More Relations, More Context and More Openness: A Review and Outlook for Relation Extraction
Xu Han, Tianyu Gao, Yankai Lin, H. Peng, Y. Yang, Chaojun Xiao, Zhiyuan Liu, Peng Li,... 2020

REKER: Relation Extraction with Knowledge of Entity and Relation
H. Liu, Yian Wang, Fangzhao Wu, Pengfei Jiao, Hongyan Xu, X. Xie 2019

A survey on neural relation extraction
Kang Liu 2020

Neural relation extraction: a survey
Mehmet Aydar, Ozge Bozal, Furkan Özbay 2020

Hierarchical Relation Extraction with Coarse-to-Fine Grained Attention
Xu Han, Pengfei Yu, Zhiyuan Liu, M. Sun, Peng Li 2018

Two Training Strategies for Improving Relation Extraction over Universal Graph
Qinyun Dai, Naoya Inoue, Ryo Takahashi, Kentaro Inui 2021

A Hybrid Model with Pre-trained Entity-Aware Transformer for Relation Extraction
Jinxin Yao, Min Zhang, B. Wang, Xianda Xu 2020

Multi-task Learning for Relation Extraction
Kai Zhou, X. Luo, Hongya Wang, R. Xu 2019

Towards Accurate and Consistent Evaluation: A Dataset for Distantly-Supervised Relation Extraction
Tong Zhu, Haitao Wang, Junjie Yu, Xiabing Zhou, W. Chen, W. Zhang, Min Zhang 2020

OpenNRE: An Open and Extensible Toolkit for Neural Relation Extraction
Xu Han, Tianyu Gao, Y. Yao, D. Ye, Zhiyuan Liu, M. Sun 2019

Improving Distant Supervised Relation Extraction by Dynamic Neural Network
Yanjie Gou, Y. Lei, Lingqiao Liu, Pingping Zhang, Xi Peng 2019

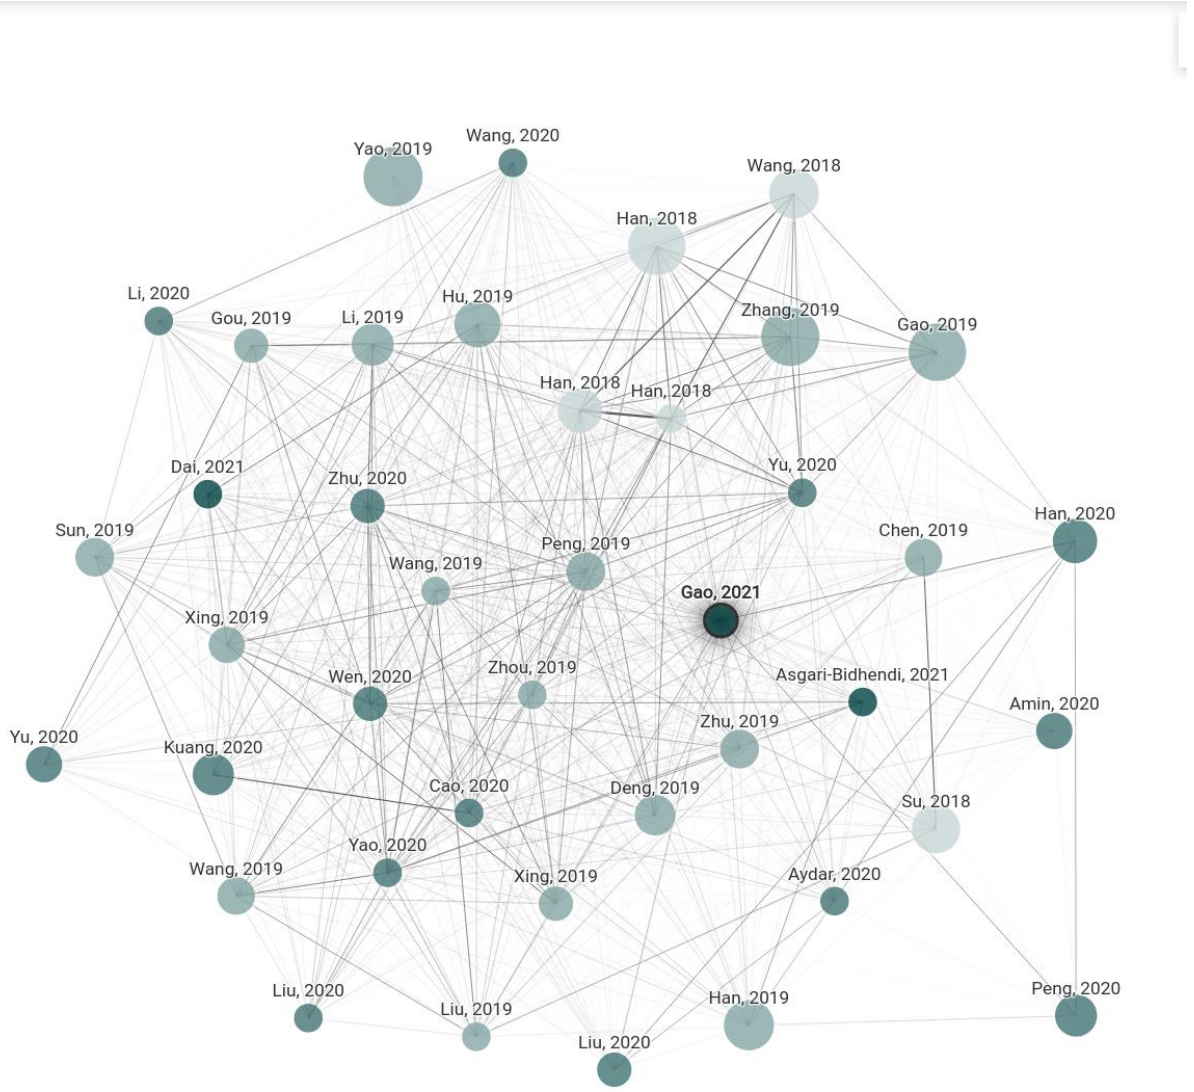

Leaderboards,
articles,
code :
https://paperswithcode.com/

Papers With Code

Named Entity Recognition

Named Entity Recognition on CoNLL 2003 (English)

Leaderboard | Dataset

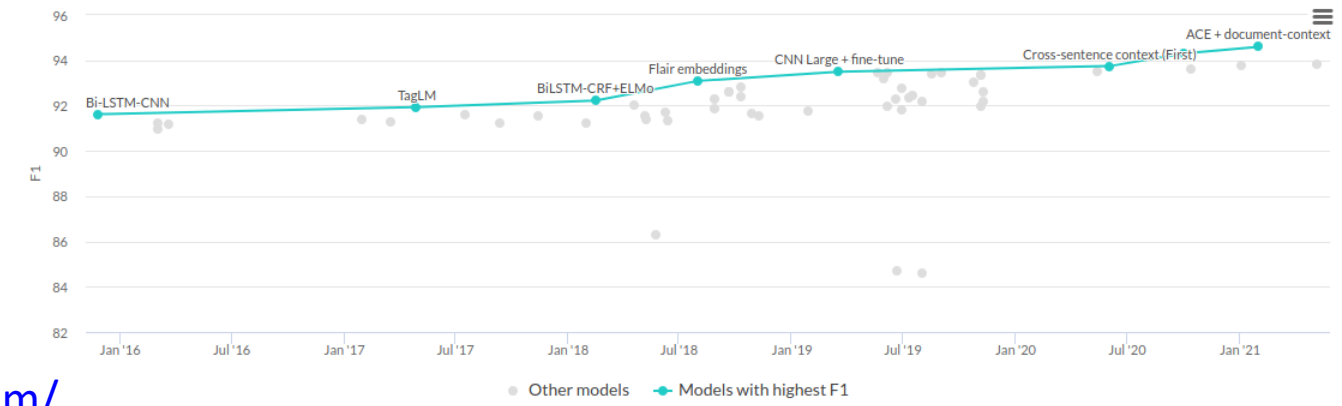

View F1 All models Edit Leaderboard

Rank	Model	F1	Extra Training Data	Paper	Code	Result	Year
1	**ACE + document-context**	94.6	×	Automated Concatenation of Embeddings for Structured Prediction			2021
2	**LUKE**	94.3	×	LUKE: Deep Contextualized Entity Representations with Entity-aware Self-attention			2020
3	**CL-KL**	93.85	×	Improving Named Entity Recognition by External Context Retrieving and Cooperative Learning			2021
4	**InferNER**	93.76	×	InferNER: an attentive model leveraging the sentence-level information for Named Entity Recognition in Microblogs			2021
5	**Cross-sentence context** (First)	93.74	×	Exploring Cross-sentence Contexts for Named Entity Recognition with BERT			2020

NLP progress

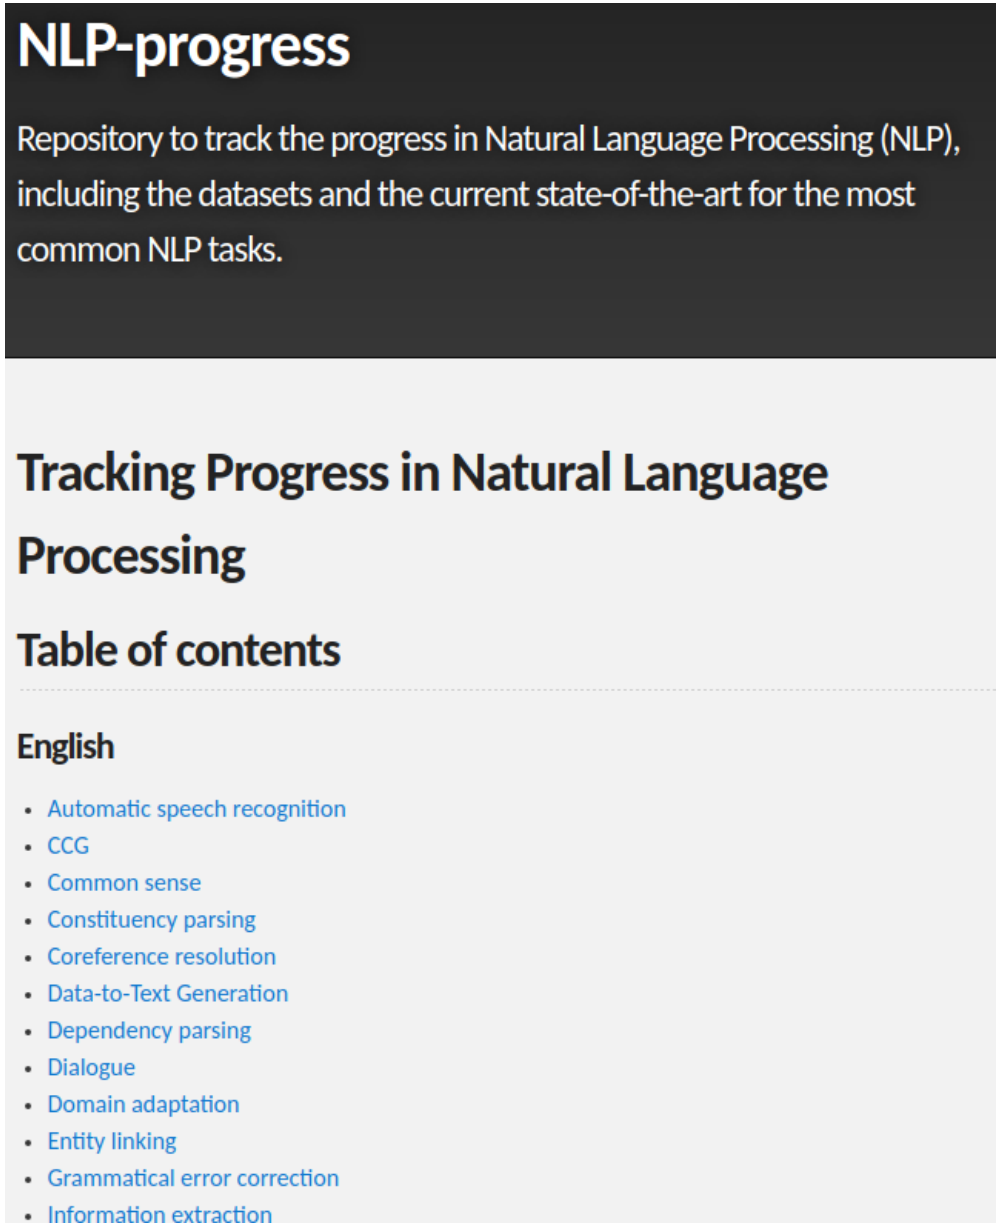

NLP-progress

Repository to track the progress in Natural Language Processing (NLP), including the datasets and the current state-of-the-art for the most common NLP tasks.

Tracking Progress in Natural Language Processing

Table of contents

English

- Automatic speech recognition
- CCG
- Common sense
- Constituency parsing
- Coreference resolution
- Data-to-Text Generation
- Dependency parsing
- Dialogue
- Domain adaptation
- Entity linking
- Grammatical error correction
- Information extraction

http://nlpprogress.com/

THE NLP PANDECT

"almost anything related to Natural Language Processing that is available online"
https://github.com/ivan-bilan/The-NLP-Pandect

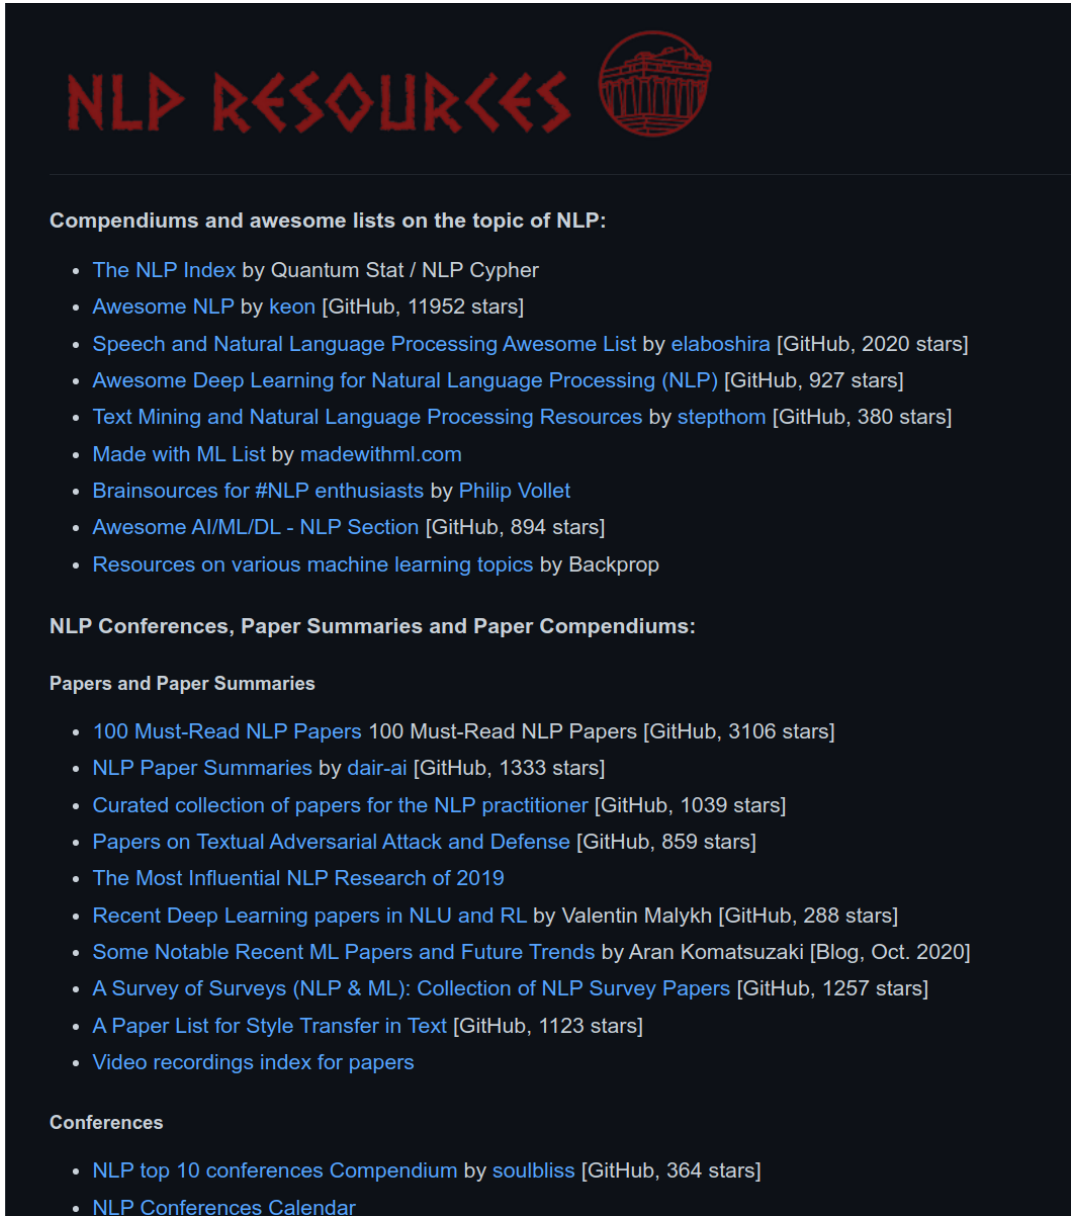

NLP RESOURCES

Compendiums and awesome lists on the topic of NLP:

- The NLP Index by Quantum Stat / NLP Cypher
- Awesome NLP by keon [GitHub, 11952 stars]
- Speech and Natural Language Processing Awesome List by elaboshira [GitHub, 2020 stars]
- Awesome Deep Learning for Natural Language Processing (NLP) [GitHub, 927 stars]
- Text Mining and Natural Language Processing Resources by stepthom [GitHub, 380 stars]
- Made with ML List by madewithml.com
- Brainsources for #NLP enthusiasts by Philip Vollet
- Awesome AI/ML/DL - NLP Section [GitHub, 894 stars]
- Resources on various machine learning topics by Backprop

NLP Conferences, Paper Summaries and Paper Compendiums:

Papers and Paper Summaries

- 100 Must-Read NLP Papers 100 Must-Read NLP Papers [GitHub, 3106 stars]
- NLP Paper Summaries by dair-ai [GitHub, 1333 stars]
- Curated collection of papers for the NLP practitioner [GitHub, 1039 stars]
- Papers on Textual Adversarial Attack and Defense [GitHub, 859 stars]
- The Most Influential NLP Research of 2019
- Recent Deep Learning papers in NLU and RL by Valentin Malykh [GitHub, 288 stars]
- Some Notable Recent ML Papers and Future Trends by Aran Komatsuzaki [Blog, Oct. 2020]
- A Survey of Surveys (NLP & ML): Collection of NLP Survey Papers [GitHub, 1257 stars]
- A Paper List for Style Transfer in Text [GitHub, 1123 stars]
- Video recordings index for papers

Conferences

- NLP top 10 conferences Compendium by soulbliss [GitHub, 364 stars]
- NLP Conferences Calendar

En vrac (pour la veille et la formation)

- ACL Anthology https://www.aclweb.org/anthology/

- #NLProc 
- arXiv Computation and Language https://arxiv.org/list/cs.CL/recent

En vrac (pour la veille et la formation)

- ACL Anthology https://www.aclweb.org/anthology/

- #NLProc
- arXiv Computation and Language https://arxiv.org/list/cs.CL/recent

Le statut des articles revus par des pairs et publiés n'est pas le même que celui des preprints et des discussions des réseaux sociaux !

(malgré la crise actuelle du peer-reviewing en NLP)

Anna Rogers, Isabelle Augenstein
What Can We Do to Improve Peer Review in NLP?
Findings of EMNLP, 2020

En vrac (pour la veille et la formation)

- ACL Anthology https://www.aclweb.org/anthology/

- #NLProc
- arXiv Computation and Language https://arxiv.org/list/cs.CL/recent

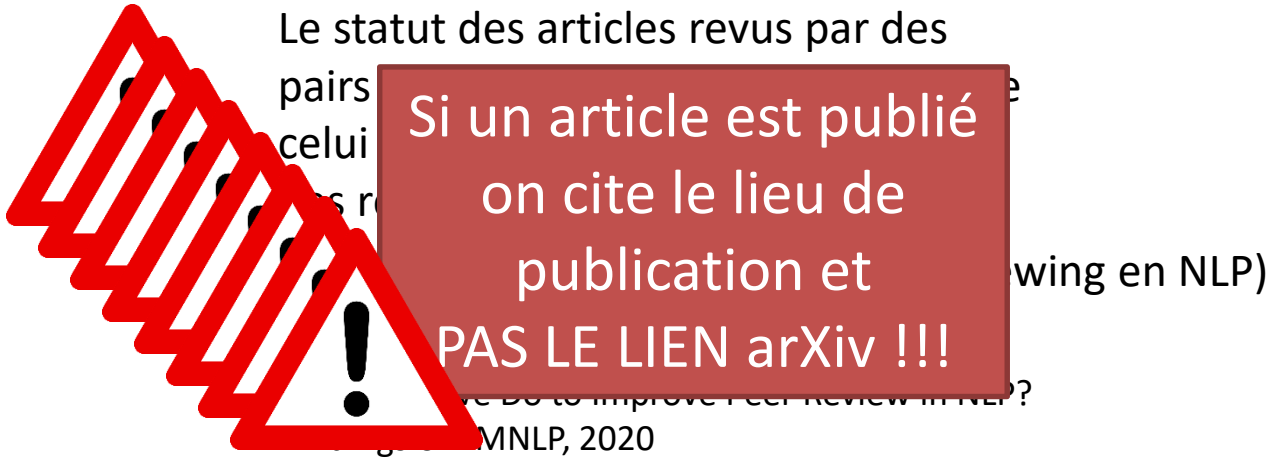

En vrac (pour la veille et la formation)

- ACL Anthology https://www.aclweb.org/anthology/

- #NLProc 
- arXiv Computation and Language https://arxiv.org/list/cs.CL/recent
- La liste de diffusion corpora https://mailman.uib.no/listinfo/corpora

- ATALA et liste LN https://www.atala.org/
- Le blog éthique et TAL : http://www.ethique-et-tal.org/

- Les cours d'Hugo Larochelle https://www.youtube.com/user/hugolarochelle
- Les cours de Stanford https://www.youtube.com/watch?v=8rXD5-xhemo
- Le blog de Sebastian Ruder https://ruder.io/

En vrac

- Campagnes d'évaluation / shared tasks
  - SemEval
  - CLEF
  - TREC
  - NTCIR
  - MediaEval
  - DEFT 🇫🇷
  - Quaero 🇫🇷
  - ESTER 🇫🇷
  - Workshop on Machine Translation (WMT)
  - VarDial
  - Kaggle
- … et beaucoup, beaucoup d'autres initiatives et benchmarks utiles

Très en vrac

- https://github.com/brianspiering/awesome-dl4nlp
- https://towardsdatascience.com/a-collection-of-must-known-pre-requisite-resources-for-every-natural-language-processing-nlp-a18df7e2e027
- https://www.kaggle.com/tags/nlp
- https://github.com/niderhoff/nlp-datasets
- https://data.world/datasets/nlp

Quelques outils

(liste personnelle, incomplète et biaisée)

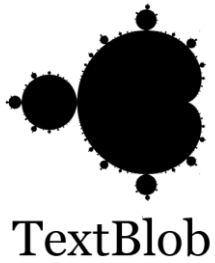

Fin !

xavier.tannier@sorbonne-universite.fr