



Le traitement du langage naturel en 2023

SSIE workshop, mars 2023

Lonneke van der Plas, Idiap

lonneke.vanderplas@idiap.ch



Qui suis-je?



MPhil University of Cambridge

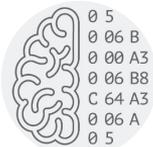
PhD University of Groningen

Junior Professorship
University of Stuttgart

Postdoc University of Geneva

Associate Prof. University of Malta

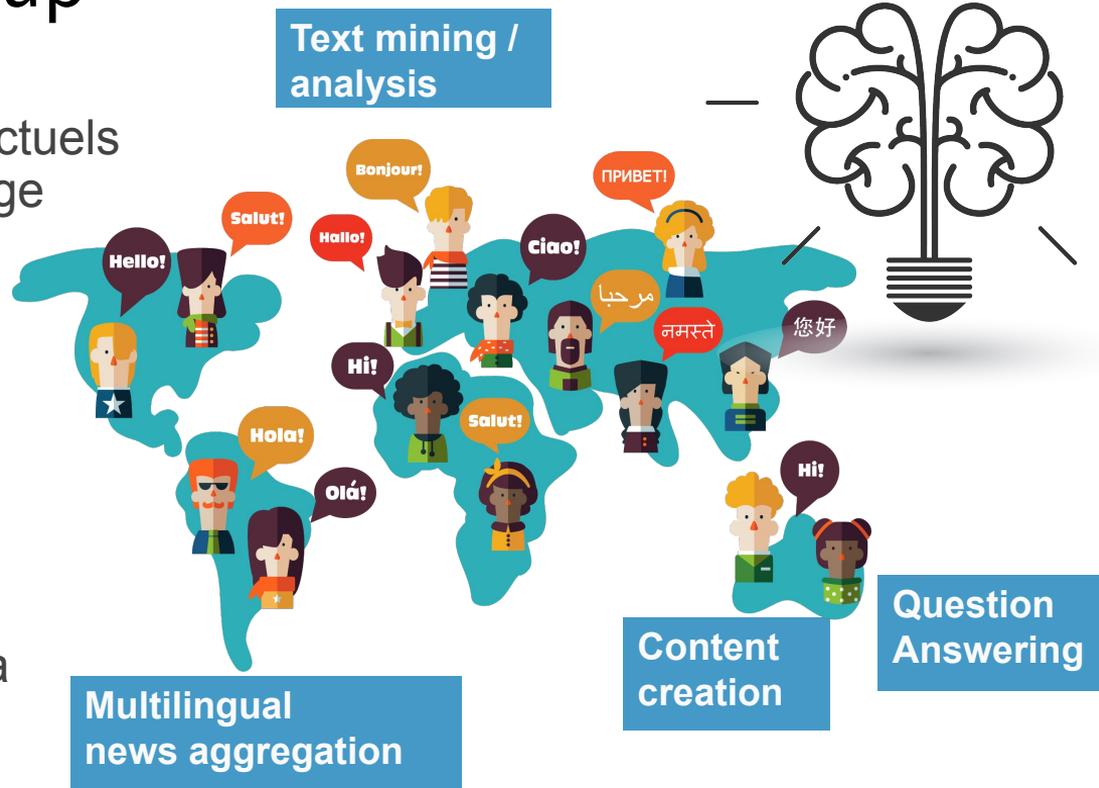
Actuellement responsable du groupe *Computation, Cognition & Language* à l'Idiap à Martigny

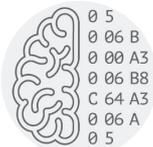


Computation, Cognition & Language Group

Limites des systèmes d'IA actuels
en ce qui concerne le langage

- Développement de technologie du langage multilingue
- Modélisation des capacités cognitives humaines sous-exposées, telles que la créativité

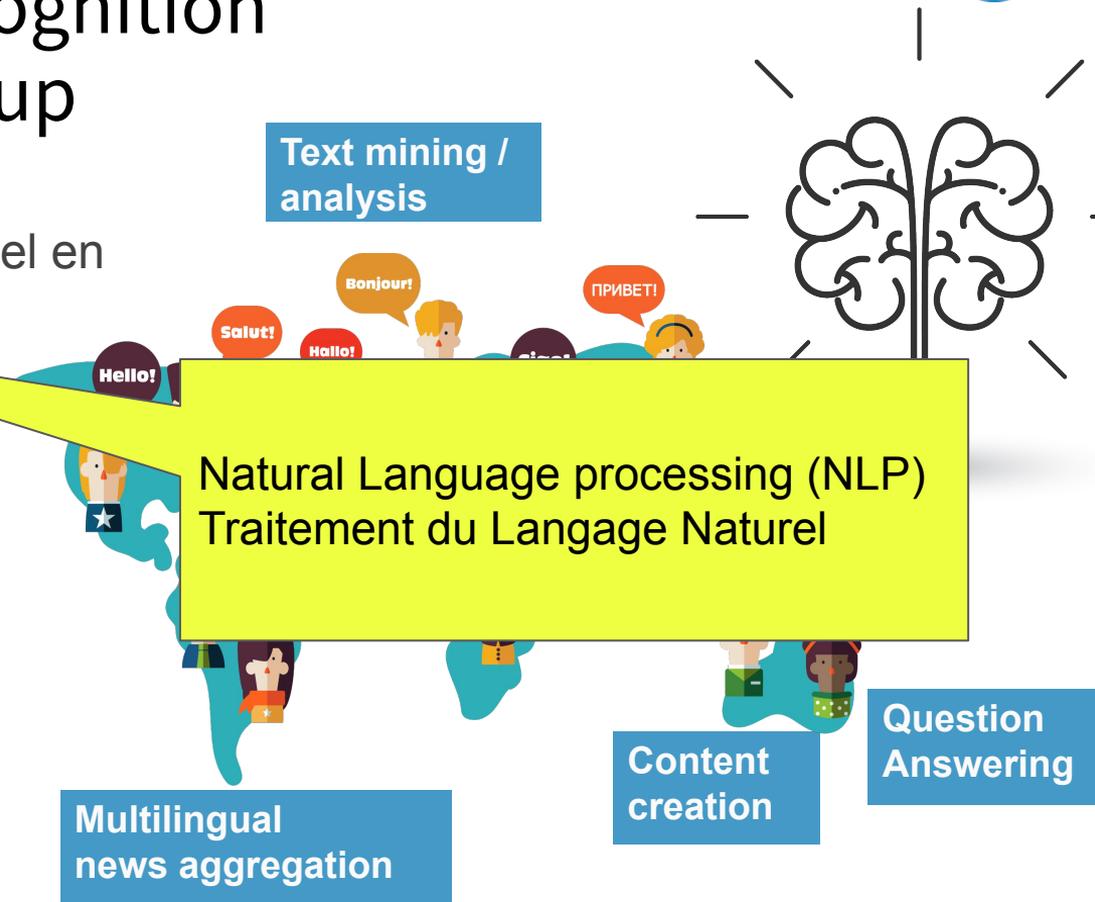




Computation, Cognition & Language Group



- Limites du système d'IA actuel en ce qui concerne la langue :
- Développement de technologie du langage multilingue
- Modélisation des capacités cognitives humaines sous-exposées, telles que la créativité





+3 Cross Research Groups

Expertise

Signal Processing

Computer Vision

Robotics

Machine Learning

Speech & Language

Human Computer Inter.

Privacy & Security

Data Science

Data types

Text

Speech and Audio

Images

Video

...

Application domains

Health and

Life Sciences

Energy

Security

Manufacturing and

Industry 4.0

Media and

Entertainment

Devices



+150 employees, +65 research projects and +120 publications per year

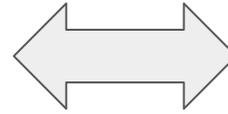
Les merveilles du NLP

- Le domaine du NLP a fait d'énormes progrès
- Il est de plus en plus utilisé dans notre quotidien
- Il y a beaucoup d'avantages, mais aussi plusieurs menaces



Miracle of the Slave by Tintoretto, from Wikimedia Commons

Que doit contenir un modèle de langage ?



***Probike*shop**

Que doit contenir un modèle de langage ?

Le sens des mots : quels mots sont similaires ?

Que doit contenir un modèle de langage ?

Le sens des mots : quels mots sont similaires ?

Un chien mord un homme \neq Un homme mord un chien

Que doit contenir un modèle de langage ?

Le sens des mots : quels mots sont similaires ?

La structure du langage

Que doit contenir un modèle de langage ?

Le sens des mots : quels mots sont similaires ?

La structure du langage

Utilisateur : Dois-je apporter un parapluie demain à Martigny ?

Système : Il n'y aura pas de pluie demain à Martigny, donc non.

Que doit contenir un modèle de langage ?

Le sens des mots : quels mots sont similaires ?

La structure du langage

Connaissance du monde

Que doit contenir un modèle de langage ?

Le sens des mots : quels mots sont similaires ?

La structure du langage

Connaissance du monde

Rien d'autre?

Que doit contenir un modèle de langage ?

Le sens des mots : quels mots sont similaires ?

La structure du langage

Connaissance du monde

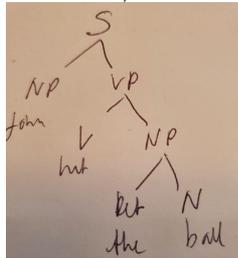
Savoir raisonner

Modèles informatiques du langage (un peu d'histoire)

Le domaine du NLP/CL a commencé avec des modèles qui étaient des versions informatisées de modèles que les linguistes avaient développés « à l'aide d'un stylo et de papier ».

John hit the ball

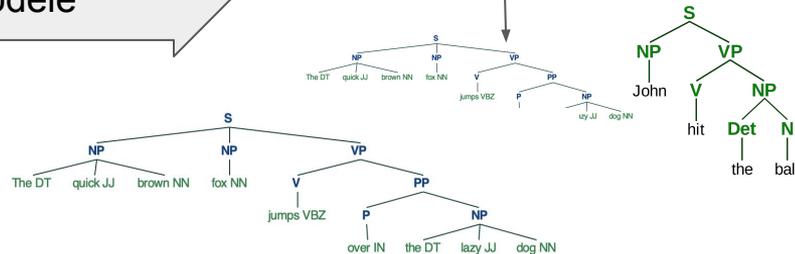
Modèle que le linguiste a écrit



Utiliser un langage de programmation pour numériser le modèle

John hit the ball. After that, the girl wanted to find the .. and the bla blah blah ...

Modèle qui peut être traité par ordinateur

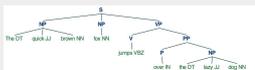


Modèles informatiques du langage (un peu d'histoire)

Puis vint la révolution statistique... avec un accent sur les données

'Treebanks' avec des structures/informations linguistiques annotées par des linguistes

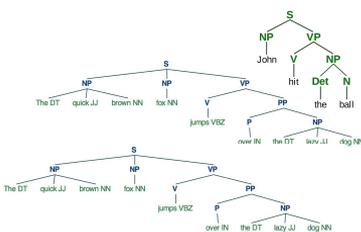
Données annotées



Utiliser machine learning pour construire un modèle de langage

John hit the ball. After that, the girl wanted to find the .. and the bla blah blah ...

Modèle générique qui peut être traité par ordinateur



Modèles informatiques du langage (un peu d'histoire)

Ensuite, on a voulu extraire automatiquement des modèles sans compter sur les annotations

~~'Treebanks' avec des structures/informations linguistiques annotées par des linguistes~~

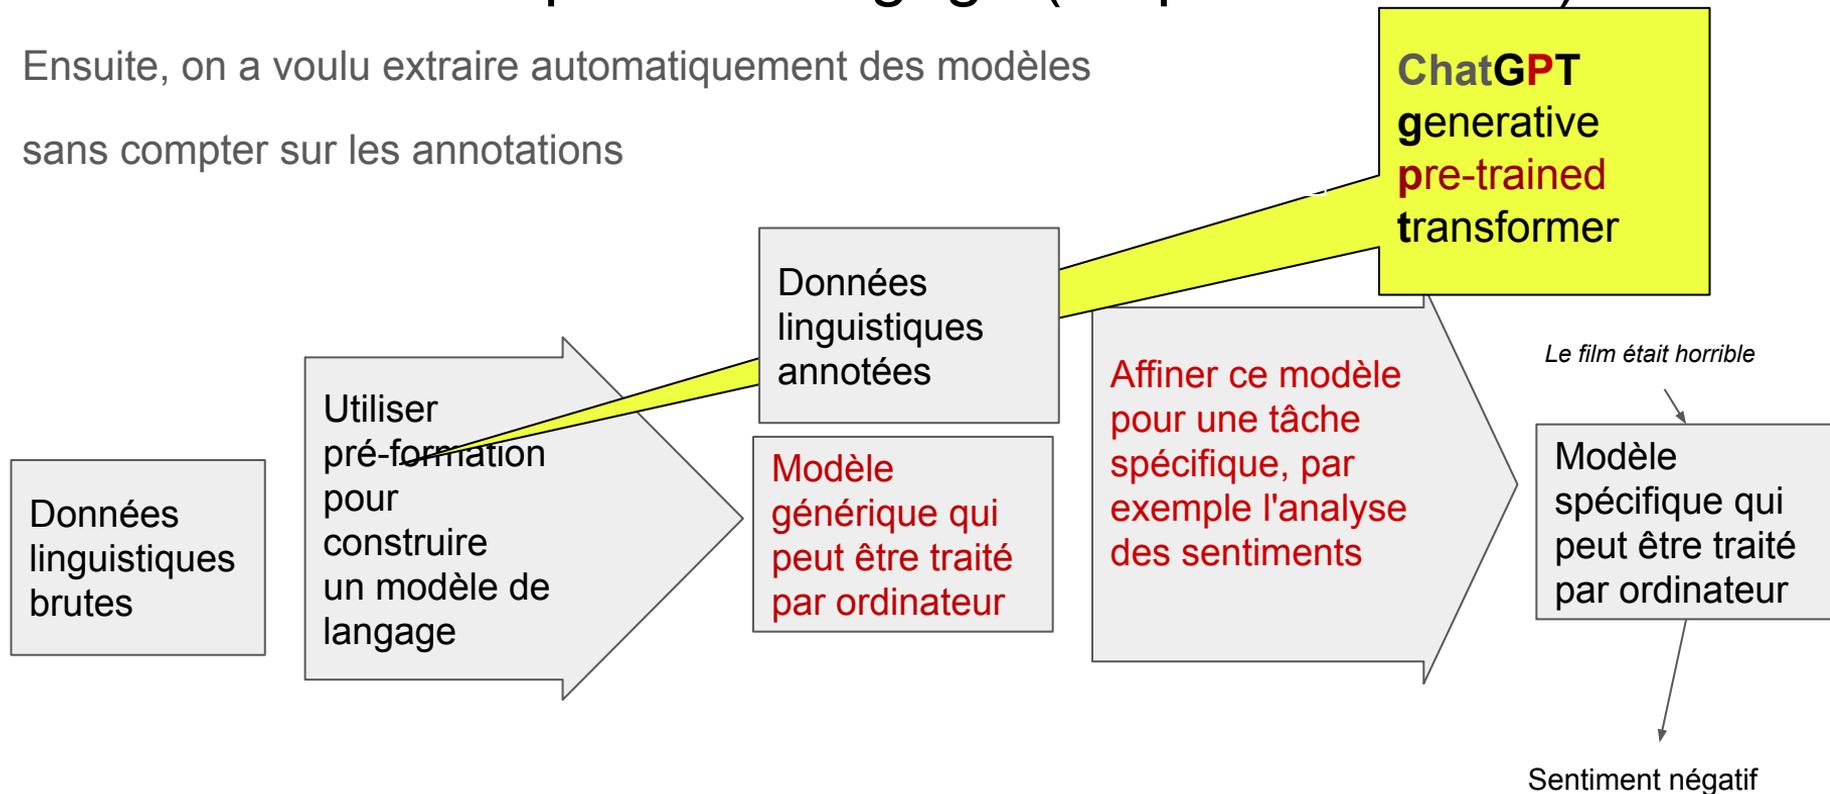
Données linguistiques brutes

Utiliser machine learning pour construire un modèle de langage

Modèle générique qui peut être traité par ordinateur

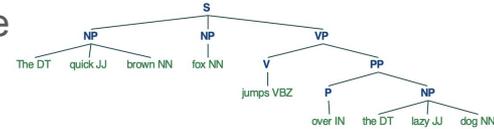
Modèles informatiques du langage (un peu d'histoire)

Ensuite, on a voulu extraire automatiquement des modèles sans compter sur les annotations



Comment les machines apprennent-elles ?

- Ils peuvent apprendre de manière supervisée
 - Ils ont besoin de données annotées/étiquetées en entrée
 - Les annotations sont faites par des humains et coûtent de l'argent
 - Non disponible pour toutes les langues du monde
- Ils peuvent apprendre de manière non supervisée
 - Vous leur donnez des textes bruts et ils devraient comprendre comment les données peuvent être organisées
- Ils peuvent apprendre de manière self-supervisée
 - Pas besoin d'étiquettes. Une partie des données est ce qui doit être prédit. Apprend ce qui est bon ou mauvais à partir des données elles-mêmes



Comment les machines apprennent-elles ?

- Ils peuvent apprendre de manière supervisée
 - Ils ont besoin de données annotées/étiquetées en entrée
 - Les annotations sont faites par des humains et coûtent de l'argent
 - Non disponible pour toutes les langues du monde
- Ils peuvent apprendre de manière non supervisée
 - Vous leur donnez des textes bruts et ils devraient comprendre comment les données peuvent être organisées
- Ils peuvent apprendre de manière self-supervisée
 - Pas besoin d'étiquettes. Une partie des données est ce qui doit être prédit. Apprend ce qui est bon ou mauvais à partir des données elles-mêmes

Ces modèles intègrent les connaissances qui sont explicitement données

Ces modèles apprennent à trouver des modèles dans les données sans avoir vu d'exemples étiquetés

The infamous black box

Ils atteignent de très bonnes performances lorsqu'ils sont utilisés pour plusieurs applications

Que doit contenir un modèle de langage ?

Le sens des mots : quels mots sont similaires ?

La structure du langage

Connaissance du monde

Savoir raisonner

Sémantique distributionnelle

L'hypothèse distributionnelle de Harris (1968) :

Les mots qui apparaissent dans les mêmes contextes ont tendance à avoir des significations similaires

Implication pratique :

Nous pouvons trouver des mots similaires en comparant leur distribution dans les contextes

Sémantique distributionnelle

Kzvarit ?????

Les contextes :

Deux bouteilles de **Kzvarit**!

J'aime mon **Kzvarit** *on the rocks*.

Il buvait beaucoup de **Kzvarit**, mais il n'était jamais vraiment ivre.

Sémantique distributionnelle

Les mêmes contextes fonctionnent pour:

Martini

Les contextes :

Deux bouteilles de **Martini** !

J'aime mon **Martini** *on the rocks*.

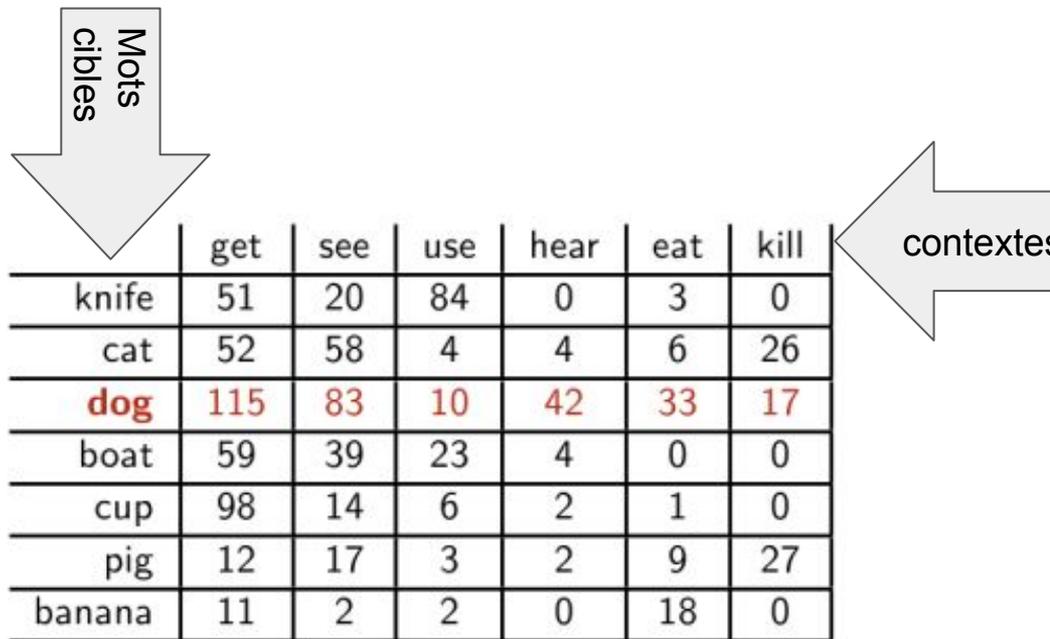
Il buvait beaucoup de **Martini**, mais il n'était jamais vraiment ivre.

Peut-on calculer la similarité sémantique en utilisant des contextes ?

Comptons combien de fois les mots apparaissent dans plusieurs contextes

Et vérifiez ensuite si des mots sémantiquement similaires apparaissent effectivement dans des contextes similaires

Le chat ressemble-t-il plus au chien qu'au couteau ?



Mots cibles	get	see	use	hear	eat	kill
knife	51	20	84	0	3	0
cat	52	58	4	4	6	26
dog	115	83	10	42	33	17
boat	59	39	23	4	0	0
cup	98	14	6	2	1	0
pig	12	17	3	2	9	27
banana	11	2	2	0	18	0

Comment mesurer la similarité ?

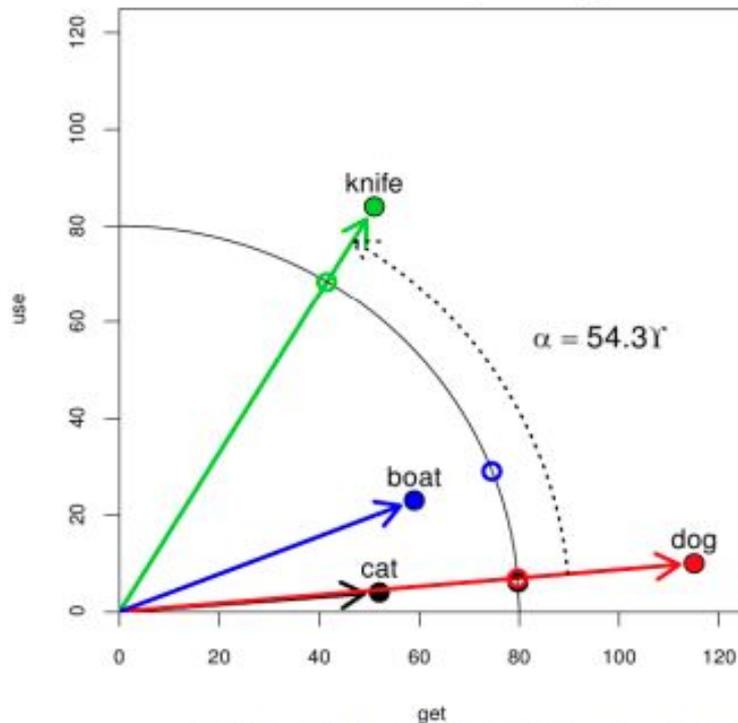
	get	see	use	hear	eat	kill
knife	51	20	84	0	3	0
cat	52	58	4	4	6	26
dog	115	83	10	42	33	17
boat	59	39	23	4	0	0
cup	98	14	6	2	1	0
pig	12	17	3	2	9	27
banana	11	2	2	0	18	0

Mots cibles comme vecteurs

Contextes en tant que dimensions
(exemple avec seulement deux contextes/dimensions)

Calculer l'angle entre les vecteurs
à l'aide de la mesure cosinus

Vous donne une valeur entre 0 et 1



Caractéristiques sémantiques redéfinies



~~[A quatre
pattes, est
poilu, est
vivant]~~



~~[A quatre pattes,
n'est pas vivant, est
en bois]~~



Caractéristiques sémantiques redéfinies



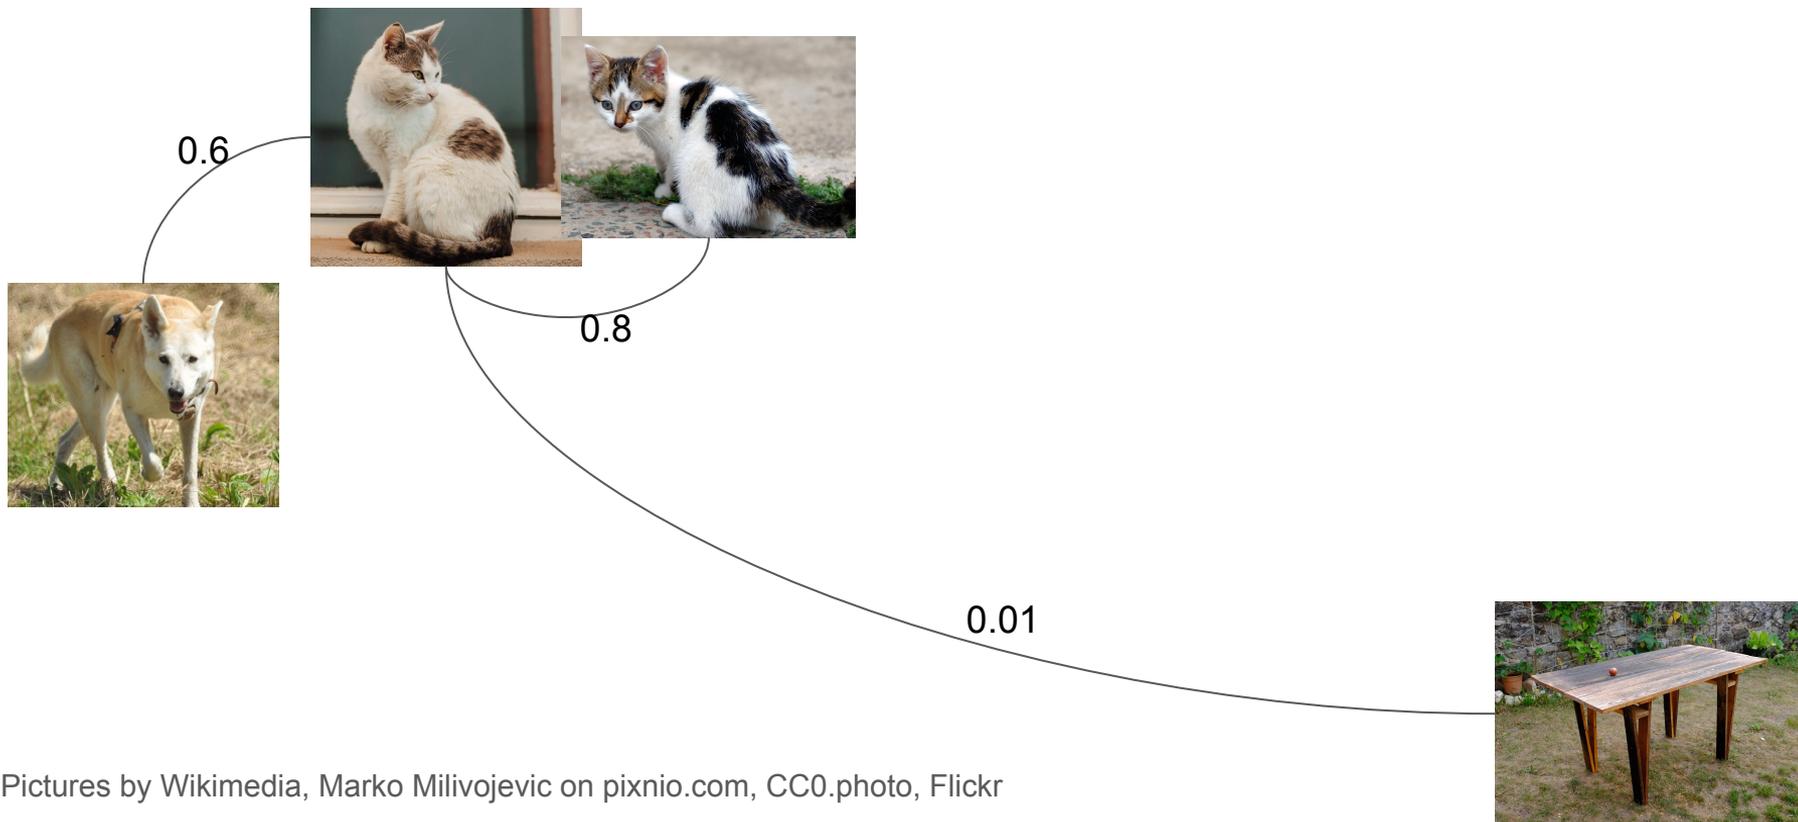
[get: 110,
feed:30,
paint:1
...]



[get: 110,
feed:0,
paint:50
...]



Similitude sémantique sur une échelle continue



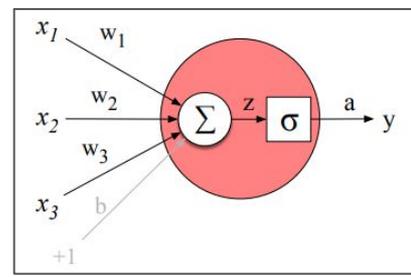
Word2vec, une méthode neuronale auto-supervisée pour obtenir des vecteurs denses

- Software package appelé word2vec (Mikolov et al. 2013a, Mikolov et al. 2013b)
- Le résultat de la formation est un vecteur dense pour chaque mot
- Fonctionne mieux pour chaque tâche NLP que les vecteurs 'sparse'

	Dim 1	Dim 2	Dim 3	etc...		
knife	.81	.51	etc...	0	3	0
cat	.81	.37	etc...	4	6	26
dog	115	83	10	42	33	17
boat	59	39	23	4	0	0
cup	98	14	6	2	1	0
pig	12	17	3	2	9	27
banana	11	2	2	0	18	0

Exemple de Evert, Baroni, Lenci, 2010, Distributional Semantic Models Tutorial at NAACL-HLT 2010

Modèles de réseaux de neurones artificiels



Les origines résident dans un modèle simplifié du neurone humain et de ses interactions

Aujourd'hui juste un réseau de petites unités de calcul

Ceux-ci prennent un vecteur de valeurs d'entrée et produisent une sortie unique

Ils sont puissants en raison des couches alimentant les couches suivantes

Apprentissage « profond » car les réseaux sont souvent profonds (couches multiples)

Ils apprennent à induire des caractéristiques (*features*) dans le cadre du processus d'apprentissage

Ils nous permettent de faire de la modélisation de bout-en-bout (pas besoin de composants de modèle)

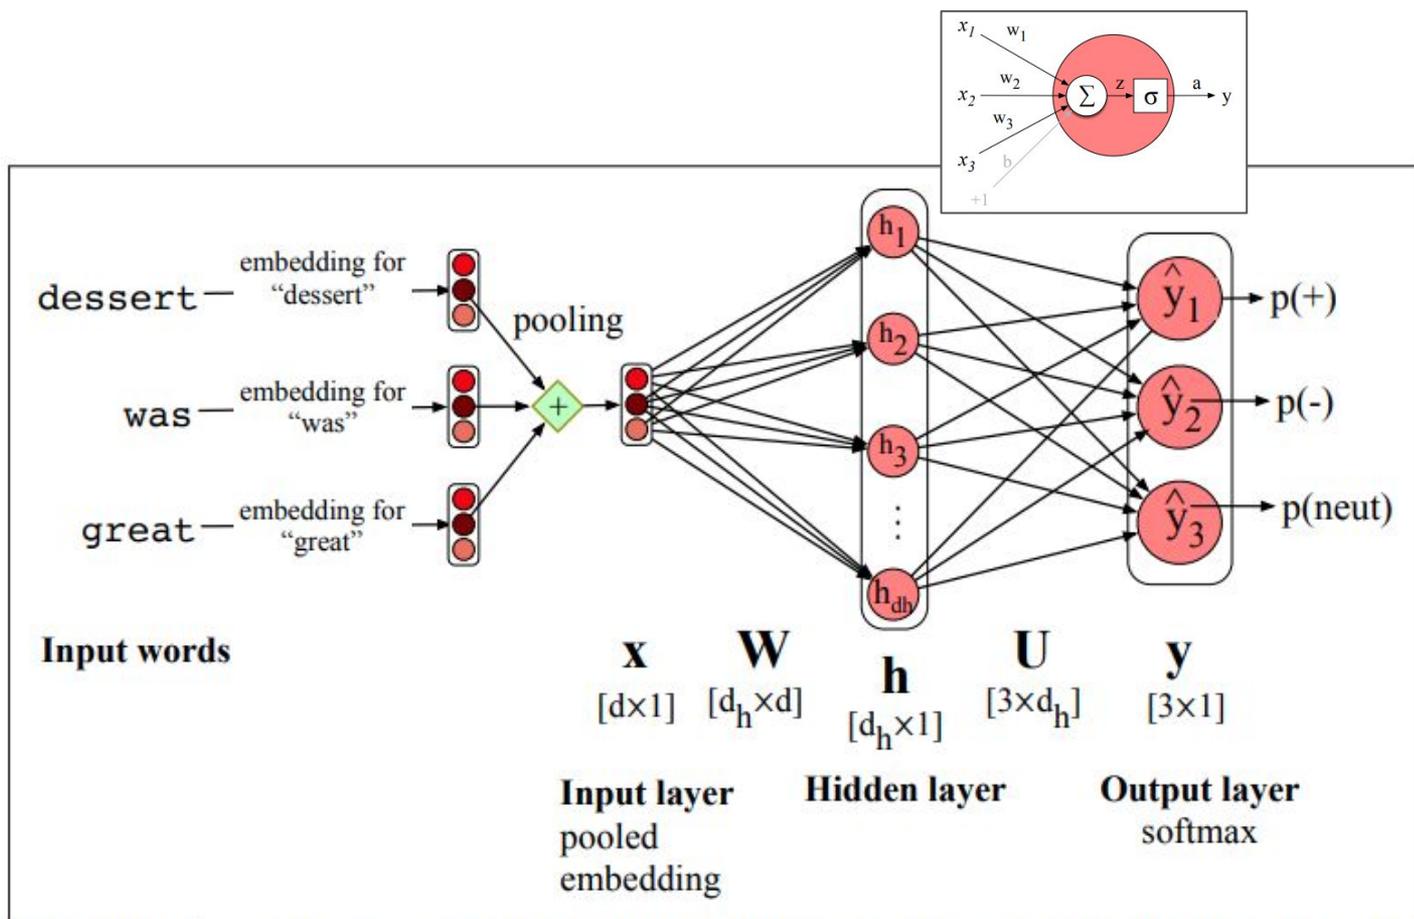


Figure 7.11 Feedforward sentiment analysis using a pooled embedding of the input words.

Comment fonctionne word2vec ?

Auto-surveillance !

Un des algorithmes : skip-gram avec échantillonnage négatif (SGNS)

Entraîne un classifieur sur une tâche de prédiction :

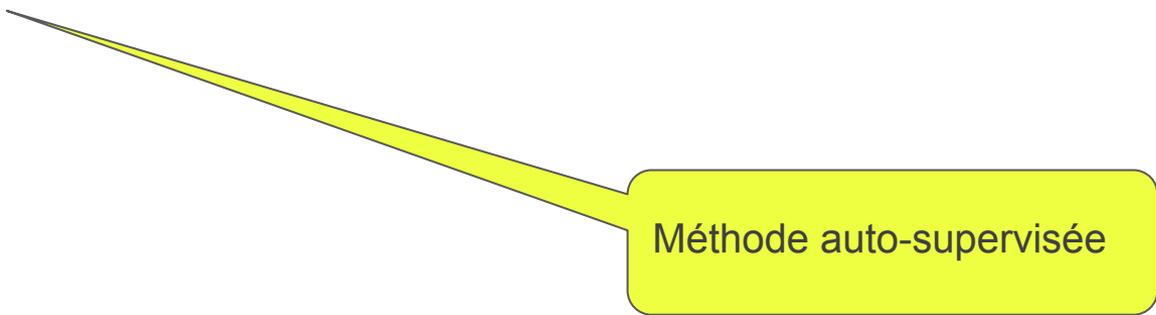
"Le mot w est-il susceptible d'apparaître dans le contexte c ?"

En savoir plus sur word2vec

Entraîne un classifieur sur une tâche de prédiction :

"Le mot w est-il susceptible d'apparaître dans le contexte c ?"

- Exemples positifs : texte réel
- Exemples négatifs : des mots échantillonnés au hasard dans le reste du texte



Méthode auto-supervisée

Exemple

Positive examples

Negative examples



Appearing on Good Morning America along just after the announcement, Primetime Emmy-winning comedian with Schumer joked:
"I'm not sure who thought this was a good wall wine idea out I am hosting the Oscars, along with my good friend Wanda Sykes and Regina Hall.

Mots dans le contexte

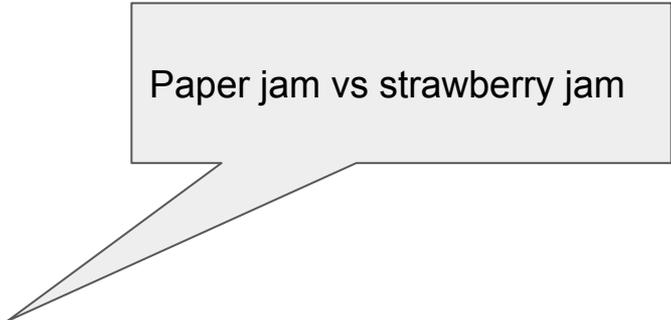
Nous avons parlé des représentations de mots

Mais les mots ont des sens différents selon le contexte

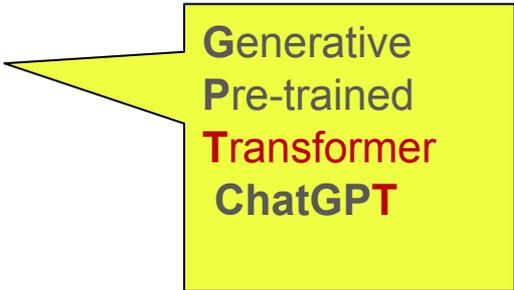
La langue ne se limite pas aux mots. Ce sont des blocs de construction pour de plus longues portions de texte

> Nous avons besoin de modèles qui capturent les relations entre les mots même lorsqu'ils sont éloignés, et nous avons besoin de représentations contextualisées

Les transformateurs sont un type de modèle qui tente de résoudre ce problème



Paper jam vs strawberry jam



**Generative
Pre-trained
Transformer
ChatGPT**

Transformeurs (BERT, Devlin et al. 2018)

La modélisation du langage masqué est la tâche d'auto-supervision utilisée pour entraîner le modèle + la prédiction de la phrase suivante

Représentations contextualisées grâce au mécanisme de l'attention

L'attention multi-tête permet au modèle de capturer les multiples relations qui existent entre les mots dans un contexte donné, même lorsqu'ils sont éloignés

Des millions de paramètres entraînaibles en nombre de couches (base BERT : 12 couches contenant 12 têtes d'attention)

Nécessite d'énormes quantités de données et de calculs (3,3 milliards d'éléments de texte sans étiquette)

Généralement formé une fois (*pre-training*) et utilisé pour plusieurs tâches à l'aide d'une configuration de *fine-tuning*

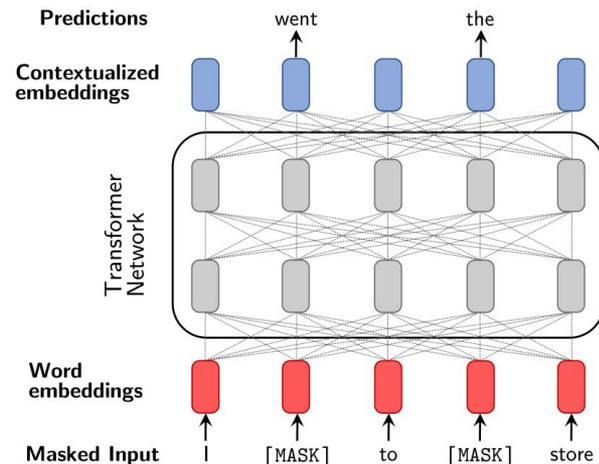
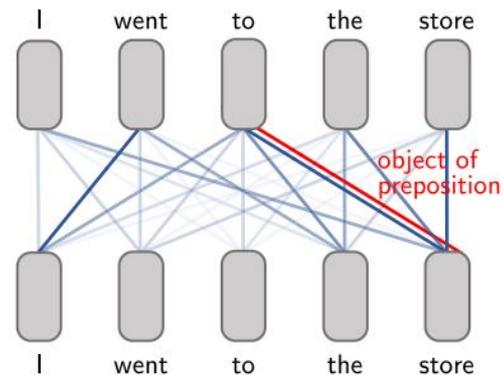


Photo de Christopher D. Manning et al., 2020



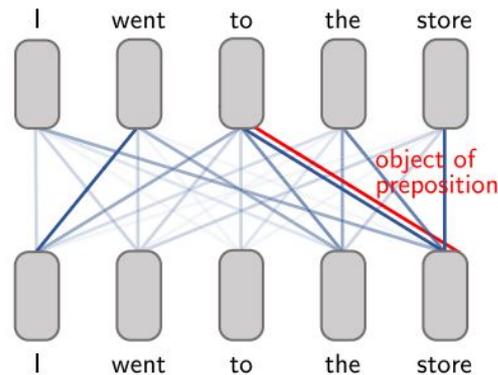
Qu'apprennent les transformeurs ?

Les têtes d'attention sont destinées à capturer les relations entre les mots

Nous pouvons examiner le mot le plus suivi à chaque position dans une séquence de mots

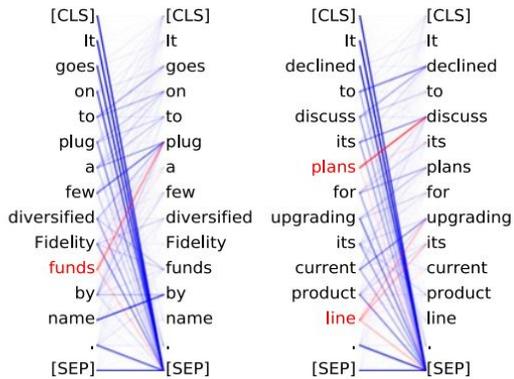
Cela nous permet de vérifier quel mot de la séquence est le plus "important" pour que le modèle détermine la représentation d'un mot donné

Nous pouvons jeter un œil à l'intérieur des couches spécifiques



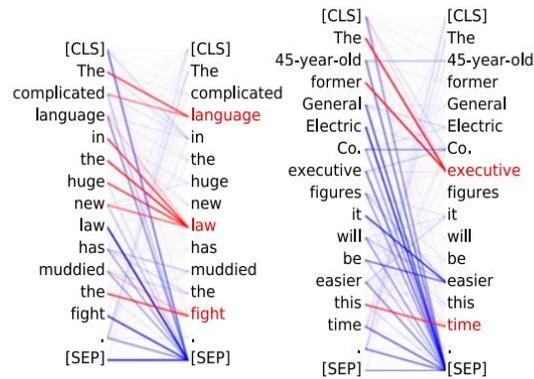
Head 8-10

Direct objects most attend to their verbs 86.8% of the time.



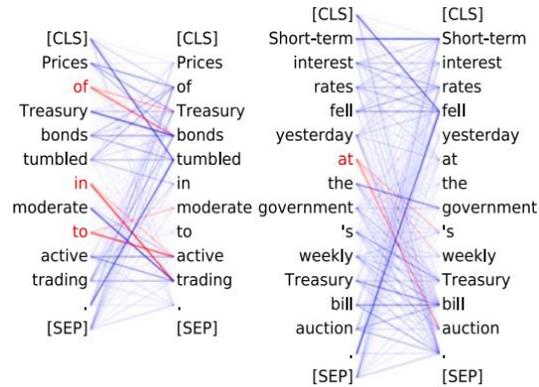
Head 8-11

Noun premodifiers attend to their noun. Determiners most attend to their noun 94.3% of the time.



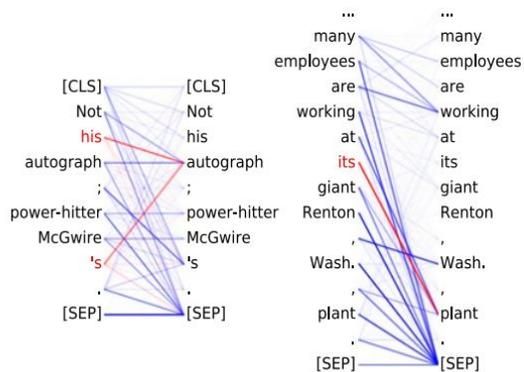
Head 9-6

Prepositions most attend to their objects 76.3% of the time



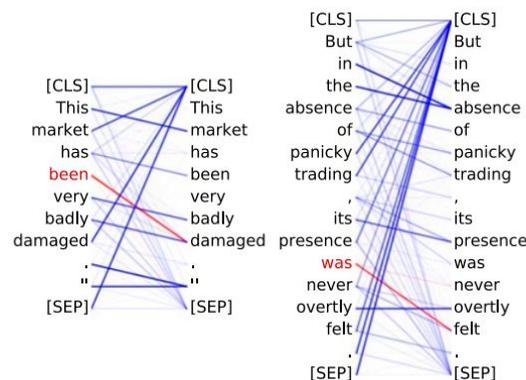
Head 7-6

Possessive pronouns and apostrophes most attend to the head of the corresponding NP 80.5% of the time.



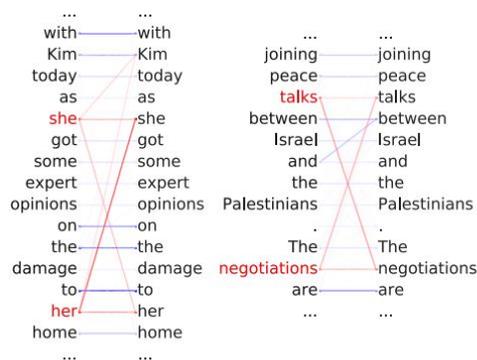
Head 4-10

Passive auxiliary verbs most attend to the verb they modify 82.5% of the time.



Head 5-4

Coreferent mentions most attend to their antecedents 65.1% of the time.



No single head in a single layer corresponds well to dependency syntax overall

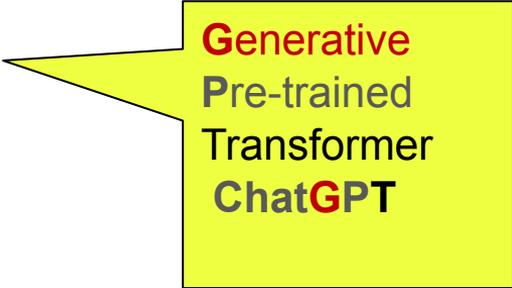
"Generative"??

Les architectures de transformeurs peuvent être constituées d'un codeur, d'un décodeur ou de l'un de ces deux

Le transformeur BERT est un modèle de codeur

GPT-3 est un décodeur

Il génère du texte en se basant sur un *prompt*



Generative
Pre-trained
Transformer
ChatGPT

La famille des modèles de langage et leurs défauts

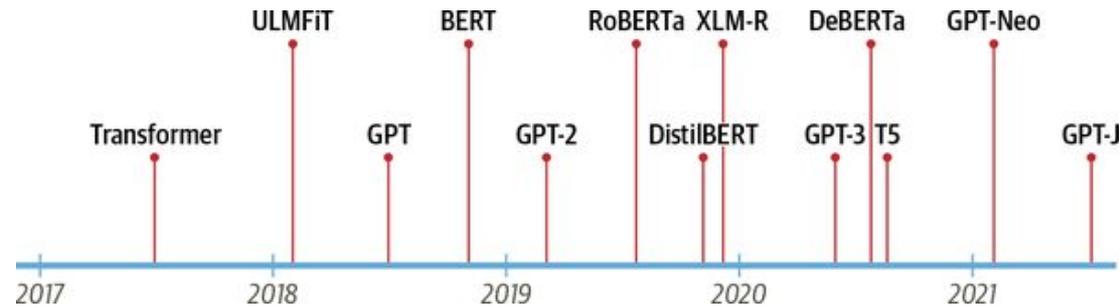
Capturent les patterns statistiques dans le langage

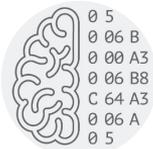
Ont besoin de très grandes quantités de données textuelles et de ressources informatiques massives. Nous n'avons pas accès à ces données

Seuls les «acteurs majeurs» peuvent créer de tels modèles. Ils ne sont pas disponibles pour toutes les langues

Ne savent pas ce qui est vrai ou faux

Ils ne font qu'imiter les textes vus

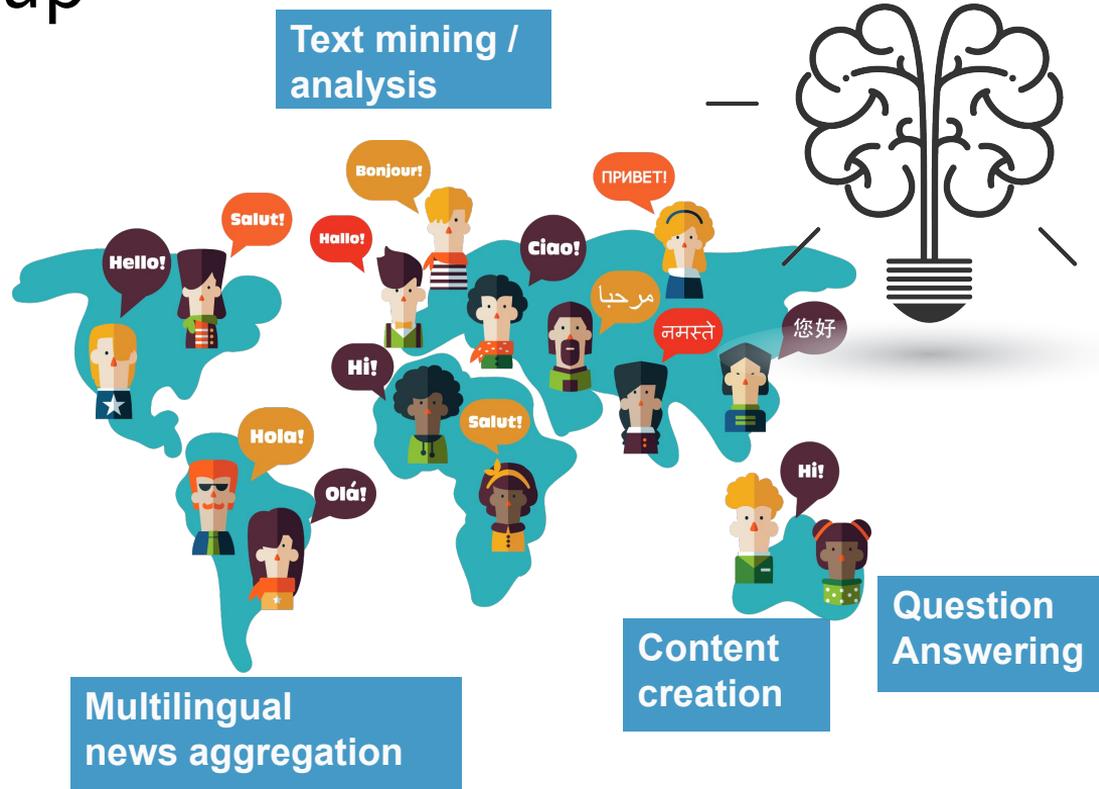




Computation, Cognition & Language Group

Limites du système d'IA
actuel en ce qui concerne
le langage

- Développement de technologie du langage multilingue
- Modélisation des capacités cognitives humaines sous-exposées, telles que la créativité



Systemes de recommandation de news

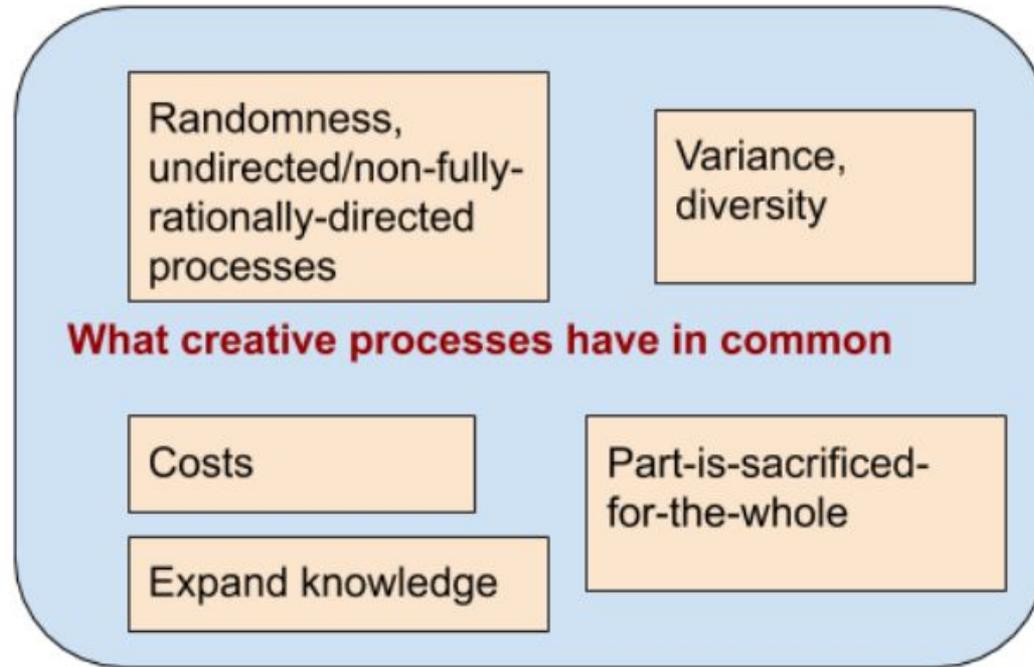
- Les gens lisent souvent les actualités sur leur téléphone portable
- Les flux d'actualités des systemes de recommandation (tels que YouTube et des medias sociaux) influencent la façon dont les gens découvrent les informations
- Ces flux d'actualités peuvent être personnalisés de manière algorithmique pour chaque utilisateur
- La personnalisation est une fonctionnalité utile
- Cependant, elle limite l'exposition des lecteurs à différents types d'informations

Comment les chercheurs de NRS tentent d'atténuer

Algorithmes sensibles à la diversité

Nudging

Compromis entre diverses mesures d'évaluation



Quelques travaux qui introduisent certains aspects de créativité

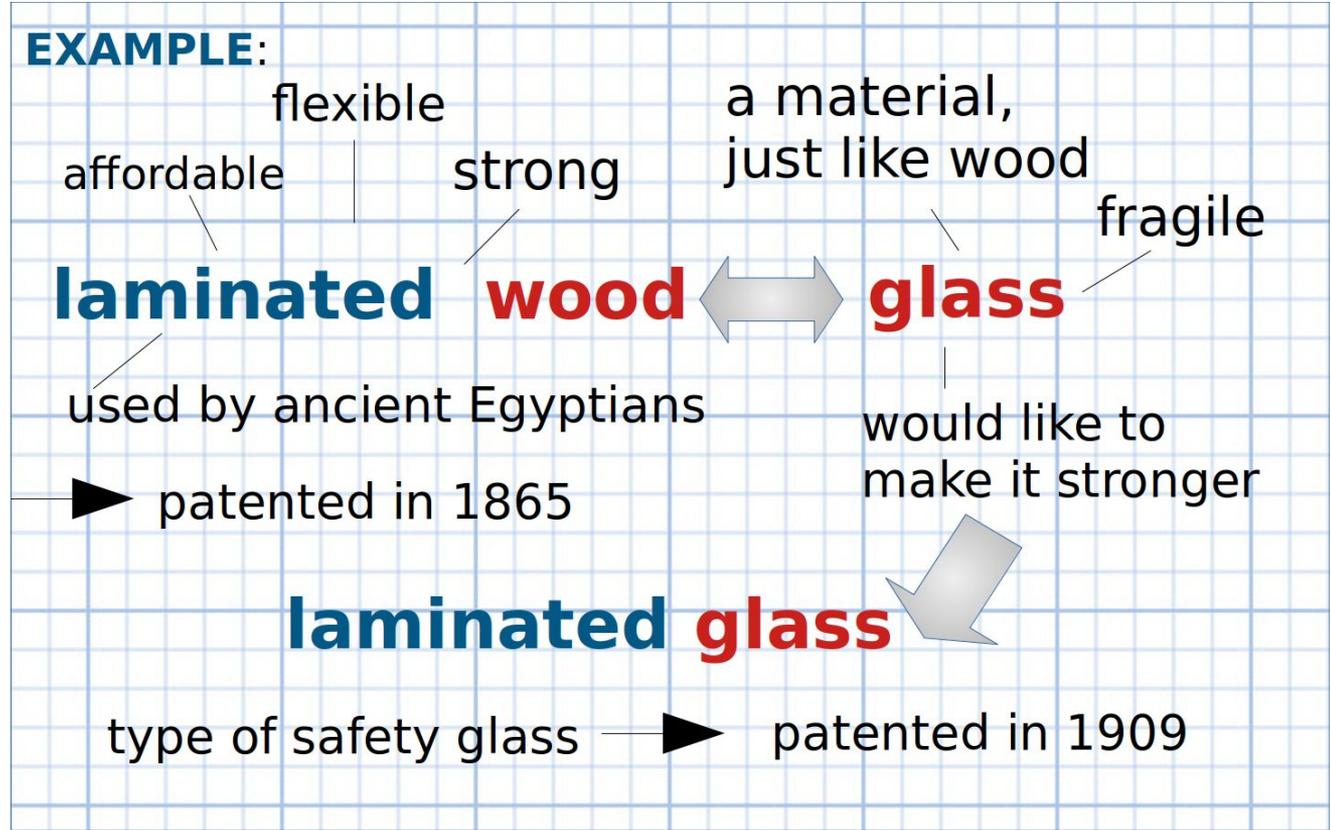
- Novelty search (Lehman & Stanley, 2011)
- Intrinsically Motivated Reinforcement Learning (Kaplan & Oudeyer, 2006)
- Work on using off-policy learning for recommender systems to avoid 'myopic recommendations', where the short term reward overshadows long-term user utility (Ma et al., 2020)



Patterns dans la génération de concepts

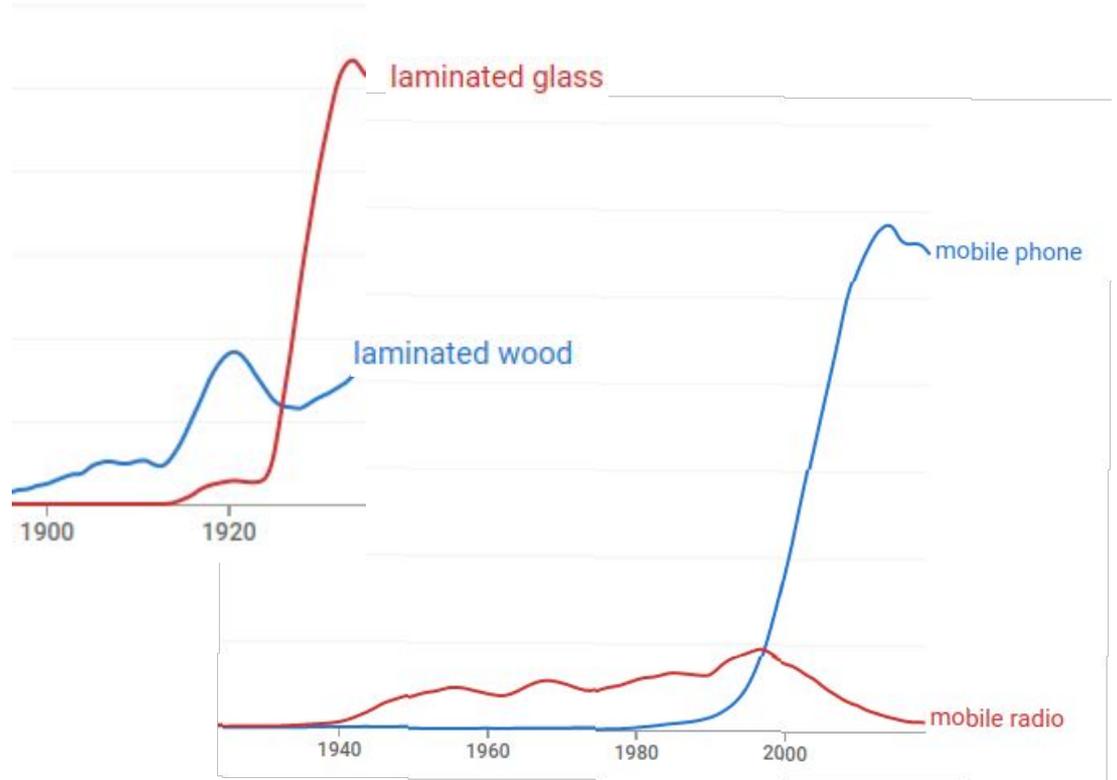
La pensée
créative suit
certains
schémas

Peuvent être
appris par un
système





Emergence et succès de nouveaux concepts dans les corpus





Les mots composés comme véhicules de la pensée créative

- Les mots composés nous permettent de faire de la recombinaison conceptuelle
- Utilisation de concepts connus en combinaison pour en créer de nouveaux
- Les enfants sont capables de produire des mots composés

(Example: *moon cheese* ...)

- Très flexible, pas besoin de préciser la relation entre les constituants



Génération de nouveaux mots composés : comment ?

- Utiliser des représentations distribuées pour les deux parties et modéliser leur combinaison
- Par exemple, le bateau à fond de verre est connu, mais pas le canoë de verre
- Tâche : Déduire qu'un canoë de verre est un concept plausible





Représentations vectorielles denses

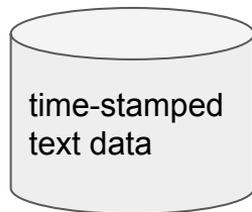
L'espace condensé lisse la distribution et ajoute la généralisation, remède à la rareté des données

Cependant, non seulement il s'occupe d'événements rares

C'est aussi l'occasion de créer des combinaisons inédites (vraiment inédites) mais plausibles

CogSci : les réseaux sémantiques d'individus de faible créativité et de créativité élevée ont des propriétés structurelles différentes [Kennet et al, 2014]

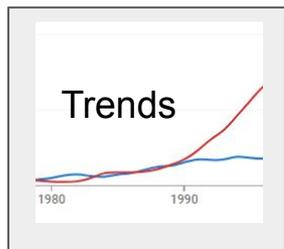
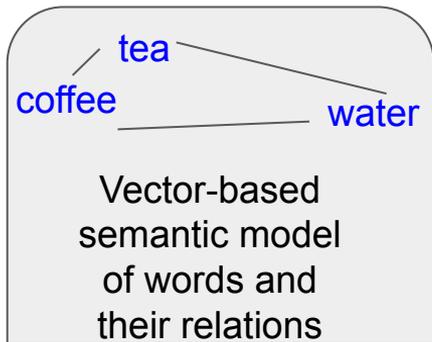
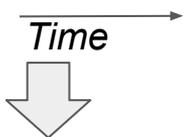
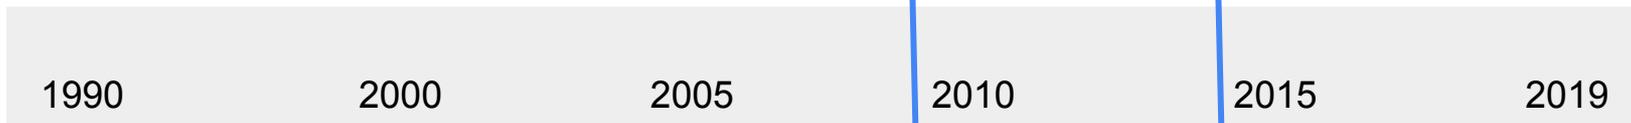
Les derniers peuvent atteindre des concepts plus éloignés et plus faiblement connectés plus facilement [Kennet et Austerweil, 2016]



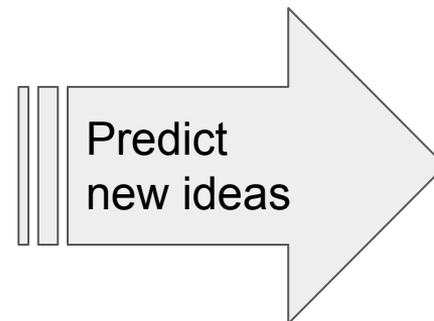
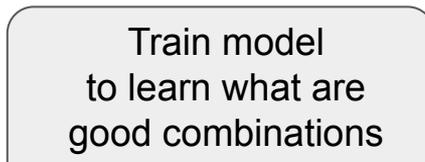
TRAIN

DEV

EVALUATE



coffee machine = good
coffee mouse = bad



TRAIN

DEV

EVALUATE



List of compounds
word2vec representations

List of compounds
Not seen in training data

List of compounds
Not seen in training/dev
data

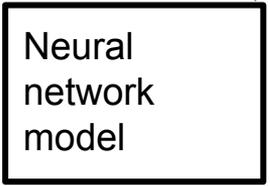
train

Generate positive and
negative evidence for
training by corrupting
attested compounds:
coffee machine = good
coffee mouse = bad

Generate positive and
negative examples by
corrupting attested
compounds:
time sink = good
banana sink = bad

train

*Disambiguator:
apply and
evaluate*



Accuracy: 69,4%

TRAIN

DEV

EVALUATE

1990

2000

2005

2010

2015

2019

List of compounds
word2vec representations

List of compounds
Not seen in training data

train

Generate positive and
negative evidence for
training by corrupting
attested compounds:
coffee machine = good
coffee mouse = bad

Generate novel
compounds by replacing
modifier by semantically
similar word (Cosine)
coffee machine > coffee
computer?

train

*Generator:
apply and
evaluate*

Neural
network
model

Accuracy: 54,5%



System output Generator

Found in evaluation set
2015-2019

Predicted by system

riesling sauce
cheeseburger spread
kevlar jacket
waistband blouse
boy food
healthcare burden
hashish store

brain sculpting
knee-length glove
light-emitting lamp
melting cloud
misrepresentation
campaign

vaccination law
infection outbreak
authentication method
verification code

tilapia skin
horseradish juice
loot box
pork burger

software school

township law
evidence need
toxicity datum
lineup spot

assistance community
summer trial

jail worker
day candidate

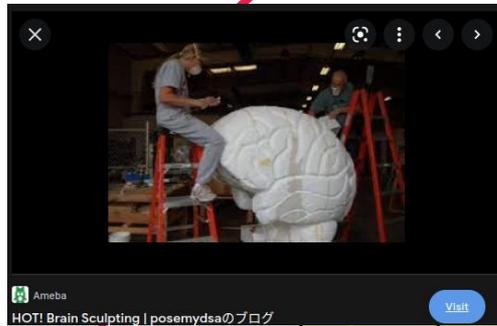


System output Generator

Found in evaluation set
2015-2019

Predicted by system

riesling sauce



brain sculpting

knee-length glove
light-emitting lamp
melting cloud
heron tooth
porky dog
mucous defect

ger spread

blouse

arden
ore

vaccination law

infection outbreak

authentication method
verification code

tilapia skin

horseradish juice
loot box
pork burger

software school

township law
evidence need
toxicity datum
lineup spot

assistance community
summer trial

jail worker
day candidate



System output Generator

Found in evaluation set
2015-2019

Predicted by system

riesling sauce
cheeseburger spread
kevlar jacket
waistband blouse
boy food
healthcare burden
hashish store

brain sculpting
knee-length glove
light-emitting lamp
melting cloud
heron tooth
porky dog
mucous defect

software school

ship law
nce need
toxicity datum
o spot

ance community
ner trial

ail worker
andidate



TeePublic

Melting Cloud

\$22.00 USD* · In stock

Visit



System output Generator

Found in evaluation set
2015-2019

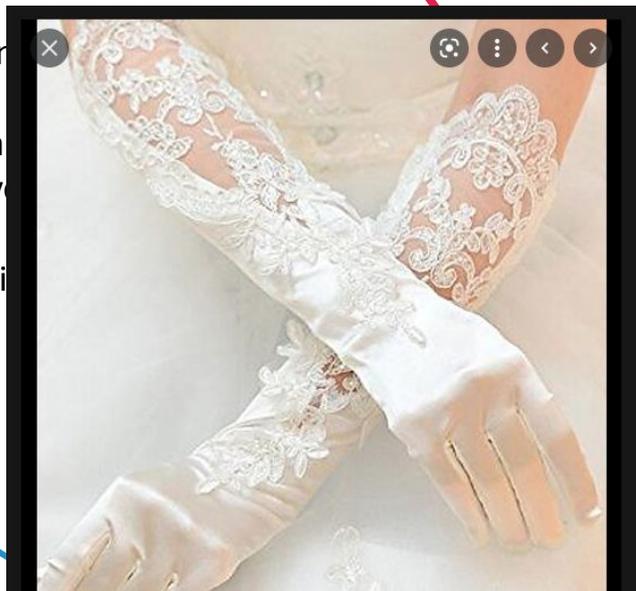
Predicted by system

riesling sauce
cheeseburger spread
kevlar jacket
waistband blouse
boy food
healthcare burden
hashish store

brain sculpting
knee-length glove
light-emitting lamp
melting cloud
heron tooth
porky dog
mucous defect

vaccination law

software school



LightInTheBox

Satin Knee-Length Glove Gloves / Sequins With Appliques / Solid
Wedding / Party Glove 2022 - US \$20.22

Visit

o law
need
ity datum
ot
e community
trial
worker
idate



L'évaluation est un défi

- Un certain nombre de composés parmi nos faux positifs semblent être de vrais positifs
- Comment le déterminer automatiquement ?
- Recherches Google (comptes) ?
- Cependant, il est difficile de choisir un seuil approprié pour ce que nous pouvons considérer comme un « bon » composé.



Évaluation est un *challenge*

- Prenez un échantillon aléatoire de 100 mots composés de notre liste de faux positifs.
- Obtenez ensuite le nombre d'occurrences renvoyées par Google lors de la recherche de chaque mot composé.

Threshold: minimum 5000 Google hits

Percentage of 'correct' compounds among false positives: 66%

Adjusted accuracy if this were true: 84,48%

Counted as

correct:

cash counter

porcky dog

Counted as

incorrect:

mucous defect

mistreatment

complaint

heron tooth

Threshold: above median

Percentage of 'correct' compounds among false positives: 50%

Adjusted accuracy if this were true: 77,20%

Counted as

correct:

Snowmobile rental

heel sandal

Counted as

incorrect:

midmorning train

porcky dog



International Create Challenge '21



time-stamped text data

Scientific articles

Social media data

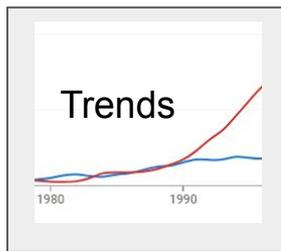
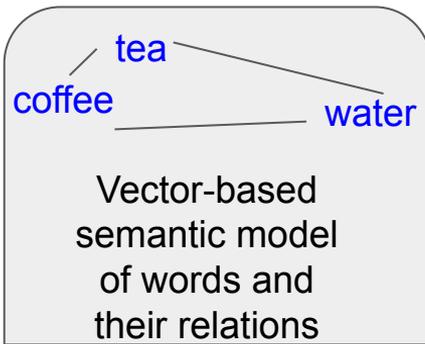
Company-internal data

TRAIN

EVALUATE

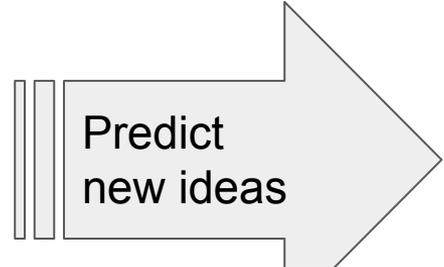


Time →



coffee machine = good
coffee mouse = bad

Train model to learn what are good combinations



Create an interface that allows for topic-specific browsing

Winning team of ICC'21

MICHELLE: BUSINESS LIAISON



AI CONSULTANT

PRAJIT: ALGORITHM



PHD STUDENT: DEEP LEARNING

LANNEKE: LANGUAGE PROCESSING EXPERT



GROUP LEADER AT IDIAP

JANIS: INTERFACE



PHD STUDENT: DIGITAL HUMANITIES

GLORIANNA: SOCIAL MEDIA



PHD STUDENT: HEALTH RESEARCH

Industry partners



Merck Serono Aubonne (pharma)

Beverages and food company

Informants & support

Educational publisher

Information science non-p

ICC mentors

IDIAP technical staff

FoodHack





C-LING : vers des systèmes Créatifs avec modélisation LINGuistique



Projet Fond National Suisse de la Recherche Scientifique
(FNS) : 2 doctorants travaillent sur le sujet

Résolution créative de problèmes

Inclut également des modèles interdomaines et
interlinguistiques

Capacités créatives des LLMs génératives

- Il est facile de voir un comportement créatif
- Nous (Prof. Antoine Bosselut (EPFL), Soyoung Oh et moi) collaborons avec des chercheurs en sciences cognitives de l'UVA pour tester les capacités créatives de ces systèmes
- Les tests de créativité humaine ne sont pas adaptés pour les systèmes
- La fixation semble être un inconvénient des LLMs

Résumé

- Histoire des modèles de langage naturel
- Quelques menaces et opportunités du NLP
- Exemples de recherche de mon équipe

Merci de votre attention!