

# **TRAITEMENT AUTOMATIQUE DE LA LANGUE: PLONGEON AU CŒUR DES WORD EMBEDDINGS**

**De Word2vec à BERT, un espoir nouveau pour le TAL**

Mikaël Dusenne

2021-11-23

# INTRODUCTION

*80% des données cliniques pertinentes sont non structurées*

Comment représenter efficacement les données textuelles pour l'apprentissage automatique?

# Apprentissage automatique et langage naturel

Approches classiques : un mot / n-gram = une variable

Problèmes :


- Pas de notion de **distance sémantique**
- Très grand **nombre de variables**
- Données **éparses**

mot	hospitalisé	asthme	occlusion	...	colique	intestinale	aigüe
asthme	0	1	0	...	0	0	0
colique	0	0	0	...	1	0	0
intestinale	0	0	0	...	0	1	0

# Word Embeddings


- Représentation dense des mots
- Vecteurs de nombres réels
- Dimension indépendante de la taille du vocabulaire
- Proximité dans l'espace vectoriel corrélée à la similarité sémantique

mots	0	1
asthme	0.888	0.014
colique	0.017	1.500
intestinale	-0.420	1.880



# Word Embeddings

Les Embeddings permettent d'utiliser le calcul vectoriel pour effectuer des transformations sémantiques



$$King + (Woman - Man) = Queen$$

# Embeddings et TAL : implémentations


- 2013 : Word2Vec<sup>1</sup> :
  - réseau de neurones pour créer les embeddings
- 2014 : GloVe<sup>2</sup>
  - "global vectors", matrice de co-occurrence utilisant le corpus entier
- 2014 : Doc2Vec<sup>3</sup>
  - Vecteurs de Documents
- 2016 : FastText<sup>4</sup>
  - Décomposition des mots en n-grams de caractères
- 2018 : ELMo<sup>5</sup>
  - utilise l'ordre des mots (LSTM bi-directionnel)
- 2018 : BERT<sup>6</sup>
  - utilise des "attention network" (Transformer)
  - gestion des homonymes
- 2018 : Flair<sup>7</sup>
  - Zalando Research
  - Étiquetage morpho-syntaxique
- 2019 : ALBERT<sup>8</sup>
  - Améliore BERT : moins de paramètres, entraînement plus rapide
- 2019 : BioBERT<sup>9</sup>
  - pré-entraîné sur pubmed et PMC (en anglais)
- 2019 : camemBERT<sup>10</sup>
  - pré-entraîné sur un corpus français ( OSCAR corpus, non médical)
- 2019 : FlauBERT<sup>11</sup>
  - pré-entraîné sur un corpus français (non médical)

## 2013 - word2vec

- Première adaptation réellement fonctionnelle des techniques d'embedding au TAL
- réseau de neurones simple
- apprentissage "semi-supervisé"

The quick brown fox jumps over the lazy dog ...

# 2013 - word2vec




## Inconvénients:

- Ne prend pas en compte l'ordre des mots dans le contexte
- un mot a toujours la même représentation -> problème pour la polysémie

# 2015 - Représentations contextuelles

Besoin d'une solution pour prendre en compte l'ordre des mots




Le LSTM est un type de réseau neuronal récurrent qui introduit des boucles permettant à une information apparue précédemment d'être "mémorisée".

-> Respect de l'ordre d'apparition des mots dans une phrase.  
Semi-supervised Sequence Learning (Andrew M. Dai, Quoc V. Le)

# 2015 - Représentations contextuelles

Besoin d'une solution pour prendre en compte l'ordre des mots




The repeating module in an LSTM contains four interacting layers.


## EMBEDDINGS FOR LANGUAGE MODELS (ELMO)

Combine un LSTM "en avant" et un LSTM "en arrière"

**Train Separate Left-to-Right and Right-to-Left LMs**



**Apply as “Pre-trained Embeddings”**




source: Stanford CS224N: NLP with Deep Learning | Winter 2020 | BERT and Other Pre-trained Language Models


# 2018 - Generative Pre-trained Transformer

- GPT1 créé par OpenAI
- Utilise pour la première fois les mécanismes d'Attention apportés par les transformers pour accorder une importance plus grande à certains mots
- Publication: Attention Is All You Need (Ashish Vaswani et al.)

# Réseaux neuronaux et Mécanisme d'Attention



# Réseaux neuronaux et Mécanisme d'Attention



# Réseaux neuronaux et Mécanisme d'Attention



# Transformers

- Les transformers permettent d'utiliser les mécanismes d'attention afin de se référer aux mots précédents d'une phrase, sans avoir recours aux réseaux récurrents (LSTM).
- utilisent le matériel récent (GPU, TPU) de façon beaucoup plus efficace (parallélisation plus simple)



# Inconvénients de GPT

Le modèle est uni-directionnel (le texte n'est lu que de gauche à droite)

# 2018 - Bidirectional Encoder Representations from Transformers (BERT)



- Réellement bidirectionnel
- Utilise les transformers
- entraînement en [MASK]ant 15% des mots de chaque phrase

# Performances

System	MNLI-(m/mm)	QQP	QNLI	SST-2	CoLA	STS-B	MRPC	RTE	Average
	392k	363k	108k	67k	8.5k	5.7k	3.5k	2.5k	-
Pre-OpenAI SOTA	80.6/80.1	66.1	82.3	93.2	35.0	81.0	86.0	61.7	74.0
BiLSTM+ELMo+Attn	76.4/76.1	64.8	79.8	90.4	36.0	73.3	84.9	56.8	71.0
OpenAI GPT	82.1/81.4	70.3	87.4	91.3	45.4	80.0	82.3	56.0	75.1
BERT <sub>BASE</sub>	84.6/83.4	71.2	90.5	93.5	52.1	85.8	88.9	66.4	79.6
BERT <sub>LARGE</sub>	<b>86.7/85.9</b>	<b>72.1</b>	<b>92.7</b>	<b>94.9</b>	<b>60.5</b>	<b>86.5</b>	<b>89.3</b>	<b>70.1</b>	<b>82.1</b>

Table 1: GLUE Test results, scored by the evaluation server (<https://gluebenchmark.com/leaderboard>). The number below each task denotes the number of training examples. The “Average” column is slightly different than the official GLUE score, since we exclude the problematic WNLI set.<sup>8</sup> BERT and OpenAI GPT are single-model, single task. F1 scores are reported for QQP and MRPC, Spearman correlations are reported for STS-B, and accuracy scores are reported for the other tasks. We exclude entries that use BERT as one of their components.

# BERT-like

- (2019) BioBERT : a pre-trained biomedical language representation model for biomedical text mining
  - BERT entraîné sur des documents biomédicaux en anglais
  - amélioration significative des performances sur des tâches biomédicales
  - démontre la possibilité de créer des modèles spécialisés dans certains domaines
- (2019) RoBERTa : A Robustly Optimized BERT Pretraining Approach
  - Réévalue et améliore l'entraînement de BERT
- (2019) ALBERT : A Lite BERT for Self-supervised Learning of Language Representations
  - optimisation de BERT: réduction drastique du # de paramètres ( 12M, -89% )
- (2019) StructBERT : Incorporating Language Structures into Pre-training for Deep Language Understanding
  - focus sur la structure du langage, ajout d'une tâche de reconstruction de l'ordre des mots / phrases pendant l'entraînement
- (2019) TinyBERT : Distilling BERT for Natural Language Understanding
  - 7.5x smaller, 9.4x faster, 96.8% of BERT performances on GLUE
- (2019) FlauBERT : Unsupervised Language Model Pre-training for French
  - entraîné sur l'ordinateur Jean Zey au CNRS ( 28 PétaFlops )
  - sur un corpus français généraliste
  - FLUE
- (2020) DeBERTa : Decoding-enhanced BERT with Disentangled Attention
  - amélioration de la gestion de la position des mots
- (2021) BERTAC : Enhancing Transformer-based Language Models with Adversarially Pretrained Convolutional Neural Networks
  - CNN utilisant un apprentissage de type GAN sur le texte de wikipedia, puis combiné à ALBERT
- (2020) CamemBERT : a Tasty French Language Model
  - Basé sur RoBERTa
  - entraîné sur le corpus multilingue OSCAR

# TRAVAUX AU D2IM

# Travaux Emeric Dynomant

- Sujet : Bioinformatics articles structuring with an end-to-end processing pipeline
- Machine Learning for NLP; word & document embeddings for text
- Word embeddings
  - Comparaison de cinq algorithmes sur 11,8 M de documents de santé d'un EDS
- Document embeddings
  - Doc2Vec2PubMed vs. algorithme actuel Related Articles

# Medical word embeddings querying page

12M ▾ endocardite

**GloVe** infectieuse, myocardite, eto, native, streptocoque, bovis, bactériémie, faecalis, \_endocardite

**FastText (CBOW)** proprio\_septive, myopericardite, septo\_optique, endo\_aortique, endocardite, endoculaire, acrodermite, rhino\_septale, salmonellose, épidermolyse

**Word2Vec (Skip-Gram)** bovis, sanguinis, eto, gordonii, gallolyticus, aorto\_mitrale, mutans, infectieuse, streptoccoque, salivarius

**FastText (Skip-Gram)** endocardite, endocardique, proctologique, extancilline, septo\_basale, prolongements, recanalisée, précentrale, dantrolene, podoscopique

**Word2Vec (CBOW)** endocardite, \_endocardite, native, bovis, médiastinite, myocardite, mutans, gallolyticus, myopéricardite, tamponnade

[Home](#)

# Word embeddings dans deux contextes différents

QUERY : "facebook"

<b>LiSSa corpus (300k)</b>	internet, twitter, web, blog, e_learning, blogs, internautes, tic, game, ...
<b>RUH documents (12M)</b>	reproches, injures, messages, insultes, rumeurs, ex_conjointe, menaces, insultant, ...

Espace vectoriel disponible pour la communauté scientifique

# Annotateur Sémantique

Intégration de BERT\* pour améliorer l'annotateur sémantique  
de l'EDSaN ?



# MERCI