



MODÈLES DE LANGUE



Emanuela Boros
boros@teklia.com





Christopher Kermorvant
kermorvant@teklia.com

Cryptographie et modèles de langue

Chiffrement par substitution

ZLNLSHGLD O'HQFBFORS HGLH OLEUH



Code de César


WIKIPEDIA L'ENCYCLOPEDIE LIBRE



Décryptage par modélisation de la fréquence des lettres

LIVITCSWPIYVEWHEVSRIQMXLEYVEOIEWH
RXEXIPFEMVEWHKVESTYLXZIXLIKIIXPJVSZE
YPERRGERIMWQLMGLMXQERIWGSPRIHMX
QEREKIETXMJTTPRGEVEKEITREWHEXXLEX
MZITWAWSQWXSWEEXTVEPMRXRSJGSTVRI
EYVIEXCVMUIMWERGMIWXMJMGCSMWXS
JOMIQXLIVIQIVIXQSVSTWHKPEGARCSXRW

Hereupon Legrand arose, with a grave and stately air, and brought me the beetle from a glass case in which it was enclosed. It was a beautiful scarabaeus, and, at that time, unknown to naturalists—of course a great prize in a scientific point



+ fréquence des bigrams

+ fréquence des trigrams

Modèles de langue



CentraleSupélec

Modélisent des séquences de mots ou caractères :

$$P(w_1, \dots, w_T)$$

Permettent d'évaluer la probabilité d'une phrase :

- mot plus probable :

$$P(\text{the, cat, sat, on, the, } \underline{\text{mat}}) > P(\text{the, cat, sat, on, the, } \underline{\text{yesterday}})$$

- ordre plus probable

$$P(\text{the, cat, sat, on, the, mat}) > P(\text{the sat, cat the on, mat})$$

Modèles de langue par chaîne de Markov

Hypothèse Markovienne : la probabilité du prochain symbole ne dépend que des n précédents :

$$\begin{aligned} P(w_1, \dots, w_m) &= \prod_{i=1}^m P(w_i \mid w_1, \dots, w_{i-1}) \\ &\approx \prod_{i=1}^m P(w_i \mid w_{i-(n-1)}, \dots, w_{i-1}) \end{aligned}$$

Modèles de langue par chaines de Markov



CentraleSupélec

Zerogram : $\frac{1}{|V|}$, $|V|$ est la taille du vocabulaire

Unigram : probabilité des symboles

Bigram : probabilité des symboles étant donné le symbole précédent :

$$p(w_2|w_1) = \frac{\text{count}(w_1, w_2)}{\text{count}(w_1)}$$

Trigram : probabilité des symboles étant donné les 2 symboles précédents :

$$p(w_3|w_1, w_2) = \frac{\text{count}(w_1, w_2, w_3)}{\text{count}(w_1, w_2)}$$


Modèles de langue par chaînes de Markov



CentraleSupélec

Entraînement par comptage sur de très grands corpus de texte électronique :

Consommation mémoire et CPU importante



The ClueWeb09 Dataset : 1,040,809,705 de pages web

Heafield et al., Scalable Modified Kneser-Ney Language Model Estimation, 2013

Mesures de qualité

Cross-Entropie

$$H(w_1, \dots, w_N) = -\frac{1}{N} \log_2 P(w_1, \dots, w_N)$$

$$P(w_1, \dots, w_m) = \prod_{i=1}^m P(w_i \mid w_1, \dots, w_{i-1})$$

= combien de bit faut-il pour encoder la séquence de mot avec le modèle

Perplexité : $2^{H(w_1, \dots, w_N)}$

= combien de mots sont possibles après un contexte donné

Lissage (smoothing)

$$P(w_1, \dots, w_N) = \prod_{I=1}^N P(w_i | w_{i-(n-1)}, \dots, w_{i-1})$$

Si une seule des probabilités est nulle, toute la séquence est nulle :

$P(\text{je bois un tesgüino avec mes amis}) = 0$

Il faut s'assurer que $P(w_i | \text{contexte})$ ne soit jamais nulle, quel que soit le contexte et w_i

Lissage (smoothing) : une solution possible

Interpolation :

$$p_I(w_n | w_{n-2}, w_{n-1}) = \lambda_3 p(w_n | w_{n-2}, w_{n-1}) + \lambda_2 p(w_n | w_{n-1}) + \lambda_1 p(w_n).$$

$$\lambda_3 + \lambda_2 + \lambda_1 = 1.$$

De multiples méthodes ont été proposées :


An empirical study of smoothing techniques for language modeling. Stanley Chen and Joshua Goodman, 1998.

Modèles de langue neuronaux




CentraleSupélec

Les précurseurs :



Bengio et al, a Neural probabilistic language model, 2003


Limite : le contexte est fixe



Mikolov et al, Recurrent neural network based language model, 2010

La régression logistique peut être vue comme un réseau de neurones très simple :

$$p(x) = \frac{1}{1 + e^{-(b+Wx)}}$$



Réseaux de neurones récurrents




CentraleSupélec

- Famille de réseaux de neurones permettant le traitement de séquences
- Les réseaux récurrents permettent de faire des prédictions pour chaque élément de la séquence d'entrée (*time step*)
- Les paramètres sont partagés entre les éléments à chaque *time step*

Réseaux de neurones récurrents

Les réseaux récurrents incluent des connexions entre les neurones des couches cachées et/ou entre les neurones de sortie et les neurones des couches cachées




Réseaux de neurones récurrents



CentraleSupélec


On peut « dérouler » un neurone récurrent selon le temps : à chaque pas de temps i , le même neurone est utilisé pour faire une prédiction en prenant en compte l'entrée courante X_i et la sa sortie au pas précédent $i-1$



Réseaux de neurones récurrents




CentraleSupélec



$$x_1, \dots, x_{t-1}, x_t, x_{t+1}, \dots, x_T$$

$$h_t = \sigma \left(W^{(hh)} h_{t-1} + W^{(hx)} x_{[t]} \right)$$

$$\hat{y}_t = \text{softmax} \left(W^{(S)} h_t \right)$$




Ces réseaux ont longtemps été difficiles à entraîner : plus le nombre de pas de temps augmente, plus il est difficile d'entraîner les neurones éloignées du pas de temps courant. C'est le problème du *vanishing gradient* (Bengio1994)

Un autre problème de ces réseaux est l'explosion numérique du gradient : dépassement des capacité numériques, saturation des neurones.

Réseaux de neurones récurrents



Pour résoudre le problème du *vanishing gradient*, un mécanisme de mémoires et de portes a été introduit dans la cellule récurrente : le modèle LSTM (*long short-term memory*) [Hochreiter1997]




Réseaux de neurones récurrents : LSTM



CentraleSupélec



RNN




LSTM

Réseaux de neurones récurrents : LSTM



CentraleSupélec

Détails des calculs :



...

$$\begin{aligned}\Gamma_f^{(t)} &= \sigma(W_f[a^{(t-1)}, x^{(t)}] + b_f) \\ \Gamma_u^{(t)} &= \sigma(W_u[a^{(t-1)}, x^{(t)}] + b_u) \\ \tilde{c}^{(t)} &= \tanh(W_c[a^{(t-1)}, x^{(t)}] + b_c) \\ c^{(t)} &= \Gamma_f^{(t)} \circ c^{(t-1)} + \Gamma_u^{(t)} \circ \tilde{c}^{(t)} \\ \Gamma_o^{(t)} &= \sigma(W_o[a^{(t-1)}, x^{(t)}] + b_o) \\ a^{(t)} &= \Gamma_o^{(t)} \circ \tanh(c^{(t)})\end{aligned}$$

Réseaux de neurones récurrents : LSTM



CentraleSupélec


Ce mécanisme, dont les paramètres sont appris, permet au réseau de choisir la longueur des dépendances utilisées pour faire les prédictions

Grace à ce mécanisme et à une méthode d'entraînement (CTC) [Graves2006], ces modèles ont pu être utilisés avec succès sur des applications réelles.

Réseaux de neurones récurrents : BiLSTM



Afin de modéliser les dépendances dans une séquence, les réseaux récurrent peuvent être utilisés dans les deux directions (voire 4 dans le cas d'une image) :




Réseaux de neurones récurrents : GRU




CentraleSupélec

Une version simplifiée des LSTM a été proposée avec des performances similaires : GRU [Cho2014]



LSTM




GRU

Modèles de langue neuronaux



CentraleSupélec

Modèle de caractères :




Modèles de langue neuronaux



CentraleSupélec

Modèle de mots:




Leonard, Language modeling a billion words, 2016.

Modèles de langue neuronaux



CentraleSupélec

Modèle de mots:




Leonard, Language modeling a billion words, 2016.

Modèles de langue : applications



CentraleSupélec


Reconnaissance de la parole



Signal acoustique




« How cold is it outside »



- Convolution Layer
- Recurrent Layer
- Fully Connected Layer

28

Traduction automatique





Recherche d'information : question answering

Stanford Question Answering Dataset (SQuAD)

Question: Which British general was killed at Khartoum in 1885?

Answer: Gordon

Context: In February 1885 **Gordon** returned to the Sudan to evacuate Egyptian forces. Khartoum came under siege the next month and rebels broke into the city, killing **Gordon** and the other defenders. The British public reacted to his death by acclaiming '**Gordon** of Khartoum', a saint. However, historians have suggested that **Gordon**...

SQuAD2.0 combines the 100,000 questions in SQuAD1.1 with over 50,000 new, unanswerable


Leaderboard

SQuAD2.0 tests the ability of a system to not only answer reading comprehension questions, but also abstain when presented with a question that cannot be answered based on the provided paragraph. How will your system compare to humans on this task?

Rank	Model	EM	F1
	Human Performance Stanford University (Rajpurkar & Jia et al. '18)	86.831	89.452
1 Sep 13, 2018	nlnet (single model) Microsoft Research Asia	74.238	77.022
2 Oct 12, 2018	YARCS (ensemble) IBM Research AI	72.670	75.493
3 Oct 13, 2018	RNANetSimple (ensemble) Anonymous	72.602	75.089

Modèles de langue : applications

Recherche d'information : question answering



Wu et al., Bidirectional Attention Flow for Machine Comprehension, ICLR 2017

Modèles de langue : applications

Reconnaissance d'écriture

Paris, le 07 Juin 2008


ARNAUD Frédéric
1 rue de la Vierge
54 760 Bayardville

Marcus Assurance
15 rue de la Vierge
75 005 Paris


Bonjour,
Je soussigné, Arnaud Frédéric, né le 04
Avril 1977, soussigné à la carte
d'assurance. Cette résiliation prendra fin
le 30 Décembre 2008.
Hors de compétence.

PERSONAL INFORMATION	
NAME	ARNAUD, Frédéric
DATE OF BIRTH	04/04/1977
DATE OF SIGNATURE	07/06/2008
ADDRESS	1 rue de la Vierge, 54760 Bayardville
CITY	BAYARDVILLE
POSTAL CODE	54760
COUNTRY	FRANCE
TELEPHONE	
EMAIL	
PROFESSION	
EDUCATION	
RELIGION	
POLITICAL AFFILIATION	
LANGUAGES	FRANCE
OTHER INFORMATION	

Amazing haircut - and there
are some damn cool earrings
I see the girl in the blue top
with blonde hair on
line 7. If you want to grab a
coffee, call me at 01029766205



Reconnaissance d'écriture



Even the bone cuff-links found beside the body, which had at first been considered as belonging to the killer, proved yet another red herring, for it was learned that they had been borrowed by Elizabeth Camp from one of her sisters. A young man from Reading named Marshall had an uncomfortable time in the presence of the coroner.