

De nouvelles perspectives dans l'analyse du langage

Prof. Jacques Savoy


chaire de linguistique computationnelle

Université de Neuchâtel




L'écrivain: automate de Jaquet-Droz (1774-1776)

Sommaire




- **Linguistique et informatique**
- L'hortogaffe!
- Loi de Zipf
- Profilage et Cie
- Déterminer l'auteur d'un écrit ou d'un roman
- 2016 : Détection des menteurs (fake news)


Langage, Langue





- Langage : système de communication le plus efficace mais il demeure complexe.
- Langue : mode d'expression propre à une communauté.
- Langue naturelle et artificielle.
- Propre à l'homme ?
 - et chez les animaux ?
 - et les plantes ?
- Formes
 - Seulement écrit et oral ?
- Linguistique et informatique ?



Domaines de la linguistique



Phonétique



Au Père Spicace,

Un grand malheur est arrivé à l'abbaye.


Pendant que l'abbé Nédicte donnait les dernières grâces, l'abbé Quille perdit l'équilibre dans l'escalier et tomba inanimé dans les bras du Père Iscope.

Un seul restait joyeux : le père Fide.

Quant à l'abbé Tise, il n'y comprenait rien. Il aurait bien voulu que le saint Plet l'aide à comprendre.

A la fin, le Père Nod et le Père Collateur servirent à boire et chacun pût se remettre de ses émotions.

Domaines de la linguistique



Phonétique : Cendrillon a un soulier en verre ou vair?

Lexique : Je suis le président.

je être/suivre le président


Syntaxe : sujet(je), verbe(suis), det(le), nom(président).

Sémantique : Etre ou suivre ?

Pragmatique : Qui est le suiveur ? Qui est le président ?

Exemple 2 : "On vit des évènements graves."

Synonymie / Polysémie




Références

Mr Major est arrivé en France aujourd'hui. **Le premier ministre** rencontrera le Président demain. **Le leader du parti conservateur** partira ensuite pour Moscou où il rencontrera Mr Gorbachev. Mme Major rejoindra **son mari** en Russie où **ce fils d'un artiste de cirque** est relativement inconnu.


Idiomes

Marcher sur des œufs (*to skate on a thin ice*).


Quand les poules auront des dents (*pigs might fly*).



Domaines de la linguistique




Famille de langues



- Origine des langues
- Diversité des langues
- Famille de langues



Diversification des langues



5 000 à 6 000 langues vivantes

2 197 en Asie

2 092 en Afrique

1 310 en Océanie

1 002 en Amérique

230 en Europe.

Seulement 600 sont écrites.

80 % de la population mondiale parle 75 langues différentes.


40 % de la population mondiale parle 8 langues différentes.

75 langues sont parlées par plus de 10 M personnes.

20 langues sont parlées par plus de 50 M personnes.


8 langues sont parlées par plus de 100 M personnes.

Identification d'une langue



1. Strč prst skrz krk
2. Mitä sinä teet?
3. Mam swoją książkę
4. Nem fáj a fogad?
5. Er du ikke en riktig nordmann?
6. Добре дошли в България!
7. 정보검색시스템
8. 我不是中国人
9. Fortuna caeca est

Evolution linguistique (main)



allemand	Hand
anglais	hand
danois	hånd
roumain	mine
italien	mano
espagnol	mano
polonais	ręka
russe	рука
irlandais	lámh
japonais	手




Famille indo-européenne

Chaque
membre
partage de
similarités

Je / moi
Tu / toi


Ich / mich
du / dich




Famille eurasiatique



LA FAMILLE EURASIATIQUE




Le français



- Langue latine (espagnol, italien, portugais, ...).
- "La plus germanique des langues romandes"
Henriette Walter
- Proto-français
- *842 : Le Serment de Strasbourg*
- Français
- 1539 : Ordonnance de Villers-Cotterêts (François I^{er})
- 1635 : Académie française (Richelieu)
- 1694 : premier dictionnaire de l'Académie

Le français ne vit pas isolé




Emprunt de mots d'autres langues

- Gaulois : crème, benne, bouc, galet, luge, ...
- Allemand : maçon, espion, hareng, bonnet, gigot, ...
- Italien : ducat, florin, piastre, alarme, sentinelle, bille, ...
- Anglais : interview, cash, rail, pedigree, sport, ...
- Russe : zibeline, vodka, tsar, ...
- Hongrois : sabre, goulasch
- Japonais : karaté, judo, sushi, ...


- Et "trop" et "guère" viennent de ?

Sommaire




- Linguistique et informatique
- **L'hortogaffe!**
- Loi de Zipf
- Profilage et Cie
- Déterminer l'auteur d'un écrit ou d'un roman
- 2016 : Détection des menteurs (fake news)

L'orthographe



- La communication est facilitée par une bonne orthographe.
- Signe de sérieux (compétence).
- Complexité de la relation entre la phonétique et la graphie dans certaines langues (dont le français ou l'anglais).
- Intérêt relativement récent (Révolution française).
- Favorisé en France.
- Mais en perdition ?


L'orthographe XVIIIe



Madame de Sévigné (XVIIIe)

"Monsieur vous me permettes de souhaiter la paix car
je trouve avec votre permission qu'une heure de
Conversation vaut mieux que cinquante lettres, quand
vous serez icy et que j'auray l'honneur de vous voir je vous
feray demeurer d'accort que la querre est vne fort sott
chose ..."

Sur les réseaux sociaux




Toi t'est un qui n'a rien vue

Toi t'est un qui n'a rien vue contre le FCC. Je te rappelle que contre le fcc sur 11 joueur sur le terrain il y avait que 4 joueurs licencié. Sinon c'était des essais pour voir le niveau des nouveaux arrivées.

FC Bosna

fc bosna j aisspaire que momo revienne sest le seule qui peux nous faire monté comme entreneure


Est-ce si simple ?




- Des règles simples
- Correspond à l'étymologie
- Invariable dans le temps

- En perdition avec les réseaux sociaux ?
- "Avec leurs acronymes, smileys et émoticons, les jeunes ne connaissent plus l'orthographe!"

Variations



- Variantes possibles :
 - yogurt, yoghurt, yoghourt.
 - gnôle, gnole, gniole, gnaule, niaule.
- Avec des noms propres
 - Oscar vs. Oskar.
 - Taylor vs. Tailor.
 - Katherine vs. Katherin vs. Catherine vs. ...
 - Shaksper vs. Shakspere vs. Shakspeare vs. Shakespeare, ...




Variations temporelles

- Orthographe correcte se modifie :
 - arcs-boutants (1694)
 - arc-boutants (1718)
 - arcs-boutants (1740)
 - arc-boutants (1762)
 - arcs-boutants (1835)
- L'influence des grands écrivains
Chinois & Anglois → Anglais (Voltaire)

F. de Closets: Zero faute. L'orthographe, une passion française. Mille et Une Nuits, Paris, 2009.

Etymologie



- Relation pas évidente...
 - hauteur → altus
 - pomme → poma
 - huile → olea (et les autres langues latines)
- Accents et prononciation (pas toujours)
 - pôle et police → pas de différence
 - pêcheurs et pécheurs → pas de différence
- Accent indique une lettre perdue
 - âne → asinus
 - théâtre → theatrum
- Arbitraire (**a**percevoir et **app**araître)

Réforme de l'orthographe



Ancienne

pique-nique
porte-clé
auto-stop
mille-feuille
ping-pong

Nouvelle

piquenique
porteclé
autostop
millefeuille
pingpong

Ancienne

a priori
statu quo
hot-dog
cow-boy
week-end

Nouvelle

apriori
statuquo
hotdog
cowboy
weekend

québécois
événement
edelweiss
veto

québécois
évènement
édelweiss
véto

crémerie
diesel
revolver

crèmerie
diésel
révolver


chariot
eczéma
relais

charriot
exéma
relai

combatif
nénuphar

combattif
nénufar

Et la grammaire



Accord du participe passé

sans auxiliaire les chats **lavés** mangent.

avoir (c.o.d.) Vous avez **envoyé** une lettre. Je l'ai bien **reçue**.

avec infinitif L'histoire que j'ai **entendu raconter**.

La cantatrice que j'ai **entendue chanter**.

(les deux sont correctes, dès 1990)

avec en (invar.) J'ai **cueilli** des fraises et j'*en* ai **mangé**.

Ses ordres, s'il *en* a **donnés** ne me sont pas **parvenus**.

être (sujet) Les chats sont **lavés**.


"se" est c.o.d. Les chats se sont **lavés**.

"se" est c.o.ind. Les chats se sont **lavé** les pattes.

que faire ? Les chats de Marie que Jean a **vus (vue)** sont **lavés**.

Jean a vu les chats (ou Marie)?

Linguistique computationnelle



Trouver et analyser des régularités dans la langue.


Aspects plus quantitatifs.

Disposer d'un corpus pour l'analyse


- Journaux
- Débats parlementaires
- Réseaux sociaux

- Google N-Gram



Google N-Gram Viewer




The United States are/have



Google N-Gram Viewer





Idée de progrès



between 1900 and 2000 from the corpus French with smoothing of 3 .

Search lots of books





Et Internet

Google Books Ngram Viewer

Graph these comma-separated phrases: case-insensitive

between and from the corpus with smoothing of [Search lots of books](#)



(click on line/label for focus)

Sommaire



- Linguistique et informatique
- L'hortogaffe!
- **Loi de Zipf** (une langue étrangère, c'est très simple!)
- Profilage et Cie
- Déterminer l'auteur d'un écrit ou d'un roman
- 2016 : Détection des menteurs (fake news)

La loi de Zipf




Classons les mots d'après leur fréquence d'occurrence, du plus fréquent au moins fréquent.


Quel mot est le plus fréquent en français ?

Une illustration du principe du moindre effort.


Ces mots sont si fréquents qu'ils passent inaperçus.



Rang	Mot	Fréquence rel.	cumulée
1	de	5,48 %	5,48 %
2	la	3,08 %	8,56 %
3	l	2,35 %	10,91 %
4	le	2,34 %	13,25 %
5	à	1,98 %	15,23 %
6	les	1,90 %	17,13 %
7	et	1,72 %	18,85 %
8	des	1,69 %	20,54 %
9	d	1,59 %	22,14 %
10	en	1,38 %	23,52 %
11	du	1,27 %	24,79 %
12	a	1,19 %	25,98 %
13	un	1,14 %	27,12 %
14	une	0,97 %	28,09 %
15	est	0,81 %	28,90 %
16	dans	0,77 %	29,67 %



Rang	Mot	Fréquence rel.	cumulée
1	der	3,46 %	3,46 %
2	die	3,44 %	6,90 %
3	und	2,13 %	9,02 %
4	in	1,78 %	10,80 %
5	den	1,29 %	11,93 %
6	von	0,95 %	12,88 %
7	das	0,95 %	13,84 %
8	mit	0,84 %	14,68 %
9	im	0,81 %	15,49 %
10	zu	0,79 %	16,28 %
11	für	0,76 %	17,05 %
12	des	0,70 %	17,75 %
13	auf	0,69 %	18,43 %
14	sich	0,65 %	19,09 %
15	dem	0,62 %	19,70 %
16	ein	0,60 %	20,30 %



Rang	Mot	Fréquence rel.	cumulée
1	il	6,0 %	6,0 %
2	di	3,18 %	9,18 %
3	e	2,81 %	12,03 %
4	essere	2,80 %	14,82 %
5	che	2,48 %	17,31 %
6	a	1,90 %	19,21 %
7	avere	1,87 %	21,08 %
8	un	1,69 %	22,77 %
9	del	1,64 %	24,41 %
10	non	1,61 %	26,02 %
11	in	1,29 %	27,31 %
12	al	1,09 %	28,40 %
13	per	1,05 %	29,45 %
14	si	1,04 %	30,49 %
15	una	1,04 %	31,53 %
16	con	0,84 %	32,37 %

Sommaire



- Linguistique et informatique
- L'hortogaffe!
- Loi de Zipf
- **Profilage et Cie**
- Déterminer l'auteur d'un écrit ou d'un roman
- 2016 : Détection des menteurs (fake news)

Analyse des écrits




Peut-on distinguer un écrit rédigé par un homme de celui écrit par une femme ?

Par exemple, écrivez le récit de votre dernier voyage.

Peut-être cela n'est pas vraiment possible...


Examinons quelques cas extraits des blogs (votre journal personnel sur le Web).



Exemple : Ecrit par ?

Un homme ou une femme ?
et pourquoi ?


Hier nous avons eu notre deuxième compétition de jazz. Dieu merci on n'a pas été évalué... Nous étions si mauvais. Comme, j'avais tellement honte, je ne voulais même plus parler à personne après. Je me sentais tellement en colère, et je voulais pleurer, mais ... bon c'est passé.



Exemple : Ecrit par ?

Un homme ou une femme ?
et pourquoi ?


Hier *nous* avons eu notre deuxième compétition de jazz. Dieu merci on *n'a pas* été évalué... *Nous* étions si *mauvais*. Comme, *j'*avais tellement honte, *je* ne voulais même plus parler à personne après. *Je* me sentais tellement en *colère*, et je voulais *pleurer*, mais ... bon c'est passé.



Exemple : Ecrit par ?

Un homme ou une femme ?
et pourquoi ?

Mon super patron avait accepté de me laisser une semaine de «travail». Il m'a finalement rendu mon rapport après huit jours fous! Maintenant, je n'ai que le reste de la semaine et une semaine entière après mes vacances pour finir ce fichue travail.




Exemple : Ecrit par ?

Un homme ou une femme ?
et pourquoi ?

Mon super *patron* avait accepté de me laisser une *semaine* de «*travail*». Il m'a finalement rendu mon *rapport* après huit *jours* fous! Maintenant, je n'ai que le *reste* de la *semaine* et une *semaine* entière après mes *vacances* pour finir ce fichue *travail*.

Genre (Schler *et al.*, 2005)



Termes	Hommes	Femme
travail	68.1 ± 0.6	56.5 ± 0.5
argent	43.6 ± 0.4	37.1 ± 0.4
sports	31.2 ± 0.4	20.4 ± 0.2
tv	21.1 ± 0.3	15.9 ± 0.2
sexe	32.4 ± 0.4	43.2 ± 0.5
famille	27.5 ± 0.3	40.6 ± 0.4
nourriture	23.9 ± 0.3	30.4 ± 0.3
amis	20.5 ± 0.2	25.9 ± 0.3
dormir	18.4 ± 0.2	23.5 ± 0.2
pos-émotions	248.2 ± 1.9	265.1 ± 2
neg-émotions	159.5 ± 1.3	178 ± 1.4

Fréquence (dans les blogs) pour 10 000 mots (et erreur standard)


Genre



Femmes	Hommes
Pronoms	Articles
Négations	Adjectifs
Emotions	Noms
Mots cognitifs	Prépositions
Mots sociaux	Mots longs
Verbes	Nombres
et, dans, pour, avec	Gros mots
	Technologies

Différences possibles, mais le rapport signal / bruit est faible !

Plagiat ?



Plagiat ?

Un vrai problème...

Swisscom 08:33 87%


< News

Suisse Il y a 10h

Uni: les «ghostwriters» ont toujours autant la cote



Un nombre croissant d'universitaires en Suisse engagent une tierce personne pour qu'elle rédige leurs travaux scientifiques. Consciente du problème, l'Uni de Saint-Gall vient de déposer plainte.



Plagiat ?

J.F. Kennedy, 1961

“Ask not what your country can do for you, ask rather what you can do for your country”.

W. Harding, 1923


“We need to be thinking not so much of what the country can do for us but what we can do for our country”.

P. St. John, 1930s (headmaster of Choate)

“It’s not what Choate does for you, but what you can do for Choate”.

J. Humes: *Confessions of a White House Ghostwriter: Five Presidents and Other Political Adventures*. Regnery Publ., 1997.

Les réseaux sociaux



Sylwester, K., & Purver, M. 2015. *Twitter Language Use Reflects Psychological Differences between Democrats and Republicans*. PLoS


Social Networks



	Republicans	Democrats
I, me (je)		+
We, our (nous)	+	
jurons		+
émotions positives		+
émotions négatives	=	=
religion	+	
sentiments		+


Sylwester, K., & Purver, M. 2015. *Twitter Language Use Reflects Psychological Differences between Democrats and Republicans*. PLoS

Sommaire




- Linguistique et informatique
- L'hortogaffe!
- Loi de Zipf
- Profilage et Cie
- **Déterminer l'auteur d'un écrit ou d'un roman**
- 2016 : Détection des menteurs (fake news)

Attribution d'auteur



- Etant donné un ensemble de textes dont les auteurs sont certains (disons que l'on a des textes de quatre auteurs distincts), on dispose d'un nouveau texte (un roman, une pièce de théâtre) dont l'auteur est inconnu (ou douteux), pouvez vous me donner le véritable nom de ce nouveau texte (extrait ou non des 4 auteurs que l'on dispose).
- Lettre ou courriel menaçant
- Revendication d'un attentat
- Testament
- Œuvre littéraire (le cas Elena Ferrante)



Qui est l'auteur ?

Comme auteurs possibles : John F. Kennedy, B. Obama, A. Lincoln. Attribuez chaque texte à son auteur.


Texte 1: “Il y a quatre-vingt sept ans, nos pères donnèrent naissance sur ce continent à une nouvelle nation conçue dans la liberté et vouée à la thèse selon laquelle tous les hommes sont créés égaux.”

Texte 2: “Yes, we can.”

Texte 3: “Mes chers compatriotes, ne demandez pas ce que votre pays peut faire pour vous, demandez ce que vous pouvez faire pour votre pays.”

Texte 4: “Ich bin ein Berliner.”

A la poursuite d'Elena...



Problème classique en attribution d'auteur :
Etant donné un texte, qui l'a écrit ?

Avec Elena Ferrante, un intérêt mondial.

1992: Le premier roman: *L'amore molesto* (film en 2007)
2014 : *L'Amica geniale*


A la poursuite d'Elena...




Problème classique en attribution d'auteur
Etant donné un texte, qui l'a écrit ?

Avec Elena Ferrante, un intérêt mondial

1992: Le premier roman: *L'amore molesto*
2014 : *L'Amica geniale*




L'affaire Molière-Corneille



- Jean Baptiste Poquelin (1622-1673)
- 1645-1659 (14 ans).
années difficiles, production faible.
- 1659-1673 (14 ans) production
abondante, comédien, directeur du
théâtre du Roi.
- 1658 Corneille & Molière à Rouen
- *Psyché* (1671), pas de doute, les deux
auteurs ont écrits ensemble.
- Le droit d'auteur a un sens différent.
- Pierre Louys (octobre 1919) sur le style
et la versification.




Attribution d'auteur




- Notre problème : retrouver le véritable auteur d'un roman ou pièce de théâtre.
- Chaque auteur a-t-il /elle un style personnel ?
- Pourquoi utiliser un nom de plume ?
- Dans quel contexte ?

- Quelques cas en littérature (Ferrante n'est pas unique).
- L'affaire Molière-Corneille
- Shakespeare
- et plus récemment...

Shakespeare



- Est-ce que Shakespeare a bien écrit toutes les pièces ?
 - Plusieurs auteurs ont été nommés Bacon, Marlowe ou Giovanni Florio.
 - “Shakespeare” est peut-être un nom-de-plume pour un groupe d'écrivains ?
- Pièces écrites par plus d'un auteur
 - *Two Noble Kinsmen* – Shakespeare & Fletcher
 - *Edward III* – Shakespeare? & Kyd?
 - *Titus Andronicus* – Shakespeare & Peele?
 - *Henry VIII* – Shakespeare & Fletcher?
 - *Timon of Athens* - Shakespeare & Fletcher?



Gary – Ajar en France

- Romain Gary (1918-1980)
Romancier français (Roman Kacew).
- Emile Ajar apparaît en 1973 avec
le roman *Gros-Câlin*
“un nouvel style” rapporte la presse.
- 1974: débute la recherche pour trouver qui est “Ajar”.
- 1975: Ajar reçoit le prix Goncourt (*La Vie devant soi*).
- 1975: le cousin de Gary est-il “Ajar” ?
- 1980: R. Gary écrit qu'il est le véritable E. Ajar.






Le cas Galbraith–Rowling


- Depuis 2007, on dit que J.K. Rowling (Harry Potter) désire écrire un roman policier.
- *The Cuckoo's Calling* est publié le 4 avril 2013 sous le nom de Robert Galbraith.
- Qui est ce R. Galbraith?
- Le 13 juillet 2013, *The Sunday Times* indique que J.K. Rowling est le véritable auteur de ce roman.





Style et ordinateur

Lemma	Carofiglio	De Luca	Ferrante	Starnone
il	4,18 %	5,86 %	4,33 %	4,55 %
di	2,82 %	2,80 %	2,55 %	2,56 %
e	2,43 %	2,31 %	2,13 %	2,14 %
essere	2,65 %	2,11 %	2,07 %	2,06 %
che	2,15 %	1,59 %	2,36 %	2,10 %
a	1,44 %	1,87 %	1,92 %	1,65 %
avere	1,73 %	1,11 %	1,54 %	1,70 %
un	1,52 %	1,60 %	1,12 %	1,25 %
del	1,25 %	1,31 %	1,10 %	1,21 %
non	1,52 %	1,47 %	1,42 %	1,23 %



Distance de Labbé

Texte A

la bocca del
lupo.

la: 1
bocca: 1
del: 1
lupo: 1


Texte B

la bocca del
leone.

la: 1
bocca: 1
del: 1

leone: 1


$$\text{Dist}(A,B) = (|1-1| + |1-1| + |1-1| + |1-0| + |0-1|) / (2 \cdot 4) = 2 / 8 = 0,25$$



Distance de Labbé


- Chaque roman correspond à un texte.
- Prendre tous les mots ayant une fréquence > 2 .
- Les romans singées E. Ferrante.

Id	Année	Titre
46	1992	L'amore molesto
47	2002	I giorni dell abbandono
48	2006	La figlia oscura
49	2011	<i>L'amica geniale</i>
50	2012	<i>Storia del nuovo cognome</i>
51	2013	<i>Storia di chi fugge e di chi resta</i>
52	2014	<i>Storia della bambina perduta</i>



Distance de Labbé (lemmes)

Rang	Distance	Id	Titre	Id	Titre	
1	0.111	51	Ferrante	52	Ferrante	
2	0.121	50	Ferrante	51	Ferrante	
3	0.128	49	Ferrante	50	Ferrante	
4	0.134	50	Ferrante	52	Ferrante	
5	0.142	145	Veronesi	147	Veronesi	
6	0.146	42	Faletti	44	Faletti	
7	0.150	43	Faletti	44	Faletti	
8	0.154	41	Faletti	42	Faletti	
9	0.157	42	Faletti	43	Faletti	
10	0.161	38	De Silva	39	De Silva	
11	0.161	49	Ferrante	51	Ferrante	
...						
33	0.193	52	Ferrante	132	Starnone	<-
38	0.195	51	Ferrante	131	Starnone	<-
41	0.196	51	Ferrante	132	Starnone	<-
...						
84	0.216	25	Carofiglio	147	Veronesi	Erreur




Mais un modèle a ses limites ...

Le classement FIFA (octobre 2017)

Rang	Pays
1	Brésil
2	Allemagne
3	Argentine
4	Suisse
5	Pologne
6	Portugal
7	Chili
8	Colombie
9	Belgique
10	France

Et les prochains ?




Evidence #2

- Un texte = tous les romans écrits par un même auteur.
- Ignorez les mots apparaissant une ou deux fois.
- Appliquer la distance de Labbé (min: 0; max: 1).

Conclusion

1. Dist (Ferrante, Starnone) = 0,177
2. Dist (Picollo, Veronesi) = 0,220
3. Dist (Nesi, Veronesi) = 0,226
4. Dist (De Silva, Veronesi) = 0,227




Evidence #3: Le test Zeta


- Etablir une liste des mots employés souvent par Starnone mais peu par les autres auteurs. C'est la liste X.
(par exemple, *volta, er, sua, solo, poi, senza, della, quando, ...*)
- Et une liste des mots utilisés fréquemment par les autres auteurs (sans considérer les romans de Ferrante). C'est la liste Y.
(par exemple, *volto, muro, strana, nonstante, propria, ognuno, ...*)
- Prenons un passage de 4 000 mots d'un roman (*L'amica geniale* de Ferrante). Combien de mots appartiennent à la liste X et à la liste Y ?

Le test Zeta

Clustering by authors




9 % des mots
utilisés
souvent par
les autres
Liste Y



Le test Zeta


Clustering by authors




Contre-exemple


Carofiglio

Style différent de Ferrante






Les auteures



Large distance entre *Ferrante* et les autres auteures

(c) A. Tuzzi, 2018




Les auteur-e-s de Campania



Distance très faible
entre *Ferrante* et
Starnone

(c) A. Tuzzi, 2018



Nous découvrons que ...

- Evidence #1
Roman par roman
Storia Della Bambina Perduta proche de *Lacci*
- Evidence #2
Par auteur: Ferrante très proche de Starnone
- Evidence #3 (Zeta)
L'amica geniale a un vocabulaire
proche de celui de Starnone
- Evidence #4 (Homme et Campania)
Toujours Starnone!

Domenico Starnone



Analyse des mots




Mots	Corpus	Ferrante (6,5%)	Starnone (6,4%)
padre	9 815	833 (8,5%)	1 170 (11,9%)
madre	8 246	1 104 (13,4%)	762 (9,2%)
perciò	1 263	222 (17,6%)	254 (20,1%)
persino	1 351	266 (19,7%)	205 (15,2%)
temere	1 345	274 (20,4%)	207 (15,4%)
tono	2 135	421 (19,7%)	286 (13,4%)
<i>strunz</i>	85	18 (21,2%)	63 (74,1%)

Vérification




- Est ce que cette conclusion est falsifiable?
- Eliminons Starnone de notre corpus...
- Appliquons nos modèles pour recherche le véritable auteur.
- 12 noms apparaissent au moins une fois au premier rang :
Balzano, Mazzucci, Milone, Tamaro, Veronesi,
Brizzi, Carofiglio, Giordano, Fois, Murgia, Raimo, Sereni

Sommaire



- Linguistique et informatique
- L'hortogaffe!
- Loi de Zipf
- Profilage et Cie
- Déterminer l'auteur d'un écrit ou d'un roman
- **2016 : Détection des menteurs (fake news)**

2016 : Election aux Etats-Unis



Un candidat hors norme apparaît: D. Trump.

Il gagne les primaires républicaines.

Et gagne l'élection le 8 novembre 2016



Donald Trump – Parti républicain

Colistier : Mike Pence

Voix 62 984 828



Grands électeurs 304



Hillary Clinton – Parti démocrate


Colistier : Tim Kaine

Voix 65 853 514




Grands électeurs 227


2016 : Election aux Etats-Unis



Evolution of the number of queries sent in the US with the candidate name




Discours électoral



- Comment gagner une élection ?
- Communication démontrant les qualités du candidat.
- Homme fort (un dur à cuire et pas une lavette).
- Connaissant les problèmes et les solutions.
- Paraître honnête avec de l'empathie (mais juste un peu).

- Parler direct et franc: Vers la simplicité!
- Par un lexique choisi, un rythme dans les phrases, ...

- Mots courts, phrases courtes, simplissime, à la tweet




Mots très fréquents

Les lemmes les plus fréquents dans les primaires.
Le Je/moi et le Nous.

	Bush	Cruz	Trump	Clinton	Sanders
1e	be	be	be	be	be
2e	the	the	I	the	the
3e	to	and	the	to	I
4e	we	to	we	I	to
5e	that	I	and	and	and

Savoy J. (2018). Analysis of the style and the rhetoric of the 2016 US presidential primaries. *Digital Scholarship in the Humanities*, 33(1), 143-159 .

Simplicité




- Pourcentage de mots complexes (Big Words, BW)
- Hypothèse : les mots longs sont plus complexes.


$$BW = \frac{|\#longueur(mots) > 5|}{|\#de mots|}$$


“One finding of cognitive science is that words have the most powerful effect on our minds when they are simple. The technical term is basic level. Basic-level words tend to be short. ... Basic-level words are easily remembered; those messages will be best recalled that use basic-level language.” (Lakoff & Wehling, 2012, p. 41).

Simplicité



Comparison of Mean sentence length vs.
Percentage of big words (in %) (longer than 6 letters)





Mesures stylistiques

Transcrits des débats des primaires.


LMP : Longueur moyenne des phrases.

BW : % de mots complexes.

LD: densité des mots porteurs de sens.

	Bush	Cruz	Trump	Clinton	Sanders
LMP	17,3	19,4	13,7	20,5	19,7
BW	24,4 %	26.4 %	18,3 %	24,1%	26,4%
LD	40,7 %	44,6 %	36,6 %	40,4 %	43,6 %

Savoy J. (2018). Analysis of the style and the rhetoric of the 2016 US presidential primaries. *Digital Scholarship in the Humanities*, 33(1), 143-159.



Phrases caractéristiques

D. Trump, Speech, Sept 13th, 2016


“American cars will travel the roads, American planes will soar in the skies, and American ships will patrol the seas.”

D. Trump, TV debate, March 10th, 2016

“They don't like seeing bad trade deals, they don't like seeing higher taxes, they don't like seeing a loss of their jobs where our jobs have just been devastated.”

H. Clinton, Interview on CNN, February 24th, 2016



“So what people talk to me about is how I'm going to get incomes up, how I'm going to make sure the Affordable Care Act works, and get prescription drug costs down, and make college affordable and relieve student debt.”



Mensonge et Fake news

- Énoncé délibéré d'un fait que l'on sait contraire à la vérité.
- Nouvelles trompeuses, information fallacieuse, infox.
- *Fake news* : nouvelle qui est intentionnellement fausse, mais vérifiable, pour induire en erreur le lecteur (ou le consommateur).
- Propagande ?
- Et la satire, moquerie, canular ?

Photos / Images



LA VRAIE
MARINE LE PEN
UNE BOBO CHEZ LES FACHOS





Photos / I

- Exemples

@realDonaldTrump Poor Jeb. I could've sworn I saw him outside Trump Tower the other day! pic.twitter.com/EMelEdsinX
4:42 PM - 22 Jan 2016



RETWEETS

46

LIKES

42



Dans un document ?

Les faux ont toujours existés.



Donation de Constantin : L'empereur Constantin I^e (4^e siècle) transfère l'autorité sur Rome et la partie occidentale de l'empire romain au pape.

En 1439, Lorenzo Valla conclut que ce document est une contrefaçon (présence de termes anachroniques indiquant un texte écrit au 8^e siècle).

Evidences externes : analyse papier, encre, écriture manuscrite, contexte historique, ...

Sur Internet



Donald J. Trump 

@realDonaldTrump

 Follow



Terrible! Just found out that Obama had my "wires tapped" in Trump Tower just before the victory. Nothing found. This is McCarthyism!

RETWEETS

50,923

LIKES

144,493



3:35 AM - 4 Mar 2017


 49K

 51K

 144K

Shu K., Silva, A., Wang, S., Tang, J., Liu, H. (2017). *Fake News Detection on Social Media: A Data mining Perspective*. Proceedings SIGKDD Explanatory Newsletter, 19(1), 22-36.

Fact-checking



Donald J. Trump 

@realDonaldTrump

Follow




We do have a Trade Deficit with Canada, as we do with almost all countries (some of them massive). P.M. Justin Trudeau of Canada, a very good guy, doesn't like saying that Canada has a Surplus vs. the U.S. (negotiating), but they do...they almost all do...and that's how I know!

6:29 AM - 15 Mar 2018

16,902 Retweets 78,984 Likes






Mensonge ?

- Si on analyse une histoire, le menteur a tendance à :
 - écrire une histoire plus courte;
 - utiliser des mots courts et phrases courtes;
 - moins de détails, moins de nombres (moins précis);
 - moins de conjonctions (mais, sauf), moins de références au temps, lieu, mouvement;
 - plus d'émotions;
 - plus de mots cognitifs (penser, croire, ...);
 - plus de certitude, plus de références aux autres;

Pennebaker, J.W. (2011). *The Secret Life of Pronouns. What our Words say about us.* New York: Bloomsbury Press.

Vrai ou Faux ? Expérience 1\$




“No, I didn't take your dollar.”

“I don't believe in stealing. I did it once a long time ago; I was ... younger.”

“It really offends me that you would accuse me of something like that.”

“Why would I? I would never even think to look in the book to look for a dollar.”


Vrai ou Faux ?



“Mistakes were quite probably made by the administrations in which I served.” Henry Kissinger


“I'm going to say this again: I did not have sexual relations with that woman, Miss Lewinsky.” Bill Clinton

“I want to state clearly and without qualification: I did not take steroids, human growth hormone, and any other banned substances.” Un cycliste américain




Le cas Stephen Glass

- Journaliste au *New Republic Magazine* (NY).
- Déc. 1995 à mai 1998, 41 longs articles et sur différents thèmes dans un style émouvant et avec des citations colorées.
- Une étoile montante du journal.
- Mais six articles sont complètement faux et 21 autres largement imaginaires (14 authentiques).
- Détection automatique : taux de succès 60 à 65%.



Raisons : contexte sociétal


1. Préférence pour les nouvelles brèves;
2. Alphabétisation fonctionnelle (littératie)
(45 % en France, Italie, US (OCDE));
3. Se forger une opinion via ses amis
(biais de représentativité);
4. Biais de confirmation (répétition implique la véracité).
5. Les communautés jouent le rôle de relais,
d'amplificateur. La répétition du message est
important.



(Re)Diffusion des mensonges

- Comment obtenir une large diffusion ?
 - Nombre de personnes sur tweeter (2,6 milliards);
 - Recherche des nouvelles via ces réseaux (62 % aux US).
- Les réseaux sociaux :
 - gratuits;
 - rapides;
 - faciles à utiliser;
 - faciles à propager;
 - pas d'intermédiaire (contrôle, vérification);

Exemples de communautés




Chemtrails	Théorie du complot
Vaccin et autisme	Extra-terrestre
Energie libre	Reptiliens

Pizzagate (30 oct. 2016, contre H. Clinton (4 déc. 2016))

Quattrociocchi, W. (2016). *Fake Online News Spreads Through Social Echo Chambers*. Scientific American. November 2016.

Bessi, A., et al. (2016), *Users polarization on Facebook and Youtube* in PLOS ONE, 11 (ISSN 1932-6203)





Diffusion (Retweet) ?

Pour un tweet, les chances de retweet augmentent si :


1. Contenu surprenant
2. Emotionnel négatif (colère)
3. Conforme à notre a priori

Exemple : contenu scandaleux, négatif avec une image.
Amplification par la communauté (chambre d'écho).

En conclusion




(Tom Toles)



Exercice: Créer votre infox


Prenons une affaire,
Ajoutez une photo (ou vidéo),
Et provoquez la colère (sur un a priori)
Pierre Maudet, ...






Conclusion

- Les langues évoluent
- Et l'informatiquer
 - Facilité de diffusion (nouvelle forme d'expression (tweets))
 - Moteur de recherche (accès à l'information)
 - Correction de l'orthographe
 - Aide à la traduction
 - Qui est le véritable auteur ?
 - Profilage (publicité)
 - Détection de mensonge
- Illectronisme





Conclusion

Merci de votre attention.

Questions ?

Donald J. Trump 
@realDonaldTrump

TERRIBLE! Just found out that Prof. Savoy's conference is just FAKE NEWS. UNBELIEVABLE!

RETWEETS	LIKES
3,761	9,670

12:38 PM - 16 Oct 2018

14 4K 10K

Copyright © Liberty Classics