

# L'apport de l'analyse textuelle à la statistique d'entreprise :

*L'exploitation de 10 ans de visites d'entreprises  
par les DIRECCTE*


STATISTIQUE D'ENTREPRISE

Nicolas CAVALLO

le cnam

JMS 2015  
SESSION 3 : ANALYSE DES DONNÉES  
1<sup>er</sup> avril 2015

**DGE**  
DIRECTION GÉNÉRALE  
DES ENTREPRISES



# Les données textuelles

## Les données textuelles

- 10 ans de visites d'entreprises



a pour objectif d'accompagner les entreprises

- Plus de 400 chargés de missions visitent fréquemment des entreprises

A partir de 2004, mise en place d'un outil métier pour collecter les données issues de ces visites d'entreprises

Objectif initial

- Assurer le suivi de l'entreprise visitée

Nouvel objectif

- Exploiter ces données pour **comprendre les entreprises**

# Les visites représentent ...

PRESTATION D'ENTREPRISE

## En 10 ans,

- ✓ 60 000 visites d'entreprises
- ✓ Plus de 30 000 entreprises différentes visitées

## Chaque année :

- ✓ Jusqu'à 6 000 entreprises différentes visitées
- ✓ Plus de 5% de l'activité française concernée
- ✓ Plus de 15% des exportations françaises

# Les entreprises visitées sont ...

## Principalement des entreprises industrielles

- ✓ Plus de la moitié des entreprises visitées sont industrielles
- ✓ 1/5 de l'activité industrielle concernée par des visites chaque année
- ✓ 1/4 des exportations industrielles concernées par des visites chaque année

## Principalement des grandes entreprises

- ✓ Chaque année, 44 % des grandes entreprises concernées
- ✓ 8 % de l'activité des ETI et GE
- ✓ Plus de 15 % des exportations des ETI et GE

# Les données collectées sont ...

## Principalement des données textuelles

Données textuelles collectées pour une entreprise visitée



**Conclusion générale**  
32 000 caractères



**Points forts et faiblesses**  
4 000 caractères



**Grands donneurs d'ordres**  
200 caractères




**Clients principaux**  
200 caractères



**Projets de développement**  
200 caractères

# Les données collectées sont ...

## ...Volumineuses



- 53 640 Conclusions Générales

≈ 30 millions d'occurrences

- 17 851 Projets de développement
- 25 045 Clients principaux
- 13 205 Grands donneurs d'ordre
- 120 170 Points forts et faiblesses

≈ 3 millions d'occurrences

# La statistique textuelle

**Les données  
textuelles**

- 10 ans de visites d'entreprises

**Statistique Textuelle**

Formes	fréquence
<b>de</b>	1 795 481
<b>la</b>	757 955
<b>l</b>	687 689
<b>et</b>	678 280
<b>en</b>	569 854
<b>d</b>	566 989
<b>le</b>	549 512
<b>à</b>	538 778
<b>des</b>	503 222
<b>les</b>	437 332
<b>est</b>	330 322
<b>du</b>	319 290
<b>pour</b>	309 261
<b>un</b>	308 340
<b>une</b>	272 404
<b>a</b>	257 069
<b>entreprise</b>	240 917
<b>sur</b>	232 343

- **Analyse des formes employées dans le corpus**
- **Présentées selon la fréquence d'apparition**
- **Problèmes :**
  - ✓ Les formes mises en avant ne sont pas porteuses de sens

# Simplification du lexique

Formes	fréquence
de	1 795 481
la	757 955
l	687 689
et	678 280
en	569 854
d	566 989
le	549 512
à	538 778
des	503 222
les	437 332
est	330 322
du	319 290
pour	309 261
un	308 340
une	272 404
a	257 069
entreprise	240 917
sur	232 343



- ✓ Gérer les expressions
- ✓ Gérer les abréviations
- ✓ Lemmatisation
- ✓ Suppression des formes  
« outils » (*pronoms*, « être », « avoir », ..)

Formes « pleines »	fréquence
entreprise	273 446
société	115 339
activité	108 562
marché	99 350
chiffre_affaires	98 939
client	95 810
projet	91 466
production	84 168
produit	80 528
groupe	71 566
site	68 650
développement	64 886
mettre	55 337
commercial	52 651
permettre	52 297
réaliser	50 997
nouveau	48 474
france	43 181

# Le tableau lexical entier

Les « formes pleines »

		Entreprise	Exporter	Investir	.	.	.	.	.	...	.	.	.	.	Mot n°M
Les segments de texte	ST n°1	1	1	0	0	0	0	1	0	...	0	0	0	0	0
	ST n°2	0	0	1	0	0	0	0	0	...	0	0	1	0	0
	ST n°3	1	0	0	0	0	0	0	0	...	0	0	0	0	0
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	ST n°N	0	0	0	0	1	0	0	0	0	0	1	0	0	0

- Application sur ce tableau des méthodes d'analyses multivariées

# La conjoncture

**Les données  
textuelles**

- 10 ans de visites d'entreprises

**Statistique Textuelle**

**La  
conjoncture**

- Comprendre les effets de la crise sur les projets des entreprises

- Application de la méthode de classification ALCESTE (Reinert) aux 18 000 projets de développement renseignés entre 2008 et 2013
- **Création de 11 classes ou thématiques** principales relatives aux projets des entreprises


Exemple pour 3 classes:

Thème de la classe	Traits lexicaux typiques par classe
<b>baisse d'activité</b>	baisser / crise / difficile / commande / difficulté / situation / chiffre_affaires / charger / carnet / activité / perte / 2009 / année / subir / économique / trésorerie / financier / partiel / retrouver / conjoncture / chômage / rentabilité / 2008 / face
<b>investissement matériel</b>	investissement / production / ligne / machine / unité / modernisation / matériel / nouvelle / projet / capacité / traitement / usinage / outil / achat / acquisition / investir / peinture / découper / productivité / automatiser / bois / automatisation / installation / fabrication
<b>Prospection de marchés à l'international</b>	coface / allemagne / prospection / chine / brésil / pays / assurance / russie / amérique / japon / canada / etats_unis / espagne / inde / unir / italie / ap / suisse / user / afrique / asie / europe / royaume / belgique / maghreb / export / implantation

# 2008

*La crise n'impacte pas encore les projets*


STATISTIQUE D'ENTREPRISE



# 2009

*Les entreprises subissent la crise... et prévoient une baisse d'activité*


STATISTIQUE D'ENTREPRISE



# 2010

*La crise est mondiale... il faut se diversifier*


PRESTIGIE ENTREPRISE



# 2011

Fin de la crise ?


PRESTIGIE ENTREPRISE



# 2012

## *L'international toujours dans la tête des dirigeants*


PRESTIGIE ENTREPRISE




# 2013

*baisse des investissements et davantage de cessations...*

STATISTIQUE D'ENTREPRISE






# Prédire l'appartenance à la filière automobile

STATISTIQUE D'ENTREPRISE

- **Problématique** : très peu d'information sur les filières car la statistique publique a une approche « secteur d'activité »
- **Pour le moment** : seule l'APE (code NAF) est disponible pour cibler les entreprises d'une filière
- **Solution** :
  - ✓ Utiliser les données textuelles comme variable explicative



# Créer la base d'apprentissage

- L'information sur les filières est disponible depuis 2008, soit pour 25 232 visites d'entreprises
- Pour évaluer le pouvoir prédictif des variables textuelles on partitionne :




# Création et comparaison de 5 modèles

PRESENTATION D'ENTREPRISE



# Conclusion sur les analyses textuelles



# Conclusion sur les données textuelles

STATISTIQUE D'ENTREPRISE

## Les données textuelles sont riches

Il faut tout de même mesurer les faiblesses de l'analyse textuelle à un niveau fin (non prise en compte de la négation, fautes d'orthographe, style atypique de l'auteur, etc)



Maintenant, l'objectif est de **trouver davantage de données textuelles**

Soit en les récupérant  
(*WEB, Dans des bases déjà disponibles*)

Soit en les créant  
(*+ de réponses ouvertes dans les enquêtes*)



**Pour élargir le champ des données exploitées au sein de la statistique d'entreprise**

**Merci pour votre attention**

STATISTIQUE D'ENTREPRISE

Nicolas CAVALLO

le **cnam**

JMS 2015  
SESSION 3 : ANALYSE DES DONNÉES  
1 avril 2015

**DGe**  
DIRECTION GÉNÉRALE  
DES ENTREPRISES